doi:10.6041/j.issn.1000-1298.2021.12.024

融合栈式自编码与 CNN 的高光谱影像作物分类方法

郭　交[1,2]　李仪邦[1]　董思意[1]　张伟涛[3]

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;
2. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100;
3. 西安电子科技大学先进遥感技术研究院, 西安 710071)

摘要: 在高光谱影像作物分类中,为了充分利用高光谱遥感影像完整的光谱信息,同时避免高维数据带来的 Hughes 现象,本文从栈式自编码网络的数据降维与 CNN 网络的分类优势出发,首先分析了此种网络在训练过程中的共性,以自编码网络优化过程中分类器的选取作为切入点,构建了可用于高光谱影像分类的融合网络架构。相较于传统方法,本文方法仅通过一次监督训练,即可实现高光谱影像直接分类,简化了传统数据处理流程,而且具有更优的分类性能。在实验中,利用 Pavia University 与雄安地区两组典型的高光谱遥感影像数据集对本文方法进行了验证,实验结果表明,Pavia University 数据集中,在仅选用 10% 的像素点作为训练集的情况下,本文方法总体分类精度达到 98.73%,比传统方法提升了 8 个百分点以上;在雄安数据集中,在仅选用 1% 的像素点作为训练集的情况下,本文方法总体分类精度达到 98.04%,比传统方法提升了 7 个百分点以上,证明了本文分析的正确性和所提方法有效性,也为小样本情况下的高光谱影像分类提供了一种新的研究思路。

关键词: 作物分类; 高光谱影像; 栈式自编码网络; 卷积神经网络

中图分类号: S127　　**文献标识码**: A　　**文章编号**: 1000-1298(2021)12-0225-08　　**OSID**:

Innovative Method of Crop Classification for Hyperspectral Images Combining Stacked Autoencoder and CNN

GUO Jiao[1,2]　LI Yibang[1]　DONG Siyi[1]　ZHANG Weitao[3]

(1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Shaanxi Key Laboratory of Agriculture Information Perception and Intelligent Service*, *Yangling*, *Shaanxi* 712100, *China*
3. *Research Institute of Advanced Remote Sensing Technology*, *Xidian University*, *Xi' an* 710071, *China*)

Abstract: In crop classification with hyperspectral images, in order to make full use of the complete spectral information of hyperspectral remote sensing images and avoid the Hughes phenomenon caused by high-dimensional data, traditional methods usually adopt the strategy of "feature reduction first, and then classification". Starting from the data dimensionality reduction of the autoencoder and the classification advantages of CNN network, the commonalities of the two networks in the training process was firstly analyzed, and a fusion network for hyperspectral image classification was constructed based on the selection of classifiers in the optimization process of the autoencoder. Compared with the traditional methods, this method can realize the direct classification of hyperspectral images through once supervision training, which simplified the traditional data processing process and had better classification performances. In the experiment, two sets of typical hyperspectral remote sensing image data sets from Pavia University and Xiong'an area were used to verify the method. The experimental results showed that in Pavia University dataset, when only 10% of pixels were selected as the training set, the overall classification accuracy of the proposed method reached 98.73%, which was more than 8 percentage points higher than those of the traditional method. In Xiong'an dataset, when only 1% of pixels were selected as the training set, the overall classification accuracy of this method reached 98.04%, which was more than 7 percentage points higher than those of the traditional method, which proved the

收稿日期: 2021-05-17　修回日期: 2021-09-14

基金项目: 国家自然科学基金项目(62071350)、陕西省重点研发计划项目(2020GY-162)和国家对地观测科学数据中心开放基金项目(NODAOP2021013)

作者简介: 郭交(1984—),男,副教授,博士,主要从事农业遥感和精准农业研究,E-mail: jiao.g@163.com

correctness of this analysis and the effectiveness of the proposed method, and also provided a strategy for hyperspectral image classification with small training samples.

Key words: crop classification; hyperspectral image; stacked autoencoder; CNN

0 引言

通过遥感技术对农作物进行精准分类,对于指导农业生产具有重要的意义。在遥感技术方面,涌现出普通光学遥感、多光谱遥感、微波遥感等一系列遥感技术。其中高光谱遥感技术作为一种新型的对地观测方法,相较于普通光学遥感,具有空间信息与光谱信息合一、光谱分辨率高的特点,可提供丰富的观测信息,进而实现精准的作物参数反演、病虫害检测、作物估产与精细分类。高光谱遥感技术逐渐在农业遥感及精准农业领域获得了广泛的应用[1-4]。

