

中图法分类号: TP751 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-19

论文引用格式: Xiao Daifeng, Yu Dongbo, Wang Ying, Xiao Jun. SE-Mamba: Hyperspectral image classification method based on spatial enhancement[J/OL]. Journal of Image and Graphics, XXXX:1-19. DOI: 10.11834/jig.260119. (肖岱峰, 于东伯, 王颖, 肖俊. SE-Mamba: 空间信息增强的高光谱图像分类方法[J/OL]. 中国图象图形学报, XXXX:1-19. DOI: 10.11834/jig.260119.) [DOI: 10.11834/jig.260119]

SE-Mamba: 空间信息增强的高光谱图像分类方法

肖岱峰, 于东伯, 王颖, 肖俊*

中国科学院大学人工智能学院, 北京 100049

摘要: 目的 随着 Mamba 等前沿深度学习技术的发展, 高光谱遥感影像分类研究取得快速进展。然而, 当前基于 Mamba 的分类方法存在空间信息利用不足、空间-光谱特征融合不合理等问题, 导致空间细节信息侵蚀与特征淹没。为此, 本文聚焦空间视角下的高光谱图像特征表示这一核心任务, 提出一种基于空间信息增强的高光谱图像分类方法 (SE-Mamba), 旨在通过强化空间特征表达、优化空谱融合, 提升分类精度与效率, 为高光谱图像分类提供有效的技术路径。**方法** SE-Mamba 围绕空间信息的有效引入与合理融合构建, 核心包含两方面设计: 一是全流程空间信息增强机制, 构建前端空间增强特征提取器 (SEFE) 与后端高阶特征细化模块 (HFR), 通过位置信息注入、多尺度空间卷积等策略, 实现空间信息从浅层到深层的持续强化与保持; 二是空间-光谱特征合理融合架构, 设计包含空间-光谱融合模块 (SSFM) 的空间-光谱协同模块 (SSCM), 通过特征解耦双分支建模、“先校准后融合”及自适应权重分配, 实现空间与光谱信息的深度互补融合, 同时有效保留空间特征。**结果** 在 HanChuan、HongHu、Houston 和 PaviaU 四个代表性数据集 (涵盖农业、城市场景, 贴合空间信息增强研究重点) 上的实验结果表明, SE-Mamba 在总体精度 (OA) 和平均精度 (AA) 上均达到最优, Kappa 系数与最优方法相当; 同时, 其计算复杂度及参数量与主流方法持平, 推理速度优于部分对比模型, 在空间特征提取与空谱融合效率上表现突出, 实现了分类精度与计算效率的良好平衡。消融实验验证了各核心模块对空间特征表示的重要支撑作用。**结论** 实验结果表明, 显式增强空间信息与状态空间建模相结合的策略能有效协同, 缓解现有基于 Mamba 方法的空间信息侵蚀与特征淹没问题。该方法通过全流程空间特征强化、优化空谱融合方式, 充分凸显了空间视角下特征表示的核心价值, 使模型在复杂农业、城市场景及多类别高光谱数据集上保持稳定高效的分类性能, 并具有良好的效率优势, 为高光谱图像分类提供了有效的技术路径, 也为基于状态空间模型的遥感图像处理研究提供了参考。可为后续泛化性优化、轻量化部署等延伸研究奠定坚实基础。本文相关数据集及代码已共享 [DOI: 10.57760/sciencedb.j00240.00182.]。

关键词: 高光谱图像分类; Mamba; 空间-光谱特征表示; 特征融合; 高阶特征细化

SE-Mamba: Hyperspectral image classification method based on spatial enhancement

Xiao Daifeng, Yu Dongbo, Wang Ying, Xiao Jun*

School of Artificial Intelligence, University of Chinese Academy of Sciences, Beijing 100049, China

收稿日期: 2026-03-05; 修回日期: 2026-04-13

* 通信作者: 肖俊, 男, 教授, 主要研究方向为计算机视觉、图形图像处理及 AI+交叉学科。E-mail: xiaojun@ucas.ac.cn

基金项目: 国家自然科学基金 (U21A20515, 62476262, 62206263, 62271467, 62306297, 62306296); 北京市自然科学基金 (4242053, L242096); 中国博士后科学基金 (2022T150639)

Supported by: National Natural Science Foundation of China (U21A20515, 62476262, 62206263, 62271467, 62306297, 62306296); Natural Science Foundation of Beijing, China (4242053, L242096); China Postdoctoral Science Foundation (2022T150639)

Abstract: **Objective** Hyperspectral Image (HSI) classification is critical in remote sensing and widely used in land cover monitoring, agricultural survey, and urban planning. Mamba-based models have been increasingly applied in HSI classification due to their advantages in linear computational complexity and long-range dependency modeling. However, existing Mamba-based methods suffer from insufficient spatial information utilization and unreasonable spatial-spectral feature fusion, which leads to spatial information erosion and feature submergence, thereby limiting classification accuracy and efficiency. In this context, this study proposes a spatial information enhancement-based method, named SE-Mamba (Spatial Enhancement-Mamba), to improve classification accuracy and efficiency through effective integration of spatial and spectral information. **Method** SE-Mamba incorporates two key designs focusing on the effective introduction and reasonable fusion of spatial information. First, a full-process spatial information enhancement mechanism is constructed, consisting of a front-end Spatial Enhancement Feature Extractor (SEFE) and a back-end High-Order Feature Refinement (HFR) module. Before the features are serialized and processed, SEFE explicitly encodes local structural priors and geometric dependencies into the feature map to alleviate the spatial information loss caused by Mamba serialization; HFR restores fine-grained geometric structures through high-order interaction and dual gate control enhancement mechanisms. Second, a rational spatial-spectral fusion architecture, namely the Spatial Spectral Collaborative Module (SSCM), is designed, which includes a Spatial-Spectral Fusion Module (SSFM). The SSCM decouples spatial and spectral features into two separate branches to strengthen the independent representation of heterogeneous features, while the SSFM adopts a "calibration-first, then-fusion" strategy to achieve in-depth integration through cross-guidance and adaptive weight allocation, thereby avoiding spatial information erosion. For experimental verification, four representative hyperspectral datasets (HanChuan, HongHu, Houston, PaviaU) covering agricultural and urban scenes are used to evaluate the model's performance and robustness. Key evaluation indicators include Overall Accuracy (OA), Average Accuracy (AA), and Kappa coefficient. The ablation experiment compared the performance of using SEFE, HFR, and SSCM separately on the baseline model, and analyzed the role of the proposed modules themselves, the synergy between each module, and the coupling effect of the internal sub-modules of SSCM by removing the SEFE, HFR, and SSCM modules from the complete framework. Computational complexity, parameter size, and inference speed are also evaluated to assess the model's efficiency. **Results** Experimental results on the four representative datasets (HanChuan, HongHu, Houston, and PaviaU) demonstrate that SE-Mamba achieves the best Overall Accuracy (OA) and Average Accuracy (AA), with its Kappa coefficient also reaching a level comparable to the state-of-the-art methods. Specifically, SE-Mamba attains an average OA of 96.07% across the four datasets, surpassing the benchmark model MambaHSI by 2.32%. In terms of efficiency, the computational complexity and parameter size of SE-Mamba are comparable to those of mainstream methods, while its inference speed is superior to that of some comparison models, achieving a good balance between classification accuracy and computational efficiency. Ablation experiments verify the effectiveness of each core module in spatial feature representation. Compared with existing Mamba-based methods (e.g., MambaHSI), SE-Mamba effectively addresses spatial information erosion and feature submergence through spatial enhancement and optimized fusion, while preserving Mamba's linear computational advantage. Compared with traditional CNN/Transformer-based methods, SE-Mamba combines state space modeling with spatial enhancement, achieving more stable performance in complex scenes. **Conclusions** Experiments verify that the combination of explicit spatial enhancement and state space modeling is effective, and the two core strategies of SE-Mamba synergistically alleviate spatial information erosion and feature submergence. By strengthening spatial feature extraction and optimizing spatial-spectral fusion, SE-Mamba maintains stable and efficient classification performance on complex agricultural, urban, and multi-category HSI datasets, achieving improved classification accuracy and efficiency. SE-Mamba provides a novel approach for HSI classification and serves as a reference for state space-based remote sensing image processing, offering technical support for land cover monitoring and agricultural survey. Future work could consider designing adaptive scanning mechanisms and introducing transfer learning to enhance the model's adaptability to complex scenarios and cross-regional generalization ability, and promote its practical application on portable devices through lightweight design. The dataset and code related to this article have been shared [DOI: 10.57760/scientificdb.j00240.00182].

Key words: Hyperspectral Image Classification; Mamba; Spatial-Spectral Feature Representation; Feature Fusion; High-Order Feature Refinement.

0 引言

高光谱图像 (Hyperspectral Image, HSI) 能够捕捉地物连续且精细的光谱特征与空间细节, 基于此优势, 其分类任务已成为遥感信息处理领域的重要内容, 在精准农业、环境监测、城市规划、资源勘探等多个关键领域展现出广阔的应用前景, 成为遥感与计算机视觉交叉领域的研究热点 (Zhang 等, 2012; Obermeier 等, 2019; 何明一等, 2025)。与 RGB 图像相比, HSI 包含丰富的光谱波段, 能够精准区分光谱特征相似的地物类别, 为精细化地物识别与分类提供了丰富的数据基础 (Xia 等, 2014; Akewar 等, 2024; 曹丽琴等, 2024)。随着高光谱遥感技术的快速发展, 如何高效挖掘高光谱数据中的空间-光谱联合特征、缓解高维光谱冗余与复杂空间依赖建模难题, 进一步提升复杂场景下的分类精度与推理效率, 已成为当前领域的核心研究目标。

在高光谱图像分类的研究进程中, 深度学习技术的应用实现了分类性能的跨越式提升, 并推动研究范式从传统统计方法向深度学习方法转变 (Melgani 等, 2004; Le 等, 2008)。早期, 卷积神经网络 (Convolutional Neural Networks, CNNs) 凭借其强大的局部特征提取能力, 成为高光谱分类的主流方法, 其中 3DCNN 可同时捕获空间与光谱局部特征, 显著提升了地物分类精度 (Hu 等, 2015; Li 等, 2019)。然而, CNN 有限的局部感受野限制了其对全局空间-光谱长程依赖的建模能力, 难以应对复杂场景中类内光谱差异大、类间边界模糊等挑战 (Xu 等, 2019; Zhu 等, 2021)。为解决这一局限, 研究人员开始在高光谱图像分类领域引入视觉 Transformer (Vision Transformers, ViTs) (Dosovitskiy 等, 2020), 通过自注意力机制实现全局特征交互, 突破了 CNN 局部感受野的限制, 建立了新的性能基准 (Hong 等, 2021; Mei 等, 2022)。但 Transformer 的计算复杂度随序列长度呈二次增长, 在处理大规模数据时, 面临内存消耗大、运算效率低的瓶颈, 难以满足实际应用需求 (Tao 等, 2025; Lin 等, 2022; Zhao 等, 2024)。

