

中图法分类号: 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-15

论文引用格式: Ma Shuai, He Jinrong. Hyperspectral open-set recognition guided by frequency domain knowledge[J/OL]. Journal of Image and Graphics, XXXX: 1-15. DOI: 10.11834/jig.260254. (马帅, 何进荣. 频域知识引导的高光谱图像开集识别方法[J/OL]. 中国图象图形学报, XXXX: 1-15. DOI: 10.11834/jig.260254.) [DOI: 10.11834/jig.260254]

频域知识引导的高光谱图像开集识别方法

马帅, 何进荣

延安大学数学与计算机科学学院, 延安 716000

摘要: 目的 针对高光谱图像开集识别中存在的异物同谱现象, 以及传统深度模型基于闭集假设对未知类产生过度自信误判的问题, 提出一种频域知识引导的高光谱开集识别方法(frequency knowledge-guided contrastive learning, FKCL)。方法 本文提出一种数据驱动与物理知识协同的双分支网络架构。其中, 特征分支利用3D-2D混合卷积网络提取深层空谱语义特征。频域分支利用实值快速傅里叶变换提取地物中心光谱的频域物理属性, 并通过指数移动平均在线更新各类别的频域原型。在此基础上, 该方法引入基于类锚点聚类损失的双重距离决策机制, 从而在特征度量空间与频域物理空间中为已知类构建准确的判别边界。结果 在WHU-Hi-LongKou、Pavia University和Salinas三个公开高光谱数据集上, 采用类别留出协议构造伪未知类, 对FKCL方法进行开集识别评估。实验结果表明, FKCL在保持已知类分类性能的同时能够提升对伪未知类的拒识能力。其中, 在Pavia University数据集上, 模型总体准确率(overall accuracy, OA)达到92.02%, 未知类识别准确率为100.00%。同时, 不同数据集上的性能提升存在差异, Salinas中多个未知类与已知类光谱高度相似, 未知类拒识仍更具挑战性。结论 本文方法通过引入频域物理先验知识作为特征距离度量的补充, 缓解了传统深度学习模型对伪未知类样本过度自信的问题。在类别留出构造的伪未知评测协议下, FKCL提升了模型对训练阶段未见地物类别的鉴别与拒识能力。

关键词: 高光谱图像; 开集识别; 频域引导; 类锚点聚类; 空谱融合; 双分支架构

Hyperspectral open-set recognition guided by frequency domain knowledge

Ma Shuai, He Jinrong

School of Mathematics and Computer Science, Yan'an University, Yan'an, 716000, China

Abstract: **Objective** Hyperspectral image (HSI) classification is an important task in remote sensing image interpretation because HSI data contain continuous spectral responses that are useful for fine-grained land-cover recognition. Existing deep learning methods, especially convolutional neural networks (CNNs), have achieved high classification accuracy under the closed-set assumption. However, this assumption requires that all test classes have been observed during training, which is often inconsistent with real remote sensing applications. In large-scale and dynamic scenes, a trained model may encounter undefined or newly emerging land-cover categories. Conventional closed-set classifiers usually force such unknown samples into one of the known classes and may produce overconfident predictions. In addition, HSI data are affected by illumination variation, atmospheric scattering, sensor noise, and mixed pixels, resulting in the phenomena of same material with different spectra and different materials with similar spectra. These factors make hyperspectral open-set recognition (OSR) more challenging than ordinary closed-set classification. To address these problems, this paper pro-

收稿日期: 2026-05-07; 修回日期: 2026-06-30

基金项目: 国家自然科学基金(项目编号: 62366053); 延安大学研究生实践创新计划项目(项目编号: YSJ2026018)

Supported by: National Natural Science Foundation of China (Grant No. 62366053); Yan'an University Graduate Practice Innovation Program (Grant No. YSJ2026018)

poses a frequency knowledge-guided contrastive learning method, called FKCL, for hyperspectral open-set recognition. The main purpose is to improve the rejection ability for unknown land-cover classes while maintaining reliable classification performance for known classes. **Method** The proposed FKCL framework integrates data-driven spatial-spectral representation learning with frequency-domain physical prior knowledge. The whole network consists of two collaborative branches. The first branch is a spatial-spectral feature extraction branch based on a 3D-2D hybrid convolutional neural network. It uses 3D convolution to capture local spectral correlations and then uses 2D convolution to extract spatial contextual information from hyperspectral image patches. The extracted high-level representation is projected into a compact feature space, where class-wise metric learning is performed. The second branch is a frequency-domain physical attribute extraction branch. Instead of using the average spectrum of the whole patch, this branch uses the central pixel spectrum because the category label of a hyperspectral patch usually corresponds to the central pixel. The central spectral sequence is transformed into the frequency domain by real fast Fourier transform (RFFT), and its magnitude spectrum is used to describe the frequency fluctuation pattern of the ground object. This design preserves the correspondence between the original spectral reflectance curve and its physical frequency representation, and avoids the interference caused by heterogeneous neighboring pixels. To obtain stable class-level frequency representations, an exponential moving average (EMA) mechanism is introduced to update the frequency prototype of each known class during training. The EMA update reduces prototype fluctuation caused by small-batch sampling and gradually accumulates the stable frequency pattern of each known category. For feature-space discrimination, the class anchor clustering (CAC) loss is adopted. The anchor loss pulls samples toward their corresponding class anchors, whereas the tuplet loss pushes samples away from non-corresponding anchors, thereby improving intra-class compactness and inter-class separability. During inference, FKCL uses a dual-distance decision strategy. The semantic feature distance and the frequency-domain prototype distance are fused by a frequency weight selected on the validation set, and the open-set rejection threshold is also determined on the validation set. The test set is used only for final evaluation, so no test information is involved in threshold selection. **Result** Experiments were conducted on three public HSI benchmark datasets, namely WHU-Hi-LongKou, Pavia University, and Salinas. A class-holdout protocol was adopted to construct pseudo-unknown classes. In this protocol, selected categories are completely removed from training and appear only during validation and testing for unknown rejection evaluation. For WHU-Hi-LongKou, the Mixed weed class was held out as the pseudo-unknown class. For Pavia University, the Shadows class was held out. For Salinas, Stubble, Lettuce_roumaine_6wk, Lettuce_roumaine_7wk, Vinyard_untrained, and Vinyard_vertical_trellis were treated as pseudo-unknown classes. The proposed FKCL method was compared with six representative closed-set and open-set methods, including DBDA, SSFTT, CACL, SSMTL, HyperCASR, and SS-MTr. The evaluation metrics included overall accuracy (OA), average accuracy (AA), Kappa coefficient, area under the receiver operating characteristic curve (AUROC), and unknown class accuracy. Experimental results show that FKCL achieves a better balance between known-class classification and unknown-class rejection. On WHU-Hi-LongKou, FKCL achieved an OA of 92.38%, an AA of 92.58%, and a Kappa coefficient of 90.08%, while its unknown class accuracy reached 25.20%, which was higher than most deep closed-set comparison models. On Pavia University, FKCL achieved an OA of 92.02%, an AA of 89.13%, a Kappa coefficient of 89.48%, an AUROC of 99.96%, and an unknown class accuracy of 100.00%, indicating that the frequency-guided dual-distance strategy can effectively identify the held-out Shadows class. On Salinas, the proposed method maintained high classification performance for known classes, but the rejection of pseudo-unknown samples remained more difficult because several unknown classes had very high spectral similarity to known classes. This result indicates that the open-set difficulty is closely related to the physical and spectral separability between known and unknown categories. The ablation analysis further shows that the frequency-domain branch, frequency prototype learning, and dual-distance decision mechanism contribute to the improvement of open-set detection performance. In particular, removing the frequency prototype EMA weakens unknown rejection, demonstrating that stable frequency prototypes are important for modeling class-level physical attributes. **Conclusion** The proposed FKCL method introduces frequency-domain knowledge into hyperspectral open-set recognition and constructs a collaborative framework that combines deep spatial-spectral features with physical spectral priors. Compared with single-branch data-driven models, FKCL uses RFFT-based frequency representations and EMA-updated frequency prototypes to provide complementary information for distinguishing spectrally similar but physically different

land-cover categories. The CAC-based metric learning module constructs a compact and separable feature space for known classes, and the dual-distance decision strategy further improves the ability to reject samples outside the known-class distribution. Under the class-holdout pseudo-unknown evaluation protocol, FKCL reduces the overconfidence problem of conventional deep models and improves the discrimination of unseen categories. Nevertheless, when unknown classes are extremely similar to known classes in both the original spectral domain and the frequency domain, open-set rejection remains challenging. Future work will focus on adaptive frequency-weight learning, more realistic open-world remote sensing scenarios, cross-region generalization, dynamic newly emerging categories, and open-set recognition with multimodal remote sensing data.

