

Beijing Forest Studio
北京理工大学信息系统及安全对抗实验中心



不完全多视图聚类技术 -减小缺失视图的影响

硕士研究生 杨景然

2024年09月01日

- **总结反思**

- 讲解语速较快，时间较短，内容详略不当
- 算法部分熟悉程度不够，TIPO花费过多时间
- 回答问题不准确，信息量太少

- **相关内容**

- 2024.12.10 杨景然 《多视图聚类技术》
- 2023.04.22 谢崇玮 《深度半监督聚类技术》
- 2022.09.04 谢崇玮 《半监督聚类和患者相似性分析》
- 2021.07.18 董 勃 《多视角深度学习》

- 预期收获
- 内涵解析
- 背景简介
- 知识基础
- 算法原理
 - GIGA
 - AGDIMC
- 特点总结与工作展望
- 参考文献

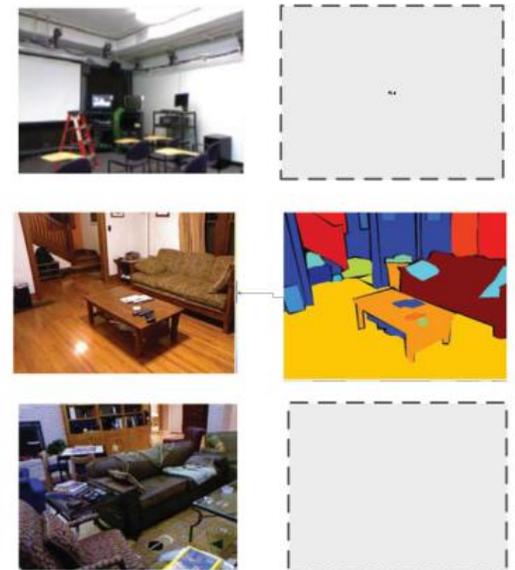
- 预期收获
 - 掌握不完全多视图聚类技术的基本概念
 - 理解几何层面的不完全多视图学习
 - 了解不完全多视图聚类的技术原理
 - 明确不完全多视图聚类的应用领域和发展方向

• 内涵解析

- 聚类：将相似的事物聚集在一起，不相似的事物划分到不同的类别的过程
- 多视图：对于同一事物的不同的描述构成了事物的多个视图
- 不完全多视图（Incomplete Multi-View Clustering, IMVC）：但是在实际应用中，由于信息采集器**自身故障或信息传输过程受干扰**等导致获取数据中**部分样本缺失**

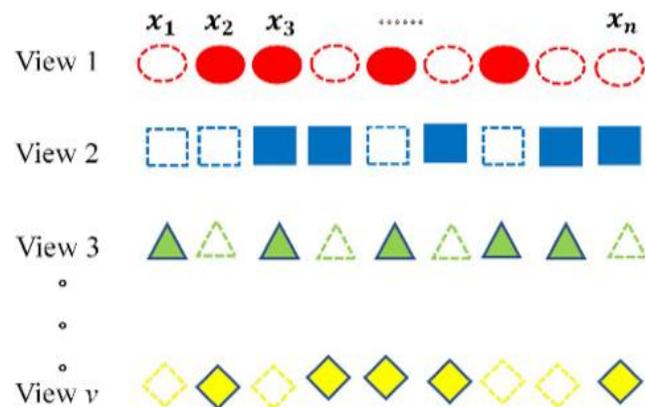
• 研究目标

- 面向数据处理领域中从**各种特征收集器**获得的**不完全数据**
- 从**几何角度**分析缺失数据的影响
- 结合图结构、谱聚类、深度学习等理论
- 实现对不完全多视图数据的**准确聚类**



• 研究背景

- 多视图聚类作为多视图学习的重要应用方向，广泛应用于图像处理、文本分类、生物信息学等领域
- 数据不完全性问题在多视图学习中尤为突出：由于各种原因，如数据获取的困难、仪器操作问题、传感器故障或成本限制等，某些视图的部分数据可能无法获得
- 不同视图可能有不同的质量，如何在聚类过程中有效地衡量和利用各视图的质量，从而避免质量较差的视图对聚类结果的负面影响



研究意义

- 提升**聚类算法的鲁棒性**：IMVC研究使得聚类方法在面对不完全数据时仍然能够保持良好的性能
- 促进**大规模数据处理的发展**：据规模不断增大，IMVC的研究有助于开发出更高效的算法，能够在大规模数据环境下处理不完全的多视图数据
- 促进**数据隐私保护和伦理研究**：IMVC方法在处理不完全数据时，通常涉及到数据的推断与补全，这与数据隐私保护和伦理研究密切相关

管中窥豹！



研究历史 不完全多视图聚类



Trivedi等人**首次**对不完全多视图进行了聚类：并使用拉普拉斯正则化填充不完整视图的核，这种方法要求**至少存在一个包含所有实例的完整视图**

S. 等提出了PVC方法：主要思想是应用非负矩阵分解分别提取完整样本和不完整样本的**共同潜在表示**和特定于视图的潜在表示

Xen等人提出的方法引入了误差矩阵和反向图正则化方案来**同时完成**缺失数据和捕获公共局部结构

Pu等人利用权图融合(包含**互补信息**)和潜在图(捕获拓扑细节)来捕获不完全多视图数据的**拓扑信息**，从而进行深度不完全多视图聚类



2010

2013

Shao等人放宽约束，通过优化数据集的共享**实例的对齐**来共同完成不完整数据集的核矩阵；但**不能利用两个以上视图**之间的关系

2014

2015

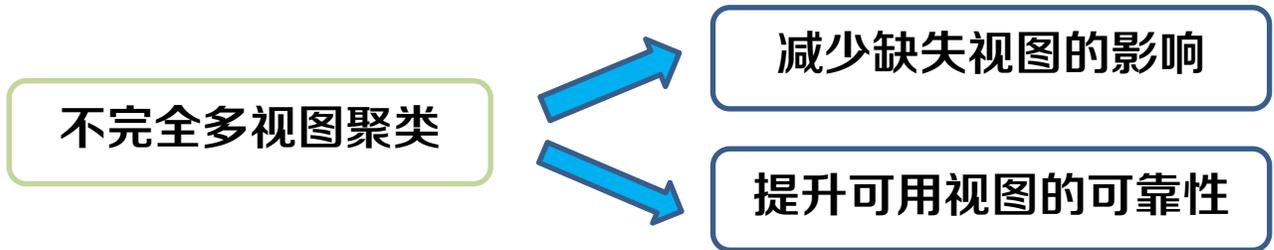
Shao等人通过联合加权非负矩阵分解，给予不完整实例**更小的权重**来减少缺失数据的影响

2019

2021

Xue 等人开发了一种聚类诱导深度IMVC方法，通过使用多视图自编码器来**推断缺失数据**，从而提升聚类性能

2023



- 减少缺失视图的影响

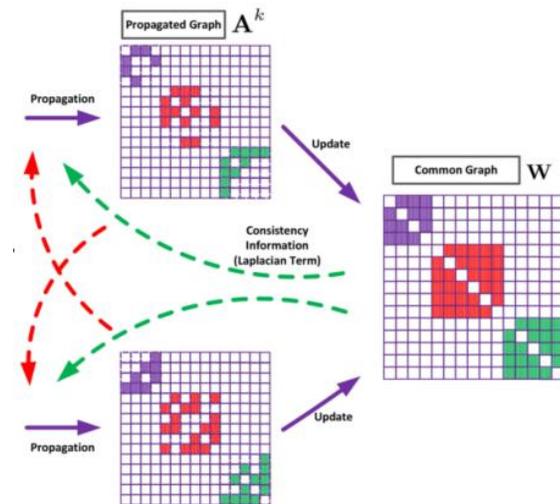
- 通过对不同视图上的**共享信息**进行联合学习来合理地恢复缺失视图

- 基于矩阵补全的方法：利用已有视图的**低秩结构**，通过矩阵分解等技术补全缺失数据
- **基于图嵌入的方法**：构建视图之间的相似性图，将各视图的关系嵌入到**统一的低维空间**中，从而推断缺失视图的内容
- 生成对抗网络：能够学习视图之间的复杂关系，生成与真实视图接近的补全视图

