

# 基于深度学习的高光谱图像空-谱联合特征提取

黄 鸿, 何 凯, 郑新磊, 石光耀

重庆大学光电技术及系统教育部重点实验室, 重庆 400044

**摘要** 由于高光谱遥感数据具有波段多、特征非线性、空间相关等特点, 提出一种基于深度学习的空-谱联合 (SSDL) 特征提取算法来有效提取数据中的空-谱特征。该算法利用多层深度学习模型——堆栈自动编码机对高光谱数据进行逐层学习, 挖掘图像中的深层非线性特征, 然后再根据每个特征像元的空间近邻信息, 对样本深度特征和空间信息进行空-谱联合, 增加同类数据聚集性和非同类数据分散度, 提升后续分类性能。在帕维亚大学和萨利纳斯山谷高光谱数据集上进行地物分类实验: 在 1% 样本比例下, 地物总体分类精度达到了 91.05% 和 94.16%; 在 5% 样本比例下, 地物总体分类精度达到了 97.38% 和 97.50%。结果表明: 由于 SSDL 特征提取算法融合了数据中深层非线性特征和空间信息, 能够提取出更具鉴别特性的特征, 较其他同类算法能够获取更高分类精度。

**关键词** 图像处理; 高光谱图像分类; 特征提取; 深度学习; 空间信息

**中图分类号** TP751      **文献标识码** A

**doi:** 10.3788/LOP54.101001

## Spatial-Spectral Feature Extraction of Hyperspectral Image Based on Deep Learning

Huang Hong, He Kai, Zheng Xinlei, Shi Guangyao

*Key Laboratory of Optoelectronic Technology and systems, Ministry of Education,  
Chongqing University, Chongqing 400044, China*

**Abstract** On the basis of the characteristics of multi-band, nonlinear and spatial correlation of hyperspectral remote sensing data, a new feature extraction algorithm based on spatial-spectral deep learning (SSDL) is proposed. This algorithm uses a multiple layers deep learning model, which is the stacked automatic encoder to study high spectral data layer by layer and explore the deep nonlinear characteristics of the image. Based on the spatial neighbor information of each feature pixel, the spatial-spectral combination of sample depth feature and spatial information is used to increase the compactness of homogeneous data and the separability of non-homogeneous data, and improve the performance of subsequent classification. The ground objects classification experiments are performed on Pavia University and Salinas Valley hyperspectral remote sensing datasets. When sample proportion is 1%, the ground objects overall classification accuracy reaches 91.05% and 94.16%. When sample proportion is 5%, the ground objects overall classification accuracy reaches 97.38% and 97.50%. The results show that the SSDL feature extraction algorithm fuses the deep nonlinear characteristics and spatial information of data. It can effectively extract the discriminant features, and obtain higher classification accuracy than other algorithms.

**Key words** image processing; hyperspectral image classification; feature extraction; deep learning; spatial information

**OCIS codes** 100.2000; 100.4997; 100.2960

收稿日期: 2017-03-21; 收到修改稿日期: 2017-05-04

基金项目: 国家自然科学基金(41371338)、重庆市研究生科研创新项目(CYS16040)、重庆市基础与前沿研究计划(cstc2013jcyjA40005)

作者简介: 黄 鸿(1980—), 男, 博士, 副教授, 主要从事高光谱遥感影像智能化处理方面的研究。

E-mail: hhuang@cqu.edu.cn

## 1 引言

作为当今遥感技术领域的重要组成部分,高光谱遥感技术在资源探索、地质矿物识别和环境检测等领域应用广泛<sup>[1-2]</sup>。由于高光谱图像光谱维度高,数据冗余大,且存在非线性特性<sup>[3]</sup>,直接进行分类易导致 Hughes 现象<sup>[4]</sup>。因此,如何降低高光谱影像光谱维数,提取低维特征并实现有效分类,已成为高光谱图像处理中的研究热点。

在特征提取算法中,主成分分析(PCA)法<sup>[5]</sup>是常用的子空间算法,但其基于高维数据的嵌入子空间是线性的假设。然而研究表明高光谱图像中存在着非线性结构。邻域保持嵌入(NPE)、局部保持投影(LPP)与局部 Fisher 判别分析(LFDA)等虽能够在一定程度上揭示高光谱遥感数据的内在结构<sup>[6]</sup>,但大都是基于线性变化的特征提取算法,并不适合提取高光谱数据中蕴含的非线性特征。

20世纪80年代末期,人工神经网络的反向传播算法掀起了机器学习热潮<sup>[7]</sup>,但由于对多层网络训练难度较大,实际使用的也只是具有一层隐层节点的浅层模型。而后多种浅层学习模型被提出,如支持向量机(SVM)、Boosting、逻辑回归(LR)等。2006年,Hinton 等<sup>[8]</sup>提出多层神经网络可通过逐层初始化来克服训练难度,使得深度学习在图像分类、语音识别等领域广泛应用。由于 Hinton 等在限制玻尔兹曼机、自动编码机(AE)上的重大突破,研究者尝试将深度学习理论应用到高光谱数据分类中。AE 近年来在高光谱遥感图像(HSI)分类中得到应用。通过深度模型的学习虽然可以充分、有效地提取高维数据中的非线性特征<sup>[9]</sup>,但由于该法未考虑高光谱图像域空间的一致性,未能有效利用其中包含的空间信息。

