

〈图像处理与仿真〉

## 基于栈式自编码神经网络对高光谱遥感图像分类研究

张国东, 周浩, 方洪, 张露, 杨峻

(云南大学 信息学院, 云南 昆明 650500)

**摘要:** 为了有效利用高光谱遥感图像中的波段信息, 提高高光谱遥感图像分类的精确度, 本文提出了基于栈式自编码神经网络 (Stacked Autoencoder, SA) 对高光谱遥感图像进行分类。栈式自编码神经网络充分利用高光谱图像中的光谱信息, 对其进行相应特征提取, 避免了相邻信息间的相关性和信息的冗余, 本方法采用无监督学习和监督学习相结合, 既可以像传统方法那样进行降维, 简化相关的计算复杂度, 同时在分类精度上有很大地提高。

**关键词:** 栈式自编码神经网络; 高光谱图像; 光谱特征; 微调

中图分类号: TP75 文献标识码: A 文章编号: 1001-8891(2019)05-0450-07

## Classification of Hyperspectral Remote Sensing Images Based on Stack Self-encoding Neural Network

ZHANG Guodong, ZHOU Hao, FANG Qi, ZHANG Lu, YANG Jun

(School of Information, Yunnan University, Kunming 650500, China)

**Abstract:** In this study, we aim to utilize the band information in hyperspectral remote sensing images effectively and improve the accuracy of hyperspectral remote sensing image classification. The proposed method is aimed at the classification of hyperspectral remote sensing images based on a stacked autoencoder. A stack self-encoding neural network takes advantage of the spectral information in a hyperspectral image, extracts the corresponding features, and reduces the relativity between adjacent information and the redundancy. This method combines unsupervised learning with supervised learning. Hence, we can reduce the dimension and simplify the computation complexity as in traditional methods. The proposed algorithm improved the classification accuracy effectively.

**Key words:** stack self-encoding neural network, hyperspectral image, spectral feature, fine-tuning

### 0 引言

高光谱遥感技术是20世纪60年代发展起来的对地物目标进行识别分类的技术, 已经成为了具有特色的遥感前沿综合技术<sup>[1]</sup>, 在观测的领域中占有很重的分量, 如今高光谱遥感技术已经应用于海洋监测、军事、土地资源、城市监测、气象、地质、水利水电设施、探矿等方面<sup>[2]</sup>。各国加大了对高光谱遥感图像技术的研究。

在高光谱遥感图像处理中精确的目标分类有着重要的研究, 同时也是高光谱遥感图像处理领域研究

的热点<sup>[3]</sup>。高光谱遥感图像是由光谱成像仪通过采集数据形成的, 在军事、农业、土地资源等诸多领域都有应用, 高光谱图像数据是一个立方体, 和普通的二维图像相比, 多了一维光谱维数据信息, 其中包含的数据量很大, 不同地物的信息非常丰富, 这为后期进行识别提取特征提供了大量信息, 但是随着高光谱图像数据中波段数的增加, 数据量也成指数增加, 相邻波段间有很大的相关性, 造成信息冗余, 这些会影响地物识别和分类精度, 给高光谱图像分类带来了一定的难度, 处理数据的过程也变得复杂<sup>[4-5]</sup>。

