

基于 S^2AF -GCN 的高光谱遥感图像分类模型

宋海林, 汪西莉*

陕西师范大学计算机科学学院, 陕西 西安 710119

摘要 在高光谱图像分类任务中,图卷积网络能够建模像素或区域间的结构关系和相似性关系。针对利用像素原始光谱特征计算节点相似度构造邻接矩阵不准确的问题,提出基于空间-光谱聚合特征的图卷积网络(S^2AF -GCN),用于特征提取和像素级分类。以像素的空间位置为中心,聚合像素空间邻域内的其他像素特征,利用聚合后的像素特征动态更新与邻域内其他像素的权重,通过多次聚合,实现区域内像素特征平滑,得到像素的有效特征表示。然后利用聚合特征计算相似度并构图,获得更为准确的邻接矩阵,同时利用聚合特征训练网络,获得更好的分类结果。 S^2AF -GCN 在三个常用高光谱数据集 Indian Pines, Pavia University, Kennedy Space Center 上利用 1% 的标记样本取得了 85.51%、96.95%、94.92% 的总体分类精度。

关键词 图卷积网络; 聚合特征; 高光谱遥感图像分类; 空谱信息

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP220612

Hyperspectral Remote Sensing Image Classification Model Based on S^2AF -GCN

Song Hailin, Wang Xili*

School of Computer Science, Shaanxi Normal University, Xi'an 710119, Shaanxi, China

Abstract For hyperspectral image classification tasks, a graph convolutional network can model the structural and similarity relationships between pixels or regions. To solve the problem of inaccurate construction of an adjacency matrix by calculating the node similarity using the original spectral features of pixels, a graph convolutional network based on spatial-spectral aggregation features (S^2AF -GCN) is proposed for feature extraction and pixel-level classification. The S^2AF -GCN considers the spatial position of the pixel as the center, aggregates other pixel features in the spatial neighborhood of the pixel, and uses the aggregated pixel features to dynamically update the weights of other pixels in the neighborhood. Through multiple aggregations, the pixel features in the region are smoothed, and the effective feature representation of the pixels is obtained. Next, the aggregated features are used to calculate the similarity and construct a more accurate adjacency matrix. Moreover, the aggregated features are simultaneously used to train the S^2AF -GCN to obtain better classification results. The S^2AF -GCN achieves overall classification accuracies of 85.51%, 96.95%, and 94.92% on three commonly used hyperspectral datasets, namely, Indian Pines, Pavia University, and Kennedy Space Center, respectively, using 1% labeled samples.

Key words graph convolution network; aggregation feature; hyperspectral remote sensing image classification; spatial-spectral information

1 引言

随着高光谱成像技术的迅猛发展,近年来高光谱图像在土地覆被利用、军事目标检测、矿物识别、防灾减灾等领域受到广泛关注^[1-2]。高光谱图像由数百个连续的光谱带组成,丰富的光谱特征使其在识别土地覆盖类型方面具有显著优势^[3-4]。许多研究者对高光谱图像进行了深入的研究,早期研究主要基于传统的

模式识别方法,直接利用光谱特征或基于人工设计的空谱特征进行特征提取,之后采用支持向量机(SVM)^[5]等方法进行分类。

近年来,受益于卷积神经网络(CNN)和深度学习(DL)技术,对高光谱图像进行分类的各种先进的深度神经网络取得了重大进展^[6-7]。Chen等^[8]采用的CNN从高光谱图像中自动提取空间特征和光谱特征,同时获得了更高的分类性能。CNN可以应对像素特征的提取

收稿日期: 2022-01-24; 修回日期: 2022-02-26; 录用日期: 2022-03-14; 网络首发日期: 2022-03-26

基金项目: 国家自然科学基金(61701290)

通信作者: *wangxili@snnu.edu.cn

任务,但传统的 CNN 模型只对规则的矩形区域进行卷积,也有对不规则的区域提高特征提取能力的研究,如可变形卷积^[9],但其计算复杂度很高;CNN 模型参数较多,在标记样本较少的情况下往往不能很好地提取特征,且模型训练时间较长;此外,CNN 不能捕捉和利用高光谱图像中不同像素或区域间的关系,而这种通常以相似性表达的关系隐含了数据的结构信息,会为特征提取和分类提供更多的有用信息。2017 年,Kipf 等^[10]提出了图卷积网络(GCN)模型,将 GCN 模型用于高光谱图像分类时,图像中的每一个像素(或超像素^[11])看作一个节点,通过计算节点之间的相似度构造邻接矩阵,建模节点之间的几何结构关系和相似性关系,为分类提供更多更有效的信息^[12]。

众多研究表明,像素的空间邻域信息与光谱信息对分类结果都至关重要^[13]。Hong 等^[14]对比了 GCN 与 CNN 的区别和联系,提出了 GCN 与 CNN 相结合的模型 FuNet-C。该模型利用 CNN 提取像素 7×7 范围内的特征,同时利用光谱特征计算节点相似度构造邻接矩阵,利用 GCN 提取节点特征,将两个网络获得的特征级联再加全连接层进行分类。该模型意在建模像素之间的关系,利用 GCN 模型更新节点光谱特征,同时利用 CNN 提取像素局部空间特征和光谱特征,但在标记样本比较少的情况下,CNN 难以很好地提取像素的空间光谱特征,因此该模型的性能提升受限。Danel 等^[15]认为 GCN 模型能够建模节点之间的关联关系,但忽视了像素在图像中的空间相邻关系,提出了空间图卷积网络(SGCN),该模型在构建邻接矩阵时选择的邻居节点均为像素空间邻域内的节点。Qin 等^[16]认为像素的光谱特征信息与像素在图像中的空间邻域信息都很重要,提出了光谱-空间图卷积网络(S^2 GCN)模型。该模型利用像素的光谱特征计算节点之间的相似度,通过 KNN(K-nearest neighbor)算法选择 10 个近邻,然后再计算每个像素与图像中 5×5 范围内其他像素的相似度,二者进行相乘融合,获得最终的邻接矩阵。SGCN 模型与 S^2 GCN 模型虽然都利用了空间光谱信息,但二者构造的邻接矩阵都限制在空间局部邻域范围内。

构造的邻接矩阵不准确是影响 FuNet-C、 S^2 GCN

等模型性能的另一个原因。FuNet-C 模型和 S^2 GCN 模型都利用像素的原始光谱特征计算相似度,利用 KNN 算法选择 K 个近邻构造邻接矩阵,因遥感影像中“同谱异物,同物异谱”现象的存在,邻接矩阵中不同类节点之间可能存在关联,因此 GCN 模型更新后的节点特征中可能包含非同类节点的特征,影响分类结果。为获得较为准确的邻接矩阵,Wan 等^[17]设计了动态图卷积,即 GCN 对节点特征更新后,利用更新后的节点特征重新计算节点的相似度,重新构造邻接矩阵。但若初始构造的邻接矩阵不准确,后续再更新节点特征和邻接矩阵的话,依然难以达到获得具有所需表达能力的节点特征和邻接矩阵的目的,进而难以提升分类性能。为此,Bai 等^[18]利用核光谱角度映射器与光谱信息散度(KSAM-SID)度量节点之间的相似性,以构造较为准确的初始邻接矩阵,然后再利用 GCN 更新节点特征,利用新的节点特征重新构造邻接矩阵,该方法取得了不错的分类效果。