高光谱遥感地物分类的过程中,原始光谱数据维度高,若直接使用完整的原始光谱信息进行分类,会导致 Hughes 现象[5],严重影响高光谱遥感影像地物分类的精度。此外,在大尺度的高光谱影像地物分类任务中,难以完整获取准确的地面真实分布信息,存在训练样本过少的问题,无法有效地发挥神经网络技术的分类能力。如何有效利用原始影像数据中丰富的光谱信息,在尽可能使用少量的训练样本下提升分类精度,同时避免 Hughes 现象,成为研究热点[6]。对于传统的高光谱影像,地物分类方法都采用先降维后分类的处理思路。在高光谱影像特征降维方面,通常采用主成分分析(Principal component analysis, PCA)、独立分量分析(Independent component analysis, ICA)等算法[7-8]进行特征降维,但这类方法仅利用了光谱信息,没有利用空间信息。为了更好地利用高光谱影像中的空谱信息,形态学特征、空间变换域特征等空间信息的加入,优化了高光谱影像的降维效果[9-11]。在分类方法方面,K 最近邻(K-nearest neighbor, KNN)算法、支持向量机(Support vector machine, SVM)算法等在高光谱影像分类方面取得了较好的效果。基于人工神经网络(Artificial neural network, ANN)的深度学习方法凭借其出色的特征提取能力,在高光谱影像处理领域得到了广泛应用[12-17]。除了直接应用于数据分类外,栈式自编码网络(Stacked autoencoder, SAE)作为一种典型的深度学习网络,在高光谱影像特征降维方面也体现出一定优势。HINTON 等[18]研究表明深层的自编码器(Autoencoder, AE)可以有效地对高维特征进行低维表征,取得了很好的降维效果[19-21]。

在实际使用深度学习方法进行高光谱影像分类过程中,这种先特征降维,后分类的数据处理方式将特征降维与分类 2 个步骤割裂开,而且理论上无法保证降维后的特征一定适应分类网络的要求,从而影响分类效果。文献[22]提出了直接使用 SAE 对高光谱影像进行分类的方法,通过 SAE 的“微调”(Fine-tuning)过程,优化网络参数,提高分类精度。但该方法的分类方法较为简单,并未较好地利用降维后的数据进行分类。

针对以上问题,本文充分利用 SAE 的数据降维优势与卷积神经网络(CNN)的分类优势,通过对这 2 种神经网络结构的有机融合,构建用于高光谱影像作物分类的统一架构,仅通过一次监督训练,即可实现原始高光谱影像的直接分类,从理论上确保降维后的特征与分类器需求完全一致,以期简化传统高光谱影像作物分类的处理流程,提高分类精度。

1 研究方法

针对高光谱影像分类中训练样本不足,特征降维与分类过程割裂等问题,本文结合 SAE 高效的降维能力与 CNN 网络的分类能力[23],提出了一种融合栈式自编码网络与 CNN 的高光谱影像作物分类方法,构建了一种降维与分类为一体的融合网络。

1.1 栈式自编码网络

SAE 是一种多层网络结构,它由简单的自编码器栈式连接而成[24]。图 1 为单层自编码器结构图,包括输入层、中间隐层与输出层。自编码器尽可能使输入数据等于输出数据,在中间隐层中重构输入信号,实现数据的有效降维[25]。

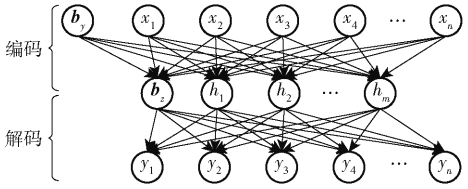

图 1 典型自编码器结构图

Fig. 1 Structure of autoencoder

在自编码器中,数据会通过编码与解码过程,实现数据降维。规定输入数据为 $x=\{x_1,x_2,\cdots,x_n\}$,中间隐层输出为 $h=\{h_1,h_2,\cdots,h_m\}$,自编码器输出为 $y=\{y_1,y_2,\cdots,y_n\}$。在自编码器的编码与解码过程中,输入数据分别经过变换

$$h=f(\boldsymbol{W}_y x+\boldsymbol{b}_y) \tag{1}$$

$$y = g(\boldsymbol{W}_z h + \boldsymbol{b}_z) \tag{2}$$

式中　$f(\cdot)$、$g(\cdot)$——激活函数，一般取 sigmoid 函数

$\boldsymbol{W}_y$——输入层神经元与中间隐层神经元间的权重矩阵

$\boldsymbol{b}_y$——输入层神经元与中间隐层神经元间的偏置

$\boldsymbol{W}_z$——输出层神经元与中间隐层神经元间的权重矩阵

$\boldsymbol{b}_z$——输出层神经元与中间隐层神经元间的偏置

自编码网络的训练可以概括为通过反向传播算法(Backpropagation algorithm)，不断训练参数$\{\boldsymbol{W}_y, \boldsymbol{W}_z\}$与$\{\boldsymbol{b}_y, \boldsymbol{b}_z\}$来最小化损失函数，本文规定损失函数为均方误差(Mean square error，MSE)。

SAE 由简单的自编码网络栈式连接而成，每层自编码器均进行单独训练，将前一层自编码的输出作为下一层自编码器的输入，构成 SAE，具备更好的数据低维特征提取能力，如图 2 所示。