由于高光谱遥感图像具有丰富地物波谱信息, 不

收稿日期: 2018-11-28; 修订日期: 2019-01-24

作者简介: 张国东 (1992-), 硕士, 主要从事视频图像、语音信息处理研究。E-mail: zgd13985300845@163.com。

通信作者: 周浩 (1972-), 副教授, 博士, 主要从事图像处理与视频跟踪研究。E-mail: zhouhao@ynu.edu.cn。

基金项目: 国家自然科学基金项目资助 (11663007); 中国科学院天体结构与演化重点实验室开放课题资助 (OP201510)。

同的物质,光谱不同,特定的物质有特定的光谱,这也为高光谱的遥感图像的分类提供了可能,基于特征空间的分类方法通常分为无监督学习和监督学习两种,无监督学习分类是不需要先验知识,可以直接对原始高光谱遥感图像数据进行分类,虽然分类精度往往不太理想,但是容易实现,比如K均值聚类<sup>[6]</sup>,监督学习分类需要一定的先验知识,也是常用的分类方法之一,首先要经过学习,训练得到分类器,通过得到的分类器对为标签的样本进行分类,如最大似然估计、支持向量机等分类方法,总体来说,监督学习分类效果比非监督分类效果要好很多<sup>[7]</sup>,支持向量机是人工智能神经网络发展起来的一种机器学习方法,在较长时间段里,支持向量机(Support Vector Machine, SVM)算法在高光谱图像分类中占很重要的位置<sup>[8-9]</sup>,近几年随着深度学习研究的火热,深度学习可以提取不同层次的特征,在图像处理、自然语言处理等方面取得了重大进展,因此深度学习受到了越来越多研究学者的关注,有很多研究学者也通过把深度学习相关的方法应用到高光谱图像分类中,使分类精度有了提高,陈雨时等使用深度置信网络(Deep Belief Net, DBN)来对图像进行分类,从而提高分类效果<sup>[10]</sup>。胡伟等人使用神经网络(Convolutional Neural Networks, CNN)来改善以提高分类精度,基于DBN神经网络和CNN神经网络对高光谱图像分类都取得了很好的效果<sup>[11]</sup>。但是目前基于神经网络对高光谱图像分类方法研究中,利用光谱信息对高光谱图像的分类取得的正确率还不是很高。

本文为了提高分类的正确率,采用栈式自编码神经网络和级联方式通过对高光谱图像光谱数据进行训练和分类,本文首先采用非监督学习方式对高光谱数据进行降维,提取光谱特征,然后通过监督学习将提取的特征进行分类<sup>[12]</sup>。

## 1 实验方法及相关技术

### 1.1 自编码神经网络

自编码神经网络是属于非监督学习领域中的一种,它可以自动从无标注的数据中学习相应的特征,是一种以重构输入信号为目标的神经网络,它可以重构出比原始数据更好的数据特征来描述原始数据所代表的类别,学习特征的能力较强,在深度学习中经常用自编码神经网络训练生成的数据特征来代替原始数据<sup>[13]</sup>,以便在后续的识别分类中有更好的效果。

自编码神经网络是输入等于输出的神经网络,输出的数据特征可以代替输入数据的特征,但是输出的数据不等于输入的数据<sup>[14]</sup>。自编码神经网络最基本的

模型可以分为3层神经网络,由输入层、隐含层、输出层组成,如图1所示,自编码神经网络也可以理解为两个部分,分别为编码过程和解码过程,从输入开始到中间低维数据特征的过程叫做编码,从中间低维数据特征到输出层的过程叫做解码,编码过程和我们主成分分析(PCA)算法功能相似<sup>[15]</sup>,都是降维的目的,解码的目的是尽可能地恢复原始数据。




图1 自编码神经网络结构图

Fig.1 Self-encoding neural network structure

### 1.2 数据集选择

Pavia University 的数据集是用 ROSIS 传感器在意大利北部的帕维亚地区的一次采集获得的<sup>[16]</sup>,该图像的空间分辨率是1.3m,该图像的像素是610×340,总共有207400个像素点,其中分类样本为9类,这9类的样本总数目是42776个。Pavia University 的图像是通过由115个光谱波段组成的,由于受到大气和噪声的影响,去掉了12个光谱波段,只保留了103个光谱波段。Pavia University 图像如图2所示。




图2 Pavia University 图像 Fig.2 Pavia University image

### 1.3 数据预处理

高光谱图像是三维的数据张量,我们可以用一个矩阵 $I$ 对其表示,矩阵 $I=M \times N \times P$ , $M$ 表示图像的行像素, $N$ 表示图像的列像素, $P$ 表示图像的光谱波段数据<sup>[17]</sup>。因为高光谱遥感图像比普通图像多了一维光谱维数据,所以计算量大、处理起来很复杂<sup>[18]</sup>。为了减小计算量、提高效率,我们将对Pavia University图像的三维数据进行归一化,归一化的计算公式如式(1)所示,其中 $X'$ 是归一化后的数据, $X$ 是原始数据,mean是均值,std是方差,归一化的目的是使计算量

减小和收敛快，从而得到更好的分类效果：

$$X' = \frac{(X - \text{mean})}{\text{std}}$$

(1)

