

# 基于自动编码器的高光谱遥感图像分类

董安国<sup>1\*\*</sup>, 刘洪超<sup>1\*</sup>, 张倩<sup>1</sup>, 梁苗苗<sup>2</sup>

<sup>1</sup>长安大学理学院, 陕西 西安 710064;

<sup>2</sup>江西理工大学信息工程学院, 江西 赣州 341000

**摘要** 根据高光谱遥感图像数据维度高、空间相关性、特征非线性等特点,提出了一种基于深度学习的空-谱特征提取分类算法。首先在堆栈稀疏自动编码器中加入权重衰减项,再利用主成分分析方法对图像数据进行降维处理,然后根据主成分影像块内所有像元的第一主成分与中心像元间的差距对邻域信息进行排序、删除、重组和堆栈,最后将得到的空-谱信息输入到与 SoftMax 分类器相结合的堆栈稀疏自动编码器中进行分类。通过两组实验数据的对比,验证了所提分类算法可以提高高光谱图像的分类精度。

**关键词** 遥感; 高光谱遥感图像; 遥感图像分类; 深度学习; 空-谱特征

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP56.192801

## Hyperspectral Remote Sensing Image Classification Based on Auto-Encoder

Dong Anguo<sup>1\*\*</sup>, Liu Hongchao<sup>1\*</sup>, Zhang Qian<sup>1</sup>, Liang Miaomiao<sup>2</sup>

<sup>1</sup> School of Science, Chang'an University, Xi'an, Shaanxi 710064, China;

<sup>2</sup> School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

**Abstract** Hyperspectral remote sensing image data have characteristics of high dimension, spatial correlation, and feature nonlinearity, based on which a spatial-spectral feature extraction classification method based on deep learning is proposed herein. First, the weight decay is added to a stacked sparse auto-encoder. Next, the principal component analysis method is used to reduce the dimensionality of the image data. Then, neighborhood information is sorted, deleted, reorganized, and stacked according to the difference between the first principal component of all pixels in the principal component image block and the central pixel. Finally, the obtained spatial-spectral information is input into a stacked sparse auto-encoder combined with the SoftMax classifier for classification. The comparison of two sets of experimental data reveals that the proposed classification algorithm improves the classification accuracy of hyperspectral images.

**Key words** remote sensing; hyperspectral remote sensing image; remote sensing image classification; deep learning; spatial-spectral feature

**OCIS codes** 280.4788; 100.4145; 100.3008; 100.2960

## 1 引言

高光谱遥感技术因具有地表覆盖识别能力而被广泛地应用在土地资源调查与管理、环境实时监测、地质灾害评估等方面<sup>[1]</sup>。高光谱波段间相关性强、图像数据维度高、光谱混合等特点增加了其分类的难度<sup>[2]</sup>。目前,高光谱在图像分类中主要存在两大难

题:1)遥感图像分辨率的提高导致收集到的光谱数据呈高维状态,容易引发“维度灾难”;2)在图像监督分类方法中,标签数据的获取难度较大,样本数量有限。

在高光谱分类算法中,支持向量机(SVM)具有对高维度的敏感性较低且不受“Hughes”现象影响<sup>[3]</sup>的优点,可以取得良好的分类效果;稀疏表示算法<sup>[4]</sup>通过将训练样本线性组合后来表示每一个测试

收稿日期: 2019-03-10; 修回日期: 2019-03-31; 录用日期: 2019-04-11

基金项目: 国家自然科学基金(41601437,41571346,11201038)

\* E-mail: 18710866110@163.com; \*\* E-mail: donganguo@chd.edu.cn

样本,通过最小残差来确定每个测试样本的类别。因为只用到了光谱信息,所以上述两种方法容易导致图像分类结果不平滑<sup>[5]</sup>。多尺度自适应稀疏表示(MASR)<sup>[6]</sup>可以有效地结合被分类像元的空间信息,在多尺度空间通过自适应的稀疏矩阵对高光谱图像进行分类;CK-SVM<sup>[7]</sup>是在SVM算法的基础上提出的基于核的SVM算法,该算法引入了空间信息,并且空间特征通常用空间邻域中像元的平均值或标准差来表示。上述方法通过在分类方法中引入空间信息,降低了像元被错分的概率,提高了图像的分类精度。近年来,深度学习<sup>[8]</sup>开始受到人们的关注,并被成功应用于图像分类研究方面。深度学习源于人们对神经网络的研究,其结构由包含多个隐藏层的多层感知器组成,属于神经网络的延续。深度学习最大的特点是可以非线性方式提取高维数据特征,挖掘数据信息。目前,在图像分类中,深度学习主要分为以下三大理论:自动编码器(AE)与堆栈自动编码器(SAE)<sup>[9]</sup>、受限玻尔兹曼机(RBM)与深度置信网络(DBN)<sup>[10-11]</sup>、卷积神经网络(CNN)<sup>[12]</sup>。本文主要从堆栈自动编码器理论出发进行研究;同时,为了优化模型加入了权重衰减项与稀

疏约束条件,为了提高特征信息的提取效果,对空-谱信息的提取方式进行改进,对邻域信息进行一定筛选后再对高光谱图像信息进行分类。实验结果证明了所提方法可以有效地提高分类结果的精确度。

## 2 堆栈稀疏自动编码器(S-SAE)与逻辑回归分类器模型

### 2.1 自动编码器

自动编码器是一种可以自主学习的包含输入层、隐藏层及输出层的三层神经网络模型。输入层与隐藏层组合为编码层,用于数据特征的提取;隐藏层与输出层组合为解码层,用于数据的重建。首先将数据输入,提取数据特征到隐藏层,再通过重建得到输出层,使输出层数据与输入层数据的差距最小,然后删除输出层,保留编码层。