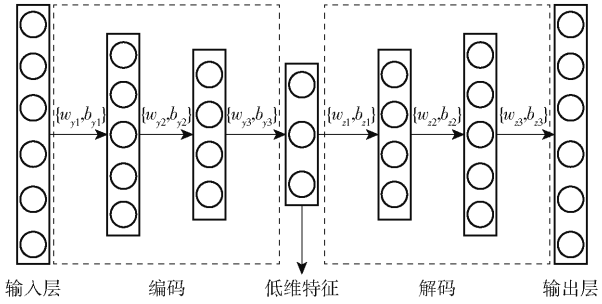

图 2　栈式自编码器结构图

Fig. 2　Structure of stacked autoencoder

在完成 SAE 的无监督训练后，提取编码器网络。将编码器网络与 Softmax 分类器连接，使用少量的样本进行简单的有监督训练，实现编码器网络参数的微调(Fine-tuning)，使编码器网络的泛化能力更强[26-28]，得到更好的数据降维效果，其训练模式如图 3 所示。

1.2　SAE 与 CNN 融合的可行性分析

高光谱遥感影像作为一种高维遥感数据，采用 SAE 对高维遥感数据进行特征降维并使用 CNN 对降维后数据进行分类，在分类精度上具有较大的优势[24]，但是数据的特征降维过程与数据的分类过程仍然是两步的割裂过程。

首先，通过深入分析 SAE 与 CNN 2 种网络结构可以看出，二者均采用原理相同的前向传播和基于梯度下降的误差反向传播，在训练的过程中存在共性，具备网络融合的理论基础。其次，在完成 SAE 的训练后，可以提取编码器网络，结合 Softmax 分类器对 SAE 监督训练，实现网络参数的微调和更好的数据降维效果。基于以上分析，利用 CNN 网络代替原先网络中的 Softmax 分类器，进一步对降维后的数据进行特征提取。最终在同一个网络中同时实现高维数据的降维与分类，充分利用 SAE 的数据降维能力与 CNN 的特征提取与分类能力，构建融合网络，简化数据处理流程，并且使降维后的低维特征更加适合 CNN 进行分类，提高分类精度，2 种网络的融合示意图如图 4 所示。

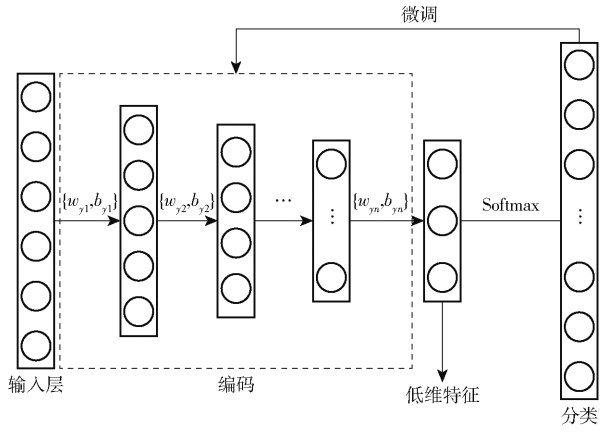

图 3　栈式自编码网络的微调

Fig. 3　Fine-tuning of stacked autoencoder

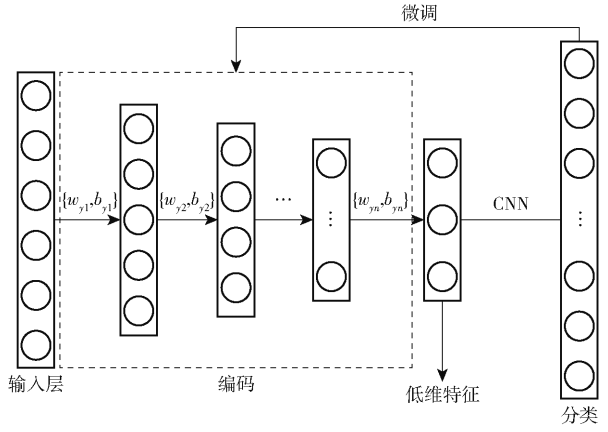

图 4　栈式自编码网络与 CNN 的融合方法

Fig. 4　Fusion method of stacked autoencoder and CNN

1.3　整体网络结构

结合 SAE 较强的数据特征提取能力与 CNN 网络的分类能力，提出了如图 5 所示的网络融合结构，完成 2 个网络结构的有机融合，简化数据处理流程，并提高数据分类精度。

本文构建的网络整体上由数据输入、数据降维、CNN 特征提取及数据分类 4 部分组成。在数据降维部分，构建了一个 4 层的 SAE，实现单个像素点原始光谱数据的 $x-220-64-32-24$ 降维；在 CNN 特征提取部分，构建了一个 3 分支并行结构的一维卷积神经网络(1 dimensional convolutional neural networks，1d-CNN)，该结构借鉴了 Inception 模块

