

一种基于 DBN 的高光谱遥感图像分类方法

李新国 黄晓晴

(南京航空航天大学自动化学院 南京 210016)

摘 要: 高光谱遥感数据越来越普及并为人们广泛使用,基于高光谱数据的地面物体精确分类是高光谱遥感技术的核心应用之一。对高光谱数据进行提特征提取是进行地物分类的有效方法。深度学习是机器学习研究中的新领域,它多隐层的多层感知器结构使其能够学习到对数据有更本质的刻画的特征,在图像分类和可视化领域取得了更好的成绩。深度置信网(deep belief network, DBN)是深度学习网络中常见的模型。利用高光谱数据的高维特性,搭建基于 DBN 的高光谱图像分类模型,结合高光谱数据的空间结构对地物进行分类。实验表明,基于 DBN 的高光谱图像分类方法可以得到更好的分类效果。

关键词: 高光谱图像;深度学习;深度置信网;DBN 模型

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 590.2060

Deep neural networks based on hyperspectral image classification

Li Xinguo Huang Xiaoping

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: Hyperspectral data is becoming increasingly popular and widely used. Accurate classification of the high ground objects is one of the core application of hyperspectral remote sensing technology. Extracting feature from hyperspectral data is an effective method for classification. Deep learning is the new areas of machine learning research. It has multilayer perceptron structure so that it can learn to portray a more essential characteristic, and have better results in the field of image classification and visualization. DBN is a normal model of deep learning network. A hyperspectral image classification model based on DBN is constructed by using high dimensional feature of hyperspectral data and combining the spatial structure of hyperspectral data. Experiment shows that high spectral image classification based on DBN can get better classification results.

Keywords: hyperspectral image; deep learning; deep belief network; model of DBN

1 引 言

高光谱遥感图像结合了光学成像技术和光谱技术。光谱成像仪获取空间成像的同时,对每一个像素又可获得几十乃至几百个波段的光谱值。高光谱图像有信息量大、光谱分辨率高的特点,这使其地物分类能力得到了很大的提高^[1]。

遥感图像分类的方法大致分为两类:一种是基于匹配的分类,包括基于角度和编码的匹配、基于纹理和颜色的匹配^[2-3]和基于局部特征匹配^[4]等方法。另一种是基于特征空间的影像分类方法,包括最小距离分类、最大似然分类、 k -均值聚类法及支持向量机分类法^[5]。其中支持向量机(SVM)方法因不受 Hughes 现象^[6]影响

而使用最多。

深度学习是机器学习研究中的新领域,其概念源于人工神经网络的研究。2006年, Hinton 和他的学生提出利用深度信念网(DBN)来解决分类问题,引发了深度学习的浪潮。深度学习采用无监督的“逐层初始化”来进行预训练,解决了神经网络中容易发生的过拟合问题,使得构建更多隐含层的网络成为可能。从而可以学习到更有用的特征,最终提升分类或预测的准确性^[7-9]。

高光谱图像中不同地物点的光谱曲线有着特征上很大的差别。根据这个特点,本文搭建了基于 DBN 的高光谱图像分类模型,利用 Salinas 和 PaviaU 两个高光谱数据集进行验证,并和传统的高光谱图像分类方法进行对比,验证了深度学习模型可以取得更好的分类效果。

2 DBN 模型分析

2.1 限制波尔兹曼机(RBM)

RBM 是一种特殊形式的玻尔兹曼机^[10], 由一个可见层(一般用 v 表示)和一个隐含层(一般用 h 表示)组成。只有可见层节点和隐含层节点有连接权值, 而每一层的节点之间没有链接, 如图 1 所示。已知 v 的情况下, 所有的隐藏节点之间是条件独立的。输入 v 时, 通过条件概率可以得到隐藏层 h , 同理, 根据隐藏层 h 可以得到可视层 v 。对参数进行调整后, 如果从隐藏层得到的可视层 v' 与原来的可视层 v 一致, 那么得到的隐藏层就是可视层另外一种表示。




