

文章编号 1004-924X(2025)23-3737-17

对比学习结合 DenseNet 的高光谱图像开放集分类

刘城洋¹, 赵琳¹, 于亮², 吴海滨¹, 王爱丽^{1*}

(1. 哈尔滨理工大学 黑龙江省激光光谱技术及应用重点实验室, 黑龙江 哈尔滨 150080;

2. 哈尔滨工业大学 仪器科学与工程学院 超精密光电仪器工程研究所,
黑龙江 哈尔滨 150080)

摘要: 高光谱图像分类通常假设训练与测试数据共享相同类别, 且测试集中不存在未知类, 但这一前提在实际环境中过于理想。针对高光谱数据类别间差异较小, 特征分布容易出现重叠, 从而导致边界混淆问题, 提出了对比学习结合 DenseNet 的高光谱图像开放集分类方法。利用光谱特征提取模块获取原始光谱维度特征, 并通过 DenseNet 实现多层次特征信息交互, 同时利用过渡模块压缩光谱通道, 以形成更清晰的类边界分布。将输出特征映射至空间特征提取模块获取空间维度特征, 并借助 ResNet 捕获局部空间结构特征, 从而增强对空间结构信息的感知。引入对比学习以提升类内聚合性和类间可分性, 并结合困难样本挖掘机制对易混淆的边界特征进行优化, 提升模型对边界区域样本的判别能力。最后, 在 Houston2013, Pavia University, WHU-Hi-LongKou 数据集上的实验表明, 本文方法在未知类别上获得了更高的地物分类精度, 分别为 68.81%, 69.24%, 59.26%, 整体的分类精度分别为 89.49%, 95.06%, 95.03%, 实现了在保持已知类别高精度的同时, 有效提升未知类别的识别能力。

关键词: 高光谱图像; 开放集; DenseNet; 对比学习; 困难样本挖掘

中图分类号: TP751; TP181 **文献标识码:** A

doi: 10.37188/OPE.20253323.3737

CSTR: 32169.14.OPE.20253323.3737

Contrastive learning combined with DenseNet for open-set classification of hyperspectral images

LIU Chengyang¹, ZHAO Lin¹, YU Liang², WU Haibin¹, WANG Aili^{1*}

(1. Heilongjiang Province Key Laboratory of Laser Spectroscopy Technology and Application,
Harbin University of Science and Technology, Harbin 150080, China;

2. Institute Ultra-Precision Optoelectronic Instrument Engineering, School of Instrument Science and
Engineering, Harbin Institute of Technology, Harbin 150080, China)

* Corresponding author, E-mail: aili925@hrbust.edu.cn

Abstract: Hyperspectral image classification typically assumes that the training and test data share identical categories and that no unknown classes appear in the test set. However, this assumption is rarely satisfied in practical applications. In addition, the subtle inter-class differences inherent in hyperspectral data often lead to overlapping feature distributions and consequent decision boundary ambiguity. To address these issues, an open-set classification method for hyperspectral images is proposed that integrates contrastive learning with DenseNet. The spectral feature extraction module obtains original spectral dimension features, and DenseNet realizes multi-level feature information interaction. Meanwhile, the transition module compresses the spectral channels to form clearer class boundary distributions. The output features are mapped to the spatial feature extraction module to obtain spatial dimension features, and ResNet is used to capture local spatial structure features, thereby enhancing the perception of spatial structure information. Contrastive learning is introduced to improve intra-class aggregation and inter-class separability, and a hard sample mining mechanism is used to optimize boundary features that are easy to confuse. Finally, experiments on the Houston2013, Pavia University, and WHU-Hi-LongKou datasets show that the proposed method achieves higher land use classification accuracy on unknown classes, with accuracies of 68.81%, 69.24%, and 59.26% respectively. The overall classification accuracies are 89.49%, 95.06%, and 95.03% respectively, achieving higher accuracy on unknown classes while maintaining high accuracy on known classes.

收稿日期: 2025-08-26; 修订日期: 2025-09-19.

基金项目: 黑龙江省重点研发计划资助项目(No. JD2023SJ19); 黑龙江省自然科学基金资助项目(No. LH2023F034)

tive learning with DenseNet. First, a spectral feature extraction module is employed to obtain the original spectral features, and multi-level feature interaction is realized through DenseNet. A transition module is further applied to compress spectral channels, thereby yielding clearer class boundary distributions. Second, the extracted spectral features are mapped to a spatial feature extraction module to obtain spatial-domain representations, where ResNet is adopted to capture local spatial structural information and enhance spatial perception. Subsequently, contrastive learning is introduced to reinforce intra-class compactness and inter-class separability, and is combined with a hard-sample mining mechanism to optimize ambiguous boundary features and improve the model's discriminative capability for boundary-region samples. Experiments conducted on the Houston 2013, Pavia University, and WHU Hi-LongKou datasets demonstrate that the proposed method achieves superior ground-cover classification performance on unknown categories, with accuracies of 68.81%, 69.24%, and 59.26%, respectively. Meanwhile, overall accuracies of 89.49%, 95.06%, and 95.03% are obtained, indicating that the recognition of unknown categories is effectively enhanced while maintaining high classification accuracy for known categories.

Key words: hyperspectral image; open-set; DenseNet; contrastive learning; hard samples mining

1 引 言

高光谱图像(Hyperspectral Image, HSI)能够在空间和光谱维度上提供丰富信息,因此广泛应用于精细地物分类^[1]、环境监测^[2]和军事侦察^[3]等领域。与多光谱影像相比,高光谱图像具有丰富的光谱和空间信息,能够捕捉地物之间细微的差异,这为精细分类提供了坚实基础。然而,高光谱数据也存在不同类别光谱相似度高、特征分布易混淆的问题,这不仅加大了类别区分的难度,而且在开放集分类任务中会被进一步放大,导致未知类更容易与已知类混淆。

现有的大多数高光谱图像分类方法建立在闭集假设之上,即假定所有测试样本类别均已在训练集中被定义和标注,此类任务通常被称为闭集分类^[4-6]。然而,在实际高光谱遥感应用中,由于采集范围广泛且地物类型复杂,训练阶段难以覆盖所有类别,从而在测试阶段不可避免地出现未知类样本,在这种情况下,分类任务被定义为开放集分类^[7]。传统的闭集方法在该情境下往往将未知类误判为最相似的已知类,降低了模型的实用性与稳定性^[8]。因此,在开放集环境下,精准分类已知类,并有效区分与其高度相似的未知类,成为高光谱图像开放集分类待解决的关键问题^[9]。

为应对这一挑战,开放集分类被引入HSI领域,其目标是在保证已知类别准确分类的同时,

有效识别并拒绝未知类别样本,从而提升模型在复杂遥感场景下的泛化能力与稳定性^[10-11]。Liu等提出了一种面向开放集的多任务深度学习方法,通过联合分类任务与重建机制,实现了对未知类别的有效分类,并提升了小样本场景下的分类性能^[12]。Yue等则设计了一种光谱-空间重建框架,在开放集环境下同时进行特征重建与逐像素分类,不仅增强了对未知类的稳定性,还保持了对已知类的高精度识别^[13]。然而,这些方法在特征学习阶段普遍缺乏约束,可能导致已知类与未知类在特征空间中过于接近,从而削弱判别能力^[14-15]。