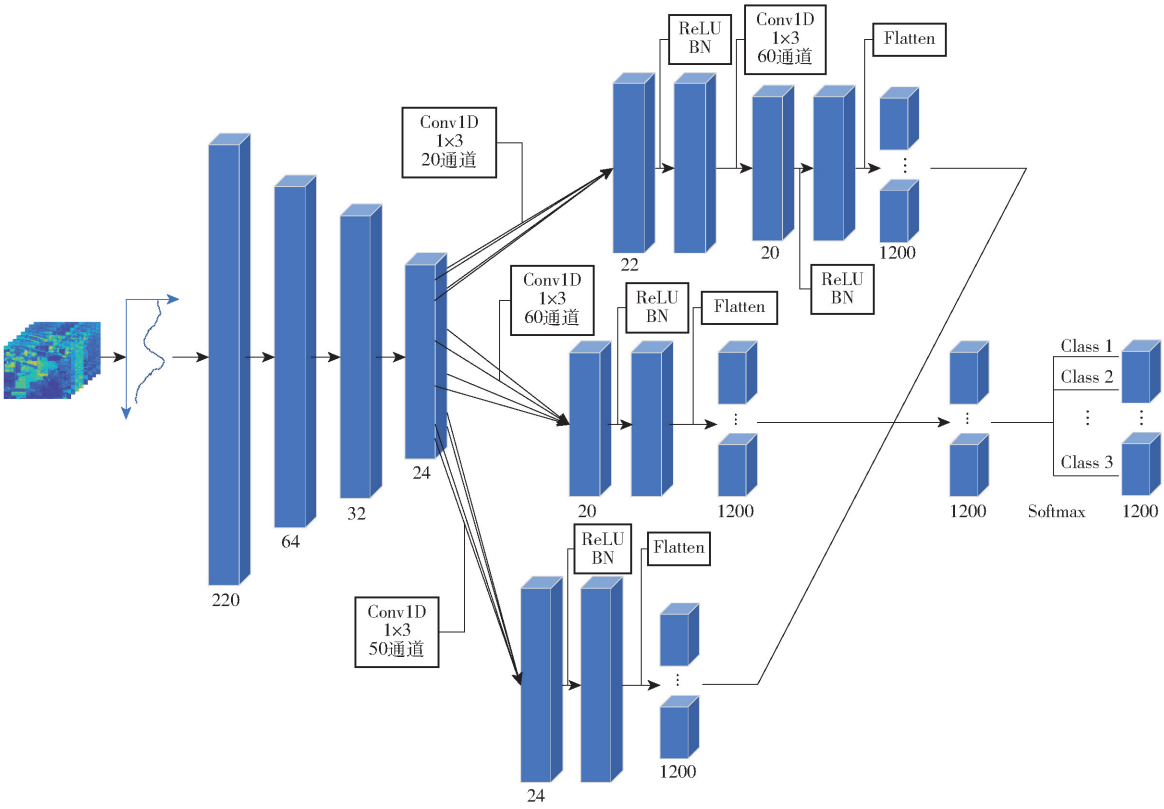

图 5 整体网络结构

Fig. 5 Overall structure of network

结构[24],通过多个并行的 CNN 分支来实现不同感知野的特征提取,其中分支 1 首先采用了 20 个 1×3 卷积核进行卷积,随后采用 60 个 1×3 卷积核进行卷积;分支 2 则采用了 60 个 1×3 卷积核进行卷积;分支 3 采用了 50 个 1×3 卷积核完成卷积。上述每个卷积操作后均加入批量标准化(Batch normalization,BN)层与线性整流函数(Rectified linear units,ReLU)层;在数据分类部分,即在 3 个分支网络结构后,使用 Add 操作将 3 个分支所提取的特征激活值进行累加,最终由 Softmax 分类器得到 n 类的概率结果,完成分类。

在模型使用中,首先选取一定数量或比例的已知像素点作为训练集,采用逐层贪婪式训练算法预训练 SAE,并提取编码器网络,其次将提取的编码器网络与 CNN 网络连接,使用有监督训练方式对整体网络进行学习,实现对 CNN 参数的训练以及预编码器网络参数的微调,最终完成模型训练。

1.4 数据集选择

选择了 Pavia University 和雄安地区 2 组公开的高光谱遥感影像数据集进行实验验证。Pavia University 数据集由 ROSIS 成像光谱仪在意大利 Pavia University 上空采集。对应的观测场景中包含 9 种地物类别。数据集共包含 115 个光谱波段信息,其波长范围为 400~860 nm,空间分辨率为 1.3 m。去除 12 个干扰噪声波段,最终剩下 103 个有效波段信息,图像尺寸为 610 像素×340 像素。Pavia University 数据集信息如图 6 所示。

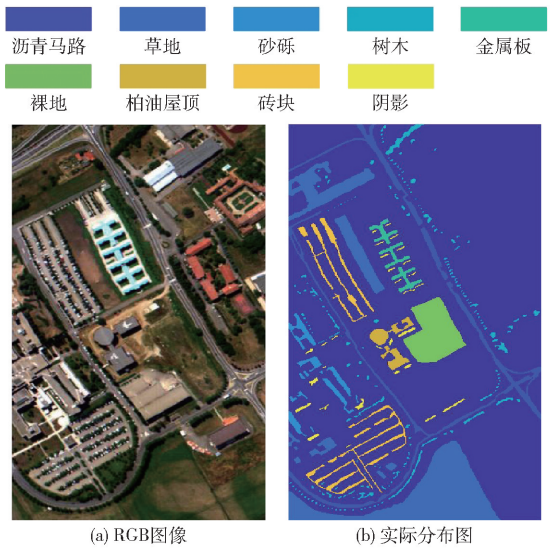

图 6 Pavia University 数据集信息

Fig. 6 Pavia University dataset information

雄安新区马蹄湾村航空高光谱遥感影像分类数据集由中国科学院空天信息创新研究院发布[29],对应场景中包含 20 种地物类别。数据集包含了 400~1 000 nm 的 250 个有效光谱波段信息,空间分辨率为 0.5 m,图像尺寸为 3 750 像素×1 580 像素,雄安数据集信息如图 7 所示。