Key words: hyperspectral image; open-set recognition; frequency domain guidance; class anchor clustering; spatial-spectral fusion; dual-branch architecture

论文引用格式: Ma Shuai, He Jinrong. Hyperspectral open-set recognition guided by frequency domain knowledge [J/OL]. Journal of Image and Graphics, XXXX:1-16. DOI:10. 11834/jig. 260254. (马帅,何进荣. 频域知识引导的高光谱图像开集识别方法[J/OL]. 中国图象图形学报, XXXX:1-16. DOI: 10. 11834/jig. 260254.)【DOI: 10. 11834/jig. 260254】

0 引言

遥感高光谱成像技术能够捕获可见光至红外波段的连续地物光谱信息,在复杂场景下能够辅助地物精细识别(Tong 等,2014)。高光谱图像分类是遥感数据领域的核心任务,在资源勘探、精准农业和地学监测等领域具有重要作用(何明一 等,2025)。早期高光谱图像分类研究主要聚焦于人工特征提取与统计分类相结合的方法,例如利用主成分分析(principal component analysis, PCA)对光谱数据降维后,结合 K 近邻(Song 等,2016)或支持向量机(Okwuashi 和 Ndehedehe, 2020)进行分类。然而,受限于浅层模型的表征能力,此类方法在处理高维非线性的高光谱数据时,难以挖掘数据的深层语义信息,且易受传感器噪声干扰。

近年来,以卷积神经网络(convolutional neural network, CNN)为代表的深度学习方法推动了高光谱图像分类的发展,特别是空谱特征的联合提取显著提升了模型性能(叶珍 等,2021)。Chen 等人(2014)利用深度架构提取光谱的层次特征。针对高光谱数据常面临的样本稀缺难题,吴鸿昊等人(2021)探讨了基于卷积神经网络的小样本分类策略。为兼顾空间上下文与光谱序列信息,He 等人

(2017)提出多尺度 3D-CNN,同时何进荣等人(2021)利用 3D 卷积自编码器提取高阶稠密特征,均有效提升了空谱特征的协同表达能力。针对 3D 卷积计算开销较大的问题, Roy 等人(2020)设计了 HybridSN 模型,通过混合 2D 与 3D 卷积提取空谱特征,实现了提取效率与分类精度的平衡。受视觉 Transformer(vision Transformer, ViT)启发, Hong 等人(2022)提出 SpectralFormer,利用自注意力机制捕获光谱维度的长程依赖关系。尽管这些模型在标准数据集上取得了较高的分类精度,但大多遵循“闭集”假设,即假设测试样本所属类别在训练阶段完全已知(Scheirer 等,2013)。在实际遥感任务中,受覆盖范围广、地物分布动态变化等因素影响,模型常面临训练集未定义的“未知类”地物。传统闭集分类器会将未知类强制映射至已知类的特征空间中导致误判,限制了模型在开放环境下的识别能力。需要说明的是,现有公开高光谱数据集通常只提供有限类别的像素级标注,缺少真实开放世界中不断出现的新类别标注。因此,本文采用类别留出(class-holdout)协议构造伪未知类,即在训练阶段完全移除部分类别,仅在测试阶段将其作为未知类出现。该协议能够在可控条件下评估模型对未见类别的拒识能力,是开放集识别研究中的常用代理评测方式,但不能完全等同于真实开放遥感场景中所有可能未知地物的分布。

针对上述开集挑战,开集识别(open-set recognition, OSR)逐渐成为高光谱图像分类领域的研究重点(樊港辉 等,2022)。OSR 的核心任务是在保证已知类分类精度的同时,识别并拒绝未知类。现有研究策略主要分为判别式模型与生成式模型。判别式方法如 Bendale 等人(2016)提出的 OpenMax 算法,通过极值理论(extreme value theory, EVT)拟合已知

类的分数分布,在测试阶段对低概率样本进行拒识。为强化光谱特征空间的类间差异,孙旭豪等人(2023)与 Miller 等人(2021)分别探索了环状原型空间优化与类锚点聚类(class anchor clustering, CAC)损失,通过中心约束使已知类特征在空间中更紧凑,为未知类预留判定区域。生成式方法侧重于填补特征空间空白, Liu 等人(2021)与 Nirmal 等(2020)利用生成对抗网络(generative adversarial network, GAN)模拟未知样本分布,通过对抗学习使模型在训练阶段具备识别未知边界的能力。从特征重构角度, Yoshihashi 等人(2019)提出 CROSR 模型,通过分析样本的重构误差判定其是否属于已知类分布。

然而,现有方法在应对高光谱开集识别时仍面临诸多问题。一方面,光谱异质性导致同类地物的特征表示不稳定。受光照、大气散射及传感器量子噪声等影响,遥感场景普遍存在“同物异谱”和“异物同谱”现象,同类地物在特征空间的表现存在明显差异(马晓瑞等, 2024; Zhang 等, 2021)。现有 OSR 策略过度依赖光谱表现特征,缺乏对地物物理本质的建模,导致模型在面对光谱偏移时易产生分类波动。向数据与知识融合驱动的范式演进,已成为解决该瓶颈的重要方向(何明一等, 2025)。另一方面,基于 Softmax 的分类框架倾向于将特征映射至全空间,这种过度线性划分使得模型对远离训练中心的样本缺乏判别能力(Bendale 等, 2016)。现有的度量学习方法在缺乏物理先验引导的情况下,也难以在多维光谱特征空间中构建紧凑且鲁棒的判别空间。光谱曲线作为典型的波动信号,其在频域中的能量分布规律通常与物质的分子结构及理化性质直接相关。Song 等人(2023)指出,频域特征在描述光谱本质属性时具有尺度不变性与抗噪稳定性。当前高光谱 OSR 框架大多局限于空-谱域特征提取,未能充分挖掘频域知识在区分物理性质相近的“已知”与“未知”地物方面的潜力。

针对上述不足,本文提出的 FKCL 框架采用双分支协同架构,将空谱特征学习与物理知识引导相结合,实现高光谱图像的开集识别。该方法基于类锚点度量学习框架,设计双分支知识协同架构:其中一个分支利用深度空谱卷积网络捕获判别性的空-谱语义特征;另一分支通过实值快速傅里叶变换(real fast fourier transform, RFFT)引入频域物理先验,并利用指数移动平均(exponential moving aver-

age, EMA)构建稳定的频域原型。通过特征距离与频域距离的协同决策机制,FKCL 能够在多维空间中为已知类设定严格的判别边界,缓解现有模型在开集环境下的“过度自信”问题。本文的主要贡献总结如下:

1) 构建了双分支知识与数据驱动协同的 OSR 架构。该架构将空谱特征提取器获取的深层语义信息与 RFFT 提取的物理频率模式相结合,通过多维信息互补识别因光谱异质性产生的变异样本,弥补了单一数据驱动模型在复杂场景下鲁棒性不足的问题。

2) 设计了基于 EMA 更新的频域原型学习机制。该机制通过在线学习获取各类地物在频域中的能量分布,使模型在无额外监督条件下建立对已知类物理属性的理解,进而识别表现相似但物理属性差异显著的未知地物。

3) 提出了双重距离决策框架与协同拒识策略。通过类锚点度量学习强制特征分布对齐,并结合频域距离约束与加权融合策略,有效平衡了特征空间与物理空间的判别鲁棒性。

1 频域知识引导的高光谱图像开集识别方法

1.1 基本思路和整体分析

本文提出的 FKCL 框架采用双分支协同的架构,将空谱特征学习与物理知识引导相结合,实现高光谱图像的开集识别。如图 1 所示,该框架包含两个核心分支:

特征分支基于深度卷积神经网络,从高光谱图像块中提取判别性的空间-光谱联合特征表示。频域分支基于物理先验知识,利用快速傅里叶变换提取频域特征,并学习类级别的频域原型。两个分支通过双距离决策机制进行融合,同时保证已知类别的分类精度和未知类别的有效检测。

1.2 问题定义

给定高光谱图像数据立方体 $X \in \mathbb{R}^{H \times W \times B}$, 其中 H 和 W 分别表示高光谱图像的空间高度和宽度, B 表示光谱波段数量。对于图像中位置 (i, j) 的像素,其对应的光谱特征为 $x_{i,j} \in \mathbb{R}^B$, 是一个 B 维向量,表示该像素在所有波段上的光谱反射值。

设已知类别集合为 $Y_k = \{1, 2, \dots, K\}$, 其中 K




图1 FKCL方法双分支协同网络架构

Fig. 1 Dual-branch collaborative network architecture of the FKCL method

为已知类别总数,未知类别集合为 $Y_u = \{K+1, K+2, \dots\}$, 且满足 $Y_k \cap Y_u = \emptyset$ 。训练集仅包含已知类别的样本 $D_{tr} = \{(x_i, y_i) | y_i \in Y_k\}$, 而测试集可能包含来自未知类别的样本, 即 $y_i \in Y_k \cup Y_u$ 。

开集识别的目标是学习一个分类器 $f: X \rightarrow Y_k \cup \{\text{unknown}\}$, 使得对于已知类样本 ($y \in Y_k$), 准确预测其类别标签, 对于未知类样本

($y \in Y_u$), 正确识别为未知。

对于分类任务, 以每个标记像素 (i, j) 为中心提取空间邻域块 $p \in \mathbb{R}^{B \times S \times S}$, 式中, S 为空间块大小。本文默认设置 $S = 13$, 即提取 13×13 的空间邻域。该局部块以中心像素为分类对象, 同时保留其邻域空间上下文信息, 其中 $p[b, s_1, s_2]$ 表示第 b 个波段、空间位置 (s_1, s_2) 处的像素值。




图2 空谱特征提取分支网络结构

Fig. 2 Network structure of the spatial-spectral feature extraction branch

1.3 空间-光谱特征编码

特征分支采用3D-2D混合卷积架构, 如图2所示, 分三个阶段逐步提取从低层到高层的判别性特征。设输入图像块为 $p \in \mathbb{R}^{B \times S \times S}$, 式中, B 为波段数, S 为空间尺寸。

1) 光谱特征编码

光谱编码器采用3D卷积网络, 沿光谱维度捕获波段间的相关性。输入图像块 p 首先被重塑为 $p' \in \mathbb{R}^{1 \times B \times S \times S}$ 。

第一层卷积使用核大小为 $(7, 1, 1)$ 的3D卷积, 沿光谱维度进行降采样, 输出通道数为28。步长 $(2, 1, 1)$ 将光谱维度从 B 降采样至约 $B/2$, 而空间维度保持不变。添加残差块保持光谱维度不变, 增强特征表达能力, 其中 $\text{padding}(3, 0, 0)$ 保证光谱维度的尺寸不变。

添加残差块进一步提取光谱特征, 然后沿光谱维度进行全局平均池化, 消除光谱维度。输出的形状为 $[28, 13, 13]$, 包含28个通道的空间特征图。

2) 空间特征编码

空间编码器采用2D卷积网络,捕获空间域的上文信息和纹理模式。第一层空间卷积核大小为 3×3 ,padding为1,保持空间尺寸不变。添加两个残差块,通过残差连接,缓解梯度消失问题,使网络能

够学习更深层次的特征表示。

最终进行特征聚合与投影,通过全局平均池化将空间维度 $S \times S$ 压缩为1,然后通过全连接层投影到特征空间,最终得到的特征向量 z 用于后续类锚点欧氏距离计算。网络架构细节如表1。

表1 空谱特征提取分支网络架构

Table 1 Network architecture of the spatial-spectral feature extraction branch

组件	配置参数	输出维度
输入层	高光谱图像块	[B, 13, 13]
光谱编码器	3D卷积, Kernel (7,1,1), 通道28, 步长(2,1,1)	[28, B', 13, 13]
光谱残差块1	3D卷积, 核(7,1,1), 通道28, padding(3,0,0)	[28, B', 13, 13]
光谱残差块2	3D卷积, 核(7,1,1), 通道28, padding(3,0,0)	[28, B', 13, 13]
光谱池化	沿光谱维度平均池化	[28, 13, 13]
空间卷积	2D卷积, 核 3×3 , 通道28, padding=1	[28, 13, 13]
空间残差块1	2D卷积, 核 3×3 , 通道28, padding=1	[28, 13, 13]
空间残差块2	2D卷积, 核 3×3 , 通道28, padding=1	[28, 13, 13]
全局池化	自适应平均池化至 1×1	[28]
投影层	全连接层, 输出维度128	[128]

注: (B') 表示经过3D光谱卷积后得到的光谱维度。

1.4 频域物理属性提取分支

本文频域分支采用中心像素光谱而非patch平均光谱。原因在于高光谱分类标签通常对应中心像素地物类别,中心像素光谱能够更直接反映该类别的原始物理响应;patch平均光谱容易受到邻域异质像素影响,尤其在地物边界处可能产生混合光谱;主成分光谱和卷积后特征谱虽然具有降维或判别优势,但会削弱频域特征与原始物理反射曲线之间的对应关系。因此,本文对中心像素的一维光谱序列进行RFFT,以构建具有物理解释性的频域原型。高光谱图像中,不同地物类别具有独特的光谱反射特性,这些特性在频域中表现为特定的频率模式。高频成分光谱曲线的快速变化部分,反映了地物的表面纹理和微观结构差异,低频成分反映了地物的基本光谱特征和吸收特性,频域表示对于光谱曲线形状相似但变化模式不同的地物类别来说,能够提供空间-光谱卷积特征难以捕捉的互补信息。

(1) 频域特征提取

对于输入图像块($p \in \mathbb{R}^{B \times S \times S}$),提取中心像素位置($(S/2, S/2)$)的目标光谱 $s \in \mathbb{R}^B$:

$$s_b = p[b, S/2, S/2], \quad b = 1, 2, \dots, B \quad (1)$$

应用实值快速傅里叶变换(real fast Fourier transform, RFFT):

$$F = \text{RFFT}(s; \text{norm} = \text{ortho}) \in \mathbb{C}^{M+1} \quad (2)$$

