

文章编号 1004-924X(2019)03-0680-14

高光谱图像分类的研究进展

闫敬文¹, 陈宏达¹, 刘 蕾^{2*}

- (1. 汕头大学 工学院电子系, 广东 汕头 515063;
2. 汕头大学 医学院, 广东 汕头 515063)

摘要:高光谱图像分类是利用高光谱数据图谱合一且光谱信息丰富的特点,对图像中的每个像素进行分门别类,以达到对地物目标进行高精度分类和自动化识别的目的,是对地观测的重要组成部分。在分析高光谱图像特点的基础上,本文从普通机器学习和深度学习这两方面对高光谱图像像素级分类的研究进展及效果进行总结、评述和比较,通过具体实验的结果对比,直观地展现各种算法的优劣。针对高光谱分类问题,本文从两个方面对今后的研究方向及发展前景进行了分析和展望。一方面,在算法研究上,高光谱图像分类算法可在保证分类精度的前提下降低算法的复杂度,利用多源遥感数据、多特征综合、多尺度复合,提升小样本、少参数分类模型的分类精度,适应智能化、快速化高光谱遥感对地观测的发展要求;另一方面要紧密结合市场应用需求,重视高光谱图像在实际中的应用,研究具有市场竞争力的分类算法,提升高光谱图像分类在遥感技术应用领域的竞争力。

关键词:高光谱图像;像素级分类;机器学习;深度学习

中图分类号:TP751;TP181 **文献标识码:**A **doi:**10.3788/OPE.20192703.0680

Overview of hyperspectral image classification

YAN Jing-wen¹, CHEN Hong-da¹, LIU Lei^{2*}

- (1. Department of Electronics, Shantou University, Shantou 515063, China;
2. Medical College, Shantou University, Shantou 515063, China)

* Corresponding author, E-mail: wliulei@stu.edu.cn

Abstract: Hyperspectral image classification comprises the classification of every pixel in an image by applying the combination of hyperspectral data atlas and rich spectral information, which can be employed for achieving high-precision classification and automatic recognition of ground objects. Hyperspectral image classification plays an important role in earth observation. Based on the analysis of the characteristics of hyperspectral images with respect to two aspects of general machine learning and deep learning, the progress in associated research and comparison of the effects of pixel-level classification of hyperspectral images are summarized and discussed in this study. The advantages and disadvantages of various algorithms were visually illustrated by comparing the corresponding results. Research objectives and development prospects of hyperspectral image classification are analyzed with respect to two aspects. Firstly, various algorithms need to be studied. A hyperspectral classification algorithm can guarantee classification accuracy required for reducing the algorithm complexity by incor-

收稿日期:2018-10-30; **修订日期:**2018-11-26.

基金项目:国家自然科学基金资助项目(No. 61672335, No. 61601276);广东省自然科学基金资助项目(No. 2016A030310077)

porating multi-source remote sensing data with multi-feature and multi-scale composites. Such an algorithm can improve the classification accuracy of a small sample of the classification model with few parameters, and it can adapt to the intelligent and rapid development requirements of earth observation. Secondly, market applications need to be closely integrated. Practical applications of hyperspectral images should be considered and efficient classification algorithms with marketable competency should be investigated for enhancing the applicability of hyperspectral image classification in remote sensing applications.

Key words: hyperspectral image; pixel-level classification; machine learning; deep learning

1 引言

随着空间遥感技术地不断发展,获取遥感数据的空间分辨率和光谱分辨率不断提升,随之产生了高光谱遥感技术。自20世纪80年代以来,高光谱遥感技术显现出越来越多的优势,目前已成为对地观测的重要组成部分,也是国际对地观测技术研究的前沿热点。高光谱图像能够获取地表物体上百个连续波段的光谱信息,其谱范围包含着紫外、可见光、近红外及中红外等波段,具有较高的光谱分辨率。随着遥感技术的飞速发展,高光谱图像的空间分辨率也得到了极大的提升,增强了高光谱数据对于地物的表达能力。利用高光谱数据图谱合一且波段覆盖范围广的特性,能够大大地提高其他地物类别的分辨识别能力^[1],使得高光谱遥感技术被广泛地应用到精细化农业^[1-3]、军事^[4-5]、环境监测^[6-7]等方面。

高光谱图像分类的主要目的是将图像中的像素进行类别判定,从而实现地物类别的自动识别,为其他部门提供服务。由于高光谱图像本身特殊的数据特点,使得其在分类领域面临着以下几个方面的挑战^[8-9]:(1)高光谱数据的光谱维具有上百个波段值,且波段间信息具有冗余,导致其数据维度高,处理时需要耗费大量计算资源^[10];(2)同物异谱和异物同谱问题导致常规的线性分类器难以较好地处理高光谱图像;(3)混合像素的存在给高光谱图像分类带来了不小干扰,因为一个像素对应着多个地物类别目标极易导致误分类;(4)高光谱图像样本标注成本较高,导致标签样本不足。

早期应用于高光谱图像分类的机器学习分类诸如支持向量机(Support Vector Machine, SVM)^[11]、K-近邻法(K-Nearest Neighbor, K-

NN)^[12]、朴素贝叶斯^[13]、决策树^[14]、极限学习机(Extreme Learning Machine, ELM)^[15]都是基于高光谱图像的谱特征,并没有考虑到其空间信息,分类效果大都不是理想^[16]。不过值得一提的是,SVM是其中最具代表性也是分类效果较好的一种机器学习分类方法,它利用核变换技术能够通过较少的训练样本来获得一个分离超平面,进而将不同类别的高光谱像素进行区分,避免了Houghes现象,获得较好的效果。近年来,稀疏表示分类(Sparse Representation-based Classifier, SRC)作为一种新型机器学习分类器开始受到越来越多学者的重视,大批基于SRC分类器的算法被提出^[18-22]。

基于神经网络的深度学习算法虽然很早就被提出,但迫于模型参数庞大且当时硬件算力不足,一直得不到大规模应用与发展。直到2012年AlexNet^[23]在谷歌举办的ImageNet比赛中取得重大突破之后,基于卷积神经网络(Convolutional Neural Networks, CNN)的深度学习方法才开始得到全球各个研究单位重视,VGG(16/19)^[24]、ResNet^[25]、GoogLeNet^[26]等关于CNN的深度学习算法不断被提出并应用于图像分类、目标检测、图像风格转换等领域。随着CNN的不断发展,基于深度学习的高光谱图像分类方法已成为了学界的研究新热点,这其中当然也包含高光谱图像分类领域。相较于传统机器学习算法,深度学习算法能够通过训练集来学习自动地获得数据的高级特征,而不用像传统方法一样需要通过特征工程来进行分类特征选择,使得分类模型能更好地表达数据集本身的特点,提高分类精度。2015年,胡伟等研究者把CNN应用到基于谱特征的深度表示方法的研究当中,效果比传统的SVM算法更加优异^[27]。随后,Romero A等研究者通过CNN以贪婪分层方式学习得到无监督稀疏特

征,并用于最终的像素分类^[28]。Zhao 等学者 CNN 被利用在局部判别嵌入后从子空间自动发现空间相关特征^[29]。随后, Li 等学者让 CNN 通过学习像素对特征来获得更加准确分类能力^[30]。2016 年,武汉大学的张良培教授系统性地阐述与分析了如何对遥感图像构建一个普遍的深度神经网络,同时也首次对行业内各种深度学习算法在遥感图像上的表现进行评估^[31]。2018 年, Zhang 等学者提出了一种基于多区域的高光谱图像 CNN 分类方法^[32]。

