第37卷,第1期	Ē	自然	资	源	遥	感	Vol.37
2025年02月	REMOTE SI	ENSINC	FOR	NAT	URAL	L RESOURCES	Feb.

Vol.37, No.1 Feb., 2025

doi: 10.6046/zrzyyg.2023260

引用格式:黄川,李雅琴,祁越然,等. 基于 3D-CAE 的高光谱解混及小样本分类方法[J]. 自然资源遥感,2025,37(1):8-14.(Huang C,Li Y Q,Qi Y R,et al.A hyperspectral unmixing and few-shot classification method based on 3DCAE network[J]. Remote Sensing for Natural Resources,2025,37(1):8-14.)

基于 3D-CAE 的高光谱解混及小样本分类方法

黄川1,李雅琴1,祁越然2,魏晓燕3,邵远征4

(1. 武汉轻工大学数学与计算机学院,武汉 430023; 2. 安徽师范大学地理与旅游学院,芜湖 241001;

3. 云南省测绘资料档案馆(云南省基础地理信息中心),昆明 650034;

4. 武汉大学地球空间信息技术协同创新中心,武汉 430079)

摘要:我国高光谱遥感技术的快速发展为开展大区域地物分类应用提供了充分保障。然而,如何在小样本下充分 利用高光谱自身的空谱信息实现高精度的分类成为挑战。该文通过构建 3D 卷积自编码网络,以混合像元分解物 理约束对模型进行引导,从而实现在准确估计端元丰度的同时获得对规则化的高光谱空谱特征的有效表达,结合 支持向量机分类器实现在小样本条件下的高光谱分类。实验中,采用包括监督分类方法在内的多种传统高光谱图 谱特征提取及分类方法进行对比验证,并对比了不同模型在不同采样率下的分类性能表现。实验结果表明,所提 出的高光谱分类方法具有明显的精度优势,其中平均交并比(mean intersection over union,mIoU)达到 0.829,相对于 传统分类方法精度有明显提升;在 1/200 采样率下 mIoU 值依然能接近 0.8,优于同类方法,证实了该文方法在小样 本条件下依然具有较好的鲁棒性,为解决小样本下高光谱分类问题提供了技术参考。

关键词:深度学习;高光谱影像;分类;卷积神经网络;解混

中图法分类号: TP 79 文献标志码: A 文章编号: 2097-034X(2025)01-0008-07

0 引言

高光谱技术被认为是 21 世纪遥感领域最热门的研究方向之一,在对地观测中发挥着重要的作用。 高光谱图像 (hyperspectral imaging, HSI)具有"图谱 合一"的特点,其通常具有数百个波段,且蕴含着大 量信息,在定量遥感应用中具有独特的优势^[1],常 被应用于地物分类、环境监测、地质填图等领域^[2]。 得益于国产高光谱卫星事业的蓬勃发展,目前我国 已成功发射多颗高光谱卫星,如 GF-5^[3], GF5-02, ZY1-02D^[4]等,为开展广域的高光谱遥感应用提供 了数据保障。然而,高光谱维数灾难及由此引发的 小样本分类问题依然是阻碍高光谱数据进一步推广 应用所面临的挑战。

在过去的几十年间,学者们提出众多高光谱地物分类的方法,大体上可以概括为图像增强方法、光谱特征分析方法和机器学习方法。图像增强方法,如最小噪声分离变换(minimum noise fraction rota-

tion, MNF)^[5-6]、主成分分析(principal component analysis, PCA)^[7]等,旨在通过降维保留有效信息, 实现对不同类别地物类图像的增强显示。光谱特征 分析方法通常具有明确的物理意义,可以进一步细 分为光谱特征提取方法和光谱匹配方法。前者基于 对地物的光谱特征的分析,并人为地设定识别规则 以实现分类的目的,如植被光谱指数;后者则是通 过比较目标光谱与参考光谱的一致性来进行分类. 如光谱角匹配(spectral angel match, SAM)^[8]和光 谱信息散度(spectral information divergence, SID)^[9]。传统机器学习方法如随机森林、支持向量 机(support vector machine, SVM)^[10]等的应用虽然 在一定程度上解决了特征提取的难题,但依然没有 充分利用高光谱数据的空谱联合特征。近年来,随 着深度学习技术在遥感应用领域不断取得突破,依 靠卷积神经网络(convolutional neural network, CNN) 强大的学习能力,深度学习模型在监督分类场景下 的高光谱分类应用中取得非常有竞争力的结 果[11-12],然而人工标记样本成本高昂,而且小样本