为了解决上述问题,Li等提出了基于对比学习的开放集模型,通过对比学习减少同类样本的距离,增大异类样本的距离,并通过类锚点距离获取地物类别^[16]。对比学习的方法可在同类样本间形成更紧凑的聚类,同时拉远不同类之间的距离,利用这一特性增强未知类与已知类的可区分性^[17-18]。尽管对比学习能够增大不同样本之间的距离,但在形成类别聚类时往往将所有类别等同对待,容易忽视那些与已知类相似度较高的未知类样本。这类样本通常分布在类间边界区域,处理不当将削弱模型的判别能力。

针对这一问题,困难样本挖掘通过识别与已知类高度相似的边界样本,并在训练中赋予其更高权重,从而强化模型对这类样本的学习,提升开放集分类的性能。Tu等将图结构与困难

样本挖掘相结合,在生成图结构的同时对不同节点赋予差异化权重,其中,相似度较高的节点被分配更大的权重,引导模型在训练过程中更加关注困难节点^[19]。Guan等利用光谱特征和空间邻域特征构建双视角,从而在聚类中同时捕捉样本的光谱信息和空间上下文信息。在训练过程中,通过困难样本发掘识别那些难以区分的样本,并对这些样本赋予更高的权重,以增强模型对边界样本的关注度,从而提升整体聚类效果^[20]。然而,这些方法大多针对闭集分类任务,未能充分考虑高光谱数据类别间光谱相似度高的特点,因此,仅依靠困难样本挖掘难以满足开放集分类的需求。

在开放集特征提取模型的选择上,需要既能充分挖掘光谱特征信息,又能有效增加已知类与未知类在特征空间中边界的清晰度,从而提升对未知类别的识别能力。DenseNet的稠密连接机制能够促进浅层局部光谱特征与深层语义特征的交互,从而更有效地捕捉光谱中细微而关键的差异,有助于区分未知类别样本^[21]。在每次稠密连接后引入的过渡模块可对光谱通道进行压缩,使同类样本在特征空间内分布更加集中、类间边界更加清晰,从而不仅提升已知类别的分类精度,也使偏离这些紧密类簇的未知类别样本更易被识别为未知类,增强开放集识别的稳定性^[22]。

综上所述,本文针对高光谱图像开放集分类中存在的光谱相似度高和特征分布易混淆等问题,提出了一种结合对比学习与DenseNet的开

放集分类方法。通过构建空-谱特征提取模型,在训练过程中精细捕捉光谱差异并有效结合空间信息,形成更清晰的类边界。同时,结合困难样本挖掘策略挖掘易混淆的边界样本,使模型在训练过程中更加关注易混淆的边界特征,从而提升对未知类别的判别精度。

2 HSI开放集分类方法-CLCD

2.1 CLCD 的模型架构

对比学习结合 DenseNet 的高光谱图像开放集分类方法(Contrastive Learning Combined with DenseNet, CLCD)的架构如图 1 所示。在光谱特征提取阶段,采用改进的 DenseNet 获取光谱特征将二维卷积改进为三维卷积,能够在不破坏空间结构的前提下捕获光谱维度的连续性信息,从而更好地区分光谱相似的类别。在过渡模块(Transition block, TB)中去除下采样,仅通过 $1 \times 1 \times 1$ 卷积实现通道压缩,有效避免了光谱信息丢失,同时去除冗余特征,使同类样本在特征空间中更加紧凑,异类样本间的边界更清晰。压缩后的光谱特征被输入空间特征提取模块,并映射至 ResNet 模块,以提升模型对边缘、纹理及复杂空间结构的感知能力。接着,训练对比学习损失函数 $L_{\text{SCL_Spe}}$ 和 $L_{\text{SCL_Spa}}$,加强类内样本的聚合性和类间样本的可分性,进一步提升特征的表达能力。在对比学习特征空间中引入困难样本挖掘(Hard Sample Mining, HSM)策略,不再局限于均匀训练所有样本,而是重点关注边界处易混淆




图 1 CLCD 模型架构

Fig. 1 Architecture of CLCD model

的样本,使模型在复杂类别交界和未知类出现时具备更强的判别能力。最后,通过样本与类别锚点的距离获取地物的类别。

2.2 空-谱特征提取模型

高光谱图像在开放集分类任务中普遍面临类间光谱相似度高、特征分布易混淆的挑战,单一模型方法往往难以同时兼顾已知类的精确分类与未知类的有效拒识。因此,本文在模型设计中针对不同维度特征进行有针对性的处理。首先,3D-CNN能够同时处理光谱与空间维度而不破坏其结构完整性,因此被用作光谱/空间的特征提取模块,并在不同维度上分别单独处理。其次,在光谱维度中引入改进的DenseNet模型,将二维卷积改进为三维卷积实现对光谱维的精细特征提取,并在过渡模块中去除下采样,在有效压缩冗余信息的同时避免了光谱信息的损失。最后,在空间维度中,为更好地捕捉高光谱图像的二维上下文信息,采用ResNet模型利用二维卷积增强模型的空间表征能力,从而进一步提升整体分类性能。

2.2.1 光谱特征提取

在光谱特征提取阶段,模型由光谱特征提取模块和改进的DenseNet组成。针对改进后的DenseNet,本文主要进行了两方面改进:首先,将传统的二维卷积替换为三维卷积,并采用形状为 $7 \times 1 \times 1$ 的卷积核,以充分捕捉光谱维度上的连续性信息,同时保持空间结构完整;其次,在过渡层中去除了传统的下采样操作,避免光谱信息丢失,仅通过 $1 \times 1 \times 1$ 卷积实现通道压缩,有效去除冗余特征、保留判别信息,从而增强类内特征的紧凑性,使模型在开放集高光谱分类任务中能够更准确地区分光谱相似的类别。假设HSI数据为 $x \in \mathbf{R}^{B \times C \times D \times H \times W}$,其中 B 为批次大小, C 为输入的通道数, D 为HSI光谱维数, H, W 为空间尺寸。为了在从HSI中获取光谱维度特征,首先将 x 映射到光谱特征提取模块中,通过3D卷积沿光谱维进行特征提取,过程如下:

$$X_1[b, c_{\text{out}}, d, h, w] = \sum_{c_{\text{in}}=1}^{C_{\text{in}}} \sum_{i=1}^7 W_{c_{\text{out}}, c_{\text{in}}, i, 0, 0} \cdot$$

$$X[b, c_{\text{in}}, 2(d-1)+i, h, w], \quad (1)$$

其中: $b \in [1, B]$, $c_{\text{in}}, c_{\text{out}}$ 分别表示输入和输出通

道, W 代表3D卷积的权重,卷积核尺寸为 $7 \times 1 \times 1$,Padding为 $(2, 1, 1)$ 。

与此同时,对输出的特征图进行批归一化(Batch Normalization, BN)处理,以稳定训练过程中的梯度分布,并采用LeakyReLU激活函数,引入非线性映射能力,从而增强模型对复杂数据的表达能力。其定义如下:

$$X_2 = \sigma(\mathcal{B}(X_1)), \quad (2)$$

其中: σ 代表LeakyReLU激活函数, $\mathcal{B}$ 表示为BN层。将输出的特征图输入改进后的DenseNet,该模型将传统的2D卷积改进为3D卷积,从而充分处理HSI第三维光谱特征。其模型架构如图2所示(彩图见期刊电子版),包含DSB_1和DSB_2两个子模块。其中紫色箭头表示稠密连接,即每一层的输出特征都会与前一层的特征相加。同时,DSB_2模块的输出特征还会与DSB_1各层的输出特征进行相加,从而实现多层次信息的交互。