虽然高光谱图像分类领域已经取得了不俗的研究成果和进展,但当前对该领域研究现状系统地总结、分析与评价仍然相对欠缺。因此,本文将针对目前高光谱图像分类领域的发展状况进行较为系统地阐述,向广大科研工作者提供一个较为全面的行业综述。本文主要从普通机器学习和深度学习这两大方面来系统性阐述当前国内外高光谱图像分类领域的研究现状,依次进行分析和实验结果评价,最后提出建议和展望。

2 普通机器学习方法在高光谱图像分类中的应用

高光谱图像分类是对图像中的每一个像素样本进行分门别类。机器学习的高光谱图像分类方法根据是否需要引入先验类别的训练样本,主要可分为无监督学习方法和监督学习方法。

2.1 无监督学习分类

无监督学习是在无先验知识的前提下,仅凭高光谱图像自身光谱特征的分布规律进行“盲目”分类(聚类)。无监督学习虽然不需要人工标注信息,但必须对结果进行大量地分析和后处理,匹配难度大、计算量大,最终的结果精度也不是很准确。典型的无监督学习方法有 K-means 聚类^[33]和动态聚类分析法(Iterative Selforganizing Data Analysis, ISODATA)^[34]。

K-means 聚类方法是首先随机初始化 K 个聚类中心,然后数据集内每个样本根据与各个聚类中心的距离,选择距离最小的聚类中心。所有具有相同聚类中心的点聚为一簇。之后重新计算每个簇的聚类中心,重复前面操作直至各个聚类中心不再变化。聚类中心的个数 K 需要人为指

定。ISODATA 是一种与 K-means 较为相似的算法,主要区别在于该算法能够在聚类过程中动态调整聚类中心的个数。当某一类样本方差较大且样本数量较大时,对该类进行分裂;而当某两个类别的聚类中心的距离较小时,对它们进行合并。然而,童庆禧等人指出无监督方法得到的结果并不能直接作为高光谱图像分类的结果,最终的分类结果需要实地勘测比对才能决定^[35]。

2.2 监督学习分类

监督学习是根据先验知识即标签训练样本来学习获得高光谱图像像素样本与对应类别之间的内在联系,以此作为未被标注的像素样本与相应类别的映射,最终为未标注像素确定类别。监督学习的分类方法虽然需要人工标注的训练样本进行辅助训练分类模型,其缺点在于人工成本高且含有较强的人为主观因素,相比无监督学习方法,其优势在于可通过先验的训练样本反复检验以提高模型分类精度,因此监督学习方法比无监督学习方法更受广大科研工作者的青睐。应用于高光谱图像分类的主要监督学习方法有 SVM、K-NN、朴素贝叶斯、决策树、ELM、SRC 和深度学习方法等及他们的衍生算法,他们的分类框架如图 1 所示。在这些算法中,特征提取是分类过程中必不可少的环节,它在很大程度上影响着算法最后的分类精度^[8]。根据是否能自动地从原始高光谱数据中自动学习特征,本文将监督机器学习分类方法分别为普通机器学习分类和深度学习分类两大类。




图 1 监督学习的分类框架

Fig. 1 Classification framework for supervised learning

基于普通机器学习的分类方法只能依据高光谱图像固有的特征或者经过特征工程设计的特征进行来拟合样本与对应类别间的关系。根据所依据的特征,又可将普通机器学习分类方法归为基

于谱特征的分类方法和基于空谱联合特征的分类方法。

(1)基于谱特征的分类方法。早期机器学习分类方法仅仅以高光谱图像的谱特征或经过特征工程从原始数据提取的谱特征作为分类的依据,没有利用图像的空间信息,包括 K-NN、最大似然、SVM、朴素贝叶斯、决策树、ELM、SRC 等。在这其中 K-NN 算法当属最为简单的分类器,它仅仅采用欧式距离来度量测试样本和训练样本间的相似性并作为分类依据。然而高光谱数据标签样本有限,大部分以谱特征为分类依据的机器学习方法都会受到 Houghes 现象的影响,分类结果经常会出现很多离散的孤立点,这与实际地表覆盖分布严重不符合^[36]。图 2 展示了 Indian Pines 数据的 6 类像素样本的谱线特征。从图中我们可以明显地看出 6 类不同的样本却有着极为相似的谱线,这无疑给传统的机器学习分类方法带来了极大的干扰。值得说明的是普通机器学习算法中 SVM 对于小训练样本数据集有较好的分类效果,它是利用核变换技术通过少量训练样本来获得一个分离超平面,从而得以将高维数据进行分类。大部分基于谱特征的普通机器学习分类算法之所以无法取得较为出色的效果,主要原因在于高光

谱数据存在着“同谱异物”及“同物异谱”的问题,导致其呈高度非线性,最终使得一些基于统计模式识别的分类模型难以处理原始高光谱图像^[8]。表 1 介绍了一些常见的基于谱特征的机器学习方法的优劣。

(2)基于空谱联合特征的分类方法。高光谱图像存在着高维特性、谱间冗余度大以及混合像元的问题。在标签样本有限的情况下,直接利用谱特征作为分类依据很难得到较为精确的分类结果。因此,近年来不断有学者在谱信息的基础上引入高光谱图像的空间信息,通过空间上像素间的依赖关系来弥补仅利用谱信息的不足^[37]。这个操作的理论基础在于,同属一个小区域的像素有大概率属于同一类,即相邻像素之间很大程度具有关联。例如,某个像素周围很多像素的类别是属于稻田,那么该像素的类别有很大概率也是属于稻田。该点类别的判定不仅仅依赖于其本身的谱信息,还有空间联系。在基于谱特征的普通机器学习方法中,因引入空间信息而获得极大提升的典型代表当属 SVM 和 SRC 分类器。例如, G. Camps-Valls 等人^[38]使用合成核机的方法结合空谱信息来提升 SVM 的分类精度;M. Fauvel 等人^[39]将数学形态学方法提取的空间信息与谱