为了充分利用像素的空间邻域信息和光谱信息,同时解决利用原始光谱特征计算节点相似度构造邻接矩阵不准确的问题,本文提出了基于空间-光谱聚合特征的图卷积网络(S^2 AF-GCN),用于高光谱遥感图像分类。该模型首先提取像素的空间-光谱聚合特征,再利用 GCN 更新与转换节点特征,获得分类结果。本文主要贡献有两个方面:一是提出了空间-光谱聚合特征方法,该方法以像素的空间位置为中心,聚合其周围邻域内的像素特征,利用聚合后的像素特征动态更新像素与邻域内像素的相似度权重,通过多次聚合,可充分利用像素的空间光谱信息,并对空间区域内的像素特征进行平滑,得到像素的有效特征表示;二是建模节点之间的连接关系,并利用聚合特征计算节点之间的相似度,与利用原始光谱特征计算节点相似度相比,利用聚合特征计算所得的邻接矩阵更为准确,可以获得更好的分类结果。

2 基于空间-光谱聚合特征的图卷积网络

基于 S^2 AF-GCN 的高光谱遥感图像分类模型如图 1 所示。该模型主要由空间-光谱聚合特征模块和

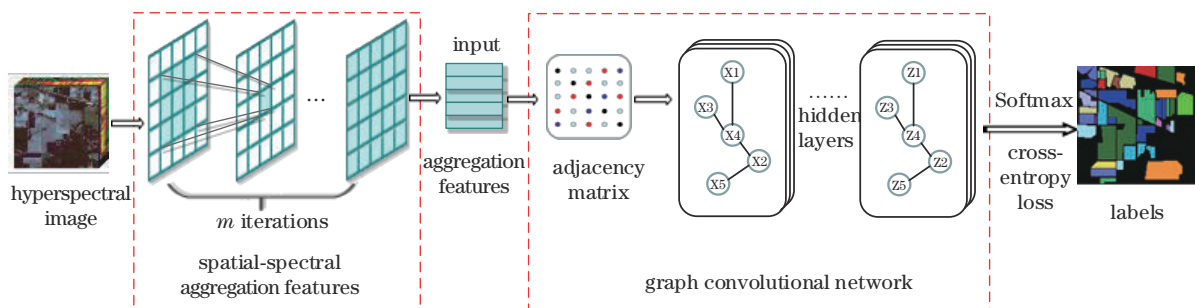


图 1 基于 S^2 AF-GCN 的高光谱遥感图像分类模型

Fig. 1 Classification model of hyperspectral remote sensing images based on S^2 AF-GCN

图卷积网络模块组成。输入一幅高光谱图像,利用空间-光谱聚合特征模块对像素的原始光谱特征(OF)进行聚合平滑,将聚合平滑后的像素特征称为聚合特征(AF);以像素为节点,利用聚合特征计算节点之间的相似度,构造邻接矩阵;将聚合特征和邻接矩阵送入图卷积网络,获得分类结果。

2.1 空间-光谱聚合特征

对于像素级图像分类任务,空间上相邻的像素往往属于同一类^[13,16,19],为充分利用像素的空间邻域信息,对中心像素空间邻域内的像素特征进行动态加权聚合是一种有效的方式。在图像中,对位于边界上的像素聚合周围三邻域或五邻域的像素特征,对于其他内部像素,则聚合周围八邻域的像素特征。记 \mathbf{X}_{OF} 为像素的原始光谱特征矩阵, \mathbf{X}_{AF} 为像素的聚合特征矩阵, $\mathbf{X}_{\text{OF}} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)^T$, 其中 N 为像素的个数, $\mathbf{x}_i \in \mathbf{R}^d$, \mathbf{x}_i 代表第 i 个像素的特征列向量, d 为特征的维度。将空间邻域矩阵记为 \mathbf{S} , $\mathbf{S} \in \mathbf{R}^{N \times N}$, 若 $S_{ij} > 0$, 则节点 j 位于节点 i 的空间八邻域内, 否则 $S_{ij} = 0$ 。 S_{ij} 可由径向基函数计算得到, 表达式为

$$S_{ij} = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right), \quad (1)$$

式中: σ 为径向基函数的参数。记 \mathbf{H} 为空间邻域矩阵 \mathbf{S} 的度矩阵, 即 \mathbf{H} 的对角线元素为 $H_{ii} = \sum_j S_{ij}$, 其余元素均为 0。将聚合后第 i 个像素的特征记为 $(\mathbf{X}_{\text{AF}})_i$, 则空间-光谱聚合特征操作的计算过程为

$$(\mathbf{X}_{\text{AF}})_i = \mathbf{H}^{-1} \mathbf{S}_i \mathbf{X}_{\text{OF}} = \sum_j H_{ii}^{-1} S_{ij} \mathbf{x}_j. \quad (2)$$

对每一个像素,按式(2)计算一次,便是一次特征聚合过程,每完成一次特征聚合,像素的特征便更新一

次,更新后的每个像素特征都包含其周围邻域内的像素特征。特征聚合操作使得同类节点之间的特征更加相似,因此在聚合过程中,中心像素与其邻域内其他像素的相似度权重也应该动态更新,更新公式为

$$S_{ij}^{(m)} = \exp\left(-\frac{\|\mathbf{x}_i^{(m)} - \mathbf{x}_j^{(m)}\|^2}{2\sigma^2}\right), \quad (3)$$

式中: m 为特征聚合次数。通过多次聚合迭代,可实现区域特征的平滑。聚合迭代公式为

$$\mathbf{X}^{(m+1)} = \mathbf{H}^{-1} \mathbf{S}^{(m)} \mathbf{X}^{(m)}. \quad (4)$$

当 $m=0$ 时, $\mathbf{X}^{(0)}$ 即为像素原始光谱特征 \mathbf{X}_{OF} , 式(3)即为式(1), 当 $m > 0$ 时, $\mathbf{X}^{(m)}$ 统称为像素聚合特征 \mathbf{X}_{AF} 。

以每个像素的空间位置为中心,聚合其周围邻域内的像素特征到中心节点,不仅充分利用了像素的空间信息,同时缩小了像素之间的类内距离,相对扩大了类间距离。如图2所示,以 Indian Pines 数据集中空间位置坐标为(35,30)的像素(方形节点)作示例,其余8个圆形节点代表该像素在图像中的空间八邻域像素。这8个像素在图2(a)中的位置坐标通过计算所得,8个节点到中心节点的直线距离等于利用原始光谱特征计算8个节点到中心节点所得的欧氏距离,以左上角节点为例,即 $\sqrt{(34.48 - 35)^2 + (30.52 - 30)^2} = \|\mathbf{x}_{(34.48,30.52)} - \mathbf{x}_{(35,30)}\|$ 。同理,利用聚合特征计算8个节点到中心节点的欧氏距离,可得8个节点在图2(b)中的位置坐标。通过图2(a)和图2(b)的对比可以发现,经过特征聚合操作,与中心节点特征越相似的邻域节点的距离被拉得越近,在聚合中起的作用越大,表明聚合特征可以使相似节点的特征变得平滑,通过聚合可得到像素更有效的特征表达。




图2 空间邻域特征聚合效果。(a)原始特征计算所得欧氏距离;(b)聚合特征计算所得欧氏距离
Fig. 2 Renderings of spatial neighborhood feature aggregation. (a) European distance calculated by original features; (b) European distance calculated by aggregation features

2.2 构图

在基于图的分类任务中,构图非常重要。构图包括两步:一是确定节点间有没有边;二是计算边上的权

重。在空间邻域矩阵 \mathbf{S} 中,像素只与其空间八邻域的像素存在边连接,边上的权重随着特征的不断聚合而动态更新,通过空间-光谱聚合特征操作,可以充分利