如图1所示,在输入层输入变量 $\mathbf{x}$ ,通过编码层中权重 $\mathbf{W}_e$ 与偏置 $\mathbf{b}_e$ 的非线性函数映射得到隐藏层特征 $\mathbf{h}$ ,再通过解码层的权重 $\mathbf{W}_d$ 与偏置 $\mathbf{b}_d$ 反投影隐藏层,得到输出层 $\mathbf{z}$ 。上述过程可表示为

$$f_e(\mathbf{x}) = S(\mathbf{W}_e \mathbf{x} + \mathbf{b}_e), \quad (1)$$

$$f_d(\mathbf{x}) = S(\mathbf{W}_d \mathbf{x} + \mathbf{b}_d), \quad (2)$$

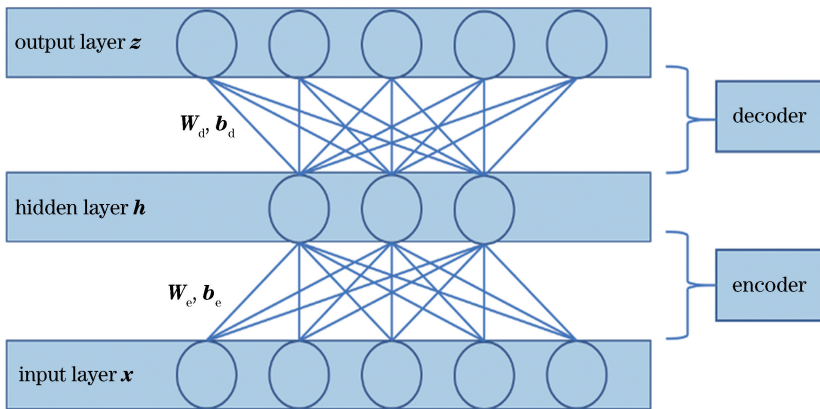


图1 自动编码器模型

Fig. 1 Auto-encoder model

式中: $f_e(\mathbf{x})$ 为隐藏层的信息值; $f_d(\mathbf{x})$ 为输出层的信息值; $S(\cdot)$ 为sigmoid函数, $S(t) = 1/[1 + \exp(-t)]$ , $t \in \mathbf{R}$ 。当 $t$ 为任意实数时,其导数可用其自身的形式表达为

$$S'(t) = S(t)[1 - S(t)], \quad (3)$$

$$S''(t) = S(t)[1 - S(t)][1 - 2S(t)]. \quad (4)$$

定义 $\mathbf{S}(t) = [S(t_1) \ S(t_2) \ \cdots \ S(t_n)]^T$ ,  
 $\mathbf{S}'(t) = [S'(t_1) \ S'(t_2) \ \cdots \ S'(t_n)]^T$ ,  
 $\mathbf{t} = [t_1 \ t_2 \ \cdots \ t_n]^T$ ,  
 $n$ 为向量 $\mathbf{t}$ 的维数。记隐藏层的特征值 $\mathbf{h}(\mathbf{x}) = f_e(\mathbf{x})$ ,则输出层 $\mathbf{z}(\mathbf{x}) = f_d[\mathbf{h}(\mathbf{x})]$ ,并记

$\mathbf{W} \in \{\mathbf{W}_e, \mathbf{W}_d\}$ ,以及 $\mathbf{b} \in \{\mathbf{b}_e, \mathbf{b}_d\}$ 。为了使输出层数据与输入层数据的差距最小,将最小平方差作为函数的损失衡量标准,并引入整体代价函数:

$$J(\mathbf{W}, \mathbf{b}) = \operatorname{argmin} \left( \frac{1}{2m} \sum_{i=1}^m \|\mathbf{x}^{(i)} - \mathbf{z}^{(i)}\|_2^2 \right), \quad (5)$$

式中: $m$ 为总样本个数; $\mathbf{x}^{(i)}$ 、 $\mathbf{z}^{(i)}$ 为第 $i$ 个输入、输出向量; $\frac{1}{2}$ 是为了方便计算而加入的常数。模型的计算使用随机梯度下降算法,迭代公式为

$$\mathbf{W}' = \mathbf{W} - \eta \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}}, \quad (6)$$

$$\mathbf{b}' = \mathbf{b} - \eta \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}}, \quad (7)$$

式中： $\mathbf{W}$ 为迭代前的权重； $\mathbf{W}'$ 为迭代后的权重； $\mathbf{b}$ 为迭代前的偏置； $\mathbf{b}'$ 为迭代后的偏置； $\eta$ 为学习率。本研究需要对模型中的 $\mathbf{W}_e$ 、 $\mathbf{b}_e$ 、 $\mathbf{W}_d$ 、 $\mathbf{b}_d$ 都进行如(6)~(7)式的迭代更新。

因成像过程中环境因素的影响,收集到的高光谱信息呈非线性特性<sup>[13]</sup>,因此,利用非线性方法提取特征就显得尤为重要。而自动编码机的优势在于利用非线性函数可以更好地提取数据信息,所以自动编码机比其他线性方法在高光谱特征提取方面更具有优势。

### 2.2 堆栈自动编码器

堆栈自动编码器是指由多个自动编码器堆叠后得到的深层神经网络,堆叠的层数越多,就可以提取到更高层次的特征,并且通常会在最后一层加上一个逻辑回归分类层进行分类。图2是一个由三层堆栈自动编码器堆叠得到的编码网络,其中每一层的构造原理与单层自动编码器相同,第二层的输入是由第一层提取得到的特征,第三层的输入是由第二层提取得到的特征,层层叠加完成编码机的堆栈与特征提取;顶层分类器需要使用带有已知标签的样本数据,属于有监督的分类方法。此模型分为两个阶段进行:预训练与微调。预训练阶段是从第一层开始逐层训练模型参数,保证编码器可以最大可能地保留输入数据的特征,属于逐层贪婪训练法,是一种无监督的训练;在训练分类器时,通过反向传播的算法微调优化整个自动编码机的参数,属于有监督的微调。

### 2.3 堆栈稀疏自动编码器

堆栈稀疏自动编码器经过层层堆栈可以很好地学习到高光谱的高层次特征,但为了更好地发现输入数据的结构以及更符合人脑神经元的工作特点,在损失函数中添加一个稀疏惩罚项,构成堆栈稀疏自动编码器。损失函数为

$$\operatorname{argmin} J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^g K_L(\rho \parallel \hat{\rho}_j), \quad (8)$$

