Vol. 47 No. 4

DOI: 10. 13718/j. cnki. xdzk. 2025. 04. 018

苏谦,范永胜,桑彬彬,等.一种全局空间特征提取的深度网络高光谱解混方法 [J].西南大学学报(自然科学版),2025,47(4):204-214.

一种全局空间特征提取的深度网络 高光谱解混方法

苏谦, 范永胜, 桑彬彬, 徐敏靖

重庆师范大学 计算机与信息科学学院,重庆 401331

摘要:针对现有高光谱解混方法提取全局上下文信息不充分、光谱空间特征之间的融合也会丢失全局信息,进而 导致获取地表信息不准确的现状,提出一种运用双分支网络来提升解混性能的方法。该方法通过3个模块完成解 混任务:首先在空间特征提取模块中使用 Swin Transformer 对全局空间上下文信息进行建模;然后与三维卷积构 建的光谱模块提取的光谱信息进行融合;最后运用光谱空间自注意力残差模块对光谱空间特征进行分析。通过相 同高光谱数据集上的土壤、树、水、路4种要素对该方法进行验证,并与 DAEU、CyCU-Net、DeepTeans、MSNet、 DAAN 5 种方法的实验数据进行对比,结果表明:在 Samson 数据集上,该方法比上述 5 种方法在丰度估计上平均 提升了 18.31%,在端元提取上平均提升了 2.00%;在 Jasper Ridge 数据集上,丰度估计平均提升了 2.70%,端元 提取平均提升了 8.24%。

关 键 词:高光谱解混;全局信息;双分支网络;自注意力
 中图分类号:TP751 文献标志码:A
 文 章 编 号: 1673-9868(2025)04-0204-11



开放科学(资源服务)标识码(OSID):

A Deep Network Hyperspectral Unmixing Method with Global Spatial Feature Extraction

SU Qian, FAN Yongsheng, SANG Binbin, XU Minjing

College of Computer and Information Science, Chongqing Normal University, Chongqing 401331, China

Abstract: Aiming at the current situation that the existing hyperspectral unmixing methods do not extract enough global context information, and the fusion between spectral and spatial features could also lose global information, which will lead to inaccurate land surface information, a method using a double-branch network to improve the unmixing performance was proposed in this paper. The unmixing task had been completed by this method through three modules. Firstly, the Swin Transformer was used to model the global spatial context information in the spatial feature extraction module. Then, the model was fused

基金项目:国家自然科学基金项目(62306054)。

作者简介:苏谦,硕士研究生,主要从事计算机视觉高光谱解混研究。

通信作者:范永胜,博士,副教授。

with the spectral information extracted by the spectral module constructed by 3D convolution. Finally, the spectral spatial self-attention residual module was used to analyze the spectral spatial features. The proposed method was verified by four elements of soil, tree, water and road on the same hyperspectral data set, and compared with the experimental data of five methods: DAEU, CyCU-Net, DeepTeans, MSNet and DAAN. On the Samson dataset, the proposed method had an average increase of 18.31% in abundance estimation and 2.00% in endmember extraction compared with the above five methods. On the Jasper Ridge dataset, the average increase was 2.70% in abundance estimation and 8.24% in endmember extraction.

Key words: hyperspectral unmixing; global information; double-branch network; self-attention

高光谱图像是一种通过在大量连续波长范围内采集数据来获取物体表面光谱信息的图像,因其具有丰富的光谱信息,能更精准识别其他图像无法区分的细微材料。地表相关信息对农业生产具有重大意义,其研究需要运用高光谱图像,例如适宜的土壤能够生产出更加优质的烟草^[1-2]和茶叶^[3],不同的土壤能够让辣椒产生不同的营养和风味品质^[4],精准的陆面资料能够降低地区天气和降水的模拟误差^[5],生态系统碳储存功能与景观格局变化有着极大相关性^[6]等。然而高光谱图像具有空间分辨率较低,图像中普遍存在混合像元的问题,因此对下游任务的开展将带来不利影响。高光谱解混技术的研发,其目的就是将高光谱图像中高度混合的像元分解成纯物质的光谱(即端元)和纯物质所占像元的比例(即丰度)。高光谱解混技术的大量研究和应用主要基于2个不同的混合模型,即线性和非线性混合模型^[7]。线性混合模型假设入射光只与一种物质产生作用,其混合光谱可以表示为纯物质光谱的线性组合。非线性混合模型考虑到了多种物体之间的多次反射,更符合实际情况,但面临着缺乏适当的非线性程度以及先验知识相关方面的挑战。