收稿日期: 2023-08-28;修订日期: 2024-09-01

基金项目:国家自然科学基金项目"孟中缅印经济走廊公路网时空风险评估与归因"(编号:42061074)与"基于深度学习的高光谱图 像红肉品质检测理论与技术"(编号:61906140)资助。

第一作者:黄川(1973-),男,博士,副教授,主要从事基于深度学习的遥感数据处理与地理信息系统研究。Email: stephensky123@ 163.com。

通信作者: 邵远征(1983-),男,博士,副研究员,主要从事地理信息研究研究与遥感行业化应用研究。Email: yshao@ whu.edu.cn。

第1期

场景下监督分类方式更容易导致过拟合。

已有研究发现.解决少样本高光谱分类问题的 核心是获取高光谱信息的有效表征[13],并且采用无 监督或半监督的方式可以降低模型对于样本的依 赖,从而提升模型的鲁棒性。最新进展表明,混合像 元分解理论可以指导网络学习到更有效的和规则化 的表征特征,其生成的端元丰度可以为半监督分类 提供有用的空间-光谱联合特征[14]。这也为解决小 样本分类问题提供了新的思路。通常,高光谱混合 像元分解可以概括为2类:线性混合模型和非线性 混合模型[15-16],线性混合模型的原理和计算过程简 单,但未充分考虑到多重散射函数和物体之间的相 互作用,这使得它不适合解决复杂场景中的混合像 元分解问题[17]。传统神经网络算法也常被用来解 决非线性解混的问题[18-19],部分研究中将非线性视 为线性目标函数的非线性变换,从而实现模型的简 化以及鲁棒性的提升^[20-21]。近几年,基于卷积自编 码网络(convolutional auto-encoders, CAE)进行光谱 分解应用的研究取得新进展[22-24],去噪自编码 器^[25]、稀疏自编码器^[26]以及堆叠自编码器^[27-28]等 被引入到高光谱解混应用中来估计端元的丰度。诸 多研究证实通过 CNN 可以模拟传统非线性混合像 元分解过程来生成端元丰度图,从而获得有效的高

光谱表征特征,相对于传统方法如全约束最小二乘法(fully constrained least squares, FCLS)^[29]更准确高效。

为了克服 HSI 监督分类所面临的样本依赖性 强、模型鲁棒性差等问题,本文在前人研究的启发 下,提出一种轻量化的半监督高光谱分类方法。该 方法利用混合像元分解约束条件对自编码网络的隐 层特征进行引导,以实现在高光谱解混的同时获得 对规则化的空谱特征的有效表达。此外,本文还引 人多种高光谱分类方法进行对比实验,以便进一步 说明本文提出的方法在空谱特征提取和小样本下高 光谱分类方面的优势。

1 数据及方法

1.1 高光谱数据

Urban 数据集是高光谱研究中使用最广泛的高 光谱数据集之一,常被用于高光谱解混和分类应用 研究。图像大小为 307 像元×307 像元,拥有 210 个 波段,光谱范围从 400 nm 到 2 500 nm,如图 1 所示。 除去 48 个异常波段,其余 162 个波段被用于高光谱 解混实验。该数据集中即包含地物端元光谱也包括 各端元的丰度数据,其中 6 个端元地物分别是沥青、 草地、树木、屋顶、金属和土壤。







1.2 基于 3D-CAE 的高光谱解混

线性混合模型通常假设反射光谱由不同的端元 线性混合,其公式可以表示为:

$$\boldsymbol{M} = \boldsymbol{E}\boldsymbol{A} + \boldsymbol{N} \quad , \tag{1}$$

式中: *M* 为混合像元; *E* 为端元; *A* 为丰度; *N* 为 附加向量。但考虑到多重散射函数和物体之间的相 互作用,非线性模型更适合解决复杂场景下的高光 谱解混问题。非线性模型定义为:

$$M = g(EA) + N , \qquad (2)$$

式中 g 为非线性函数。

自动编码器是无监督的训练网络,旨在强制所 学习的表征表现出有用的特性。在自学习过程中, 输入数据被压缩,在此过程中数据的结构和分布规 律能够被模型学习和利用。被降维后的隐层空谱特 征可以看作是端元光谱矩阵与端元丰度矩阵的乘 积,而解码器的作用是利用隐层空谱特征实现对原 始高光谱数据的重构。基于以上认识,当自编码器 中给定端元光谱即可通过数据重建过程来实现对端 元丰度的估计。此外,CNN 的堆叠卷积层和激活层 可以解释为线性函数的非线性变换。