近年来, 状态空间模型 (State Space Model, SSM) 的出现为平衡分类精度与计算效率提供了新思路, 其中 Mamba 架构凭借线性计算复杂度与全局感受野的双重优势, 迅速成为高光谱分类领域的研究热

点 (Gu 等, 2023; Yao 等, 2024; Xu 等, 2024)。Mamba 通过隐藏状态转换机制, 在保证运算效率的同时, 实现了全局特征的高效建模, 有效弥补了 CNN 与 Transformer 的固有缺陷 (Gu 等, 2023; Xu 等, 2024)。具体来说, Li 等人 (2024) 提出的 MambaHSI 作为首个基于 Mamba 的全图范式高光谱分类框架, 构建了空间-光谱联合建模体系, 实现了长程像素级交互的高效建模; 在此基础上, Wang, Y 等人 (2025) 设计的 MambaHSI+ 通过引入多方向扫描机制, 进一步优化特征表示能力; Tao 等人 (2025) 的 SSFR 则通过分层分组光谱建模, 缓解高光谱数据的光谱冗余问题。此外, DBMGNet (Wang 等, 2025) 通过多尺度学习提升复杂场景适应性, IGroupSS-Mamba (He 等, 2024) 利用分层分组策略优化特征提取, 取得了显著的研究进展。

尽管基于 Mamba 的分类方法已有所突破, 但仍存在若干局限: 一是二维高光谱特征在序列化过程中存在明显的空间信息侵蚀 (展平操作会破坏二维拓扑结构与邻域像素相关性, 造成空间结构信息损失) (Li 等, 2024; Wang Y 等, 2025); 二是现有融合方案导致的空间细节特征淹没 (当前方法多采用分支整体加权或通道级加权策略, 在融合过程中光谱特征易因维度更高、判别性更强而占据主导的同时, 空间细节特征则易被稀释甚至淹没; 另外即便提升空间分支整体权重, 也难以对边缘、细碎地物等局部关键区域实现差异化增强, 最终导致分类边界模糊) (Tao 等, 2025; He 等, 2024); 三是网络加深后细粒度几何细节易被全局语义特征淹没, 进一步影响分类精度 (Li 等, 2024; Wang Y 等, 2025)。这些问题限制了空间-光谱联合特征优势的发挥, 在复杂场景分类中仍有较大提升空间。

针对上述问题, 本文以缓解空间信息侵蚀与特征淹没问题为导向, 聚焦空间视角下的高光谱特征表示学习, 提出一种基于空间信息增强的高光谱图像分类方法 (SE-Mamba)。该方法通过设计专门的特征提取、融合与细化模块, 强化空间信息挖掘与利用, 优化空间-光谱特征的融合效率与利用的合理性, 针对性缓解现有方法的核心局限, 进而实现复杂场景下高光谱图像的高精度分类, 为高光谱图像分类任务提供有效技术思路。

本文的主要贡献总结如下:

1) 提出空间增强特征提取器 (SEFE) 作为前端

模块,采用多尺度深度可分离卷积与自适应位置门控机制,在特征序列化前编码局部拓扑结构,减轻序列展开带来的空间信息侵蚀。

2)构建空间-光谱协同模块(SSCM),其中,空间-光谱融合模块(SSFM)通过分支交互实现特征自适应校准,减少关键空间细节丢失,有效缓解信息冗余与特征淹没问题。

3)在框架末端引入高阶特征细化(HFR)模块,

借助双门强化机制增强 Mamba 输出的全局特征,恢复高频几何分量、锐化分类边界,提升特征判别能力,进一步弥补细粒度几何细节被淹没的缺陷。

4)在四个公开数据集上的实验结果表明,SE-Mamba 在四个基准数据集上的平均总体准确率(OA)达 96.07%,达到领域领先水平,验证了所提方法能有效缓解目前的空间信息侵蚀和特征淹没问题,显著提升了分类性能。

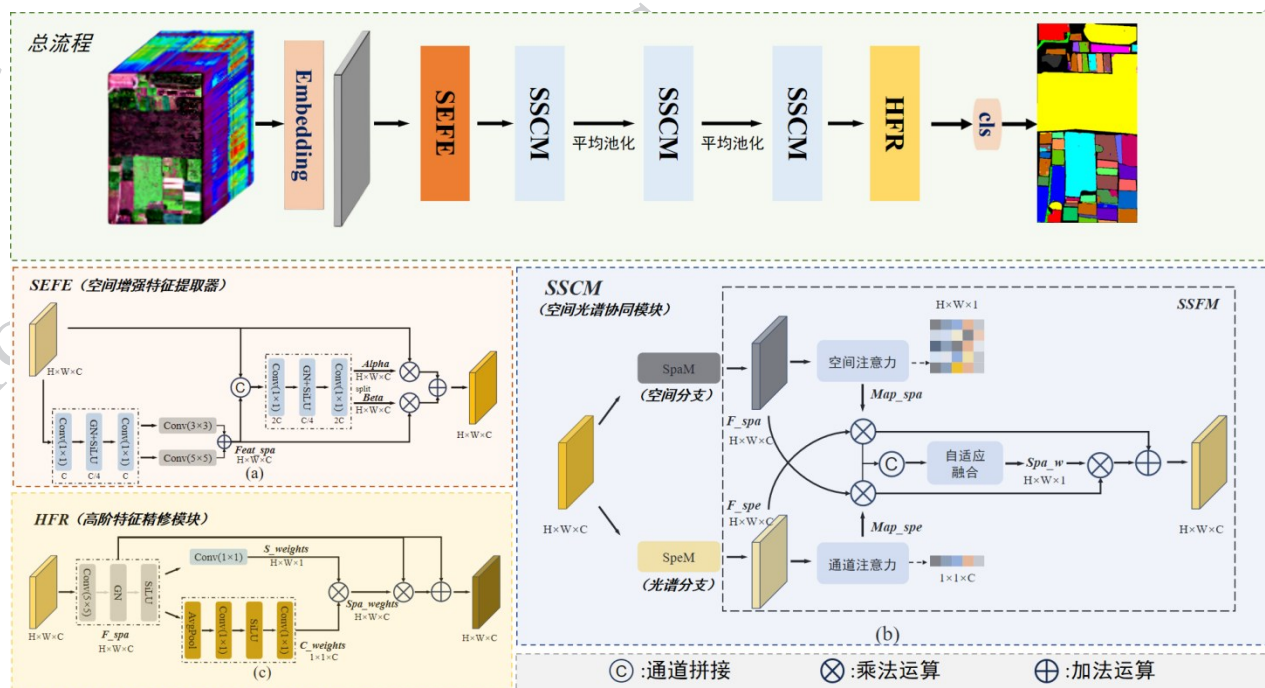


图 1 SE-Mamba 的总体架构

Fig. 1 Overall architecture of the SE-Mamba

1 研究方法

SE-Mamba 采用全图输入输出的端到端架构,整体结构如图 1 所示,旨在缓解基于序列建模方法在 HSI 分类中存在的空间信息侵蚀与特征淹没问题。整个框架包含 SEFE、SSCM、HFR 三个核心部件,整体流程可概括为“初始特征输入—空间增强预处理—空谱协同特征提取—高阶特征细化—分类输出”。具体数据流及各阶段核心作用如下:首先,网络通过嵌入层(embedding)获得初始特征图 $X \in \mathbb{R}^{H \times W \times C}$ 后,进入第一阶段——空间增强特征提取器(SEFE),该模块结合显式结构先验和自适应位置感知注入,强化空间基础;相较于直接进行展平的方式,SEFE 通过预先建模空间结构,减轻二维拓扑破坏与邻域相

关性损失。随后,进入核心阶段——多个空间-光谱协同模块(SSCM)块进行特征提取,每个 SSCM 包含并行的空间 Mamba (SpaM) 和光谱 Mamba (SpeM) 分支,以及空间-光谱融合模块(SSFM)。SSFM 通过自适应融合策略减少信息冗余并抑制空间细节稀释。最后,在网络末端引入高阶特征细化(HFR)模块,该模块细化分类边界、恢复网络传递过程中被淹没的高频几何细节;经过 HFR 模块优化后的特征图,再通过线性层投影到标签空间,最终生成像素分类结果 $Y \in \mathbb{R}^{H \times W \times N}$ 。

1.1 空间增强特征提取器

Mamba 的序列展开操作会破坏二维空间拓扑结构与相邻像素相关性,进而引发空间信息侵蚀。为此,提出空间增强特征提取器(SEFE)作为前端空间感知模块,在进入 Mamba 之前预先对局部空间结构

与邻域依赖进行显式建模与编码,从而减轻后续序列化操作对空间信息的损失。SEFE的结构如图1(a)所示,在特征图被序列化和处理之前,将局部结构先验和几何依赖显式编码到特征图中。具体而言,

1) SEFE对输入特征 X 通过卷积进行初步校正,之后通过专用的空间分支处理 X_{pos} ,以提取多尺度的空间信息 F_{spa} :

$$F_{spa} = \text{GN}\left(\text{DWC}_{3 \times 3}(X_{pos}) + \text{DWC}_{5 \times 5}(X_{pos})\right) \quad (1)$$

其中GN为组归一化,DWC为深度可分离卷积。通过使用 3×3 和 5×5 的卷积核, F_{spa} 有效地聚合了细粒度纹理和中等尺度结构信息,有利于在光谱相似的复杂场景中提升地物判别能力。

2)为实现稳定的像素级融合并避免特征失衡,设计了一个融合门。通过两个动态系数 α 和 β 来控制每条路径的增益:

$$F_{out} = F_{spa} \odot (0.5 + 0.5\alpha) + X \odot (0.5 + 0.5\beta) \quad (2)$$

其中 α 和 β 通过门控生成,该策略确保各分支至少保留50%的基础信息,避免训练过程中出现特征崩溃。最终输出如式(3)所示,SiLU为激活函数,Proj为投影校正。

$$Y_{SEFE} = \text{SiLU}\left(\text{Proj}(F_{out}) + X\right) \quad (3)$$

综上,SEFE通过多尺度空间结构建模,在序列化前提前注入局部空间先验,能够在一定程度上减轻Mamba展平带来的空间信息侵蚀,为后续特征学习提供更具空间感知能力的初始表示。

