

基于多视图多样性学习的联合谱嵌入聚类算法

李顺勇, 郑孟蛟, 李嘉茗, 赵兴旺

引用本文

李顺勇, 郑孟蛟, 李嘉茗, 赵兴旺. 基于多视图多样性学习的联合谱嵌入聚类算法[J]. 计算机科学, 2026, 53(1): 104-114.

LI Shun Yong, ZHENG Mengjiao, LI Jiaming, ZHAO Xingwang. Joint Spectrum Embedding Clustering Algorithm Based on Multi-view Diversity Learning [J]. Computer Science, 2026, 53(1): 104-114.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

基于超图网络嵌入的蛋白质复合体识别算法

Protein Complex Identification Algorithm Based on Hypergraph Network Embedding

计算机科学, 2025, 52(12): 102-114. <https://doi.org/10.11896/jsjcx.250900062>

基于知识图谱嵌入的异构图欺诈用户检测

Fraud User Detection Based on Heterogeneous Information Network with Knowledge Graph

Eembedding

计算机科学, 2025, 52(11A): 250400085-7. <https://doi.org/10.11896/jsjcx.250400085>

基于LLaMa3和Choquet积分的最优相似度选择集成学习方法

Selective Ensemble Learning Method for Optimal Similarity Based on LLaMa3 and Choquet Integrals

计算机科学, 2025, 52(9): 80-87. <https://doi.org/10.11896/jsjcx.250100150>

基于跨视图二部图图扩散的多视图聚类

Multi-view Clustering Based on Bipartite Graph Cross-view Graph Diffusion

计算机科学, 2025, 52(7): 69-74. <https://doi.org/10.11896/jsjcx.240500097>

基于跨结构特征选择和图循环自适应学习的多视图聚类

Multi-view Clustering Based on Cross-structural Feature Selection and Graph Cycle Adaptive Learning

计算机科学, 2025, 52(2): 145-157. <https://doi.org/10.11896/jsjcx.231100173>

基于多视图多样性学习的联合谱嵌入聚类算法

李顺勇^{1,2} 郑孟蛟¹ 李嘉茗¹ 赵兴旺^{3,4}

1 山西大学数学与统计学院 太原 030006

2 复杂系统与数据科学教育部重点实验室(山西大学) 太原 030006

3 山西大学计算机与信息技术学院 太原 030006

4 计算智能与中文信息处理教育部重点实验室(山西大学) 太原 030006

(lisy75@sxu.edu.cn)

摘要 现有的大多数多视图聚类算法仅依赖于视图间的低阶相似性信息,未能有效地捕捉数据中的高阶结构特性,且对多视图数据的多样性特征关注不足,导致聚类结果的准确性和鲁棒性受限。针对以上问题,提出了一种基于多视图多样性学习的联合谱嵌入聚类算法——JSEC。首先通过视图多样性学习,保留数据间的多样特征,从而有效去除了视图中的噪声;然后提出了一种挖掘视图高阶信息的方法,使得视图的多样性特征尽可能靠近混合相似图,从而实现不同视图信息的高效整合,实现视图间的多样性和补充性融合;最后在谱嵌入模块将视图的多样性特征矩阵融合为联合谱嵌入矩阵,通过谱聚类实现图聚类。另外,设计了一种交替迭代的方法,用于优化目标函数。在与目前最新的多视图聚类算法的对比中,JSEC算法在5个中小规模的真实数据集的3个指标上均展现出优越的性能,同时在2个大规模数据集上也有优异的表现,相比次优算法,ARI指标在不同规模数据集上分别有1.27%和2.57%的提升,从而在理论和实验上验证了所提算法的稳健性。

关键词: 多视图聚类;多样性学习;高阶信息;谱嵌入;权重学习

中图分类号 TP311.13

Joint Spectrum Embedding Clustering Algorithm Based on Multi-view Diversity Learning

LI Shunying^{1,2}, ZHENG Mengjiao¹, LI Jiaming¹ and ZHAO Xingwang^{3,4}

1 School of Mathematics and Statistics, Shanxi University, Taiyuan 030006, China

2 Key Laboratory of Complex Systems and Data Science of Ministry of Education (Shanxi University), Taiyuan 030006, China

3 School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China

4 Key Laboratory of Computational Intelligence and Chinese Information Processing of Ministry of Education (Shanxi University), Taiyuan 030006, China

Abstract Most of the existing multi-view clustering algorithms only rely on the low-order similarity information between views, fail to capture the high-order structural features in the data effectively, and pay insufficient attention to the diversity features of the multi-view data, resulting in the accuracy and robustness of the clustering results. To solve these problems, JSEC, a joint spectral embedding clustering algorithm based on multi-view diversity learning, is proposed. Through view diversity learning, multiple features between data are preserved, so as to effectively remove the noise in the view. Then, a method of mining higher-order information of views is proposed to make the diversity features of views as close as possible to the hybrid similarity graph, so as to realize efficient integration of information of different views, and realize the diversity and complementary integration of views. Finally, the diversity feature matrix of the view is fused into the joint spectral embedding matrix in the spectral embedding module, and the graph clustering is realized by spectral clustering. In addition, an alternate iteration method is designed to optimize the objective function. In comparison with the latest multi-view clustering algorithms, JSEC algorithm shows superior performance on 3 indicators of 5 medium and small scale real datasets, and also on 2 large scale datasets. Compared with the suboptimal algo-

到稿日期:2024-11-12 返修日期:2025-02-27

基金项目:国家自然科学基金(82274360);山西省基础研究计划(202303021221054, 202403021211086);山西省回国留学人员科研资助项目(2024-002);山西省留学回国人员科技活动择优项目(20250001);山西省研究生教育创新计划(2025SJ032, 2025JG006)

This work was supported by the National Natural Science Foundation of China(82274360), Fundamental Research Program of Shanxi Province, China(202303021221054, 202403021211086) and Research Project Supported by Shanxi Scholarship Council of China(2024-002), Fund Program for the Scientific Activities of Selected Returned Overseas Professionals in Shanxi Province(20250001) and Postgraduate Education Innovation Program of Shanxi Province(2025SJ032, 2025JG006).

通信作者:赵兴旺(zhaoxw@sxu.edu.cn)

rithm,ARI index has an improvement of 1.27% and 2.57% on datasets of different scales. The superiority of the algorithm is proved theoretically and experimentally.

Keywords Multi-view clustering, Diversity learning, High-order information, Spectral embedding, Weight learning

1 引言

在当今数据驱动的时代,多视图数据广泛存在于各个领域,如生物医学、计算机视觉和社会科学等领域。多视图聚类作为一种重要的数据分析方法,旨在从多个角度挖掘数据的内在结构,以实现更准确的分类和理解。例如,在计算机视觉领域,在对自然场景图像进行分类时,综合考虑颜色、纹理和形状等多视图特征的聚类结果,能够更准确地区分不同的场景类别。与传统单视图聚类难以全面捕捉数据的内在结构的特点相比,多视图聚类通过整合不同方式或来源的信息来提高聚类的准确性、鲁棒性和适用性,为数据提供更加全局和多层次的表征^[1-4]。