- 提升可用视图的可靠性

- 强化可用视图的有效信息，构建更可靠的联合表示

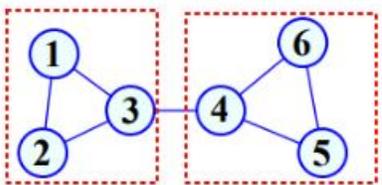
- 自适应加权策略（**图融合过程中各视图权重**）
- 半监督和弱监督学习



扬长避短，去芜存菁！

拉普拉斯矩阵

- 给定一个具有 n 个顶点图 $G = (V, E)$, V 为顶点集合, E 为边集合
 - 邻接矩阵 A : $n \times n$ 的矩阵, 1表示对应的一对顶点有边相连, 0表示没有边相连
 - 度矩阵 D : 将邻接矩阵各行元素累加至对应的主对角元素
- 拉普拉斯矩阵: 图 G 的拉普拉斯矩阵可以定义为: $L = D - A$
- 连通: 在无向图中, 若从两点之间相连, 则称这两点是连通的
- 连通分量: 无向图中极大连通子图称为连通分量; 图拉普拉斯矩阵有多少个零特征值, 就有多少个连通分量 **与聚类有什么关系?**



$$A = \begin{pmatrix} 0 & 1 & 1 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 1 & 0 \end{pmatrix}$$

$$D = \begin{pmatrix} 2 & & & & & \\ & 2 & & & & \\ & & 3 & & & \\ & & & 3 & & \\ & & & & 2 & \\ & & & & & 2 \end{pmatrix}$$

$$L = D - A = \begin{pmatrix} 2 & -1 & -1 & 0 & 0 & 0 \\ -1 & 2 & 1 & 0 & 0 & 0 \\ -1 & -1 & 3 & -1 & 0 & 0 \\ 0 & 0 & -1 & 3 & -1 & -1 \\ 0 & 0 & 0 & -1 & 2 & -1 \\ 0 & 0 & 0 & -1 & -1 & 2 \end{pmatrix}$$



• 约束拉普拉斯秩

- 图拉普拉斯矩阵的秩与图的连接分量数量有关：拉普拉斯矩阵 L 的秩等于**节点总数减去图的连通分量数**

- $rank(L) = n - k$

- 通过控制拉普拉斯矩阵的秩，来引导数据的聚类过程

- 假设聚类簇数为 k ，则在控制拉普拉斯矩阵的秩为 $n - k$ （即意味着最终的图有 k 个连通分量）

- $k = rank(L) - n$

• 在图聚类中的应用

- 结合多个视图的拉普拉斯矩阵并控制其秩，可以确保最终聚类的数量或连通分量的数量满足预期的要求



Geometric-inspired graph-based Incomplete Multi-view Clustering

GIGA TIPO

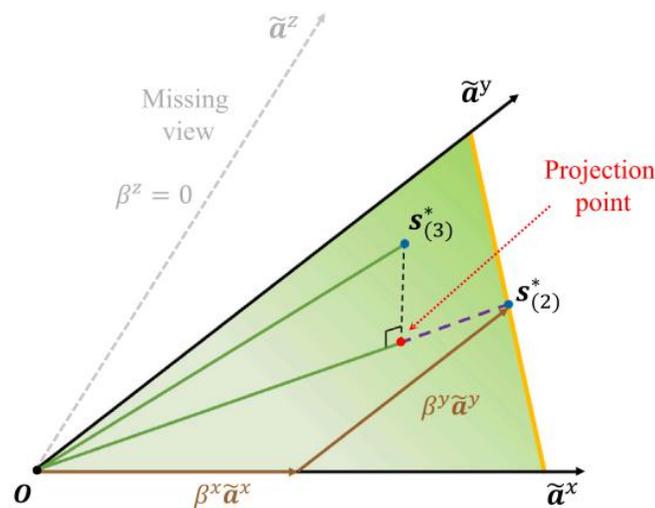
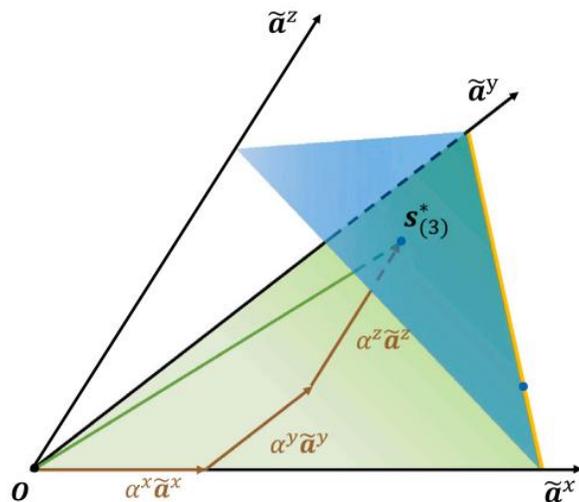
T	目标	分析缺失数据如何影响聚类解，并完成准确聚类
I	输入	不完全多视图数据集*8
P	处理	<ol style="list-style-type: none"> 1.几何方法分析解偏移现象 2.确定样本缺失情况，在每个视图中根据可用样本建立图 3.根据拉普拉斯约束秩自适应各视图权重迭代更新得到聚类结果
O	输出	聚类结果

P	问题	现有不完全多视图聚类未分析缺失数据对聚类效果具体影响
C	条件	每个样本至少存在一个可用视图
D	难点	自适应调节各视图权重，有效整合信息
L	水平	Pattern Recognition2024 (SCI一区)

几何分析

- 假设一个样本有3个可用视图，表示为 $\tilde{a}^x, \tilde{a}^y, \tilde{a}^z$
- 多视图完整：3个视图均可获得，3个视图的权重分别为 $\alpha^x, \alpha^y, \alpha^z$ ，且 $\alpha^x + \alpha^y + \alpha^z = 1$
- 多视图数据的信息整合解可以表示为 $s^* = \alpha^x \tilde{a}^x + \alpha^y \tilde{a}^y + \alpha^z \tilde{a}^z$
- 最优解 $s_{(3)}^*$ 位于蓝色解空间中
- 当视图有缺失时（假设视图 \tilde{a}^z 缺失），最优解的位置会发生偏移

• $s_{(3)}^* \rightarrow s_{(2)}^*$



几何分析

– 解偏移: $s_{(3)}^* \rightarrow s_{(2)}^*$; $s_{(2)}^* = \beta^x \tilde{a}^x + \beta^y \tilde{a}^y$, $\beta^x + \beta^y = 1$