1.4 栈式自编码神经网络结构

栈式自编码神经网络是通过在自编码神经网络的基础上进行改变形成的。因为在深度学习中，对一些复杂数据进行特征提取，为了取得好的效果，一般的搭建的神经网络都在三层网络以上，但是随着神经网络层数的增多，在进行训练网络时，一开始参数设置都是随机初始化，反馈回来的梯度下降值会消失，造成参数无法进行更好的调节，神经网络层数的增多并不能带来好的训练结果。栈式自编码神经网络很好的解决了这一问题，栈式自编码神经网络由多层训练好的自编码器组成的神经网络，栈式自编码神经网络中的每一层的自编码器都是单独训练的，相当于每一层的参数都是经过合理的初始化，而不是随机初始化，这样既保证了降维特征的可控性、参数的可控性，同时也使高维度的数据分类问题简单化，这就相当初始化了合理的参数使数据进行降维，每一层自编码器单独训练的好处是层数少，容易训练，更易收敛和精度高。

本文实验中，采用基于栈式自编码神经网络（Stacked Autoencoder，SA）对高光谱图像进行分类，本文设计的栈式自编码神经网络共五层，由一层输入层、三层隐藏层、和一层输出层组成，采用五层神经网络主要原因是为了更好地提取特征和节约时间，为了不影响分类精度和训练每一层的速度，针对本试验采用的是 Pavia University 数据集，其中包含 103 个波段，对其进行 9 种分类，我们进行了每一层数据量设定，第一层采用无监督学习将 103 个波段降维到 80 个波段，第二层采用无监督学习将 80 个波段降维到 50 个波段，第三层采用无监督学习将 50 个波段降维到 30 个波段，第四层采用无监督学习将 30 个波段降维到 9 个波段，最后一层也就是输出层，采用监督学习结合 softmax 分类器，将第四层降维后的 9 个波段进行分类。本文设计的五层栈式自编码神经网络参数设定的框图如图 3 所示。利用原始输入来训练网络的第一层，得到其第一层网络训练好的参数，然后第一层网络中通过降维后的数据作为第二层网络的输入，进行第二层神经网络的训练，第二层网络训练好得到第二层网络参数，依次类推，直到训练完最后一层神经网络，对于上述训练方式，在训练每一层参数的时候，会固定其它各层参数保持不变。对每一层的神经网络进行训练都采用的是无监督学习的方式，为了得到更好分类的效果，在上述的每一层网络都训练完

后，采用“微调（fine-tuning）”<sup>[19]</sup>的方法通过反向传播算法来调整所有层的参数，以便取得更好的分类结果<sup>[19]</sup>。这里进行微调训练采用的是有监督学习方式，最后将网络中最深那一层的输出作为 softmax 分类器的输入特征，最终进行分类。图 4 所示是 5 层的栈式自编码神经网络分类结构图。

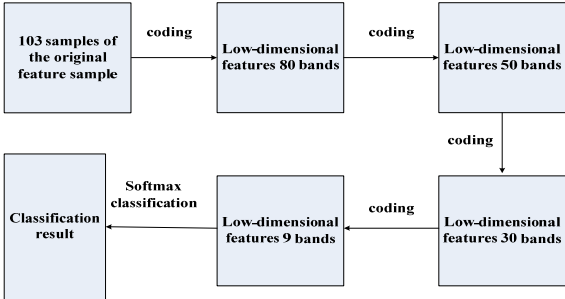


图 3 5 层栈式自编码神经网络参数设定的结构图  
Fig.3 Structure diagram of five-layer stack self-encoding neural network parameter setting

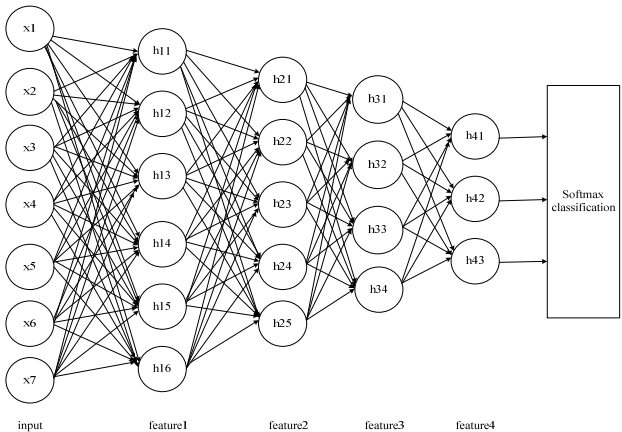


图 4 5 层的栈式自编码神经网络分类结构图  
Fig.4 5-layer stack self-encoding neural network classification structure