在多视图学习领域,许多方法已尝试通过不同策略融合多视图信息。然而,这些方法仍有进一步提升的空间。早期的加权聚合方法通过加权平均各视图的相似性矩阵来获取最终的相似性矩阵^[5-6],虽然简单易行,但往往忽略了视图之间的非线性关系和噪声影响。研究表明,基于加权聚合的方法在高维数据中,ACC可能低于40%^[7-8]。尽管深度学习方法在一定程度上克服了这些问题^[9-10],但仍面临计算复杂度高、参数调整困难等挑战,特别是在高维数据集上,ACC常低于50%^[11]。一些图优化方法已证明能有效学习数据结构,但通常侧重于局部结构建模,忽视了高阶全局结构,导致处理复杂数据或噪声数据时表现不佳,在ARI和NMI上仅能达到0.4左右,远低于高阶结构优化方法^[12]。传统图优化方法对全局信息的捕捉能力有限,无法应对高度复杂的多视图数据集,从而限制了其聚类性能。

因此,如何优化图结构、有效捕捉高阶结构,提升聚类性能和鲁棒性,成为多视图学习领域亟待解决的问题。为此,提出了一种基于多视图多样性学习的联合谱嵌入聚类算法(Joint Spectrum Embedding Clustering Algorithm based on Multi-view Diversity Learning, JSEC)。本文的主要贡献包括:

1)提出了一种可根据数据分布方式进行自适应权重更新的方法,它能根据每个视图的特性动态调整其在模型中的重要性,更好地利用多视图数据的多样性和互补性特征。

2)引入高阶结构优化思想,在传统图优化的基础上识别并优化数据的全局关系,避免了局部结构优化的局限性。

3)引入了一种多样性学习方法。该方法对于有较多噪声和异质性特征的多视图数据,能够减少多样特征的干扰,以构建更准确的图结构;通过自动调整噪声影响较大的视图权重,提升了算法在复杂数据集上的适应能力。

4)通过结合高阶结构优化和多视图学习,JSEC展现了较强的泛化能力。在高维数据、高噪声和复杂关系场景中,JSEC算法具有较高的准确性和鲁棒性。本文将视图多样性学习、高阶信息融合、谱嵌入3个部分融合在一个框架下进行联合优化,采用交替迭代最小化优化方案。实验结果表明,JSEC算法在与多个最新算法的对比中展现出较好的性能,

充分验证了其优越性。

2 相关工作

2.1 基于图的多视图聚类方法

基于图的多视图聚类算法是一类利用图结构表示多视图数据间关系的算法,图结构能很好地表达数据点间的相似性,尤其在处理多视图数据时,将这些图融合或联合使用,可以得到更好的聚类结果。现有算法^[13-15]大多通过图结构融合多视图信息,结合张量核范数或互信息最大化策略来优化聚类过程,捕捉全局和局部特征。Zhao等^[16]考虑多视图数据的邻域关系和多视图信息融合的重要性,通过引入聚类指示矩阵的方式,实现了更精准和鲁棒的聚类。此外,一些传统的方法利用图结构进行多视图数据处理。GMC^[17]通过图矩阵融合多视图;WMSMC^[18]则通过二部图划分实现视图间的关系建模;Cai等^[19]提出基于分层伪标签的图像聚类方法,通过局部平滑、自训练和低密度分离假设提升模型鲁棒性;Liu等^[20]提出基于对比共识图学习的多视图属性图聚类算法,利用图滤波除噪并保留结构,选取少量节点学习共识图,降低复杂度,采用对比正则化改进学习。尽管这些算法在不同场景下展现出一定的优势,但仍然存在计算复杂度高、对噪声敏感、无法有效捕捉高阶结构等问题,亟需进一步优化和完善,特别是在大规模、多样性数据和高噪声环境下的适应能力。

2.2 高阶信息融合

在多视图聚类中,高阶信息是指跨越局部关系限制,捕获多视图数据中全局结构关系或复杂交互模式的信息,高阶图遵循邻居的邻居也是邻居的原则。如图1所示,实线连接的两个节点之间构成了一阶近邻关系,点划线、虚线相连的节点之间分别构成了二、三阶近邻关系,它们通过各节点之间的公共节点实现了高阶信息的整合。目前的多视图聚类研究主要集中在对低阶特征的利用,而忽视了对高阶信息的挖掘,导致模型在捕捉复杂数据结构和潜在关系方面的能力受限。当前高阶信息的捕获主要是通过NMF、超图学习、隐式权重学习等方式构建高阶图^[21-25]。但是,这些方法普遍存在计算复杂度高、对噪声敏感、高阶信息融合不充分等问题,有待进一步解决。




图1 高阶近邻关系示意图

Fig. 1 Diagram of high order neighbor relationship

为了弥补上述方法存在的不足,本文将多样性学习、高阶信息融合和谱嵌入整合到同一框架下,采用交替迭代优化,有效解决多视图数据融合问题,提升聚类准确性。

3 理论知识

本章介绍了多视图聚类的视图多样性学习、高阶信息融合和联合谱嵌入融合。

3.1 符号说明

本文中使用的符号及定义如表 1 所列。

表 1 符号说明

Table 1 Symbol description

符号	定义
V	视图总数
W	用于衡量视图间多样性的矩阵
$M^v \in \mathbb{R}^{n \times d}$	第 v 个视图的初始图矩阵
$S^v \in \mathbb{R}^{n \times n}$	第 v 个视图的相似矩阵, 衡量视图内样本对间的相似性
$E^v \in \mathbb{R}^{n \times n}$	第 v 个视图的多样特征, 是通过对相似矩阵 S^v 进行分解得到的一部分
$A^v \in \mathbb{R}^{n \times n}$	第 v 个视图的一致特征, 是通过对相似矩阵 S^v 进行分解得到的一部分
γ^v	第 v 个视图的权重, 用于衡量各视图在聚类过程中的重要性程度
$f_v(W)$	第 v 个视图的混合相似图, 包含不同阶数的相似图
W_v^n	第 v 个视图的第 n 阶相似图
$F^v \in \mathbb{R}^{n \times c}$	将视图通过谱嵌入转化得到的第 v 个视图的嵌入矩阵
$F^* \in \mathbb{R}^{n \times c}$	通过融合多个视图的 F^v 得到的联合谱嵌入矩阵, 整合多视图信息
$\otimes$	哈达玛积

3.2 视图多样性学习

本文采用 K 近邻(K-Nearest Neighbors, KNN)方法构建各视图的初始相似图矩阵, 如式(1)所示:

$$S_{ij}^v = \begin{cases} \frac{e_{i,k+1} - e_{i,j}}{ke_{i,k+1} - \sum_{h=1}^k e_{i,h}}, & j \leq k \\ 0, & j > k \end{cases} \quad (1)$$

其中, $e_{ij} = \|x_i^v - x_j^v\|_2^2$ 表示两个样本点之间的距离。

多样特征是反映不同视图间特定差异和信息多样性的特征, 用于捕捉视图间的不一致性和噪声。一致特征是多视图数据中各视图间共享的核心信息, 反映了视图之间的一致性, 通过提取一致特征, 能强化不同视图间的互补性。为了整合学习视图间的一致性信息, 本文将每个视图的相似性矩阵 S^v 拆分为一致部分 A^v 和多样部分 E^v , 即:

$$S^v = A^v + E^v \quad (2)$$

目前, 大多数多视图矩阵分解方法主要关注数据中的噪声建模^[26-27], 而本文所讨论的视图多样部分 E^v 则涉及噪声与视图特定特征之间的差异。由于不同视图中的节点关系在本质上是不同的, 因此视图之间的差异可能会在相似图的各个位置出现。为确保视图之间的多样特征是稀疏的, 本文引入了文献[28]中的式(3)和式(4), 即最小化多样特征乘积之和, 用于自动识别不一致的部分。

$$\alpha \sum_{v,u=1, v \neq u}^V \text{sum}((E^v) \otimes (E^u)) \quad (3)$$

同时, 最小化每个视图内的多样特征, 即:

$$\beta \sum_{v=1}^V \text{sum}((E^v) \otimes (E^v)) \quad (4)$$

其中, α 和 β 为权衡参数。

3.3 高阶信息整合

混合相似图(Mixed Similarity Graphs, MSGs)是一种通过结合多个视图的信息来提高聚类效果的方法。文献[29]