式中, F 为复数向量, M 为 $\lfloor B/2 \rfloor$, norm=ortho表示正交归一化,确保能量守恒 $\|F\|_2^2 = \|s\|_2^2$,取模得到幅度谱:

$$g = |F| = [|F_1|, |F_2|, \dots, |F_{B/2+1}|]^T \in \mathbb{R}^{M+1} \quad (3)$$

式中, $|F_j| = \sqrt{\text{Re}(F_j)^2 + \text{Im}(F_j)^2}$ 表示第 j 个频率分量的幅度。

(2) 频域原型学习机制

为每个已知类别 $k \in \{1, 2, \dots, K\}$, K 为已知类别总数,维护一个频域原型 $q_k \in \mathbb{R}^{B/2+1}$,通过指数移动平均在线更新,对于首次遇到的类别 k ,直接使用该类样本的平均频域特征初始化:

$$q_k^{(0)} = \frac{1}{|C_k|} \sum_{i \in C_k} g_i \quad (4)$$

式中, $C_k = \{i | y_i = k\}$ 表示当前批次中属于类别 k 的样本集合, $|C_k|$ 表示该集合的样本数。

在训练过程中,每个批次结束后通过EMA更新原型:

$$q_k^{(t+1)} = \alpha \cdot q_k^{(t)} + (1 - \alpha) \cdot \frac{1}{|C_k|} \sum_{i \in C_k} g_i \quad (5)$$

式中, $\alpha = 0.9$ 为动量系数, $q_k^{(t)}$ 表示第 t 次更新后的原型。EMA 更新可视为对历史频域原型与当前批次类别均值的加权平均。本文采用 EMA 的目的在于抑制小批量采样带来的原型波动, 使频域原型逐步逼近类别稳定频率模式。动量系数 α 理论上可设计为可学习参数, 但在小样本开放集设置中, 可学习动量会引入额外自由度并可能导致训练不稳定。为保证方法简洁性和可复现性, 本文固定 $\alpha = 0.9$ 。

(3) 频域距离计算

给定频域特征 $g \in \mathbb{R}^{B/2+1}$ 和原型集合 $\{q_k\}_{k=1}^K$, 每个 $q_k \in \mathbb{R}^{B/2+1}$, 计算到类别 k 的欧氏距离:

$$d_k^t(g) = \|g - q_k\|_2 \quad (6)$$

式中, g_j 为 g 的第 j 个分量, $q_{k,j}$ 为原型 q_k 的第 j 个分量。最终得到频域距离向量。

$$d^t = [d_1^t, d_2^t, \dots, d_K^t]^T \in \mathbb{R}^K \quad (7)$$

对于尚未初始化的类别, 设置默认距离为 10.0。

1.5 类锚点学习与特征距离度量

传统 softmax 分类使用线性分类头, 但对于开集识别存在局限, 难以确定区分已知类和未知类的阈值, 未显式建模类内紧凑性和类间分离度, 对特征分布的假设较强, 类锚点方法将每个类别表示为特征空间中的一个锚点, 通过距离度量进行分类。

(1) 锚点初始化与更新

为每个已知类别 $k \in \{1, \dots, K\}$ 定义一个锚点向量 $a_k \in \mathbb{R}^d$, 特征维度 $d = 128$, 使用 Xavier 均匀初始化:

$$a_{k,j} \sim \mathcal{U}\left(-\sqrt{\frac{6}{d+d}}, \sqrt{\frac{6}{d+d}}\right) \quad (8)$$

式中, $a_{k,j}$ 为锚点 a_k 的第 j 个分量, $\mathcal{U}(a, b)$ 表示区间 $[a, b]$ 上的均匀分布。与频域原型类似, 通过 EMA 更新锚点:

$$a_k^{(t+1)} = \alpha \cdot a_k^{(t)} + (1 - \alpha) \cdot \frac{1}{|C_k|} \sum_{i \in C_k} z_i \quad (9)$$

式中, $\alpha = 0.9$ 为动量系数, z_i 为样本 i 的特征向量, C_k 为当前批次中类别 k 的样本集合。

本文采用特征向量与类别锚点之间的距离度量样本归属关系。

$$d_s^k(z) = \|z - a_k\|_2 \quad (10)$$

1.6 类锚点聚类损失 (CAC Loss)

如图 3 所示, 类锚点聚类损失旨在实现两个目标: 同类样本在特征空间中聚集在其锚点周围。不同类别的样本被推离其他类别的锚点。不同颜色和形状表示不同已知类别样本, 星形符号表示类别锚点, 灰色叉号表示未知类。




图 3 类锚点聚类与度量机制示意图

Fig. 3 Schematic diagram of class anchor clustering and metric mechanism

(1) 锚点损失 (Anchor Loss)

将样本拉向对应类别的锚点:

$$L_a = \frac{1}{K} \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i \in C_k} d_k^s(z_i) \quad (11)$$

式中, K 为已知类别总数, C_k 为当前批次中属于类别 k 的样本索引集合, $|C_k|$ 为类别 k 的样本数, $d_k^s(z_i)$ 为样本 i 到类别 k 锚点的特征距离, 最小化同类样本到其锚点的平均距离, 促进类内紧凑性。

(2) 三元组损失 (Triplet Loss)

将样本推离其他类别的锚点, 带有间隔 m :

$$L_t = \frac{1}{K} \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i \in C_k} \max(0, m - \min_{j \neq k} d_j^s(z_i)) \quad (12)$$

式中, $m = 3.0$ 为间隔参数 (margin), 控制期望的类间分离程度 $\min_{j \neq k} d_j^s(z_i)$ 表示样本 i 到最近的负类锚点的距离, $\max(0, \cdot)$ 为 ReLU 函数, 确保非负损失。

间隔参数 m 控制当样本与最近的负类锚点距离大于 m 时, 损失为 0, 此时说明样本已充分分离, 无需优化, 当距离小于 m 时, 产生正损失, 推动样本远离负类锚点, 避免过度分离导致的优化困难。因此, 类锚点聚类损失的总形式为:

$$L = L_a + \lambda \cdot L_t \quad (13)$$

L_a 用于约束同类样本向对应类别锚点聚合, L_t 用于增强样本到非对应锚点之间的间隔, 式中, $\lambda =$

0.1 为损失平衡系数。这种加权组合主要优化目标为类内紧凑性和类间分离性。需要说明的是,频域原型通过 EMA 机制更新,并在推理阶段参与融合距离计算,不作为额外反向传播损失项。

1.7 双距离决策机制

单一的距离度量可能存在局限,仅依赖特征距离,可能忽略频域中的判别信息,仅依赖频域距离,对空间上下文信息利用不足。双距离决策机制融合两种互补信息,提升开集识别的鲁棒性。对样本 x ,其到第 k 类的特征距离和频域距离分别为 $d_k^s(x)$ 和 $d_k^f(x)$ 。二者分别刻画样本在深层语义特征空间和频域物理空间中与已知类原型的接近程度。由于特征距离和频域距离分别来自深层语义特征空间与频域物理空间,二者数值尺度和分布范围不同。为减少两类距离尺度差异对融合结果的影响,本文在验证集上对频域权重和拒识阈值进行联合选择。测试阶段固定使用验证集选定的频域权重和阈值,不再利用测试集信息。为了融合两类互补信息,本文定义融合距离为

$$d_k^c(x) = (1 - \omega)d_k^s(x) + \omega d_k^f(x) \quad (14)$$

式中, $\omega \in [0, 1]$ 为频域距离权重。当 $\omega = 0$ 时,模型仅依赖特征距离;当 $\omega > 0$ 时,频域原型距离参与开集判别。本文在验证集上从候选集合中选择 ω ,测试集仅用于最终性能评估。