随着大数据时代的来临,深度学习迅速发展,并已用于高光谱解混任务中[8]。与传统的解混方法相 比,深度学习可以在任意网络结构组合以及非线性结构上实现,具有更高的适用性与灵活性。自动编码 器(Auto Encoder, AE)是高光谱解混方法中典型的基于深度学习方法的基本网络结构,其主要分为编码 器和解码器 2 个部分。编码器主要用于提取隐藏层的低维特征来进行丰度估计,解码器主要用于将低维 特征重构为原始输入数据并获得端元矩阵。目前,已经有学者提出许多基于 AE 方法的变体。例如: Palsson 等^[5]提出了一种深层 AE 来进行高光谱解混,并验证了不同激活函数对 AE 的作用; Shi 等^[10]针 对现有方法对光谱变异性建模能力的不足,提出了一个概率生成模型来解决端元变异性问题,并通过神 经网络的非线性建模功能来拟合任意端元分布,进而提供更准确的丰度和端元估计。然而,高光谱图像 中的相邻像素间往往表现出高度的空间相关性,上述方法并没有充分考虑空间信息。因此, Palsson 等[11]提出了一种基于卷积 AE 的解混方法,该方法直接使用高光谱图像块,并且不使用任何池化或上采 样层,因此始终保留了图像的空间结构。Yu 等^[12]受感受野机制和多级框架有效性的启发,提出了一种 用于高光谱解混的多级卷积 AE 网络,能够通过卷积 AE 在逐步多级分解过程中学习广泛的上下文信息 而不丢失细节特征。过去也有一些学者尝试解决这些问题,例如 Ghosh 等^[13]将卷积 AE 与 Transformer 相结合,提出了一种新颖的基于深度神经网络的 Transformer 高光谱解混模型,使 Transformer 在视觉领 域中建模全局上下文信息得到成功应用^[14]。但目前大多数基于 AE 的解混方法都是纯粹基于卷积神经 网络(Convolutional Neural Network, CNN)提出的,而 CNN 又受卷积核大小的限制,容易丢失原始图像 中的大量上下文信息,使其在处理高光谱图像的复杂性问题上面临较大的挑战。

近年来,许多学者也通过 Swin Transformer 和三维 CNN 的结合来进行光谱信息处理,例如 Ma 等^[15] 使用 Transformer 代替 CNN 来学习 HSI(Hyperspectral Image)的先验,然后在 Transformer 层后面添加 了三维 CNN 探索 HSI 的空间光谱相关性,使得在 2 个广泛使用的 HSI 数据集和真实世界数据集上实现了 相当大的增益。Farooque 等^[16]提出了一种以处理 HSI 立方体作为输入,并采用涉及具有不同 Atrous 速率 的三维层并行分支光谱空间特征提取模块的方法,该方法能够以多种尺度和分辨率提取特征,并在多个 HSI 数据集上取得一定的优越性。但是使用 Swin Transformer 和三维 CNN 结合的方法依然是针对 HSI 的 2 种特征进行直接融合或拼接,对于深层融合时出现的特征冗余现象的处理存在一定不足。

为此,本文提出一种综合考虑全局上下文信息的双分支网络结构,其中空间特征提取模块利用 Swin Transformer 建模全局空间上下文信息^[17],光谱特征提取模块利用三维 CNN 进行光谱信息的建模,而光 谱空间自注意力模块进一步提取全局深度融合的上下文信息,最后在2个真实数据集上通过消融实验和对 比实验进行验证。