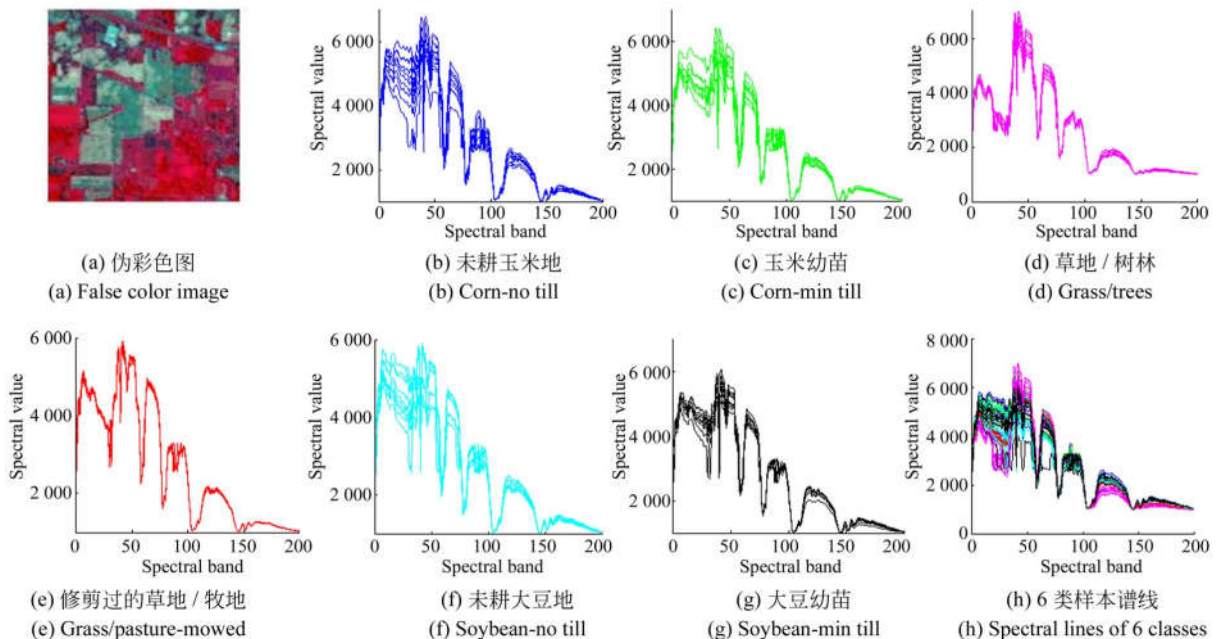


图 2 Indian Pines 数据的 6 类样本的谱线特征。(b)~(g)为 6 类不同样本的谱线,每类样本取 10 个;(h)为 6 类样本谱线合并显示

Fig. 2 Spectral lines of samples of 6 classes. (b)-(g)Spectral lines for each of 6 classes of HSI samples, 10 samples per sample were obtained

表 1 普通监督学习方法的优劣

Tab. 1 Advantages and disadvantages of general supervised learning methods

方法	类别	优点	缺点
K-NN	监督	1、简单易用,理论成熟;2、训练时间少。	1、计算复杂性和空间复杂性高;2、样本不平衡问题。
朴素贝叶斯	监督	1、对小规模数据表现较好,适合多分类;2、算法简单。	1、由于强调“朴素”(条件独立性),会导致准确率降低;2、对输入数据的表达形式敏感;3、需要计算先验概率。
最大似然法	监督	能快速指定被分类像元到若干类中的一类去。	对于高光谱数据,如加上类别较多时,运算速度则明显减慢,且需要大量的训练样本。
决策树	监督	1、计算复杂度不高;2、能够处理不相关的特征;3、适合对具有较多属性的数据集,可扩展性强。	1、容易过拟合;2、当各类别样本不平衡时,信息增益的结果会偏向具有更多数据值的特征;
ELM	监督	学习算法速度更快,泛化能力好。	模型的参数是随机选择的,会造成 ELM 不稳定
SRC	监督	方法简单,计算复杂度不高。	各类子字典间的原子相关性高,同类样本可能被不同类别子字典线性表示,导致分类精度较差
SVM	监督	1、泛化错误率低,计算开销不大,结果易解释;2、可解决小样本、高维数据情况下的分类问题;3、分类效果最好。	对参数调节和函数的选择敏感

信息结合为 SVM 分类器新的输入;J. Li 等人^[40]提出一种 SVM 的拓展方法,该方法是利用合成核技巧来结合高光谱图像的空谱信息;P. Ghamsi 等人^[41]提出了一种通过结合隐马尔科夫随机场和 SVM 分类器的方法,简单来说就是利用隐马尔科夫随机场产生分割结果和 SVM 产生的分类结果,通过经过多数表决来决定最终算法的分类结果。至于引入空间信息的 SRC 方法,经典的算法为 Chen 等人^[18]提出的联合稀疏表示分类(JSRC)算法,它的核心思想是以测试样本像素为中心的较小邻域内的像素是由相似的物质即同类像素构成的,它们可由一组共同的字典原子以不同的稀疏系数表示。这样可减少因高光谱数据不同类间像素之间谱特征具有较高相似性所带来的干扰。在此基础上,Zhang 等人^[19]提出了非局部加权联合稀疏表示分类方法,该算法是利用搜索窗内各邻点与中心测试点的相似性来赋予窗内各点不同的权重,从而根据图像空间-谱间结构的特点来弱化异类点的作用;Fu 等人^[20]提出了一种基于形状自适应的联合稀疏表示高光谱图像分类

算法,该算法通过比较高光谱图像的空间结构信息来自适应地为每个测试像素选择一个局部平滑的区域,减少邻域内异类点的干扰;Wang 等人^[21]为了解决矩形窗所带来的过平滑分类问题以及更好的利用高光谱图像丰富的光谱信息,提出一种基于自适应非局部空谱核的高光谱图像分类算法;Gan 等人^[22]采用空间区域核测量不同像素点对应的 LBP 特征间的相似性,并通过类导向的策略来优化文中提出的加权核稀疏表示。尽管上述基于空谱联合联合特征的分类方法取得了不俗的结果,但都要通过特征工程来手动设计分类特征来提高分类精度,这需要耗费大量的时间精力来反复验证。不同于普通机器学习需要人为设计提取分类特征,深度学习方法可以自动提取最佳分类特征。

3 深度学习的分类方法在高光谱中的应用

深度学习方法相较于普通机器学习方法而言具有自动学习特征且分类能力强大的特点,在许多领域都取得了极大的性能提升,例如图像分类、

目标检测、自然语言处理等领域。正是由于深度学习在众多领域都取得快速地发展,一些基于深度学习的遥感图像处理算法也在近些年慢慢地被提出来。常见的应用于高光谱图像分类的深度学习算法主要有栈式自编码网络(Stacked Auto-Encoder, SAE)^[43]、深度置信网络(Deep Belief Network, DBN)^[42]和卷积神经网络(CNN)^[23]。

3.1 栈式自编码网络(SAE)

SAE算法是由多个稀疏自编码器堆叠而成的深度神经网络模型,通常前一层自编码器的输出作为后一层自编码器的输入,最后一层通过 logistic(用于二分类)或 softmax(用于多分类)分类器输出最终的分类结果。SAE算法在高光谱图像分类中有较多的应用。例如,Chen 等人^[9]通过多层堆叠的自编码器组成一个深层网络来提取高光谱图像中的空谱特征;Ma 等人^[44]提出一种空间更新深度自编码器,该算法是在损失函数添加了正则项来考虑样本间的相似性;Liu 等人^[45]通过空间限制来组合堆叠的去噪自编码器和超像素,以此新型结构来提升分类精度。

3.2 深度置信网络(DBN)

DBN 与 SAE 算法相似,由多个限制玻尔兹曼机层堆叠而成,它的生成过程实质就是每个限制玻尔兹曼机进行无监督预训练的过程。相比 SAE,DBN 在高光谱分类中的应用较少。Chen

等人^[46]提出一种基于 DBN 的新特征提取和图像分类框架用于高光谱图像分类;Zhong 等人^[47]通过多样性提升潜在因素的先验来正则化预训练和微调阶段,达到对原始 DBN 分类效果的改进。