1.8 开集决策策略

(1) 分类决策

对于被判定为已知类的样本,基于特征距离进行分类:

$$\hat{y} = \arg \min_k d_k^s \quad (15)$$

选择特征距离最近的类别作为预测标签,式中, $\hat{y} \in \{1, 2, \dots, K\}$ 。

(2) 开集检测决策

通过融合距离判断样本是否属于未知类:

$$d_{\min}^c = \min_k d_k^c \quad (16)$$

$$I(x) = \begin{cases} 1 & d_{\min}^c \leq \tau \\ 0 & d_{\min}^c > \tau \end{cases} \quad (17)$$

式中, τ 为预定义的阈值, $I(\cdot)$ 为指示函数。

本文在验证集上选择拒识阈值 τ , 候选阈值集合为 $\{0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0, 1.2, 1.4\}$ 。阈值选择准则是在保持已知类分类性能的同时提高未知类拒识能力。测试集仅用于最终性能报告,不参与阈值选择。

最终预测规则为:

$$\hat{y} = \begin{cases} \arg \min_k d_k^s(x), & d_{\min}^c \leq \tau \\ -1, & d_{\min}^c > \tau \end{cases} \quad (18)$$

式中, $\hat{y} = -1$ 表示样本被判定为未知类。

2 实验

2.1 数据集

本文使用 WHU-Hi-LongKou、Pavia University 和 Salinas 三个公开高光谱数据集评估 FKCL 方法。三个数据集来自农田、城市和农业场景,能够从不同空间结构和光谱分布条件下验证模型的开集识别能力。




图4 WHU-Hi-LongKou 数据集概览。默认 open-set 协议中,第9类 Mixed weed 被留出作为 pseudo-unknown。

Fig. 4 Overview of WHU-Hi-LongKou dataset. In the default open-set protocol, class 9 Mixed weed is held out as pseudo-unknown ((a) False-color image; (b) Ground-truth map; (c) Class legend)

WHU-Hi-LongKou (LK) 数据集由 WHU 高光谱成像系统采集,空间分辨率为 0.463 m,包含 270 个光谱波段,图像尺寸为 550×400,共包含 9 个地物类别。本文默认将第 9 类 Mixed weed 作为伪未知类,其余 8 类作为已知类参与训练和测试。

Pavia University (UP) 数据集由 ROSIS 传感器采集,空间分辨率为 1.3 m,包含 103 个有效光谱波段,图像尺寸为 610×340,共包含 9 个地物类别。本文在默认 open-set 协议中将第 9 类 Shadows 作为伪未知类,在训练阶段不使用该类样本,仅在测试阶段用于未知类拒识评估,默认类别留出方案如表 2 所示。

Salinas (SA) 数据集由 AVIRIS 传感器采集,空间分辨率为 3.7 m,包含 204 个有效光谱波段,图像





图 5 Pavia University 数据集概览。默认 open-set 协议中, 第 9 类 Shadows 被留出作为 pseudo-unknown。

Fig. 5 Overview of Pavia University dataset. In the default open-set protocol, class 9 Shadows is held out as pseudo-unknown ((a) False-color image; (b) Ground-truth map; (c) Class legend)

图 6 Salinas 数据集概览。默认 open-set 协议中, 第 6、13、14、15、16 类被留出作为 pseudo-unknown。

Fig. 6 Overview of Salinas dataset. In the default open-set protocol, classes 6, 13, 14, 15, and 16 are held out as pseudo-unknown ((a) False-color image; (b) Ground-truth map; (c) Class legend)



尺寸为 512×217 , 共包含 16 个地物类别。本文默认 open-set 协议中, 将第 6、13、14、15、16 类作为伪未知类, 其余类别作为已知类。

表 2 给出了三个数据集的默认 open-set 类别留出方案。其中, 伪未知类在训练阶段完全不可见, 仅在验证阶段用于拒识阈值选择, 并在测试阶段用于评估模型的未知类拒识能力。

2.2 实验设置

在模型训练过程中, 采用 AdamW 作为优化器, 动量参数设置为 $\beta_1 = 0.9$ 和 $\beta_2 = 0.999$, L2 正则化

表 2 三个数据集的默认开放集类别留出方案

Table 2 Default open-set class-holdout splits of three datasets

数据集	已知类	伪未知类
UP	1-8	9 Shadows
LK	1-8	9 Mixed weed 6 Stubble; 13 Lettuce_romaine_6wk; 14 Lettuce_romaine_7wk; 15 Vinyard_untrained; 16 Vinyard_vertical_trellis
SA	1-5, 7-12	

系数 λ_w 设为 10^{-4} 。模型完整训练 250 轮, 每个训练批次的样本数 B 设为 64。初始学习率 η 设定为 10^{-3} , 并配合余弦退火学习率调度策略。

在特征提取与表示方面, 提取的图像块空间尺寸 S 为 13, 特征向量维度 d 为 128。针对模型的损失函数与动态更新机制, Anchor 与 Tuple 损失的平衡系数 λ 设为 0.1, 三元组损失的 CAC 间隔参数 m 默认设为 3.0。同时, 用于锚点和原型更新的 EMA 动量系数设定为 0.9。温度缩放初始值 $T^{(0)}$ 被设定为 1.0。

2.3 对比实验

本文采用总体准确率 (OA)、平均准确率 (AA)、Kappa 一致性系数、开集检测 ROC 曲线下面积 (AUROC)。为了验证本文实验方法的有效性, 本文使用 6 种经典的对比方法在三个不同的数据集上进行了验证, 分别是 CACL、DBDA、SSFTT、SSMTL、HyperCASR、SS-MTr。在数据划分方面, 本文采用类别留出协议构造伪未知类。对于已知类, 每类随机选取 20 个标注样本作为训练集, 剩余已知类样本划分为验证集和测试集, 用于阈值选择与最终分类性能评估。对于伪未知类, 其样本在训练阶段完全不可见, 仅在验证和测试阶段用于开集拒识阈值选择与未知类检测评估。所有数据划分均采用多个固定的随机种子确保实验的可重复性。表中表示去除伪未知类后重新编号的已知类, 并不对应原始数据集的类别编号。

最终的模型结果如图 7-9 和表 3-5 所示, 在 WHU-Hi-LongKou 数据集中, SSFTT 和 DBDA 等传统闭集分类方法虽然在已知类上取得了较高的总体准确率 (OA), 但对未知类 (Unknown) 的识别率较低, 其中 SSFTT 的未知类准确率仅为 4.21%。这表




图7 不同方法在 WHU-Hi-LongKou 数据集上的分类结果对比

Fig. 7 Comparison of classification results by different methods on WHU-Hi-LongKou dataset ((a)GT; (b)DBDA; (c)CACL; (d)SSFTT; (e)SS-MTr; (f)SSMTL; (g)HyperCASR; (h)FKCL)




图8 不同方法在 Pavia University 数据集上的分类结果对比
Fig. 8 Comparison of classification results by different methods on Pavia University dataset ((a)GT; (b)DBDA; (c)CACL; (d)SSFTT; (e)SS-MTr; (f)SSMTL; (g)HyperCASR; (h)FKCL)

明传统模型在开集环境下存在明显的过度自信问题,倾向于将未知地物误划分为已知类。相比之下,本文方法在保持 92.38% 总体准确率的基础上,显著提升了对未知类的拒识能力,准确率达到 25.20%。上述优势在 Pavia University 数据集中表

现更为显著。在该数据集中,FKCL 方法的 OA 为 92.02%,未知类准确率达到 100.00%,整体开集检测 AUROC 为 99.96%。与之相比,表现最优的基线模型 DBDA 在该数据集上的未知类准确率仅为 0.05%。在更具挑战性的 Salinas 数据集中,FKCL 仍实现了 98.77% 的高 OA,且未知类准确率为 18.39%,性能显著优于 SSFTT(1.23%)等对比方法。实验结果表明,通过引入频域先验知识,本文的双分支架构能够有效构建紧凑的已知类特征空间边界,从而在保证已知类分类精度的前提下,增强了模型对未知地物的鉴别能力。