图2 改进的DenseNet模型架构

Fig. 2 Structure of improved DenseNet model

首先,通过第一个稠密光谱模块(Dense Spectral Block, DSB),该模块由3D卷积层、BN层及LeakyReLU激活函数组成,具体处理流程如下:

$$Y_l[b, c_{\text{out}}, d, h, w] = \sum_{c_{\text{in}}=1}^{C_{\text{in}}} \sum_{k=1}^7 W_{c_{\text{out}}, c_{\text{in}}, k, 0, 0} \cdot H_l[b, c_{\text{in}}, d+k-4, h, w], \quad (3)$$

其中: $H_l = \sigma(\mathcal{B}(X_{l-1}))$, X_{l-1} 表示上一层输入, C_{in} 为输入通道数, C_{out} 为输出通道数,

在此基础上结合稠密连接机制,将当前输出

与历史特征在通道维拼接,实现不同层次信息的交互,捕捉细粒度的光谱变化,计算过程如下:

$$X_l = \text{Cat}(X_{l-1}, Y_l), \quad (4)$$

其中:Cat($\bullet$)代表通道拼接, X_l 表示通道拼接后输出的特征。完成稠密连接后,通过过渡模块,将拼接后的特征,通过 3D 卷积层压缩回 28 个通道,使模型后续训练过程中形成清晰类间边界,为后续的困难样本挖掘提供清晰的边界分布,以便挖掘困难样本。过渡模块定义如下:

$$X_3 = \sigma(\text{Conv3D}(\mathcal{B}(X_l))), \quad (5)$$

其中:Conv3D 表示为 3D 卷积,尺寸为 $28 \times 1 \times 1$ 。

最后,将第 DSB_2 的输出 X_4 输入平均池化层,获得最后的光谱维度的损失值,定义如下:

$$L_{\text{SCL_Spe}} = \frac{1}{D \cdot H \cdot W} \sum_{d=1}^D \sum_{h=1}^H \sum_{w=1}^W X_4[c, d, h, w], \quad (6)$$

其中 D, H, W 分别为光谱、高度和宽度。

2.2.2 空间特征提取

该模块与光谱特征提取阶段级联,用于在空间维度上捕提高光谱图像的局部细节信息。首先,将光谱特征的输出映射至空间特征提取模块,通过尺寸为 $49 \times 3 \times 3$ 的 3D 卷积,整合光谱连续波段信息的同时提取空间结构特征。其过程如下:

$$Y[b, c_{\text{out}}, h, w] = \sum_{c_{\text{in}}=1}^{C_{\text{in}}} \sum_{i=1}^k \sum_{j=-1}^1 \sum_{l=-1}^1 W_{c_{\text{out}}, c_{\text{in}}, i, j+2, l+2} \cdot X_4[b, c_{\text{in}}, d+i-1, h+j, w+l]. \quad (7)$$

随后,通过 Squeeze 函数实现从光谱维到空间维的映射,定义如下:

$$X_5 = \text{Squeeze}(Y, \text{spectral dim}). \quad (8)$$

此外,对卷积输出的每个通道,通过 Leaky-ReLU 激活函数增强模型对复杂空间特征的代表能力。接着进行 BN 处理,以稳定训练过程中的数值分布,定义如下:

$$X_6 = \mathcal{B}(\sigma(X_5)), \quad (9)$$

其中: σ 为 LeakyReLU 激活函数, $\mathcal{B}$ 为 BN 层。将空间特征提取模块的输出输入 ResNet,由第一个残差模块(Residual Spatial, ResSPA)提取空间特征。该模块由 2D 卷积、BN 层和 LeakyReLU 激活函数组成,其结构如图 3 所示。

通过残差连接既缓解了深层网络的梯度消失问题,又保留并强化了边缘和纹理等空间细




图 3 增强局部空间特征的残差块架构

Fig. 3 Structure of residual block for enhancing local spatial features

节,其处理过程如下:

$$y_{b, c_{\text{out}}, i, j} = \sum_{c_{\text{in}}=1}^{C_{\text{in}}} \sum_{m=0}^2 \sum_{n=0}^2 W_{c_{\text{out}}, c_{\text{in}}, m, n} \cdot x_{b, c_{\text{in}}, i+m-p_h, j+n-p_w}. \quad (10)$$

接下来,在每个卷积操作后,均通过 BN 层和 LeakyReLU 激活函数,具体过程如下:

$$X_7 = \sigma(\mathcal{B}(y_{b, c_{\text{out}}, i, j})) + X_6. \quad (11)$$

通过第二个 ResSPA 模块后,得到精细的空间上下文信息 X_8 。随后,利用 2D 平均池化操作对 X_8 进行处理,得到最终空间维度损失值,定义如下:

$$L_{\text{SCL_Spa}} = \frac{1}{H \cdot W} \sum_{h=1}^H \sum_{w=1}^W X_8(c, h, w), \quad (12)$$

其中: H, W 分别为高度、宽度, X_8 为第二个 ResSPA 模块的输出。

2.3 对比学习中的困难样本挖掘

在空-谱特征提取模型获得精细的光谱-空间特征后,模型已能够捕获判别性较强的特征表示并形成清晰的类别边界,但在开放集场景下,仅依赖特征提取仍不足以保证对未知类别的高精度识别。为此,本文在特征提取之后级联对比学习模块,通过引导同类样本特征向各自类别中心聚合,增强类内一致性;同时推动不同类别间的特征分离,提升类间可分性,从而在嵌入空间中构建更具结构性的分布,有助于提升对未知类别的识别能力。

然而,传统对比学习往往对所有样本一视同仁,难以充分关注那些与已知类别语义相近的困难样本,而这类样本往往决定了模型的最终性能。为解决这一问题,本文进一步在对比学习空间中引入困难样本挖掘策略。与传统困难样本挖掘仅根据距离选择负样本不同,本方法引入了加权困难样本机制,保证模型重点关注“距离近”和“类别相似”的困难样本,而不是只选择距离近