在高光谱图像中,各像元的类别与其分布位置关系密切,相同类别地物在图像中往往呈现集中性或块状分布。研究表明,结合光谱特征与空间特征可进一步提升高光谱图像的分类性能<sup>[10]</sup>。Tan 等<sup>[11]</sup>引入空间近邻的标记信息参与投票表决,提出了一种基于空间近邻信息与分类器集成的半监督分类算法,但需要进行多次迭代来选取样本,且分类性能受参数影响较大。文献[12]提出了一种基于空间相干距离(SCD)的近邻选取算法,通过计算环块之间的欧氏距离来度量数据点间相似度,但该算法重在比较环块中相同位置像元,而忽略了环块中各像元间的空间相关性。魏峰等<sup>[13]</sup>提出一种基于空间一致性的邻域保留嵌入(SC-NPE)降维算法。该算法首先在每一像素周围选取环块,通过对比环块间的差异来选取近邻,有效降低了同一类别中像素值差异较大的孤点或噪点的影响。

针对传统特征提取算法不能有效提取图像深层非线性特征且未能有效利用图像空间信息的问题,本文提出一种基于深度学习的空-谱联合特征提取算法(SSDL)。其主要思想是:通过堆栈自动编码机<sup>[14]</sup>提取高光谱影像深层非线性特征,得到高光谱图像的深度特征,再对深度特征进行空-谱联合,得到包含空间信息的深度特征,进而增大了同类样本之间相关性和不同类样本之间差异性,最后利用传统的分类算法,即可实现高光谱图像分类。在帕维亚大学数据集上进行实验,结果表明,该算法相比于其他相关算法,算地物分类精度得到了明显提升。

## 2 自动编码机

自动编码机是一种非监督学习数据特征的神经网络模型<sup>[15]</sup>,其模型结构如图1所示。该模型相当于一个输入层与输出层节点数相等的多层神经网络。输入数据为  $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$ ,式中  $n$  为数据  $\mathbf{x}$  的维度,即输入层的结点数。输入-隐含层中,模型根据输入数据  $\mathbf{x}$  计算隐含层结点上的值  $\mathbf{y}_i$ ,可得  $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$ ,也即数据  $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$  的特征。式中  $m$  为隐含层结点数,即数据  $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$  降维后的特征维度。在隐含-输出层中,模型根据  $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$  恢复出输入数据  $\mathbf{z} = \{z_1, z_2, \dots, z_n\}$ 。在重建  $\mathbf{z}$  的过程中,  $\mathbf{z}$  的全部信息都来自  $\mathbf{y}$ ,因此  $\mathbf{z}$  的质量可用来评价特征  $\mathbf{y}$  是否包含了输入  $\mathbf{x}$  足够的特征信息。

在自动编码机模型训练中,希望在输出  $\mathbf{z}$  与输入  $\mathbf{x}$  差异尽量小时,得到  $\mathbf{x}$  的主要特征  $\mathbf{y}$ 。

自动编码网络中各个神经元的激活函数为 sigmoid 函数

$$f(x) = \text{sigmoid}(x) = \frac{1}{1 + \exp(-x)}, \quad (1)$$

输入-隐含层称为编码器,将输入向量  $\mathbf{x}$  ( $\mathbf{x} \in \mathbf{R}^n$ ) 映射到隐含层,得到向量  $\mathbf{x}$  的特征  $\mathbf{y}$  ( $\mathbf{y} \in \mathbf{R}^m$ ):

$$\mathbf{y} = \text{sigmoid}(\mathbf{W}_y \mathbf{x} + \mathbf{b}_y), \quad (2)$$

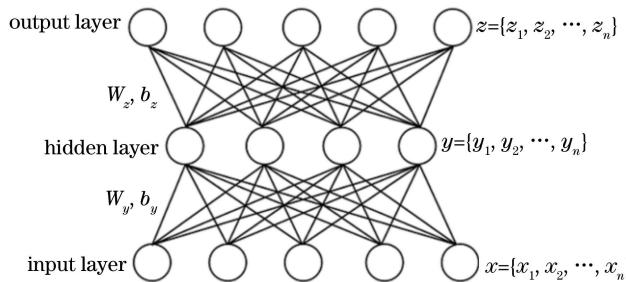


图 1 自动编码机模型

Fig. 1 Model of automatic encoder

隐含-输出层称为解码器,特征  $y$  映射到输出层,得到重建的向量  $z$  ( $z \in \mathbb{R}^n$ ):

$$z = \text{sigmoid}(W_z y + b_z), \quad (3)$$

式中  $W_y, W_z$  分别是输入- 隐含层和隐含- 输出层的连接矩阵,  $b_y, b_z$  是隐含层与输出层每个结点的偏置。这里约定  $W_y = W_z^T = W$ , 因此只需训练该模型学习  $W, b_y, b_z$  这三组参数, 以使输出  $z$  与输入  $x$  差异最小化, 目标函数为

$$I_{\text{model}} = \underset{W, b_y, b_z}{\text{argmin}} [C_{\text{cost}}(x, z)]. \quad (4)$$