SAE 和 DBN 网络是以全连接为基础的深度神经网络,随着网络深度加深,模型的参数量会变得异常庞大,这不利于后续训练且对算力要求较大。除此之外,尽管上述的深度网络模型能在一定程度上有效地提取了高光谱图像中的深层特征来增强不同类别间的区分度,但通过把输入数据转换成一维向量会导致模型不能很好地利用高光谱图像的空间信息。对此,学界采用了基于 CNN 的分类方法来避免上述问题,更高效地提升网络的学习表达能力。因此,本文主要从当前最为火热的 CNN 方法来阐述深度学习在高光谱图像领域的应用。表 2 给出了普通神经网络和卷积神经网络的对比。传统的高光谱分类方法大多基于特征工程来进行分类研究,这需要丰富的先验知识,而且获得的特征也大多是一些浅层特征,但实际研究中并不能准确地知道图像中存在的哪种特征最适应眼前的问题,这需要耗费大量的时间与精力进行尝试。然而,基于 CNN 的高光谱图像算法能够通过构造一个多层的神经网络来自动地学习获取图像中隐藏的高级特征,进而能更加高效准确地获得分类结果。

表 2 普通神经网络和卷积神经网络的比较

Tab. 2 Comparison between ordinary ANN and CNN

方法	特点	优点	缺点
普通神经网络	1. 堆栈自编码网络 2. 深度置信网络	自动学习数据的高级特征,分类性能较优异	1. 模型所需参数庞大,对算力要求高;2. 输入为一维向量,不能很好地利用图像的空间信息;3. 训练困难,易产生梯度消失
卷积神经网络	由卷积层、池化层、激活函数、全连接层等堆叠而成	1. 自动学习数据的高级特征,分类性能优异;2. 模型所需参数相较于普通神经网络大大减少;3. 训练速度较快	池化层的存在可能会导致许多非常有价值的信息丢失,同时也会忽略整体与部分之间的联系

3.3 卷积神经网络(CNN)

3.3.1 CNN 的基本框架

CNN 的基本数学模型如下:

$$y = F(\mathbf{x}) = f_n(f_{n-1}(\dots f_1(\mathbf{x}))), \quad (1)$$

$$f_i(\mathbf{Z}^{[i]}) = \delta(\mathbf{W}^{[i]} f_{i-1}(\mathbf{Z}^{[i-1]}) + \mathbf{b}^{[i]}), \quad (i = 1, 2, \dots, n) \quad (2)$$

其中: y 是分类结果, $F(\mathbf{x})$ 代表着要训练的 CNN 模型, $f_i(\mathbf{Z}^{[i]})$ 是 CNN 模型中的第 i 层隐藏层, δ

代表着激活函数, $f_0(\mathbf{Z}^{[n]}) = \mathbf{x}$ (输入数据), n 是网络层数, $\mathbf{W}^{[n]}$ 是卷积核参数, $\mathbf{b}^{[n]}$ 是偏置。基于 CNN 的高光谱图像分类算法通过多次迭代, 不断学习更新网络模型参数, 使得最终的模型能更好地表达高光谱数据的特点, 提高分类精度。




图 3 CNN 中的卷积操作

Fig. 3 Convolution operation in CNN

至于 CNN 模型本身, 它是由输入层、卷积层 (convolutional layers)、激活函数、池化层 (pooling layers)、全连接层 (fully connected layers) 和输出层共同构成, 根据实际研究过程的需要, 还可添加批量标准化层 (batch norm) 和随机失活 (dropout)

对模型进行优化。为防止模型对训练集过拟合, 可再向模型添加正则项, 常规的正则化操作有 L1 范数、L2 范数和 dropout 等。CNN 中卷积层主要是对上一层输入进行卷积操作, 需要说明的是深度学习中的卷积操作与传统的信号处理领域中的卷积是不一样的, 它仅仅是对操作区域 (感受野) 内的像素进行加权求和, 如图 3 所示。CNN 在对图像块进行逐层卷积时使用相同的卷积核, 优化学习的参数即是卷积核内的权重, 这便是 CNN 一大特点: 参数共享。参数共享使得 CNN 与普通全连接深度神经网络相比模型参数大大减少。池化层可分为平均池化和最大池化, 一般使用的是最大池化层, 它主要是对输入进行下采样, 增加深层网络的感受野。最大池化层是返回每一个感受野内的最大值来组成新的特征, 以此减少下一层的计算量。深度学习中的激活函数则是用来给模型加入非线性因素, 提高模型对更高级特征的表达能。为了更好地进行分类, 在 CNN 模型的后面添加全连接层来连接整合上一层的所有输入特征, 并把输出传到 Softmax 层达到分类目的。

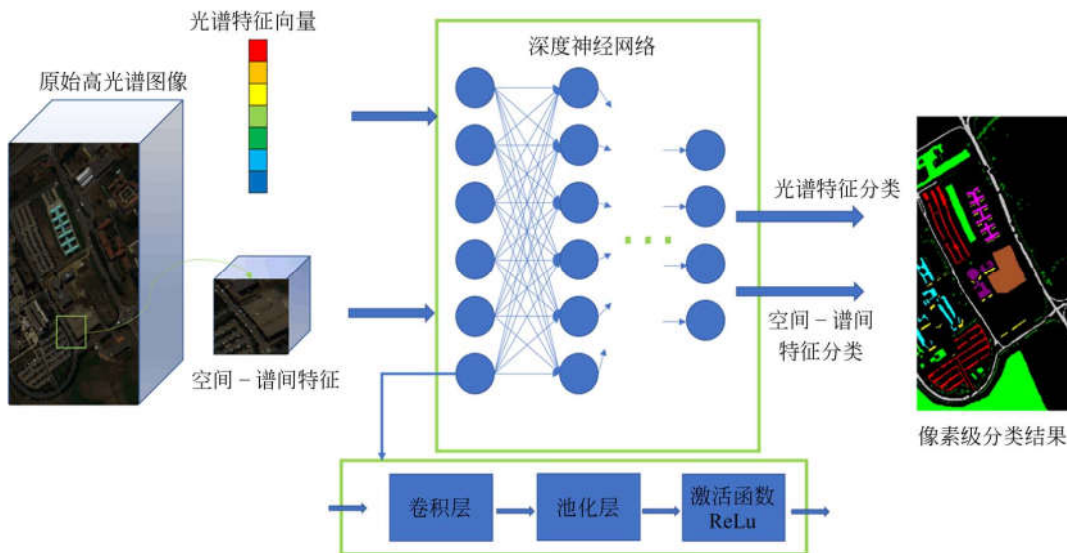


图 4 基于深度学习的高光谱图像分类框架

Fig. 4 Hyperspectral image classification framework based on deep learning

3.3.2 基于 CNN 的高光谱图像分类算法

基于 CNN 的高光谱图像分类算法主要包含以下几个方面^[31]: 输入数据; 训练多层的卷积神经网络模型; 进行测试分类。图 4 介绍了算法的

流程框架。第一步的输入可以是高光谱图像的空间特征, 或是空间特征, 抑或是空谱联合特征。第二步是设计一个深度神经网络模型对输入数据进行期望特征的学习。最后是采用训练好的网络模