的困难样本,使模型在训练过程中更加专注于易混淆样本,从而有效提升特征区分能力,并显著增强对未知类别的判别精度。

首先,在对比学习空间中计算每对样本之间的特征距离,其定义如下:

$$D(z_i, z_j) = \|z_i - z_j\|_2^2. \quad (13)$$

为了进一步提高类内特征聚合性并强化类间区分性,引入对比损失函数 L_{SCL} 对样本之间的相对关系进行优化,其表达式如下:

$$L_{\text{SCL}} = \frac{1}{2N} \sum_{n_{ij}=1, i \neq j}^N M_{ij} D^2 + (1 - M_{ij}) \cdot \max(0, \eta - D)^2, \quad (14)$$

其中: N 表示样本对的总数, $M_{ij} = 1$ 表示样本对 (i, j) 属于同一类别, $M_{ij} = 0$ 表示样本对 (i, j) 不属于同一类别, η 为负样本边界阈值。该损失函数促进同类样本间距离尽可能小,异类样本间距离至少大于 η , 进一步提升特征分布的可分性。

最后,对比学习的损失函数由 $L_{\text{SCL_Spe}}$ 和 $L_{\text{SCL_Spa}}$ 构成,定义如下:

$$L_{\text{contrastive}} = L_{\text{SCL_Spe}} + L_{\text{SCL_Spa}}. \quad (15)$$

在构建对比学习特征空间后,进一步引入困难样本挖掘策略,使模型在训练过程中更加关注与真实类别相近的困难样本,从而增强对边界困难样本的区分能力。困难样本挖掘的示意图如图 4 所示,其中白色表示未知类,其余表示已知类。带阴影的白色样本为权重较高的困难样本,表示这些样本在训练过程中需要被重点关注。




图 4 结合对比学习的困难样本挖掘

Fig. 4 Hard samples mining using contrastive learning

首先,计算每个训练样本与所有类别锚点之间的欧氏距离,提取其中与真实类别锚点之间的距离作为正样本距离 d^+ , 并通过掩码排除正类, 获得负类距离集合 $d^- \in \mathbf{R}^{B \times (K-1)}$, 其中 B 为批大小, K 为已知类别数; 随后, 在所有负类中采用困难样本选取策略获得 k 个类别作为困难负样本,

$k = \max(1, r \cdot (K - 1))$, 其中 $r = 0.3$ 表示困难样本选择比例, 具体定义如下:

$$L_{\text{HSM}} = \frac{1}{B} \sum_{i=1}^B \log \left(1 + \sum_{j=1}^k \exp(d_i^+ - \hat{d}_{ij}^-) \right), \quad (16)$$

其中: $\hat{d}_{ij}^-$ 为 Top- k 加权困难负类的距离, 其中的权重为 $w_{ij}^{\text{class}} = \exp(-\Delta_{ij})$, Δ_{ij} 表示不同类别索引之间差值, 值越小代表相似度越高, 越值得被关注。同时结合类锚中心损失 L_{anchor} , 将样本特征向其对应类别锚点聚合, 提升类内特征的一致性, 定义如下:

$$L_{\text{anchor}} = \frac{1}{B} \sum_{i=1}^B \|z_i - c_{y_i}\|_2. \quad (17)$$

最后, 本文构建了一个联合优化的损失函数。通过 L_{anchor} , $L_{\text{contrastive}}$, L_{HSM} 三者的协同作用, 共同指导训练样本, 使模型在有效学习已知类别特征的基础上, 进一步聚焦于边界区域, 提升对边界困难样本的区分能力, 从而提升 CLCD 模型性能的提升。总的损失函数定义如下:

$$L_{\text{total}} = \alpha \cdot L_{\text{anchor}} + \beta \cdot L_{\text{contrastive}} + L_{\text{HSM}}, \quad (18)$$

其中: $\alpha = 1.5$, $\beta = 0.05$, 为控制权重的超参数。

2.4 判别未知类别

在未知类别判别方面, 本文采用基于类锚点距离的分类策略: 当测试样本与所有已知类别锚点的最小距离超过预设阈值时, 将其判定为未知类别; 否则, 则将其归类为距离最近的已知类别。

在测试阶段, 通过拒绝分数向量 δ 来衡量样本不属于已知类别的可能性, 基于类锚点距离的判别得分定义如下:

$$\delta = d \cdot (1 - \text{softmax}(d)), \quad (19)$$

其中, $\cdot$ 表示为元素间的乘积, d 为 z_i 和每个锚点之间的距离。基于上述得分函数, 进一步构建了最终的分类决策规则, 用于在测试阶段判别样本是否属于未知类别。具体的分类规则定义如下:

$$\hat{y} = \begin{cases} \text{unknown}, & \min(\delta) > \theta \\ \arg \min(\delta), & \min(\delta) \leq \theta \end{cases}, \quad (20)$$

其中分类阈值 $\theta = 0.1$, 表示用于判别类别距离阈值的超参数。当样本与所有已知类别锚点的距离均大于该阈值 (即 $\min(\delta) > \theta$) 时, 说明它不属于任何已知类别, 应判定为未知类别; 反之, 则将它分配给距离最近的已知类别。

3 实验结果与分析


3.1 实验数据集描述

为了验证所提模型在 HSI 开放集分类任务中的性能,本文在 Houston2013, Pavia University, WHU-Hi-LongKou 3 个公开数据集上进行了实验。Houston2013 数据集包含 $349\times1\,905$ 像素,144 个波段,空间分辨率为 2.5 m,15 个地物类别,将“water, parking lot 2, tennis court, running track”设为未知类别,其余作为已知类别参与训练和测试。表 1 给出每类样本的类别及数目、伪彩色图及地面真值图。

Pavia University 数据集包含 610×340 像素,103 个波段,空间分辨率为 1.3 m,共有 9 个类别。

表 1 Houston2013 数据集土地类别详情


Tab. 1 Land class details in Houston2013 dataset

颜色	类别	样本	伪彩色图	真值图
	Healthy grass	1251		
	Stressed grass	1254		
	Synthetic grass	697		
	Trees	1244		
	Soil	1242		
	Residential	1268		
	Commercial	1244		
	Road	1252		
	Highway	1227		
	Railway	1235		
	Parking lot1	1233		
	Novel	1882		

将“Shadow”作为未知类别,其余 8 个类别作为已知类别,如表 2 所示。

表 2 Pavia University 数据集土地类别详情

Tab. 2 Land class details in Pavia University dataset

颜色	类别	样本	伪彩色图	真值图
	Asphalt	6631		
	Meadows	18649		
	Gravel	2099		
	Trees	3064		
	Sheets	1345		
	Bare soil	5029		
	Bitumen	1330		
	Bricks	3682		
	Novel	947		


WHU-Hi-LongKou 数据集在中国湖北省龙口镇采集,包含 550×400 像素,270 个波段,空间分辨率为 1.3 m,空间分辨率为 0.463 m,共有 9 个类别。将“Mixed weed”作为未知类别,其余 8 个类别作为已知类别,如表 3 所示。