由于光谱维度对于高光谱数据是冗余的,因此,

• 10 •

本文采用 3D 卷积来完成对有效特征的提取。用于 实现高光谱解混的 3D-CAE 特点在于卷积单元采 用了 3D 卷积结构,其表达式为:

$$v_{lf}^{xyz} = \sigma \left(\sum_{m} \sum_{h=0}^{H_{k}-1} \sum_{w=0}^{W_{k}-1} \sum_{d=0}^{C_{k}-1} w_{lfm}^{hwd} v_{(l-1)m}^{(x+h)(y+w)(z+d)} \right) + b_{lf} ,$$
(3)

式中: v_{y}^{syz} 为第l层第f个三维卷积层输出的特征映 射在(x,y,z)处的值;m为上层传入的特征映射个 数; H_k , W_k , C_k 分别为卷积的行、列及通道大小;k为卷积核; w_{ym}^{hed} 为第f个特征层的三维卷积核在 (h,w,d)处的权重值;b为偏置项; σ 为激活函数。

原始 HSI 数据经由编码器进行通道维降维处 理,被降维后的特征再经由解码器被重建得到与原 始高光谱数据相同的维度。模型经过多轮次的训练 后,被降维后的隐层空谱特征将包含可表达原始高 光谱数据的绝大部分信息,然而这些隐层空谱特征 往往具有随机性,直接将其作为空谱特征用于分类 往往会增加模型不确定性。与常规的自编码网络不同的是,本文提出的 3D-CAE 将混合像元分解的约束条件嵌入到隐层空谱特征中,使其数据结构具有规则化特征,其表现形式既是给定端元光谱的条件下模型估计的端元丰度,也是对于高光谱分类有着重要作用的空谱特征。

3D-CAE 的结构采用一种轻量化的设计,主要 由编码器和解码器 2 部分构成(图 2),其中编码器 由 4 个 3D 卷积层组成,解码器部分由多个全连接 层组成,各特征层详细信息见表 1。为了确保输出 特征满足高光谱解混的"非负"及"和为 1"约束条 件^[30-31],解码器中 Dense-2 层需加入 Softmax 激活 函数。需要说明的是,模型采用轻量化的设计而未 使用结构复杂的编码器,原因有以下 2 个方面:一 是为了保持模型的低参数和高效率;二是强调该模 型的性能增量主要来源于将物理约束引入自编码网 络,虽然通过提升模型复杂度也能带来性能提升,但 这并不是本文讨论的焦点。



图 2 基于 3D-CAE 的高光谱分类流程

Fig.2 The hyperspectral classification workflow based on 3D-CAE

表1 网络组成及相关参数设置	Ï
----------------	---

Tab.1 Network composition and related par	ameter settings
---	-----------------

特征层	卷积核 大小	卷积核 数量/个	激活 函数	特征 尺寸
Conv3D-1	(1, 1, 7)	32	ReLU	(1, 1, 155, 32)
Conv3D-2	(1, 1, 7)	16	ReLU	(1, 1, 148, 16)
Conv3D-3	(1, 1, 7)	8	ReLU	(1, 1, 141, 8)
Conv3D-4	(1, 1, 7)	2	ReLU	(1, 1, 134, 2)
Flatten	—	_	—	134×2
Dense-1	—	32	ReLU	32
Dense-2	_	6	Softmax	6
Dense-3	—	162	ReLU	162

1.3 半监督高光谱分类模型

端元丰度数据作为带有先验知识的空谱特征, 可结合分类器实现小样本条件下的地物分类应用。 本文选择经典的机器学习算法 SVM 作为分类器,原 因是其可以自动寻找对分类有较大区分能力的最优 分离超平面,可以缩小同类间隔的同时扩大不同类 的差异化,被公认为是一种分类精度高、泛化能力 强,且更适用于小样本分类的模型^[32]。