型对测试集进行分类。由此可知,根据输入特征的类型,基于 CNN 的高光谱图像分类算法可分为基于谱特征的 CNN 分类方法和基于空谱联合特征的 CNN 分类方法。

(1)基于谱特征的 CNN 分类方法。高光谱图像具有丰富的谱信息,每个像素都对应着一条由上百个波段构成的一维向量(谱线),谱线所蕴含的谱信息对于地物类别的甄别工作十分有利。基于谱特征的 CNN 分类方法便是将这些一维训练样本作为网络的输入,由一维卷积层、池化层、全连接层等层的相关操作对一维输入谱特征自动进行特征的学习,使模型能更好地从原始谱特征中学习深层特征,从而使得模型能更好地表达高光谱数据,进而提高分类精度。基于谱特征的 CNN 分类方法使用的卷积核、池化操作都是一维,这与一般的 CNN 方法中卷积和池化采用的二维操作有所不同,但思路基本一致。基于谱特征的 CNN 方法并不是主流,如前面介绍的高光谱数据存在“同物异谱”和“异谱同物”等特点,导致仅仅利用谱信息的分类方法难以获得较高的分类精度。因此,关于这方面的内容并不多。2015 年 Hu 等人^[48]提出一个包含卷积层、最大池化层和两层全连接层的网络模型来对一维输入样本进行分类;2016 年 Mei 等人^[49]通过一个包含一层卷积层、BatchNorm 和两层全连接层的一维 CNN

网络模型来获得较高精度的高光谱图像分类,其中还使用了 dropout 和参数修正线性单元函数(PReLU)作为激活函数。尽管基于谱特征的方法取得了不错的效果,但其仅仅利用光谱信息,模型输入为一维向量,不能提取到高光谱图像的空间信息。

(2)基于空谱联合特征的 CNN 分类方法。与 SAE、DBN 等深度学习神经网络算法相似,基于谱特征的 CNN 方法同样采取的是一维输入,没有发挥高光谱图像图谱合一的优势。采用空谱联合特征既可以利用高光谱图像丰富的谱信息,还可以利用空间上像素间的联系来提高分类精度。目前主流的 CNN 模型的输入大多采用的是空谱联合特征。采用空谱联合特征输入,CNN 模型更有机会学习到鲁棒性更好的抽象特征以提高分类精度。高光谱图像的谱间信息对应的是每个像素点对每个光谱波段的反射特性,而空间信息则是对应这每个像素点的邻域信息。因此,将空谱联合特征作为深度神经网络的输入,训练得到的模型能够更好地表达高光谱图像数据蕴含的信息。值得说明的是,目前基于空谱联合特征的方法有两种不同做法,一种是对原始高光谱图像进行压缩,再选择待测像素邻域的图像块作为输入。例如,Konstantinos Makantasis 等人^[50]提出了一种基于空谱联合特征的 CNN 网络,算法是先将原始数据进行 R-PCA 降维,然后将以待测像素为中心的 $5 \times 5 \times c_r$ (c_r 是降维后的光谱维,数值为 10 或 30) 图像块输入由两层卷积核空间尺寸为 3×3 的卷积层,还有全连接层和 softmax 层构成的卷积网络;与 Konstantinos Makantasis 等人不同的是,Yue 等人^[51]所采用的网络添加有两层池化层,且输入图像块只保留了 3 个主成分且空间尺寸也较大。

另一种是直接原始数据上进行空谱联合特征进行提取。例如,Yang 等人^[52]提出一个双通道的 CNN 模型,两个通道分别从光谱域和空域学习特征,然后再把学习到的特征合并输入到全连接层为最后的分类提取空谱联合特征;Xu 等人^[53]在前面的基础上又增加了一个对异源数据进行特征提取的分支,该分支利用激光雷达(light detection and ranging)数据或高分辨率的可见光图像(visual image)等异源数据空间高分辨率来弥补高光谱图像空间分辨率的不足,与高光谱图

表 3 本文测试的 Pavia University 数据的训练集和测试集
Tab.3 Number of training samples and test samples for the Pavia University data set

Class	Name	Training	Test
1	Asphalt	200	6 431
2	Meadows	200	18 449
3	Gravel	200	1 899
4	Trees	200	2 864
5	Painted metal sheets	200	1 145
6	Bare Soil	200	4 829
7	Bitumen	200	1 130
8	Self-Blocking bricks	200	3 482
9	Shadows	200	747
	Total	1 800	40 976

像的空谱联合特征进行特征融合;Li 等人^[54]则直接采用三维 CNN 直接从空间尺寸为 5×5 的原始高光谱数据块学习深层特征,而没有对原始数据进行任何预处理;Zhang 等人^[55]通过将原始高光谱图像块多样化区域处理(包括上下左右、全局以及局部区域),然后针对每种区域设计一个特征提取网络进行特征学习,最后将从每种区域学习到的深层特征合并输入到全连接层进行联合特征提取。基于空谱联合特征的分类方法同时利用了高光谱图像的谱信息和空间信息,使得提取到的联合特征能更好地表征数据的特点,减少原始数据因呈高度非线性多带来的干扰,最终提高分类精度。

4 各算法性能对比与分析

为了更加直观地展现各算法的优劣,本文将在 Pavia University 数据集上测试各算法的性能表现。Pavia University 数据集是由德国宇航局研制的反射光学系统成像光谱仪(Reflective Optics System Imaging Spectrometer sensor, ROSIS-3)采集于意大利帕维亚大学周边的一个城市场景。该图像场景大小为 610×340 ,空间分辨率达到了

1.3 m,波长范围为 $0.43 \sim 0.86 \mu\text{m}$,总共有 115 个光谱波段。其中,有 12 个波段收到严重的噪声干扰,在实验前去除这 12 个波段,形成具有 103 个波段的数据。图 6 展示了 Pavia University 数据的伪彩色合成图像,该数据总共有 9 类不同的地物覆盖,本次实验每类地物覆盖样本随机选取 200 个作为训练集,剩下的作为测试集。表 3 展示了本次实验 Pavia University 数据的训练集和测试集的具体情况,表格左边的颜色编码代表着不同的地物覆盖(彩图见期刊电子版)。为了更好地说明对比各个类型算法的优劣,本文分别采用了 K-NN、ELM、SVM、SRC、JSRC、NLW-JSRC、MFASR、CNN、CNN-PPF、TB-CNN 等高光谱图像分类算法在 Pavia University 数据集上进行测试验证。表 4 展示了各个算法在 Pavia University 数据集上的分类结果。分类的主要指标分别是总体精度(OA)、平均精度(AA)和 Kappa 系数。从表 4 可知,SVM 算法是传统机器学习算法中对高光谱图像分类表现最好的,这得益于它对小样本高维数据优秀的处理能力。相比传统的机器学习分类方法,基于空谱联合特征的稀疏表示分类方法和基于 CNN 的高光谱图像分类算法具有更加强大的分类能力。

表 4 各算法对于 Pavia University 数据集的分类结果

Tab. 4 Comparison of the classification accuracy among several algorithms using the Pavia University data set(%)