图 1 限制波尔兹曼机示意

RBM 是一个典型的能量模型, 它的能量函数可以表示为:

$$E(v, h) = - \sum_{i=1}^m \sum_{j=1}^n w_{ij} v_i h_j - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j \quad (1)$$

式中: w_{ij} 表示第 i 个可见层节点 v_i 与第 j 个隐含层节点 h_j 之间的权值, a_i 和 b_j 分别表示 v_i 和 h_j 的偏置。有了联合组态的能量函数, 就可以定义可见层节点 v 和隐含层节点 h 的联合概率:

$$P(v, h) = \frac{e^{-E(v, h)}}{\sum_{v, h} e^{-E(v, h)}} \quad (2)$$

RBM 层内节点没有连接, 所以根据联合概率可以得到条件概率:

$$P(v) = \frac{\sum_h e^{-E(v, h)}}{\sum_{v, h} e^{-E(v, h)}}, P(h) = \frac{\sum_v e^{-E(v, h)}}{\sum_{v, h} e^{-E(v, h)}} \quad (3)$$

$$P(v | h) = \frac{e^{-E(v, h)}}{\sum_v e^{-E(v, h)}}, P(h | v) = \frac{e^{-E(v, h)}}{\sum_h e^{-E(v, h)}} \quad (4)$$

得到 RBM 网络的概率密度函数后, 需要学习 (w, a, b) 等参数使 RBM 网络表示的吉布斯分布最大可能的拟合输入数据, 一般采用求解输入样本的最大似然的方法来进行参数的求解。

为了解决训练时间漫长的问题, 2006 年, Hinton 提出了对比散度的方法来加快训练时间。对比散度将对数似然函数梯度的求解进行了两个近似: 1) 使用从条件分布中得到的样本来近似替代计算梯度时的平均求和。2) 吉布斯采样时只进行一次。通过对比散度算法, 可以快速的得到 (w, a, b) 等参数的更新, 从而完成了 RBM 网络的训练。

2.2 DBN 模型

2.2.1 DBN 模型的结构

DBN 由多个 RBM 层堆叠而成, 每层的 RBM 通过对比散度的方法单独训练, 一个经典的 DBN 网络结构如图 2 所示。

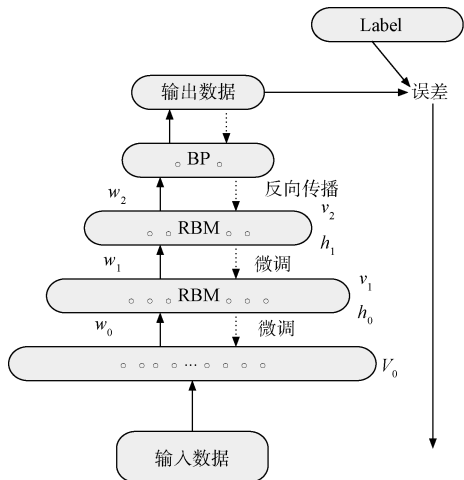


图 2 DBN 示意

每一层 RBM 网络通过调整自己的 (w, a, b) 等权值使本层特征向量映射达到最优, 然后在最后一层 RBM 网络后加入一层反向传播网络(bp)借助 label 值来对整个网络进行微调。

2.2.2 DBN 模型的训练过程

DBN 在训练模型的过程中主要分为两步:

1) 以底层的输出作为上一层的输入, 使用对比散度的方法分别无监督地训练每一层 RBM 网络, 确保特征向量映射达到最优。

2) 在 DBN 的最后一层设置 BP 网络, 对整个 DBN 网络的参数进行微调。BP 接收顶层 RBM 的输出特征向量作为它的输入特征向量, 得到预测的分类类别。将得到的分类结果同真实结果就行比较得到误差, 将错误信息自顶向下传播至每一层 RBM, 微调整个 DBN 网络。