模型与原理 1

1.1 线性混合模型

对于线性混合模型,高光谱图像解混的过程可以根据如下公式进行表示:

$$Y = MA + N \tag{1}$$

式中: $Y \in \mathbf{R}^{L \times N}$ 为包含 L 个波段和 N 个像素的被观测到的高光谱图像; $M \in \mathbf{R}^{L \times p}$ 为端元矩阵, 其中端 元矩阵的每一列表示 1 个端元的光谱; $A \in \mathbb{R}^{p \times N}$ 为相应的丰度矩阵; $N \in \mathbb{R}^{L \times N}$ 为添加的噪声向量。此 外, 丰度矩阵代表每个像元中各个端元所占的比例, 所以丰度矩阵需要同时满足丰度和为一约束 (Abundance Sum-to-one Constraint, ASC) 和丰度非负约束(Abundance Nonnegativity Constraint, ANC), 相应的公式如下:

$$\begin{cases} a_i \ge 0, \ \forall i \\ \sum_{j=1}^p a_{i,j} = 1 \end{cases}$$

$$\tag{2}$$

式中: a_i 为第i个像素; $a_{i,j}$ 为第j个端元在第i个像素中所占的比例;p为端元数目。

1.2 基于 AE 解混的原理

基于 AE 的结构因适合于解混任务而被广泛 应用。如图1所示,编码器部分(Encoder)用来对 原始高光谱图像提取图像特征,同时将高维的数 据转换成位于隐藏层的低维特征。解码器部分 (Decoder)则通过学习隐藏层的低维特征来重构高 光谱数据。利用原始高光谱数据和重建高光谱数 据之间的误差可以很好地训练 AE。其中, 隐藏层 的低维特征 A 代表丰度矩阵, 解码器部分的权重 M 代表端元矩阵。

此外,基于 AE 的解混方法通常使用 ReLU 激活函数和 Softmax 激活函数来满足 ASC 和 ANC, 相应的公式如下:

$$\operatorname{ReLU}(x) = \max(0, x) \tag{3}$$

Softmax(x) =
$$\frac{e^{a_{i,j}}}{\sum_{j=1}^{p} e^{a_{i,j}}}$$

(4)

双分支网络模型 2

双分支网络模型能够解决现有高光谱解混方法的不足之处,它既能充分保留原始上下文信息,又能有 效避免卷积核过小的问题。下面分别介绍其网络结构以及所采用的损失函数。

2.1 网络结构

与常规 AE 一样,本文的方法主要包括编码和解码 2 部分。图 2 呈现了所提出的高光谱双分支网络 (Hyperspectral Double-branch Network, HDN)整体架构。首先,编码部分通过双分支网络结构获得光谱 和空间特征,这部分将在第2.2节中详细阐述。随后是光谱空间自注意力模块 SSSAM(Spectral Spatial Self-attention Module),将在2.3节中详细阐述。通过引入空间特征提取模块和光谱特征提取模块,该网



络能够同时获取光谱和空间上下文信息,并通过自注意力模块 SSSAM 进一步提升全局上下文信息的建模 能力。最后,解码部分使用简单的 1×1 卷积进行维度调整以获取重构的输入。



图 2 HDN 网络架构

2.2 双分支特征提取模块

与其它图像不同,高光谱图像可理解为一个三维图像,其中包括空间维度与光谱维度。现有方法针对 AE进行较多改进,但都是基于二维卷积来考虑空间信息从而忽略了光谱维度的信息,这就对解混性能造成负面影响。受Yu等^[12]以多尺度信息为基础提出一种多级卷积 AE 思路的启发,本文提出一种双分支网络结构(图 3),该网络结构将同时考虑高光谱图像的空间信息和光谱信息。



图 3 双分支网络结构

如图 3a 所示,本文利用 Swin Transformer 作为双分支网络结构中的空间特征提取模块,该模块以整 个高光谱图像作为输入并将其划分成若干个不重叠的令牌补丁,然后这些令牌补丁经过若干次重复的 Transformer Blocks 以进行空间信息长程相关性建模,最后重塑维度得到与丰度图相同的尺寸。

如图 3b 所示,对于光谱信息提取模块,本文使用 1×1×3 的三维卷积进行光谱信息提取,每个三维卷 积后使用 Leaky_ReLU 激活函数以及最大池化,最后使用 1 个 1×1 的二维卷积将通道数调整至对应数据

集的端元数量。第 i 层和第 j 层特征图神经元值的具体公式如下:

$$u_{i,j}^{x,y,z} = g\left(\sum_{\tau=1}^{a_{l-1}}\sum_{\lambda=-\eta}^{\eta}\sum_{\beta=-\rho}^{\rho}\sum_{\alpha=-\gamma}^{\gamma}w_{i,j,\tau}^{\alpha,\beta,\lambda} \times v_{i-1,\tau}^{x+\alpha,y+\beta,z+\lambda} + b_{i,j}\right)$$
(5)