Class	K-NN	ELM	SVM	SRC	JSRC	NLW-JSRC	MFASR	CNN	CNN-PPF	TB-CNN
1	76.07	68.89	80.77	61.16	81.36	83.80	99.61	95.66	97.31	94.71
2	91.86	80.53	84.15	79.52	95.03	93.77	97.18	93.92	95.24	98.78
3	82.78	82.25	78.41	70.98	99.21	99.42	99.63	87.47	93.21	96.68
4	87.67	94.31	95.71	90.33	93.72	97.66	97.42	98.36	97.63	99.27
5	99.74	99.65	99.83	99.56	99.91	99.48	99.91	100.00	100.00	100.00
6	53.43	80.95	83.14	71.59	99.15	89.79	99.71	94.14	99.48	99.34
7	85.93	91.77	92.92	85.49	98.85	99.73	99.82	98.05	96.37	99.47
8	54.88	65.19	81.56	72.43	95.35	97.42	99.28	91.38	93.11	99.40
9	96.52	32.53	99.73	98.80	56.22	90.63	100.00	99.60	99.60	99.87
OA	81.14	78.46	84.78	76.54	93.03	92.84	98.37	94.40	96.20	98.27
AA	81.14	77.34	88.47	81.09	90.98	94.63	99.17	95.40	96.88	98.61
Kappa	74.48	71.99	80.06	69.41	90.73	90.46	97.81	92.54	94.93	97.68

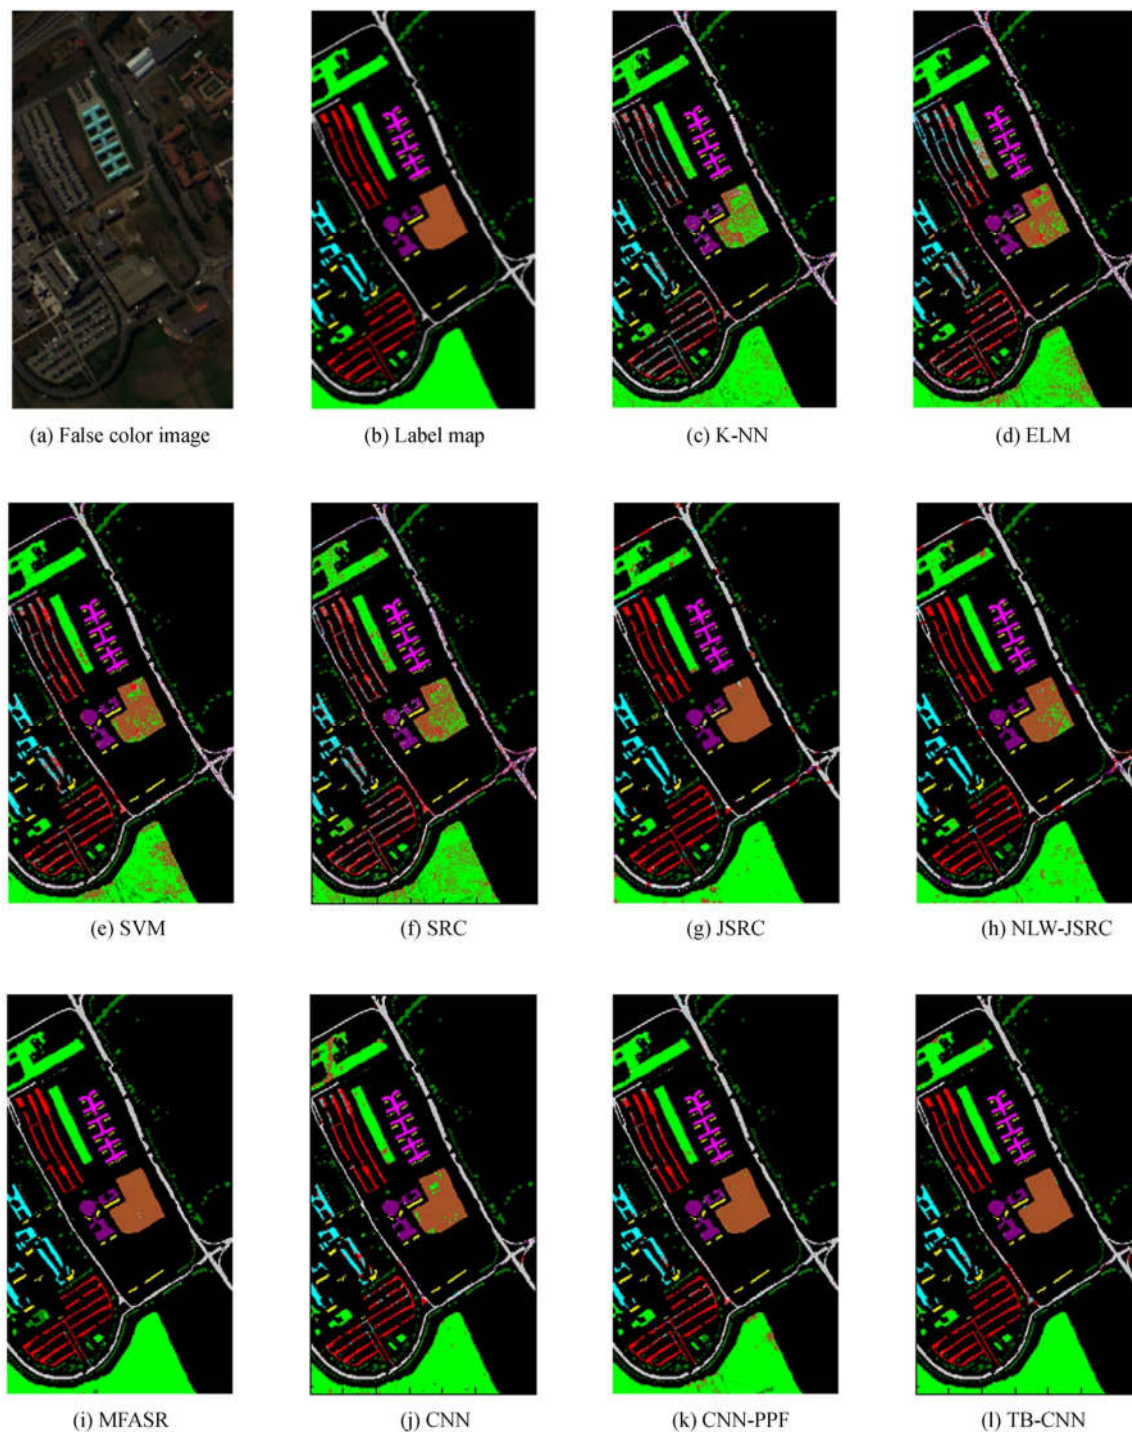


图 6 各算法对于 Pavia University 数据的分类结果图

Fig. 6 Classification results of Pavia University data for each algorithm

此外,从表 4 也可以看出,基于单像素特征即仅仅依靠谱特征分类的算法(K-NN、ELM、SVM、SRC)的分类精度不如依靠谱间-空间特征的算法。由于高光谱数据存在着不同类别像素间谱线相似,

且具有数据维数多、标签样本少的特点,使得仅依靠谱间特征的算法分类精度不够。空谱联合特征能够提供更加准确的关于高光谱图像的信息,使得基于该类型算法的分类结果精度较高。

5 总结与展望

高光谱数据具有图谱合一和较高的空谱分辨率的特点,这使得基于高光谱图像的分类方法在资源勘探、精细化农业、环境保护等众多关系国计民生等领域有着重大的应用。但是,由于高光谱数据维度高、存在混合像素、标签样本少、同物异谱和异物同谱,使得高光谱图像分类面临着不小的挑战。传统基于谱特征的分类方法虽取得一些成就,但未能考虑高光谱数据的空间信息,分类精度差强人意。近些年来,基于空谱联合特征的高光谱图像分类算法兴起,特别是随着深度学习的高速发展,基于深度学习的高光谱图像分类算法也随着异军突起,成为前沿热点。基于空谱联合特征的高光谱图像分类算法,由于充分地挖掘数据本身蕴含的特征,且算法本身对应高维数据的优秀处理,使得最终得以较好弥补高光谱数据维度高、非线性、样本标签少的缺点,提升分类精度。