定义了 n 阶相似图, 如式(5)所示:

$$W_v^n = W_v^{n-1} \times W W_v^1 \quad (5)$$

同时构建了一个混合相似图, 它包含了具有最多数据信息的一阶和 n 阶图。定义 $n \rightarrow \infty$ 时代价最小的混合相似图, 如式(6)所示:

$$f_v(W) = W_v^1 + W_v^n \quad (6)$$

为了结合视图中的高阶信息, 需要使一致特征 A^v 与混合相似图 $f_v(W)$ 之间尽可能接近, 并引入视图权重:

$$\min_{\gamma^v, A^{(1)}, \dots, A^{(V)}} \sum_{v=1}^V \gamma^v \|f_v(W) - A^v\|_F^2 \quad (7)$$

3.4 联合谱嵌入融合

联合谱嵌入是将多个视图的一致特征通过谱分解融合到统一低维空间的过程, 用于捕捉视图间的全局一致性和互补性, 从而构建更精确的聚类表示。为了保证在多视图聚类过程中相似性矩阵中的连通分量个数等于类簇个数, 确保解的唯一性和稳定性, 本文引入了秩约束 $\text{rank}(L^v) = n - c$, 其中 $L^v = D^v - S^v$, D^v 是 S^v 的度矩阵。对于复杂的优化问题, 直接添加此秩约束求解难度较大, 根据 K-F 定理^[30]:

$$\sum_{i=1}^c \sigma_i(L^v) = \min_{(F^v)^T F^v = I_c} \text{tr}((F^v)^T L^v F^v) \quad (8)$$

其中, $\sigma_i(L^v)$ 是 L^v 的第 i 个最小特征值, 因此将秩约束问题转化为最小化问题, 如式(9)所示:

$$\min_{F^v} \text{tr}((F^v)^T L^v F^v) \quad (9)$$

每个视图都可以得到其对应的谱嵌入表示 F^v 。同时, 为了挖掘数据中潜在的一致性和互补性, 将多个视图的 F^v 融合成一个联合谱嵌入矩阵 F^* , 以提供更多的划分信息, 减少冗余和噪声。在此融合过程中考虑不同视图的重要性, 引入视图权重 γ^v 。为了保证解的有效性, 本文引入一个正则化项, 如式(10)所示:

$$\min_{F^v, F^*} \gamma^v \|F^v - F^*\|_F^2 + \lambda \sum_{v=1}^V \|F^v\|_F^2 \quad (10)$$

其中, λ 是自由参数, 用于平衡谱嵌入的重构误差与模型复杂度。

4 基于多视图多样性学习的联合谱嵌入聚类算法

为了解决现有的大多数算法对视图的多样性信息挖掘不够充分、未能充分利用视图中的高阶信息、多视图存在多样性导致聚类结果不稳定等问题, 本文提出了 JSEC 算法。

4.1 JSEC 算法

为了提高多视图聚类性能, 本文提出了一种将多视图多样性学习、高阶信息融合和谱嵌入联合学习的框架。图 2 展示了本文的算法框架。




图 2 模型框架

Fig. 2 Model framework

JSEC 算法主要分为 3 部分:在多样性学习部分,通过 KNN 得到视图的相似性矩阵,将其分解为一致特征和多样特征;在高阶信息融合部分,将一致特征与构造的混合相似图 $f_v(\mathbf{W})$ 进行对比,最小化它们之间的差距;在谱嵌入部分,将每个视图的一致特征 $\mathbf{A}^v$ 转化为各视图嵌入矩阵 $\mathbf{F}^v$,然后根据 $\mathbf{F}^v$ 与 $\mathbf{A}^v$ 的差异引入视图权重 γ^v ,将其融合为联合谱嵌入矩阵 $\mathbf{F}^*$,从而获取最终的聚类结果。在目标函数中,利用经过处理的一致特征构建目标图,而不是依赖原始图,以提高聚类性能。将式(3)、式(4)、式(7)、式(9)、式(10)合并,得到目标函数:

$$\begin{aligned} \min_{\gamma^v, \mathbf{A}^1, \dots, \mathbf{A}^V, \mathbf{F}^v, \mathbf{F}^*, \gamma^*} & \sum_{v,u=1}^V \mathbf{W}_{vu} \gamma^v \gamma^u \text{tr}((\mathbf{S}^v - \mathbf{A}^v)(\mathbf{S}^u - \mathbf{A}^u)^T) + \\ & \sum_{v=1}^V \gamma^v \|\mathbf{A}^v - f_v(\mathbf{W})\|_F^2 + \text{tr}((\mathbf{F}^v)^T \mathbf{L}^v \mathbf{F}^v) + \\ & \sum_{v=1}^V \gamma^v \|\mathbf{F}^v - \mathbf{F}^*\|_F^2 + \lambda \sum_{v=1}^V \|\mathbf{F}^v\|_F^2 \quad (11) \\ \text{s. t. } & \gamma^v \geq 0, \mathbf{S}^v \geq \mathbf{A}^v \geq 0, (\mathbf{F}^v)^T \mathbf{F}^v = \mathbf{I}_C, (\mathbf{F}^*)^T \mathbf{F}^* = \mathbf{I}_C, \\ & \mathbf{1}^T \gamma^v = 1 \end{aligned}$$

其中, $\mathbf{W}$ 是一个衡量视图间及视图内多样性的矩阵, $\mathbf{W}$ 的对角元素为 β , 非对角元素为 α 。第一项为多样性学习部分,第二项为高阶信息融合部分,第三、四项为谱嵌入部分,最后一项为正则化项,用于避免平凡解。将得到的联合谱嵌入矩阵 $\mathbf{F}^*$ 使用 K-means 算法对数据进行最终的聚类。

4.2 优化过程

目标函数式(11)难以直接求解,因此,本文采用交替迭代最小化的方案对目标函数进行优化。分别固定其他变量,更新 $\mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V, \mathbf{F}^v, \mathbf{F}^*, \gamma^v$ 。将此优化问题分解成 4 个子问题,每次优化一个子问题,迭代此过程并不断优化,直到目标函数收敛。

4.2.1 固定 $\mathbf{F}^v, \mathbf{F}^*, \gamma^v$, 更新一致特征矩阵 $\mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V$

将目标函数式(11)展开,得到与 $\mathbf{A}^v$ 相关的项,对 $\mathbf{A}^v$ 求导并将导数设置为 0,可以得到以下矩阵方程等式:

$$\gamma^v \mathbf{A}^v + \sum_{v=1}^V \mathbf{W}_{vu} \gamma^v \gamma^u \mathbf{A}^v = \gamma^v f_v(\mathbf{W}) + \gamma^v \sum_{v=1}^V \mathbf{W}_{vu} \gamma^v \gamma^u \mathbf{S}^v \quad (12)$$

可以观察到,上述矩阵方程被重新表示为具有以下系数矩阵 $[\gamma_{vu}^1, \gamma_{vu}^2, \dots, \gamma_{vu}^V]$ 的 n^2 个线性方程组:

$$\mathbf{M} = \mathbf{W} \otimes (\gamma \gamma^T) \mathbf{A}^v + \text{diag}(\gamma) \quad (13)$$