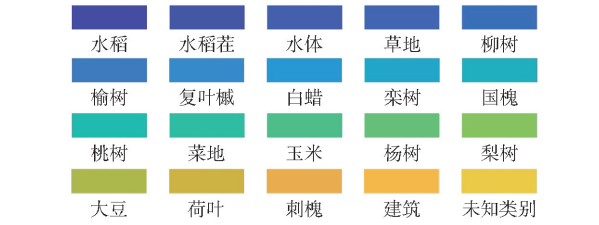

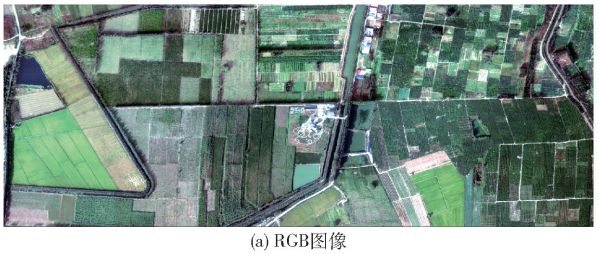

(a) RGB图像

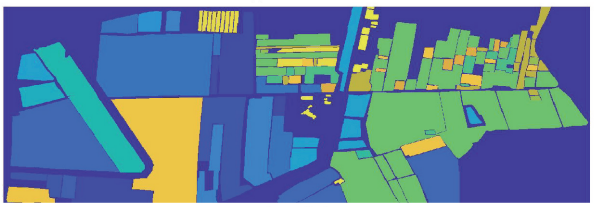

(b) 实际分布图

图 7　雄安数据集信息(RGB 图像、实际分布、标签)

Fig. 7　Xiong'an dataset information (RGB image, ground truth, feature label)

2　实验与结果分析

2.1　实验设计与评价

将本文方法与文献[14]提出的 1d－CNN 方法、文献[22]提出的 SAE 方法进行对比，其中对文献[14]中的 1d－CNN 方法进行了修改，实现类似 x－220－64－32－24 的降维过程。在分类效果评估中，使用了总体分类精度(Overall accuracy，OA)与 Kappa 系数(Kappa)作为分类性能的评估指标。此外，本实验采用的硬件环境为 Intel i7－8750H CPU，Quadro P600 GPU，使用的软件环境为 Python 3. 8. 2，TensorFlow 2. 3. 1。

其它实验参数设置：训练集均采用随机方式进行选取，对于 Pavia University 数据集，每一类的训练集数量为该类像素数的 10%；对于雄安数据集，训练集样本数量约为每一类像素数目的 1%。对于本文提出的方法，在训练的过程中，预训练采用的损失函数为均方误差损失函数(MSE)，采用的优化器为自适应矩估计(Adaptive moment estimation，Adam)，学习率设定为 0. 001；整体训练采用损失函数为交叉熵损失函数(Categorical cross entropy)，采用的优化器为 Adam，学习率设定为 0. 000 1。预训练阶段采用较大的学习率，用于加速网络的收敛，节约预训练的时间。在整体训练的过程中，采用较小的学习率，让网络参数均得到最优解，优化参数微调效果[30]。

2.2　Pavia University 数据集实验与结果分析

图 8 为 Pavia University 数据集在 3 种不同方法下的分类结果，表 1 为分类精度结果统计。由图 8、表 1 可以看出，在采用相同测试集的情况下，本文提出的方法优于其他方法，其 OA 与 Kappa 系数分别为 98. 73% 和 0. 983 1，其中 OA 相较于 SAE 和 1d－CNN 分别提高了 9. 25 个百分点和 8. 79 个百分点，Kappa 系数分别提升了 0. 126 1 和 0. 118 8。

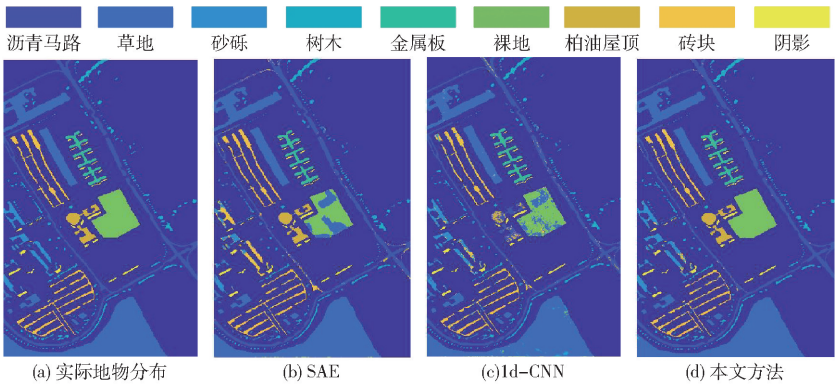

(a) 实际地物分布　(b) SAE　(c)1d-CNN　(d) 本文方法

图 8　Pavia University 数据集在不同方法下的分类结果

Fig. 8　Classification results of Pavia University dataset with different methods

2.3　雄安数据集实验与结果分析

雄安地区高光谱遥感数据集共包含了 20 种地物，图 9 为该数据集在不同方法下的分类结果，表 2 为分类精度指标统计结果。在采用相同测试集的情况下，本文方法的 OA 与 Kappa 系数分别达到了 98. 04% 和 0. 977 3，其中 OA 相较于其它方法分别提高了 9. 00 个百分点和 7. 07 个百分点，Kappa 系数分别提高了 0. 104 9 和 0. 082 4。