RBM 网络训练模型的过程使 DBN 克服了 BP 因随机初始化权值参数而容易陷入局部最优的缺点。

3 基于 DBN 的高光谱图像分类方法

3.1 将 DBN 用于高光谱图像分类

DBN 模型具有提取图像特征并将其正确分类的特点, 并且在一些公开的语音、图像数据集上取得了很好的效果^[11-12]。同时, 由于高光谱图像不同类别的样本点的上百个波谱值存在着很大的差异, 将 DBN 模型用于高光谱图像的分类中是可行的。

选择 PaviaU 高光谱数据集中四种不同类别样本(包括 Meadows(草地), Gravel(碎石路), Sheets(覆盖物), Bare soil(裸露土壤))来绘制光谱曲线。PaviaU 数据集采集了帕维亚大学的一片地域内从 0.43~0.86 μm 范围内的 103 个

不同波段对应的光谱强度值,以 103 个不同的波段 λ 为横轴,以其对应的光谱强度值 m 作为纵轴来绘制光谱曲线图。如图 3 所示,可以看出每个类别的光谱图都有不同的

形状。由此可以预测 DBN 模型可以学习到不同类别样本之间的区别,并且将它们进行正确的分类。

3.2 重构输入数据

高光谱图像具有维度高、训练样本少、空间关联性强的特点,而 DBN 模型显著的特点就是需要较多数量的训练样本。所以样本在输入之前,要对其进行样本扩充、降维等操作。

高光谱图像训练样本不足以满足 DBN 模型的需求,我们采用临近像素相加求平均值的方法来得到新的样本,这样既增加了训练样本,又利用了空间相关性。具体有两种方法,1) 每个像素与其横向、竖向、左斜、右斜 4 个方向的临近的像素分别相加后除以 3,这样就得到 4 倍新的样本。2) 取每个像素临近的 3×3 小块相加除以 9 得到 1 倍新样本。这样,假设图像像素数为 n ,扩充之后,样本个数变为 $5n$ 。

高光谱图像相同类别像素比较集中,所以利用空间结合性来改进输入数据会对分类效果有很大提高。如果简单的采用将训练像素和周围邻居像素相加作为输入的话,就会带来很高的维度和很大的冗余性。

为了引入空间结合性同时保证较小的维度,需要对数据进行降维。自编码器(AE)和主成分分析(PCA)都可以对数据进行降维。区别在于 AE 为非线性降维而 PCA 为线性降维。相比之下,AE 能够更好的保留住数据的特征,而 PCA 能够用较少的维度将数据表示出来。

实验中采用以训练像素为中心周围 3×3 区域作为输入,边界像素同样采用镜像的方法实现。训练像素采用 AE 进行降维,保证跟原始像素误差在 1% 以下。8 个邻居像素采用 PCA 进行降维,分别取前 10 个维度作为数据输入。降维完成后,将包含原始样本在内的 9 个像素按顺序拼装成 1 个像素作为输入。

3.3 训练和分类

将进行数重构后的像素作为高光谱 DBN 模型第一层 RBM 可见层 v_1 的输入,每次随机选取 100 个高光谱像素分批的对 DBN 模型进行训练。

对 RBM 层的训练就是要通过迭代得到参数的值,从而得到高光谱图像的另一种表达。由式(2)和(3)可以得到第一层 RBM 隐含层第 j 个节点的激活概率为:

$$P(h_j = 1 | v) = \frac{1}{1 + \exp(-\sum_i w_{ij}v_i - b_j)} \quad (5)$$

同理,若已知隐含层节点状态,则第 i 个可见层节点激活概率为:

$$P(v_i = 1 | h) = \frac{1}{1 + \exp(-\sum_j w_{ij}h_j - a_i)} \quad (6)$$

根据对比散度的方法进行训练,经过多次迭代,可以得到此 RBM 层中 (w, a, b) 等参数的值,这样隐含层 h_1 便是高光谱数据的另一种表示形式。

将隐含层 h_1 作为第二层 RBM 的输入,同样的方法进

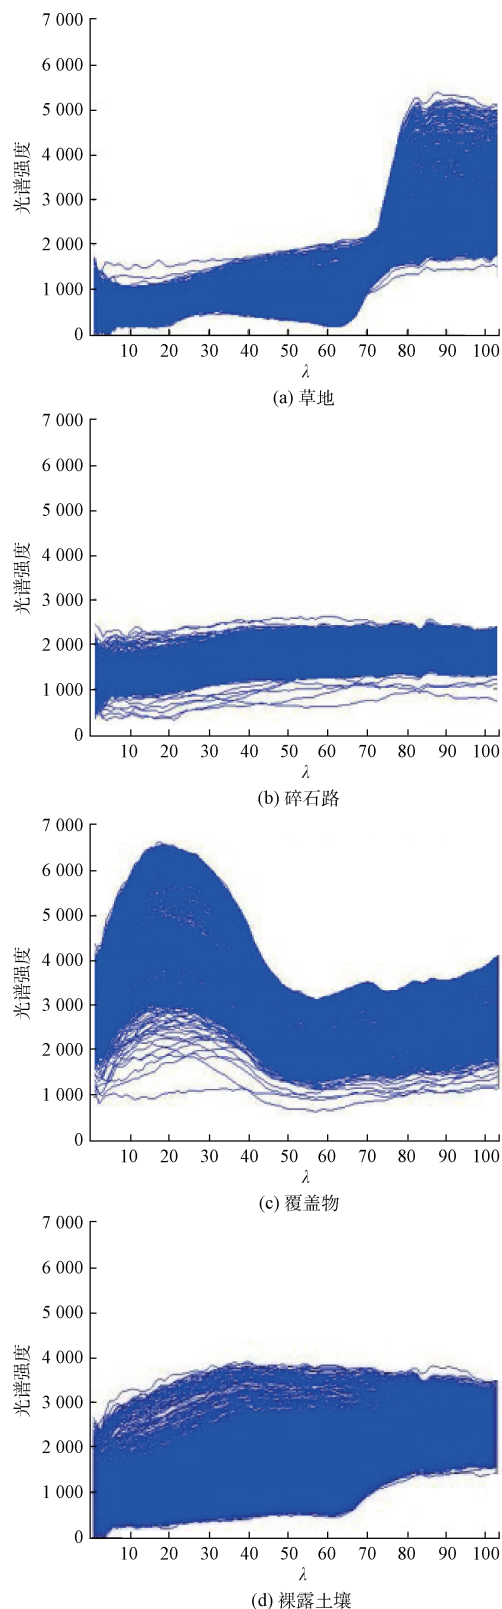


图 3 PaviaU 中不同类别地物的 103 波段光谱曲线

行迭代训练,会得到新的隐含层 h_2, h_3, \dots , 以及对应的每层 (w, a, b) 等参数的值, 它们是高光谱图像更高级的表示形式。通过这样的逐层训练, 完成了高光谱 DBN 模型的预训练过程。

要想得到好的分类结果, 需要在最后的隐含层 n' 之后加入一个 bp 层对参数进行微调。假设高光谱数据集中给出的 ground truth 值(即期望分类结果值)为 d , n' 层输出结果为 y' , 计算它们之间的“残差” $\delta^{(l)}$ 为:

$$\delta^{(l)} = -(d - y')y'(1 - y') \tag{7}$$

“残差”由后层向前层传递, 当 $l = n' - 1, n' - 2, \dots$ 的各层时, 计算 $\delta^{(l)}$ 为:

$$\delta^{(l)} = (w^{(l)})^T \delta^{(l+1)} y'(1 - y') \tag{8}$$

根据各层的 $\delta^{(l)}$ 计算 w 和 b 的偏导数值:

$$\nabla w^{(l)} J = y' \delta^{(l+1)}, \nabla b^{(l)} J = \delta^{(l+1)} \tag{9}$$