3.2 实验平台及参数设置

实验环境是 Intel(R)Xeon(R)CPU E5-2620 v4@2.10GHz 处理器、128 GB 内存和 NVIDIA GeForce RTX 2080Ti GPU 显卡;此外,深度学习框架是 Pytorch,它使用 Python 作为编程语言,采用预热余弦退火学习率调整算法进行优化。在训练初期,学习率从 1×10^{-6} 逐渐增加到 1×10^{-3} ,防止刚开始训练时因学习率过大而导致不稳定,迭代次数设为 500。为了减少训练样本带来的随机性,每个试验重复 10 次取平均值作为

表 3 WHU-Hi-LongKou 数据集土地类别详情

Tab. 3 Land class details in WHU-Hi-LongKou dataset

颜色	类别	样本	伪彩色图	真值图
	Corn	34511		
	Cotton	8374		
	Sesame	3031		
	Broad-leaf soybean	63212		
	Narrow-leaf soybean	4151		
	Rice	11854		
	Water	67056		
	Roads and houses	7124		
	Novel	5229		

最终实验结果。

评估方法性能方面,采用总体分类精度 (Overall Accuracy, OA)、平均分类精度 (Average Accuracy, AA) 和 Kappa 系数 3 项指标对模型进行全面评估。OA 表示正确分类样本占测试样本总数的比例。AA 则表示各类别分类精度的平均值,能够衡量不同类别间的分类差异。Kappa 系数表示分类结果与地面真实值的一致性。Memory 表示训练过程中占用的显存。Training Time 和 Test Time 分别表示模型的训练时间和测试时间,用于评估模型的计算效率。此外,Training Time 不包括训练前后的数据准备与处理,仅统计模型训练过程中(包括数据加载、前向传播、反向传播及参数更新)的耗时;Test Time 则仅指模型在测试集上的推理时间。

3.3 实验对比及分析

3.3.1 不同分类方法的对比

为了验证 CLCD 方法的有效性,本文将它与 OSC-SCL^[16], DCRN^[23], HybridSN^[24], ResNet^[25] 和 3D-CNN^[26] 和 DTCL^[27] 等模型进行了比较。其中,DCRN 是一个双通道光谱-空间特征提取模型,分别对空间和光谱特征进行特征提取,然后融合光谱和空间特征,最后进行分类。Hybrid-SN 结合二维和三维卷积的混合卷积网络,可同

时提取光谱和空间特征,兼顾特征表达能力与计算效率。ResNet 通过残差连接缓解深层网络训练中的梯度消失问题,增强网络的深度和非线性表达能力。3D-CNN 采用三维卷积直接处理高光谱立方体数据,可同时捕获光谱和空间信息。OSC-SCL 是一种开放集分类方法,通过引入对比学习增强类内紧致性和类间分离性,从而提升已知类判别能力并增强未知类的区分能力。DTCL (Dynamically Temperature Contrastive Learning) 通过动态温度缩放函数优化对比学习。本文将该机制引入 OSC-SCL 基线模型中,以验证本文方法相较先进对比学习方法的优势。不同方法在 Houston2013, Pavia University 和 WHU-Hi-LongKou 数据集上的分类结果分别如表 4~表 6 所示。不同方法在 3 个数据集上的分类结果分别如图 5~图 7 所示。

由表 4 可知,CLCD 模型在 Houston2013 数据集上的 OA, AA 和 Kappa 指标均达到最高值,分别为 89.49%, 90.79% 和 89.43。相较于 OSC-SCL 方法,本文在 Healthy grass, Synthetic grass, Trees, Soil, Residential, Highway 等类别分别提升了 0.35%, 0.1%, 0.14%, 0.19%, 0.24%, 2.35%。而在 Stressed grass, Commercial, Road, Railway, Parking lot1 等类别上略逊于 OSC-SCL, 分别降低了 0.46%, 1.45%, 1.76%,

表 4 不同方法在 Houston2013 数据集上的分类精度对比

Tab. 4 Comparison of classification accuracy of different methods on Houston2013 dataset

模型	Healthy grass	Stressed grass	Synthetic grass	Trees	Soil	Residential
3D-CNN	83.69±3.17	42.71±6.01	60.26±2.87	48.76±6.41	28.34±4.76	47.52±6.20
ResNet	84.20±0.52	78.36±2.31	87.81±4.62	65.83±12.76	62.26±15.69	73.69±3.13
HybridSN	91.19±7.27	91.63±4.59	98.10±3.16	94.03±4.04	90.28±12.55	84.33±5.75
DCRN	90.25±2.70	97.32±2.52	100.00	98.93±0.90	96.54±4.79	91.25±5.96
OSC-SCL	98.59±0.41	98.76±0.75	99.85±0.25	94.01±0.09	99.78±0.30	91.64±0.18
DTCL	99.21±0.37	98.40±0.31	100.00	94.00±0.14	99.76±0.26	92.29±0.38
CLCD	98.94±0.78	98.30±0.13	99.95±0.08	94.15±0.12	99.97±0.04	91.88±0.68
模型	Commercial	Road	Highway	Railway	Parking lot1	Novel
3D-CNN	44.70±14.41	53.28±5.30	39.70±2.47	37.62±3.20	28.83±8.65	—
ResNet	42.71±1.51	71.99±7.03	51.40±13.71	47.48±6.20	39.01±8.99	—
HybridSN	61.05±17.71	80.07±14.71	55.73±13.82	63.67±29.06	71.17±9.53	—
DCRN	74.63±7.54	93.26±2.82	88.07±8.38	79.52±15.53	88.02±12.80	—
OSC-SCL	86.96±0.37	87.20±5.04	95.64±4.18	79.04±1.06	91.90±2.24	62.01±3.96
DTCL	86.36±0.68	83.26±3.64	97.62±0.70	80.23±0.76	92.93±1.74	60.62±3.98
CLCD	85.51±0.49	85.44±1.71	97.99±0.56	78.19±2.85	90.41±0.26	68.81±6.91

续表 4 不同方法在 **Houston2013** 数据集上的分类精度对比

Tab. 4 Comparison of classification accuracy of different methods on Houston2013 dataset

模型	OA/%	AA/%	Kappa×100	Memory/MB	Training time/s	Test time/s
3D-CNN	40.55±1.81	42.95±1.90	35.34±1.96	227.01	15.38	3.01
ResNet	55.26±1.72	58.73±1.57	51.33±1.86	795.35	97.72	16.91
HybridSN	69.49±2.71	73.43±2.65	66.80±2.94	422.30	13.47	3.21
DCRN	79.03±2.13	83.15±2.16	77.20±2.34	211.70	29.41	3.37
OSC-SCL	88.84±0.27	90.45±0.24	88.01±2.60	309.73	510.70	12.94
DTCL	88.71±0.63	90.39±0.49	86.42±5.17	309.73	508.32	13.20
CLCD	89.49±1.08	90.79±0.79	89.43±6.68	641.79	362.31	12.84

表 5 不同方法在 **Pavia University** 数据集上的分类精度对比

Tab. 5 Comparison of classification accuracy of different methods on Pavia University dataset