这里采用  $x$  与  $z$  的互熵来度量这种差异, 其定义如下

$$C_{\text{cost}}(x, z) = -\frac{1}{b} \sum_{i=1}^b \sum_{k=1}^n [x_{ik} \lg(z_{ik}) + (1 - x_{ik}) \lg(1 - z_{ik})], \quad (5)$$

式中  $b$  为每份小批量数据的大小。 $x_{ik}$  (或  $z_{ik}$ ) 表示小批量数据中第  $i$  个输入(或重建)的第  $k$  个元素。

确定目标函数后, 采用梯度下降法对模型进行训练。更新各模型参数( $\eta$  为学习率), 不断迭代即可学习得到优化后的  $W, b_y$  和  $b_z$  分别为

$$W = W - \eta \frac{\partial C_{\text{cost}}(x, z)}{\partial W}, \quad (6)$$

$$b_y = b_y - \eta \frac{\partial C_{\text{cost}}(x, z)}{\partial b_y}, \quad (7)$$

$$b_z = b_z - \eta \frac{\partial C_{\text{cost}}(x, z)}{\partial b_z}. \quad (8)$$

完成模型训练后, 如果  $y$  可以很好地重建  $z$ , 则表明  $y$  中已经包含了充分的  $x$  的信息, 那么  $y$  即为 AE 模型提取的  $x$  的特征。

### 3 基于深度学习的 SSDL 特征提取算法

基于深度学习的 SSDL 特征提取算法通过堆栈自动编码机(SAE)模型提取高光谱图像深层非线性特征, 得到学习后的深度特征。考虑到高光谱数据中图像域空间一致性特点, 像元空间距离越靠近, 像元属于同一类别的概率就越大<sup>[16-18]</sup>。为有效利用空间信息, 增强特征的鉴别性, 利用所提 SSDL 算法对深度特征进行加权重构, 即可得到包含空间信息的深度特征—SSDL 深度特征。图 2 为基于深度学习的 SSDL 特征提取算法结构示意图。

SAE 作为一种深度学习模型, 由多层自动编码机堆叠而来。上一层自动编码机隐含层的输出作为下一层自动编码机的输入, 并利用非监督贪心逐层训练的方法自下而上预训练各层神经网络。图 3 为 4 层堆栈自动编码机模型结构图。利用 2 节中的训练方法, 首先对模型的第一层进行训练, 确定第一层连接权重矩阵  $W_1$  和偏置  $b_{y1}$ , 然后将该层输出作为下一层的输入, 利用同样方法训练第二层连接权重矩阵和偏置, 依次对下一层结点进行训练, 确定模型所有参数。利用该模型不仅可以有效降低光谱数据维度, 而且能揭示出光谱数据中蕴含的深层非线性特性。

定义高光谱遥感图像数据集  $X \in \mathbb{R}^{M \times N \times D}$ ,  $M \times N$  为数据集大小,  $D$  为数据集波段数,  $l$  为堆栈自动编码

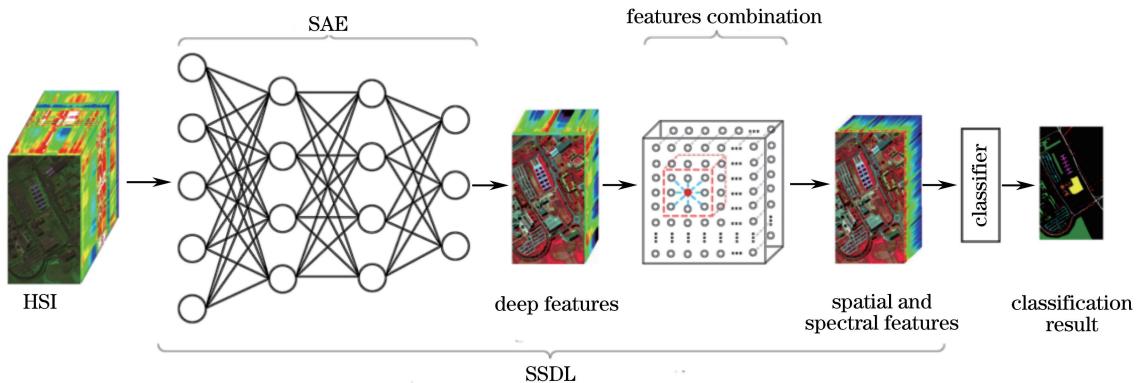


图 2 SSDL 特征提取模型

Fig. 2 Features extraction model of SSDL

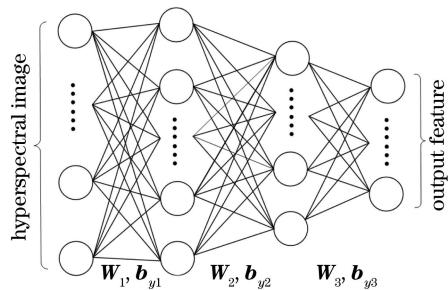


图 3 堆栈自动编码机

Fig. 3 Model of stacked automatic encoder

机层数(不包含输入层), $\mathbf{X}_i$ 为原始高光谱图像经过前*i*层学习后的深度特征( $l \geq i \geq 0$ ), $\mathbf{X}_0$ 为原始输入数据, $\mathbf{W}_i$ 与 $\mathbf{b}_{yi}$ 分别为第*i*层的连接矩阵和偏置,可得深度特征的递归式为

$$\mathbf{X}_i = \text{sigmoid}(\mathbf{W}_i \cdot \mathbf{X}_{i-1} + \mathbf{b}_{yi})。 \quad (9)$$