2.4　实验结果分析

通过以上实验结果可以看出，本文所提出的高光谱影像作物分类方法相较于其它方法在分类精度上均有所提升，对于 Pavia University 数据集与雄安数据集，在选用训练集仅占全部像素点数目 10% 与 1% 的情况下，其整体分类精度最高分别提升了 8 个

表 1 不同方法在 Pavia University 数据集的分类效果

Tab. 1 Classification results with different methods of Pavia University dataset

类别	像素点数	训练样本数目	精度/%		
			SAE	1d－CNN	本文方法
沥青马路	6 631	66	92. 19	95. 22	98. 70
草地	18 649	186	99. 70	98. 13	99. 55
砂砾	2 099	21	43. 93	80. 94	95. 66
树木	3 064	31	74. 48	84. 50	97. 81
金属板	1 345	13	100	99. 93	100
裸地	5 029	50	66. 32	72. 30	100
柏油屋顶	1 330	13	93. 23	31. 65	98. 27
砖块	3 682	37	95. 06	87. 53	94. 70
阴影	947	9	100	100	100
OA/%			89. 48	89. 94	98. 73
Kappa 系数			0. 857 0	0. 864 3	0. 983 1

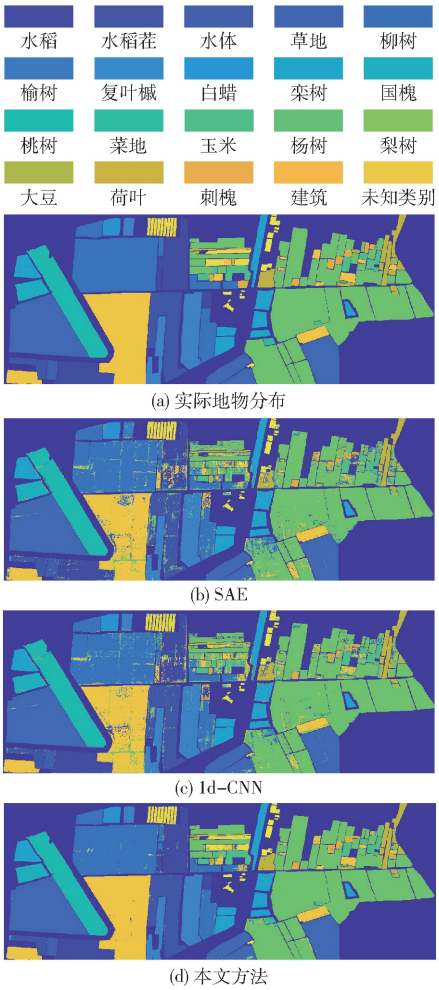

(a) 实际地物分布

(b) SAE

(c) 1d-CNN

(d) 本文方法

图 9 雄安数据集在不同方法下的分类结果

Fig. 9 Classification results of Xiong'an dataset with different methods

表 2 不同方法在雄安数据集的分类效果

Tab. 2 Classification results with different methods of Xiong'an dataset

类别	像素点数	训练样本数目	精度/%		
			SAE	1d－CNN	本文方法
水稻	225 647	2 256	72. 56	81. 41	96. 83
水稻茬	180 766	1 808	85. 56	92. 79	98. 84
水体	15 353	154	91. 75	93. 93	98. 92
草地	452 144	4 521	98. 82	98. 95	99. 47
柳树	475 591	4 756	92. 91	90. 06	98. 37
榆树	169 342	1 693	87. 13	95. 60	98. 70
复叶槭	23 304	233	95. 88	98. 09	99. 76
白蜡	165 647	1 656	97. 11	96. 63	99. 24
栾树	38 409	384	95. 65	97. 22	99. 17
国槐	193 830	1 938	97. 68	98. 25	99. 76
桃树	5 612	56	0. 91	2. 26	70. 74
菜地	59 165	592	81. 33	82. 17	95. 28
玉米	1 026 513	10 265	90. 28	93. 00	98. 90
杨树	7 151	72	77. 40	62. 09	83. 78
梨树	91 072	911	77. 90	84. 72	94. 42
大豆	29 148	291	46. 40	42. 75	65. 60
荷叶	1 496	15	0	0. 40	43. 92
刺槐	421 790	4 218	85. 96	87. 15	97. 63
建筑	65 514	655	64. 98	60. 43	93. 32
未知类别	29 616	296	87. 55	88. 68	97. 19
OA/%			89. 04	90. 97	98. 04
Kappa 系数			0. 872 4	0. 894 9	0. 977 3