有了偏导数值, 就可以对 w 和 b 进行权值更新。经过多次迭代, 就完成了对预训练后的 DBN 模型的微调。

由于对高光谱数据集进行了样本扩充、数据降维和空间结合等操作, 使此 DBN 模型能够挖掘更深层次更抽象的光谱, 特征由于预训练的加入, 此 DBN 模型可以克服 bp 网络容易陷入局部最优的缺点, 从而实现更好地分类效果。实验中, 每个高光谱数据集采用 70% 的像元样本进行训练, 剩下的 30% 样本进行结果检验。过程流程如图 4 所示。




图 4 高光谱 DBN 分类模型流程

4 实验与分析

4.1 实验数据和设置

实验中, 用两组不同地域的高光谱数据集来验证 DBN

模型分类方法, 它们分别为 Salinas 和 PaviaU (The University of Pavia)。对于每组数据集, 随机的选取 70% 的样本对 DBN 模型进行训练, 去学习每个神经元的权重、偏置以及最合适的隐层数量和每层节点数。剩下的 30% 用来对分类效果进行验证。另外, 每个像素的值都会归一化为 $[0.0 \sim 1.0]$ 。

Salinas 数据集是由 AVIRIS 传感器捕捉到的 Salinas Valley 某一块地域的遥感影像。该高光谱遥感图像有 220 个波段, 图像大小为 512×217 。共 16 种物体类别: Broccoli green weeds, Fallow, Stubble, Grapes untrained 等。遥感影像如图 5 所示。根据之前的数据重构, 对样本进行 AE 降维保留前 140 维度, 对邻居样本进行 PCA 降维。然后进行重组后输入节点数 $n_1 = 220(140 + 10 \times 8)$ 。




图 5 Salinas 数据集遥感影像

PaviaU 数据集来自于 ROSIS 传感器, 该高光谱遥感图像有 103 个波段, 图像大小为 610×340 。共 9 中物体类别, 包括 Asphalt, Meadows, Trees, Bare soil 等。遥感影像如图 6 所示。对样本进行 AE 降维保留 60 维度, 同样对邻居样本进行 PCA 降维, 重组后输出节点数 $n_1 = 140(60 + 10 \times 8)$ 。



图 6 PaviaU 数据集遥感影像

4.2 DBN 模型的参数设置

DBN 模型的层数和隐含层节点数的选择需要通过反复实验来确定。通过固定其它参数,逐次改变层数的方法得到最佳层数,用同样的方法得到隐含层节点的个数。最终得到 Salinas 数据集的 DBN 模型由 1 层 RBM 输入层、3 层 RBM 隐含层和 1 层 bp 层构成,模型每层节点数为 $n_1=220, n_2=170, n_3=110, n_4=110, n_5=16$ 。PaviaU 数据集的 DBN 模型由 1 层 RBM 输入层、3 层 RBM 隐含层和一层 bp 层构成,每层节点数为 $n_1=140, n_2=90, n_3=70, n_4=70, n_5=9$ 。另外,训练块的大小设为 100,学习率为 0.1,迭代次数为 50。

4.3 实验结果分析和比较

采用混淆矩阵(confusion matrix)来分析分类结果和实

际测得值。混淆矩阵通过将每个实测像元的类别同地表真实类别进行比较,反应了分类结果同真实类别的误差信息。通过混淆矩阵还可以得到总体精度(OA)和 Kappa 系数^[13]等指标,通过这些指标,可以对分类结果有更清晰的认识。

表 1 为 DBN 模型方法对 PaviaU 数据集的分类结果的混淆矩阵,每一行的数值代表此类别样本正确或错误分类的样本数。总体上看,取得了很好的分类效果。另外,Asphalt 和 Bitumen 两个类别以及 Gravel 和 Bricks 两个类别混淆较为严重,说明此模型对这几种类物还没能很好的区分,希望能继续改进此模型,提取到更好的特征,进一步改进分类效果。