– 目标: 找到最接近于 $s_{(3)}^*$ 的解 $s_{(2)}^*$

- 即找到 α^x, α^y 与 β^x, β^y 的最优转换

- 几何角度: $s_{(2)}^*$ 应与 $s_{(3)}^*$ 有着最小的角度

– 方法: 借助投影关系分析 $s_{(2)}^*$ 、 $s_{(3)}^*$ 之间关系

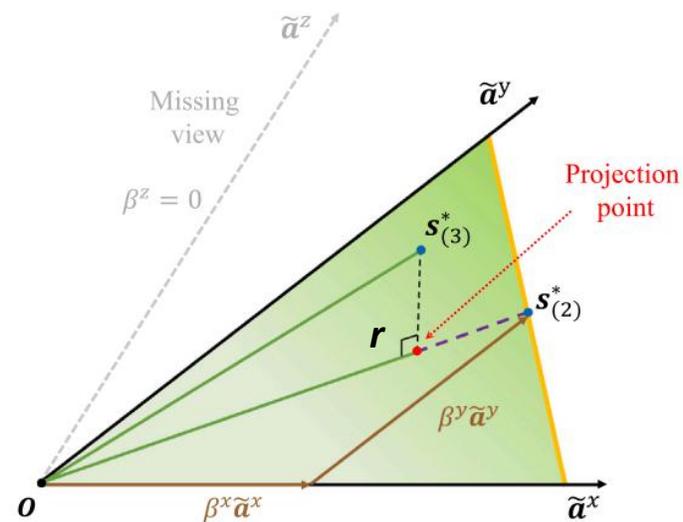
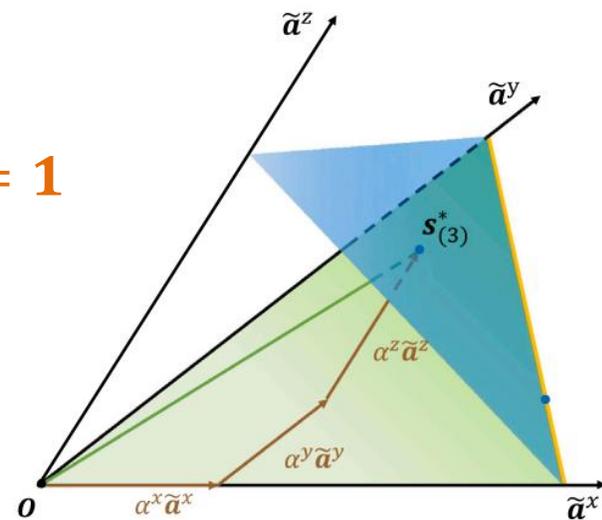
- 做 $os_{(3)}^*$ 与 \tilde{a}^x, \tilde{a}^y 的垂线

- 与基平面交于一点 (投影点 r)

- or 与解空间交点即为最优 $s_{(2)}^*$

- 所以有以下关系

$$\left\langle \sum_{u=1}^l \alpha^u \mathbf{a}^u - \sum_{i=1}^c \hat{\beta}^{vi} \mathbf{a}^{vi}, \mathbf{a}^{vj} \right\rangle = 0, \text{ for } j = 1, \dots, c.$$



几何分析

– **问题转换**: 转变为含有 c 个变量和 c 个等式的方程组

- $\hat{\beta}$: 各视图的权重
- U : 视角内相似度 ($c \times c$): 在第 i 个视图中, 视图 v^i 与视图 v^j 的相似度

$$U_{ij} = \frac{\langle a^{v_i}, a^{v_j} \rangle}{\langle a^{v_i}, a^{v_i} \rangle}$$

- V : 不同相似度 ($c \times l$): 不同视图相似度

$$V_{ij} = \frac{\langle a^{v_i}, a^{v_j} \rangle}{\langle a^{v_i}, a^{v_i} \rangle}$$

$$P_{ij} = \begin{cases} \frac{1}{\sum_{k=1}^c \hat{\beta}^{v_k}} U^{-1} V, & i = 1 \dots c \\ 0 & \text{others} \end{cases}$$

$$\left\langle \sum_{u=1}^l \alpha^u \mathbf{a}^u - \sum_{i=1}^c \hat{\beta}^{v_i} \mathbf{a}^{v_i}, \mathbf{a}^{v_j} \right\rangle = 0, \text{ for } j = 1, \dots, c.$$



$$\begin{aligned} \sum_{i=1}^c \hat{\beta}^{v_i} \frac{\langle \mathbf{a}^{v_1}, \mathbf{a}^{v_i} \rangle}{\langle \mathbf{a}^{v_1}, \mathbf{a}^{v_1} \rangle} &= \sum_{u=1}^l \alpha^u \frac{\langle \mathbf{a}^{v_1}, \mathbf{a}^u \rangle}{\langle \mathbf{a}^{v_1}, \mathbf{a}^{v_1} \rangle} \\ \sum_{i=1}^c \hat{\beta}^{v_i} \frac{\langle \mathbf{a}^{v_2}, \mathbf{a}^{v_i} \rangle}{\langle \mathbf{a}^{v_2}, \mathbf{a}^{v_2} \rangle} &= \sum_{u=1}^l \alpha^u \frac{\langle \mathbf{a}^{v_2}, \mathbf{a}^u \rangle}{\langle \mathbf{a}^{v_2}, \mathbf{a}^{v_2} \rangle} \\ &\vdots \\ \sum_{i=1}^c \hat{\beta}^{v_i} \frac{\langle \mathbf{a}^{v_c}, \mathbf{a}^{v_i} \rangle}{\langle \mathbf{a}^{v_c}, \mathbf{a}^{v_c} \rangle} &= \sum_{u=1}^l \alpha^u \frac{\langle \mathbf{a}^{v_c}, \mathbf{a}^u \rangle}{\langle \mathbf{a}^{v_c}, \mathbf{a}^{v_c} \rangle} \end{aligned}$$