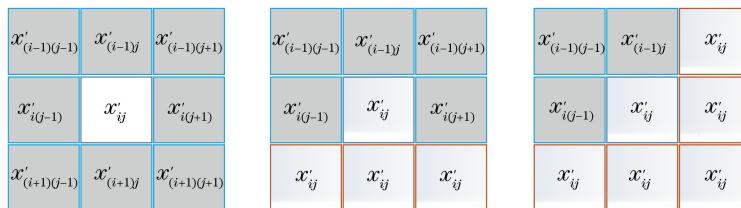
经过整个堆栈自动编码机网络学习后的深度特征为 $\mathbf{X}' \in \mathbb{R}^{M \times N \times D'}$ ,其中 $D'$ 为最后一层节点数,因此

$$\mathbf{X}' = \text{sigmoid}(\mathbf{W}_l \cdot \mathbf{X}_{l-1} + \mathbf{b}_{yl})。 \quad (10)$$

定义特征像元为 $\mathbf{x}'_{ij} \in \mathbb{R}^{D'} (\mathbf{x}'_{ij} \text{ 是深度特征 } \mathbf{X}' \text{ 中位置在 } i \text{ 行、 } j \text{ 列的特征矢量})$ ,以 $\mathbf{x}'_{ij}$ 为中心的 $\omega \times \omega$ 方形窗口区域定义为 $\Omega(\mathbf{x}'_{ij})$ ,其中 $\omega$ 称为窗口大小,为正奇数, $\Omega(\mathbf{x}'_{ij})$ 为像元 $\mathbf{x}'_{ij}$ 的近邻空间,定义为

$$\Omega(\mathbf{x}') = \{\mathbf{x}'_{st} | s \in [i-a, i+a], t \in [j-a, j+a]\}, \quad (11)$$

式中 $\mathbf{x}'_{st}$ 为 $\Omega(\mathbf{x}'_{ij})$ 中某一特征像元, $a=(\omega-1)/2$ 。对分布在数据集边缘的特征像元构建时,通过增补待构建特征像元来填充整个窗口,以 $3 \times 3$ 窗口为例,不同情况下近邻空间如图 4 所示。

图 4 不同位置时  $\mathbf{x}'_{ij}$  的近邻空间。(a) 处于中心; (b) 处于边缘; (c) 处于角落Fig. 4 Neighbor space of  $\mathbf{x}'_{ij}$  at different positions. (a) At the center; (b) on the edge; (c) in the corner

按(12)式计算 $\mathbf{x}'_{ij}$ 与 $\Omega(\mathbf{x}'_{ij})$ 内每个特征像元 $\mathbf{x}'_{st}$ 的相似度为

$$s_{st} = \frac{\mathbf{x}'_{ij} \cdot \mathbf{x}'_{st}}{\|\mathbf{x}'_{ij}\| \cdot \|\mathbf{x}'_{st}\|}, \quad (12)$$

根据 $s_{st}$ ,利用(13)式计算 $\mathbf{x}'_{ij}$ 引入空间信息后的特征矢量为

$$\mathbf{x}_{ss,ij} = \frac{\sum_{\mathbf{x}'_{st} \in \Omega(\mathbf{x}'_{ij})} s_{st} \cdot \mathbf{x}'_{st}}{\sum_{\mathbf{x}'_{st} \in \Omega(\mathbf{x}'_{ij})} s_{st}}. \quad (13)$$

为降低 SSDL 算法的复杂度,这里只取特征像元间夹角余弦值来度量两像元间相似性,特征像元夹角越小,像元光谱矢量方向越一致,属于同一类别的可能性越大,因此在引入空间信息时所占权重越大。将  $\mathbf{x}'_{ij}$  中所有特征像元利用(12)式和(13)式引入空间信息,即可得到包含空间信息的深度学习特征——SSDL 深度特征  $\mathbf{X}_{ss}$ 。需说明的是,该算法中参数  $\omega$  可依据遥感图像的特征进行设置:对于地物分散较为零散的数据集,应采用较小窗口,以减小不属同一类的像元带来的空间干扰信息;对于地物分布较集中的数据集,窗口可以适当增大,以增加同类像元间的相关性。

SSDL 算法具体步骤如下。

输入:高光谱图像数据集  $\mathbf{X} \in \mathbf{R}^{M \times N \times D}$ ,训练样本比例  $p$ ,窗口大小  $\omega$ 。

输出:样本低维 SSDL 深度特征  $\mathbf{X}_{ss}$ 。

1) 从数据集  $\mathbf{X}$  中随机选取比例为  $p$  的训练样本,训练样本类别已知,其余样本为测试样本;

2) 构造 SAE 模型,确定模型层次和每层节点数,训练 SAE 模型,确定各层  $\mathbf{W}_i$ 、 $\mathbf{b}_{yi}$ ,按(10)式计算深度特征  $\mathbf{X}' \in \mathbf{R}^{M \times N \times D'}$ ;

3) 按(12)式计算特征像元  $\mathbf{x}'_{ij} \in \mathbf{R}^{D'}$  与近邻空间  $\Omega(\mathbf{x}'_{ij})$  内其他特征像元相似度  $s_{st}$ ;