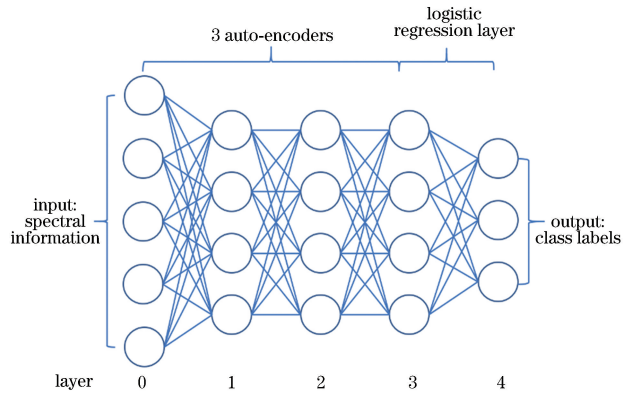


图2 堆栈自动编码器与分类器

Fig. 2 Stack auto-encoder and classifier

式中： $g$ 为第 $g$ 个隐藏层网络节点的个数； $\beta$ 为稀疏性约束参数；稀疏性惩罚项 $\sum_{j=1}^g K_L(\rho \parallel \hat{\rho}_j)$ 用来计算两个随机变量的相对熵,即

$$K_L(\rho \parallel \hat{\rho}_j) = \rho \ln \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \ln \frac{1 - \rho}{1 - \hat{\rho}_j}, \quad (9)$$

其中,

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m h_j[\mathbf{x}^{(i)}], \quad (10)$$

式中： $h_j[\mathbf{x}^{(i)}]$ 为第 $i$ 个输入变量在隐含层的第 $j$ 个分量； $\rho$ 为稀疏性系数； $\hat{\rho}_j$ 为在隐藏层第 $j$ 个神经元处激活的所有数值的平均值。

模型中有很多参数,这会增大模型计算的复杂度。为了减小权重变化的幅度,避免发生过度拟合<sup>[14]</sup>现象,在损失函数中加入了权重衰减项 $\frac{\lambda}{2}(\|\mathbf{W}_e\|_2 + \|\mathbf{W}_d\|_2)$ ,其中 $\lambda$ 为调节参数,其堆栈稀疏自动编码函数的损失函数变为

$$\operatorname{argmin} J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^g K_L(\rho \parallel \hat{\rho}_j) + \frac{\lambda}{2}(\|\mathbf{W}_e\|_2 + \|\mathbf{W}_d\|_2). \quad (11)$$

记 $f(\mathbf{x}) = \mathbf{x} \cdot (\mathbf{1} - \mathbf{x})$ ,  $\hat{\rho} = (\hat{\rho}_1, \dots, \hat{\rho}_g)^\top$ ,则自动编码器中的更新梯度为

$$\begin{cases}
 \frac{\partial J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}_e} = \frac{1}{m} \sum_{i=1}^m \left\{ \left\{ -\mathbf{W}_d^T \times \{ [\mathbf{x}^{(i)} - \mathbf{z}^{(i)}] \cdot \mathbf{f}[\mathbf{z}^{(i)}] \} + \beta \left( -\frac{\hat{\rho}}{\rho} + \frac{1-\hat{\rho}}{1-\rho} \right) \right\} \cdot \mathbf{f}\{h[\mathbf{x}^{(i)}]\} \right\} \times \\
 [\mathbf{x}^{(i)}]^T + \lambda \mathbf{W}_e \\
 \frac{\partial J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}_e} = -\frac{1}{m} \sum_{i=1}^m \left\{ \mathbf{W}_d^T \times \{ [\mathbf{x}^{(i)} - \mathbf{z}^{(i)}] \cdot \mathbf{f}[\mathbf{z}^{(i)}] \} + \beta \left( \frac{\hat{\rho}}{\rho} - \frac{1-\hat{\rho}}{1-\rho} \right) \right\} \cdot \mathbf{f}\{h[\mathbf{x}^{(i)}]\} \\
 \frac{\partial J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}_d} = -\frac{1}{m} \sum_{i=1}^m \{ [\mathbf{x}^{(i)} - \mathbf{z}^{(i)}] \cdot \mathbf{f}[\mathbf{z}^{(i)}] \} \times \{ h[\mathbf{x}^{(i)}] \}^T + \lambda \mathbf{W}_d \\
 \frac{\partial J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}_d} = -\frac{1}{m} \sum_{i=1}^m [\mathbf{x}^{(i)} - \mathbf{z}^{(i)}] \cdot \mathbf{f}[\mathbf{z}^{(i)}]
 \end{cases}, \quad (12)$$

式中： $\cdot$ 为矩阵点乘运算(即两个向量中对应分量相乘所得的向量)； $\times$ 为乘法运算。模型的参数优化更新为

$$\mathbf{W}' = \mathbf{W} - \eta \frac{\partial J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}}, \quad (13)$$

$$\mathbf{b}' = \mathbf{b} - \eta \frac{\partial J_{\text{S-SAE}}(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}}. \quad (14)$$

## 2.4 SoftMax 分类器

本文选用的是 SoftMax 分类器,在训练分类器的同时可以微调自动编码器模型参数。将由上述堆栈稀疏自动编码器提取的光谱特征输入到分类器中便可以得到每个样本所属的类别,这是一种有监督的分类方法。

SoftMax 分类器解决的是样本中有多个类别的分类问题,设  $a$  个已知标签样本为  $\{[\mathbf{x}^{(1)}, y^{(1)}], \dots, [\mathbf{x}^{(r')}, y^{(r')}], \dots, [\mathbf{x}^{(a)}, y^{(a)}]\}$ , 其中  $\mathbf{x}^{(r')}$  为光谱向量,  $y^{(r')}$  为样本所对应的标签类别,  $y^{(r')} \in \{1, 2, \dots, k\}$ ,  $k$  为最大类别数目。本文用函数  $p[y^{(d)} = r | \mathbf{x}^{(d)}]$  表示给定测试样本  $\mathbf{x}^{(d)}$  属于类别  $r$  的概率,用  $h_{\theta}(\mathbf{x})$  函数来计算  $\mathbf{x}^{(d)}$  分别属于第 1 类到第  $k$  类的概率估计值( $d$  为第  $d$  个测试样本),且属于每一类的概率估计值用  $P_r$  表示,即

$$h_{\theta}[\mathbf{x}^{(d)}] = \left\{ \begin{array}{l} p[y^{(d)} = 1 | \mathbf{x}^{(d)}; \theta] \\ p[y^{(d)} = 2 | \mathbf{x}^{(d)}; \theta] \\ \vdots \\ p[y^{(d)} = k | \mathbf{x}^{(d)}; \theta] \end{array} \right\} = \frac{1}{\sum_{r=1}^k \exp[\theta_r^T \mathbf{x}^{(d)}]} \left\{ \begin{array}{l} \exp[\theta_1^T \mathbf{x}^{(d)}] \rightarrow P_1 \\ \exp[\theta_2^T \mathbf{x}^{(d)}] \rightarrow P_2 \\ \vdots \\ \exp[\theta_k^T \mathbf{x}^{(d)}] \rightarrow P_k \end{array} \right\}, \quad (15)$$