其中, $\text{diag}(\gamma)$ 是对角矩阵,第 i 个对角元素为 γ_i 。令 $\mathbf{P}^v = \gamma^v f_v(\mathbf{W}) + \sum_{u=1}^V \mathbf{W}_{vu} \gamma^v \gamma^u \mathbf{A}^u$, $\mathbf{p}^v = \text{vec}(\mathbf{P}^v)$, 其中 $\text{vec}(\cdot)$ 表示向量化算子。经过推导得到:

$$\begin{bmatrix} \text{vec}(\mathbf{A}^1) \\ \vdots \\ \text{vec}(\mathbf{A}^V) \end{bmatrix} = \text{pinv}(\mathbf{M}) \cdot \begin{bmatrix} \mathbf{p}_1 \\ \vdots \\ \mathbf{p}_V \end{bmatrix} \quad (14)$$

其中, $\text{pinv}(\cdot)$ 表示伪逆矩阵。通过对 $\text{vec}(\mathbf{A}^v)$ 的重塑来获得 $\mathbf{A}^v$ 。为满足定义域 $\mathbf{S}^v \geq \mathbf{A}^v \geq 0$ 的要求,对 $\mathbf{A}^v$ 进行求解:

$$\mathbf{A}^v = \max(\mathbf{A}^v, 0), \mathbf{A}^v = \min(\mathbf{S}^v, \mathbf{A}^v) \quad (15)$$

其中,式(15)的第一项确保 $\mathbf{A}^v$ 中的元素是非负的,第二项确保 $\mathbf{A}^v$ 中的值不能超过原始的相似性矩阵 $\mathbf{S}^v$ 中的对应元素,使得到的 $\mathbf{A}^v$ 符合实际意义。

4.2.2 固定 $\mathbf{F}^*, \gamma^v, \mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V$, 更新视图嵌入矩阵 $\mathbf{F}^v$

去除其他与 $\mathbf{F}^v$ 无关的项,优化问题转化为:

$$\min_{\mathbf{F}^v} \text{tr}((\mathbf{F}^v)^T \mathbf{L}^v \mathbf{F}^v) + \sum_{v=1}^V \gamma^v \|\mathbf{F}^v - \mathbf{F}^*\|_F^2 + \lambda \sum_{v=1}^V \|\mathbf{F}^v\|_F^2 \quad (16)$$

通过对 $\mathbf{F}^v$ 求偏导并令其等于 0,从而得到视图嵌入矩阵 $\mathbf{F}^v$ 的更新公式:

$$\mathbf{F}^v = (\gamma^v \mathbf{I} + \lambda \mathbf{I} + \mathbf{L}^v)^{-1} \gamma^v \mathbf{F}^* \quad (17)$$

4.2.3 固定 $\mathbf{F}^*, \mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V, \mathbf{F}^v$, 更新视图权重 γ^v

去除其他与 γ^v 无关的项,并根据现有的约束项构建拉格朗日函数:

$$\begin{aligned} L = & \sum_{v,u=1}^V \mathbf{W}_{vu} \gamma^v \gamma^u \text{tr}((\mathbf{S}^v - \mathbf{A}^v)(\mathbf{S}^u - \mathbf{A}^u)^T) + \\ & \sum_{v=1}^V \gamma^v \|\mathbf{A}^v - f_v(\mathbf{W})\|_F^2 + \sum_{v=1}^V \gamma^v \|\mathbf{F}^v - \mathbf{F}^*\|_F^2 + \\ & \epsilon (\mathbf{1}^T \gamma^v - 1) \end{aligned} \quad (18)$$

其中, ϵ 为拉格朗日系数标量,由式(18)对视图权重 γ^v 求导,并根据 Karush-Kuhn-Tucker(KKT)条件令导数等于 0,求解得到权重 γ^v 的表达式:

$$\gamma^v = -\frac{\epsilon + h_v}{\sum_{u=1}^V \mathbf{W}_{vu} g_v} \quad (19)$$

其中:

$$\begin{cases} h_v = \|\mathbf{A}^v - f_v(\mathbf{W})\|_F^2 + \|\mathbf{F}^v - \mathbf{F}^*\|_F^2 \\ g_v = 2\text{tr}((\mathbf{S}^v - \mathbf{A}^v)(\mathbf{S}^v - \mathbf{A}^v)^T) \end{cases} \quad (20)$$

将式(19)带入约束条件 $\mathbf{1}^T \gamma^v = 1$,得到拉格朗日系数 ϵ 的表达式:

$$\epsilon = \frac{\sum_{v=1}^V \mathbf{W}_{vu} g_v - \sum_{v=1}^V h_v}{V} \quad (21)$$

因此,将 ϵ 的表达式(21)带回到权重 γ^v 的表达式(19)中,得到:

$$\gamma^v = \frac{1}{V} + \frac{1}{V \sum_{v,u=1}^V \mathbf{W}_{vu} g_v} (1 + h_v - \sum_{v=1}^V h_v) \quad (22)$$

4.2.4 固定 $\gamma^v, \mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V, \mathbf{F}^v$, 更新联合谱嵌入矩阵 $\mathbf{F}^*$

去除其他与 $\mathbf{F}^*$ 无关的项,将优化问题进行变换得到优化形式:

$$\begin{aligned} \max_{\mathbf{F}^*} & \text{tr}((\mathbf{F}^*)^T \mathbf{N}) \\ \text{s. t. } & (\mathbf{F}^*)^T \mathbf{F}^* = \mathbf{I}_C \end{aligned} \quad (23)$$

其中, $\mathbf{N} = 2 \sum_{v=1}^V \gamma^v \mathbf{F}^v$ 。对于受约束问题:

$$\begin{aligned} \max_{\mathbf{A}} & \text{tr}(\mathbf{A}^T \mathbf{B}) \\ \text{s. t. } & \mathbf{A}^T \mathbf{A} = \mathbf{I} \end{aligned} \quad (24)$$

已知 $\mathbf{B} = \mathbf{U} \Sigma \mathbf{V}^T$, 则有闭式解 $\mathbf{A} = \mathbf{U} \mathbf{V}^T$, 因此可以得到上式的闭式解: $\mathbf{F}^* = \mathbf{U}_1 \mathbf{V}_1^T$ 。其中 $\mathbf{U}_1$ 和 $\mathbf{V}_1$ 分别是矩阵 $\mathbf{N}$ 的左右奇异矩阵。

在此迭代优化的方案中, $\mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V, \mathbf{F}^v, \gamma^v, \mathbf{F}^*$ 通过相互作用的方式进行更新迭代,直至目标函数收敛。根据文献[31]的设置,本文定义下界为 10^{-5} 。本文的 JSEC 算法流程如算法 1 所示。

算法 1 基于多视图多样性学习的联合谱嵌入聚类算法 JSEC

输入:多视图数据 $\mathbf{M}^1, \dots, \mathbf{M}^V$; 聚类数 c ; 参数 α, β, λ

输出:聚类结果

1. 初始化;
2. 根据式(3)、式(4),初始化一致特征矩阵 $\mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V$;
3. 根据式(1)初始化相似图,并设每个视图权重 $\gamma^v = \frac{1}{V}$;
4. 根据式(6)构建混合相似图 $f_v(\mathbf{W})$;

5. 用拉普拉斯矩阵的特征向量初始化嵌入矩阵 $\mathbf{F}^v$;
6. 随机初始化正交矩阵 $\mathbf{F}^*$
7. While not converged do;
8. 根据式(14)、式(15),更新一致特征矩阵 $\mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^V$;
9. 根据式(17),更新视图嵌入矩阵 $\mathbf{F}^v$;
10. 根据式(22),更新视图权重矩阵 γ^v ;
11. 通过解决式(23)的问题,更新联合谱嵌入矩阵 $\mathbf{F}^*$;
12. End while.
13. 根据联合谱嵌入矩阵 $\mathbf{F}^*$,通过 K-means 聚类获得聚类结果.