模型	Asphalt	Meadows	Gravel	Trees	Sheets	Bare soil	Bitumen
3D-CNN	65.01±3.30	81.76±3.51	50.47±2.85	94.52±2.13	89.39±3.19	43.00±7.03	76.66±7.62
ResNet	69.95±2.16	81.74±1.43	52.55±4.79	93.11±2.54	97.25±2.97	58.97±1.29	77.59±13.70
HybridSN	91.55±6.23	85.97±8.03	86.92±9.62	98.48±0.56	99.69±0.29	95.71±3.84	90.86±5.85
DCRN	95.47±3.19	85.52±2.14	97.81±1.67	96.23±1.45	100.00	99.58±0.38	99.72±0.36
OSC-SCL	95.53±1.93	92.51±1.07	95.65±2.11	97.77±0.43	100.00	99.79±0.26	99.99±0.03
DTCL	94.80±1.94	93.05±2.02	95.54±1.60	97.09±1.13	100.00	99.97±0.07	100.00
CLCD	95.10±2.35	94.29±2.12	95.49±2.25	97.86±0.81	100.00	99.93±0.14	99.90±0.19

模型	Bricks	Novel	OA/%	AA/%	Kappa×100	Memory/MB	Training time/s	Test time/s
3D-CNN	64.21±5.45	—	70.75±1.76	62.78±0.57	61.73±2.14	168.45	10.06	6.52
ResNet	71.06±6.94	—	74.25±1.06	66.91±1.87	66.50±1.44	606.57	55.10	36.03
HybridSN	71.54±11.87	—	86.36±3.49	80.08±0.75	82.43±4.21	304.93	8.46	6.85
DCRN	95.58±3.03	—	89.96±0.79	85.55±0.48	87.04±0.99	156.14	16.38	6.55
OSC-SCL	90.93±3.30	65.75±8.94	94.09±0.44	93.10±1.31	86.65±6.27	216.87	279.79	31.34
DTCL	95.59±1.79	66.79±8.11	94.61±1.05	93.65±0.45	87.83±6.65	216.87	259.51	29.27
CLCD	92.80±2.26	69.24±6.97	95.06±0.94	93.85±0.44	94.00±0.51	458.06	192.13	30.14

0.85%, 1.49%, 在 Novel 类别提升了 6.8%, 充分验证了所提方法在开放集分类任务中的有效性。结合图 5 可以发现, CLCD 的分类结果与地面真值图最为接近, 其中 Highway 和 Novel 类别呈现出更为清晰的边界轮廓, 说明本文方法在区分易混淆类别边界方面具备更强的特征捕获能力。

如表 5 所示, 在 Pavia University 数据集上, 本文提出的方法在 Meadows, Trees, Bare soil, Bricks 和 Novel 五个类别上的分类性能均有显著提升, 分别达到 94.29%, 97.86%, 99.93%, 92.80% 和 69.24%。从图 6 可以看出, 这些类别区域的边缘更为精确, 轮廓更加清晰, 进一步证

明了在增加对困难样本的训练后, 本文方法能够有效提升开放集分类的性能, 从而验证了其有效性。


从表 6 可以发现, 在 WHU-Hi-LongKou 数据集中, 相较于 OSC-SCL 方法, 在 Sesame, Broad-leaf soybean, Narrow-leaf soybean, Rice, Water, Novel 等类别分别提升了 0.2%, 0.42%, 0.9%, 0.17%, 0.02% 和 9.1%。而在 Corn, Cotton, Roads and houses 等类别分别下降了 0.04%, 0.51%, 0.71%。总体表现优于对比方法, 进一步证明了本文方法在开放集分类任务中的优越性。从图 7 可以发现, 本文方法的分类结果与真实地物图最为接近, 错分区域最少, 说明模型在

表 6 不同方法在 WHU-Hi-LongKou 数据集上的分类精度对比


Tab. 6 Comparison of classification accuracy of different methods on WHU-Hi-LongKou dataset

模型	Corn	Cotton	Sesame	Broad-leaf soybean	Narrow-leaf soybean	Rice	Water
3D-CNN	36.06±5.96	89.86±0.98	36.48±3.21	52.76±1.76	57.18±19.05	68.69±5.31	97.11±0.50
ResNet	87.88±1.68	92.37±2.24	60.86±6.07	47.44±7.40	79.76±3.09	85.80±8.68	98.74±0.55
HybridSN	97.20±1.33	92.99±3.64	92.97±0.98	83.89±8.76	95.90±2.10	96.00±2.75	99.95±0.02
DCRN	99.51±0.55	93.43±10.37	99.85±0.27	89.59±1.88	96.13±3.15	98.78±0.63	99.98±0.02
OSC-SCL	96.04±2.26	98.02±0.50	99.79±0.19	90.38±0.84	96.60±0.56	99.50±0.15	99.71±0.04
DTCL	95.76±1.37	96.27±0.51	99.69±0.26	89.80±0.48	97.27±0.83	99.73±0.20	99.63±0.26
CLCD	96.00±0.62	97.51±0.44	99.99±0.02	90.80±1.33	97.50±1.12	99.67±0.12	99.73±0.14


模型	Roads and houses	Novel	OA/%	AA/%	Kappa×100	Memory/ MB	Training time/s	Test time/s
3D-CNN	69.81±7.68	—	66.02±1.45	56.44±1.40	57.90±1.63	408.00	17.49	61.56
ResNet	86.10±5.07	—	76.13±2.06	70.99±1.12	70.36±2.34	1371.33	132.96	417.99
HybridSN	96.66±0.49	—	89.94±2.59	83.32±0.64	87.06±3.18	787.37	16.00	71.44
DCRN	97.48±2.61	—	93.63±0.61	86.08±1.27	91.71±0.77	408.45	53.58	67.61
OSC-SCL	96.43±0.28	50.16±3.00	94.68±0.16	91.85±0.36	87.03±4.45	565.93	656.99	264.90
DTCL	96.28±0.54	52.82±3.91	94.45±0.47	91.92±0.47	92.50±5.37	565.93	648.66	239.44
CLCD	95.72±0.28	59.26±6.64	95.03±0.47	92.91±0.71	92.93±2.48	1200.09	614.69	284.38



Ground truth



3D-CNN



ResNet




图5 不同方法在 Houston2013数据集上的分类结果

Fig. 5 Classification results of different methods on Houston2013 dataset

边界判别上具有优越的表现,提升了模型的最终性能。

通过实验结果可以看出,尽管现有的开放集分类方法 OSC-SCL 在已知类上能够取得一定的精度,但在处理类别间光谱相似性和特征分布混淆时仍存在明显不足,导致对未知类的分类能力有限。相比之下,本文提出的 CLCD 方法通过在

光谱维度引入改进的 DenseNet、在对比学习空间引入困难样本挖掘策略后有效增强了类内紧凑性与类间可分性。与现有方法相比,CLCD 在保持已知类分类精度的同时,显著提升了对未知类的识别性能,体现出在开放集高光谱图像分类任务中的优势。