(15)式右边的分母是将所有的概率分布归一化,即  $P_1 + P_2 + \dots + P_k = 1$ 。输出概率中最大值的对应

角标即为该测试样本  $\mathbf{x}^{(d)}$  所属类别,例如  $P_1$  最大,则  $\mathbf{x}$  属于第一类。 $\theta$  为参数,为了方便起见,记  $\theta = [\theta_1^T, \theta_2^T, \dots, \theta_r^T, \dots, \theta_k^T]$ ,  $r = 1, \dots, k$ , 其中的任何一个参数  $\theta_r$  均为  $p+1$  维,  $p$  为输入特征个数,  $p+1$  维代表在计算过程中将分类器的偏置项放在了最后一层。模型的代价函数为

$$J(\theta) = -\frac{1}{a} \cdot$$

$$\left[ \sum_{c=1}^a \sum_{r=1}^k 1[y^{(c)} = r] \ln \frac{\exp[\theta_r^T \mathbf{x}^{(c)}]}{\sum_{l=1}^k \exp[\theta_l^T \mathbf{x}^{(c)}]} \right] + \frac{\varphi}{2} \sum_{i=1}^{p+1} \sum_{j'=1}^k \theta_{ij'}^2, \quad (16)$$

式中： $\varphi$  为正则项系数； $\mathbf{x}^{(c)}$  为第  $c$  个训练样本； $\theta_l$  为  $\theta$  中第  $l$  个参数,  $l = 1, \dots, k$ ； $1[\cdot]$  为示性函数,计算时若  $[\cdot]$  中的内容为真,则  $1[\cdot]$  值为 1,若  $[\cdot]$  中的内容为假,则  $1[\cdot]$  值为 0； $\frac{\varphi}{2} \sum_{i=1}^{p+1} \sum_{j'=1}^k \theta_{ij'}^2$  为权重衰减项,可使函数具有唯一解； $\theta_{ij'}$  为  $\theta_r$  第  $i'$  行第  $j'$  列的矩阵元。本文使用迭代优化算法(L-BFGS)来计算  $J(\theta)$  函数的最小化问题,求导后可得

$$\nabla_{\theta_r} J(\theta) = -\frac{1}{a} \sum_{c=1}^a \{ \mathbf{x}^{(c)} \{ 1[y^{(c)} = r] - p[y^{(c)} = r | \mathbf{x}^{(c)}; \theta] \} \} + \varphi \theta_r. \quad (17)$$

设  $\alpha$  为学习率,每一次迭代均需要进行如下更新:

$$\theta_r := \theta_r - \alpha \nabla_{\theta_r} J(\theta), \quad r = 1, 2, \dots, k. \quad (18)$$

## 3 基于旋转不变特性的空-谱特征提取

高光谱分类过程中存在同类异谱与异类同谱现






图3 高光谱遥感图像。(a)实际分类图;(b)堆栈稀疏自动编码器算法的分类结果;(c)光谱曲线图

Fig. 3 Hyperspectral remote sensing images. (a) True classification picture; (b) classification result of S-SAE algorithm; (c) spectral curves

象<sup>[15]</sup>,如图3所示。图3(a)为实际分类图,图3(b)为堆栈稀疏自动编码器算法的分类结果,图3(c)为A、B、C三个像元的光谱图。由图3可知:B和C属于同一类别,但光谱曲线差异较大,属于分类中的同类异谱现象;A、C的光谱曲线很相似,但属于不同的类别,属于分类中的异类同谱现象。

为了减少上述同类异谱与异类同谱现象,提高高光谱的分类精度,在分类时往往会加入空间信息进行分类,即空-谱联合分类。将高光谱的像元信息与空间位置上的邻域信息组合,并输入到上述构造的堆栈稀疏自动编码器中进行特征提取。因为光谱存在信息冗余,所以在对像元提取邻域空间信息时首先用主成分分析(PCA)方法对数据进行降维,保留的

主成分个数是根据数据特征进行选择的。假设保留 $K$ 个主成分进行分类实验,以当前像元 $x_0$ 为中心像元,以 $L$ 为半径提取邻域信息,邻域像元分别记为 $x_1, x_2, \dots, x_{(2L+1)^2-1}$ ,将进行主成分降维后的 $K$ 维向量分别记为 $f_0, f_1, \dots, f_N, N = (2L+1)^2 - 1$ 。根据第一主成分的大小删除邻域内与中心像元差距最大的 $q$ 个像元,并将剩余的邻域像元按第一主成分进行排序得 $f_{(1)}, f_{(2)}, \dots, f_{(N-q)}$ ,再将信息进行堆栈,操作规则如图4所示。重新排序虽然破坏了中心像元与邻域像元的局部位置关系,但该方法具有旋转不变特性<sup>[16]</sup>,因此局部特征的提取不受图像平移与旋转的影响。在实验中大约删除邻域窗口内像元总数的 $1/4$ 像元,即 $q=L \times (L+1)$ 。