4.3 算法复杂度分析

JSEC 算法主要包括 3 个模块:多样性学习模块、高阶信息融合模块和联合谱嵌入模块。多样性学习模块主要包括相似矩阵计算和多样性学习两个部分,其时间复杂度为 $O(n^2k + n^3)$,空间复杂度为 $O(n^2)$;在高阶信息融合模块,算法构建了混合相似图,其时间复杂度为 $O(Vn^2d)$,空间复杂度为 $O(Vn^2d)$;谱嵌入模块的作用是生成各视图嵌入矩阵,并生成联合谱嵌入矩阵,其时间复杂度为 $O(Vn^3)$,空间复杂度为 $O(Vn^2)$;在使用交替迭代的方法优化目标函数时,主要的计算集中在更新视图嵌入矩阵过程中,优化部分的总时间复杂度为 $O(TV(n^2 + n^3))$,其中 T 为算法迭代次数。因此,JSEC 算法的总时间复杂度为 $O(T(Vn^2 + Vn^3 + n^2k))$,总空间复杂度为 $O(Vn^2d)$ 。根据上述理论分析,JSEC 算法在时间复杂度和空间复杂度上适用于中等规模的数据集,但随着数据量和视图数的增加,可能需要优化和加速策略以处理大规模数据集。通过实验验证,结果表明 JSEC 算法在处理中小规模数据集时效率较高,并且优化过程能够在较少迭代次数内收敛。

5 实验分析

5.1 实验设置

5.1.1 实验数据集

为了验证 JSEC 算法的有效性,本文选取了 5 个中小规模的真实数据集作为实验数据进行对比分析,表 2 列出了 5 个真实数据集的统计信息。

表 2 数据集统计信息
Table 2 Statistics of datasets

统计项	Caltech101_7	3Sources	MSRC_v1	ORL	BBCSport
# d1	48	3 560	24	512	3 183
# d2	40	3 631	576	59	3 203
# d3	254	3 068	512	864	—
# d4	1 984	—	256	254	—
# d5	512	—	254	—	—
# d6	928	—	—	—	—
# 视图数	6	3	5	4	2
# 样本数	1 474	169	210	400	544
# 类别数	7	6	7	40	5

1)Caltech101_7 数据集:在 101 个类的图像数据集中选择了 7 个较为常见的类别,包含 1 474 个样本,提取 6 个常用的图像特征以形成不同的视图特征。

2)3Sources 数据集:包含 3 个新闻资源,分别为 BBC, Reuters 和 The Guardian,共 169 篇文章,按类别划分为 6 类,分别是商业、娱乐、政治、健康、体育和科技。

3)MSRC_v1 数据集:包含了 210 张图像,共 7 个类别,分

别用 5 种不同的特征提取方法将图像构成不同的视图。

4)ORL 数据集:包含 40 位不同的人的 400 张灰度人脸图像。每人提供 10 张不同姿势和表情的图像,在相机中以不同的光照条件捕获。

5)BBCSport 数据集:包含 544 篇体育文章,涵盖田径、板球、足球、橄榄球和网球 5 个主题领域,每篇文章包含两个特征。

5.1.2 对比算法

在实验过程中,本文选取了 11 种算法进行对比,包括单视图聚类算法(SCbest^[32]),基于子空间学习的算法(SMC^[33], CoMSC^[34],OPMC^[35]和 MSCTM^[36]),基于集成学习的算法(AWP^[37]),基于图学习的算法(GMC^[17], WMSC^[18], MCGC^[38],SMVSC^[39]和 CDMGC^[40])。

5.1.3 实验细节

本文使用调整兰德指数(ARI)、归一化互信息(NMI)和准确率(ACC)来评价 JSEC 算法以及其他聚类方法的聚类性能。对于这 3 个指标,其数值范围均在 0 到 1 之间,值越大表明聚类效果越好。

实验中,本文使用 KNN 对所有的原始数据进行相似性矩阵初始化。根据文献[24]中的设置,本文数据集所需的 k 值均取为 6。为减少随机误差,对于对比算法及本文算法,均重复实验 20 次,每种算法设置的最大迭代次数为 300。本文算法需要调整的参数有 3 个,即权衡参数 α 和 β 及正则化参数 λ ,这些参数都在 $\{10^{-4}, 10^{-3}, \dots, 10^3, 10^4\}$ 内进行测试。

5.2 实验结果与分析

表 3 中,以粗体表示最佳性能,以下划线表示次优性能;本文算法 JSEC 后面括号中的数字为各指标在置信水平为 0.05 时的误差。根据表 3 中的结果,可以观察到:

1)JSEC 在 ORL 和 BBCSport 这 2 个真实数据集的 3 个指标上均得到最优结果,在其他数据集上的大多数指标上也能得到较好的结果,表明了 JSEC 在各类数据集上的鲁棒性。与经典的和最新的多视图聚类算法 AWP, MCGC, SMC, OPMC, CoMSC, SMVSC, CDMGC, MSCTM 相比,本文算法在 5 个数据集和指标上均取得了显著进步。例如,在 3Sources 数据集上,较次优算法,JSEC 在 ACC, NMI, ARI 这 3 个指标上分别提升了 0.19%, 5.11%, 5.59%。

2)相较于单视图聚类算法 SCbest, JSEC 性能有较大提升。例如,在 Caltech101_7 数据集上,其 ACC 指标提升了 162%。这是因为 JSEC 在全面整合多视图信息、充分挖掘和利用不同视图间的互补信息、融合高阶信息方面有着较好的表现。

3)在部分数据集的指标上,基于子空间学习的算法 SMC 得到了次优结果。原因在于 SMC 整合了基于子空间学习的信息,但 SMC 对高阶信息的捕获能力较弱,而 JSEC 通过多样性学习和高阶信息融合,能更好地捕捉视图间的互补信息和复杂结构关系,相比 SMC 在 ARI 指标上提升了 13.53%。OPMC 和 CoMSC 算法在 BBCSport 数据集的不同指标上取得了稍逊于 JSEC 的次优结果。这是因为 OPMC 通过移除非负约束和联合优化矩阵分解与分区生成来改进聚类性能,但在处理复杂数据结构和视图多样性方面存在局限,且 OPMC

算法没有参数,在实际应用中可能无法适应不同数据集特性,而 JSEC 综合考虑了各种因素,大幅提高了聚类性能,在 Caltech101_7 数据集的 ACC 指标上提升了 25.33%。JSEC 采用视图多样性学习方法,在一致信息的捕捉上优于通过特征分解去除数据冗余的 CoMSC,在 MSRC_v1 数据集上, JSEC 对 ARI 的提升幅度超过 60%。

4)在 ORL 数据集的 ARI 指标上,基于集成学习的算法 AWP 得到了次优结果。这是因为 AWP 对视图间一致性的假设较强,而 JSEC 考虑了视图多样性在聚类过程中的变化,在构建相似性矩阵时排除了多样特征干扰,使构建的图更能反映数据的真实结构,从而得到了更好的结果。

5)在 MSRC_v1 数据集的 ACC 和 ARI 指标上,WMSC 算法得到了最优或次优结果。JSEC 与基于谱扰动理论对多视图进行加权的 WMSC 相比,在学习共识自表示矩阵时考虑了不同视图的相关性,并通过多样性学习去除噪声,利用高阶信息融合模块捕捉复杂结构关系。相较于 GMC 算法,JSEC