1.2 空间光谱协同模块

空间-光谱协同模块(SSCM)用于并行建模空间域与光谱域的长程依赖关系,并通过非对称融合策略实现空间与光谱特征的自适应整合,缓解特征冗余与空间细节淹没问题。具体来说:

1) SpaM分支专注于空间全局上下文建模:将二维特征展平为序列后,采用双向扫描机制克服标准状态空间模型(SSM)的单向性局限,最终将特征映射回空间维度。

2) SpeM分支则面向波段间相关性建模:先通过前置归一化(Pre-Norm)层校准高维光谱信号;之后Mamba模块对光谱特征进行状态空间转换,以捕捉波段间相关性;与SpaM分支类似,SpeM引入全局残差路径,在整合学习到的分组级依赖关系的同时,保留原始光谱保真度。

3) SSFM采用先校准后融合的策略。首先是构建双路径交叉引导:从 F_{spa} 生成空间注意力(Spatial Attention)以突出结构重要区域,同时通过通道注意力(Channel Attention)重新校准空间分支:

$$\hat{F}_{spa} = F_{spa} \odot (1 + \text{CAM}(F_{spe})) \quad (4)$$

$$\hat{F}_{spe} = F_{spe} \odot (1 + \text{SAM}(F_{spa})) \quad (5)$$

其中SAM(\cdot)和CAM(\cdot)分别表示空间注意力机制和通道注意力机制。这种交互使空间与光谱特征在融合前相互引导、互补增强。

之后,通过自适应残差门控处理拼接后的特征,生成像素级空间权重图 W_{spa} (图中记为 Spa_w):

$$W_{spa} = \text{Sigmoid}\left(\Phi_{\text{gate}}\left(\left[\hat{F}_{spa}, \hat{F}_{spe}\right]\right)\right) \quad (6)$$

最终融合输出以光谱信号为基础,选择性注入经权重强化的空间细节:

$$F_{fused} = \hat{F}_{spe} + \hat{F}_{spa} \odot W_{spa} \quad (7)$$

SSCM通过双Mamba分支提取有效的空间和光谱特征,并借助SSFM实现以光谱特征为基础保持判别能力、同时对空间细节进行自适应加权增强的融合方式,有效减少特征噪声,从而缓解整体融合方式导致的信息冗余以及对空间细节信息的淹没。

1.3 高阶特征细化模块

在深层网络中,多次Mamba状态转换易使模型偏向全局语义,导致高频空间细节弱化、分类边界模糊。为此,本文引入图1(c)的高阶特征细化模块(HFR),旨在通过高阶交互和双门控增强机制,恢复细粒度几何结构。

1)首先,HFR对输入特征图进行空间重聚焦处理。如式(8),模块采用大核深度卷积对特征进行空间重聚焦,捕捉被稀释的局部纹理与边界信息:

$$F_{refine} = \text{SiLU}\left(\text{GN}\left(\text{DWC}_{5 \times 5}(F_{fused})\right)\right) \quad (8)$$

其中 F_{refine} 表示重聚焦后的空间特征表示。该步骤确保后续的精修过程以稳健的局部结构为基础。

2)其次,HFR通过双路径实现高阶交互来联合优化空间维度和光谱维度的特征。 F_{refine} 分别进入空间增强路径和通道重校准路径。空间增强路径通过 1×1 卷积生成空间权重图 $S_{weights}$,捕捉像素级显著信息。通道校准路径采用AvgPool-Conv-SiLU-Conv结构生成通道级权重 $C_{weights}$ 。

高阶交互通过联合调制掩码实现,该掩码是一个复合空谱增益 W_{joint} 。最终输出 Y 如式(10)。

$$W_{\text{joint}} = \text{Sigmoid}(S_{\text{weights}} \otimes C_{\text{weights}}) \quad (9)$$

$$Y = F_{\text{refine}} \odot (1 + W_{\text{joint}}) \quad (10)$$

这种机制可有效抑制特征噪声、强化判别性结构信息,恢复深层传播中丢失的细粒度几何细节,进一步锐化分类边界,提升最终分类性能。

2 实验与分析

本节首先介绍使用的 HSI 数据集及实验设置,随后进行对比实验与消融实验,并分析模型效率。

2.1 数据集介绍

实验采用四个具有代表性的真实 HSI 数据集,覆盖复杂农业、典型城市场景,涵盖不同尺寸、波段数及地物类别,可充分检验方法有效性,图 2 到图 5 为数据集示意图。各数据集详细信息如下:

1) **帕维亚大学(PaviaU)**:由 ROSIS 传感器在意大利帕维亚采集,共有 9 个类别,图像尺寸为 610×340 像素,空间分辨率为 1.3m,共 103 个光谱波段,覆盖可见光至近红外范围。该数据集代表典型城市场景,地物类别清晰但存在局部破碎化现象。

2) **汉川(HanChuan)**:在湖北省汉川市使用 Headwall Nano Hypersec 传感器采集,共 16 个类别,图像尺寸为 1217×303 像素,空间分辨率为 0.109m,包含 400 到 1000nm 的 274 个波段。数据集以复杂农业区为主,地物分布较密集且类别差异细微、光谱特征相近,对细粒度分类能力提出较高要求。

3) **洪湖(HongHu)**:使用 Headwall Nano Hypersec 传感器采集于湖北省,共 22 个类别,图像尺寸为 940×475 像素,空间分辨率为 0.043m,包含 400 至 1000nm 共 270 个波段。作物类型密集、光谱特征相似,对地物边界判别构成较大挑战。

4) **休斯顿(Houston)**:由 ITRES CASI 1500 传感器采集,共 15 个类别,图像尺寸为 349×1905 像素,空间分辨率为 2.5m,覆盖 380 至 1050 nm 共 144 个波段。覆盖草地、建筑、道路等地物类型,可检验模型对复杂城市场景的适配性。

2.2 实验设置

2.2.1 数据划分与评价指标

实验数据划分与主流方法保持一致,选取每类目标的 30 个像素进行训练,10 个像素进行验证,其余用于测试。定量评估指标包括:**总体精度(Over-**

all Accuracy, OA)指正确分类的像素占全部像素的百分比,反映整体分类效果。**平均精度(Average Accuracy, AA)**为所有类别精度的均值,衡量模型在非平衡数据集上的表现。**Kappa 系数(κ)**则有效反映模型分类结果的可靠性。

2.2.2 实现细节

实验设置与 MambaHSI 一致:优化器为 Adam,学习率为 3×10^{-4} 。遵循全局图像输入范式,批次大小设为 1,训练总 epoch 为 200。embedding 层的维度 D 为 128,SSCM 模块的光谱分组数 G 为 4。

2.2.3 硬件环境

所有实验均基于单张 NVIDIA A100 GPU 实现,该 GPU 部署于配备 Intel Xeon Gold 6348 CPU (64 核) 及 256 GB 内存的服务器上。A100 具备高内存带宽与算力,可高效支撑全图像状态空间建模,尤其适用于处理 HongHu、Houston 等大规模数据集。


2.3 对比实验

为全面评估 SE-Mamba 性能,从定量与定性两个角度进行比较,确保评估结果的全面性与可靠性。在定量比较中,选取了 9 种先进方法进行对比:基于 CNN 的方法包括 GiGCN (Jia 等, 2022) 和 CLONL (Li C 等, 2024); 基于 Transformer 的方法包括 SpectralFormer (Hong 等, 2021) 和 GSC-ViT (Zhao 等, 2024); 基于 Mamba 的方法包括 SpectralMamba (Yao 等, 2024)、MambaHSI (Li 等, 2024)、S2Mamba (Wang G 等, 2025)、DBMGNet (Wang 等, 2025) 以及 SSFR (Tao 等, 2025)。在定性评估中,选取性能最优的 4 种方法进行可视化对比。定量结果见表 1 至表 4,定性结果见图 6 至图 9。定量结果表格中采用“均值±标准差”的形式,加粗表示最优值,下划线表示次优值;若两个模型精度相同,则取标准差较小者为最优。

2.3.1 PaviaU 数据集

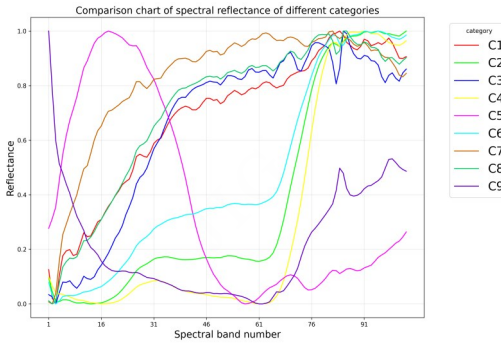
表 1 的定量结果表明, SE-Mamba 在 OA (98.10%) 和 AA (98.28%) 上均保持最优结果, Kappa 系数虽为次优但与 SSFR 方法相当;相较于基准模型 MambaHSI, OA 提升 2.36%, 在类别破碎化的城市场景中优势显著。该模型虽未在所有类别中取得最高精度,但性能稳定,无明显分类缺陷,尤其在 Gravel、Bitumen 等类别上,仍保持 97.63% 和 99.72% 的高精度;最低类别精度 (Tree) 仍达 95.65%, 远优于 GiGCN 等架构 (低于 82%)。

图 6 的结果显示, SE-Mamba 相比 MambaHSI 和
© 中国图象图形学报版权所有



(a) 伪彩图

(b) 真值图



(c) 不同地物类别示例以及在不同波段下的反射率


Asphalt	Meadows	Gravel
6631	18649	2099
Trees	Metal sheets	Bare soil
3064	1345	5029
Bitumen	Bricks	Shadows
1330	3682	947

(d) 地物类别及其样本数量

((a) Pseudo color image; (b) Label map; (c) Examples of different land cover categories and reflectance at different frequency bands; (d) Land cover categories and their sample sizes)


图 2 PaviaU 数据集

Fig. 2 PaviaU dataset



(a) 伪彩图

(b) 真值图



(c) 不同地物类别示例以及在不同波段下的反射率

Strawberry	Cowpea	Soybean	Sorghum
44735	22753	10287	5353
Water spinach	Watermelon	Greens	Trees
1200	4533	5903	17978
Grass	Red roof	Gray roof	Plastic
9469	10516	16911	3679
Bare soil	Road	Bright object	Water
9116	18560	1136	75401

(d) 地物类别及其样本数量


((a) Pseudo color image; (b) Label map; (c) Examples of different land cover categories and reflectance at different frequency bands; (d) Land cover categories and their sample sizes)