表 1 PaviaU 数据集分类结果的混淆矩阵

类别	Asphalt	Meadows	Gravel	Trees	Sheets	Bare soil	Bitumen	Bricks	Shadows
Asphalt	1715	13	46	2	4	12	135	62	1
Meadows	12	5360	4	58	0	161	0	0	0
Gravel	3	3	486	0	2	2	1	133	0
Trees	0	36	0	871	0	10	1	2	0
Sheets	1	2	1	0	397	3	0	0	0
Bare soil	5	122	3	2	1	1372	0	4	0
Bitumen	63	2	1	0	0	1	332	0	0
Bricks	24	7	172	0	1	5	4	892	0
Shadows	0	1	0	1	0	0	1	0	282
正确率(%)	86.18	95.79	77.14	94.67	98.26	90.92	83.21	80.72	98.94

总体精度等于正确分类的像元除以总的像元个数。可以通过混淆矩阵对角线元素相加来计算。Kappa 系数则是一种更加合理的分析技术,它利用到了混淆矩阵所有因子,评价更为客观。用 N 表示像元总数, c 表示类别数, n_{ij} 表示混淆矩阵对角线元素, n_{ir} , n_{ic} 分别表示混淆矩阵第 i 行和第 i 列的总和,则 Kappa 系数表示如下:

$$K = \frac{N \sum_{i=1}^c n_{i=j} - \sum_{ir=k=1}^c (n_{ir} n_{ic})}{N^2 - \sum_{ir=k=1}^c (n_{ir} n_{ic})} \tag{10}$$

表 2 中将 DBN 模型的方法同 SVM 方法以及传统的

神经网络(NN)方法进行分类精度的比较。SVM 方法采用开源工具 LIBSVM 中的带 RBF 核的 SVM,使用交叉验证的方法,取最优值作为结果。NN 同 DBN 的主要区别则是其没有 RBM 层的预训练过程。

从表 2 中可以看出,相对于 NN,经过预训练后的 DBN 模型在分类精度上有了明显的提升。相对于 SVM,DBN 模型分类总精度提升不明显,但 Kappa 系数有所提升,说明 DBN 模型相对于 SVM 能更好的对高光谱图像进行分类。

图 7 显示了 NN、SVM 和 DBN 三种方法对 Salinas 数据集分类的结果,可以看出 DBN 的分类效果要明显好于传统的神经网络 NN。另外,在 Grapes untrained 等类别的分类效果上也要好于 SVM。

DBN 模型的分类效果优于 NN 的原因是其通过无监督的预训练为整个网络提供了合适的初值,而 NN 则是随机赋初值。DBN 利用其更深的结构,结合了监督学习和无监督学习的特征,使其能够提取高光谱图像中更抽象更深层次的特征,相比于传统的 SVM 等算法,取得更好的分类效果。

表 2 实验结果对比

数据集	测试指标	NN	SVM	DBN
Salinas	OA	0.82	0.91	0.90
	Kappa	0.78	0.86	0.87
PaviaU	OA	0.80	0.90	0.91
	Kappa	0.76	0.86	0.88