考虑了多样性与高阶信息,其 ACC 指标提升了 16.14%。
6)相比其他基于图学习的算法,MCGC 和 CDMGC 算法在部分数据集的指标上取得次优结果,它们均存在无法全面捕捉到数据中所有类型的多样性的问题,而 JSEC 引入了熵约束机制,同时通过多样性学习模块平衡了视图间的一致性和多样性,大幅提升了聚类性能。在 ACC 指标上,JSEC 相比 MCGC 提升了 25.65%,相比 CDMGC 提升了 12.60%。

7)与基于子空间学习的算法相比,JSEC 的高阶信息融合和多样性学习模块在复杂数据集上能更全面地反映视图间的关系,子空间学习类算法在低维表示和一致特征提取上相对较弱;与基于集成学习的算法相比,JSEC 的联合谱嵌入和高阶信息融合模块使其在全局结构和视图一致性上的表现优异;与其他基于图学习的算法相比,JSEC 实现了一致性与多样性的平衡、高阶信息的有效融合和谐嵌入的全局特征优化。因此,JSEC 能够更好地整合多视图信息、适应数据特点,从而提高算法的稳定性和鲁棒性。

表 3 5 个中小规模的真实数据集上 3 个评价指标的结果
Table 3 Results of 3 evaluation indicators on 5 small and medium-sized real datasets

数据集	指标	SCbest	AWP	GMC	MCGC	SMC	WMSC	OPMC	CoMSC	SMVSC	CDMGC	MSCTM	JSEC
Caltech 101_7	ACC	0.3055	0.5638	0.6499	0.2300	<u>0.7869</u>	0.2329	0.5487	0.6988	0.5487	0.7631	0.6933	0.8020(0.0014)
	NMI	0.8229	0.4756	0.5609	0.4197	0.4829	0.4581	0.4115	0.5630	0.4115	0.6247	0.5987	<u>0.7356(0.0048)</u>
	ARI	0.4640	0.4152	0.5943	0.1384	0.4428	0.1539	0.3532	0.2971	0.3532	<u>0.5997</u>	0.4874	0.6023(0.0031)
3Sources	ACC	0.4852	0.5980	0.6528	0.4615	<u>0.7858</u>	0.6331	0.6632	0.5479	0.3082	0.3538	0.5226	0.7877(0.0043)
	NMI	0.3869	0.5530	0.5319	0.5470	<u>0.6542</u>	0.4647	0.4546	0.3719	0.0832	0.0676	0.4343	0.7053(0.0038)
	ARI	0.5917	0.7410	<u>0.7801</u>	0.6627	0.7020	0.7041	0.6173	0.2836	0.0341	0.0128	0.2605	0.8360(0.0021)
MSRC_v1	ACC	0.7429	0.7571	0.7476	<u>0.8381</u>	0.6857	0.8464	0.7905	0.4123	0.8190	0.7452	0.3523	<u>0.7826(0.0044)</u>
	NMI	0.6001	0.7084	0.7623	0.7399	0.6400	0.7381	0.7136	0.3463	0.7118	0.6879	0.2724	<u>0.7538(0.0023)</u>
	ARI	0.5737	0.7148	0.7905	0.8381	0.6682	<u>0.8464</u>	0.6255	0.2090	0.6486	0.5635	0.1456	0.8561(0.0017)
ORL	ACC	0.6401	0.7815	0.6320	0.6425	0.6719	0.8097	0.6731	0.4372	0.4239	<u>0.8314</u>	0.7812	0.8532(0.0029)
	NMI	0.6154	0.7251	0.8570	0.7767	0.7648	0.9031	0.7621	0.6680	0.7526	<u>0.9077</u>	0.6354	0.9103(0.0102)
	ARI	0.5245	<u>0.7629</u>	0.3360	0.2158	0.7023	0.7453	0.5796	0.4123	0.5625	0.6272	0.5943	0.7755(0.0024)
BBCSport	ACC	0.4485	0.6951	0.7390	0.6745	0.7586	0.6732	<u>0.9021</u>	0.8865	0.6741	0.8057	0.8556	0.9038(0.0088)
	NMI	0.2398	0.6841	0.7950	0.4671	0.7011	0.6772	<u>0.7962</u>	0.7820	0.7342	0.6821	0.7492	0.8057(0.0034)
	ARI	0.4240	0.5465	0.6000	0.0341	0.7312	0.5543	0.8307	<u>0.8490</u>	0.6624	0.7194	0.7544	0.8531(0.0046)

为进一步验证 JSEC 算法在大规模数据集上的表现,本文在两个大规模数据集 DBLP 和 Hdigit 上进行了实验。DBLP 是一个学术文献数据集,包含 5 000 篇学术论文,从中

提取标题、摘要、关键词等多视图特征;Hdigit 数据集有 10 000 个样本,包含 10 个类且均匀分布。实验结果如表 4 所列。

表 4 2 个大规模真实数据集上 3 个评价指标的结果
Table 4 Results of 3 evaluation indicators on 2 large-scale real datasets

对比算法	DBLP			Hdigit		
	ACC	NMI	ARI	ACC	NMI	ARI
SCbest	0.6689	0.6676	0.6783	0.6416	0.6313	0.5146
AWP	0.7095	0.7358	0.7735	0.5667	0.6805	0.6997
GMC	0.8653	0.8320	0.8512	0.6121	0.6559	0.6221
MCGC	0.9298	0.8302	0.7746	0.3253	0.5190	0.3159
SMC	0.8305	0.7343	0.7810	0.6208	0.6371	0.5973
WMSC	0.6315	0.6387	0.6231	0.7124	0.7354	0.7203
OPMC	0.8185	<u>0.8617</u>	0.7921	0.8080	<u>0.8453</u>	0.7753
CoMSC	0.8667	0.8084	<u>0.8532</u>	0.7670	0.7880	0.7216
SMVSC	0.6147	0.6724	0.6903	0.7375	0.7486	0.7510
CDMGC	0.8431	0.7711	0.7637	<u>0.8144</u>	0.8276	<u>0.8167</u>
MSCTM	0.8713	0.8071	0.8176	0.7315	0.7591	0.7734
JSEC	<u>0.8861</u>	0.8676	0.8572	0.8712	0.8520	0.8640

可以看出,JSEC 在两个数据集上的指标性能均能达到最优或次优,相较于次优算法,JSEC 在 NMI 和 ARI 指标上的

的提升幅度为 0.63%和 2.57%,这表明 JSEC 算法具有较强的泛化能力,且在大规模数据集上,本文算法的 3 个指标均能

够维持在较高水平,体现了算法的鲁棒性和高效性。

5.3 收敛性分析

本节对 JSEC 在 5 个数据集的收敛性进行了分析,收敛

曲线如图 3 所示。由图 3 可见,5 个数据集的目标函数值在迭代过程中均迅速下降,并在 5 次以内迅速收敛,证明 JSEC 有着较好的收敛性。




图 3 收敛性分析
Fig. 3 Convergence analysis

5.4 参数稳定性分析

本节对算法涉及的 3 个参数 α, β, λ 进行稳定性分析。将 3 个参数都设置在 $\{10^{-4}, 10^{-3}, \dots, 10^4\}$ 范围内,分别用 3 个评价指标 ACC, NMI, ARI 进行评估。先固定正则化参数 λ , 对多样性学习中涉及的两个参数 α 和 β 调优,图 4—图 6 展示了参数在不同数据集上的性能。