用像素的空间邻域信息提取空谱特征。利用 GCN 模型进行节点分类时同样需要先构图,通过空间-光谱聚合特征操作得到聚合特征,利用聚合特征计算节点之间的相似度,使用 KNN 算法为每一个像素选择出 K 个近邻,建立起节点之间的连接关系,同时将聚合特征计算所得节点间的相似度作为边上的权重。这样构图可以让同类节点更多地连接在一起,减少不同类节点之间的连接,同时同类节点间的连接权重更大,从而构造出更为准确的邻接矩阵。

高光谱图像波段有数百个,不同的地物类型可能具有相似的光谱特征,同类地物也可能呈现差异较大的光谱特征。因此,直接利用像素的光谱特征计算节点之间的相似度难以准确反映同类或不同类节点间的相似性。如图 3 所示,圆形节点为同一类,方形节点为另一类,假设利用 KNN 算法选择近邻时,由于光谱特征比较相似,圆形节点可能出现在方形节点的 K 近邻




图 3 不同类节点之间存在连接关系

Fig. 3 Connections between nodes of different classes




图 4 原始光谱特征构图与聚合特征构图对比。(a)随机样本;(b)原始特征所得 5 近邻;(c)聚合特征所得 5 近邻

Fig. 4 Comparison of composition based on original features and aggregation features. (a) Random samples; (b) 5 nearest neighbors from original features; (c) 5 nearest neighbors from aggregation features

2.3 图卷积网络

图是一种复杂的非线性数据结构,用于描述非欧几里得空间中一对多的关系。图可以表示为 $G = (V, E, A)$,其中 $V = (v_1, v_2, \dots, v_N)$ 代表节点的集合, E 代表边的集合, A 是图的邻接矩阵,如果节点 v_i 和 v_j 之间存在边连接,即 $e_{ij} = (v_i, v_j) \in E$,那么 $A_{ij} > 0$,否则

中,同理,方形节点也有可能出现在圆形节点的近邻中。当利用 GCN 进行节点分类时,圆形中心节点也对方形节点的特征进行了聚合,当堆叠更多的图卷积层时,方形节点的邻居节点特征也会被聚合到圆形中心节点。考虑一个极端的情况,假设构图时,同一类的节点都连接在一起,不同类的节点之间没有连接关系,只要不同类别之间是可区分的,那么通过堆叠多个卷积层就可以获得很好的分类效果。因此,邻接矩阵的准确性对于图神经网络的分类至关重要。

与原始光谱特征相比,利用聚合特征计算节点间相似度,并通过 KNN 算法选择近邻,可以构造出更为准确的邻接矩阵。如图 4(a) 所示,随机地从 Indian Pines 数据集第 1 类和第 8 类样本中各选择 10 个样本,以样本点在图像中的空间位置为坐标作图展示,其中圆形代表第 1 类样本,三角形代表第 8 类样本。利用原始光谱特征计算相似度,利用 KNN 算法选择图 4(a) 中样本点的 5 近邻,同样将选择出的近邻在图像中的空间位置为坐标作图展示,结果如图 4(b) 所示。在图 4(b) 中,若选择的近邻与样本点类别一致,则与样本点标注同样的类型,若类别不一致,则将近邻标注为“×”。由图 4(b) 可知,利用原始光谱特征计算相似度得到的近邻有很多其他类别的节点,即邻接矩阵反映的相似性关系很多是不准确的。图 4(c) 为利用聚合特征计算相似度求得的近邻,可以明显地看出,图 4(c) 中得到的大部分近邻都与样本点类别一致。因此,利用聚合特征构图,可以得到更为准确的邻接矩阵,另一方面,聚合特征使得同类节点之间相似度更高,可进一步提升分类结果。

$A_{ij} = 0$ 。图的拉普拉斯矩阵定义为 $L = D - A$, D 称为度矩阵,对角线元素为 $D_{ii} = \sum_j A_{ij}$,归一化的拉普拉斯矩阵定义为 $L_{\text{sym}} = I_N - D^{-\frac{1}{2}} L D^{-\frac{1}{2}}$,其中 I_N 为单位矩阵。

图卷积网络是一个多层神经网络,它可以直接在图上进行卷积操作。图上的卷积操作定义为

$$\mathbf{g}_\theta \star \mathbf{x} = \mathbf{U} \mathbf{g}_\theta \mathbf{U}^T \mathbf{x}, \quad (5)$$

式中: \mathbf{x} 为图节点信号; $\mathbf{g}_\theta = \text{diag}(\theta)$ 是参数化的对角矩阵; \mathbf{U} 是归一化的拉普拉斯矩阵的特征向量, 即 $\mathbf{L}_{\text{sym}} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^T$, $\mathbf{\Lambda}$ 是由特征值组成的对角矩阵; \mathbf{g}_θ 可以理解为 \mathbf{L}_{sym} 的特征值函数, 即 $\mathbf{g}_\theta(\mathbf{\Lambda})$ 。式(5)所定义的卷积操作需对拉普拉斯矩阵进行特征分解, 代价较大, Defferrard 等^[20]和 Hammond 等^[21]用切比雪夫多项式 $T_k(\mathbf{x})$ 的 k 阶截断展开式有效地逼近特征值函数 $\mathbf{g}_\theta(\mathbf{\Lambda})$ 。

$$\mathbf{g}_\theta(\mathbf{\Lambda}) \approx \sum_{k=0}^K \theta'_k T_k(\tilde{\mathbf{\Lambda}}), \quad (6)$$

式中: $\theta' \in \mathbf{R}^k$ 是切比雪夫系数向量; $\tilde{\mathbf{\Lambda}} = \frac{2}{\lambda_{\max}} \mathbf{\Lambda} - \mathbf{I}$, λ_{\max} 代表拉普拉斯矩阵 \mathbf{L}_{sym} 最大的特征值。Kipf 等^[10]用切比雪夫多项式的一阶截断展开式来近似特征值函数, 同时进一步近似 $\lambda_{\max} = 2$, 得到了简化的图卷积操作, 表达式为

$$\mathbf{g}_\theta \star \mathbf{x} \approx \theta \left(\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \right) \mathbf{x}. \quad (7)$$

记 $\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}}$ 为 $\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$, 其中 $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$, $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ 。对图卷积定义进行推广, 假设节点特征向量有 P 个通道, 则 N 个节点的特征向量矩阵为 $\mathbf{X} \in \mathbf{R}^{N \times P}$ 。假设有 F 个滤波器, 一次卷积操作为

$$\mathbf{Z} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X} \mathbf{\Theta}, \quad (8)$$

式中: $\mathbf{\Theta} \in \mathbf{R}^{P \times F}$ 为滤波器参数矩阵; $\mathbf{Z} \in \mathbf{R}^{N \times F}$ 为获得的卷积向量矩阵。式(8)代表的卷积操作可以当作一个卷积层。通过堆叠多个卷积层便可建立起更深层的图卷积网络模型, 表达式为

$$\mathbf{X}^{(l+1)} = \sigma \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}^{(l)} \mathbf{W}^{(l)} \right), \quad (9)$$

式中: $\sigma(\cdot)$ 为激活函数; \mathbf{W} 为可训练的参数矩阵; l 代表图卷积网络层数。空间-光谱聚合特征模块对空间邻域内的像素特征进行动态聚合, 得到聚合特征, 利用聚合特征构造准确的邻接矩阵, 根据式(9)构建一个两层的图卷积网络:

$$\mathbf{X}^{(2)} = \text{ReLU} \left[\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \text{ReLU} \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}^{(0)} \mathbf{W}^{(0)} \right) \mathbf{W}^{(1)} \right], \quad (10)$$

式中: $\mathbf{X}^{(2)} \in \mathbf{R}^{N \times C}$, C 为样本类别个数。将聚合特征和邻接矩阵送入图神经网络, 根据已知样本标签, 计算交叉熵损失, 表达式为

$$\text{Loss}(\mathbf{y}, \hat{\mathbf{y}}) = - \sum_{m=1}^M y_m \log \hat{y}_m, \quad (11)$$