图 3 HanChuan 数据集


Fig. 3 HanChuan dataset

S2Mamba, 分类结果中同质区域更平滑, 椒盐噪声显著减少, 在 Meadows、Bare soil 等大面积区域效果更佳。定量与定性结果均表明, SE-Mamba 能更好地保

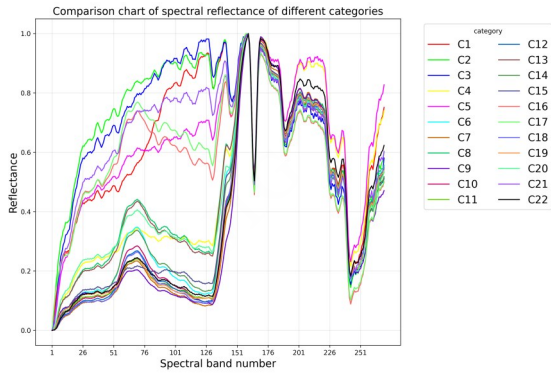
持地物结构完整性, SSCM 能构建全局空间-光谱的长程依赖关系, 有效缓解空间信息侵蚀和特征淹没问题。



(a) 伪彩图



(b) 真值图



(c) 不同地物类别示例以及在不同波段下的反射率

Red roof	Road	Bare soil	Cotton	Cotton firewood	Rape
14041	3512	21821	163285	6218	44557
Chinese cabbage	Pakchoi	Cabbage	Tuber mustard	Brassica parachinensis	Brassica chinensis
24103	4054	10819	12394	11015	8954
Small Brassica chinensis	Lactuca sativa	Celtuce	Film covered lettuce	Romaine lettuce	Carrot
22447	7356	1002	7262	3010	3217
White radish	Garlic sprout	Broad bean	Tree		
8712	3486	1328	4040		

(d) 地物类别及其样本数量


((a) Pseudo color image; (b) Label map; (c) Examples of different land cover categories and reflectance at different frequency bands; (d) Land cover categories and their sample sizes)

图4 HongHu数据集

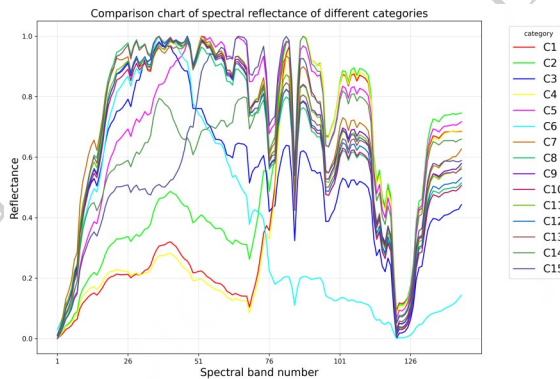
Fig. 4 HongHu dataset



(a) 伪彩图



(b) 真值图



(c) 不同地物类别示例以及在不同波段下的反射率

Healthy Grass	Stressed Grass	Synthetic Grass	Tree	Soil
1251	1254	697	1244	1242
Water	Residential	Commercial	Road	Highway
325	1268	1244	1252	1227
Railway	Parking Lot 1	Parking Lot 2	Tennis Court	Running Track
1235	1233	469	428	660

(d) 地物类别及其样本数量

((a) Pseudo color image; (b) Label map; (c) Examples of different land cover categories and reflectance at different frequency bands; (d) Land cover categories and their sample sizes)

图5 Houston数据集

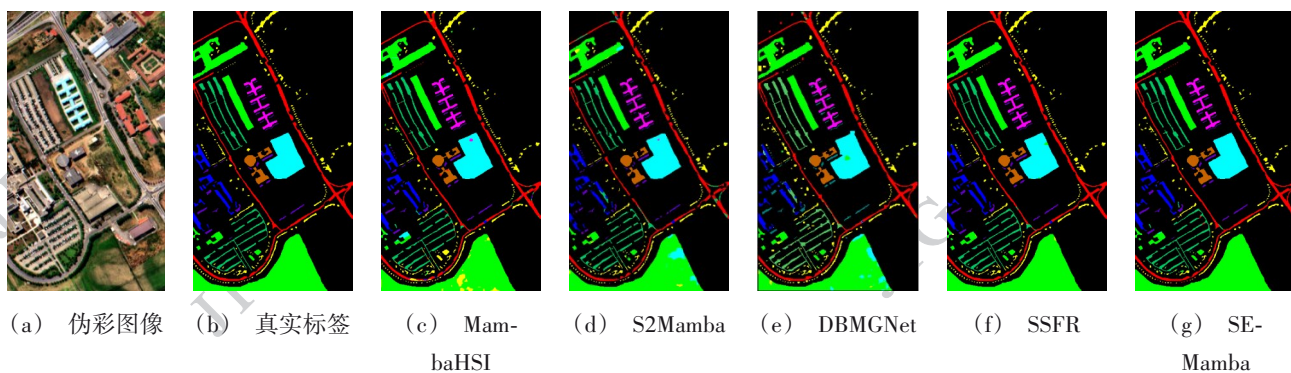
Fig. 5 Houston dataset

表3 HongHu数据集结果

Table 3 Quantitative result of HongHu

表 1 PaviaU数据集结果
Table 1 Quantitative result of PaviaU

类别	GiGCN	CLONL	SpectralFormer	GSC-VIT	SpectralMamba	MambaHSI	S2Mamba	DBMGNet	SSFR	Ours
Asphalt	90.36± 1.73	98.27 1.00	92.60±2.29	97.10± 1.64	88.46±5.24	94.35± 1.73	<u>98.10±</u> <u>0.23</u>	96.69± 0.38	97.23± 1.10	96.06± 2.51
Meadows	<u>98.86±</u> <u>0.78</u>	98.98 0.76	93.58±2.14	97.68± 1.32	92.07±5.88	96.43± 1.92	93.94± 0.48	97.82± 0.81	97.90± 1.27	98.49± 1.17
Gravel	91.66± 6.33	87.83± 7.44	86.46±7.42	86.46± 7.42	94.07±4.71	93.39± 5.35	99.60 0.34	96.00± 1.06	<u>97.66±</u> <u>2.46</u>	97.63± 2.75
Trees	81.34± 10.11	<u>97.80±</u> <u>1.46</u>	92.28±6.23	91.83± 9.94	92.40±2.91	89.75± 3.60	98.24 0.59	97.56± 0.48	95.49± 1.28	95.65± 1.72
Metal sheets	91.15± 1.31	99.68± 0.59	98.00±1.72	99.45± 0.53	99.95±0.07	<u>99.99±</u> <u>0.02</u>	99.46± 0.38	100.00 0.00	99.98± 0.03	99.94± 0.11
Bare soil	98.87± 1.90	85.27± 7.50	63.92±12.41	79.65± 9.24	97.87±1.65	98.60± 3.93	97.26± 1.38	97.68± 0.16	<u>99.35±</u> <u>0.36</u>	99.63 0.85
Bitumen	99.28± 0.61	85.92± 7.00	48.11±8.47	89.63± 10.10	98.41±1.43	96.50± 3.13	99.81 0.12	99.62± 0.29	99.14± 0.64	<u>99.72±</u> <u>0.29</u>
Bricks	87.68± 7.46	90.93± 4.12	81.22±4.66	89.50± 1.70	96.53±2.24	94.40± 2.93	96.35± 0.93	94.31± 1.80	<u>97.50±</u> <u>1.74</u>	98.57 1.19
Shadows	97.21± 3.36	97.12± 0.33	88.78±5.92	98.71± 1.10	97.77±1.42	99.36± 0.62	99.36± 0.63	99.89 0.10	<u>99.45±</u> <u>0.48</u>	98.83± 0.89
OA(%)	94.47± 0.97	94.97± 1.49	91.10±2.60	92.65± 2.30	93.25±2.65	95.74± 0.90	96.23± 0.21	97.28± 0.41	<u>97.88±</u> <u>0.68</u>	98.10 0.66
AA(%)	92.93± 1.07	93.53± 1.53	79.93±2.67	91.89± 1.73	95.28±1.06	95.86± 1.11	98.01± 0.15	97.63± 0.29	<u>98.19±</u> <u>0.40</u>	98.28 0.45
Kappa (%)	92.67± 1.26	93.38± 1.84	77.40±4.41	90.38± 2.95	94.13±3.06	95.00± 2.24	95.04± 0.27	96.40± 0.54	98.12 1.51	<u>98.00±</u> <u>1.87</u>



(a) Pseudo color image; (b) Label map; (c) MambaHSI; (d) S2Mamba; (e) DBMGNet; (f) SSFR; (g) SE-Mamba