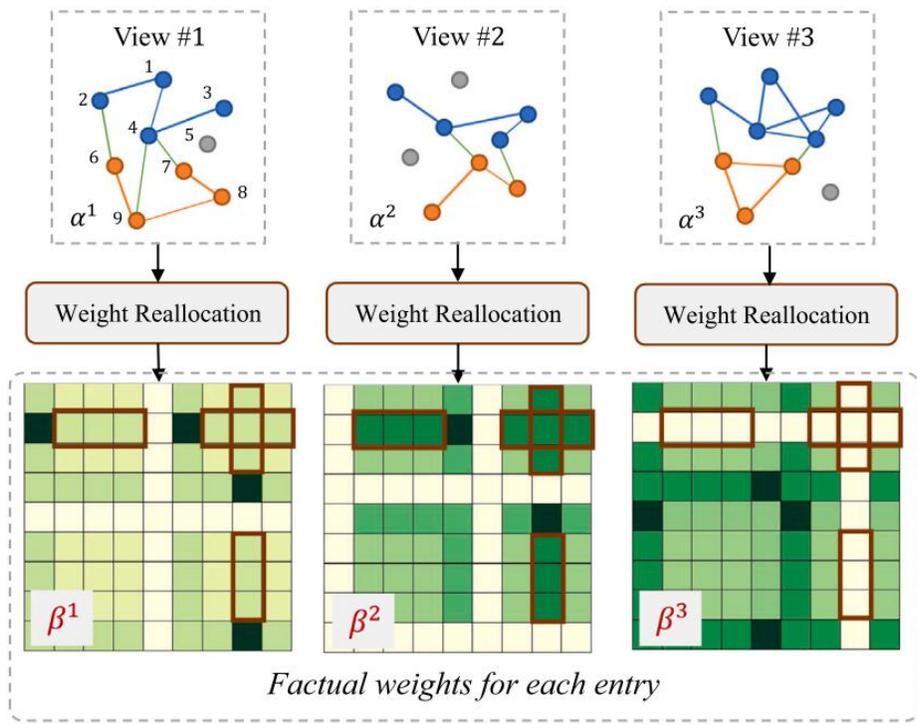


$$\hat{\beta} = U^{-1} V \alpha$$



算法原理图

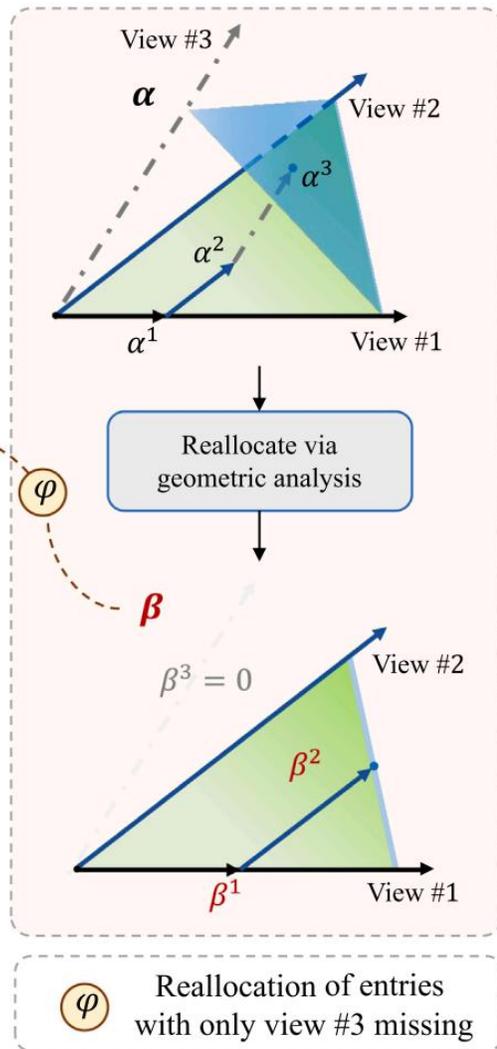
权重分配



图融合



拉普拉斯秩
约束聚类



损失函数

– 结合约束拉普拉斯的谱聚类，损失函数如下：方法

$$\min_{S^*, \alpha, \{\tilde{P}_{(ij)}\}} \sum_{i,j=1}^n \left(S_{ij}^* - (\tilde{P}_{(ij)} \alpha)^T a_{(ij)} \right)^2 + \gamma \|\alpha\|_2^2$$

• S_{ij}^* : 约束图； L_{S^*} 为其拉普拉斯矩阵， $\text{rank}(L_{S^*}) = n - k$ ；优化该目标可以得到满足聚类情况的图 S_{ij}^*

• $\tilde{P}_{(ij)}$: 权重再分配矩阵

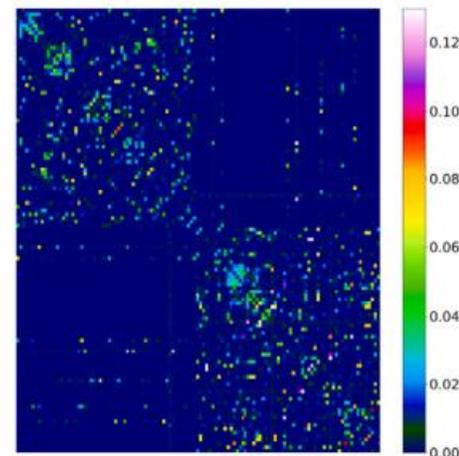
• $\alpha = [\alpha^1, \alpha^2, \dots, \alpha^l]^T$: 权重矩阵

• $a_{ij} = [A_{ij}^1, A_{ij}^2, \dots, A_{ij}^l]$: 每个视图的图向量（ k 邻近图）

• $\gamma \|\alpha\|_2^2$: 正则化项，防止最佳视图权重被设为1

– 函数中3个变量 S_{ij}^* 、 $\tilde{P}_{(ij)}$ 、 α ，使用块坐标下降法轮流优化

• 优化 $\tilde{P}_{(ij)}$ 、 α 本质上是优化 β



Constrained graph of GIGA

- 数据资源

- 数据集：数据集*8（图像*5、表格*1、文本*1、视频*1）

- 对比方法

- 传统单视图聚类方法

- BSV

- 现有的不完全多视图聚类方法

- 基于子空间：DAIMC、LSIC、MIC
- 基于谱：PIC、SRLC、SSIC
- 其他：MKIK、AGCIC、TCIMC

- 实验设置

- 缺失率 η ：每个视图的每个样本将以概率 η 被丢弃，保证每个样本至少有一个视图可用
- 评价指标：ACC、NMI、ARI

Details of real-world datasets.

Dataset	Size	Class	View	Dimensionality
MSRC-v1 [58]	210	7	5	24/576/512/256/254
HW4 [59]	2000	10	4	76/216/47/6
Caltech101-20 [60]	2386	20	6	48/40/254/1984/512/928
Caltech101-7 [60]	1474	7	6	48/40/254/1984/512/928
NGs [61]	500	4	3	2000/2000/2000
100Leaves [62]	1600	100	3	64/64/64
YoutubeFace [63]	101 499	31	5	64/512/64/647/838
TinyImageNet [64]	100 000	200	3	512/512/1280

实验结果

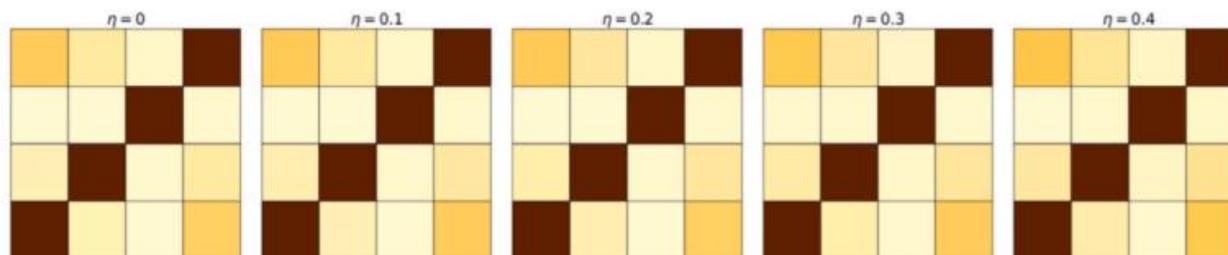
- DAIMC算法性能强：双重对齐和自适应加权：即使部分视图的数据严重缺失，算法也能够通过**其它视图**的信息进行**补偿**
- 缺失率数据增多，算法性能为什么还继续上升？
 - 缺失数据的情况下，算法可能更倾向于**强化现有视图之间的对齐和协同工作**

Clustering result with different missing ratio η on MSRC-v1 dataset.

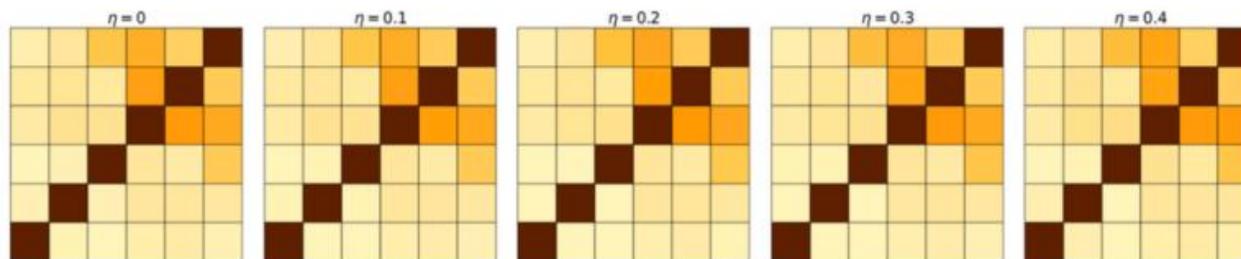
Dataset	MSRC-v1											
Metric	η	BSV	MIC	DAIMC	LSIC	PIC	SRLC	SGIC	MKIK	TCIMC	AGCIC	GIGA*
ACC	0	0.745	0.538	0.826	0.655	0.781	0.810	0.733	0.610	0.819	0.771	0.877
	0.1	0.635	0.522	0.828	0.573	0.793	0.777	0.734	0.607	0.690	0.802	0.870
	0.2	0.564	0.487	0.821	0.571	0.785	0.766	0.711	0.634	0.738	0.673	0.845
	0.3	0.477	0.410	0.828	0.534	0.804	0.731	0.730	0.643	0.765	0.562	0.809
	0.4	0.417	0.330	0.827	0.517	0.777	0.690	0.610	0.586	0.711	0.431	0.738
NMI	0	0.638	0.473	0.726	0.624	0.716	0.723	0.704	0.530	0.689	0.718	0.782
	0.1	0.539	0.438	0.724	0.526	0.704	0.670	0.669	0.524	0.620	0.719	0.774
	0.2	0.477	0.373	0.721	0.516	0.699	0.640	0.651	0.537	0.697	0.637	0.767
	0.3	0.410	0.285	0.726	0.433	0.713	0.605	0.655	0.547	0.693	0.576	0.745
	0.4	0.340	0.210	0.724	0.416	0.682	0.553	0.548	0.501	0.643	0.486	0.682
ARI	0	0.728	0.326	0.655	0.479	0.649	0.669	0.579	0.395	0.636	0.581	0.740
	0.1	0.683	0.280	0.653	0.376	0.643	0.611	0.568	0.393	0.520	0.643	0.724
	0.2	0.602	0.227	0.648	0.369	0.631	0.585	0.526	0.411	0.597	0.508	0.702
	0.3	0.530	0.139	0.653	0.295	0.648	0.535	0.535	0.434	0.613	0.382	0.661
	0.4	0.448	0.095	0.654	0.270	0.613	0.475	0.387	0.373	0.540	0.307	0.568