式中: g 为激活函数; $w_{i,j,\tau}$ 为第 $i \in \mathbb{R}$ 层和第 $j \in \mathbb{R}$ 层特征图中权重参数的值; $b_{i,j}$ 为对应的偏置, d_{i-1} 为特征图的数量。通过 $2\rho + 1$ 、 $2\gamma + 1$ 以及 $2\eta + 1$ 可分别计算卷积核的宽、高与深度。

2.3 光谱空间自注意力模块

近年来,注意力网络能够帮助网络模型减少特征的冗余,使模型更加聚焦于重要的目标区域,所以 在计算机视觉领域应用广泛。考虑到高光谱图像的波段数量较多且普遍存在波段信息冗余的问题,以及 传统 Self-attention 虽能进行不同空间位置的特征交互,但大多数仍通过计算(query, keys, value)三元组 的交互获得全局注意力信息,这并没有考虑相邻键值对之间的丰富上下文信息,因此本文将上下文信息 与 Self-attention 的学习结合在一起,形成光谱空间自注意力模块,如图 4 所示。



图 4 光谱空间自注意力模块

由图 4 可知,该模块首先经过 2 个 3×3 卷积核进行空间信息提取,同时卷积核使用批归一化(BN)和 ReLU激活函数。此外,为防止梯度爆炸或梯度消失的问题,本文引入残差连接以帮助网络训练。接着通过 3×3 卷积核对上下文进行编辑以获取相邻图像的局部信息,随后与原输入进行通道维度的拼接操作。进一 步经过 1 个 1×1 卷积学习多头注意力矩阵,再进行 Softmax 操作以得到注意力权重矩阵 *A*,此时 *A* 中每 个空间位置都考虑到了全局特征。权重矩阵 *A* 再与 Value Map 进行 Self-attention 计算,获得图像全局信 息,以实现输入的动态上下文表示。最后将所得的局部信息与全局信息进行相加融合,得到了对突出点着 重关注的输出特征。

2.4 损失函数

光谱角距离(Spectral Angular Distance, SAD)是尺度不变的目标函数,因而使用光谱角距离作为网络 损失函数的第1项,其公式如下:

$$L_{\text{SAD}}(I, \tilde{I}) = \sum_{i=1}^{p} \arccos\left(\frac{\langle I_i, \tilde{I}_i \rangle}{\|I_i\|_2 \|\tilde{I}_i\|_2}\right)$$
(6)

式中: I_i 和 \hat{I}_i 分别为原始高光谱数据和模型所重建的高光谱数据; p 为数据个数。

光谱角距离虽有利于端元的提取,但没有考虑到丰度估计的偏差,所以第2项损失使用均方误差 (Mean Square Error, MSE),其公式如下:

$$L_{\rm Re} = \sum_{i=1}^{p} \| I_i - \tilde{I}_i \|^2$$
(7)

总损失为这2项损失的加权和,即:

$$L = L_{\rm SAD} + \partial L_{\rm Re} \tag{8}$$

式中: ∂ 为权重系数,用于控制 2 项损失函数之间的平衡。

208

3 实验与分析

3.1 实验设置

实验中训练模型使用的处理器型号为 Intel Core i9-13900HX,显卡为 8 GB 的 RTX4060。本方法模型 使用 Python 3.7 和 PyTorch 1.11 深度学习框架进行编写,其训练参数如表 1 所示。

数据集	优化器	9	学习率	迭代次数	丢失率
Samson	Adam	0.1	0.030	800	0.2
Jasper Ridge	Adam	0.1	0.001	800	0.2

表1 训练参数

3.2 高光谱数据集描述

1.0

0.8

0.6

0.4

0.2

0

0

20

40

60

反射比

实验中使用的高光谱数据集描述如下:

1) Samson 数据集: 原始高光谱数据的空间分辨率为 952×952,为了便于实验分析,从原始图像的第(252,332)个像素开始,该数据集在第 100 个通道的可视化如图 5a 所示,真实端元曲线可视化 如图 5c 所示。