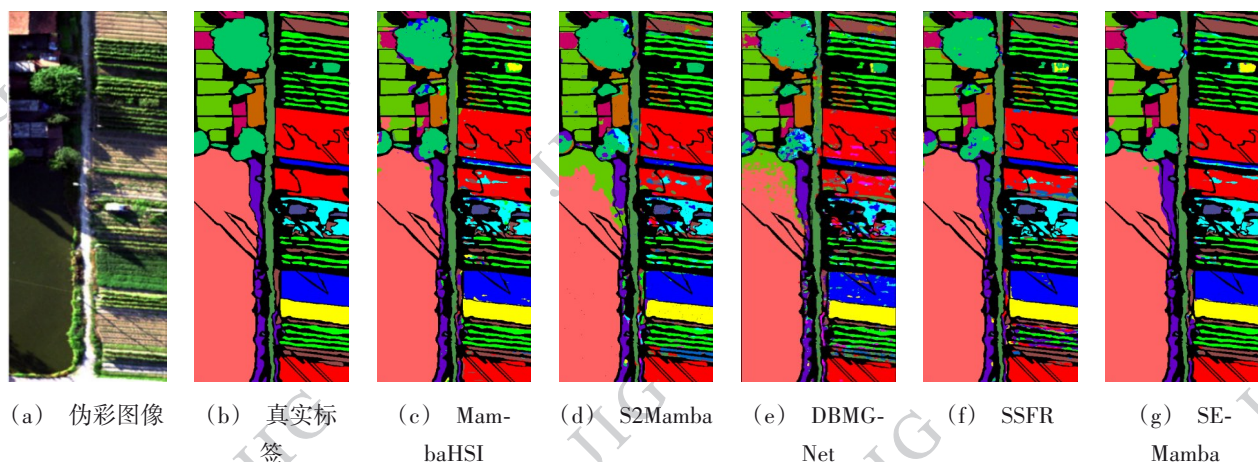
图 6 不同模型在PaviaU数据集上的可视化结果

Fig. 6 Visualization results of different models on the PaviaU dataset

表 2 HanChuan 数据集结果

Table 2 Quantitative result of HanChuan

类别	GiGCN	CLONL	SpectralFormer	GSC-ViT	SpectralMamba	MambaHSI	S2Mamba	DBMGNet	SSFR	Ours
Strawberry	89.34± 2.23	95.97 1.87	95.13±1.25	<u>95.26±</u> <u>1.50</u>	94.50±1.79	89.72± 5.75	90.82± 0.45	92.45± 0.46	93.96± 4.29	94.83± 2.51
Cowpea	81.64± 3.38	92.48 2.56	87.27±3.37	91.22± 3.05	<u>91.52±2.41</u>	81.37± 5.69	84.25± 1.21	83.83± 0.64	86.51± 4.40	91.05± 4.90
Soybean	81.06± 6.56	80.03± 9.18	70.36±6.15	78.37± 7.47	88.54±4.02	94.88± 3.73	93.06± 0.41	93.23± 0.46	<u>95.34±</u> <u>3.39</u>	96.98 2.32
Sorghum	67.09± 4.82	91.12± 7.72	88.62±6.67	85.17± 12.38	98.61±0.86	98.46± 1.35	96.62± 0.35	97.57± 0.17	<u>98.72±</u> <u>1.06</u>	98.93 0.89
Water spinach	34.98± 2.76	56.82± 12.89	42.01±11.48	46.57± 13.03	99.69±0.18	99.54± 0.85	<u>99.99±</u> <u>0.03</u>	99.70± 0.10	99.87± 0.39	100.00 0.00
Watermelon	53.81± 9.81	38.07± 8.70	34.68±6.40	35.97± 7.01	75.89±7.12	76.99± 4.95	92.29 0.78	87.58± 0.80	<u>89.82±</u> <u>6.46</u>	82.31± 8.29
Greens	80.84± 8.87	68.87± 17.46	67.69±10.29	66.90± 15.67	92.60±3.90	92.61± 4.63	96.29 0.31	<u>95.83±</u> <u>0.48</u>	95.45± 4.30	95.17± 4.87
Trees	89.27 4.80	81.52± 7.87	83.17±4.16	82.39± 5.23	<u>86.69±4.11</u>	70.73± 7.10	73.19± 0.70	72.50± 0.96	81.75± 4.88	78.49± 6.47
Grass	65.14± 6.79	68.59± 6.61	63.00±4.53	60.64± 17.62	83.82±5.41	89.01± 3.62	84.48± 1.57	82.46± 0.95	<u>90.50±</u> <u>3.85</u>	90.98 3.90
Red roof	93.03± 4.21	90.79± 14.71	88.76±12.99	93.22± 4.31	95.65±2.74	94.44± 2.18	99.47 0.07	97.10± 0.35	96.44± 1.61	<u>97.26±</u> <u>1.99</u>
Gray roof	93.86± 5.06	87.86± 4.63	77.41±13.19	82.13± 7.96	93.3±4.15	<u>96.13±</u> <u>1.66</u>	97.48 0.51	91.91± 1.22	89.57± 4.32	90.90± 4.72
Plastic	89.22± 7.45	63.48± 14.80	51.40±6.89	51.92± 6.01	85.13±5.41	88.83± 6.91	97.72 0.75	94.05± 0.41	93.58± 3.07	<u>94.41±</u> <u>2.66</u>
Bare soil	66.66± 6.60	50.21± 6.71	47.62±9.17	53.28± 10.88	80.57±6.31	78.69± 3.73	79.97± 0.76	80.31± 1.15	<u>81.51±</u> <u>3.13</u>	82.41 5.50
Road	91.25± 2.43	90.78± 2.74	88.92±3.08	90.64± 3.07	91.15±2.96	89.68± 3.03	81.92± 2.23	74.52± 0.87	<u>93.06±</u> <u>2.14</u>	94.38 1.58
Bright object	46.57± 17.42	62.42± 10.67	52.51±8.59	70.05± 12.35	95.05±2.59	94.42± 2.41	<u>99.54±</u> <u>0.26</u>	99.93 0.04	95.87± 1.47	98.62± 1.55
Water	<u>99.75±</u> <u>0.14</u>	98.97± 1.02	99.47±0.33	99.77 0.23	98.81±0.75	98.28± 1.62	<u>99.52±</u> <u>0.08</u>	98.66± 0.17	98.59± 0.80	98.68± 0.60
OA(%)	86.78± 1.43	85.14± 2.93	82.99±2.31	83.14± 3.96	91.64±1.12	90.21± 1.67	91.63± 0.16	90.40± 0.21	<u>93.13±</u> <u>1.13</u>	93.71 0.79
AA(%)	76.47± 1.62	76.13± 3.26	71.13±2.56	73.97± 2.06	90.18±1.31	89.20± 1.36	91.66± 0.19	90.10± 0.19	<u>92.53±</u> <u>0.69</u>	92.84 1.03
Kappa(%)	84.64± 1.62	82.75± 3.31	80.29±2.61	80.57± 4.33	89.99±1.63	89.07± 2.31	90.24± 0.19	88.81± 0.25	<u>91.87±</u> <u>2.44</u>	92.67 2.23



((a) Pseudo color image; (b) Label map; (c) MambaHSI; (d) S2Mamba; (e) DBMGNet; (f) SSFR; (g) SE Mamba)

图 7 不同模型在 HanChuan 数据集上的可视化结果

Fig. 7 Visualization results of different models on the HanChuan dataset

类别	GiGCN	CLONL	SpectralFormer	GSC-ViT	SpectralMamba	MambaHSI	S2Mamba	DBMGNet	SSFR	Ours
Red roof	90.93±2.64	95.36±5.56	96.66±1.63	98.16 1.08	96.37±0.62	96.47±1.50	96.03±0.39	<u>98.10±0.04</u>	96.73±1.01	96.90±0.57
Road	51.88±7.77	78.60±6.19	62.84±4.24	73.78±9.09	<u>97.40±1.32</u>	95.43±2.33	96.11±0.71	96.93±0.30	96.41±2.02	97.89 1.03
Bare soil	78.80±2.87	98.22 1.32	95.60±2.81	<u>97.21±1.81</u>	93.58±1.18	94.66±1.05	84.95±0.31	92.19±1.34	94.05±1.44	93.95±0.69
Cotton	99.37±0.32	99.48±0.37	99.42±0.30	99.57 0.14	97.82±1.65	96.96±1.79	95.43±1.10	95.12±0.45	98.97±0.60	<u>99.50±0.24</u>
Cotton firewood	62.41±8.43	41.33±18.92	42.14±16.25	37.03±9.33	<u>98.13±0.79</u>	96.20±1.77	96.42±0.85	96.19±0.26	97.70±1.48	98.62 1.17
Rape	89.61±3.17	96.09±1.07	95.73±1.02	95.72±1.83	94.16±1.75	93.90±2.47	92.03±0.60	96.89 0.55	95.81±1.98	<u>96.76±1.26</u>
Chinese cabbage	82.91±3.07	92.72 1.96	90.05±2.26	<u>90.38±3.66</u>	87.72±3.04	86.60±3.30	77.29±0.89	78.52±0.63	89.09±2.84	90.07±2.07
Pakchoi	75.44±8.66	46.44±6.02	35.59±5.04	32.12±4.83	<u>97.04±2.28</u>	96.08±2.90	79.23±0.97	85.33±0.76	97.46 2.66	96.52±2.94
Cabbage	85.39±3.04	97.04±2.05	97.89±1.07	97.06±2.73	96.76±1.44	94.78±1.69	99.05 0.14	95.87±0.34	96.91±1.42	<u>98.31±1.03</u>
Tuber mustard	92.42±2.80	84.88±3.47	78.81±4.58	79.23±7.53	93.35±2.25	90.45±2.72	89.62±0.99	89.38±0.59	<u>94.06±1.35</u>	95.52 1.70
Brassica parachinensis	75.17±4.50	72.03±8.35	69.29±7.09	72.41±8.95	91.82±3.30	91.96±2.87	93.75±0.67	83.20±0.85	<u>94.07±2.21</u>	94.56 2.57
Brassica chinensis	82.52±5.36	66.63±8.82	58.68±5.96	65.61±8.66	90.22±4.64	87.40±5.22	89.67±1.34	88.93±0.71	<u>91.00±4.20</u>	92.31 3.86
Small Brassica chinensis	89.28±2.70	82.67±5.83	76.20±6.07	77.49±8.47	90.24 3.02	89.12±3.12	87.32±1.48	71.76±1.04	<u>90.02±2.27</u>	89.43±2.41
Lactuca sativa	68.03±5.44	87.59±7.03	83.89±6.15	86.26±11.93	95.58±1.75	94.01±1.65	<u>96.49±0.56</u>	94.42±0.65	95.58±1.76	97.29 1.01

表 3 续表


类别	GiGCN	CLONL	SpectralFormer	GSC-ViT	SpectralMamba	MambaHSI	S2Mamba	DBMGNet	SSFR	Ours
Celtuce	21.65± 2.65	75.88± 12.93	61.24±13.37	63.62± 20.25	<u>99.69±0.73</u>	98.84± 1.17	99.81 0.12	99.24± 0.15	99.15± 0.80	99.78± 0.33
Film covered lettuce	71.70± 6.79	97.39± 1.73	95.23±2.99	97.42± 1.66	97.35±1.76	96.83± 1.60	99.49 0.30	97.16± 0.20	97.42± 1.85	<u>98.22±</u> <u>1.19</u>
Romaine let- tuce	54.94± 4.04	80.09± 9.70	68.68±8.79	84.92± 6.09	99.10 1.25	98.60± 1.49	98.05± 0.69	96.24± 0.23	98.65± 1.75	<u>98.91±</u> <u>1.58</u>
Carrot	67.65± 8.17	65.55± 15.89	60.99±7.01	67.44± 10.50	<u>98.47±0.98</u>	96.72± 1.82	<u>98.78±</u> <u>0.25</u>	99.50 0.22	98.43± 0.99	98.77± 0.82
White radish	72.71± 8.86	82.53± 7.23	82.77±4.78	85.10± 8.11	92.89±2.15	91.30± 3.07	<u>94.63±</u> <u>0.34</u>	<u>94.92±</u> <u>0.30</u>	93.68± 2.61	95.10 1.03
Garlic sprout	66.48± 6.47	81.38± 6.60	71.18±8.29	71.64± 10.46	99.42 0.63	99.18± 0.42	96.60± 0.60	98.95± 0.19	<u>99.25±</u> <u>0.48</u>	99.15± 0.62
Broad bean	65.20± 14.58	30.19± 12.06	28.91±8.18	25.92± 7.91	100.00 0.00	99.91± 0.18	<u>99.98±</u> <u>0.05</u>	99.01± 0.44	99.94± 0.19	99.88± 0.35
Tree	85.35± 8.84	55.02± 10.89	58.01±15.28	46.26± 11.15	99.64±0.37	99.54± 0.51	99.38± 0.21	95.36± 0.34	<u>99.86±</u> <u>0.34</u>	99.87 0.23
OA(%)	87.22± 0.60	87.93± 2.11	86.04±2.83	86.18± 1.86	95.41±1.07	94.58± 1.01	92.65± 0.53	92.28± 0.31	<u>96.31±</u> <u>0.39</u>	96.90 0.27
AA(%)	74.08± 1.50	77.60± 2.25	73.17±2.45	74.74± 1.64	95.76±0.61	94.77± 0.61	93.64± 0.19	92.87± 0.16	<u>96.10±</u> <u>0.36</u>	96.70 0.22
Kappa(%)	83.95± 0.73	85.06± 2.49	82.72±3.22	82.93± 2.16	95.05±1.57	94.00± 1.88	90.82± 0.64	90.35± 0.38	<u>95.76±</u> <u>1.30</u>	96.14 1.45