2.4 困难未知类分析

为进一步解释本文方法在不同数据集上的性能差异,并分析模型面对困难未知类时的表现,本文计算各伪未知类与所有已知类平均光谱之间的余弦相似度,并选取光谱最接近的 known-unknown 类别对作为 hardest unknown cases。表 6 给出了三个数据集中的困难未知类对及其频域相似性结果。

由表 6 可见, Pavia University 中伪未知类 Shadows 与最接近已知类 Asphalt 的平均光谱余弦相似度为 0.9159,相对低于其他数据集中的困难类别对,因此在类别留出协议下未知类边界较清晰,频域原型能够有效辅助拒识。相比之下, LongKou 中 Mixed weed 与 Rice 的光谱余弦相似度达到 0.9995, Salinas 中多个伪未知类与已知农业类别也高度相似,尤其 Vinyard_untrained 与 Grapes_untrained 的平均光谱几乎重合,光谱余弦相似度达到 0.9997。这说明 Salinas 中未知类拒识更接近困难开放集场景,未知类与已知类之间存在严重的异物同谱和作物生长期相近问题。因此,本文方法在 Pavia University 上提升更明显,而在 Salinas 上未知类拒识提升相对有限。

为验证 FKCL 模型各核心组件的有效性,本文在三个数据集上分别进行消融实验。如表 7 所示,以 PaviaU 数据集为例,仅采用基线与三元组损失时,模型 OA 为 57.07%。加入基于 EMA 更新的频域知识分支后,OA 提升至 90.01%;在进一步结合类锚点约束与双距离决策机制后,完整模型 OA 达到 92.02%。这表明频域知识分支能够增强开集判别能力,而完整模型的最优性能来自频域原型、类锚点聚类 and 融合决策的协同作用。实验结果表明,频域特征蕴含的高频纹理与低频光谱趋势等物理规

表 3 不同方法在 WHU-Hi-LongKou 数据集上的分类性能对比
Table 3 Classification performance comparison of different methods on the WHU-Hi-LongKou dataset

指标	CACL	DBDA	SSFTT	SSMTL	HyperCASR	SS-MTr	FKCL
Class 1	95.40±3.66	99.34 0.98	95.87±2.57	74.62±3.98	66.46±37.58	90.92±4.75	98.93±0.49
Class 2	93.49±3.64	79.64±19.76	99.10 0.60	32.31±5.97	70.24±34.64	88.86±2.80	98.20±1.49
Class 3	97.07 1.31	91.51±14.70	96.91±1.73	82.15±4.54	92.10±13.69	72.62±11.42	93.59±1.10
Class 4	71.15±13.23	83.41±3.80	94.88 1.84	52.37±2.67	82.82±14.35	48.46±18.96	80.86±2.74
Class 5	93.03±13.04	63.34±31.83	79.25±23.34	71.96±3.34	54.51±45.56	77.91±11.62	97.21 1.26
Class 6	90.14±5.62	95.09±4.43	96.46 3.40	86.50±1.09	85.53±24.55	81.53±15.60	95.07±1.36
Class 7	97.23±2.27	99.83±0.24	99.89±0.16	94.00±0.68	99.89±0.15	94.98±5.20	99.98 0.01
Class 8	72.87±20.97	82.33±6.89	85.49 18.03	33.76±3.11	78.68±36.97	85.24±3.91	76.82±3.43
Unknown	30.40±10.44	10.57±2.85	4.21±1.89	78.58 6.42	0.07±0.14	0.03±0.03	25.20±5.19
OA	85.65±5.82	89.82±1.55	91.02±1.65	71.79±1.86	82.60±14.46	75.44±5.63	92.38 0.85
AA	82.31±4.79	78.34±4.01	83.56±4.92	67.36±1.50	70.03±19.34	71.17±2.42	92.58 0.76
Kappa	81.91±7.04	86.83±1.93	88.15±2.16	65.39±2.13	77.65±18.28	69.79±6.41	90.08 1.07
AUROC	86.39±2.46	90.80±1.91	91.89±2.83	0.00±0.00	79.21±14.86	47.79±5.07	88.95 1.32

注:加粗字体为每行最优值。

表 4 不同方法在 Pavia University 数据集上的分类性能对比
Table 4 Classification performance comparison of different methods on the Pavia University dataset

指标	CACL	DBDA	SSFTT	SSMTL	HyperCASR	SS-MTr	FKCL
Class 1	65.69±32.56	67.59±4.35	76.23±17.45	76.58±5.37	74.68±14.31	68.53±6.87	92.72 1.44
Class 2	64.84±17.93	90.63±8.03	92.81 8.37	91.94±2.80	88.85±8.68	63.86±8.60	92.65±5.64
Class 3	95.95 2.31	75.28±13.36	76.81±26.17	68.43±5.10	72.73±38.12	55.95±6.57	91.53±5.07
Class 4	95.68±2.40	96.28±1.01	97.93 1.08	76.05±2.94	89.33±10.12	76.74±11.90	95.54±1.70
Class 5	99.89±0.13	99.77±0.25	99.77±0.35	0.43±0.34	100.00 0.00	99.78±0.40	53.26±4.30
Class 6	78.67±12.53	75.78±13.70	79.31±21.26	80.62±2.58	89.84±17.47	77.42±8.90	93.78 1.28
Class 7	79.11±16.67	82.32±13.45	92.16±4.05	95.23±0.86	73.79±38.81	67.84±14.21	99.83 0.30
Class 8	42.63±28.09	60.51±10.93	80.10±17.95	50.60±3.04	84.72±17.03	58.63±13.36	93.75 2.28
Unknown	41.35±21.91	0.05±0.09	4.13±2.53	4.44±0.89	0.19±0.24	0.89±0.47	100.00 0.00
OA	69.42±7.98	80.39±2.65	85.37±7.56	77.67±2.35	83.58±11.20	66.10±2.90	92.02 2.45
AA	73.76±2.81	72.02±1.47	77.69±8.71	60.48±1.87	74.90±15.12	63.29±3.85	89.13 1.10
Kappa	62.75±8.51	74.26±3.12	80.65±10.20	71.10±2.84	78.78±14.47	57.67±3.36	89.48 3.09
AUROC	81.69±4.82	21.93±6.98	74.60±21.69	0.00±0.00	71.12±18.53	41.76±22.20	99.96 0.04

注:加粗字体为每行最优值。

律,能与数据驱动特征形成互补,从而有效辨别由“同物异谱”引起的表现差异与真实的类别差异。进一步结合双重距离决策机制后,模型性能达到最优,在 Salinas 数据集和 Longkou 数据集上准确率分别提

升至 98.77% 和 92.38%。这表明在多维空间中进行协同距离度量,相比单一特征空间度量,能够构建更严谨、鲁棒的判别边界

进一步去除频域原型 EMA 后,PaviaU 数据集

图9 表5不同方法在 Salinas 数据集上的分类结果对比
不同方法在 Salinas 数据集上的分类性能对比

Fig. 9 Table 5Comparison of classification results by different methods on Salinas dataset ((a)GT;(b)DBDA;(c)CACL;(d)SSFTT;(e)SS-MTr;(f)SSMTL;(g)HyperCASR;(h)FKCL)Classification performance comparison of different methods on the Salinas dataset




表5 不同方法在 Salinas 数据集上的分类性能对比

Table 5 Classification performance comparison of different methods on the Salinas dataset