2) Jasper Ridge 数据集: 原始高光谱数据有 512×614 个像素,同样为了便于实验分析,从原始图像的第(105,269)个像素开始,去除易受密集水蒸气及大气影响的波段通道: 1~3、108~112、154~166 和 220~224,该数据集在第 100 个通道的可视化如图 5b 所示,真实端元曲线可视化如图 5d 所示。

本实验的其他详细参数如表 2 所示。





b. 第100个通道的Jasper Ridge数据集

a. 第100个通道的Samson数据集



c. Samson数据集的真实端元

80

波长/mm

100

120

140

图 5 数据集信息可视化

d. Jasper Ridge数据集的真实端元

	*	2 间九省奴加来油处		
数据集	选用分辨率	端元	波长/nm	波段数
Samson	95×95	土壤、树、水	401~889	156
Jasper Ridge	100×100	土壤、树、水、路	$512 \sim 2\ 500$	198

古业逆新招佳世法

3.3 评估指标

为了评估解混性能,该领域常常使用以下4个指标进行评估:均方根误差 E_{RMSE} 、光谱角距离 D_{SAD} 、平均均方根误差 A_{RMSE} 与平均光谱角距离 A_{SAD} 。 E_{RMSE} 与 A_{RMSE} 越低表示模型估计的丰度图更准确, D_{SAD} 与 A_{SAD} 越低表示模型提取的端元更准确,其表达式如下:

$$\begin{cases} E_{\text{RMSE}j} = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (\stackrel{\wedge}{a}_{i,j} - a_{i,j})^2} \\ A_{\text{RMSE}} = \frac{1}{p} \sum_{j=1}^{p} E_{\text{RMSE}j} \\ D_{\text{SAD}i} = \arccos\left(\frac{e_i^{\text{T}} \stackrel{\bullet}{e}_i}{\parallel e_i \parallel \parallel \stackrel{\wedge}{e}_i \parallel}\right) \\ A_{\text{SAD}} = \frac{1}{p} \sum_{p=1}^{p} D_{\text{SAD}i} \end{cases}$$
(9)

式中: $\hat{a}_{i,j}$ 和 $a_{i,j}$ 分别为第i个像元中第j个端元的丰度估计比例和真实丰度估计比例; N 为像元的数量; p为端元数量; \hat{e}_i 和 e_i^{T} 分别为模型提取的端元和数据集的真实端元。

指标值

3.4 消融实验

为了验证本方法提出模型中各个模块的有效性,在Samson数据集上进行消融实验。将本 文提出的模型拆分为:仅使用空间特征提取模 块、仅使用光谱特征提取模块、仅使用双分支 模块(空间特征+光谱特征提取模块),并与本 文最终的模型(空间特征+光谱特征提取模块 +光谱空间自注意力残差模块)进行对比,结果 如图 6 所示。

在图 6 中, 横坐标表示各个模块, 纵坐标 表示综合衡量指标数值, 本文将平均均方根误 差 A_{RMSE} 和平均光谱角距离 A_{SAD} 作为衡量指 标,可以看出仅使用光谱特征提取模块或空间 特征提取模块因提取的特征信息不够充分, 其



图 6 Samson 数据集上的消融实验结果

表现不佳。当使用双分支模块进行联合信息提取时,解混性能得到了一定改善。当所有模块进行组合时, 本文的方法获得了最好的结果,进而证明了本文方法的有效性。

3.5 定量结果分析

本文选用 5 种深度学习方法进行对比实验,然后对结果进行定量分析,验证本文提出方法的有效性,包括:DAEU^[9]、CyCU-Net^[18]、DeepTrans^[13]、MSNet^[12]、DAAN^[19]。DAEU采用全连接层构建 AE, Cy-CU-Net 级连了 2 个卷积 AE, DeepTrans 将 transformer 模型引入基于卷积编码器的解混方法中,MSNet 采用多阶段卷积神经网络用于解混,DAAN则是一种基于去噪的深度 AE 增强网络。此外,上述方法均使用顶点成分分析(Vertex Component Analysis, VCA)^[20]来初始化端元矩阵。