五层栈式自编码神经网络具体训练的方法：  
无监督 pre-training 阶段：

首先进行第一层自编码神经网络的训练，第一层网络训练结构图如图 5 所示，训练之前第一层网络参数是随机设置的，当网络训练结束后，参数经过了调整，相当于第一层网络参数进行了很好的初始化设置，我们把第一层网络中编码后的数据作为第二层自编码神经网络的输入，以进行第二层神经网络的训练，第二层网络训练结构图如图 6 所示，训练之前第二层网络参数也是随机设置的<sup>[20]</sup>，训练结束后，第二层网络参数也就设置好了，把第二层网络中编码后的数据作为第三层网络的输入，如此循环操作直到第四层网络训练结束，到此无监督训练过程就完成了。

有监督微调阶段：

在无监督学习训练神经网络中最后一层神经网络的编码后的数据作为 softmax 分类器的输入,最后把每一层训练的网络进行级联,利用无监督学习训练网络的参数作为微调神经网络中的初始化参数,进行微调网络训练,训练好后,采用测试集进行测试训练好的网络<sup>[21]</sup>。




图5 第一层网络训练结构图  
Fig.5 First layer network training structure

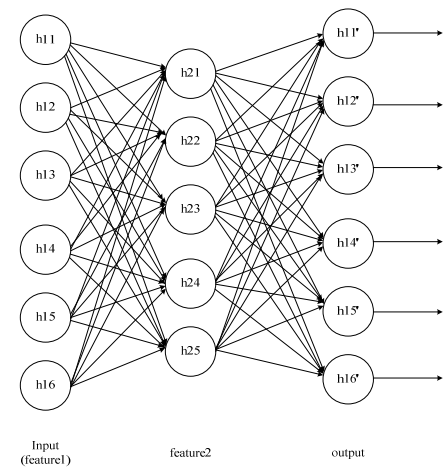


图6 第二层网络训练结构图  
Fig.6 Layer 2 network training structure

在训练每一层自编码神经网络时,我们设置网络的学习率为 0.01,这样做的目的是使每一层的网络参数快速收敛,节约训练时间,在微调训练当中我们采用的学习率为 0.001,让收敛速度变慢,让网络中所有参数得到最优解,让分类效果变得更好,如果没有使用级联的方式,直接在人为初始化上的参数使用微调,这样所有参数只会得到局部最优解,分类结果大大下降,影响分类精度。这也是为什么要把每一层网络进行单独训练然后再级联的原因,经过微调训练

后,就可以输入测试集输出最终结果。具体一些参数见表 1。

2 实验结果与分析

本试验采用 Windows 7 旗舰版 64 位系统、Tensor Flow 框架、编译的环境为 Anaconda3、编写语言是 python。为了证明本试验设计的栈式自编码神经网络对高光谱图像进行分类方法在精确度上有很大的提高,同时也为了更有说服力,我们这里选择和基于深度学习的高光谱图像分类及其参数设置研究<sup>[22]</sup>论文中的精确度对比,我们选择相同的数据集 Pavia University,训练集也是和基于深度学习的高光谱图像分类及其参数设置研究论文中选择一样的数量,每一种类训练数量占每一种类总数量的 20%,具体数据可以见表 2。在基于深度学习的高光谱图像分类及其参数设置研究论文中采用了基于 DBN 神经网络对 Pavia University 数据集进行分类和基于卷积神经网络对 Pavia University 数据集进行分类,在用两种神经网络方法对 Pavia University 数据集进行分类时,输入数据分别采用了 3 种不同的方法,第一种方法只采用高光谱图像中的光谱信息作为输入数据,第二种方法只采用空间信息作为输入数据;第三种方法是将光谱信息和空间信息相结合作为输入数据。分类模型和分类精度见表 3。