对参数 α 和 β 进行分析,以 ACC 为例,由图 4 可见,JSEC 算法在较大范围内保持了相对稳定的聚类性能,特别是在 3Sources 和 ORL 数据集上。对于 Caltech101_7 数据集来说,

过小的 α 对视图内多样特征的约束不足,使得多样特征在模型中保留较多,影响聚类效果;而当 α 增大到一定程度时,算法性能趋于稳定。在 MSRC_v1 数据集上,算法呈现出类似的规律。而对于 BBCSport 数据集来说,当参数 α 和 β 较小,可能会使视图权重分配不合理,从而无法充分融合多视图信息,导致聚类效果不稳定;当 α 和 β 增大时,JSEC 在数据集上的性能十分稳定。在以 NMI 和 ARI 为评价指标的图 5—图 6 中,可以得出类似的结论。以上结果均表明,本文模型在一定范围内是稳定的,当取定 $\alpha=10^3, \beta=10$ 时,模型性能最好。




图 4 参数 α 和 β 在不同数据集上的性能(以 ACC 为评价指标)
Fig. 4 Performance of parameters α and β on different datasets(ACC as evaluation index)




图 5 参数 α 和 β 在不同数据集上的性能(以 NMI 为评价指标)

Fig. 5 Performance of parameters α and β on different datasets(NMI as evaluation index)




图 6 参数 α 和 β 在不同数据集上的性能(以 ARI 为评价指标)

Fig. 6 Performance of parameters α and β on different datasets(ARI as evaluation index)

在固定多样性学习模块中涉及的两个参数 α 和 β 后,本文对正则化参数 λ 进行调优,分别以 ACC,NMI,ARI 为评价指标,实验结果如图 7 所示。可以看出,当参数 λ 较小时,其对模型的影响并不明显,对模型正则化的作用

较小;而当 λ 的取值增大时,会导致过度强调正则化约束,从而抑制数据真实结构的学习。因此,为了使模型发挥出最佳性能,促进多视图信息融合,在对比实验中,本文选取参数 $\lambda=10$ 。




图 7 参数 λ 在不同数据集和不同评价指标上的性能

Fig. 7 Performance of parameter λ on different datasets and different evaluation indexes

5.5 权重分析

在 JSEC 算法收敛后,对 5 个数据集各视图权重进行了评估,结果如图 8 所示。

由图 8 可见,JSEC 算法是基于各个视图在算法中的

重要性进行自适应权重分配的,未采用极化或平均化的方式对视图赋予权重。这表明了 JSEC 算法在处理多视图数据时的有效性,它通过自适应地调整权重配比,明显提高了聚类性能。




图 8 各数据集上不同视图权重配比
Fig. 8 Different view weight ratios in each dataset

5.6 高阶邻域信息影响

为了验证引入高阶信息的必要性,本节展示了在 5 个数据集上不同阶的相似图变化率的平均值,即 $\frac{|(W_v^n)_{ij} - (W_v^{n-1})_{ij}|}{(W_v^{n-1})_{ij}}$,结果如图 9 所示。

由图 9 可见,所有结果的图像均呈 U 型,各数据集的变

化主要集中在二阶和三阶之间,这表明它们之间存在较大程度的不同;而有限阶和无穷阶之间的变化也较大,表明无穷阶相似图上也包含一些信息;其他阶基本无变化。这说明了二阶和无穷阶的相似图中存在许多有价值的信息,从而验证了本文算法引入高阶信息的必要性和有效性。




图 9 不同阶的相似图变化率
Fig. 9 Variation rate of similarity graphs of different orders

5.7 消融实验

JSEC 算法主要包括 3 个模块:多样性学习模块、高阶信息融合模块和谱嵌入模块。为了探究这 3 个模块的有效性,本文设置了 JSEC 的 3 种变体,具体如下:

- 1)JSEC1-no Consistent:去除多样性学习模块,即参数 α 和 β 均设置为 0,直接用相似性矩阵代替一致特征矩阵,其余设置与 JSEC 相同。
- 2)JSEC2-no Mixture:去除高阶信息融合模块,即直接让一致特征矩阵进入谱嵌入模块,其余设置与 JSEC 相同。
- 3)JSEC3-no SpectralEmbedding:去除谱嵌入模块,将各视图的一致特征矩阵进行加权平均,构建全局一致矩阵进行聚类,其余设置与 JSEC 相同。

消融实验展示了 JSEC 算法及其 3 种变体的聚类性能对比(以 ACC 为衡量指标),如图 10 所示。

实验结果显示,JSEC 能够有效地结合多样性学习、高阶信息融合和谱嵌入模块,在多视图聚类中可以更准确地捕捉数据的内在结构,有效提升聚类精度,其整体性能最佳。

去除多样性学习模块的 JSEC1 的性能下降幅度为 42.07%,JSEC1 直接使用原始相似性矩阵,导致噪声和冗余信息干扰了一致特征提取,聚类性能不佳;JSEC 算法中的多样性学习模块通过分解相似矩阵,隔离噪声和视图特定特征,提升了一致特征的纯净度和数据鲁棒性,在噪声多或异质性强的数据集上表现尤其突出。去除高阶信息融合模块的 JSEC2 性能下降幅度为 16.62%,这是因为 JSEC2 无法有效

利用高阶结构特性,视图间协同作用不足,虽然一致特征仍然存在,但缺乏全局结构挖掘;JSEC 算法中的高阶信息融合模块通过混合相似图捕捉高阶关联关系,增强了对复杂和高维数据的全局建模能力。去除谱嵌入模块的 JSEC3 的性能下降幅度为 28.51%,这是因为各视图一致特征仅通过简单加权平均融合,缺乏全局结构约束,聚类结果稳定性和精确性降低;JSEC 算法中的谱嵌入模块通过统一低维空间的嵌入来确保多视图一致性和可分性,对特征整合和聚类性能十分重要。消融实验表明,通过 JSEC 算法的 3 个模块的协同配合,显著提升了聚类效果,去除任一模块均会削弱对数据结构的整体捕捉,导致性能下降。




图 10 JSEC 及其变体的聚类性能

Fig. 10 Clustering performance of JSEC and its variants

结束语 本文提出了一种基于多视图多样性学习的联合谱嵌入聚类算法——JSEC。JSEC 算法针对多视图数据融合中保持多样性和挖掘高阶信息的难题,将视图多样性学习、高阶信息融合与谱嵌入整合到统一优化框架中。视图多样性学习模块通过抑制视图噪声和冗余的影响,保留全局结构信息;高阶信息融合模块通过构建混合相似图,捕获视图间潜在的高阶相关性,并约束一致特征矩阵与混合相似图匹配,实现全局特征协同优化;谱嵌入模块将特征矩阵映射到低维嵌入空间,生成联合谱嵌入矩阵,进一步表征数据结构,在保留多视图信息差异性的同时提升了视图间一致性表达。实验结果表明,JSEC 算法通过 3 个模块的协同作用,提高了聚类精度和稳定性。但随着数据集规模增长,JSEC 算法的计算效率可能会受到限制。因此,未来可通过矩阵稀疏化减少存储和计算代价,通过分布式计算降低单节点计算压力,以及利用核化降维提升算法效率,拓展算法普适性。

参 考 文 献

[1] ZHANG P F,LI T R,WANG G Q,et al. Multi-source information fusion based on rough set theory:A review[J]. Information Fusion,2021,4(68):85-117.

[2] ZHAO X Y,YAN W Q,REN J L,et al. Graph-filtering and high-order bipartite graph based multiview graph clustering[J]. Digital Signal Processing,2023,133:103847.