3.5.1 Samson 数据集的实验结果分析

上述 5 种深度学习方法和本文提出的方法在 Samson 数据集上的定量分析结果如表 3 所示。根据表 3

的数据可以看出,本文提出的方法在土壤、树、水3种要素的丰度估计上分别最高提升了38.89%、28.57%、4.41%,端元提取上分别最高提升了3.51%、33.33%、6.90%。图7显示了所有方法在Samson数据集上的端元提取结果,其中图7a、7b、7c分别对应于端元:土壤、树、水。从图中的走势分析可知,在不同的波段上各方法均有一定的差异,但只有本文提出方法得到的整体结果最接近真实标签(GT)。图8为所有方法在Samson数据集上的丰度估计结果可视化图,可以看出本文提出方法的效果也与GT最为接近。

表 3 所有方法在 Samson 数据集上的定量结果对比

评估指标	端元	DAEU	CyCU-Net	DeepTrans	MSNet	DAAN	本文方法
$E_{\rm RMSE}$	土壤	0.108	0.172	0.072	0.206	0.087	0.044
	树	0.091	0.139	0.093	0.142	0.056	0.065
	水	0.069	0.152	0.116	0.098	0.068	0.065
$A_{\rm RMSE}$		0.089	0.154	0.094	0.149	0.071	0.058
$D_{ m SAD}$	土壤	0.057	0.066	0.011	0.220	0.058	0.055
	树	0.057	0.112	0.059	0.032	0.071	0.038
	水	0.084	0.058	0.084	0.080	0.019	0.054
$A_{\rm SAD}$		0.066	0.079	0.051	0.111	0.050	0.049





1.0

0.8

0.6

0.4

0.2

0 L

20

40 60

反射比







图 7 所有方法在 Samson 数据集上的端元提取结果对比

80

波长/mm c. 水

100

120 140



图 8 所有方法在 Samson 数据集上的丰度估计结果对比

3.5.2 Jasper Ridge 数据集的实验结果分析

在 Jasper Ridge 数据集上的定量分析结果如表 4 所示。根据表 4 的数据可以看出,本文提出的方法在 土壤、树、水、路 4 种要素的丰度估计上分别最高提升了 12.98%、25.00%、11.43%、19.21%,端元提取 上分别最高提升了 7.69%、39.22%、8.45%、2.70%。图 9 显示了所有方法在 Jasper Ridge 数据集上的端 元提取结果,其中图 9a、9b、9c、9d 分别对应于端元:土壤、树、水、路。从图中的走势分析可知,本文提 出方法得到的整体结果最接近 GT。图 10 为所有方法在 Jasper Ridge 数据集上的丰度估计结果可视化图, 可以看出本文提出方法的效果也与 GT 最为接近。

评估指标	端元	DAEU	CyCU-Net	DeepTrans	MSNet	DAAN	本文方法
$E_{\rm RMSE}$	土壤	0.103	0.160	0.131	0.163	0.140	0.114
	树	0.096	0.103	0.115	0.082	0.118	0.072
	水	0.144	0.140	0.151	0.153	0.100	0.124
	路	0.151	0.194	0.195	0.077	0.094	0.122
$A_{\rm RMSE}$		0.124	0.111	0.148	0.119	0.113	0.108
$D_{ m SAD}$	土壤	0.093	0.078	0.065	0.092	0.068	0.072
	树	0.069	0.123	0.051	0.071	0.103	0.031
	水	0.154	0.131	0.071	0.096	0.161	0.065
	路	0.148	0.156	0.151	0.121	0.056	0.144
$A_{ m SAD}$		0.116	0.122	0.085	0.095	0.097	0.078

表 4 所有方法在 Jasper Ridge 数据集上的定量结果对比

4 结论

针对深度神经网络方法在高光谱图像解混研究中的不足,本文提出了一种结合二维和三维卷积的双分 支网络模型,以提升解混性能。该网络模型包含3个模块,首先通过Swin Transformer 构建的空间模块和 三维卷积构建的光谱模块分别进行高光谱图像空间特征和光谱特征的提取,然后通过光谱空间自注意力残 差模块进行空间特征和光谱特征的深度融合以获得联合特征信息。在Samson数据集和Jasper Ridge数据 集上进行实验,以验证模型的有效性。采用均方根误差 E_{RMSE}、光谱角距离 D_{SAD}、平均均方根误差 A_{RMSE} 与 平均光谱角距离 A_{SAD} 作为评估指标,结果表明在丰度估计上分别平均提升了18.31%与2.70%,在端元提 取上分别平均提升了2.00%与8.24%,证明了本文方法可以有效地提升高光谱解混的性能,对于地表相关 信息能够更加精准地进行分析。