目前高光谱图像分类算法正朝着小样本、低复杂度、高效与愈加智能化的方向发展,基于空谱信息的融合、多特征综合、多数据源融合、多尺度复合、新型分类器的研究不断提高着高光谱分类算法的精度。本文在总结当前高光谱图像分类研究领域的分类算法的同时,也提出以下几点展望:

(1)当前行业领先的普通高光谱图像分类算法的分类精度虽然已有达到 98% 甚至 99% 以上的,但如何在保证高精度的前提下,减少训练样本

数量,降低算法复杂度,减少算法消耗的时间,提高分类效率,仍是未来高光谱图像分类领域关注的一个重点。此外,多分类器结合和新分类器的应用也是一个研究热点;

(2)在深度学习方面,可在保证分类精度不降低的前提下降低模型参数量、训练时间和训练集样本数,达到在小样本训练集上得到一个高精度、结构稀疏的分类模型且训练时间较当前主流基于 CNN 的方法有明显地减少。此外,当前基于 CNN 的高光谱图像分类算法虽然已取得较高的分类精度,但由于算法本身的理论限制或者高光谱图像的特点导致模型的泛化能力不足,大多只能针对特定的数据集,分类效率较低。因此,提高分类模型的训练效率和泛化能力是未来基于深度学习的高光谱图像分类算法发展的重要方向;

(3)当前的高光谱分类算法大多集中在通用分类方法上,对特定领域的相关应用算法研究不足,不利于高光谱图像分类算法的重要成果落地得到市场应用。例如在精细化农业、海洋环境监测、矿物勘探等关乎国计民生的重要应用领域,使用的分类算法仍是经典的光谱角制图模型 SAM 或者简单的二值编码分类等,新型和先进算法的成功应用实例还是比较少的。究其原因是当前大多高光谱图像分类算法的研究主要从高维数据的角度出发,而没有从实际应用需求出发。因此,未来从以解决实际问题角度出发研究高光谱图像分类算法将是一个重要方向,这对提高高光谱图像分类的市场竞争力将有极大的促进作用。

参考文献:

- [1] 黄鸿, 郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类[J]. 光学精密工程, 2016, 24(4):873-881.
HUANG H, ZHENG X L. Hyperspectral image classification based on weighted spatial-spectral and nearest neighbor classifier [J]. *Opt. Precision Eng.*, 2016, 24(4): 873-881. (in Chinese)
- [2] LEE M A, HUANG Y, YAO H, *et al.*. Determining the effects of storage on cotton and soybean leaf samples for hyperspectral analysis [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6):2562-2570.
- [3] DALPONTE M, ORKA H O, GOBAKKEN T, *et al.*. Tree species classification in boreal forests with hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(5):2632-2645.
- [4] YUAN Y, WANG Q, ZHU G. Fast hyperspectral anomaly detection via High-Order 2-D crossing filter [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 53(2):620-630.
- [5] ZHANG L, ZHANG L, TAO D, *et al.*. Hyperspectral remote sensing image subpixel target detection based on supervised metric learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(8):4955-4965.
- [6] ZHANG B, WU D, ZHANG L, *et al.*. Application of hyperspectral remote sensing for environment monitoring in mining areas [J]. *Environmental Earth Sciences*, 2012, 65(3):649-658.
- [7] CAMPS-VALLS G, TUIA D, BRUZZONE L, *et*

- al. . Advances in hyperspectral image classification: earth monitoring with statistical learning methods [J]. *IEEE Signal Processing Magazine*, 2013, 31 (1):45-54.
- [8] 张号达,李映,姜晔楠. 深度学习在高光谱图像分类领域的研究现状与展望[J]. *自动化学报*, 2018, 44(6):961-977.
ZHANG H K, LI Y, JIANG Y N. Research status and prospect of in-depth learning in hyperspectral image classification [J]. *Acta Automation*, 2018, 44 (6). (in Chinese)
- [9] CHEN Y, LIN Z, ZHAO X, et al. . Deep learning-based classification of hyperspectral data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6):2094-2107.
- [10] 侯榜煊,姚敏立,贾维敏,等. 空谱结构保持的高光谱图像分类[J]. *红外与激光工程*, 2017, 46 (12): 1228001-1228008.
HOU P H, YAO M L, JIA W M, et al. . Classification of hyperspectral images with spatial structure preservation [J]. *Infrared and Laser Engineering*, 2017, 46 (12): 1228001-1228008. (in Chinese)
- [11] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(8):1778-1790.
- [12] BLANZIERI E, MELGANI F. Nearest neighbor classification of remote sensing images with the maximal margin principle [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(6): 1804-1811.
- [13] 贺金鑫,陈圣波,王阳,等. 一种基于朴素贝叶斯分类模型的高光谱矿物精确识别方法[J]. *光谱学与光谱分析*, 2014, 34(2):505-509.
HE J X, CHEN SH B, WANG Y, et al. . An accurate hyperspectral mineral identification method based on naive bayesian classification model [J]. *Spectroscopy and Spectral Analysis*, 2014, 34 (2): 505-509. (in Chinese)
- [14] 华晔,张涛,奚后玮,等. 基于决策树的高光谱遥感影像分类方法研究[J]. *计算机技术与发展*, 2012, 22(6):198-202.
HUA Y, ZHANG T, XI H W, et al. . Study on hyperspectral remote sensing image classification method based on decision tree [J]. *Computer Technology and Development*, 2012, 22 (6): 198-202. (in Chinese)
- [15] LI W, CHEN C, SU H, et al. . Local binary patterns and extreme learning machine for hyperspectral imagery classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(7): 3681-3693.
- [16] 吴银花,胡炳樑,高晓惠,等. 利用区域增长技术的自适应高光谱图像分类[J]. *光学精密工程*, 2018, 26(2):426-434.
WU Y H, HU B L, GAO X H, et al. . Adaptive hyperspectral image classification using regional growth technology [J]. *Opt. Precision Eng.*, 2018, 26 (2): 426-434. (in Chinese)
- [17] 唐中奇,付光远,陈进,等. 基于多尺度分割的高光谱图像稀疏表示与分类[J]. *光学精密工程*, 2015, 23(9):2708-2714.
TANG ZH Q, FU G Y, CHEN J, et al. . Sparse representation and classification of hyperspectral images based on multi-scale segmentation [J]. *Opt. Precision Eng.*, 2015, 23 (9): 2708-2714. (in Chinese)
- [18] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification using dictionary-based sparse representation [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2011, 49 (10):3973-3985.
- [19] ZHANG H, LI J, HUANG Y, et al. . A nonlocal weighted joint sparse representation classification method for hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 7(6):2056-2065.
- [20] FU W, LI S, FANG L, et al. . Hyperspectral image classification via shape-adaptive joint sparse representation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(2):556-567.
- [21] WANG J, JIAO L, WANG S, et al. . Adaptive nonlocal spatial-spectral kernel for hyperspectral imagery classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9):4086-4101.
- [22] GAN L, XIA J, DU P, et al. . Class-oriented weighted kernel sparse representation with region-level kernel for hyperspectral imagery classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(4): 1118-1130.
- [23] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]. *International Conference on Neural Information Processing Systems*. Curran