式中: y_m 代表样本的真实标签, 采用独热码形式表示; \hat{y}_m 代表样本的预测标签; M 代表已知真实标签的样本个数。当图卷积网络的损失不再下降时, 参数训练完成, 得到最终的输出 $\mathbf{X}^{(2)}$, 对最终的输出进行 Softmax

运算, 得到样本的预测标签, 表达式为

$$P(\hat{y}_i | \mathbf{x}_i) = \frac{\exp(\mathbf{x}_{ic})}{\sum_{j=1}^C \exp(\mathbf{x}_{ij})}, \quad c = 1, 2, \dots, C. \quad (12)$$

综上所述, 所提模型的算法流程如图 5 所示。

Input: hyperspectral image
Output: predicted labels for unlabeled samples

Convert 3D matrix data ($W \times H \times \text{Bands}$) to 2D matrix data ($N \times \text{Bands}$, $N = H \times W$);
For $i = 1: \text{Bands}$
 Normalize spectral features for each channel;
End
Construct the spatial neighborhood matrix S ;
For $i = 1: m+1$
 Use Equ. (3) to update S ;
 Use Equ. (4) to aggregate features;
End
Obtain aggregation features X_{AF} and construct adjacency matrix A using X_{AF} ;
According to Equ. (9), a two-layer graph convolution network Equ. (10) is established;
For $i = 1: \text{epochs}$
 Calculate the cross-entropy loss and train the parameters ($\mathbf{W}^{(0)}$, $\mathbf{W}^{(1)}$) according to Equ. (11);
End
When the loss of the graph convolutional network no longer decreases, the training is completed, and the final output $\mathbf{X}^{(2)}$ is obtained according to Equ. (10);
Calculate the predicted labels of unlabeled samples according to Equ. (12)

图 5 S²AF-GCN 算法流程

Fig. 5 Algorithm flow of S²AF-GCN

3 实验结果及分析

为测试所提模型性能, 在三个常用高光谱数据集 Indian Pines、Pavia University、Kennedy Space Center 上进行对比实验, 使用每类精度、总体精度(OA)、平均精度(AA)和 Kappa 系数作为评价指标, 并对不同比例训练样本以及模型参数(聚合次数和 K 近邻数)的选择进行实验和详细分析。

3.1 数据集与实验设置

1) Indian Pines 数据集

Indian Pines(IP)数据集由机载可见光/红外成像光谱仪(AVIRIS)传感器获取于美国印第安纳州西北部。图像大小为 145×145 , 图像包含 220 个光谱波段, 波长范围为 $400 \sim 2500$ nm, 删除覆盖吸水区域的条带后通道数量减少到 200 个。该数据集土地覆盖类型包括 16 类, 表 1 列出了该数据集 16 个类别及训练集、测试集划分情况。

2) Pavia University 数据集

Pavia University(PU)数据集由反射式光学系统成像光谱仪(ROSIS)传感器获取。图像大小为 $610 \times$

表 1 Indian Pines 数据集中土地覆盖类别及数据集划分

Table 1 Land cover category and dataset division on Indian Pines dataset

Class No.	Class name	Number of samples		
		Train	Test	Total
1	Corn Notill	14	1420	1434
2	Corn Mintill	8	826	834
3	Corn	3	231	234
4	Grass Pasture	5	492	497
5	Grass Trees	7	740	747
6	Hay Windrowed	5	484	489
7	Soybean Notill	9	959	968
8	Soybean Mintill	24	2444	2468
9	Soybean Clean	6	608	614
10	Wheat	2	210	212
11	Woods	12	1282	1294
12	Buildings Grass Trees Drives	4	376	380
13	Stone Steel Towers	2	93	95
14	Alfalfa	2	52	54
15	Grass Pasture Mowed	1	25	26
16	Oats	1	19	20
		105(1%)	10261	10366

340, 图像包含 103 个光谱波段, 波长范围为 430~860 nm, 地面采样距离为 1.3 m。该数据集土地覆盖类型包括 9 类, 表 2 列出了该数据集 9 个类别及训练集、测试集划分情况。

表 2 Pavia University 数据集中土地覆盖类别及数据集划分

Table 2 Land cover category and dataset division on Pavia University dataset

Class No.	Class name	Number of samples		
		Train	Test	Total
1	Asphalt	66	6565	6631
2	Meadows	186	18463	18649
3	Gravel	21	2078	2099
4	Trees	31	3033	3064
5	Metal Sheets	13	1332	1345
6	Bare Soil	50	4979	5029
7	Bitumen	13	1317	1330
8	Bricks	37	3645	3682
9	Shadows	10	937	947
		427(1%)	42349	42776

3) Kennedy Space Center 数据集

Kennedy Space Center (KSC) 数据集由 AVIRIS 传感器获得。图像大小为 512×614, 图像包含 224 个光谱波段, 波长范围为 400~2500 nm, 去除吸水区域和低信噪比波段后, 保留 176 个波段。该数据集土地覆盖类型包括 13 类, 表 3 列出了该数据集 13 个类别及训练集、测试集划分情况。

4) 实验设置

本文实验在 Ubuntu 工作站上完成, 工作站处理器型号为 Intel(R) Xeon(R) E5-2690, 内存大小为 128G, 硬盘大小为 4 TB。实验代码使用 Python3.6 和

表 3 Kennedy Space Center 数据集中土地覆盖类别及数据集划分

Table 3 Land cover category and dataset division on Kennedy Space Center dataset

Class No.	Class name	Number of samples		
		Train	Test	Total
1	Scrub	8	753	761
2	Willow swamp	2	241	243
3	CP hammock	3	253	256
4	Slash pine	3	249	252
5	Oak/Broadleaf	2	159	161
6	Hardwood	2	227	229
7	Swap	1	104	105
8	Graminoid marsh	4	427	431
9	Spartina marsh	5	515	520
10	Cattail marsh	4	400	404
11	Salt marsh	4	415	419
12	Mud flats	5	498	503
13	Water	9	918	927
		52(1%)	5159	5211

TensorFlow1.52 完成, 使用 1 块 NVIDIA Tesla K40c 12 GB GPU 加速。在 Indian Pines、Pavia University、Kennedy Space Center 三个数据集上分别随机选择每类样本中 1% 的样本点作为有标记样本, 其余样本视为无标记样本用作测试集。Indian Pines 数据集中, 从第 13、14、15、16 类取 1% 的样本时不足一个样本点, 为避免对整体分类精度造成影响, 对 13~16 类分别取 1 个或 2 个样本点。训练模型时, 径向基函数中的 σ 参数设置为 1, 学习率设置为 0.001, 最大迭代次数设置为 4000, 使用 Adam 优化器对网络进行优化。

3.2 模型对比

为验证所提模型的性能, 将 $S^2AF-GCN$ 模型与 FuNet-C 模型、 S^2GCN 模型作对比。FuNet-C 模型^[12]利用 CNN 提取像素特征, 利用原始光谱特征计算节点相似度构造邻接矩阵, 利用 GCN 模型更新节点特征, 将两个网络所得特征级联再加全连接层获得分类结果。 S^2GCN 模型^[14]同样利用了像素空间信息和光谱信息, 该模型先利用原始光谱特征计算节点相似度, 再通过 KNN 算法选择 10 个近邻, 然后计算中心节点在空间 5×5 的范围内与其他节点的相似度, 若通过 KNN 算法选择的 10 个近邻处于 5×5 的空间范围内, 则两个权重值相乘, 否则邻接矩阵对应位置的元素乘以一个特别小的值或者乘以 0。三个模型均利用了像素空间信息和光谱信息, 均以 GCN 模型为基础进行分类, 三个模型的异同点如表 4 所示。FuNet-C 模型与 S^2GCN 模型均利用原模型在 1% 的训练样本下得到实验结果。