图 9 所有方法在 Jasper Ridge 数据集上的端元提取结果对比



图 10 所有方法在 Jasper Ridge 数据集上的丰度估计结果对比

参考文献:

- [1] 代先强,杨盛刚,肖鹏,等. 渝东北烟区土壤退化现状剖析 [J]. 西南大学学报(自然科学版), 2023, 45(12): 65-75.
- [2] 王智,杨胜刚,范业晨,等.重庆市石柱县烟田土壤养分空间异质性分布及评价 [J].西南大学学报(自然科学版), 2023, 45(11): 42-52.
- [3] 杨鉴,张珍明,陈祖拥,等.贵州省典型茶园土壤锌含量空间异质性及影响因素 [J].东北农业大学学报,2023, 54(12):21-31.
- [4] 杨梅,胡晓婷,徐卫红.不同类型土壤与辣椒风味品质的相关性研究 [J].西南大学学报(自然科学版),2024,46(1): 2-16.
- [5] 李恬,李怀刚,何建军,等.陆面资料对复杂地形气温和降水模拟的影响——以济南市为例[J].西南大学学报(自然 科学版),2023,45(9):124-131.
- [6] 莫金宵, 雷冬梅, 李杰, 等. 县级自然保护区土地利用景观格局与固碳功能关系分析——以云南省梁王山为例 [J]. 云 南农业大学学报(自然科学), 2023, 38(4): 694-703.
- [7] HEYLEN R, PARENTE M, GADER P. A Review of Nonlinear Hyperspectral Unmixing Methods [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 1844-1868.
- [8] LIST, SONGWW, FANGLY, et al. Deep Learning for Hyperspectral Image Classification: An Overview [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(9): 6690-6709.
- [9] PALSSON B, SIGURDSSON J, SVEINSSON J R, et al. Hyperspectral Unmixing Using a Neural Network Autoencoder [J]. IEEE Access, 2018, 6: 25646-25656.
- [10] SHI S K, ZHAO M, ZHANG L J, et al. Probabilistic Generative Model for Hyperspectral Unmixing Accounting for Endmember Variability [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5516915.
- [11] PALSSON B, ULFARSSON M O, SVEINSSON J R. Convolutional Autoencoder for Spectral-Spatial Hyperspectral Unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1): 535-549.
- [12] YU Y, MA Y, MEI X G, et al. Multi-Stage Convolutional Autoencoder Network for Hyperspectral Unmixing [J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 113: 102981.
- [13] GHOSH P, ROY S K, KOIRALA B, et al. Hyperspectral Unmixing Using Transformer Network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5535116.
- [14] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An Image Is Worth 16×16 Words: Transformers for Image Recognition at Scale [EB/OL]. (2021-06-03) [2024-02-10]. https://arxiv.org/abs/2010.11929.
- [15] MA Q, JIANG J J, LIU X M, et al. Learning a 3D-CNN and Transformer Prior for Hyperspectral Image Super-Resolution [J]. Information Fusion, 2023, 100: 101907.
- [16] FAROOQUE G, LIU Q C, SARGANO A B, et al. Swin Transformer with Multiscale 3D Atrous Convolution for Hyperspectral Image Classification [J]. Engineering Applications of Artificial Intelligence, 2023, 126: 107070.
- [17] LIU Z, LIN Y T, CAO Y, et al. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows [C] // 2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. IEEE, 2021: 9992-10002.
- [18] GAO L R, HAN Z, HONG D F, et al. CyCU-Net: Cycle-Consistency Unmixing Network by Learning Cascaded Autoencoders [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5503914.
- [19] SU Y C, ZHU Z Q, GAO L R, et al. DAAN: A Deep Autoencoder-Based Augmented Network for Blind Multilinear Hyperspectral Unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5512715.
- [20] NASCIMENTO J M P, DIAS J M B. Vertex Component Analysis: A Fast Algorithm to Unmix Hyperspectral Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(4): 898-910.

责任编辑 柳剑