可解释性实验

- 在两个数据集MSRC-v1和Caltech101-20上验证**动态插值模块的稳定性**
- 结论：即使视图缺失，经过动态插值后的相似性矩阵仍然与完整数据集的相似性矩阵非常接近



(a) Approximated similarity on HW4



(b) Approximated similarity on Caltech101-20

$$\hat{\beta} = U^{-1}V\alpha$$

对参数 γ 进行超参实验

– 损失函数:

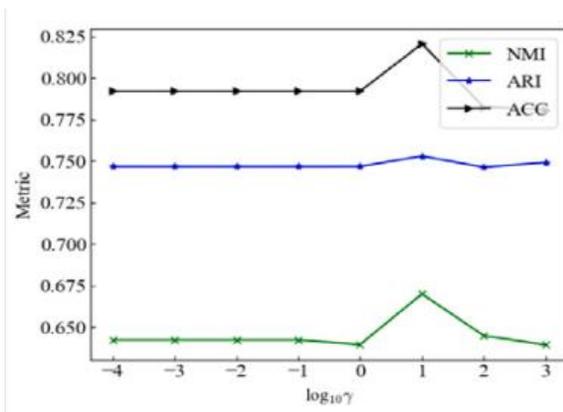
$$\min_{S^*, \alpha, \{\tilde{P}_{(ij)}\}} \sum_{i,j=1}^n \left(S_{ij}^* - (\tilde{P}_{(ij)} \alpha)^T \mathbf{a}_{(ij)} \right)^2 + \gamma \|\alpha\|_2^2$$

$$\hat{\beta} = U^{-1}V\alpha$$

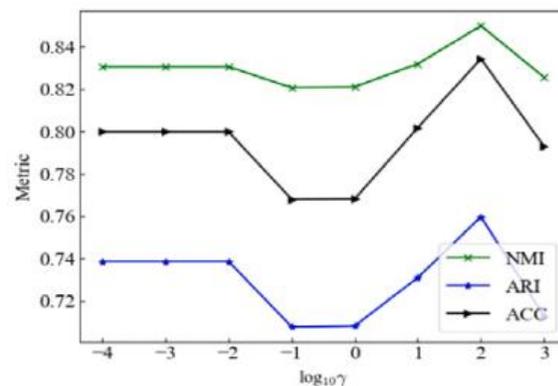
– 缺失率 η 设置为0.3

– 结论: 该正则项设置有效

- MSRC-v1数据集各视图质量分布均匀, 所以该正则项对此数据集上的聚类性能影响较小
- HW4:数据集各视图质量分布不均匀, 需要参数 γ 进行正则化, 保证算法性能



(a) MSRC-v1



(b) HW4



Adaptive Feature Imputation with Latent Graph for Deep Incomplete Multi-View Clustering

TIPO

T	目标	巩固各视图之间内在关系，减轻输入样本质量差和聚类结构差异带来的负面影响并完成准确聚类
I	输入	不完全多视图数据集*3【表格*1、文本*1、图像*1】
P	处理	<ol style="list-style-type: none"> 1.预训练自编码器提取视图潜在特征并初始化伪标签 2.(1)构建各视图潜在特征的k邻近图，使用GCN提取各图的结构信息 (2)构建各视图的融合图 3.使用融合视图指导恢复缺失样本的潜在特征 4.基于KL散度进行聚类
O	输出	聚类结果

P	问题	部分不完全多视图聚类算法忽视视图的潜在特征
C	条件	每个样本至少存在一个可用视图
D	难点	自适应调节各视图权重，有效整合信息
L	水平	AAAI2024 (CCF-A)

解决缺失数据造成的解偏移：视图恢复模块

– 通过可用数据指导恢复缺失数据

- 使用全局簇分配 q_i 、全局质心 C^v 、恢复矩阵 W 来指导缺失数据进行恢复

$$\min_{\{W^v\}_{v=1}^V} \sum_{v=1}^V \sum_{\tilde{z}_i^v \in \tilde{Z}_C} \|\tilde{z}_i^v - W^v q_i C^v\|_2^2.$$

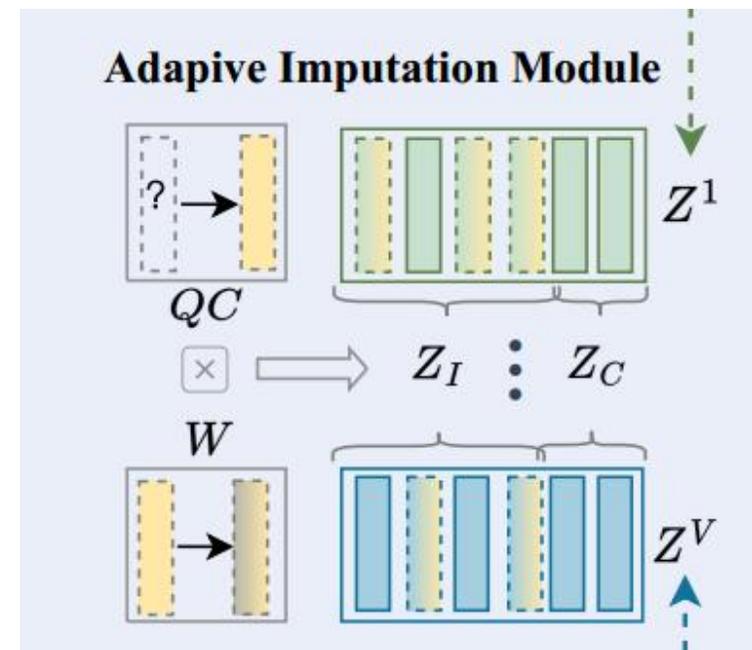
- \tilde{z}_i^v 是经过GCN提取的节点特征属性
- 使用 q_i 进行插值

$$q_{ij}^v = c_{\mu^v}^v(\tilde{z}_i^v) = \frac{(1 + \|\tilde{z}_i^v - \mu_j^v\|^2)^{-1}}{\sum_j (1 + \|\tilde{z}_i^v - \mu_j^v\|^2)^{-1}} \in Q^v$$

$$q_i = \frac{\sum_{v=1}^V \mathbf{I}_{iv} q_i^v}{\sum_{v=1}^V \mathbf{I}_{iv}} \in Q$$