- Associates Inc. 2012:1097-1105.
- [24] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]. *International Conference on Learning Representations*, 2014.
- [25] HE K, ZHANG X, REN S, *et al.*. Deep residual learning for image recognition [J]. *Computer Vision and Pattern Recognition*, 2016: 770-778.
- [26] SZEGEDY C, LIU W, JIA Y, *et al.*. Going deeper with convolutions [C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2015.
- [27] HU W, HUANG Y, WEI L, *et al.*. Deep convolutional neural networks for hyperspectral image classification [J]. *Journal of Sensors*, 2015(2):1-12.
- [28] ROMERO A, GATTA C, CAMPS-VALLS G. Unsupervised deep feature extraction for remote sensing image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(3):1349-1362.
- [29] ZHAO W, DU S. Spectral-spatial feature extraction for hyperspectral image classification: a dimension reduction and deep learning approach [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8):4544-4554.
- [30] LI W, WU G, ZHANG F, *et al.*. Hyperspectral image classification using deep pixel-pair features [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, PP(99):1-10.
- [31] ZHANG L, ZHANG L, DU B. Deep learning for remote sensing data: a technical tutorial on the state of the art [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2016, 4(2):22-40.
- [32] ZHANG M, LI W, DU Q. Diverse region-based CNN for hyperspectral image classification [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2018, 27(6):2623-2634.
- [33] 赵洁. 基于 K 均值聚类的高光谱遥感影像分类研究 [J]. *地理空间信息*, 2016, 14(3):26-29.
- ZHAO J. Classification of hyperspectral remote sensing images based on K-means clustering [J]. *Geospatial Information*, 2016, 14(3): 26-29. (in Chinese)
- [34] 舒阳, 李京, 何湜, 等. 基于空-谱约束的中餐馆过程混合模型高光谱图像聚类方法 [J]. *光谱学与光谱分析*, 2016, 36(4):1158-1162.
- SHU Y, LI J, HE SH, *et al.*. Hyperspectral Image clustering method based on spatial-spectral constrained Chinese restaurant process mixing model [J]. *Spectroscopy and Spectral Analysis*, 2016, 36(4): 1158-1162. (in Chinese)
- [35] 童庆禧, 张兵, 郑兰芬. 高光谱遥感——原理、技术与应用 [M]. 北京: 中国科学院遥感应用研究所, 2006.
- TONG Q X, ZHANG B, ZHENG L F. *Hyperspectral Remote Sensing-Principle, Technology and Application* [M]. Beijing: Institute of Remote Sensing Applied Research, Chinese Academy of Sciences, 2006. (in Chinese)
- [36] 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 SH, XUE ZH, *et al.*. Review of hyperspectral remote sensing image classification [J]. *Journal of Remote Sensing*, 2016, 20(2): 236-256. (in Chinese)
- [37] 侯榜煊, 姚敏立, 贾维敏, 等. 面向高光谱图像分类的空谱判别分析 [J]. *光学精密工程*, 2018, 26(2):450-460.
- HOU P H, YAO M L, JA W M, *et al.*. Spatial-spectral discriminant analysis for hyperspectral image classification [J]. *Opt. Precision Eng.*, 2018, 26(2): 450-460. (in Chinese)
- [38] CAMPS-VALLS G, GOMEZ-CHOVA L, MUNOZ-MARI J, *et al.*. Composite kernels for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(1):93-97.
- [39] FAUVEL M, TARABALKA Y, BENEDIKTS-SON J A, *et al.*. Advances in spectral-spatial classification of hyperspectral images [J]. *Proceedings of the IEEE*, 2013, 101(3):652-675.
- [40] LI J, MARPU P R, PLAZA A, *et al.*. Generalized composite kernel framework for hyperspectral Image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(9): 4816-4829.
- [41] GHAMISI P, BENEDIKTSSON J A, ULFARSSON M O. Spectral-spatial classification of hyperspectral images based on hidden markov random fields [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(5):2565-2574.
- [42] HINTON G E, OSINDERO S, TEH Y W, *et al.*. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [43] HINTON G E, SALAKHUTDINOV R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [44] MA X, WANG H, GENG J, *et al.*. Spectral-spatial classification of hyperspectral image based on

- deep auto-encoder [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9): 4073-4085.
- [45] LIU Y, CAO G, SUN Q, *et al.*. Hyperspectral classification via deep networks and superpixel segmentation [J]. *Journal of Remote Sensing*, 2015, 36(13): 3459-3482.
- [46] CHEN Y, ZHAO X, JIA X, *et al.*. 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.
- [47] ZHONG P, GONG Z, LI S, *et al.*. Learning to diversify deep belief networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(6): 3516-3530.
- [48] HU W, HUANG Y, WEI L, *et al.*. Deep convolutional neural networks for hyperspectral image classification [J]. *Journal of Sensors*, 2015, 2015(2):1-12.
- [49] MEI S, JI J, BI Q, *et al.*. Integrating spectral and spatial information into deep convolutional neural networks for hyperspectral classification [C]. *Geoscience and Remote Sensing Symposium*. IEEE, 2016:5067-5070.
- [50] MAKANTASIS K, KARANTZALOS K, DOULAMIS A, *et al.*. Deep supervised learning for hyperspectral data classification through convolutional neural networks [C]. *Geoscience and Remote Sensing Symposium*. IEEE, 2015:4959-4962.
- [51] YUE J, ZHAO W, MAO S, *et al.*. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks [J]. *Remote Sensing Letters*, 2015, 6(6):468-477.
- [52] YANG J, ZHAO Y, CHAN C W, *et al.*. Hyperspectral image classification using two-channel deep convolutional neural network [C]. *Geoscience and Remote Sensing Symposium*. IEEE, 2016: 5079-5082.
- [53] XU X, LI W, RAN Q, *et al.*. Multisource remote sensing data classification based on convolutional neural network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, PP(99):1-13.
- [54] LI Y, ZHANG H, SHEN Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network [J]. *Remote Sensing*, 2017, 9(1):67.
- [55] ZHANG M, LI W, DU Q. Diverse region-based CNN for hyperspectral image classification [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2018, 27(6):2623.

作者简介:



闫敬文(1964—),男,吉林磐石人,博士,教授,博士生导师,1987年于吉林工业大学(现吉林大学)获得学士学位,1992年于中国科学院长春地理所获得硕士学位,1997年于中国科学院长春光机所获得博士学位。现为汕头大学工学院电子系广东省数字信号与图像处理重点实验室副主任。主要从事小波分析及应用,压缩感知,信号稀疏表示,遥感图像处理。E-mail: jwyan@stu.edu.cn



陈宏达(1993—),男,广东揭阳人,硕士研究生,2016年于东莞理工学院获得学士学位,主要从事计算机视觉、高光谱图像处理方面的研究。E-mail: 16hdchen@stu.edu.cn

通讯作者:



刘蕾(1978—),女,河南开封人,博士,副教授,2002年于信阳师范学院获得学士学位,2006年于西安交通大学获得硕士学位,2014年于汕头大学获得博士学位。主要从事医学图像及高光谱图像处理方面的研究。E-mail: wliulei@stu.edu.cn