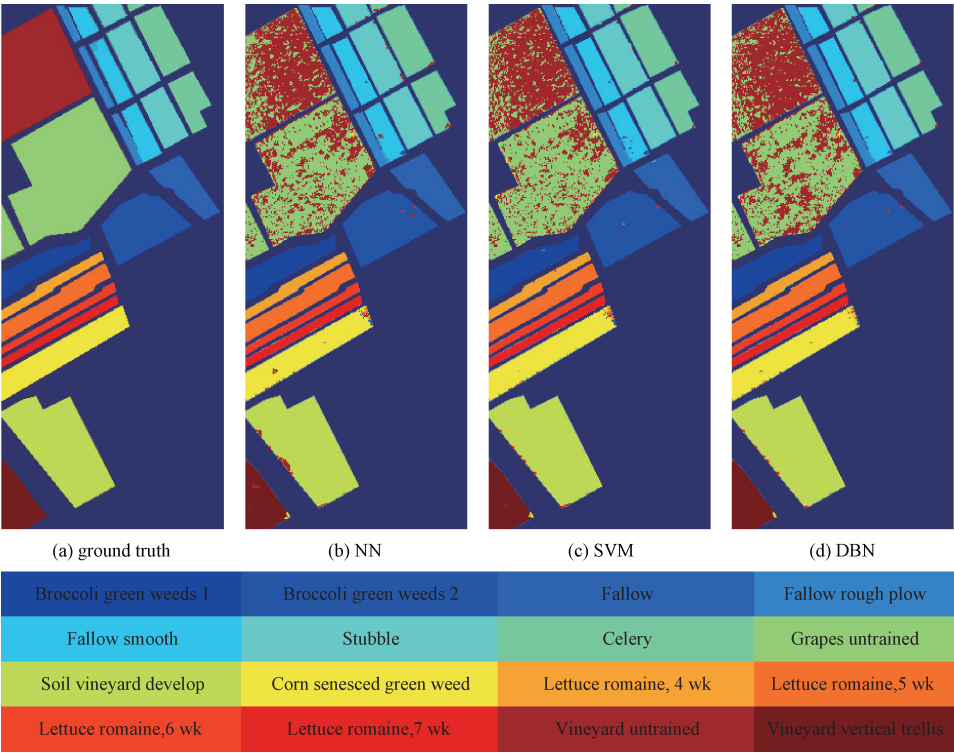


图 7 NN、SVM 和 DBN 对 Salinas 数据集分类结果比较示意

5 结 论

本文提出一种基于 DBN 模型的高光谱图像分类方法, DBN 通过无监督的预训练可以提取到更深层次的特征, 通过有监督的微调进行优化。实验表明, 相对于传统的神经网络(NN)和常用于高光谱图像分类的 SVM, DBN 可以取得更好的分类效果。另外, 结合高光谱图像集特点, 对实验中两个高光谱数据集进行了样本扩充、数据降维和空间结合操作, 进一步地提高了分类效果。

参考文献

[1] 宋琳,程咏梅,赵永强. 基于稀疏表示模型和自回归模型的高光谱分类[J]. 光学学报, 2012(3): 322-328.

[2] 施晓东,刘格. 一种光学遥感图像海陆分割方法[J]. 国外电子测量技术, 2014(11): 29-32.

[3] 胡敏,陈红波,许良凤,等. 基于颜色和纹理特征的黄瓜病害识别算法[J]. 电子测量与仪器学报, 2015(7): 970-977.

[4] 梁栋,颜普,朱明,等. 一种基于 NSCT 和 SIFT 的遥感图像配准算法[J]. 仪器仪表学报, 2011(5): 1083-1088.

[5] 谭熊,余旭初,秦进春,等. 高光谱影像的多核 SVM 分类[J]. 仪器仪表学报, 2014(2): 405-411.

[6] PAUL M, MAGALY K. Computer Processing of remotely-sensed images: an introduction [M]. New York: John Wiley & Sons, 2011: 229-285.

[7] YU D, DENG L. Deep learning and its applications

to signal and information processing[J]. IEEE Signal Processing Magazine, 2011, 28(1): 145-154.

[8] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: a review and new perspectives. [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(8): 1798-1828.

[9] 余凯,贾磊,陈雨强,等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.

[10] CHO K H, ILIN A, RAIKO T. Improved learning of gaussian-bernoulli restricted Boltzmann machines[J]. Lecture Notes in Computer Science, 2011, 6791: 10-17.

[11] YU D, DENG L. Deep learning and its applications to signal and information processing[J]. IEEE Signal Processing Magazine, 2011, 28(1): 145-154.

[12] 吕启,窦勇,牛新,等. 基于 DBN 模型的遥感图像分类[J]. 计算机研究与发展, 2014(9): 1911-1918.

[13] 罗小波,赵春晖,潘建平. 遥感图像智能分类及其应用[M]. 北京: 电子工业出版社, 2011.

作者简介

李新国, 1990 年出生, 工学硕士, 主要研究方向为深度学习, 图像处理等。
E-mail: 13776400122@163.com

黄晓晴, 1979 年出生, 博士, 副教授, 研究领域为分形, 图像处理, 数字水印等。
E-mail: sunnynuaa@163.com