为验证原始光谱特征、聚合特征和邻接矩阵对 $S^2AF-GCN$ 模型的影响, 进行消融实验: GCN(OFF) 模型利用原始光谱特征进行构图, 并利用原始光谱特征进行网络训练及节点分类; GCN(AF) 模型使用原始

表 4 各方法对比
Table 4 Comparison of each method

Model	CNN feature extraction	Information used	Features used in constructing graph	Adjacency matrix
FuNet-C	2DCNN	Spatial and spectral information	Original spectral features	Inaccurate
S ² GCN	No	Spatial and spectral information	Original spectral features	Inaccurate
S ² AF-GCN	No	Spatial and spectral information	Aggregation features	Accurate

光谱特征进行构图,但使用聚合特征训练网络并分类; S²AF-GCN(OA)模型使用聚合特征计算相似度构造邻接矩阵,使用原始光谱特征进行分类; S²AF-GCN

(AF)模型使用聚合特征计算相似度构造邻接矩阵,并使用聚合特征进行分类。消融实验中各方法的异同点对比如表 5 所示。

表 5 消融实验中各方法异同点对比
Table 5 Comparison of similarities and differences of various methods in ablation experiment

Model	Classify using original features	Classify using aggregation features	Construct adjacency matrix using original features	Construct adjacency matrix using aggregation features	Accurate adjacency matrix
GCN(OA)	✓		✓		✗
GCN(AF)		✓	✓		✗
S ² AF-GCN(OA)	✓			✓	✓
S ² AF-GCN(AF)		✓		✓	✓

3.3 实验结果

为了验证 S²AF-GCN 模型的有效性,分别在数据集 Indian Pines、Pavia University、Kennedy Space Center 上对该模型进行了定量和定性的评价,同时与 FuNet-C、S²GCN 两个模型进行了性能比较。GCN(OA)、GCN(AF)、S²AF-GCN(OA)、S²AF-GCN(AF) 四个模型为消融实验中涉及的模型,充分验证了空间-光谱聚合特征模块的有效性以及利用聚合特征构图的有效性。

1) Indian Pines 数据集

表 6 展示了不同模型在 Indian Pines 数据集上的分类结果,其中黑色加粗数据为每一类的最好分类结果。

从表 6 可以看出:GCN(OA)分类效果最差,它没有利用空间信息,只是利用原始光谱特征训练网络并分类;与之相比,GCN(AF)利用聚合特征训练网络并分类,OA 提升了 12 个百分点以上,充分证明了空间-光谱聚合特征模块利用空间信息对区域内特征进行平滑的有效性;将 GCN(OA)与 S²AF-GCN(OA)相比,虽然二者都使用原始光谱特征训练网络并分类,但是送入 S²AF-GCN(OA)模型的邻接矩阵是基于聚合特征构造的,节点间的相似性表达得更加准确,它的 OA 比 GCN(OA)提升了 13 个百分点以上。可见,进行特征聚合,利用聚合特征构图、训练网络并分类的 S²AF-GCN(AF)模型从整体上取得了最优的分类结果,表明了所提贡献点的有效性。

FuNet-C 模型虽然通过二维卷积网络提取像素节点 7×7 范围内的特征,同时考虑了空间邻域信息和光谱信息,并利用 GCN 更新节点特征,但是它的分类效果并不理想。主要原因有两方面:一,利用原始光谱特

表 6 Indian Pines 数据集上的分类结果

Table 6 Classification results on Indian Pines dataset

Class No.	FuNet-C	S ² GCN	GCN (OA)	GCN (AF)	S ² AF-GCN (OA)	S ² AF-GCN (AF)
1	81.20	83.10	61.27	67.11	81.83	82.18
2	76.15	81.48	24.46	57.51	55.57	85.84
3	89.61	98.27	39.83	47.62	51.52	60.17
4	78.66	78.05	73.37	74.19	82.11	78.46
5	71.76	92.43	85.54	87.43	89.05	99.05
6	99.38	100.00	94.42	97.11	99.79	100.00
7	73.30	82.59	61.94	87.17	78.83	88.22
8	61.46	75.16	57.90	74.02	64.57	81.18
9	46.88	78.13	31.41	39.80	59.05	70.07
10	99.52	100.00	91.90	99.05	100.00	100.00
11	96.80	99.22	95.16	94.38	97.58	98.75
12	57.18	66.76	38.83	71.81	66.22	67.82
13	83.87	86.02	80.65	80.65	77.42	88.17
14	92.31	84.62	32.69	82.69	76.92	94.23
15	72.00	92.00	36.00	92.00	80.00	100.00
16	42.11	57.89	47.37	73.68	63.16	68.42
OA / %	74.99	84.08	63.19	75.53	76.48	85.51
AA / %	76.39	84.73	59.55	76.64	76.34	85.16
Kappa	0.7181	0.8196	0.5823	0.7226	0.7317	0.8353

征构图,构造的邻接矩阵不准确,图卷积特征更新无法修正不准确甚至不正确的节点相似性关系;二,利用 1% 的少量标记样本训练二维卷积网络难以很好地提取像素的空间光谱特征。因此,尽管 FuNet-C 也利用了空间光谱特征和邻接矩阵提供的信息,但是并没有得到理想的结果。和 S²AF-GCN(AF)模型相比, S²GCN 的节点特征虽然也同时考虑了光谱信息和空间信息,但它仅利用光谱信息构图,判断近邻是否是 5×5 空间范围内的像素节点来对邻接矩阵进行修正,故 S²GCN 模型的邻接矩阵中的近邻局限于空间局部

范围内。而 $S^2AF-GCN(AF)$ 模型利用聚合特征构图, 构图比较准确, 且近邻的选择并不局限在空间局部范围内, 因此对于图像中不管近还是远距离像素之间的关系, 它都能通过邻接矩阵有效表达, 分类效果比 S^2GCN 模型更好, 也表明了所提方法特征提取和建模表达的有效性。

图 6 展示了不同模型在 Indian Pines 数据集上的分类结果, 其中图 6(a) 为 Indian Pines 数据集的假彩色图像, 图 6(b) 为 Indian Pines 数据集的真实标签图。从分类结果可以直观地看出: FuNet-C 模型因采用 CNN 提取特征, 并利用原始光谱特征构图, 在 1% 的训练样本下未能很好地提取特征, 且构造的邻接矩阵不准确, 分类效果不理想, 图 6(c) 展示结果中存在大面积的错分区域; S^2GCN 模型充分考虑了空间信息和光谱信息, 但其

邻接矩阵仍使用原始光谱特征计算所得的相似度作为权重, 邻接矩阵不准确, 且利用原始光谱特征训练网络, 分类结果仍有待提升, 分类结果如图 6(d) 所示; 未考虑空间信息和利用原始光谱特征构图、训练网络的 GCN (OF) 模型分类结果最差, 从图 6(e) 可以看出, 各个不同类别的区域均有分类错误的样本; 图 6(f) 的 GCN (AF) 模型使用聚合特征训练网络, 图 6(g) 的 $S^2AF-GCN$ (OF) 模型使用聚合特征构图, 获得了准确的邻接矩阵, 实验结果充分证明, 空间-光谱特征聚合操作可对区域特征进行平滑, 得到像素的有效特征表示, 无论使用聚合特征直接训练网络或利用聚合特征构图获得准确的邻接矩阵, 都可以大幅度提升分类结果; 既使用聚合特征构图, 又使用聚合特征训练网络的 $S^2AF-GCN(AF)$ 模型获得了最优的分类结果, 如图 6(h) 所示。