2 实验结果

2.1 实验设置

本文所采用的方法需要以地物端元作为输入, 计算获得端元丰度后用于后续分类,因而属于半监 督分类。为了证实本文方法所提取的空谱特征对于 高光谱分类的有效性,引入同样以地物端元作为输 入的 FCLS 端元丰度提取方法,以及 SAM 和 SID 这 2 种半监督分类方法进行对比。此外,还加入 PCA 和 MNF 这 2 种非监督特征提取方法作为参考。在 实验中,上述模型除 SAM 和 SID 直接得到分类结果 之外,其余模型均使用得到的空谱特征作为输入,利 用 SVM 算法在 1/50 采样率的条件下进行分类。为 了进一步说明本文方法在小样本分类中模型的泛化 能力。分别设置样本在 1/10,1/50,1/100,1/200 情 况下,对比不同半监督分类模型与 SVM 监督分类模 型在不同采样率下的分类表现。所有模型均在相同 数据集以相同的训练参数设置进行实验。

实验在 TensorFlow (2.6.0) 框架及 NVIDIA Quadro RTX8000 GPU 下进行,训练中使用自适应学 习率优化算法(Adam)作为优化器,以 0.000 5 为初 始学习率进行优化,以均方根误差(root mean squared error, RMSE)为损失函数,所有模型经过 50 轮训练后取其中最优模型进行对比。

2.2 评价指标

HSI 分类结果采用总体分类精度、精确率、召回率、F1 得分以及平均交并比(mean intersection over union, mIoU)作为评价指标。各评价参数的计算方法如下所示:

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad , \tag{4}$$

$$P = \frac{TP}{TP + FP} \quad , \tag{5}$$

$$R = \frac{TP}{TP + PN} \quad , \tag{6}$$

$$F = 2/(\frac{1}{R} + \frac{1}{P})$$
, (7)

$$mIoU = \frac{1}{k+1} \sum_{i=1}^{k} \frac{TP}{FP + FN + TP}$$
, (8)

式中: *A* 为总体分类精度; *P* 为精确率; *R* 为召回 率; *F* 为 F1 得分; *k* 为地物类别总数; *TP* 为判正的 正样本; *FN* 为判负的正样本; *FP* 为判正的负样 本; *TN* 为判负的负样本。

采用 RMSE 对端元丰度的估计精度进行定量评价,RMSE 数值越小代表估计的端元丰度越接近真实值,具体计算公式为:

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N} (AP_i - AT_i)^2}{N}} , \qquad (8)$$

式中: *N* 为观测值的总数; *AP*_{*i*}为第*i* 个预测值; *AT*_{*i*} 为第*i* 个真实值。

2.3 端元丰度估计

利用本文提出的 3D-CAE 针对 Urban 数据集中 6个端元进行丰度估计。表 2 展示了 Urban 数据集 的端元估计丰度与真实值的可视化对比结果。从整 体上看获得的 6 个端元丰度图与真实值十分接近, 平均 RMSE 为 0.106,表明基于自编码网络的高光谱 解混算法的有效性。其中屋顶和金属 2 个端元丰度 估计值与真实值的平均 RMSE 分别为0.083和0.067, 明显优于沥青路面(0.131)、草地(0.121)、树木 (0.114)以及土壤(0.121)这 4 类地物,表明模型对 于屋顶和金属这 2 个端元的丰度估计精度更高。结 果表明 3D-CAE 可以在高光谱重构过程中将隐层 空谱特征以端元丰度的形式进行规则化表达,这些 信息是后续分类应用的重要参考。



endmembers compared to the true values



2.4 基于空谱特征的 HSI 分类

为了充分说明提出空谱特征提取方法的有效 性,在相同采样率(1/50)条件下,分别采用 PCA 和 MNF 对高光谱数据进行降维, 取前3个波段作为分 类用的空谱特征。分别采用 SAM, SID 及 FCLS 方 法,基于给定的端元光谱通过波谱匹配、丰度估计等 得到空谱特征用于对比。基于以上数据结合 SVM 分类器得到 Urban 数据集的分类结果如图 3 所示。 如图 3(a) 所示, SID 预测结果中可见"树木"存在明 显的漏分,且与"沥青"存在混淆的现象; SAM 预测 结果,如图 3(b)所示,"金属"和"土壤"类地物均有 一定程度的过度提取;如图3(c)-(g)所示,其他 模型提取效果与真值在视觉效果上较为接近,都明 显优于 SAM 和 SID 方法。不同模型预测精度的对 比信息如表3所示,可见本文提出方法在各项评价 指标中均取得最优成绩,mIoU达到0.829,总体分类 精度达到 0.927。值得一提的是, 与 SVM 监督分类 方法对比,3D-CAE-SVM 依然有突出的表现,表明 利用自编码器进行空谱特征提取相对于传统高光谱 特征提取方法具有更大的优势,且以3D-CAE提取 · 12 ·