4) 按(13)式计算引入空间信息后的特征矢量  $\mathbf{x}_{ss,ij}$ ,重复 3) 和 4),对  $\mathbf{X}'$  中所有特征像元引入空间信息,最终得到 SSDL 深度特征  $\mathbf{X}_{ss}$ 。

在此基础上,可采用  $k$  最近邻( $k$ NN)、光谱角制图(SAM)和 SVM 等分类器对高光谱数据进行地物分类实验。

## 4 实验结果及分析

### 4.1 实验数据集

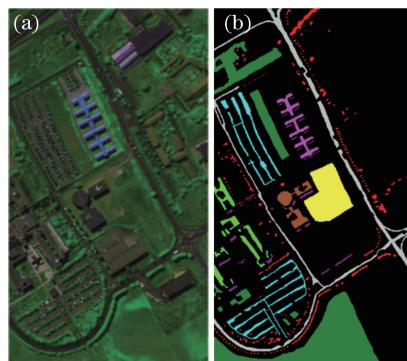
1) 帕维亚大学数据集:该数据集为 ROSIS 传感器在 2002 年获取的帕维亚大学区域的高光谱图像。图像的大小为 610 pixel×340 pixel,空间分辨率为 1.3 m,共包含 115 个光谱波段,去除 12 个噪声严重的波段,将剩余的 103 个波段用于分类实验。帕维亚大学数据集主要包含 9 类地物信息,其假彩色图和真实地物信息如图 5 所示。

2) 萨利纳斯山谷数据集:该数据集为 AVIRIS 传感器获取的美国加利福尼亚州萨利纳斯山谷区域的高光谱图像。图像大小为 512 pixel×217 pixel,空间分辨率为 3.7 m,共包含 224 个光谱波段,去除其中 20 个噪声严重的波段,将剩余 204 个波段用于分类实验。萨利纳斯数据集主要包含 16 类地物信息,其假彩色图和真实地物信息如图 6 所示。

### 4.2 实验设置

实验中,为了验证 SSDL 算法在不同数据集上都能取得较好的实验效果,分别在帕维亚大学和萨利纳斯山谷数据集上作对比实验。每次从两个数据集中随机选择一定数量样本数据作为训练样本,剩余样本作为测试样本。首先利用特征提取算法得到高光谱数据的低维嵌入特征,然后采用分类器进行地物分类,并以总体分类精度(OA)、平均分类精度(AA)、每类地物分类精度和 Kappa 系数进行分类性能评价。

选取 PCA、NPE、LPP、SAE、SC-NPE、SCD 及 SSDL 算法对每组样本进行降维,然后分别选用  $k$ NN、SVM、SAM 分类器进行分类。实验采用交叉验证方法得到各分类器的优化参数,并在每种条件下进行 10 次重复实验,以平均值和标准差进行对比。低维嵌入特征维数为 50,NPE、LPP、SC-NPE 中近邻数为 7,SC-NPE 中窗口大小为 9;SAE 算法为 4 层堆栈自动编码机,各层节点数为 103,150,100,50,迭代周期为 100,学习率为 1。实验中,SAE 模型对于不同的数据集需要设置不同的层数和节点数才能获得最佳的特征提取效果,相关研究表明,在有限层数范围内,随着层数的增加,该算法能提取出数据更深层的特征,但达到一定层数后,继续增加层数会增大算法的复杂度,影响算法性能。



asphalt (6631)  
meadows (18649)  
gravel (2099)  
trees (3064)  
sheets (1345)  
soil (5029)  
bitumen (1330)  
bricks (3682)  
shadows (947)

图 5 帕维亚大学高光谱图像。(a)假彩色图;(b)真实地物

Fig. 5 Hyperspectral images of Pavia University.

(a) Pseudo color map; (b) ground truth

在分类中,为使各算法有较好效果, $k$ NN 近邻数  $k=1$ ;SVM 采用径向基核函数(RBF),在 $(10^{-4}, 10^6)$ 和 $(2^{-4}, 2^6)$ 范围内对核参数  $\sigma$  和惩罚参数  $c$  进行交叉寻优。为验证 SSDL 算法中不同窗口  $\omega$  值对分类结果产生的影响,采用 SVM 作为分类器,随机选取 5% 训练样本进行不同  $\omega$  值的分类实验。图 7 为帕维亚大学数据集 10 次实验平均 OA 与  $\omega$  之间的关系图。由图 7 可知,当  $\omega=5$  时 OA 最高。 $\omega$  决定了窗口大小,窗口越大,存在引入较多不同类别地物空间信息的隐患,影响分类性能,且计算复杂度会增大;窗口过小,无法充分利用样本数据的空间信息,分类性能下降。考虑到分类精度和计算复杂度,实验中窗口  $\omega$  值取为 5。对于萨利纳斯山谷数据集,进行相同实验,设置参数  $\omega=5$ 。