百分点和 7 个百分点,而且对于观测场景中的每一类作物,本文所提出的算法均取得了较优的分类精度。

3 结论

(1)提出了一种融合栈式自编码网络与 CNN 的高光谱影像作物分类方法,该方法结合了 SAE 与 CNN 的优点,只需经过简单的无监督预训练和一次有监督训练,即可在一个网络中同时实现高光谱遥感数据的有效降维与分类,简化了传统高光谱影像分类的复杂流程。

(2)通过本文所提出的分类方法,在数据量较小的 Pavia University 数据集中,分类精度达到了 98. 73%,相对于传统方法提高了约 8 个百分点,在数据量较大的雄安数据集中,分类精度达到了 98. 04%,相对于传统方法提高了约 7 个百分点。实验结果表明,本文提出的方法适用于高光谱影像作物分类任务,能够提高农作物的识别分类精度。

参 考 文 献

[1] 童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报, 2016, 20(5): 689－707.
TONG Qingxi, ZHANG Bing, ZHANG Lifu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689－707. (in Chinese)

[2] BIOUCAS-DIAS J M, PLAZA A, CAMPS-VALLS G, et al. Hyperspectral remote sensing data analysis and future challenges

[J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2): 6 - 36.

[3] 方红亮, 田庆久. 高光谱遥感在植被监测中的研究综述[J]. 遥感技术与应用, 1998, 13(1): 62 - 69.
FANG Hongliang, TIAN Qingjiu. A review of hyperspectral remote sensing in vegetation monitoring[J]. Remote Sensing Technology and Application, 1998, 13(1): 62 - 69. (in Chinese)

[4] 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 Peijun, XIA Junshi, XUE Zhaohui, et al. Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2):236 - 256. (in Chinese)

[5] HUGHES G. On the mean accuracy of statistical pattern recognizers[J]. IEEE Transactions on Information Theory, 2003, 14(1): 55 - 63.

[6] IMANI M, GHASSEMIAN H. An overview on spectral and spatial information fusion for hyperspectral image classification: current trends and challenges[J]. Information Fusion, 2020, 59(1): 59 - 83.

[7] 臧卓, 林辉, 杨敏华. ICA 与 PCA 在高光谱数据降维分类中的对比研究[J]. 中南林业科技大学学报, 2011, 31(11): 18 - 22.
ZANG Zhuo, LIN Hui, YANG Minhua. Comparative study on descending dimension classification of hyperspectral data between ICA algorithm and PCA algorithm[J]. Journal of Central South University of Forestry & Technology, 2011, 31(11): 18 - 22. (in Chinese)

[8] 赵蔷, 宋笑雪, 郭新明, 等. 一种基于 PCA - LDA 的卫星遥感影像的分类方法[J]. 计算机应用与软件, 2013, 30(2): 198 - 204.
ZHAO Qiang, SONG Xiaoxue, GUO Xinming, et al. A classification approach for satellite remote sensing image based on PCA -LDA[J]. Computer Applications and Software, 2013, 30(2): 198 - 204. (in Chinese)

[9] 邵文静, 孙伟伟, 杨刚. 高光谱遥感纹理特征提取的对比分析[J]. 遥感技术与应用,2021,36(2): 431 - 440.
SHAO Wenjing, SUN Weiwei, YANG Gang. Comparison of texture feature extraction methods for hyperspectral imagery classification[J]. Remote Sensing Technology and Application,2021,36(2):431 - 440. (in Chinese)

[10] 王彩玲, 王洪伟, 胡炳樑,等. 基于邻域分割的空谱联合稀疏表示高光谱图像分类技术研究[J]. 光谱学与光谱分析, 2016, 36(9): 2919 - 2924.
WANG Cailing, WANG Hongwei, HU Bingliang, et al. A novel spatial-spectral sparse representation for hyperspectral image classification based on neighborhood segmentation[J]. Spectroscopy and Spectral Analysis, 2016, 36(9): 2919 - 2924. (in Chinese)

[11] 虎晓红,司海平. 基于自适应字典的小样本高光谱图像分类方法[J/OL]. 农业机械学报, 2021, 52(1): 154 - 161.
HU Xiaohong, SI Haiping. Hyperspectral image classification method with small sample set based on adaptive dictionary[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 154 - 161. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20210117&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2021.01.017. (in Chinese)

[12] 骆剑承,周成虎,杨艳. 人工神经网络遥感影像分类模型及其与知识集成方法研究[J]. 遥感学报, 2001, 5(2): 122 - 129.
LUO Jiancheng, ZHOU Chenghu, YANG Yan. ANN remote sensing classification model and its integration approach with geo-knowledge[J]. Journal of Remote Sensing, 2001, 5(2):122 - 129. (in Chinese)

[13] CHEN Y, ZHAO X, JIA X. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2381 - 2392.

[14] HU W, HUANG Y, WEI L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015:1 - 12.

[15] 陈亨,邓非. 分解式三维卷积神经网络的高光谱遥感影像分类[J]. 测绘科学, 2020, 45(8):96 - 102.
CHEN Heng, DENG Fei. Hyperspectral remote sensing image classification based on decomposed three-dimensional convolutional neural network[J]. Science of Surveying and Mapping, 2020, 45(8):96 - 102. (in Chinese)

[16] GONG Z, HU W, DU X, et al. Deep manifold embedding for hyperspectral image classification[J/OL]. IEEE Transactions on Cybernetics, 2021. https://ieeexplore.ieee.org/document/9408225.