表 1 栈式自编码神经网络中参数设置

Table 1 Parameter settings in stack self-encoding neural network				
First three levels of learning	Optimizer	Loss function	Post-cascade learning rate	Number of training
0.01	Adam	Mean square error	0.001	5000

使用 DBN 神经网络训练,用不同的分类模型得到对 Pavia University 图像的分类结果如图 7 所示。使用 CNN 神经网络训练,用不同的分类模型得到对 Pavia University 图像的分类结果如图 8 所示。

通过观察图 7 和图 8 的分类结果显示,对比空间样本,有些样本会被神经网络错分,有些单一颜色区域地物会被网络识别成其他地物,导致颜色混合在一块,正确率降低,同时也可以由表 3 的直观的正确率结果可知,在 DBN 神经网络和 CNN 神经网络中光谱信息+空间信息的正确率比单一光谱信息或者空间信息的正确识别率要高,CNN 神经网络的分类效果整体上要强于 DBN 神经网络。



表 2 Pavia University 图像地物类别及样本数量      Table 2 Pavia University image feature categories and sample size

Number	Different features	Number of training samples	Number of test samples	Total number of samples per class
1	pitch	1326	5305	6631
2	meadow	3730	14919	18649
3	gravel	420	1679	2099
4	trees	612	2452	3064
5	metal plate	269	1076	1345
6	bare land	1006	4023	5029
7	asphalt	266	1064	1330
8	brick	736	2946	3682
9	shadow	189	758	947
Total number of samples		8554	34222	42776

表 3 Pavia University 图像在不同分类模型下的正确率

Table 3 Correct rate of Pavia University images under different classification models

Classification model	Spectral information +DBN	Spatial information +DBN	Spatial information +DBN	Spectral information +CNN	Spatial information +CNN	Empty spectrum information +CNN	Spectral information +SA
Correct rate	81.29%	85.86%	89.20%	84.87%	91.42%	92.03%	98.24%

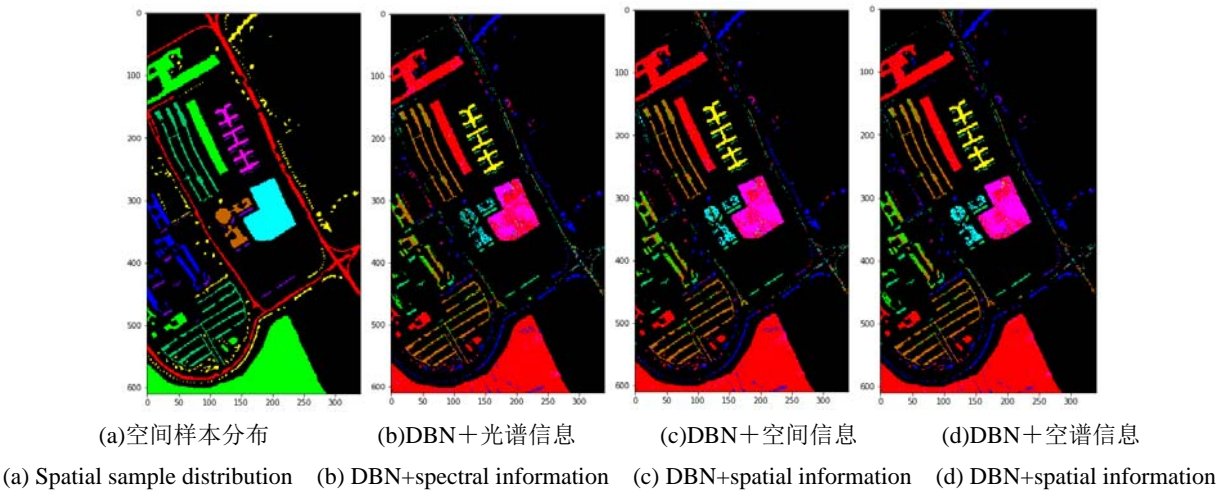


图 7 Pavia University 图像在 DBN 网络不同模型下的分类结果图

Fig.7 Classification results of Pavia University images under different DBN network models