2.3.2 HanChuan 数据集

表 2 显示, SE-Mamba 的 OA 达 93.71%, 较第二名 SSFR 提升 0.58%, 显著优于 SpectralMamba (91.64%)、MambaHSI (90.21%) 等其他 Mamba 类模型。SE-Mamba 尤其在包含光谱特征高度相似类别

的农业场景中优势明显, 在 HanChuan 数据集的 Water Spinach 和 Sorghum 类别精度分别达 100.00% 和 98.93%, 且在 Soybean、Watermelon 等类别上性能稳定。整体的 AA 达 92.84%, 优于 SpectralFormer、GSC-ViT 等早期方法。

图 7 的定性结果表明, SE-Mamba 分类结果具有



((a) Pseudo color image; (b) Label map; (c) MambaHSI; (d) S2Mamba; (e) DBMGNet; (f) SSFR; (g) SE Mamba)

图 8 不同模型在 HongHu 数据集上的可视化结果

Fig. 8 Visualization results of different models on the HongHu dataset

表 4 Houston 数据集结果
Table 4 Quantitative result of Houston

类别	GiGCN	CLONL	SpectralFormer	GSC-ViT	SpectralMamba	MambaHSI	S2Mamba	DBMGNet	SSFR	Ours
Healthy Grass	83.21±5.03	88.24±9.00	91.29±5.38	90.16±6.48	93.72±5.13	95.20 4.66	93.28±0.05	<u>94.67±1.94</u>	94.10±4.09	94.00±4.26
Stressed Grass	82.83±7.41	93.41±5.99	92.12±6.99	95.77±2.95	95.68±1.86	98.29 1.26	97.35±2.71	<u>97.45±1.46</u>	97.12±1.53	95.66±1.45
Synthetic Grass	98.83±1.66	95.21±9.84	94.68±3.25	<u>99.83±0.26</u>	99.73±0.35	99.74±0.46	99.73±0.11	99.86 0.20	99.77±0.42	99.70±0.34
Tree	72.42±10.94	97.44±3.80	93.32±9.22	94.78±7.69	96.51±2.05	97.26±2.47	98.85 0.24	<u>98.26±1.71</u>	97.29±2.21	97.23±2.17
Soil	93.14±4.62	97.07±2.86	98.18±1.72	97.63±2.69	99.82±0.24	99.54±0.76	100.00 0.00	100.00 0.00	99.39±1.63	99.45±1.62
Water	88.99±6.78	94.85±4.72	87.21±8.11	96.03±2.59	96.95±2.94	97.47±2.33	92.07±0.79	100.00 0.00	<u>98.56±1.72</u>	98.18±1.87
Residential	82.34±5.24	94.02±2.94	91.47±3.54	93.11±2.39	93.46±2.97	93.03±2.25	92.00±1.57	89.27±2.16	<u>94.61±2.63</u>	94.65 1.85
Commercial	<u>91.02±6.25</u>	93.80 3.94	84.41±7.91	90.53±8.57	79.22±4.15	81.35±3.98	81.87±1.20	86.54±2.42	83.48±3.57	87.53±4.08
Road	85.51±6.43	88.32±2.83	87.75±3.83	85.20±4.96	91.19±3.18	90.03±3.40	89.86±0.56	87.05±2.58	<u>92.63±2.72</u>	93.89 2.12
Highway	94.92±2.69	76.55±6.96	82.09±5.12	85.28±4.22	97.63±2.07	96.55±1.49	94.13±0.88	96.88±2.86	<u>98.77±1.38</u>	99.15 1.22
Railway	96.52 3.78	91.57±4.40	85.90±4.63	93.08±3.33	93.85±2.66	92.74±2.18	93.40±4.64	94.31±3.52	<u>95.84±1.25</u>	95.25±2.90
Parking Lot 1	92.45±3.63	83.37±6.17	85.33±5.87	88.46±3.14	92.25±3.69	91.19±3.68	<u>95.38±0.52</u>	95.64 3.26	93.21±2.84	93.73±3.04
Parking Lot 2	88.10±5.13	89.11±4.64	86.81±6.28	90.01±4.69	96.34±2.47	97.67±2.04	98.30 1.55	95.50±0.15	97.09±2.54	<u>97.86±1.88</u>
Tennis Court	98.30±2.67	97.98±2.63	91.65±6.36	97.01±5.11	100.00 0.00	100.00 0.00	100.00 0.00	99.79±0.15	99.97±0.08	100.00 0.00
Running Track	99.14±1.89	96.08±3.96	96.18±2.66	97.73±1.23	96.76±1.29	100.00 0.00	100.00 0.00	100.00 0.00	96.45±2.63	95.84±2.30
OA(%)	88.13±2.26	90.31±4.73	89.13±2.12	91.85±1.05	94.11±0.80	94.46±0.83	94.44±0.47	94.83±0.87	<u>95.24±0.70</u>	95.57 0.87
AA(%)	89.85±1.91	91.80±1.46	89.89±1.74	92.97±0.92	94.87±0.79	95.34±0.78	95.08±0.42	95.68±0.69	<u>95.89±0.65</u>	96.14 0.79
Kappa(%)	87.16±2.44	89.52±1.87	88.24±2.29	91.18±1.14	94.00±0.80	94.21±1.93	93.99±0.51	94.41±0.94	95.36 1.79	<u>95.21±1.63</u>

更好的空间一致性,尤其在农业区域分类边界清晰、地物区域连续,有效抑制地物类别破碎化。这得益于SEFE、SSCM与HFR模块的协同作用,在充分挖掘空间信息和光谱关系的同时,帮助模型准确区分

地物边界,保持良好几何结构。

2.3.3 HongHu 数据集

表 3 结果进一步验证了SE-Mamba在复杂农业场景下的有效性,尤其在细粒度蔬菜分类中优势突

出。针对外观相似、光谱特征相近的 Tuber mustard 和 Brassica parachinensis, 模型精度分别达 95.52% 和 94.56%, 充分体现了模型对相似地物的区分能力。此外, OA 标准差仅 0.27%, 表明模型在多类别、大规模数据集上性能稳定, 抗干扰能力较强。

图 8 的定性结果显示, SE-Mamba 分类图与真实标签图差异小, 而 DBMGNet、SSFR 等方法在大面积同质区域存在明显误分。这表明 SE-Mamba 能优化空间-光谱特征融合, 有效保证区域像素标签一致性, 在易混淆农业场景中能维持地物类别连续性。

2.3.4 Houston 数据集

表 4 展示了 SE-Mamba 在复杂城市场景下的稳健性, 其 OA 和 AA 均取得最优结果, Kappa 系数虽为次优但与最优方法相当; OA 较 MambaHSI 提升 1.11%, 整体性能优于所有对比方法。在城市基础设施类别(如 Road、Highway 和 Parking Lot 2)上取得最高精度; 在区分 Healthy Grass 与 Stressed Grass 等光谱差异细微的地物时, 精度均超过 94%, 体现了模型的细粒度分类能力。

图 9 结果显示, SE-Mamba 可有效识别 Road、Highway 等细长区域, 且能清晰分离建筑物与阴影。

这充分验证了 SEFE、SSCM 在理解复杂空间布局方面的作用, 验证了框架在捕捉细粒度几何纹理与长程依赖关系方面的有效性。

2.3.5 整体性能对比

表 5 评估了 SE-Mamba 框架在四个 HSI 数据集上的整体表现, 综合验证模型的泛化能力与稳定性。结果显示, SE-Mamba 具有最高平均 OA (96.07%), 相较于基准模型 MambaHSI 提升 2.32%。尽管 DBMGNet (STD=±0.43%) 的标准差略低于 SE-Mamba (STD=±0.65%), 但 SE-Mamba 在不同场景下的精度提升幅度更为显著, 具有更好的泛化性。此外, 该模型在平均 AA (95.99%) 和 Kappa 系数 (95.51%) 上均保持最优, 进一步验证其在应对农业场景地物光谱相似性、城市场景结构复杂性时的稳健性。

综上所述, 空间增强特征提取器 (SEFE)、空间-光谱协同与融合模块 (SSCM 和 SSFM) 及高阶特征细化模块 (HFR) 的协同作用, 能有效缓解空间信息侵蚀与特征淹没问题, 显著提升模型分类性能与空间一致性, 验证了 SE-Mamba 整体架构设计的合理性。

表 5 四种高光谱数据集的性能比较

Table 5 Comparative Performance on Four HSI Datasets

指标	GiGCN	CLONL	SpectralFormer	GSC-VIT	SpectralMamba	MambaHSI	S2Mamba	DBMGNet	SSFR	Ours
OA(%)	89.15±1.31	89.59±2.06	87.31±2.46	88.46±2.29	93.60±1.41	93.75±1.10	93.74±0.34	93.70±0.45	95.64±0.73	96.07
AA(%)	83.33±1.53	84.77±2.13	78.53±2.36	83.39±1.59	94.02±0.94	93.79±0.97	94.60±0.24	94.07±0.33	95.68±0.53	95.99
Kappa(%)	87.11±1.51	87.68±2.38	82.16±3.13	86.27±2.65	93.29±1.77	93.07±2.09	92.52±0.40	92.49±0.53	95.28±1.76	95.51

2.4 消融实验

为评估 SE-Mamba 中各核心组件的单独贡献、模块间交互作用及协同价值, 明确“全流程空间增强”和“合理融合架构”的核心思想, 在四个数据集上开展了系统的消融实验, 结果汇总于表 6 中, 其中“w/o”表示移除指定的模块。实验通过量化消融实验相对完整框架性能下降的方式, 分析各组件的贡献及模块间交互机制。