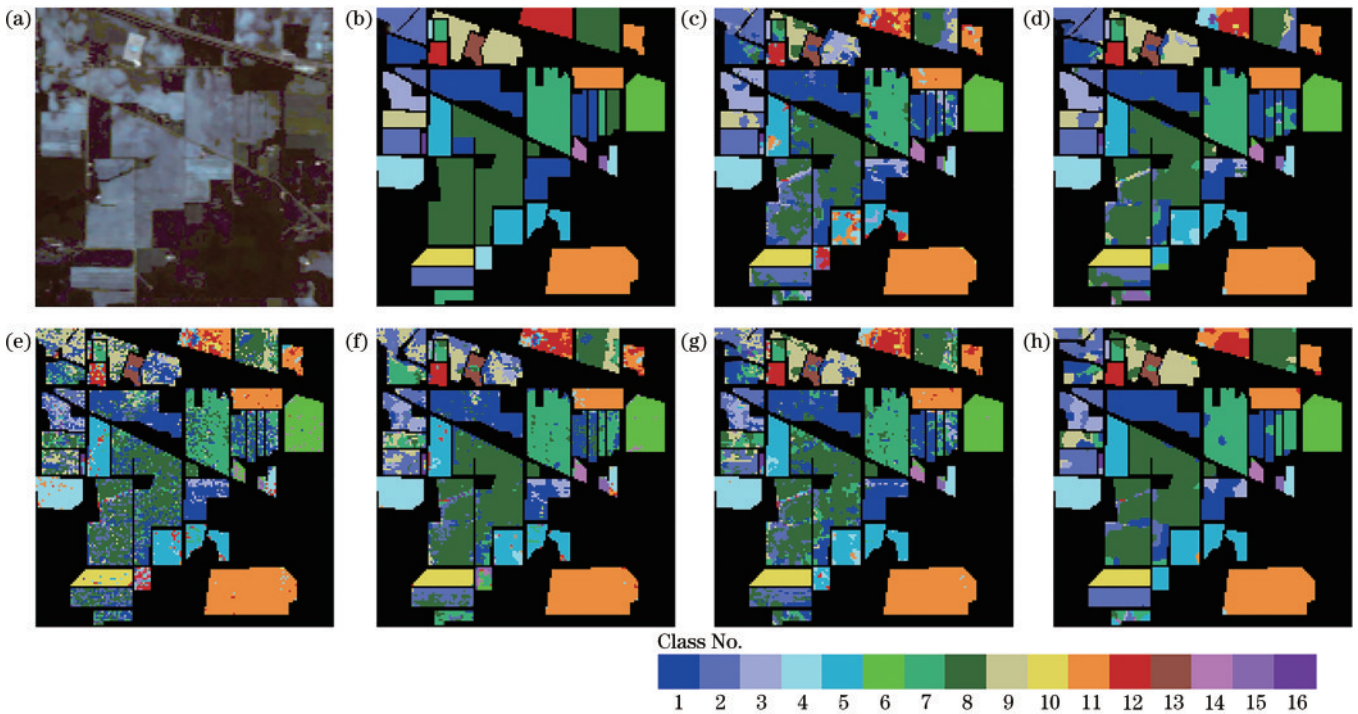


图 6 Indian Pines 数据集上的分类结果。(a)假彩色图;(b)标签图;(c)FuNet-C;(d) S^2GCN ;(e)GCN(OF);(f)GCN(AF);(g) $S^2AF-GCN(OF)$;(h) $S^2AF-GCN(AF)$

Fig. 6 Classification results on Indian Pines dataset. (a) False color; (b) ground truth; (c) FuNet-C; (d) S^2GCN ; (e) GCN(OF); (f) GCN (AF); (g) $S^2AF-GCN(OF)$; (h) $S^2AF-GCN(AF)$

2) Pavia University 数据集

表 7 展示了不同模型在 Pavia University 数据集上的分类结果, 每一类中的最好分类结果同样加黑标记。从表 7 可以看出: GCN(OF) 和 FuNet-C 仍是分类效果比较差的两个模型; 将 GCN(OF)、GCN(AF)、 $S^2AF-GCN(OF)$ 、 $S^2AF-GCN(AF)$ 四个模型的结果作对比, 同样可以证明空间-光谱聚合特征的有效性以及利用聚合特征构图的有效性。与 Indian Pines 数据集相比, 不同模型在 Pavia University 数据集上的分类结果普遍要好, 这是因为 Pavia University 数据集类别数较少, 而且每一类的标记样本数比较均衡。

图 7 展示了不同模型在 Pavia University 数据集上的分类结果, 其中图 7(a) 为假彩色图像, 图 7(b) 为真实标签图。从图 7 可以看出: 图 7(c) 和图 7(e) 所示的 FuNet-C 模型和 GCN(OF) 模型分类效果较差, 原因同样是少样本条件下 CNN 提取特征不准确和使用原始光谱特征构图所得邻接矩阵不准确。需要重点关注的是, 与 S^2GCN 相比, $S^2AF-GCN(AF)$ 使用空间-光谱聚合特征操作对原始特征进行平滑, 使用聚合特征构造的邻接矩阵更加准确, 而且 $S^2AF-GCN(AF)$ 使用了聚合特征训练网络并分类, 与 Indian Pines 数据集相比, 在样本点更多的情况下, $S^2AF-GCN(AF)$ 的优势




图 7 Pavia University 数据集上的分类结果。(a)假彩色图;(b)标签图;(c) FuNet-C;(d) S²GCN;(e) GCN(OF);(f) GCN(AF);(g) S²AF-GCN(OF);(h) S²AF-GCN(AF)

Fig. 7 Classification results on Pavia University dataset. (a) False color; (b) ground truth; (c) FuNet-C; (d) S²GCN; (e) GCN(OF); (f) GCN(AF); (g) S²AF-GCN(OF); (h) S²AF-GCN(AF)

表 7 Pavia University 数据集上的分类结果

Table 7 Classification results on Pavia University dataset

Class No.	FuNet-C	S ² GCN	GCN (OF)	GCN (AF)	S ² AF-GCN(OF)	S ² AF-GCN(AF)
1	85.73	95.55	88.35	91.32	91.93	94.58
2	99.20	98.26	95.79	95.72	98.60	99.13
3	77.53	79.40	68.62	62.03	77.53	82.24
4	57.73	86.55	90.74	92.35	89.85	89.99
5	99.47	100.00	95.35	99.40	99.55	100.00
6	75.34	89.54	74.11	89.27	90.72	98.77
7	96.13	56.42	61.73	88.84	92.10	99.92
8	85.27	91.85	82.36	97.31	95.58	98.86
9	99.89	100.00	99.15	100.00	100.00	100.00
OA / %	89.00	93.29	88.24	92.52	94.58	96.95
AA / %	86.25	88.62	84.02	90.69	92.87	95.43
Kappa	0.8511	0.9103	0.8429	0.9009	0.9278	0.9561

更加明显,这一优势也可以从图 7(d)和图 7(h)的对比中直观感受到。

3) Kennedy Space Center 数据集

表 8 展示了不同模型在 Kennedy Space Center 数据集上的分类结果。由于训练样本比较少, FuNet-C 和 S²GCN 在不同类别上的分类精度差异较大, 如在第 2 类、第 11 类、第 13 类, FuNet-C 和 S²GCN 的分类结果可以达 100%, 但是在第 4 类、第 6 类、第 7 类上精度很低。 S²AF-GCN(AF) 模型在各个类别上都取得了较高的分类精度, 结果比较均衡, 这是因为空间-光谱聚合特征模块对区域内的特征进行了平滑, 同类节点之间的特征更加相似, 使得在训练样本数少且不同类别训练样本数差异较大的情况下可以获得较为稳定的分类效果, 这一点在三个数据集上都得到了很好的体现。