[17] AHMAD M, SHABBIR S, RAZA R A, et al. Artifacts of different dimension reduction methods on hybrid CNN feature hierarchy for hyperspectral image classification[J]. Optik-International Journal for Light and Electron Optics, 2021(1): 167757.

[18] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313: 504 - 507.

[19] 戴晓爱, 郭守恒, 任清,等. 基于堆栈式稀疏自编码器的高光谱影像分类[J]. 电子科技大学学报, 2016, 45(3): 382 - 386.
DAI Xiaoai, GUO Hengsheng, REN Qing, et al. Hyperspectral remote sensing image chassification using the stacked sparse autoencoder[J]. Journal of University of Electronic Science and Technology of China, 2016, 45(3): 382 - 386. (in Chinese)

[20] 邢晨. 基于深度学习的高光谱遥感图像分类[D]. 武汉:中国地质大学, 2016.
XING Chen. Hyperspectral image classification using deep learning method[D]. Wuhan: China University of Geosciences,

2016. (in Chinese)
[21] 徐朋磊,薛朝辉,车子杰. 一种基于变分自编码器的高光谱图像分类方法[J]. 现代测绘, 2020, 43(1):16 - 20.
XU Penglei, XUE Zhaohui, CHE Zijie. Hyperspectral lmage classification method based on variational autoencoder[J]. Modern Surveying and Mapping, 2020, 43(1):16 - 20. (in Chinese)
[22] 张国东, 周浩, 方淇, 等. 基于栈式自编码神经网络对高光谱遥感图像分类研究[J]. 红外技术, 2019, 41(5): 63 - 69.
ZHANG Guodong, ZHOU Hao, FANG Qi, et al. Classification of hyperspectral remote sensing images based on stack self-encoding neural network[J]. Infrared Technology, 2019, 41(5): 63 - 69. (in Chinese)
[23] 曹林林, 李海涛, 韩颜顺, 等. 卷积神经网络在高分遥感影像分类中的应用[J]. 测绘科学, 2016, 41(9): 170 - 175.
CAO Linlin, LI Haitao, HAN Yanshun, et al. Application of convolutional neural networks in classification of high resolution remote sensing imagery[J]. Science of Surveying and Mapping, 2016, 41(9): 170 - 175. (in Chinese)
[24] 李恒辉, 郭交, 韩文霆, 等. 栈式稀疏自编码网络的多时相全极化 SAR 散射特征降维[J]. 遥感学报, 2020, 24(11): 1379 - 1391.
LI Henghui, GUO Jiao, HAN Wenting, et al. Scattering feature dimension reduction of multitemporal fully Pol SAR image based on stacked sparse autoencoder[J]. Journal of Remote Sensing, 2020, 24(11): 1379 - 1391. (in Chinese)
[25] 杜柳青,王承辉,余永维, 等. 基于深度自编码器的大型龙门加工中心热误差建模方法[J/OL]. 农业机械学报, 2019, 50(10): 395 - 400.
DU Liuqing, WANG Chenghui, YU Yongwei, et al. Error modeling method based on stacked auto-encoder for large gantry five sided machining center[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(10): 395 - 400. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20191046&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2019.10.046. (in Chinese)
[26] 康妙, 计科峰, 冷祥光, 等. 基于栈式自编码器特征融合的 SAR 图像车辆目标识别[J]. 雷达学报, 2017, 6(2): 167 - 176.
KANG Miao, JI Kefeng, LENG Xiangguang, et al. SAR target recognition with feature fusion based on stacked autoencoder [J]. Journal of Radars, 2017, 6(2): 167 - 176. (in Chinese)
[27] GUO J, LI H H, NING J F, et al. Feature dimension reduction using stacked sparse auto-encoders for crop classification with multi-temporal, Quad-Pol SAR data[J]. Remote Sensing, 2020, 12(2): 321 - 356.
[28] 何小飞,邹峥嵘,陶超,等. 联合显著性和多层卷积神经网络的高分影像场景分类[J]. 测绘学报,2016,45(9):1073 - 1080.
HE Xiaofei, ZOU Zhengrong, TAO Chao, et al. Combined saliency with multi-convolutional neural network for high resolution remote sensing scene classification[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(9): 1073 - 1080. (in Chinese)
[29] 岑奕, 张立福, 张霞,等. 雄安新区马蹄湾村航空高光谱遥感影像分类数据集[J]. 遥感学报, 2020, 24(11): 1299 - 1305.
CEN Yi, ZHANG Lifu, ZHANG Xia, et al. Aerial hyperspectral remote sensing classification dataset of Xiongan New Area (Matiwan village)[J]. Journal of Remote Sensing, 2020, 24(11): 1299 - 1305. (in Chinese)
[30] PAOLETTI M E, HAUT J M, PLAZA J, et al. Scalable recurrent neural network for hyperspectral image classification[J]. The Journal of Supercomputing, 2020, 76(11):8866 - 8882.