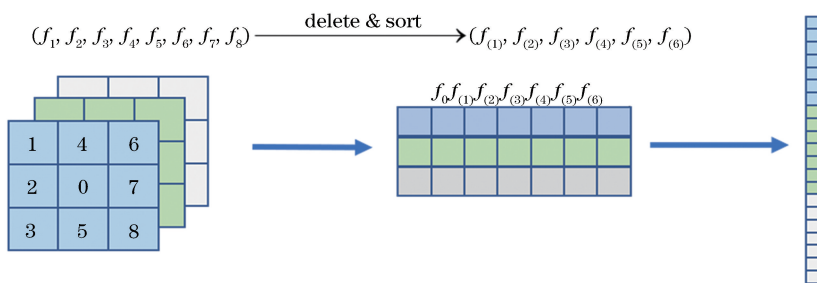


图4 基于旋转不变特性的空-谱特征提取方法

Fig. 4 Spatial-spectral feature extraction method based on rotation invariant property

图5(b)是图5(a)中方框区域放大后的图像,对高光谱图像中E、F两点的邻域信息按上述方法进行筛选;图5(c)与(d)分别为以E点与F点为中心像元的邻域信息。首先将像元数据进行归一化处理,然后采用主成分分析算法进行降维,图5(c)、(d)中标注的数值为降维后第一主成分上的信息。为了使图像数值不被未标签的黑色背景掩盖,将图5(c)、(d)两张图中的黑色背景用深灰色代替,图中标有白色字母d的区域是与中心像元差距较大且需

要被删除的像元。因为邻域大小是 $3 \times 3$ ,根据规定需要删除2个像元,图5(c)中被删除像元的恰好是两个异类像元信息,图5(d)中被删除的像元一个是异类像元,另一个是未被标记的像元。

上述结果说明此特征提取方法可以有效剔除高光谱遥感图像在成像过程中因受外界影响而形成的噪声,以及在引入空间信息时含有的异类像元信息,从而有效减少分类时因干扰信息带来的错分现象,进而提高图像的分类效果。

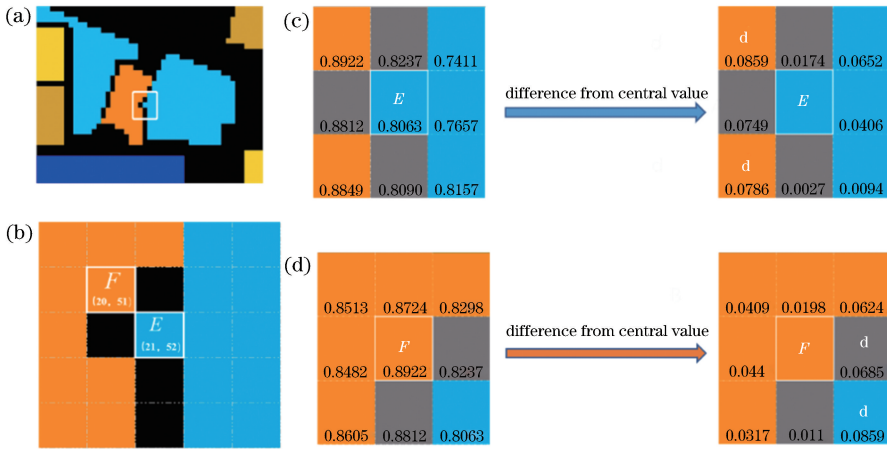


图 5 高光谱的邻域信息。(a)空间位置;(b)放大图片;(c)  $E$  点的邻域信息;(d)  $F$  点的邻域信息

Fig. 5 Hyperspectral neighborhood information. (a) Spatial position; (b) magnified picture; (c) neighborhood information of point  $E$ ; (d) neighborhood information of point  $F$

#### 4 深度学习与空-谱信息相结合的分类算法

将中心像元与基于旋转不变特性的空-谱特征

提取的邻域信息组合后输入到上述堆栈稀疏自编码网络中进行分类。图 6 给出了深度学习与空-谱信息相结合的分类算法的框架(以红色点的光谱信息为例,其中红色区域为邻域信息)。

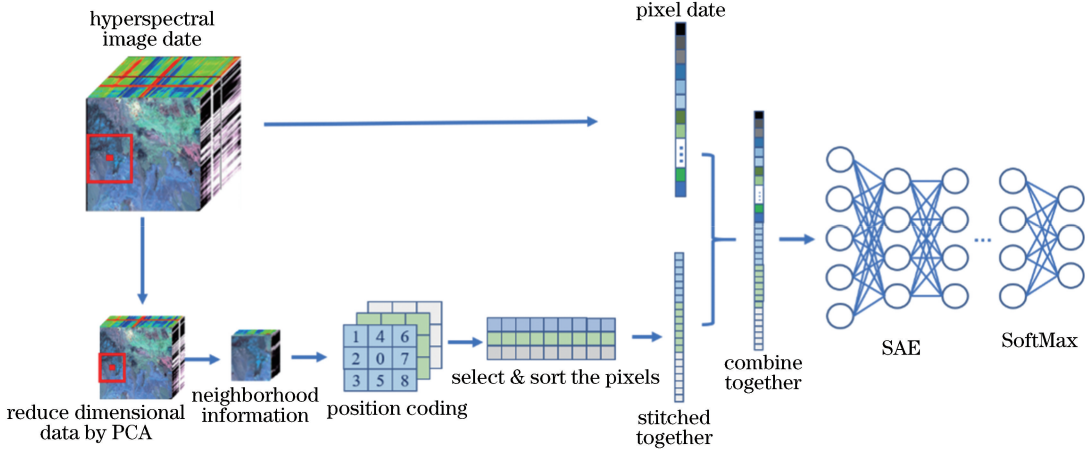


图 6 深度学习与空-谱信息相结合的分类算法的框架图

Fig. 6 Classification algorithm framework for deep learning combined with spatial-spectral information

根据深度学习与空-谱信息相结合的分类算法框架图的思想,将整个算法步骤整理如下。

步骤一:

- 1) 确定邻域半径  $L$ , 需要使用 PCA 降到的维数  $K$ ;
- 2) 用 PCA 方法对数据进行降维处理;
- 3) 得到  $(2L + 1) \times (2L + 1) \times K$  的邻域块;
- 4) 对邻域块内的像元按第一主成分信息与中心像元的差距进行删除、排序、堆栈;
- 5) 将每一个中心像元与步骤 4) 中提取的邻域信息组合在一起, 构成空-谱特征矩阵  $\mathbf{M}$ 。

步骤二:

- 1) 初始化堆栈稀疏自动编码机的权重  $\mathbf{W}_e$ 、 $\mathbf{b}_e$ 、 $\mathbf{W}_d$ 、 $\mathbf{b}_d$  以及预训练周期  $T_{pr}$ 、预训练学习率  $\eta$ 、隐藏层数量  $h$ 、每层的神经元个数  $G$ ;
- 2) 将空-谱特征矩阵  $\mathbf{M}$  输入堆栈稀疏自动编码机;
- 3) 根据目标代价函数, 对参数进行迭代更新;
- 4) 将重建好的编码器删除输出层后进行堆叠, 上一层提取的特征是下一层的输入;
- 5) 构成堆栈稀疏自动编码机;
- 6) 根据堆栈稀疏自动编码机非线性映射提取高光谱的像元特征。

步骤三:

1) 初始化分类器参数  $\theta$ 、微调周期  $f_{it}$ 、学习率  $\alpha$ 、类别数目  $N_{num}$ ;

2) 根据实验要求随机抽取提取好的高光谱信息,并将其分为训练数据集 TrainData 与测试数据集 TestData;

3) 将训练数据集 TrainData 输入到 SoftMax 分类器中进行训练,根据已知的标签类别微调整个模型参数;

4) 将测试数据集 TestData 输入到已经训练好的分类器中进行分类。

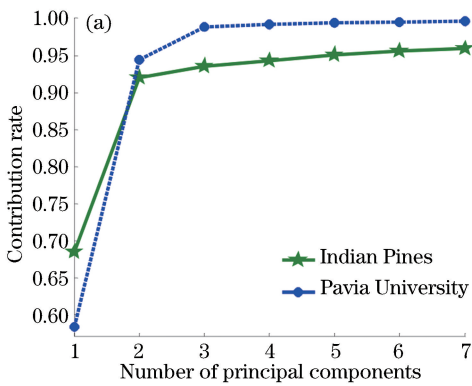
在堆栈稀疏自动编码器的参数初始化设置中,偏置  $b_e$  与  $b_d$  设为 0,权重参数的初始值是通过 Xavier 参数初始化方法<sup>[17]</sup>给出的,具体为

$$W \sim U \left[ -\frac{\sqrt{6}}{\sqrt{d+G}} \frac{\sqrt{6}}{\sqrt{d+G}} \right], \quad (19)$$

式中:  $U$  表示随机均匀分布;  $d$  和  $G$  分别为输入样本的维数与隐藏层神经元的个数。

## 5 实验结果与分析

实验数据选取 Pavia University 和 Indian Pines 地区的高光谱数据。在堆栈稀疏自动编码网络参数设置中选用了 2 个隐藏层,稀疏正则约束参数



$\beta=3$ , 权重衰减参数  $\lambda=3 \times 10^{-4}$ , 稀疏参数  $\rho=0.06$ , 迭代次数最大为 1000。将在空间信息提取时对邻域信息的排序、删除、重组和堆栈这一系列操作简称为对空间邻域信息的筛选。本文结果为算法进行 10 次实验后的均值,基于 Kappa 系数与整体分类精度(OA)这两个指标将本文算法(筛选前和筛选后)与 SVM 算法、CK-SVM 算法、OMP (Orthogonal Matching Pursuit) 算法、SOMP (Simultaneous Orthogonal Matching Pursuit) 算法进行对比。

### 5.1 主成分数量以及窗口大小的选取

在空-谱特征提取的主成分分析降维过程中,根据图 7 所示的 95% 的累计贡献率,将 Pavia University 和 Indian Pines 地区数据的主成分数目分别设为 4 和 6。图 7(b)为窗口大小对 OA 的影响,可以看到:Pavia University 地区数据的 OA 随着邻域窗口的增大呈逐渐增大的趋势,但增长速度越来越慢;Indian Pines 地区数据的 OA 随着邻域窗口逐渐增大呈先增加后减小的趋势,当窗口为  $9 \times 9$  时,OA 达到最大。由此可得:当窗口较小时,空间特征不够充分,导致 OA 较低;而当窗口较大时,则容易增加异类像元,使 OA 降低,因此本研究的邻域窗口设为  $9 \times 9$ 。

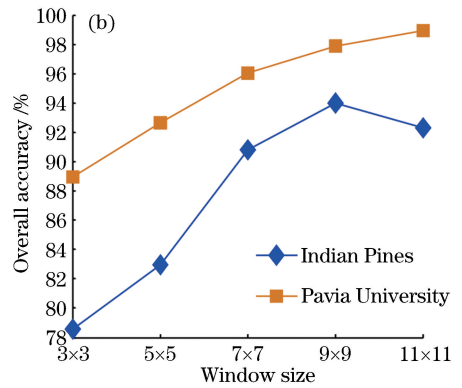


图 7 参数的选择。(a)主成分数目的选择;(b)窗口大小的选择

Fig. 7 Selection of parameters. (a) Selection of number of principal components; (b) selection of window size

### 5.2 实验一

在实验一中,Pavia University 遥感图像数据的大小为  $610 \text{ pixel} \times 340 \text{ pixel}$ ,空间分辨率为 1.3 m,谱段为  $0.43 \sim 0.86 \mu\text{m}$ ,使用保留的 103 个光谱波段进行实验。本组数据共有 9 类样本,但每类样本的个数差距很大,若按比例抽取,样本多的数据分类结果会影响样本少的分类结果,因此,本组实验从每类数据中抽取 200 个训练样本,但是抽取的总的训练样本不超总数的 10%,剩余的作为测试样本。表 1 给出了各类样本在不同算法下的实

验数据与分类精度,且最优的分类结果用粗体标出。图 8 为不同算法下 Pavia University 地区的分类结果图。

### 5.3 实验二

在实验二中,Indian Pines 遥感图像数据的大小为  $145 \text{ pixel} \times 145 \text{ pixel}$ ,空间分辨率为 20 m,谱段为  $0.4 \sim 2.5 \mu\text{m}$ 。实验中使用的数据为原始的 220 个波段的高光谱数据,训练样本选取每种样本的 10%,其余的 90%用于测试。表 2 为 Indian Pines 地区数据在各算法下的 OA 和 Kappa 系数,最优的

表 1 Pavia University 地区的实验数据与分类精度

Table 1 Experimental data and classification accuracy of the Pavia University dataset