图 3 不同模型预测分类结果与真值对比图



表 3 不同模型预测精度对比表

Tab.3	Comparison table of prediction				
accuracy for different models					

	-				
模型	总体分 类精度	精确度	召回率	F1 得分	mIoU
3D-CAE-SVM	0.927	0.936	0.883	0.905	0.829
PCA-SVM	0.912	0.928	0.854	0.884	0.796
MNF-SVM	0.895	0.913	0.847	0.873	0.779
FCLS-SVM	0.850	0.832	0.775	0.778	0.657
SVM	0.916	0.929	0.856	0.885	0.799
SAM	0.847	0.870	0.831	0.821	0.777
SID	0.712	0.652	0.771	0.625	0.513

的空谱特征作为输入可以有效提高监督分类的精度。

2.5 小样本下模型鲁棒性分析

在实际应用中高光谱数据标签获取成本非常 高,面对一个比较大的挑战就是小样本下的分类。 以往采用监督学习方法虽然能够获得较好的应用效 果,但在样本不充足的前提下也更容易导致过拟合, 因而难以在更大范围和复杂的场景下保持模型的鲁 棒性。通过前面的实验不难发现,3D-CAE 可以实 现对端元丰度的准确估计,这种方法的优势在于能 够将混合像元分解的物理约束嵌入到具有强大学习 能力的 CNN 中,大大降低了对训练样本的需求。为 了进一步证实提出的 3D-CAE-SVM 高光谱分类方 法在小样本条件下的有效性,对比分析各个模型在 1/10,1/50,1/100,1/200 采样率下的 mIoU 值变化, 如图4所示。由图可知,随着采样率的提高,所有模 型的分类精度均有提升,但 SVM 代表的纯监督分类 方法的精度与采样率呈更为明显的线性关系,其他 基于空谱特征进行分类的方法分类精度变化相对更 平缓。MNF-SVM 和 FCLS-SVM 在不同采样率下性





能均低于 SVM 算法,证明这 2 种空谱特征提取方法 并不能改善分类效果。随着采样率的降低 PCA-SVM 方法相对 SVM 方法的优势逐渐呈现,在 1/200 采样条件下 mloU 为 0.721,超越 SVM 算法 3 个百分 点。值得注意的是本文提出的 3D-CAE-SVM 模 型,在任意采样率下均取得最优精度,具有较好的鲁 棒性,在 1/200 条件下 mloU 依然能接近 0.8,明显优 于 SVM 算法,充分证实了本文方法在小样本下对于 分类精度的提升具有积极作用。

3 结论

本文提出一种轻量化的三维自编码网络 3D-CAE,通过获取端元丰度信息实现高光谱空谱特征 的提取,结合 SVM 分类器实现在小样本条件下的高 光谱分类。对比于传统高光谱图谱特征提取方法及 纯监督分类方法具有显著优势,得出如下结论:

1)利用自编码网络嵌入混合像元分解的物理 约束条件,可以实现较好的端元丰度估计。 2)端元丰度估计结果包含了可重建原始高光 谱的规则化的空谱特征,将其用于高光谱分类可减 少模型对于样本的依赖性,实验结果证实利用 3D-CAE 方法提取的空谱特征相对于 PCA,MNF,FCLS, SAM 和 SID 等方法对于提高高光谱分类精度效果 更好。

3)3D-CAE 应用于高光谱分类具有良好的鲁棒 性。实验结果显示,在采样率为1/200 的典型小样 本场景下分类精度明显优于 SVM 算法,且采样率递 减的条件下模型精度的衰减率更低,表现出较好的 鲁棒性,为解决小样本分类问题提供了新的思路。

本文提出的方法需要给定光谱端元,在实际应 用中可通过人工标记或结合非监督端元估计的方法 获得,后续将进一步聚焦该问题,研发无监督的端元 丰度估计方法。

参考文献(References):