指标	CACL	DBDA	SSFTT	SSMTL	HyperCASR	SS-MTr	FKCL
Class 1	98.28±1.69	99.99 0.02	99.99 0.02	93.03±1.59	99.85±0.14	78.08±24.35	99.84±0.31
Class 2	80.97±32.25	75.85±36.80	96.36±3.09	91.18±1.10	99.72±0.53	45.82±21.70	99.91 0.08
Class 3	75.82±24.05	85.82±10.26	33.41±24.52	78.33±3.80	99.66 0.42	42.36±26.34	99.11±1.69
Class 4	93.06±6.29	99.51±0.37	96.41±5.90	79.00±3.67	99.65±0.56	97.54±2.43	100.00 0.00
Class 5	94.31±2.94	96.74 2.80	79.21±38.18	74.48±1.89	96.33±4.41	89.97±3.51	93.57±3.72
Class 6	99.34±0.67	99.68±0.28	98.73±2.44	77.44±2.26	100.00 0.00	58.63±34.12	99.99±0.01
Class 7	96.70±1.23	96.34 ±1.56	96.59±0.83	77.01±1.01	98.74 1.20	91.41±5.44	98.13±0.96
Class 8	93.66±7.47	98.34±0.89	43.43±33.71	58.58±8.65	98.57±2.17	52.34±41.14	100.00 0.00
Class 9	73.07±34.20	85.05±16.42	83.74±22.41	20.21±3.35	99.59 0.45	68.39±18.09	97.74±1.71
Class 10	37.88±37.76	87.42±13.85	94.85±6.57	36.99±7.07	99.27±0.64	95.38±4.99	99.96 0.08
Class 11	61.80±35.07	100.00 0.00	76.98±36.36	89.15±2.56	98.84±2.12	62.61±33.61	100.00 0.00
Unknown	18.17±8.86	1.97±1.10	1.23±1.10	61.78 1.12	0.26±0.26	5.26±1.84	18.39±0.89
QA	68.85±6.89	68.22±2.74	59.52±7.36	68.45±1.44	71.48±0.43	53.11±9.27	98.77 0.56
AA	76.92±9.62	85.56±3.99	75.08±8.98	69.76±2.00	90.87±0.42	65.65±10.28	98.93 0.49
Kappa	63.91±8.05	64.27±3.03	54.54±8.09	61.39±1.88	67.74±0.49	45.89±11.16	98.56 0.65
AUROC	48.89±12.96	40.98±7.96	50.85±11.77	0.00±0.00	69.29±9.40	38.83±6.80	78.20 1.64

注:加粗字体为每行最优值。

的 Unknown Acc 由 100.00% 降至 48.71%, AUROC 由 99.96% 降至 92.01%; Salinas 数据集的 Unknown Acc 由 45.99% 降至 40.45%, 说明频域原型的稳定累积对未知类拒识具有重要作用。

为了验证引入频域物理先验知识在开集识别任务中的必要性, 本文对不同数据集中的“异物同谱”

样本进行了频域可视化分析。如图 10 所示, 在 Salinas、Pavia University 和 WHU-Hi-LongKou 三个数据集中, 分别选取了物理属性不同但光谱表现高度相似的已知类与未知类样本对。

由图 10 第一排可知, 受高光谱成像过程中的光照条件、大气散射以及混合像元等因素影响, 真实场

表 6 三个数据集中的困难未知类对其频域相似性

Table 6 Hardest pseudo-unknown cases and frequency-domain similarity on three datasets

数据集	伪未知类	最接近已知类	光谱余弦相似度	AC 频域余弦相似度
PaviaU	Shadows	Asphalt	0.9159	0.9513
LongKou	Mixed weed	Rice	0.9995	0.9993
Salinas	Stubble	Corn_senesced_green_weeds	0.9942	0.9959
Salinas	Lettuce_romaine_6wk	Corn_senesced_green_weeds	0.9907	0.9895
Salinas	Lettuce_romaine_7wk	Grapes_untrained	0.9968	0.9965
Salinas	Vinyard_untrained	Grapes_untrained	0.9997	0.9997
Salinas	Vinyard_vertical_trellis	Brocoli_green_weeds_2	0.9924	0.9942

表 7 FKCL 模型在三大数据集上的消融实验结果

Table7 Results of the ablation study for the FKCL model on three datasets

Method	PaviaU		Salinas		LongKou	
全量	92.02	2.45	98.77	0.56	92.38	0.85
基线+频域知识	90.01±1.14		76.34±0.67		92.32±0.74	
基线+三元组损失	57.07±16.73		71.11±1.09		82.60±1.53	

注:本表用于分析不同模块对 FKCL 性能的影响,不替代主对比实验结果。

景中常出现“异物同谱”现象。选取的已知类与未知类样本的一维光谱反射率曲线高度重合,其在光谱域的余弦相似度分别为 0.965、0.960 和 0.967。针对此类高度相似的表观特征,仅依赖数据驱动的深度空谱卷积网络难以提取有效的类间差异,易将未知地物混入已知类的特征空间,导致开集识别出现过度自信误判。

将上述一维光谱信号通过实值快速傅里叶变换(RFFT)映射至频域后(图 10 第二排),两者呈现出明显的分布差异,其幅度谱的差异度指标分别为 12.5、15.6 和 15.8。该结果表明,幅度谱中的低频分量能够反映地物材质的全局吸收与反射基态,高频分量则刻画了地物表面微观纹理与分子结构的高频振荡特征。因此,频域空间能够有效剥离表观冗余信息,反映地物的物理属性。上述可视化分析为本文提出的 FKCL 双分支协同架构提供了理论与物理依据,表明频域距离度量可作为特征距离度量的有效补充,在多维空间中为已知类别构建更为鲁棒的判别边界。

2.5 参数分析


间隔参 m 的影响。如图 11 所示类锚点聚类损

失中的间隔参数 m 用于调节特征空间中各类别锚点间的分离程度。若 m 取值过小,已知类间的判别边界可能出现重叠;若 m 取值过大,则会增加模型优化的难度。实验结果显示,当 $m = 3.0$ 时,模型在类内紧凑性与类间分离性方面达到了最优平衡。


如图 12 所示,空间邻域块大小 S 的影响。空间邻域块(Patch)的大小 S 决定了模型对空间上下文信息的提取能力。若 S 过小,受感受野限制,模型难以有效提取地物的空间纹理特征;若 S 过大,则易引入异类地物的噪声干扰,导致分类边界模糊。为分析空间邻域块大小对模型性能的影响,本文比较了 $S=7, 9, 13, 15$ 四种设置。实验结果表明,当 $S=13$ 时,模型在已知类分类性能和未知类拒识能力之间取得较好平衡。较小的空间邻域难以充分捕获地物空间上下文,而过大的空间邻域可能引入邻近异类像元噪声。因此,本文默认采用 $S=13$ 作为输入图像块大小。

3 结 论


针对高光谱图像在复杂开放场景下存在的“未知类”地物误判问题,本文提出一种频域知识引导的高光谱开集识别方法(FKCL)。该方法采用数据与知识协同的双分支架构:利用 3D-2D 混合卷积网络提取深层空谱语义特征,同时结合离散傅里叶变换提取地物的频域物理属性,并通过指数移动平均(EMA)构建稳定的频域原型。在此基础上,引入基于类锚点聚类损失的双重距离决策机制,在特征空间与频域物理空间中同步构建已知类的判别边界。在三大高光谱基准数据集的类别留出伪未知评测协




(a) 原始光谱域(SA)




(b) 原始光谱域(UP)




(c) 原始光谱域(LK)



(d) 频域幅度谱(SA)



(e) 频域幅度谱(UP)



(f) 频域幅度谱(LK)