图 8 展示了不同模型在 Kennedy Space Center 数据集上的分类结果图, 其中图 8(a) 为假彩色图像, 图 8(b) 为真实标签图。从图 8 可以看出, Kennedy Space Center 数据集图像比较大, 背景占据了绝大部分。结合表 8 中的分类数据, 从图 8(c) 和图 8(d) 可以




图 8 Kennedy Space Center 数据集上的分类结果。(a)假彩色图;(b)标签图;(c) FuNet-C;(d) S²GCN;(e) GCN(OF);(f) GCN(AF);(g) S²AF-GCN(OF);(h) S²AF-GCN(AF)

Fig. 8 Classification results on Kennedy Space Center dataset. (a) False color; (b) ground truth; (c) FuNet-C; (d) S²GCN; (e) GCN(OF); (f) GCN(AF); (g) S²AF-GCN(OF); (h) S²AF-GCN(AF)

表 8 Kennedy Space Center 数据集上的分类结果

Table 8 Classification results on Kennedy Space Center dataset

Class No.	FuNet-C	S ² GCN	GCN (OF)	GCN (AF)	S ² AF-GCN (OF)	S ² AF-GCN (AF)
1	98.41	100.00	92.96	96.95	95.22	98.94
2	100.00	100.00	87.97	94.19	98.76	98.34
3	45.06	100.00	82.21	90.91	70.36	100.00
4	6.83	59.84	17.27	58.63	64.26	72.69
5	90.57	100.00	61.01	62.26	92.45	97.48
6	22.47	62.56	50.66	59.03	64.32	92.95
7	40.38	69.23	37.50	46.15	40.38	76.92
8	83.84	100.00	88.52	91.57	94.38	100.00
9	83.69	83.69	84.85	83.11	89.90	83.69
10	96.50	94.00	71.00	93.75	80.25	94.00
11	100.00	100.00	80.24	87.47	87.23	97.11
12	96.50	96.39	94.58	95.78	95.38	96.39
13	100.00	100.00	99.78	99.46	100.00	100.00
OA / %	84.09	93.35	82.05	88.41	88.58	94.92
AA / %	74.16	89.67	72.97	81.48	82.53	92.96
Kappa	0.8228	0.9259	0.7999	0.8707	0.8727	0.9435

看出,第4类、第6类、第7类分类效果不好, FuNet-C模型和 S²GCN模型在不同类别样本上的分类精度差异大,主要是使用原始光谱特征训练网络引起的。高光谱图像光谱波段多,利用原始光谱特征训练网络使得分类结果极易受像素特征的影响。S²AF-GCN模型使用空间-光谱聚合特征模块对原始光谱特征进行了平滑,同类节点之间的特征差异更小,尽量避免了“同谱异物、同物异谱”现象,不仅提升了分类精度,而且减小了对各个类别的分类精度差异。

4) 运行时间

表 9 显示了 FuNet-C、S²GCN、S²AF-GCN 模型分别在 Indian Pines、Pavia University、Kennedy Space Center 数据集上的运行时间(训练与测试同步进行,运行时间包括训练时间和测试时间)。不同模型在不同的数据集上运行时,当运行多个 epoch 而模型的损失不再下降时,程序停止运行,将此时的运行时间作为模型的运行时间。将程序运行 5 次,求平均运行时间,结果如表 9 所示。从表 9 可以看出:Pavia University 数据

表 9 FuNet-C、S²GCN、S²AF-GCN 模型在三个数据集上的运行时间

Table 9 Running time of FuNet-C, S²GCN, S²AF-GCN models on three datasets unit: s

Dataset	FuNet-C	S ² GCN	S ² AF-GCN
Indian Pines	420	117	182
Pavia University	963	133	240
Kennedy Space Center	280	40	56

集样本数最多,三个模型在该数据集上的运行时间均为最长,Indian Pines 数据集次之,Kennedy Space Center 数据集上的运行时间最短。在三个数据集上,FuNet-C 模型用时最长,因为该模型需要同时训练 GCN 和 CNN,需要训练的参数比较多;S²AF-GCN 多了空间-光谱聚合特征模块,故运行时间比 S²GCN 要长,但从分类结果和分类效果上来看,S²AF-GCN 增加的运行时间是值得的。

3.4 模型参数及训练样本数的影响分析

S²AF-GCN 模型中的空间-光谱聚合特征模块为 GCN 提供了初始的节点特征,也决定了初始构图的准确度,越准确,越有利于后续的 GCN 特征提取和分类。

表 10 不同聚合次数下,S²AF-GCN 对不同数据集的分类结果

Table 10 Classification results of S²AF-GCN on different datasets under different aggregation times

$m+1$	Indian Pines			Pavia University			Kennedy Space Center		
	OA / %	AA / %	Kappa	OA / %	AA / %	Kappa	OA / %	AA / %	Kappa
2	77.52	80.36	0.7451	93.98	92.34	0.9200	90.83	85.29	0.8978
4	81.56	82.24	0.7912	95.89	94.57	0.9455	92.61	87.54	0.9177
6	84.81	84.01	0.8276	96.42	95.52	0.9526	93.47	89.09	0.9272
8	85.51	85.16	0.8353	96.65	95.43	0.9561	94.92	92.96	0.9435
10	85.05	85.19	0.8304	96.69	95.94	0.9595	92.44	87.65	0.9157
12	83.74	85.14	0.8156	95.96	93.41	0.9462	93.14	89.12	0.9236

2) K 近邻数

图 9 展示了近邻数 K 对三个数据集总体精度 (OA) 的影响。从图 9 可以看出,当 $K=5$ 时,总体精度

该模块通过控制特征聚合次数 m ,对局部区域内的特征进行平滑,如果聚合次数过大,容易导致过平滑,不利于像素分类。GCN 利用聚合特征构图时,使用 KNN 算法选择 K 个近邻构造邻接矩阵, K 值代表了邻接矩阵中每个节点的邻居个数,当 K 值过大时,选择的邻居节点与该节点可能并非同一类,将此邻接矩阵送入图神经网络反而会降低分类结果。此外,3.3 节中的实验结果均为 1% 训练样本下所得结果,为充分评估模型性能,对不同比例训练样本下的分类结果进行了实验和分析。

1) 聚合次数

表 10 展示了不同聚合次数下,S²AF-GCN 对 Indian Pines、Pavia University、Kennedy Space Center 三个数据集分类的结果。在聚合次数为 8 时,S²AF-GCN 对 Indian Pines 数据集的分类结果达到最优;在聚合次数为 10 时,S²AF-GCN 对 Pavia University 数据集的分类结果达到最优;在聚合次数为 8 时,S²AF-GCN 对 Kennedy Space Center 数据集的分类结果达到最优。当聚合次数较少时,像素的空间信息没能完全被利用,但当聚合次数超过最优聚合次数时,过平滑现象产生,OA、AA、Kappa 三个评价指标都会下降。

最优,当 K 增大时,总体精度出现小范围波动,但整体上呈现下滑趋势。近邻数 K 代表了邻接矩阵中节点的邻居个数,所提模型利用聚合特征构图,意在构建




图 9 近邻数 K 对不同数据集总体精度的影响。(a) Indian Pines; (b) Pavia University; (c) Kennedy Space Center

Fig. 9 Influence of nearest neighbor number K on the overall accuracy on different datasets. (a) Indian Pines; (b) Pavia University; (c) Kennedy Space Center