[3] ZHANG D P,HUANG H N,ZHAO Q B,et al. Generalized latent multi-view clustering with tensorized bipartite graph[J]. Neural Networks,2024,175:106282.

[4] WANG S W,LIU X W,LIU L,et al. Highly-efficient incomplete large-scale multi-view clustering with consensus bipartite graph [C]// 2022 IEEE/CVF Conference on Computer Vision and

Pattern Recognition(CVPR). IEEE,2022:9776-9785.

[5] LIU S S,LIN L. Adaptive Weighted Multi-View Clustering [C]// ACM Conference on Health,Inference,and Learning. PM-LR,2023:19-36.

[6] GUO W,CHEN H J,LEUNG M F. Tensor-Based Adaptive Consensus Graph Learning for Multi-View Clustering[J]. IEEE Transactions on Consumer Electronics,2024,70(2):4767-4784.

[7] XU C,TAO D C,XU C. A Survey on Multi-view Learning[J]. Neural Computing and Applications,2012,13:2031-2038.

[8] ZONG L L. Research on Multi-view Clustering [D]. Dalian: Dalian University of Technology,2017.

[9] XU J,REN Y Z,LI G F,et al. Deep embedded multi-view clustering with collaborative training [J]. Information Sciences, 2021,573:279-290.

[10] ZHEN L L,HU P,PENG X,et al. Deep Multimodal Transfer Learning for Cross-Modal Retrieval[J]. IEEE Transactions on Neural Networks and Learning Systems,2022,33(2):798-810.

[11] KIPF T N,WELLING M. Semi-supervised classification with graph convolutional networks [C]// Proceedings of the 5th International Conference on Learning Representations. 2017:1-10.

[12] LIN Z P,KANG Z. Graph Filter-based Multi-view Attributed Graph Clustering[C]// International Joint Conference on Artificial Intelligence(IJCAI). AAAI,2021:2723-2129.

[13] ZHOU B,LIU W L,SHEN M Z,et al. Adaptive graph fusion learning for multi-view spectral clustering[J]. Pattern Recognition Letters,2023,176:102-108.

[14] CAI B,LU G F,LIANG Y,et al. Aligned multi-view clustering for unmapped data via weighted tensor nuclear norm and adaptive graph learning[J]. Neurocomputing,2024,597:128016.

[15] XIE D Y,GAO Q X,ZHAO Y G,et al. Consistent graph learning for multi-view spectral clustering[J]. Pattern Recognition, 2024,154:110598.

[16] ZHAO X W,WANG S J,LIU X L,et al. Joint Spectral Embedding Multi-view Clustering Algorithm Based on Bipartite Graphs [J]. Journal of Software,2024,35(9):4408-4424.

[17] WANG H,YANG Y,LIU B. GMC:graph-based multi-view clustering[J]. IEEE Transactions on Knowledge and Data Engineering,2020,32(6):1116-1129.

[18] ZONG L L,ZHANG X C,LIU X Y,et al. Weighted multi-view spectral clustering based on spectral perturbation[C]// Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2018:4621-4628.

[19] CAI S T,CHEN X J,CHEN L T,et al. Stratified Pseudo-label Based Image Clustering[J]. Computer Science,2023,50(6):225-235.

[20] LIU P Y,HU J,WANG H J. Multi-view Attributed Graph Clustering Based on Contrast Consensus Graph Learning[J]. Computer Science,2024,51(11):73-80.

[21] LIU Z H,SONG P. Deep low-rank tensor embedding for multi-view subspace clustering [J]. Expert Systems With Applications,2024,237:121518.

[22] MEI Y Y,REN Z W,WU B,et al. Multi-order similarity learning for multi-view spectral clustering[J]. Pattern Recognition,

2023,137:109264.

[23] LI L,LI Z N,ZHENG J,et al. Unsupervised dimensionality reduction by jointing dynamic hypergraph and low-rank embedding for classification and clustering[J]. Expert Systems with Applications,2022,208:118225.

[24] XIN H N,HAO Z Z,SUN Z S,et al. Multi-view and Multi-order Graph Clustering via Constrained $l_{1,2}$ -norm[J]. Information Fusion,2024,111:102483.

[25] YOU Y N,TANG C,LIU X W,et al. High-order graph fusion for multi-view clustering[J]. Scientia Sinica (Informationis), 2024,54(9):2098-2115.

[26] XIA R K,PAN Y,DU L,et al. Robust Multi-View Spectral Clustering via Low-Rank and Sparse Decomposition[C]// Proceedings of the 28th AAAI Conference on Artificial Intelligence. AAAI,2014:2149-2155.

[27] BOJCHEVSKI A,MATKOVIC Y,GUNNEMANN S. Robust spectral clustering for noisy data; Modeling sparse corruptions improves latent embeddings[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM,2017:737-746.

[28] LIANG Y W,HUANG D,WANG C D,et al. Multi-view graph learning by joint modeling of consistency and inconsistency[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024,35(2):2848-2862.

[29] PAN E L,KANG Z. High-order multi-view clustering for generic data[J]. Information Fusion,2023,100:101947.

[30] FAN K. On a theorem of Weyl concerning eigenvalues of linear transformations;II[C]// Proceedings of the National Academy of Sciences of the United States of America. 1950:31-35.

[31] HUANG L,CHAO H Y,WANG C D. Multi-view intact space clustering[J]. Pattern Recognition,2019,86:344-353.

[32] NG A Y,JORDAN M,WEISS Y. On spectral clustering: Analysis and an algorithm[C]// Proceedings of the 15th International Conference on Neural Information Processing Systems; Natural and Synthetic. MIT,2001:849-856.

[33] LIU L,CHEN P,LUO G C,et al Scalable multi-view clustering with graph filtering[J]. Neural Computing and Applications, 2022,34(19):16213-16221.

[34] LIU J Y,LIU X W,YANG Y X,et al. Multiview Subspace Clustering via Co-Training Robust Data Representation[J]. IEEE

Transactions on Neural Networks and Learning Systems,2022, 33:5177-5189.

[35] LIU J Y,LIU X W,YANG Y X,et al. One-pass Multi-view Clustering for Large-scale Data[C]// 2021 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2021: 12324-12333.

[36] HUANG S D,WU H J,REN Y Z,et al. Multi-view Subspace Clustering on Topological Manifold[C]// Proceedings of the 36th International Conference on Neural Information Processing Systems. 2024.

[37] NIE F P,TIAN L,LI X L. Multiview clustering via adaptively weighted Procrustes[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM,2018:2022-2030.

[38] ZHAN K,NIE F P,WANG J,et al. Multiview consensus graph clustering[J]. IEEE Transactions on Image Processing, 2019, 28(3):1261-1270.

[39] SUN M J,ZHANG P,WANG S W,et al. Scalable Multi-view Subspace Clustering with Unified Anchors[C]// Proceedings of the 29th ACM International Conference on Multimedia. ACM, 2021:3528-3536.

[40] HUANG S D,TSANG I W,XU Z L,et al. Measuring Diversity in Graph Learning: A Unified Framework for Structured Multi-View Clustering[J]. IEEE Transactions on Knowledge and Data Engineering,2022,34(12):5869-5883.



LI Shunyong, born in 1975, Ph.D, professor, is a member of CCF (No. U1748M). His main research interests include statistical machine learning and data mining.



ZHAO Xingwang, born in 1984, Ph.D, professor, Ph.D supervisor, is a member of CCF (No. 22414M). His main research interests include data mining and machine learning.

(责任编辑:何杨)