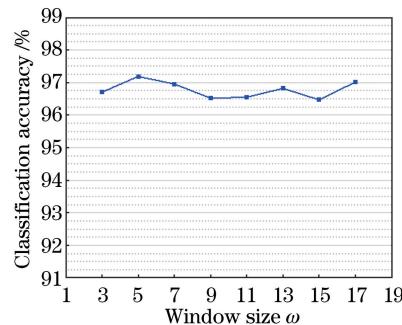


图 7 不同窗口大小下的分类精度

Fig. 7 Classification accuracy under different window sizes

#### 4.3 实验结果及分析

实验中,在两个数据集上分别对每类样本按照 1%、3%、5% 的比例随机选取训练样本,其余作为测试样本。表 1 所示为不同分类器在两个数据集上的 OA 和标准差对比。

表 1 不同分类器在帕维亚大学和萨利纳斯山谷的分类结果

Table 1 Classification results of different classifiers in Pavia University and Salinas Valley datasets

Classifiers	Pavia University			Salinas Valley		
	1	3	5	1	3	5
SAE	$k$ NN	$79.43 \pm 1.24$	$86.06 \pm 0.49$	$88.38 \pm 0.65$	$85.52 \pm 0.81$	$87.50 \pm 0.66$
	SAM	$75.63 \pm 1.86$	$81.86 \pm 1.18$	$84.05 \pm 0.85$	$84.22 \pm 0.83$	$86.96 \pm 0.56$
	SVM	$83.86 \pm 1.56$	$91.18 \pm 0.55$	$92.95 \pm 0.30$	$88.90 \pm 0.48$	$90.93 \pm 0.13$
SSDL	$k$ NN	$85.35 \pm 1.47$	$92.57 \pm 0.94$	$94.56 \pm 0.35$	$92.34 \pm 0.91$	$94.95 \pm 0.67$
	SAM	$76.86 \pm 1.98$	$89.67 \pm 1.08$	$91.4 \pm 0.78$	$90.95 \pm 0.86$	$94.14 \pm 0.33$
	SVM	<b><math>91.05 \pm 0.94</math></b>	<b><math>95.94 \pm 0.40</math></b>	<b><math>97.38 \pm 0.20</math></b>	<b><math>94.16 \pm 0.12</math></b>	<b><math>96.81 \pm 0.34</math></b>

由表 1 可知,随着样本比例增大,两个数据集上的 OA 随之增加,这是由于增加训练样本后,所包含的地物信息更为丰富,能够提取出更具鉴别的特征。在相同分类器的情况下,由于 SSDL 算法考虑到高光谱图

像局部空间图像域一致性特点,无论在帕维亚大学还是萨利纳斯山谷数据集上,利用了空间信息和光谱非线性特征的 SSDL 算法相比仅利用光谱非线性特征的 SAE 算法,在总体分类精度上提升了 5%~8%,证明了 SSDL 算法的有效性。表中数据表明,SSDL 算法在不同分类器上均能获得更高的分类精度。由表 1 还可看出,在不同比例训练样本下,SVM 分类器总能获得最好的分类精度,因此在后续对比实验中所有算法均采用 SVM 分类器进行分类实验。

为了进一步验证 SSDL 算法的特征提取性能,采用原始数据(Baseline)、NPE、LPP、PCA、SCD 和 SC-NPE 算法与其进行对比,其中 Baseline 是直接利用 SVM 分类器进行分类。表 2 所示为不同特征提取算法的 OA 和标准差对比。

表 2 不同特征提取算法在 SVM 分类器上的分类结果

Table 2 Classification results of different feature extraction algorithms on the SVM classifier

Extraction algorithm	Pavia University			Salinas Valley			%
	1	3	5	1	3	5	
SVM	Baseline	85.98±1.03	91.39±0.38	92.67±0.36	87.18±0.42	90.21±0.43	91.29±0.21
	NPE	84.51±0.85	88.05±1.00	92.02±0.57	84.30±1.55	91.74±0.19	92.59±0.13
	LPP	84.54±0.89	90.84±0.38	91.73±0.43	84.01±0.55	91.36±0.13	92.27±0.11
	PCA	85.93±1.05	91.36±0.39	92.62±0.39	87.02±0.45	87.02±0.37	91.05±0.17
	SCD	84.90±0.76	91.55±0.35	93.62±0.41	93.16±0.81	95.98±0.23	97.13±0.35
	SC-NPE	89.49±0.78	93.69±0.57	94.65±0.38	50.93±2.14	91.31±1.10	96.81±0.22
	SSDL	<b>91.05±0.94</b>	<b>95.94±0.40</b>	<b>97.38±0.20</b>	<b>94.16±0.12</b>	<b>96.81±0.34</b>	<b>97.50±0.14</b>

由表 2 可知,在不同比例样本情况下,利用空间信息的 SCD、SC-NPE 和 SSDL 算法相比没有利用空间信息的 PCA、LPP 和 NPE 算法分类精度更高,有力说明了联合空间信息有利于地物分类精度的提升。在两个数据集上,SSDL 算法相比于 SCD 和 SC-NPE 算法分类精度更高,进一步证明了 SSDL 算法特征提取的有效性。尤其在样本比例比较小的情况下,SSDL 算法效果明显,总体分类精度分别达到了 91.05% 与 94.16%。这是因为通过多层堆栈自动编码机模型的学习,揭示了蕴含在高光谱遥感数据中的深层非线性特征,同时引入了训练样本嵌入特征的空间信息,提取了样本数据的 SSDL 深度特征,使得同类样本特征更加聚集,不同类样本特征更为分散,增强了类别的鉴别力,提高了分类精度。