- \mathbf{I}_{iv} 是标识矩阵，视图存在为1，缺失为0

$$\mathbf{I}_{iv} = 0$$



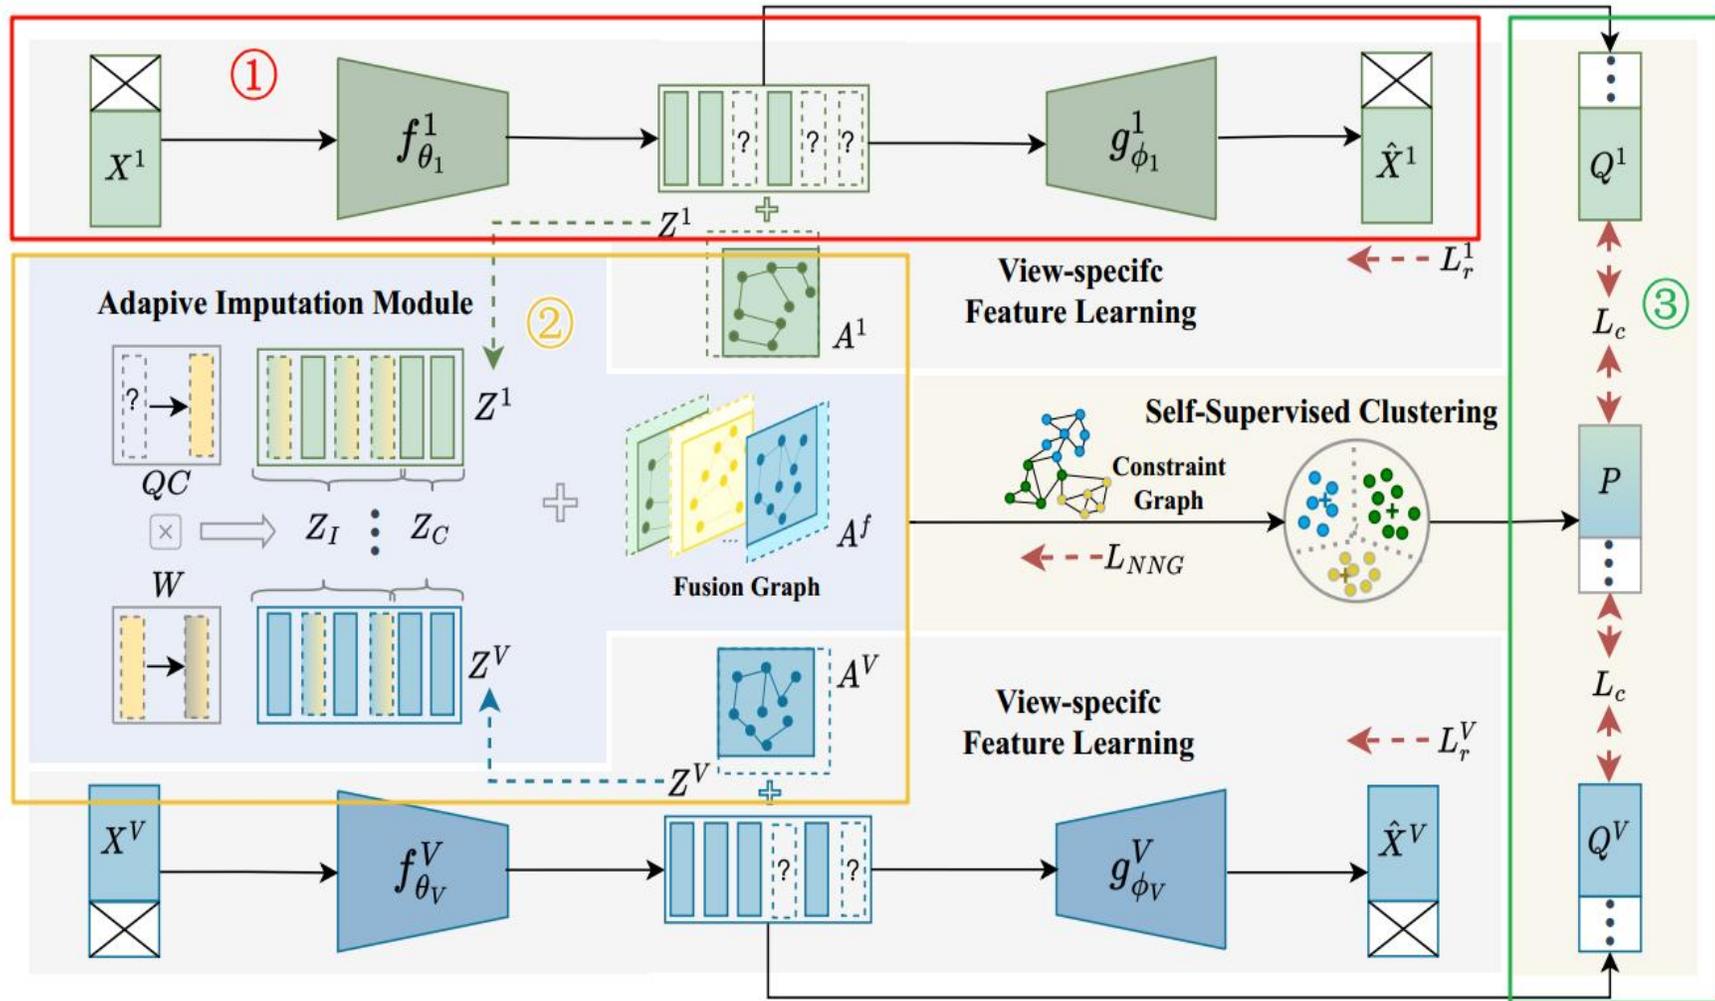
$$\tilde{z}_i^v = W^v q_i C^v \in \tilde{Z}_I$$

算法原理图

• 算法流程

- 提取特征模块
 - 自编码器
- 视图恢复模块
 - 动态插值
- KL散度聚类模块
 - 软分配
 - 目标分布

三个模块相互协同!



损失函数

• 损失函数

– 总损失函数: $L^v = L_r^v + \alpha L_c^v + L_{NNG}^v$

- 自编码器重建损失:

$$L_r^v = \sum_{v=1}^V L_r^v = \sum_{v=1}^V \sum_{i=1}^N \|x_i^v - g_{\phi^v}(f_{\theta^v}(x_i^v))\|^2$$



保证各视图的特异性

- 最邻近约束损失:

$$L_{NNG}^v = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^N \|h_i - h_j\|_2^2 A_{i,j}^v$$



加强完整数据间的关系

- KL散度聚类损失:

$$L_c^v = D_{KL}(P \| Q^v) = \sum_{i=1}^N \sum_{j=1}^K p_{ij} \log \frac{p_{ij}}{q_{ij}^v}$$



完成聚类

- 数据资源
 - 数据集: BDGP (图像)、Handwritten (表格)、Reuters (文本)
- 对比方法
 - 现有不完全多视图聚类方法数据
 - GIMC-FLSD、COMPLETER (DCP)、IMVC-CBG、DSIMVC、LSIMVC、PGP
- 实验设置
 - 自编码器设置
 - 结构: $Input - Fc500 - Fc500 - Fc2000 - Output$
 - 系数 $\alpha = 0.5$, 激活函数: ReLU
 - GCN: 两层传统GCN
 - 缺失率 η : 每个视图的每个样本将以 η 的概率被丢弃, 保证每个样本至少有一个视图可用
 - 评价指标: ACC、NMI、ARI

• 算法原理图

- AGDIMC算法在三个数据集上基本优于对比方法（完成结果见附录）
- 缺失率 η 在0.1~0.7期间聚类性能下降，但仍保持较高聚类水平
- PGP算法在缺失率下降时性能反而更优
 - 自引导模块在高缺失率时更加注重可用视图之间的关联性
- **DSIMVC**算法为次优：双层优化框架降低性能下降风险、动态插值