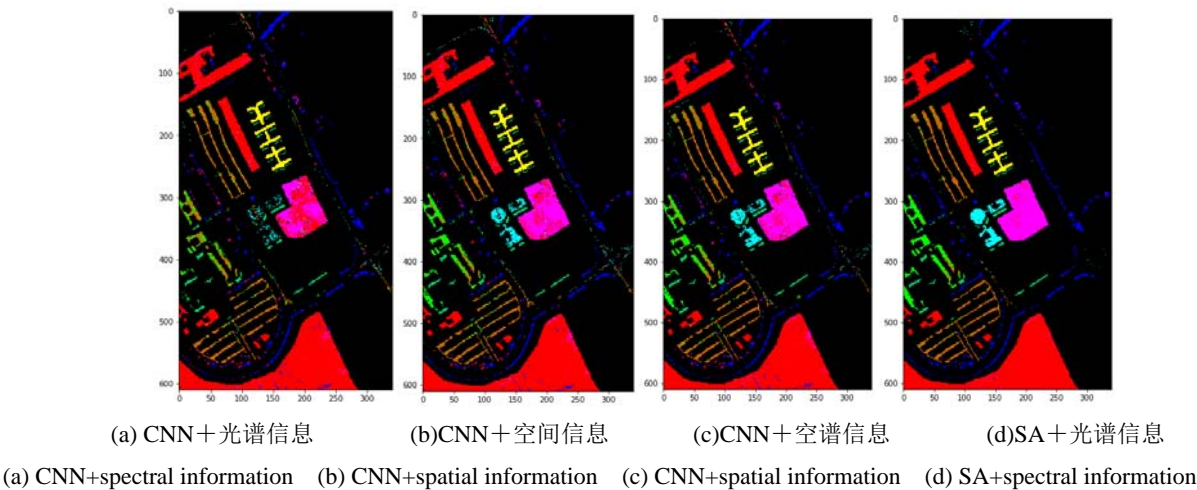


图 8 Pavia University 图像在不同模型下的分类结果图

Fig.8 Classification results of Pavia University images under different models

本文经过对含有五层的栈式自编码神经网络进行训练,每层迭代 5000 次,然后通过网络进行微调,同样也迭代 5000 次,最后用测试集测试,得到的分类结果图如图 8(d)所示。

本实验得出的分类结果图像与图 8 中的(c)图相比,一种颜色代表一种类别,图 8 中的(c)图中明显有很多颜色错分,比如粉色区域中有红色,红色区域中有蓝色,还有一些种类没有被区分出来,比如浅蓝色区域有些地方没有被识别出来,图 8(d)中错分和没被识别出来的样本很少,由此可以看出图 8(d)分类结果明显好很多,跟原图实际分类的结果图像几乎一样,为了更好地体现分类效果,我们把测试数据集在测试时候的损失函数和正确率做成图表形式,如图 9 和图 10 所示。通过损失函数可以知道随着训练次数的增加,损失函数逐渐趋近于零,说明识别率也随着训练次数的增加而增加,通过图 10 正确率曲线图也可以证明随着训练次数的增加,正确率也在增加,趋向于 1。

本次实验经过测试数据验证,最后识别的正确率是 98.24%,与前面的 DBN 神经网络和 CNN 神经网络分类结果相比,比正确率最高的空谱+CNN 分类结果还高出 6.21%,如表 3 所示,本方法只是应用了光谱信息,没有对空间信息进行处理,由此可见本方法取得了很好的效果。