Class	Number of samples		Classification accuracy / %					
	Train	Test	SVM	CK-SVM	OMP	SOMP	Our method (unselect)	Our method
Asphalt	200	6431	80.50	97.90	61.20	82.11	93.11	<b>98.10</b>
Meadows	200	18449	84.48	<b>98.95</b>	79.47	95.50	96.11	97.32
Gravel	200	1899	78.91	93.77	68.01	<b>98.11</b>	95.22	97.17
Trees	200	2864	96.24	98.96	91.95	96.24	93.74	<b>99.35</b>
Painted metal sheets	200	1145	99.74	<b>100.00</b>	99.22	99.06	<b>100.00</b>	<b>100.00</b>
Bare soil	200	4829	83.96	97.06	69.84	98.55	96.91	<b>99.28</b>
Bitumen	200	1130	91.39	<b>99.56</b>	84.39	98.34	98.81	99.51
Self-blocking bricks	200	3482	81.27	<b>96.45</b>	76.52	94.90	96.39	96.43
Shadows	200	747	98.44	99.87	98.04	88.44	97.99	<b>100.00</b>
OA / %			84.98	<b>98.16</b>	76.60	93.93	95.88	<b>97.87</b>
Kappa			0.80	<b>0.98</b>	0.70	0.92	0.94	<b>0.97</b>

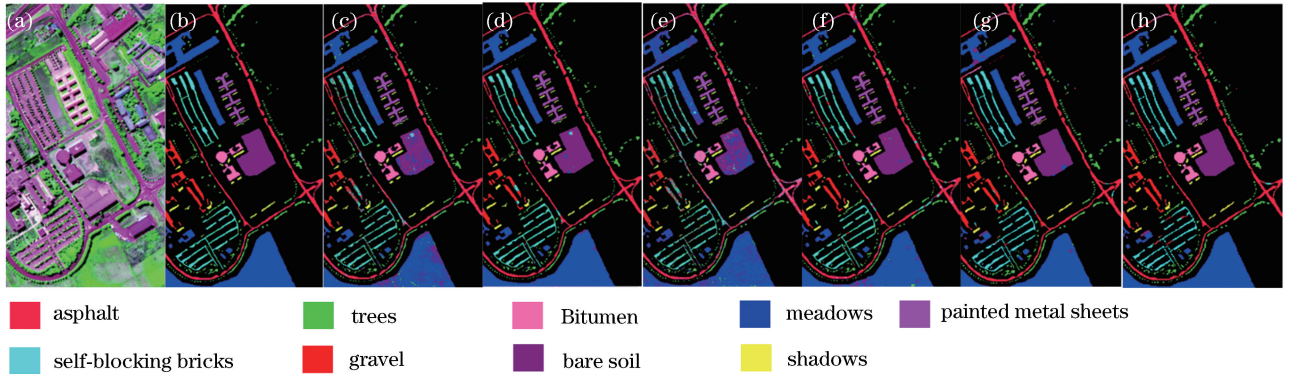


图 8 Pavia University 地区在各算法下的分类结果。(a)原图;(b)实际分类图;(c) SVM;(d) CK-SVM; (e) OMP;(f) SOMP;(g)所提方法(未筛选);(h)所提方法

Fig. 8 Classification results of Pavia University dataset obtained by different algorithms. (a) Original image; (b) true classification picture; (c) SVM; (d) CK-SVM; (e) OMP; (f) SOMP; (g) proposed method (unselect); (h) proposed method

表 2 Indian Pines 地区数据在各算法下的 OA 和 Kappa 系数

Table 2 OA and Kappa coefficient of the Indian Pines dataset obtained by different algorithms

Parameter	Classification algorithm					
	SVM	CK-SVM	OMP	SOMP	Our method (unselect)	Our method
OA / %	73.01	91.36	65.87	91.46	90.18	<b>93.99</b>
Kappa coefficient	0.69	0.90	0.61	0.90	0.89	<b>0.93</b>

分类结果用粗体标出。图 9 为在不同算法下 Indian Pines 地区的分类结果图。

### 5.4 实验结果分析

实验结果表明:仅利用光谱信息进行分类的 SVM 与 OMP 算法,分类结果中被错分的样本点较多;在结合光谱中加入空间信息后的 CK-SVM 与 SOMP 算法比只考虑光谱信息的 SVM 与 OMP 算法的分类精度明显提高了 13%和 17%,说明空间信息的加入大幅提高了分类精度。堆栈稀疏自编码网络融合了光谱与空间信息,并对空间邻域信息进行了选择和排序,使得 Pavia University 地区的 OA

提高了将近 2%,且各类的分类精度均有明显提高,同时使 Indian Pines 地区的 OA 提高了将近 4%,说明空间信息的筛选提高了高光谱遥感图像分类的 OA。在实验二中,本文算法比 CK-SVM 算法的精确度提高 2%左右;在实验一中,虽然 CK-SVM 算法的 OA 稍高于本文算法,但本文算法对各类的分类精度优于 CK-SVM 算法。例如,两种算法在 Painted metal sheets 上的分类精度相同,在 Bitumen 和 Self-blocking bricks 上的分类精度差距很小,而对于其他地物,所提算法的分类精度明显优于 CK-SVM 算法。在高光谱图像分类中,受光谱信