为进一步测试 SSDL 算法对各类别地物特征的提取性能,分别在两个数据集上随机选取 5% 的样本作为训练集,所有样本作为测试集,测试 NPE、LPP、PCA、SCD、SC-NPE 和 SSDL 算法对每类地物的分类精度。表 3 和表 4 分别为不同算法在帕维亚大学和萨利纳斯山谷数据集上每类地物样本的分类性能对比。

表 3 不同算法在帕维亚大学数据集每类地物上的分类精度

Table 3 Classification accuracy of each class of ground objects with different algorithms in Pavia University dataset %

Class	Training sample	Testing sample	Baseline	PCA	LPP	NPE	SCD	SC-NPE	SSDL
Asphalt	330	6301	92.62	92.38	93.54	93.37	90.18	94.87	<b>96.64</b>
Meadows	930	17719	97.77	97.71	98.59	98.40	99.38	<b>100</b>	<b>99.58</b>
Gravel	100	1999	73.29	72.79	68.63	67.43	83.94	85.49	<b>86.04</b>
Trees	150	2914	93.27	93.27	92.38	91.56	86.58	63.04	<b>94.75</b>
Sheets	60	1285	98.52	98.52	99.14	98.99	99.92	24.75	<b>99.92</b>
Soil	250	4779	87.38	87.49	74.41	79.87	81.96	93.91	<b>98.77</b>
Bitumen	60	1270	84.96	85.35	67.56	62.36	<b>95.98</b>	90.71	94.80
Bricks	180	3502	86.44	86.41	89.12	<b>91.12</b>	93.58	89.86	90.41
Shadows	40	907	99.78	99.78	100	<b>100</b>	98.24	83.57	96.69
Average accuracy			90.45	90.41	87.04	90.41	92.20	81.48	<b>95.29</b>
Overall accuracy			92.91	92.85	91.31	91.73	93.62	91.32	<b>97.02</b>
Kappa			0.9058	0.9049	0.8832	0.8892	0.9147	0.8803	<b>0.9605</b>

由表 3 和表 4 可知,SCD、SC-NPE 和 SSDL 算法在 AA、OA、Kappa 和地物分类精度参数上均明显优于 PCA、LPP 和 NPE 算法,这是因为前者都有效利用了空间信息来提高地物分类精度。还可以看出 SSDL 算

法对各类地物的分类精度均大于90%，相比较于SCD和SC-NPE算法能获得更高的AA、OA、Kappa性能，且绝大部分情况下地物分类精度性能更高，说明SSDL算法能够更有效地提取并融合高光谱数据集中的非线性特征和空间信息。

表4 不同算法在萨利纳斯山谷数据集上每类地物上的分类精度

Table 4 Classification accuracy of each class of ground objects with different algorithms in Salinas Valley dataset %

Class	Training sample	Testing sample	Baseline	PCA	LPP	NPE	SCD	SC-NPE	SSDL
Weeds_1	100	1909	99.53	99.53	99.74	99.69	99.67	98.01	<b>99.84</b>
Weeds_2	180	3546	99.66	99.66	99.94	99.86	99.35	96.16	<b>99.94</b>
Fallow	90	1886	97.61	97.35	99.68	98.78	99.81	97.08	<b>99.89</b>
Fallow_P	60	1334	98.8	98.88	99.25	99.03	<b>99.55</b>	94.98	98.13
Fallow_S	130	2548	99.22	99.22	99.29	98.94	99.62	97.92	<b>99.8</b>
Stubble	190	3769	99.44	99.44	99.71	99.66	100	97.74	<b>100</b>
Celery	170	3409	99.79	99.79	99.91	99.91	99.89	97.62	<b>99.91</b>
Grapes	560	10711	83.61	82.56	91.51	89.92	99.26	<b>99.62</b>	94.76
Soil	310	5893	99.76	99.76	99.95	99.9	99.78	99.69	<b>99.98</b>
Corn	160	3118	92.37	92.33	96.22	95.09	97.88	93.1	<b>97.95</b>
Lettuce_4wk	50	1018	7.35	97.25	98.23	98.33	<b>99.51</b>	78	98.82
Lettuce_5wk	90	1837	98.09	98.09	99.89	99.24	<b>100</b>	96.41	99.46
Lettuce_6wk	40	876	96.23	96.23	98.06	98.06	100	88.93	<b>100</b>
Lettuce_7wk	50	1020	94.22	94.22	98.24	97.65	98.71	88.33	<b>98.82</b>
Vinyard_U	360	6908	70.3	69.63	61.45	64.19	94.38	<b>94.43</b>	91.85
Vinyard_T	90	1717	97.85	97.85	98.6	98.31	97.61	92.43	<b>98.66</b>
Average accuracy			95.23	95.11	96.23	96.03	98.36	96.49	<b>98.59</b>
Overall accuracy			91.49	91.17	92.57	92.42	97.33	94.40	<b>97.48</b>
Kappa			0.9052	0.9017	0.9170	0.9154	0.9703	0.96.7	<b>0.9719</b>