图9 损失函数在训练回合中的变化图

Fig.9 Change diagram of the loss function in the training round

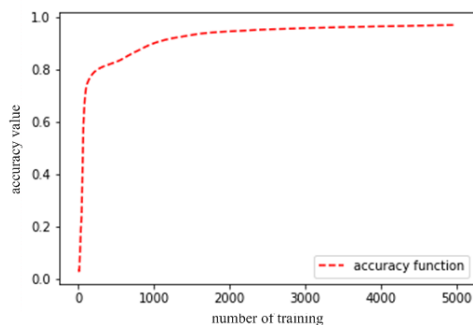


图10 正确率在训练回合中的变化图

Fig.10 The correct rates in the training round

影响本文方法能取得这么好效果的因素有很多,比如说数据集在预处理方面进行归一化处理,使数据

在训练过程当中收敛,学习率参数的选取和训练次数参数的选取,学习率 0.01 参数的选取是为了在训练中快速拟合输入的起始数据,学习率 0.001 参数的选择是为了在微调中更好地拟合分类效果,训练次数的选择,如果次数较少,影响拟合效果和最终的正确率,训练次数太多则会增加训练时间,有时会产生过拟合现象。最主要的原因是每一层网络结构实现单独训练,这样保证了降维后的特征可控性,参数也减少了很多,避免随着网络层数的增加,反向传播误差越来越小,到最后影响分类精度。

### 3 小结

为了更好地利用光谱信息进行分类,能更好地提高准确率,本文采用了栈式自编码神经网络,通过级联的方法对高光谱遥感图像进行分类,本次实验主要应用光谱信息,通过无监督学习方法对高维的数据进行降维,每一层降维都是单独训练形成的,每一层网络训练好了,这就好比合理初始化了这一层网络的参数,同时也对数据进行了降维。虽然本试验方法的正确率已经很高,也取得了很好的分类效果,但是通过对比实验也可以看出,无论什么神经网络,空间信息和空间信息+光谱信息都比单一光谱信息分类效果要好,所以在今后的研究中会使用光谱信息和空间信息相结合的方法,进而提高分类精度<sup>[23]</sup>。

### 参考文献:

- [1] 张康, 黑保琴, 周壮, 等. 变异系数降维的 CNN 高光谱遥感图像分类[J]. 遥感学报, 2018, 22(1): 87-96.  
ZHANG Kang, HEI Baoqin, ZHOU Zhuang, et al. Classification of CNN hyperspectral remote sensing images with reduced coefficient of variation[J]. *Journal of Remote Sensing*, 2018, 22(1): 87-96.
- [2] 张凯. 基于子空间分析的高光谱图像目标检测技术研究[D]. 杭州: 杭州电子科技大学, 2010.  
ZHANG Kai. Research on target detection technology of hyperspectral image based on subspace analysis[D]. Hangzhou: Hangzhou University of Electronic Technology, 2010.
- [3] 宋相法, 曹志伟, 郑逢斌, 等. 基于随机子空间核极端学习机集成的高光谱遥感图像分类[J]. 计算机科学, 2016, 43(3): 301-304.  
SONG Xiangfa, CAO Zhiwei, ZHENG Fengbin, et al. Classification of Hyperspectral Remote Sensing Images Based on Random Subspace Kernel Extreme Learning Machine Integration[J]. *Computer Science*, 2016, 43(3): 301-304.
- [4] 赵春晖, 李晓慧, 王玉磊. 高光谱图像异常目标检测研究进展[J]. 电子测量与仪器学报, 2014, 28(8): 803-811.  
ZHAO Chunhui, LI Xiaohui, WANG Yulei. Research progress of abnormal target detection in hyperspectral image[J]. *Journal of Electronic Measurement and Instrument*, 2014, 28(8): 803-811.