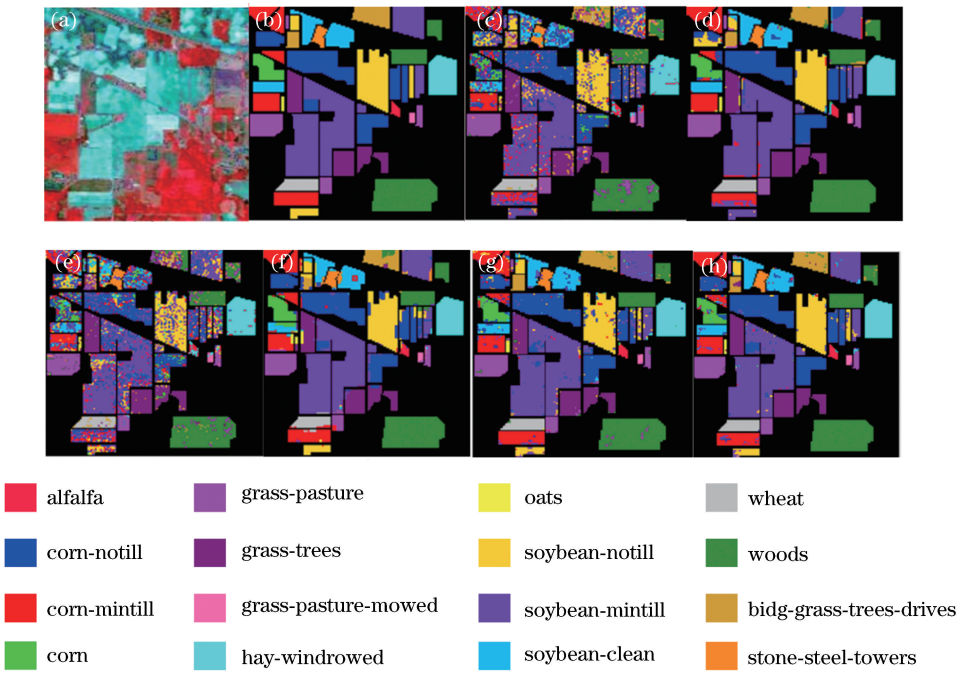


图9 Indian Pines 地区在各算法下的分类结果。(a)原图;(b)实际分类图;(c) SVM;(d) CK-SVM;(e) OMP;(f) SOMP;(g)所提方法(未筛选);(h)所提方法

Fig. 9 Classification results of Indian Pines dataset obtained by different algorithms. (a) Original image; (b) true classification picture; (c) SVM; (d) CK-SVM; (e) OMP; (f) SOMP; (g) proposed method (unselect); (h) proposed method

息相似度、噪声以及两个地区空间特征的影响,容易导致各类的分类精度存在差异,但综合比较后认为本文算法的分类效果最好。综上所述,本文所提的基于深度学习的空-谱信息分类算法可以有效剔除分类中的干扰信息,减少图像分类中像元被错误分

类的现象,改善了高光谱遥感图像的分类效果。

此外,本研究还在不同样本数量下对各算法进行了测试,实验结果表明,增加训练样本数量后,各个算法的分类精度也随之提高。图10所示为训练样本在不同数量与比例下的实验结果。

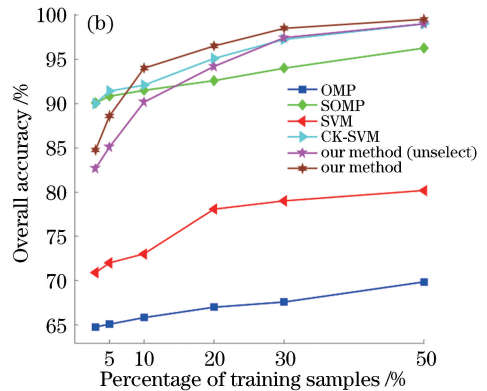



图10 训练样本数量对不同地区实验数据 OA 的影响。(a) Pavia University;(b) Indian Pines

Fig. 10 Effect of number of training samples on overall accuracy of different datasets. (a) Pavia University; (b) Indian Pines

## 6 结 论

根据高光谱遥感图像的分类问题,提出了基于堆栈自编码网络与空-谱信息相结合的分类算法。该算法在堆栈稀疏自动编码网络中加入了权重衰减

项,并在引入空间信息时删除了与中心元素差距大的部分像元信息后,对空间信息进行排序。将该算法与其他分类算法进行对比后发现,该算法不仅提高了 OA,而且减少了样本被错分的现象,使图像分类效果更加平滑。

## 参 考 文 献

- [1] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning [J]. *Acta Optica Sinica*, 2016, 36 (4): 0428001.  
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究 [J]. *光学学报*, 2016, 36 (4): 0428001.
- [2] Ji R R, Gao Y, Hong R C, *et al.* Spectral-spatial constraint hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(3): 1811-1824.
- [3] Pal M, Foody G M. Feature selection for classification of hyperspectral data by SVM[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(5): 2297-2307.
- [4] Fang L Y, Li S T, Kang X D, *et al.* Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(12): 7738-7749.
- [5] Zhang H Y, Li J Y, Huang Y C, *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*, 2014, 7(6): 2056-2065.
- [6] Fang L Y, Li S T, Kang X D, *et al.* Spectral-spatial classification of hyperspectral images with a superpixel-based discriminative sparse model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(8): 4186-4201.
- [7] Zhou Y C, Peng J T, Chen C L P. Extreme learning machine with composite kernels for hyperspectral image classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2351-2360.
- [8] Zhang H, Chen C H. Aurora sequence classification based on deep learning[J]. *Laser & Optoelectronics Progress*, 2018, 55(11): 111504.  
张浩, 陈昌红. 基于深度学习的极光序列自动分类方法[J]. *激光与光电子学进展*, 2018, 55 (11): 111504.
- [9] Chen Y S, Lin Z H, 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] Zhong P, Gong Z Q, Li S T, *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.
- [11] Chen Y S, Zhao X, Jia X P. 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.
- [12] Chen Y S, Jiang H L, Li C Y, *et al.* Deep feature extraction and classification of hyperspectral images based on convolutional neural networks [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 6232-6251.
- [13] Bioucas-Dias J M, Plaza A, Dobigeon N, *et al.* Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5 (2): 354-379.
- [14] Tao C, Pan H B, Li Y S, *et al.* Unsupervised spectral-spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(12): 2438-2442.
- [15] Dong A G, Li J X, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation [J]. *Acta Optica Sinica*, 2017, 37(8): 0828005.  
董安国, 李佳逊, 张蓓, 等. 基于谱聚类和稀疏表示的高光谱图像分类算法 [J]. *光学学报*, 2017, 37 (8): 0828005.
- [16] Tao C, Tang Y Q, Fan C, *et al.* Hyperspectral imagery classification based on rotation-invariant spectral-spatial feature [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(5): 980-984.
- [17] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks [C] // *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics*, June 6-10, 2011, Pittsburgh, Pennsylvania. Cambridge: PMLR, 2011: 249-256.