## 5 结 论

针对传统高光谱图像分类算法不能充分提取深层非线性特征且未能有效利用图像中空间信息的问题，提出了一种基于深度学习的SSDL特征提取算法。该算法首先通过多层深度学习模型逐层提取蕴含在高维数据中的非线性鉴别特征，降低数据冗余度，然后通过SSDL算法引入数据中包含的空间信息，实现空-谱特征的联合，强化相同类别像元之间的联系，增大不同类别像元间的差异，为后续分类处理提供了更具鉴别力的特征。在帕维亚大学和萨利纳斯山谷高光谱数据集上的实验结果表明，相比其他同类算法，SSDL算法更能有效利用数据中的空间信息，明显提高地物分类精度，即使在样本比例为1%的情况下，SSDL算法相比其他算法依然能够提取更有效的鉴别特征。在地物类别分布密集的区域，SSDL算法存在引入不同类像元空间信息从而影响分类精度的可能，在下一步工作中，将研究如何减小不同类别地物造成的影响。

## 参 考 文 献

- [1] Meng Xin, Li Jianxin, Zhu Rihong, et al. Compressive sampling recovery method of narrow-band hyperspectral interferometric imaging[J]. Acta Optica Sinica, 2012, 33(1): 0130001.  
孟鑫, 李建欣, 朱日宏, 等. 窄带高光谱干涉成像的压缩采样复原方法[J]. 光学学报, 2013, 33(1): 0130001.
- [2] Zhao Chunhui, Qi Bin, Zhang Yi. Hyperspectral image classification based on variational relevance vector machine[J]. Acta Optica Sinica, 2012, 32(8): 0828004.  
赵春晖, 齐滨, 张燚. 基于改进型相关向量机的高光谱图像分类[J]. 光学学报, 2012, 32(8): 0828004.
- [3] Li T, Zhang J P, Zhang Y. Classification of hyperspectral image based on deep belief networks[C]. Proceedings of IEEE International Conference on Image Processing, Paris, 2014: 5132-5136.
- [4] Fan Liheng, Lü Junwei, Deng Jiangsheng. Classification of hyperspectral remote sensing images based on bands

- grouping and classification ensembles[J]. Acta Optica Sinica, 2014, 34(9): 0910002.
- 樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法[J]. 光学学报, 2014, 34(9): 0910002.
- [5] Huang Hong, Qu Huanpeng. Hyperspectral remote sensing image classification based on SSDE [J]. Optics and Precision Engineering, 2014, 22(2): 434-442.
- 黄鸿, 曲换鹏. 基于半监督稀疏鉴别嵌入的高光谱遥感影像分类[J]. 光学精密工程, 2014, 22(2): 434-442.
- [6] Tang Y Y, Yuan H L, Li L Q. Manifold-based sparse representation for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(12): 7606-7618.
- [7] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323 (6088): 533-536.
- [8] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313 (5786): 504-207.
- [9] le Roux N, Bengio Y. Deep belief networks are compact universal approximators[J]. Neural Computation, 2010, 22 (8): 2192-2207.
- [10] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images [J]. Proceedings of the IEEE, 2013, 101(3): 652-675.
- [11] Tan K, Hu J, Li J, et al. A novel semi-supervised hyperspectral image classification approach based on spatial neighborhood information and classifier combination[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 105: 19-29.
- [12] Mohan A, Sapiro G, Bosch E. Spatially coherent nonlinear dimensionality reduction and segmentation of hyperspectral images[J]. IEEE Geoscience & Remote Sensing Letters, 2007, 4(2): 206-210.
- [13] Wei Feng, He Mingyi, Mei Shaohui. Hyperspectral data feature extraction using spatial coherence based neighborhood preserving embedding[J]. Infrared and Laser Engineering, 2012, 41(5): 1249-1254.  
魏峰, 何明一, 梅少辉. 空间一致性邻域保留嵌入的高光谱数据特征提取[J]. 红外与激光工程, 2012, 41(5): 1249-1254.
- [14] Lu S C, Liu H P, Li C W. Manifold regularized stacked autoencoder for feature learning[C]. Proceedings of IEEE International Conference on Systems Man and Cybernetics, 2015: 2950-2955.
- [15] Hu Zhaohua, Song Yaoliang. Dimensionality reduction and reconstruction of data based on autoencoder network[J]. Journal of Electronics & Information Technology, 2009, 31(5): 1189-1192.  
胡昭华, 宋耀良. 基于 Autoencoder 网络的数据降维和重构[J]. 电子与信息学报, 2009, 31(5): 1189-1192.
- [16] Yang Zhaoxia, Zou Zhengrong, Tao Chao, et al. Hyperspectral image classification based on the combination of spectral-spatial feature and sparse representation[J]. Acta Geodaetica et Cartographica Sinica, 2015, 44(7): 775-781.  
杨钊霞, 邹峥嵘, 陶超, 等. 空-谱信息与稀疏表示相结合的高光谱遥感影像分类[J]. 测绘学报, 2015, 44(7): 775-781.
- [17] Fu W, Li S T, Fang L Y. Spectral-spatial hyperspectral image classification via super pixel merging and sparse representation[C]. Proceeding of IEEE Geoscience and Remote Sensing Symposium, 2015: 4971-4974.
- [18] Yang S Y, Jin P L, Li B, et al. Semisupervised dual-geometric subspace projection for dimensionality reduction of hyperspectral image data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(6): 3587-3593.