- [1] 杜培军,谭 琨,夏俊士.高光谱遥感影像分类与支持向量机应用研究[M].Beijing:Science Press,2012,1-160.
 Du P J, Tan K, Xia J S, et al. Research on hyperspectral remote sensing image classification and support vector machine application [M].Beijing:Science Press,2012,1-160.
- [2] Bioucas-Dias J M, Plaza A, Dobigeon N, et al. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression – based approaches[J].IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(2):354-379.
- [3] 刘银年,孙德新,胡晓宁,等.高分五号可见短波红外高光谱相 机设计与研制[J].遥感学报,2020,24(4):333-344.Liu Y N, Sun D X,Hu X N, et al.Development of visible and short-wave infrared hyperspectral imager onboard GF-5 satellite[J].Journal of Remote Sensing(Chinese),2020,24(4):333-344.
- [4] Zhong Y, Wang X, Wang S, et al. Advances in spaceborne hyperspectral remote sensing in China[J].Geo-Spatial Information Science, 2021, 24(1):95-120.
- [5] Green A A, Berman M, Switzer P, et al. A transformation for ordering multispectral data in terms of image quality with implications for noise removal [J]. IEEE Transactions on Geoscience and Remote Sensing, 1988, 26(1):65-74.
- [6] Black M, Riley T R, Ferrier G, et al. Automated lithological mapping using airborne hyperspectral thermal infrared data: A case study from Anchorage Island, Antarctica [J]. Remote Sensing of Environment, 2016, 176:225-241.
- [7] Alberti A, Alessandro V, Pieruccini U, et al. Landsat TM data processing for lithological discrimination in the Caraculo area (Namibe Province, SW Angola) [J]. Journal of African Earth Sciences (and the Middle East), 1993, 17(3):261-274.
- [8] Hecker C, van der Meijde M, van der Werff H, et al. Assessing the influence of reference spectra on synthetic SAM classification results[J].IEEE Transactions on Geoscience and Remote Sensing, 2008,46(12):4162-4172.
- [9] Chang C I.An information-theoretic approach to spectral variabili-

ty, similarity, and discrimination for hyperspectral image analysis [J].IEEE Transactions on Information Theory,2000,46(5):1927–1932.

- [10] Camps-Valls G, Bruzzone L.Kernel-based methods for hyperspectral image classification [J].IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(6):1351-1362.
- [11] Zhu X X, Tuia D, Mou L, et al. Deep learning in remote sensing: A comprehensive review and list of resources [J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(4):8-36.
- [12] Zhou H, Huang L, Wang Y.Deep learning algorithm and its application in optics [J]. Infrared and Laser Engineering, 2019, 48 (12):1226004.
- [13] Han M, Cong R, Li X, et al. Joint spatial-spectral hyperspectral image classification based on convolutional neural network [J]. Pattern Recognition Letters, 2020, 130:38-45.
- [14] Li C, Cai R, Yu J.An attention-based 3D convolutional autoencoder for few-shot hyperspectral unmixing and classification [J].Remote Sensing, 2023, 15(2):451.
- [15] Dobigeon N, Tourneret J Y, Richard C, et al. Nonlinear unmixing of hyperspectral images: Models and algorithms [J]. IEEE Signal Processing Magazine, 2014, 31(1):82-94.
- [16] Winter M E.N-FINDR: An algorithm for fast autonomous spectral end-member determination in hyperspectral data [C]//Imaging Spectrometry V.Denver, CO.SPIE, 1999:266-275.
- [17] Zhang X, Sun Y, Zhang J, et al. Hyperspectral unmixing via deep convolutional neural networks [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(11):1755-1759.
- Halimi A, Altmann Y, Dobigeon N, et al. Nonlinear unmixing of hyperspectral images using a generalized bilinear model [C]//2011
 IEEE Statistical Signal Processing Workshop (SSP). June 28–30, 2011, Nice, France. IEEE, 2011;413–416.
- [19] Licciardi G A, Del Frate F.Pixel unmixing in hyperspectral data by means of neural networks [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(11):4163-4172.
- [20] Zhu F, Honeine P.Biobjective nonnegative matrix factorization:Linear versus kernel-based models[J].IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(7):4012-4022.
- [21] Févotte C, Dobigeon N. Nonlinear hyperspectral unmixing with robust nonnegative matrix factorization [J].IEEE Transactions on Image Processing, 2015, 24(12):4810-4819.
- [22] 韩 竹,高连如,张 兵,等.高分五号高光谱图像自编码网络非 线性解混[J].遥感学报,2020,24(4):388-400.
 Han Z,Gao L R,Zhang B, et al. Nonlinear hyperspectral unmixing algorithm based on deep autoencoder networks[J].National Remote Sensing Bulletin,2020,24(4):388-400.
- [23] 朱 玲,秦 凯,李 明,等.改进的堆栈稀疏自编码矿物高光谱端 元识别研究[J].光谱学与光谱分析,2021,41(4):1288-1293.
 Zhu L,Qin K,Li M, et al.Research on improved stacked sparse autoencoders for mineral hyperspectral endmember extraction [J].
 Spectroscopy and Spectral Analysis,2021,41(4):1288-1293.
- [24]朱治青,苏远超,李朋飞,等.双约束深度卷积网络的高光谱图 像空谱解混方法[J].信号处理,2023,39(1):128-142.
 Zhu Z Q,Su Y C,Li P F,et al.Spectral-spatial hyperspectral unmixing using deep double-constraints convolutional network[J].
 Journal of Signal Processing,2023,39(1):128-142.