Missing rate		0.1			0.3			0.5			0.7		
Evaluation metrics		ACC	NMI	ARI									
BDGP	GIMC-FLSD(Wen et al. 2020b)	0.833	0.628	0.634	0.783	0.594	0.555	0.772	0.532	0.534	0.725	0.497	0.456
	CDIMC-net(Wen et al. 2021)	0.882	0.789	0.819	0.744	0.537	0.503	0.727	0.594	0.517	0.524	0.311	0.224
	DCP(Lin et al. 2021)	0.465	0.447	0.186	0.443	0.325	0.066	0.424	0.305	0.054	0.356	0.277	0.053
	HCP-IMSC(Li et al. 2022)	0.968	0.902	0.922	0.938	0.823	0.852	0.901	0.769	0.759	0.896	0.726	0.759
	IMVC-CBG(Wang et al. 2022)	0.392	0.242	0.154	0.374	0.221	0.106	0.363	0.176	0.056	0.342	0.018	0.068
	DSIMVC(Tang and Liu 2022)	0.963	0.905	0.912	0.956	0.886	0.910	0.941	0.829	0.859	0.917	0.791	0.807
	LSIMVC(Liu et al. 2022)	0.732	0.713	0.805	0.613	0.555	0.571	0.490	0.388	0.493	0.380	0.236	0.575
	PGP(Liu et al. 2023)	0.526	0.327	0.536	0.472	0.316	0.542	0.496	0.310	0.496	0.422	0.268	0.496
	AGDIMC(ours)	0.979	0.937	0.949	0.962	0.908	0.912	0.961	0.883	0.906	0.922	0.829	0.816

消融实验

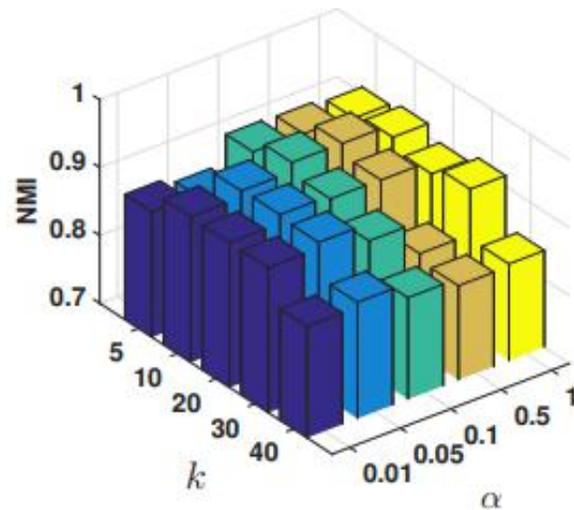
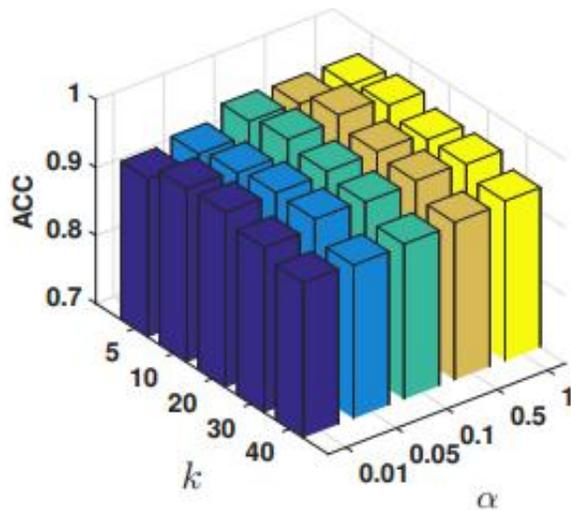
- A: 图卷积网络及全局图融合模块
- B: 视图恢复模块
- C: 最邻近约束模块
- 由图中可以看出，对视图进行有效地恢复，能够很大程度上缓解缺失视图造成的解偏移现象，提高聚类性能

	Components			BDGP			Reuters			HW		
	A	B	C	ACC	NMI	ARI	ACC	NMI	ARI	ACC	NMI	ARI
Item-1		✓	✓	0.932	0.824	0.807	0.527	0.304	0.211	0.907	0.883	0.869
Item-2	✓		✓	0.789	0.643	0.598	0.502	0.314	0.218	0.880	0.841	0.827
Item-3	✓	✓		0.913	0.783	0.797	0.462	0.268	0.204	0.938	0.902	0.895
Item-4	✓	✓	✓	0.979	0.937	0.949	0.588	0.354	0.294	0.973	0.943	0.941

超参实验

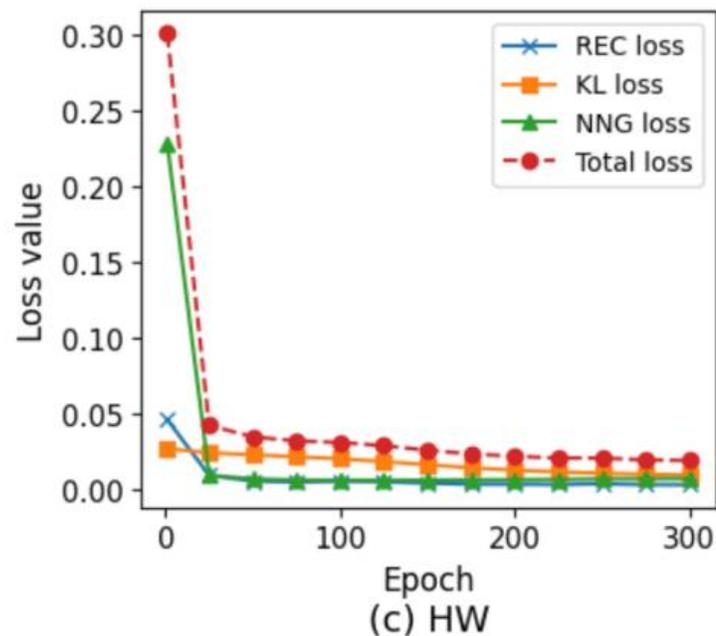
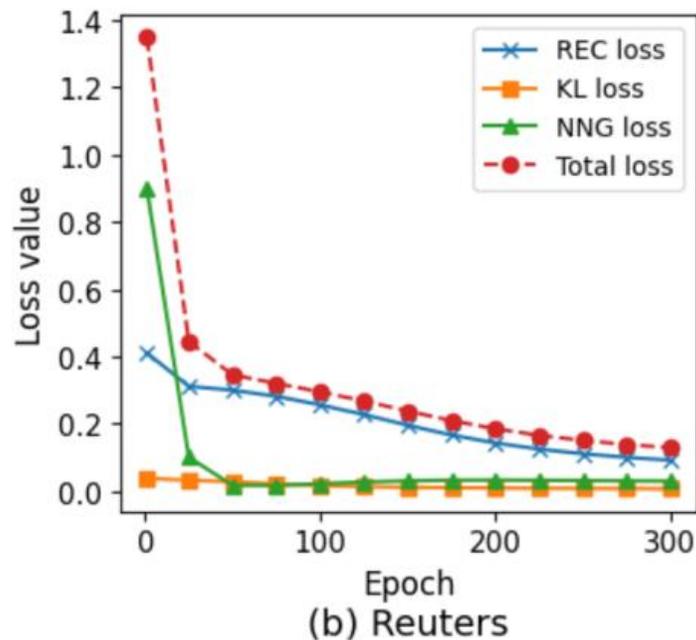
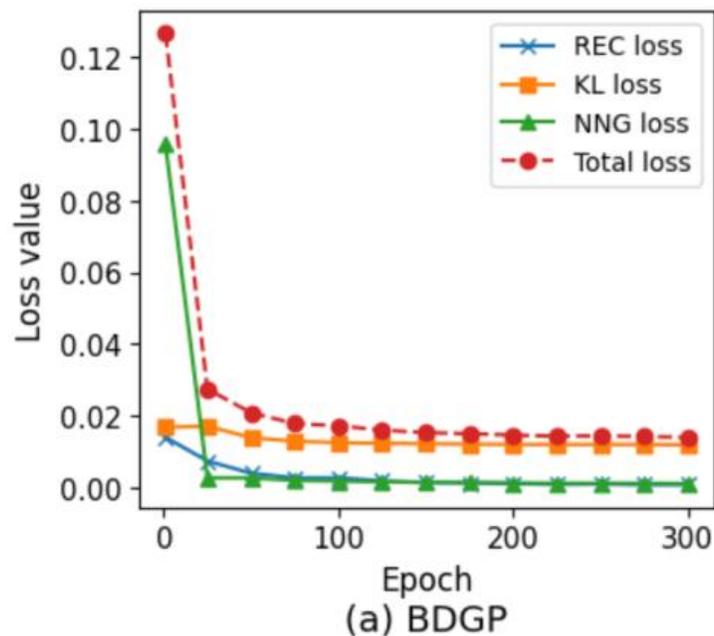
• 超参实验