- [5] 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. Progress in classification of hyperspectral remote sensing images[J]. *Journal of Remote Sensing*, 2016, 20(2): 236-256.
- [6] 王慧贤, 靳惠佳, 王娇龙, 等. k 均值聚类引导的遥感影像多尺度分割优化方法[J]. 测绘学报, 2015, 44(5): 526-532.  
WANG Huixian, ZHAI Huijia, WANG Jiaolong, et al. Multi-scale segmentation optimization method for remote sensing image guided by k-means clustering[J]. *Journal of Surveying and Mapping*, 2015, 44(5): 526-532.
- [7] 杨盛春, 贾林祥. 神经网络内监督学习和无监督学习之比较[J]. 徐州建筑职业技术学院学报, 2006(3): 55-58.  
YANG Shengchun, JIA Linxiang. Comparison of Supervised Learning and Unsupervised Learning in Neural Networks[J]. *Journal of Xuzhou Institute of Architectural Technology*, 2006(3): 55-58.
- [8] HUANG C, Davis L S, Townshend J R G. An assessment of support vector machines for land cover classification[J]. *International Journal of Remote Sensing*, 2002, 23(4): 725-749.
- [9] 阳庆. 基于支持向量机的高光谱图像分类方法研究[D]. 郑州: 解放军信息工程大学, 2009.  
YANG Qing. Research on hyperspectral image classification based on support vector machine[D]. Zhengzhou: PLA Information Engineering University, 2009.
- [10] 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.
- [11] HU W, HUANG Y, WEI L, et al. Deep Convolutional Neural Networks for Hyperspectral Image Classification[J]. *Journal of Sensors*, 2015(2): 1-12.
- [12] 叶志京. 面向高光谱图像空谱分类的学习算法研究[D]. 武汉: 华中科技大学, 2016.  
YE Zhijing. Research on learning algorithm for hyperspectral image space spectrum classification[D]. Wuhan: Huazhong University of Science and Technology, 2016.
- [13] 李时峰. 基于自编码神经网络文本特征选择的研究[D]. 天津: 天津科技大学, 2016.  
LI Shifeng. Research on text feature selection based on self-encoding neural network[D]. Tianjin: Tianjin University of Science and Technology, 2016.
- [14] 汪海波. 基于深度学习的人脸识别方法研究[D]. 合肥: 合肥工业大学, 2014.  
WANG Haibo. Research on face recognition based on deep learning[D]. Hefei: Hefei University of Technology, 2014.
- [15] 徐培, 蔡小路, 何文伟, 等. 基于深度自编码网络的运动目标检测[J]. 计算机应用, 2014, 34(10): 2934-2937, 2962.  
XU Pei, CAI Xiaolu, HE Wenwei, et al. Moving target detection based on deep self-coding network[J]. *Journal of Computer Applications*, 2014, 34(10): 2934-2937, 2962.
- [16] 吴林生. 基于集成的半监督学习和主动学习算法研究[D]. 西安: 西安电子科技大学, 2014.  
WU Linsheng. Research on semi-supervised learning and active learning algorithms based on integration[D]. Xi'an: Xidian University, 2014.
- [17] 邓禄群. 高光谱图像类别信息相关技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2010.  
DENG Luqun. Research on related information of hyperspectral image category information[D]. Harbin: Harbin Engineering University, 2010.
- [18] 谷金平. 基于云计算的高光谱遥感图像检索研究[D]. 南京: 南京理工大学, 2017.  
GU Jinping. Research on hyperspectral remote sensing image retrieval based on cloud computing[D]. Nanjing: Nanjing University of Science and Technology, 2017.
- [19] 王山海, 景新幸, 杨海燕. 基于深度学习神经网络的孤立词语音识别的研究[J]. 计算机应用研究, 2015, 32(8): 2289-2291, 2298.  
WANG Shanhai, JING Xinxing, YANG Haiyan. Research on speech recognition of isolated words based on deep learning neural network[J]. *Journal of Computer Applications*, 2015, 32(8): 2289-2291, 2298.
- [20] 张成刚, 姜静清. 一种稀疏降噪自编码神经网络研究[J]. 内蒙古民族大学学报: 自然科学版, 2016, 31(1): 21-25, 93.  
ZHANG Chenggang, JIANG Jingqing. Research on a sparse noise reduction self-encoding neural network[J]. *Journal of Inner Mongolia University for Nationalities: Natural Science Edition*, 2016, 31(1): 21-25, 93.
- [21] 刘文祺. 基于深度神经网络的铁路异物检测算法[D]. 北京: 北京交通大学, 2016.  
LIU Wenqi. Railway foreign object detection algorithm based on deep neural network[D]. Beijing: Beijing Jiaotong University, 2016.
- [22] 孙巧巧. 基于深度学习的高光谱图像分类及参数设置研究[D]. 青岛: 青岛科技大学, 2018.  
SUN Qiaoqiao. Research on classification and parameter setting of hyperspectral image based on deep learning[D]. Qingdao: Qingdao University of Science and Technology, 2018.
- [23] 肖倩. 结合空间信息与光谱信息的高光谱图像分类研究[D]. 哈尔滨: 哈尔滨工程大学, 2013.  
XIAO Qian. Research on hyperspectral image classification based on spatial information and spectral information[D]. Harbin: Harbin Engineering University, 2013.