((a) spectral domain (SA); (b) spectral domain (UP); (c) spectral domain (LK); (d) frequency spectrum (SA); (e) frequency spectrum (UP); (f) frequency spectrum (LK))

图10 已知类与未知类样本在原始光谱域与频域幅度谱中的特征分布对比

Fig. 10 Comparison of feature distributions between known and unknown classes in the original spectral domain and frequency magnitude spectrum




图11 模型在不同数据集上的间隔参数敏感性分析

Fig. 11 Parameter sensitivity analysis of the model on different datasets




图12 模型在不同数据集上的空间邻域块大小敏感性分析

Fig. 12 Parameter sensitivity analysis of the model on different datasets

以下,实验结果表明,FKCL在保持已知类总体分类精度(OA)的同时,提升了对训练阶段未见类别的拒识能力,有助于缓解传统深度学习模型对伪未知样本的过度自信误判。后续研究将进一步探索自适应频域权重分配机制,并在更真实的开放遥感场景、跨

区域数据和动态新增类别条件下验证模型的泛化能力,同时将该框架拓展至LiDAR与高光谱协同等多模态遥感数据的开集识别任务中。

参考文献(References)

- Bendale A and Boulton T E. 2016. Towards open set deep networks// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE: 1563-1572.
- Chen Y, Lin Z, Zhao X, Wang G and Gu Y. 2014. Deep learning-based classification of hyperspectral data. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(6): 2094-2107 [DOI: 10.1109/JSTARS.2014.2329330].
- Fan G H, Ma Y, Mei X G, Huang J, Fan F and Li J. 2022. Spatial-coordinated autoencoder for hyperspectral anomaly detection. Journal of Image and Graphics, 27(10): 3116-3126 (樊港辉, 马泳, 梅晓光, 黄珺, 樊凡, 李锦. 2022. 空域协同自编码器的高光谱异常检测. 中国图象图形学报, 27(10): 3116-3126) [DOI: 10.11834/jig.210246].
- He M, Li B and Chen H. 2017. Multi-scale 3D deep convolutional neural network for hyperspectral image classification// Proceedings of the 2017 IEEE International Conference on Image Processing (ICIP). Beijing, China: IEEE: 3904-3908 [DOI: 10.1109/ICIP.2017.8293904].

- 2017.8297014].
- He M Y, Li Q, Guo Y and Yan H M. 2025. Overview and prospects of intelligent classification of hyperspectral images. *Journal of Image and Graphics*, 30(6): 2207-2238 (何明一, 李强, 郭英, 闫红梅. 2025. 高光谱图像智能分类研究综述与展望. *中国图象图形学报*, 30(6): 2207-2238) [DOI: 10.11834/jig.250045].
- Hong D, Han Z, Yao J, Gao L, Zhang B, Plaza A and Chanussot J. 2022. SpectralFormer: rethinking hyperspectral image classification with transformers. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-15 [DOI: 10.1109/TGRS.2021.3130716].
- Liu S, Shi Q and Zhang L. 2021. Few-shot hyperspectral image classification with unknown classes using multitask deep learning. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6): 5085-5102 [DOI: 10.1109/TGRS.2020.3018879].
- Ma X R, Ha L, Shen D B, Mei L and Wang H Y. 2024. Cross-dataset hyperspectral image classification based on fusion feature optimization. *Journal of Image and Graphics*, 29(8): 2175-2187 (马晓瑞, 哈林, 湛敦斌, 梅亮, 王洪玉. 2024. 融合特征优化的跨数据集高光谱图像分类. *中国图象图形学报*, 29(8): 2175-2187) [DOI: 10.11834/jig.230503].
- Miller D, Suenderhauf N, Milford M and Dayoub F. 2021. Class ssanchor clustering: a loss for distance-based open set recognition// *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. Waikoloa, HI, USA: IEEE: 3569-3577.
- Nirmal S, Sowmya V and Soman K P. 2020. Open set domain adaptation for hyperspectral image classification using generative adversarial network// Ranganathan G, Chen J, Rocha Á, eds. *Inventive Communication and Computational Technologies*. Singapore: Springer: 819-827 [DOI: 10.1007/978-981-15-0146-3_78].
- Okwuashi O and Ndehedehe C E. 2020. Deep support vector machine for hyperspectral image classification. *Pattern Recognition*, 103: 107298 [DOI: 10.1016/j.patcog.2020.107298].
- Roy S K, Krishna G, Dubey S R and Chaudhuri B B. 2020. HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 17(2): 277-281 [DOI: 10.1109/LGRS.2019.2918719].
- Scheirer W J, de Rezende Rocha A, Sapkota A and Boulton T E. 2013. Toward open set recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(7): 1757-1772 [DOI: 10.1109/TPAMI.2012.256].
- Shi Y X, He J R, Li Z K and Zeng Z G. 2021. Hyperspectral image classification model based on 3D convolutional auto-encoder. *Journal of Image and Graphics*, 26(8): 2021-2036 (石延新, 何进荣, 李照奎, 曾志高. 2021. 3D卷积自编码器高光谱图像分类模型. *中国图象图形学报*, 26(8): 2021-2036) [DOI: 10.11834/jig.210146].
- Song B, Min S, Yang H, Wu Y and Wang B. 2023. A fourier frequency domain convolutional neural network for remote sensing crop classification considering global consistency and edge specificity. *Remote Sensing*, 15(19): 4788 [DOI: 10.3390/rs15194788].
- Song W, Li S, Kang X and Huang K. 2016. Hyperspectral image classification based on KNN sparse representation// *Proceedings of the 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. Beijing, China: IEEE: 2411-2414 [DOI: 10.1109/IGARSS.2016.7729622].
- Sun X H, Shen Y, Wei X S and An P. 2023. Open-set object detection based on annular prototype space optimization. *Journal of Image and Graphics*, 28(9): 2719-2732 (孙旭豪, 沈阳, 魏秀参, 安鹏. 2023. 结合环状原型空间优化的开放集目标检测. *中国图象图形学报*, 28(9): 2719-2732) [DOI: 10.11834/jig.220992].
- Tong X, Xie H and Weng Q. 2014. Urban land cover classification with airborne hyperspectral data: what features to use? . *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(10): 3998-4009 [DOI: 10.1109/JSTARS.2013.2272212].
- Wu H H, Wang L G and Shi Y. 2021. Convolution neural network method for small-sample classification of hyperspectral images. *Journal of Image and Graphics*, 26(8): 2009-2020 (吴鸿昊, 王立国, 石瑶. 2021. 高光谱图像小样本分类的卷积神经网络方法. *中国图象图形学报*, 26(8): 2009-2020) [DOI: 10.11834/jig.210103].
- Ye Z, Bai L and He M Y. 2021. Review of spatial-spectral feature extraction for hyperspectral image. *Journal of Image and Graphics*, 26(8): 1737-1763 (叶珍, 白磷, 何明一. 2021. 高光谱图像空谱特征提取综述. *中国图象图形学报*, 26(8): 1737-1763) [DOI: 10.11834/jig.210198].
- Yoshihashi R, Shao W, Kawakami R, You S, Iida M and Naemura T. 2019. Classification-reconstruction learning for open-set recognition// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, CA, USA: IEEE: 4076-4085.
- Zhang L, Zhang L and Du B. 2016. Deep learning for remote sensing data: a technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2): 22-40 [DOI: 10.1109/MGRS.2016.2540798].

作者简介

马帅,男,硕士研究生,研究方向为高光谱图像分类,计算机视觉,小样本学习等。E-mail: mashuai@yau.edu.cn
何进荣,通信作者,男,教授,主要研究方向为计算机视觉,小样本学习,高光谱图像分类等。E-mail: hejinrong@yau.edu.cn