- 损失函数: $L^v = L_r^v + \alpha L_c^v + L_{NNG}^v$
- 对两个主要超参数 α 和 k （聚类簇数）的敏感性进行分析
- 在 α 值的一定范围内，聚类性能保持相对稳定：模型对该超参数的变化具有鲁棒性



收敛性分析

- 对自编码器重建 (REC)、KL散度聚类损失 (KL)、最邻近约束损失 (NNG) 损失和总损失进行收敛分析
- 随着epoch数的增加，四个损失函数都**逐渐收敛并达到稳定状态**



北京林业大学
景观规划设计学院



特点总结与未来展望

- 特点总结

算法	GIGA	AGDIMC
优势	1. 从几何角度解析缺失视图的影响，分析了多视图聚合过程中的 解移位现象 2. 使用拉普拉斯秩约束图进行谱聚类，更好地提升聚类效果	1. 使用 自适应插值 动态恢复缺失样本 2. 结合图嵌入技术 保持各视图的局部结构
劣势	需要数据预处理	时间复杂度高

- 未来展望

- 将几何分析思想和模块运用到各类视图缺失的场景中
- 与深度学习相结合，提升算法在大规模应用场景下的适用性
- 引入更多约束条件更好地恢复视图（**多阶邻近约束**）

- 预期收获
 - 掌握不完全多视图聚类技术的基本概念势
 - 聚类
 - 不完全多视图
 - 理解几何层面的不完全多视图学习
 - 缺失视图影响
 - 不完全多视图聚合中的解位移现象
 - 了解不完全多视图聚类的技术原理
 - 互补性
 - 一致性
 - 明确不完全多视图聚类的应用领域和发展方向



- [1] Yang Z, Zhang H, Wei Y, et al. Geometric-inspired graph-based Incomplete Multi-view Clustering[J]. Pattern Recognition, 2024, 147: 110082.
- [2] Pu J, Cui C, Chen X, et al. Adaptive Feature Imputation with Latent Graph for Deep Incomplete Multi-View Clustering[C]. Proceedings of the AAAI Conference on Artificial Intelligence. 2024, 38(13): 14633-14641.
- [3] Wen J, Zhang Z, Fei L, et al. A survey on incomplete multiview clustering[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2022, 53(2): 1136-1149.

知人者智，自知者明。胜人者有力，自胜者强。知足者富。强行者有志。不失其所者久。死而不亡者，寿。

谢谢！



	Missing rate	0.1			0.3			0.5			0.7		
	Evaluation metrics	ACC	NMI	ARI									
BDGP	GIMC-FLSD(Wen et al. 2020b)	0.833	0.628	0.634	0.783	0.594	0.555	0.772	0.532	0.534	0.725	0.497	0.456
	CDIMC-net(Wen et al. 2021)	0.882	0.789	0.819	0.744	0.537	0.503	0.727	0.594	0.517	0.524	0.311	0.224
	DCP(Lin et al. 2021)	0.465	0.447	0.186	0.443	0.325	0.066	0.424	0.305	0.054	0.356	0.277	0.053
	HCP-IMSC(Li et al. 2022)	<u>0.968</u>	0.902	<u>0.922</u>	0.938	0.823	0.852	0.901	0.769	0.759	0.896	0.726	0.759
	IMVC-CBG(Wang et al. 2022)	0.392	0.242	0.154	0.374	0.221	0.106	0.363	0.176	0.056	0.342	0.018	0.068
	DSIMVC(Tang and Liu 2022)	0.963	<u>0.905</u>	0.912	<u>0.956</u>	<u>0.886</u>	<u>0.910</u>	<u>0.941</u>	<u>0.829</u>	<u>0.859</u>	<u>0.917</u>	<u>0.791</u>	<u>0.807</u>
	LSIMVC(Liu et al. 2022)	0.732	0.713	0.805	0.613	0.555	0.571	0.490	0.388	0.493	0.380	0.236	0.575
	PGP(Liu et al. 2023)	0.526	0.327	0.536	0.472	0.316	0.542	0.496	0.310	0.496	0.422	0.268	0.496
	AGDIMC(ours)	0.979	0.937	0.949	0.962	0.908	0.912	0.961	0.883	0.906	0.922	0.829	0.816
Reuters	GIMC-FLSD(Wen et al. 2020b)	0.478	0.292	0.208	0.469	0.283	0.202	<u>0.473</u>	<u>0.275</u>	0.202	<u>0.494</u>	0.283	<u>0.216</u>
	CDIMC-net(Wen et al. 2021)	0.310	0.130	0.075	0.303	0.080	0.051	0.263	0.053	0.027	0.253	0.050	0.027
	DCP(Lin et al. 2021)	0.323	0.141	0.06	0.315	0.158	0.042	0.232	0.137	0.013	0.224	0.095	0.014
	HCP-IMSC(Li et al. 2022)	0.342	0.175	0.085	0.357	0.209	0.111	0.407	0.219	0.136	0.386	0.218	0.133
	IMVC-CBG(Wang et al. 2022)	0.442	0.273	0.139	0.402	0.228	0.103	0.364	0.213	0.088	0.348	0.188	0.057
	DSIMVC(Tang and Liu 2022)	0.455	0.302	0.224	0.425	0.274	0.198	0.421	0.256	0.187	0.418	0.237	0.174
	LSIMVC(Liu et al. 2022)	0.382	0.209	0.131	0.398	0.221	0.145	0.303	0.152	0.062	0.243	0.107	0.029
	PGP(Liu et al. 2023)	<u>0.575</u>	<u>0.348</u>	0.338	<u>0.516</u>	<u>0.306</u>	0.359	0.245	0.088	0.285	0.261	0.108	0.215
	AGDIMC(ours)	0.588	0.354	<u>0.294</u>	0.548	0.261	<u>0.245</u>	0.548	0.293	<u>0.236</u>	0.509	<u>0.256</u>	0.227
HW	GIMC-FLSD(Wen et al. 2020b)	0.613	0.577	0.456	0.427	0.440	0.307	0.408	0.431	0.229	0.262	0.174	0.046
	DCP(Lin et al. 2021)	0.797	0.753	0.570	0.742	0.743	0.640	0.738	0.734	0.626	0.752	0.725	0.596
	CDIMC-net(Wen et al. 2021)	0.933	0.878	0.861	0.892	0.831	0.808	0.854	<u>0.886</u>	0.807	0.789	0.804	0.724
	HCP-IMSC(Li et al. 2022)	0.817	0.788	0.724	0.797	0.767	0.709	0.775	0.710	0.651	0.636	0.545	0.392
	IMVC-CBG(Wang et al. 2022)	0.572	0.598	0.444	0.512	0.509	0.320	0.471	0.473	0.237	0.426	0.406	0.144
	DSIMVC(Tang and Liu 2022)	0.810	0.798	0.725	0.778	0.772	0.686	0.762	0.736	0.650	0.747	0.732	0.648
	LSIMVC(Liu et al. 2022)	<u>0.943</u>	<u>0.889</u>	<u>0.920</u>	<u>0.936</u>	<u>0.880</u>	<u>0.912</u>	<u>0.874</u>	0.828	<u>0.865</u>	<u>0.858</u>	0.765	0.838
	PGP(Liu et al. 2023)	0.836	0.835	0.846	0.850	0.854	0.839	0.854	0.863	0.842	0.823	<u>0.814</u>	0.845
	AGDIMC(ours)	0.973	0.943	0.941	0.956	0.912	0.906	0.946	0.882	0.881	0.926	0.855	<u>0.842</u>