• 14 •	
--------	--

- [25] Qu Y, Qi H.uDAS: An untied denoising autoencoder with sparsity for spectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(3):1698-1712.
- [26] Ozkan S, Kaya B, Akar G B.EndNet; Sparse AutoEncoder network for endmember extraction and hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(1); 482-496.
- [27] Su Y, Li J, Plaza A, et al. DAEN: Deep autoencoder networks for hyperspectral unmixing[J].IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(7):4309-4321.
- [28] Khajehrayeni F, Ghassemian H.Hyperspectral unmixing using deep convolutional autoencoders in a supervised scenario [J].IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13:567-576.
- [29] Heinz D C, Chang C I. Fully constrained least squares linear spec-

tral mixture analysis method for material quantification in hyperspectral imagery[J].IEEE Transactions on Geoscience and Remote Sensing,2001,39(3):529-545.

- [30] Palsson B, Sveinsson J R, Ulfarsson M O.Blind hyperspectral unmixing using autoencoders: A critical comparison [J].IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15:1340-1372.
- [31] Foody G M. Approaches for the production and evaluation of fuzzy land cover classifications from remotely-sensed data [J]. International Journal of Remote Sensing, 1996, 17(7):1317-1340.
- [32] 杜培军,夏俊士,薛朝辉,等.高光谱遥感影像分类研究进展
 [J].遥感学报,2016,20(2):236-256.
 Du P J, Xia J S, Xue Z H, et al. Review of hyperspectral remote sensing image classification [J]. Journal of Remote Sensing, 2016, 20(2):236-256.

A hyperspectral unmixing and few-shot classification method based on 3DCAE network

HUANG Chuan¹, LI Yaqin¹, QI Yueran², WEI Xiaoyan³, SHAO Yuanzheng⁴

(1. School of Mathematics and Computer Science, Wuhan Polytechnic University, Wuhan 430023, China; 2. School of Geography and

Tourism, Anhui Normal University, Wuhu 241001, China; 3. Yunnan Provincial Archives of Surveying and Mapping (Yunnan Provincial Geomatics Centre), Kunming 650034, China; 4. Collaborative Innovation Center of Geospatial Technology, Wuhan University, Wuhan 430079, China)

Abstract: The rapid development of hyperspectral remote sensing technology in China fully ensures the effective application of large-scale surface feature classification. However, achieving high-precision classification under few-spot conditions while fully leveraging hyperspectral spatial – spectral information remains challenging. This study developed a 3D convolutional autoencoder (3D-CAE) network guided by physical constraints from mixed pixel decomposition. This approach enables accurate estimation of endmember abundance while effectively expressing regularized spatial-spectral features of hyperspectral data. In combination with a support vector machine (SVM) classifier, the method achieves hyperspectral classification under few – spot conditions. The classification performance of various models was evaluated at different sampling rates. To validate the proposed method, this study conducted experiments including comparisons with traditional hyperspectral feature extraction and classification methods, such as supervised classification approaches. The classification performance of various models was also evaluated at different sempling rates. The experimental results demonstrate that the proposed hyperspectral classification approaches a supervised classification over union (mIoU) of 0.829, which was close to 0.8 even at a low sampling rate of 1/200, surpassing its counterparts. These results confirm that the proposed method exhibits robustness under few-spot conditions. This study provides a valuable technical reference for addressing hyperspectral classification challenges under few-spot conditions.

Keywords: deep learning; hyperspectral imagery; classification; convolutional neural network; unmixing (责任编辑:张仙)