此外,为评估模型复杂度,本文以在训练过





图 6 不同方法在 Pavia University 数据集上的分类结果

Fig. 6 Classification results of different methods on Pavia University dataset






图 7 不同方法在 WHU-Hi-LongKou 数据集上的分类结果

Fig. 7 Classification results of different methods on WHU-Hi-LongKou dataset

程中占用的显存作为指标进行了定量分析。以 Houston2013 数据集为例,在相同硬件环境下,CLCD 方法的显存占用为 641.79 MB,相比基线模型 OSC-SCL 的 309.73 MB 增加了 332.06 MB。显存上升主要源于两方面原因:一方面,改进的 DenseNet 采用三维卷积并去除下采样操作,增加了中间特征映射的数量,从而提升了显存占用;另一方面,困难样本挖掘策略在对比学习空间中需计算更多特征间的相似度以筛选困难样本,同样带来了额外的显存开销。然而,这一复杂度的提升带来了显著的性能增益,OA 提升了 0.65%,AA 提升了 0.34%,Kappa 系数提

升了 1.42,Novel 提升了 6.8%。虽然显存占用有所增加,但相比带来的分类性能提升,这一额外开销是可以接受的,说明 CLCD 在适度增加计算资源的前提下,实现了更优的开放集分类能力。

3.3.2 消融实验分析

CLCD 方法的改进主要集中在 HSM 和 DSB 两个模块,本文设计了消融实验来分析这两部分的作用,结果如表 7 所示。实验分为 4 种情况:(1)仅采用基于对比学习的分类方法 OSC-SCL;(2)在 OSC-SCL 的基础上加入 HSM;(3)在 OSC-SCL 的基础上加入 DSB;(4)在 OSC-SCL

表 7 消融实验结果

Tab. 7 Results of ablation experiments

Dataset	HSM	DSB	OA	AA	Kappa×100
Houston2013	—	—	88.84±0.27	90.45±0.24	88.01±2.60
	—	✓	89.33±0.93	90.67±0.60	89.39±2.75
	✓	—	89.36±0.54	90.84±0.28	84.29±3.22
	✓	✓	89.49±1.08	90.79±0.79	89.43±6.68
Pavia University	—	—	94.09±0.44	93.10±1.31	86.65±6.27
	—	✓	94.78±0.49	93.11±0.47	90.93±2.80
	✓	—	94.62±0.61	94.05±1.29	90.69±3.55
	✓	✓	95.06±0.94	93.85±0.44	94.00±0.51
WHU-Hi-LongKou	—	—	94.68±0.16	91.85±0.36	87.03±4.45
	—	✓	94.78±0.33	92.08±0.32	90.03±6.18
	✓	—	94.96±0.28	92.16±0.77	90.23±3.83
	✓	✓	95.03±0.47	92.91±0.71	92.93±2.48

的基础上同时加入 HSM 和 DSB。从表 6 中可以观察到,单独加入 HSM 模块时,模型性能已有显著提升,表明 HSM 在区分类别相似且边界复杂的困难样本特征学习方面发挥了重要作用,有效提升了模型对开放集分类的精度。从消融实验结果可以看出,单独加入 DSB 模块也能提升模型性能,说明引入 DSB 提高了模型对细微光谱差异的敏感性。当 HSM 与 DSB 同时引入时,模型在 OA 和未知类的分类精度均达到最高,表明两模块具有互补效应,HSM 增强边界样本判别能力,DSB 强化光谱特征表征能力,二者协同作用显著提高了对开放集的分类能力。在 Houston2013 数据集中,单独使用 HSM 时,虽然 OA 和 AA 得到提升,这是因为 HSM 强化了边界样本的判别能力,使大部分样本预测更准确。然而,由于缺少 DSB 模块,模型获取细致光谱特征的能力有限,对特征分布更加敏感。其中,Kappa 系数受特征分布的影响大,并且该数据集特征分布混淆严重,从而出现 OA/AA 提升但 Kappa 下降的现象。因此,随着 DSB 模块的逐步引入,模型性能进一步稳步提升。相比基线模型 OSC-SCL,CLCD 算法实现了更优的分类效果,充分验证了所提模

型设计的有效性。

3.3.3 模型超参数对分类性能的影响

为评估 CLCD 在不同数据集上的参数敏感性,本文以 Houston2013 数据集为例进行了参数敏感性分析。将 HSM 中用于控制选择困难样本数量的超参数设置为 λ_1 ,类锚点距离分类策略中拒绝分数向量设置为 λ_2 并分别从 $\lambda_1 = \{0.1, 0.2, 0.3, 0.31\}$ 和 $\lambda_2 = \{0.001, 0.01, 0.1, 0.15\}$ 中选取候选值进行组合实验。图 8 展示了在 Houston2013 数据集中, λ_1 与 λ_2 组合变化下 CLCD 在 OA, AA 和 Kappa 等性能指标上的变化趋势(彩图见期刊电子版)。不同颜色的曲面反映了模型在不同参数组合下的性能变化,高峰区域表示模型在该参数组合下取得了更高的 OA, AA 和 Kappa 值,而低谷区域则代表性能较差的情况。

从图 8 中可以观察到,在 Kappa 指标上,模型存在表现出相近的性能水平,但仍存在一定差异。综合对比各项指标并考虑稳定性,本文最终选取了在各指标上表现相对优越的参数组合作为实验设定,最终确定的参数分别为 $\lambda_1 = 0.3$ 和 $\lambda_2 = 0.1$ 。




图 8 超参数对 CLCD 模型的影响

Fig. 8 Effect of hyperparameters on CLCD model

3.3.4 *t*-SNE 特征可视化分析

为了更直观地展示不同方法在特征提取方面的表现,本文采用 *t*-SNE 技术对原始 HSI 数据,OSC-SCL 以及 CLCD 在 Houston2013 和 Pavia University 数据集上的二维特征进行了可视化,相关结果分别如图 9~图 11 所示。可以明显看出,相较于原始 HSI 数据和 OSC-SCL 方法,

本文提出的 CLCD 在 3 个数据集上均表现出更低的类间特征混淆度和更清晰的分类边界,充分说明所提方法能够学习到更加具有区分性的特征表示。具体来看,从图 9(a),10(a)和 11(a)中可以观察到,原始 HSI 数据中的各类地物覆盖范围较广,类别之间存在明显的重叠,难以有效区分。




图9 Houston2013数据集的特征可视化

Fig. 9 Feature visualizations of Houston2013 dataset




图10 Pavia University数据集的特征可视化

Fig. 10 Feature visualizations of Pavia University dataset




图11 WHU-Hi-LongKou数据集的特征可视化

Fig. 11 Feature visualizations of WHU-Hi-LongKou dataset

4 结 论

本文提出了一种基于CLCD的高光谱图像

开放集精准分类方法。该方法结合困难样本挖掘策略与DenseNet模型,实现了对未知类样本的深度挖掘,不仅在确保已知类高精度分类的同

时,显著提升了对未知类的识别能力,还有效增强了模型在类别边界模糊、光谱特征相似等复杂场景下的泛化能力与稳定性。实验在 Houston2013 和 Pavia University、WHU-Hi-LongKou 等数据集上进行,CLCD 的 OA 值分别为 89.49%, 95.06%, 95.03%, AA 值分别为 90.79%, 93.85%, 92.91%, Kappa 值分别为 89.43, 94.00, 92.93, 各项指标均优于对比方法,为 HSI 开放集分类提供了一种高效且性能突出的解决方案。未来的研究将进一步聚焦于更高