1) 核心模块单独作用。

通过单独使用 SEFE、SSCM 和 HFR 说明各模块贡献: SEFE 在 HanChuan 和 HongHu 上提升更显著; SSCM 在 Houston 和 PaviaU 上表现更优; HFR 单独使用时性能提升明显小于前两者。结合数据集特点,

HanChuan 和 HongHu 光谱充足、地物紧密, SEFE 可通过补充空间信息改善分类; Houston 和 PaviaU 地物稀疏, SSCM 构建的长程空谱依赖更关键。HFR 位于网络末端, 需搭配其他模块才能充分发挥作用。

2) 核心模块协同作用及交互机制

结合各模块核心功能及数据集特点, 分析模块协同效果及交互机制, 发现协同作用呈现明显的场景差异化, 具体如下:

(1) SSCM+HFR 在 HanChuan、Houston 协同效果显著, 在 HongHu 和 PaviaU 上略逊于单独使用 SSCM。HanChuan 地物细微、边界模糊, 二者协同可实现“空谱融合-特征精修”的互补, 修复边界模糊问题; Houston 地物多样, 协同可优化空谱融合精度;

表 6 SE-Mamba 的消融实验结果

Table 6 The ablation experiment results of SE-Mamba

网络设置	HanChuan	HongHu	Houston	PaviaU
完整框架	93.71	96.90	95.57	98.10
SEFE	93.31 (-0.40)	96.33 (-0.57)	94.93 (-0.64)	96.92 (-1.18)
SSCM	92.73 (-0.98)	96.23 (-0.67)	95.24 (-0.33)	97.60 (-0.50)
HFR	92.14 (-1.57)	96.00 (-0.90)	94.08 (-1.49)	96.82 (-1.28)
w/o SEFE	93.02 (-0.69)	96.12 (-0.78)	95.33 (-0.24)	97.35 (-0.75)
w/o SSCM	92.95 (-0.76)	95.94 (-0.96)	95.00 (-0.57)	96.76 (-1.34)
w/o HFR	92.07 (-1.64)	95.92 (-0.98)	95.31(-0.26)	97.85(-0.25)
w/o SSFM	92.76 (-0.95)	96.24 (-0.66)	95.22 (-0.35)	97.49 (-0.61)
w/o SpeM	92.50 (-1.21)	96.90(-0.00)	95.40 (-0.17)	97.71 (-0.39)
w/o SpaM	93.08 (-0.63)	96.62 (-0.28)	95.43 (-0.14)	97.70 (-0.40)

HongHu、PaviaU 则因场景特性, HFR 的精修作用难以凸显, 协同增益不明显。

(2) SEFE+HFR 仅在 Houston 数据集表现更优, 其余三者无明显改善。Houston 地物稀疏多样, SEFE 提供的空间特征与 HFR 的精修功能协同, 可锐化地物边界; HanChuan、HongHu 地物密集, SEFE 已能保留充足空间细节, HFR 精修作用冗余; PaviaU 局部破碎化, 二者协同无法形成有效互补。

(3) SEFE+SSCM 在 Houston 和 PaviaU 协同效果明显, 但在 HanChuan 和 HongHu 出现性能下降。说明在地物稀疏的场景下, 二者特征互补可强化空谱关联; 而当场景光谱丰富、地物分布紧密时, 二者融合存在空间细节稀释、边界难以区分的问题, 印证了 HFR 在协同体系中的必要性。

(4) 当 SEFE、SSCM 与 HFR 三个模块协同使用时, 可构建“前端空间增强-空谱合理融合-后端特征精修”的全流程优化链路。三者各司其职、协同互补: SEFE 提供初始空间特征基础, SSCM 实现空谱特征精准整合, HFR 针对性修复协同过程中可能出现的空间细节稀释、边界模糊问题, 形成完整闭环。实验验证表明, 三者协同使用时, 在四个数据集上均取得最优分类性能, 显著优于两两协同及单独模块使用, 充分证明全流程协同可最大化发挥各模块优势, 印证了模型架构设计的科学性。

3) SSCM 内部子模块耦合分析

SSCM 由 SpeM、SpaM、SSFM 三个子模块共同组成, 其内部子模块的协同有效性可通过消融实验

证。从实验结果可以看出单独移除某个子模块的性能下降幅度, 均小于整个 SSCM 移除后的性能下降幅度, 这充分说明 SSCM 内部子模块之间协同紧密、功能互补, 整体作用大于单个子模块的单独作用。具体来看:

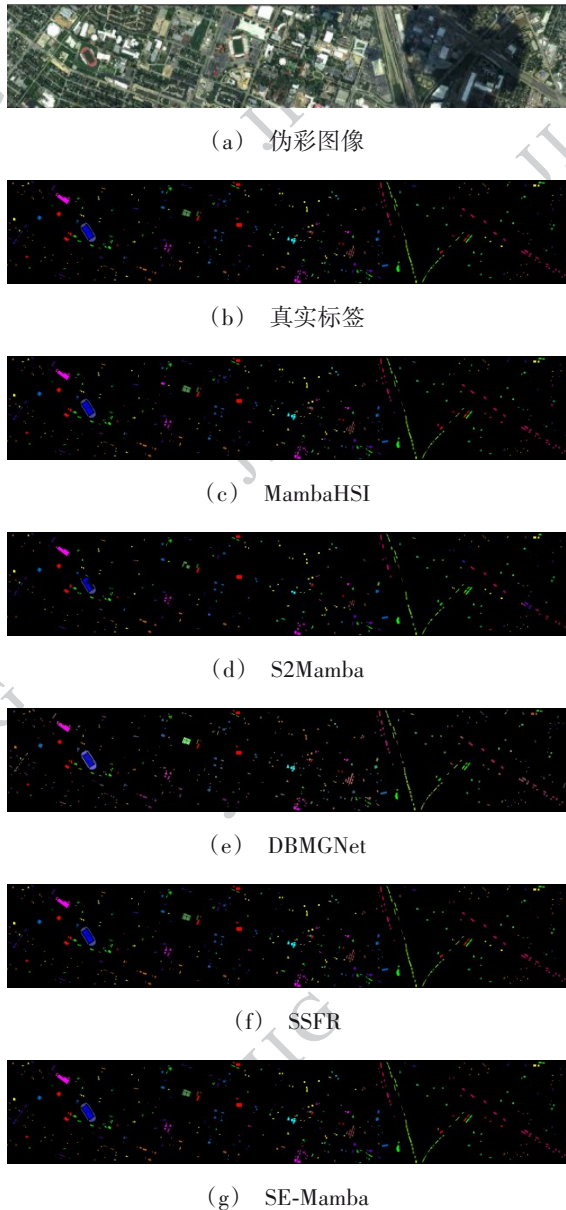
(1) 不使用 SSFM 时性能下降幅度(除 HanChuan 外)大于单独移除 SpeM 或 SpaM, 说明 SSFM 是 SSCM 的核心辅助融合模块, 功能不可替代;

(2) SSFM 搭配 SpaM 时, HanChuan 数据集性能下降最显著(-1.21%), 印证 SpeM 擅长挖掘光谱细微差异, 适配农业场景, 而 HongHu 数据集无明显下降, 因其地物分类更依赖空间边界判别;

(3) SSFM 搭配 SpeM 时, 各数据集均出现小幅性能下降, 说明在本文整体架构下, SpaM 仅起辅助空间强化作用, 核心空间增强仍依赖 SEFE 与 HFR。

(4) 为直观验证 SSFM 的空间细节增强能力, 在 PaviaU 数据集上开展可视化分析, 结果如图 10 所示。其中, 二值化权重图清晰展示了模型对边缘、道路等地物细节的关注区域。经权重强化后, 空间特征在道路及细碎地物区域的响应显著提升, 轮廓更加清晰, 有效弥补了原始特征中空间细节表达不足的问题。可视化结果直观证明, SSFM 能够通过自适应权重分配实现关键空间结构的精准增强, 进一步验证了所提空谱融合策略的有效性。

综上, SEFE、HFR 与 SSCM 功能定位清晰互补: SEFE 聚焦前端空间特征生成, SSCM 注重空谱协同融合, HFR 侧重后端特征精修, 三者协同紧密, 通过



((a) Pseudo color image; (b) Label map; (c) MambaHSI; (d) S2Mamba; (e) DBMGNet; (f) SSFR; (g) SE Mamba)

图9 不同模型在Houston数据集上的可视化结果
Fig. 9 Visualization results of different models on the Houston dataset

“前端-中间-后端”的全流程链路,实现“全流程空间增强”与“合理融合架构”的设计目标。SSCM内部子模块的紧密耦合的同时,进一步支撑了空谱融合的合理性,结合模块间交互机制的场景化分析,明确了各模块的核心价值及协同优化方向,为模型架构的精细化设计提供了充足的实验支撑。

2.5 模型效率分析

为全面评估SE-Mamba的计算效率与实际应用



((a) Spatial features; (b) Binary weight map; (c) Enhanced spatial features)

图10 SSFM模块空间特征、二值化权重图以及增强后空间特征在PaviaU数据集上的可视化结果

Fig. 10 Visualization results of spatial features, binary weight map, and enhanced spatial features in the SSFM module on the PaviaU dataset

潜力,本节从参数量、计算复杂度(GFLOPs)、训练时间及推理速度等维度进行对比分析,结果汇总于表7中。所有实验均在当前硬件环境下完成,其中Transformer类方法采用基于patch的训练范式,patch size设为8, batch size为128,其余超参数如总训练轮数等与Mamba类方法保持一致。

与基于Transformer的方法相比,Mamba系列模型在显著降低计算开销的同时获得更高分类精度;且得益于全图建模的方式,推理速度大幅提升,有效缓解了Transformer在高光谱图像分类中计算量大、推理缓慢的瓶颈。此外,在同类Mamba方法中,MambaHSI具有最低的GFLOPs与训练推理耗时;而本文SE-Mamba在精度与效率之间实现了更优的平衡。在参数量与SSFR相当的情况下,SE-Mamba取得了更具竞争力的分类性能,且单幅图像推理时间仅0.23秒,约为SSFR的四分之一,计算效率优势突出。

实验结果表明,SE-Mamba能够在保持高精度
© 中国图象图形学报版权所有

表 7 模型效率比较(基于 PaviaU 数据集)

Table 7 Comparison of Model Efficiency (Based on PaviaU Dataset)