更为准确的邻接矩阵,即减少不同类节点之间的连接。当 K 逐渐增大时,邻接矩阵中每个节点包含的邻居个数增多,但这些邻居节点可能与该节点并非同一类,将此邻接矩阵送入图神经网络会影响分类结果。当 $K=5$ 时,节点包含的邻居节点个数虽然少,但这些邻居节点是根据相似度由大到小选择出来的,与该节点为同一类的可能性更大,所以分类结果最好。图 9 的实验结果也证明了准确的邻接矩阵对于分类结果的重要性。

3) 不同比例的训练样本

图 10 展示了 FuNet-C、 S^2 GCN、 S^2 AF-GCN 三个模型在三个数据集上分别选择 0.5% (每一类按比例选择样本,若某类样本数量不足一个,该类取一个,其他类样

本数量减少,样本总数为原始样本数的 0.5%)、1%、2%、3%、5%、7%、10% 的训练样本得到的总体精度。从整体来看,随着训练样本比例的增加,三个模型在三个数据集上的分类精度均呈上升趋势,这与常识是一致的。 S^2 AF-GCN 模型在各个训练样本比例下均优于 FuNet-C 模型和 S^2 GCN 模型,在少样本的条件下, S^2 AF-GCN 模型的优势更加明显,可见 S^2 AF-GCN 模型因为进行了特征聚合,平滑了同类节点之间的特征,减小了特征间的差异,即使在少样本的情况下也能获得较优的分类效果,如在 Pavia University 数据集上,利用 0.5% 的训练样本可得 96.09% 的总体精度。这表明了所提空间-光谱聚合特征模块的有效性以及利用聚合特征构图、训练网络的有效性。




图 10 不同模型在不同比例训练样本下的总体精度。(a) Indian Pines; (b) Pavia University; (c) Kennedy Space Center

Fig. 10 OA of different models under different proportions of training samples. (a) Indian Pines; (b) Pavia University; (c) Kennedy Space Center

4 结 论

基于空间-光谱聚合特征的图卷积网络模型充分利用了高光谱图像中像素的空间信息和光谱信息,提取了像素的空间-光谱聚合特征,利用聚合特征构图,获得了更为准确的邻接矩阵,最后将聚合特征与邻接矩阵送入图卷积网络获得分类结果。在三个常用高光谱图像数据集上的实验结果表明:空间-光谱聚合特征操作在充分利用像素空谱信息的同时,可以提取区域内像素的有效特征表示。三个数据集上的消融实验证明:与利用原始光谱特征构造邻接矩阵相比,利用聚合特征构造出的邻接矩阵更加准确,准确的邻接矩阵可以大幅度地提高分类结果。与其他方法相比,所提方法简单高效且分类效果好,但需要在聚合特征过程中控制聚合次数,聚合次数少则不能很好地做到区域特征平滑,聚合次数过多则可能会导致一些边界节点难以区分。后续将对如何更好地聚合特征进行进一步研究。

参 考 文 献

[1] Matsuki T, Yokoya N, Iwasaki A. Hyperspectral tree species classification of Japanese complex mixed forest with the aid of lidar data[J]. IEEE Journal of Selected

Topics in Applied Earth Observations and Remote Sensing, 2015, 8(5): 2177-2187.

- [2] 刘玉珍, 朱珍珍, 马飞. 基于特征融合方法的高光谱图像分类综述[J]. 激光与光电子学进展, 2021, 58(4): 0400004. Liu Y Z, Zhu Z Z, Ma F. Review of hyperspectral image classification based on feature fusion method[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0400004.
- [3] Zhang M M, Li W, Du Q. Diverse region-based CNN for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2018, 27(6): 2623-2634.
- [4] 张祥东, 王腾军, 朱劭俊, 等. 基于扩张卷积注意力神经网络的高光谱图像分类[J]. 光学学报, 2021, 41(3): 0310001. Zhang X D, Wang T J, Zhu S J, et al. Hyperspectral image classification based on dilated convolutional attention neural network[J]. Acta Optica Sinica, 2021, 41(3): 0310001.
- [5] Guo Y H, Yin X J, Zhao X C, et al. Hyperspectral image classification with SVM and guided filter[J]. EURASIP Journal on Wireless Communications and Networking, 2019, 2019: 56.
- [6] 冯凡, 王双亭, 张津, 等. 基于多特征融合和混合卷积神经网络的高光谱图像分类[J]. 激光与光电子学进展, 2021, 58(8): 0810010. Feng F, Wang S T, Zhang J, et al. Hyperspectral

- images classification based on multi-feature fusion and hybrid convolutional neural networks[J]. *Laser & Optoelectronics Progress*, 2021, 58(8): 0810010.
- [7] 刘金香, 班伟, 陈宇, 等. 融合多维度 CNN 的高光谱遥感图像分类算法[J]. *中国激光*, 2021, 48(16): 1610003.
Liu J X, Ban W, Chen Y, et al. Multi-dimensional CNN fused algorithm for hyperspectral remote sensing image classification[J]. *Chinese Journal of Lasers*, 2021, 48(16): 1610003.
- [8] Chen Y S, Jiang H L, Li C Y, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 6232-6251.
- [9] Zhao C H, Zhu W X, Feng S. Hyperspectral image classification based on kernel-guided deformable convolution and double-window joint bilateral filter[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 5506505.
- [10] Kipf T N, Wainwright M W. Semi-supervised classification with graph convolutional networks[C]//*Proceedings of 2017 the International Conference on Learning Representations (ICLR)*, April 24-26, 2017, Toulon, France. [S.l.: s.n.], 2017.
- [11] 国强, 彭龙. 基于三维卷积神经网络与超像素分割的高光谱分类[J]. *光学学报*, 2021, 41(22): 2210001.
Guo Q, Peng L. Hyperspectral classification based on 3D convolutional neural network and super pixel segmentation [J]. *Acta Optica Sinica*, 2021, 41(22): 2210001.
- [12] Shahraki F F, Prasad S. Graph convolutional neural networks for hyperspectral data classification[C]//*2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, November 26-29, 2018, Anaheim, CA, USA. New York: IEEE Press, 2018: 968-972.
- [13] Zhang M H, Luo H L, Song W, et al. Spectral-spatial offset graph convolutional networks for hyperspectral image classification[J]. *Remote Sensing*, 2021, 13(21): 4342.
- [14] Hong D F, Gao L R, Yao J, et al. Graph convolutional networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(7): 5966-5978.
- [15] Danel T, Spurek P, Tabor J, et al. Spatial graph convolutional networks[M]//Yang H Q, Pasupa K, Leung A C S, et al. *Neural information processing. Communications in computer and information science*. Cham: Springer, 2020, 1333: 668-675.
- [16] Qin A Y, Shang Z W, Tian J Y, et al. Spectral-spatial graph convolutional networks for semisupervised hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 241-245.
- [17] Wan S, Gong C, Zhong P, et al. Hyperspectral image classification with context-aware dynamic graph convolutional network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(1): 597-612.
- [18] Bai J, Ding B X, Xiao Z, et al. Hyperspectral image classification based on deep attention graph convolutional network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5504316.
- [19] Mu C H, Liu Y J, Liu Y. Hyperspectral image spectral-spatial classification method based on deep adaptive feature fusion[J]. *Remote Sensing*, 2021, 13(4): 746.
- [20] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//*Advances in Neural Information Processing Systems 29*, December 5-10, 2016, Barcelona, Spain. New York: Curran Associates, 2016: 3837-3845.
- [21] Hammond D K, Vandergheynst P, Gribonval R. Wavelets on graphs via spectral graph theory[J]. *Applied and Computational Harmonic Analysis*, 2011, 30(2): 129-150.