效的 HSI 空-谱特征提取策略,推动该方法在新的未知类别不断出现的增量式开放集分类中的应用。

作者贡献声明:

刘城洋:测量方法提出,论文构思和撰写;
赵琳:论文审核,结果讨论与论文定稿;
于亮:论文修改;
吴海滨:实验数据分析与结果验证;
王爱丽:实验设计,数据整理与分析。

参考文献:

- [1] 刘敬,李银桥,刘逸. 主动学习联合聚类分组网络的高光谱遥感图像分类[J]. 光学精密工程, 2024, 32(9): 1395-1407.
LIU J, LI Y Q, LIU Y. Active learning-clustering-group convolutions network for hyperspectral images classification[J]. *Optics and Precision Engineering*, 2024, 32(9): 1395-1407. (in Chinese)
- [2] 景海钊,陶丽杰,张号逵. 3D-CNN与Transformer混合结构的高光谱图像空谱联合分类[J]. 光学精密工程, 2024, 32(23): 3504-3512.
JING H ZH, TAO L J, ZHANG H K. Spectral-spatial classification of hyperspectral imagery with hybrid architecture of 3D-CNN and Transformer[J]. *Optics and Precision Engineering*, 2024, 32(23): 3504-3512. (in Chinese)
- [3] 刘晓敏,余梦君,乔振壮,等. 面向多源遥感数据分类的尺度自适应融合网络[J]. 电子与信息学报, 2024, 46(9): 3693-3702.
LIU X M, YU M J, QIAO ZH ZH, *et al.* Scale adaptive fusion network for multimodal remote sensing data classification[J]. *Journal of Electronics & Information Technology*, 2024, 46(9): 3693-3702. (in Chinese)
- [4] HE X, HAN X, CHEN Y S, *et al.* A light-weighted fusion vision mamba for multimodal remote sensing data classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 21532-21548.
- [5] XIE J, HE N J, FANG L Y, *et al.* Multiscale densely-connected fusion networks for hyperspectral images classification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(1): 246-259.
- [6] ZHANG W T, LI Y B, LIU L, *et al.* Hyperspectral image classification based on spectral-spatial attention tensor network [J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 21: 5500305.
- [7] DU Y F, LI X P, SHI L, *et al.* A prototype network for hyperspectral image open-set classification based on feature invariance and weighted Pearson distance measurement [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5506917.
- [8] QIN B A, FENG S, ZHAO C H, *et al.* Language-enhanced dual-level contrastive learning network for open-set hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5508114.
- [9] LI Z K, QI M T, WANG Y, *et al.* An open-set domain adaptation framework for hyperspectral image classification with pixel-aware weighting and decoupled alignment [J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 5504105.
- [10] PAL D, BUNDELE V, SHARMA R, *et al.* Few-shot open-set recognition of hyperspectral images with outlier calibration network [C]. 2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). January 3-8, 2022, Waikoloa, HI, USA. IEEE, 2022: 2091-2100.
- [11] CHEN M Y, FENG S, ZHAO C H, *et al.* Fractional Fourier-based frequency-spatial - spectral prototype network for agricultural hyperspectral image open-set classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5514014.
- [12] LIU S J, SHI Q, ZHANG L P. Few-shot hyperspectral image classification with unknown classes

- using multitask deep learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(6): 5085-5102.
- [13] YUE J, FANG L Y, HE M. Spectral-spatial latent reconstruction for open-set hyperspectral image classification [J]. *IEEE Transactions on Image Processing*, 2022, 31: 5227-5241.
- [14] VAZE S, HAN K, VEDALDI A, *et al.* Open-Set Recognition: A Good Closed-Set Classifier Is All You Need [J/OL]. *arXiv*, 2022: 1-27. <https://arxiv.org/abs/2110.06207>
- [15] HUANG H Z, WANG Y, HU Q H, *et al.* Class-specific semantic reconstruction for open set recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(4): 4214-4228.
- [16] LI Z K, BI K, WANG Y, *et al.* Supervised contrastive learning for open-set hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 5509805.
- [17] LU T, HU Y C, FU W, *et al.* SCL-net: an end-to-end supervised contrastive learning network for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5544412.
- [18] KHOSLA P, TING Y, WANG H, *et al.* Supervised Contrastive Learning [J/OL]. *arXiv*, 2020, 33: 18661-18673. <https://arxiv.org/abs/2004.11362>.
- [19] TU W X, ZHOU S H, LIU X W, *et al.* Hierarchically contrastive hard sample mining for graph self-supervised pretraining [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(11): 16748-16761.
- [20] GUAN R X, TU W X, LI Z H, *et al.* Spatial - spectral graph contrastive clustering with hard sample mining for hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5535216.
- [21] ZU B K, LI Y F, LI J Q, *et al.* Cascaded convolution-based transformer with densely connected mechanism for spectral-spatial hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5513119.
- [22] YE Z, CAO Z, LIU H, *et al.* Self-supervised learning with multiscale densely connected network for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5522615.
- [23] XU Y M, LI Z K, LI W, *et al.* Dual-channel residual network for hyperspectral image classification with noisy labels [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 5502511.
- [24] ROY S K, KRISHNA G, DUBEY S R, *et al.* HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(2): 277-281.
- [25] XIE W, WU Q Z, REN W, *et al.* Hyperspectral image classification via multi-scale residual attention network [C]. *IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium. July 16-21, 2023, Pasadena, CA, USA. IEEE*, 2023: 7649-7652.
- [26] LI Y, ZHANG H K, SHEN Q. Spectral - spatial classification of hyperspectral imagery with 3D convolutional neural network [J]. *Remote Sensing*, 2017, 9(1): 67.
- [27] MANNA S, CHATTOPADHYAY S, DEY R, *et al.* Dynamically scaled temperature in self-supervised contrastive learning [J]. *IEEE Transactions on Artificial Intelligence*, 2025, 6(6): 1502-1512.

作者简介:



刘城洋(1995—),男,黑龙江人,博士研究生,2022年于哈尔滨理工大学获得硕士学位,主要从事深度学习、高光谱遥感图像处理方面的研究。E-mail:2210603084@stu.hrbust.edu.cn

通讯作者:



王爱丽(1979—),女,天津人,博士,教授,硕士生导师,2002年、2004年、2008年于哈尔滨工业大学分别获得学士、硕士和博士学位,主要研究方向为遥感图像处理。E-mail:ailli925@hrbust.edu.cn