方法	参数量(M)	计算复杂度 (GFLOPs)	训练时间(s)	推理时间(s)	OA(%)	AA(%)	Kappa(%)
GSC-ViT	0.15	2026.30	37.33	14.96	92.65	91.89	90.38
SpectralFormer	0.17	9086.19	86.73	11.15	91.10	79.93	77.40
MambaHSI	0.41	39.18	167.33	0.03	95.74	95.86	95.00
SSFR	0.85	101.72	461.24	0.94	97.88	98.19	98.12
Ours	0.89	140.34	234.57	0.23	98.10	98.28	98.00

分类性能的同时实现高效推理,具备可观的实际应用潜力与工程落地可能性。

3 结论

针对当前基于 Mamba 的高光谱图像分类方法中空间信息利用不足、特征融合不合理导致的空间信息侵蚀与特征淹没问题,本文提出空间信息增强型高光谱图像分类方法(SE-Mamba),聚焦空间视角,以空间信息有效引入与合理融合为核心,优化高光谱图像特征表示。在 HanChuan、HongHu、Houston 和 PaviaU 四个代表性数据集上的实验充分验证了其有效性,核心研究贡献如下:

1)构建全流程空间信息增强机制。针对 Mamba 序列化建模易丢失空间结构信息的问题,设计前端 SEFE 与后端 HFR 模块,通过多策略实现浅层到深层空间信息的持续强化与保持,二者协同为复杂场景分类精度提供关键支撑(消融实验验证,移除 HFR、SEFE 后核心数据集 OA 分别下降 1.64%、0.75%)。

2)提出空谱特征融合架构。设计 SSCM 模块,形成“解耦-校准-融合”完整流程,通过空谱双分支解耦与自适应权重分配缓解空间信息侵蚀,移除该模块后 PaviaU 数据集 OA 下降 1.34%,印证其作用。

3)实现分类精度与计算效率的良好平衡。对比实验表明,SE-Mamba 在四个数据集上平均 OA 达 96.07%,较 MambaHSI 提升 2.32%,各项评价指标均最优;效率分析证实,其参数量、计算复杂度与主流方法相当,推理速度更具优势,具备较强实际应用潜力。

尽管本文在基于 Mamba 的高光谱图像分类领域取得了一定进展,但未来工作仍存在可优化之处。

1)扫描策略优化:当前采用固定扫描方式,未来将探索“基于图像纹理复杂度动态选择扫描路径”的自适应机制,先通过纹理检测算法分析地物密度、边界清晰度等场景特征,再动态调整 Mamba 扫描策略,进一步强化极端复杂场景下的空间信息保持能力。

2)泛化性验证完善:依托现有四个数据集的泛化性基础,未来将适度引入更多不同气候、不同传感器的高光谱数据进行补充验证,进一步佐证 SE-Mamba 空间特征表征方法的通用性。

3)工程应用落地:在现有效率优势基础上,开展模型剪枝、量化等轻量化实验,优化模型部署性能,适配无人机、手持光谱仪等端侧设备,推动 SE-Mamba 从实验室走向实际遥感应用场景。

参考文献(References)

- Akewar M, and Chandak M B. 2024. Hyperspectral Imaging Algorithms and Applications: A Review. [DOI : 10.36227/techrxiv.24743562.v2]
- Cao L Q, Wang D, Xiong H Y and Zhong Y F. 2024. Review of information extraction methods from thermal infrared hyperspectral remote sensing images. *Journal of Image and Graphics*, 29(08):2089-2112 (曹丽琴,汪都,熊海洋,钟燕飞. 2024. 热红外高光谱遥感影像信息提取方法综述. *中国图象图形学报*, 29(08):2089-2112)[DOI: 10.11834/jig.230738]
- Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner, T, et al. 2021. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. [DOI: 10.48550/arXiv.2010.11929]
- Gu A, Dao T, and Tri D. 2023. Mamba: Linear-time sequence modeling with selective state spaces. [DOI: 10.48550/arXiv.2312.00752]
- 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.]
- He Y, Tu B, Jiang P Z, Liu B, Li J, and Plaza A. 2024. IGroupSS-Mamba: Interval Group Spatial - Spectral Mamba for Hyperspectral Image Classification. IEEE Transactions on Geoscience and Remote Sensing, 62 (1) : 1-17. [DOI: 10.1109/TGRS. 2024. 3502055]
- Hong D F, Han Z, Yao J, Gao L R, Zhang B, Plaza A, et al. 2021. SpectralFormer: Rethinking hyperspectral image classification with transformers. IEEE Transactions on Geoscience and Remote Sensing, 60(1): 1-15.[DOI: 10.1109/TGRS.2021.3130716.]
- Hu W, Huang Y Y, Wei L, Zhang F, and Li H C. 2015. Deep convolutional neural networks for hyperspectral image classification. Journal of Sensors, 2015(1): 258619.[DOI:10.1155/2015/258619]
- Jia S, Jiang S, Zhang S, Xu M, and Jia X. 2022. Graph-in-graph convolutional network for hyperspectral image classification. IEEE Transactions on Neural Networks and Learning Systems, 35(1): 1157-1171.[DOI: 10.1109/TNNLS.2022.3182715]
- Le Roux N, and Bengio Y. 2008. Representational power of restricted Boltzmann machines and deep belief networks. Neural Computation, 20(6): 1631-1649. [DOI: 10.1162/neco.2008.04-07-510]
- Li C, Rasti B, Tang X, Duan P, Li J, and Peng Y. 2024. Channel-layer-oriented lightweight spectral - spatial network for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 62: 1-14.[DOI: 10.1109/TGRS.2024.3350055]
- Li S T, Song W W, Fang L Y, Chen Y S, Ghamisi P, and Benediktsson J A. 2019. Deep learning for hyperspectral image classification: An overview. IEEE Transactions on Geoscience and Remote Sensing, 57(9): 6690-6709.[DOI: 10.1109/TGRS.2019.2907932]
- Li Y P, Luo Y, Zhang L F, Wang Z M, and Du B. 2024. MambaHSI: Spatial-spectral mamba for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, (1): 1-12. [DOI: 10.1109/TGRS.2024.3430985]
- Lin T Y, Wang Y X, Liu X Y, and Qiu X P. 2022. A survey of transformers. AI Open, 3(1): 111-132.[DOI: 10.1016/j.aiopen.2022.10.001]
- Mei S H, Song C, Ma M Y, and Xu F L. 2022. Hyperspectral image classification using group-aware hierarchical transformer. IEEE Transactions on Geoscience and Remote Sensing, 60(1): 1-14. [DOI: 10.1109/TGRS.2022.3207933]
- Melgani F, and Bruzzone L. 2004. Classification of hyperspectral remote sensing images with support vector machines. IEEE Transactions on Geoscience and Remote Sensing, 42(8): 1778-1790. [DOI: 10.1109/TGRS.2004.831865]
- Obermeier W A, Lehnert L W, Pohl M J, Gianonni S M, Silva B, Seibert R, et al. 2019. Grassland ecosystem services in a changing environment: The potential of hyperspectral monitoring. Remote Sensing of Environment, 232(1): 111273. [DOI: 10.1016/j.rse.2019.111273]
- Tao Y, Yu D B, Wang Y B, Wang Y, Xiao J, and Liu L P. 2025. Effective Spatial-Spectral Feature Representation for Hyperspectral Image Classification. IEEE Transactions on Geoscience and Remote Sensing, (Accepted for publication) : 1-18. [DOI: 10.1109/TGRS.2025.3628253]
- Wang G, Zhang X, Peng Z, Zhang T, and Jiao L. 2025. S2mamba: A spatial-spectral state space model for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, (Accepted for publication). [DOI: 10.1109/TGRS.2025.3530993]
- Wang H, Zhuang P X, Zhang X C, and Li J Y. 2025. DBMGNet: A Dual-Branch Mamba-GCN Network for Hyperspectral Image Classification. IEEE Transactions on Geoscience and Remote Sensing, (1): 1-16. [DOI: 10.1109/TGRS.2025.3564364]
- Wang Y B, Liu L P, Xiao J, Yu D B, Tao Y, and Zhang W. N. 2025. MambaHSI+ : Multidirectional State Propagation for Efficient Hyperspectral Image Classification. IEEE Transactions on Geoscience and Remote Sensing, 63(1): 1-15. [DOI: 10.1109/TGRS. 2025.4411414]
- Xia J S, Chanussot J, Du P J, and He X Y. 2014. Spectral-spatial classification for hyperspectral data using rotation forests with local feature extraction and Markov random fields. IEEE Transactions on Geoscience and Remote Sensing, 53(5): 2532-2546. [DOI: 10.1109/TGRS.2014.2361618]
- Xu R, Yang S, Wang Y H, Cai Y, Du B, and Chen H. 2024. Visual mamba: A survey and new outlooks. [DOI: 10.48550/arXiv.2404.18861]
- Xu Y H, Du B, and Zhang L P. 2019. Beyond the patchwise classification: Spectral-spatial fully convolutional networks for hyperspectral image classification. IEEE Transactions on Big Data, 6(3): 492-506. [DOI: 10.1109/TBDATA.2019.2923243]
- Yao J, Hong D F, Li C Y, and Chanussot J. 2024. Spectralmamba: Efficient mamba for hyperspectral image classification. [DOI: 10.48550/arXiv.2404.08489]
- Zhang L P, and Du B. 2012. Recent advances in hyperspectral image processing. Geo-spatial Information Science, 15(3): 143-156. [DOI: 10.1080/10095020.2012.719684]
- Zhao Z Y, Xu X, Li S T, and Plaza A. 2024. Hyperspectral image classification using groupwise separable convolutional vision transformer network. IEEE Transactions on Geoscience and Remote Sensing, (1): 1-14. [DOI: 10.1109/TGRS.2024.3377610]
- Zhu Q Q, Deng W H, Zheng Z, Zhong Y F, Guan Q F, Lin W H, et al. 2021. A spectral-spatial-dependent global learning framework for insufficient and imbalanced hyperspectral image classification. IEEE Transactions on Cybernetics, 52(11): 11709-11723. [DOI: 10.1109/TCYB.2021.3070577]

作者简介

肖岱峰,男,博士研究生,主要研究方向为遥感图像解译及三
© 中国图象图形学报版权所有

维目标检测。E-mail: xiaodaifeng21@mails.ucas.ac.cn

于东伯, 男, 博士, 主要研究方向为计算机视觉、遥感图像表
征、点云处理及三维重建与感知。E-mail: yudongbo@ucas.ac.
cn

王颖, 女, 教授, 博士生导师, 主要研究方向为计算机视觉、大
数据分析及工程计算可视化。E-mail: ywang@ucas.ac.cn

肖俊, 男, 教授, 博士生导师, 主要研究方向为计算机视觉、图
形图像处理及AI+交叉学科。E-mail: xiaojun@ucas.ac.cn