

# 基于深度学习的高光谱图像多标签分类算法

刘玉华<sup>1</sup>, 陈建国<sup>1,2</sup>

(1.福建工程学院 应用技术学院, 福建 福州 350003;

2.湖南大学 信息科学与工程学院, 湖南 长沙 410082)

**摘要:** 提出一种基于深度学习的高光谱图像多标签分类算法。采用深度学习算法中的堆叠降噪自动编码器方法对每个像素的深层特征进行抽取,该方法可以有效表现高维特征空间中的非线性混合像素。使用多标签逻辑回归方法为每个像素预测并分配多个类标签。通过对合成数据和实际高光谱数据的大量对比实验,实验结果表明:该算法能够有效地为高光谱图像的像素精确地分配多类标签。

**关键词:** 图像分类; 高光谱图像; 深度学习; 自动编码器; 逻辑回归

中图分类号: TP311.1

文献标志码: A

文章编号: 1672-4348(2018)03-0264-07

## A multi-label classification algorithm for hyperspectral image based on deep learning

LIU Yuhua<sup>1</sup>, CHEN Jianguo<sup>1,2</sup>

(1.Institute of Applied Technology, Fujian University of Technology, Fuzhou 350003, China;

2.College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China)

**Abstract:** A multi-label classification algorithm was proposed for hyperspectral images based on deep learning. The deep features of each pixel were extracted by the Stacked Denoising Auto-Encoder (SDAE) method of deep learning, which could effectively represent the nonlinear mixed pixels in a high-dimensional feature space. In addition, a multi-label logical regression method was used to predict and assign multiple class labels for each pixel. The experimental results on the synthetic and actual hyperspectral image datasets show that the proposed algorithm can accurately assign multiple class labels to the pixels of hyperspectral images.

**Keywords:** image classification; hyperspectral image; deep learning; automatic encoder; logic regression.

高光谱图像是指包含空间和光谱信息的三维数据集。其中,空间信息反映了物体的大小、形状和其他外部质量特征,光谱信息则提供对物体的额外辨别信息。高光谱图像分析广泛应用于物体识别、灾害预警、环境监测、资源勘探与考古等实际应用中<sup>[1]</sup>。高光谱图像分类旨在为每个像素分配类标签。迄今为止,国内外学者已经提出许多高光谱图像分类算法<sup>[2]</sup>。K近邻算法(K-Nearest Neighbors, KNN)<sup>[3]</sup>是一种简单有效的数据挖掘算法,被广泛应用于各种实际应用的数

据分类问题中。在KNN算法中,如果一个像素点的大部分邻居都属于某一类别,则将该像素点也分配给这个类别。此外,支持向量机(Support Vector Machine, SVM)<sup>[4]</sup>通过定义分类边界来解决线性可分离问题。如果像素数据是线性不可分离的,则将输入向量映射到具有预定义核函数的高维特征空间,然后在高维特征空间中构造一个最优超平面。近些年,深度神经网络(Deep Neural Networks, DNN)算法<sup>[5-7]</sup>也被广泛应用于图像分类中。深度学习可以通过学习图像数据的深层特征

收稿日期: 2017-10-28; 修回日期: 2018-04-16

基金项目: 湖南省研究生科研创新项目(CX2017B099)

第一作者简介: 刘玉华(1985-),女,福建福州人,助教,硕士研究生,研究方向:软件开发、数据挖掘。

来更好地反映数据的非线性,从而获取更精确的分类结果。针对多标签特征分类,目前许多学者提出了多标签 CNN 算法并使用到场景分类和图像标注等实验应用中<sup>[8-10]</sup>。但 CNN 算法属于有监督算法,大规模的参数训练容易造成过拟合现象。而且由于高光谱图像数据中往往含有混合像素(例如,从低空间分辨率卫星采集得到的高光谱图像),并且原始采集的图像数据含有不同程度的噪声数据,现有监督分类算法无法对这些图像数据进行精确分类。

为了更好地剖析高光谱图像数据的拍摄场景和成像过程,本文提出一种基于深度学习的高光谱图像多标签分类算法。首先,通过堆叠降噪自动编码器方法提取图像像素的深层特征。然后通过多标签逻辑回归方法获得每个像素的多个标签。该算法能够充分利用混合像素中固有的多标签信息,精确地为高光谱图像数据进行分类。

## 1 高光谱图像多标签分类算法

### 1.1 深层特征提取方法

作为深度学习的最常见算法,自动编码器(Auto-Encoder, AE)<sup>[11]</sup>将神经网络的隐含层当作一个编码器和解码器,输入数据经过隐含层的编码和解码,到达输出层时,确保输出的结果尽量与输入数据保持一致。换言之,神经网络的隐含层是尽量保证输出数据等于输入数据的。输入数据和输出数据之间的重建误差用于调整每一层的权重。降噪自动编码器(Denoising Auto-Encoder, DAE)通过对输入数据进行随机擦除,将加工后的数据映射到隐含层进行表示并重构<sup>[12-14]</sup>。因此,降噪自动编码器可以在一定程度上降低输入数据的噪声。堆叠降噪自动编码器(Stacked Denoising Auto-Encoder, SDAE)<sup>[15-16]</sup>是一种深层神经网络,由 DAE 通过堆叠而成,具有多个隐含层,对各个参数进行逐层评估。

与传统的基于人工规则的特征提取算法相比,SDAE 算法突出了特征学习的重要性,通过逐层特征变换,将样本在原始空间的特征表示变换到新的特征空间中,从而使特征分类更加容易。通过大规模训练数据对特征进行学习,SDAE 算法更能够表示特征数据的丰富内在信息。同时,SDAE 算法对含噪数据的分类更具有鲁棒性,能够有效训练含有不同噪声程度的原始数据。

SDAE 算法可以在不对原始数据预处理的情况下直接接受数据特征,并得到高精确度的特征提取结果。而且,随着训练数据的增加和训练网络规模的扩大,SDAE 算法的精确度能够得到显著提升。由于 SDAE 能够有效表示复杂非线性特征,因此,本文采用 SDAE 提取高光谱图像的深度特征,用于生成高光谱图像数据的混合像素多标签信息。给定一个高光谱图像原始数据集,首先需要对原始图像进行分层处理,提出各个单层图像数据。接着对单层图像数据进行像素化处理,提取各个像素数据。在此基础上,使用 SDAE 网络对各个像素数据进行特征编码。假设 SDAE 中的编码部分中有  $K$  个隐含层。SDAE 网络的一级 DAE 包括第一特征编码层和最后的特征解码层。第  $i$  级编码层的编码函数定义如下:

$$y^{(i+1)} = f_e(\mathbf{W}^{(i+1)}y^{(i)} + \mathbf{b}^{(i+1)}) \quad (1)$$

其中,  $i = (0, \dots, K-1)$ ,  $y^{(0)}$  是原始输入数据  $X$ ,  $y^{(K)}$  是最后一个输出,也就是由 SDAE 网络提取的深层特征。 $y^{(1)}$  表示训练的特征,  $\vartheta^{(1)} = \{\mathbf{W}^{(1)}, \mathbf{b}^{(1)}\}$  表示第 1 级 DAE 网络的权重,  $\mathbf{b}^{(1)}$  是一个  $d'$  维向量,  $\mathbf{W}^{(1)}$  则是一个  $d' \times d$  维的权重矩阵。基于 SDAE 的高光谱图像特征编码过程如图 1 所示。

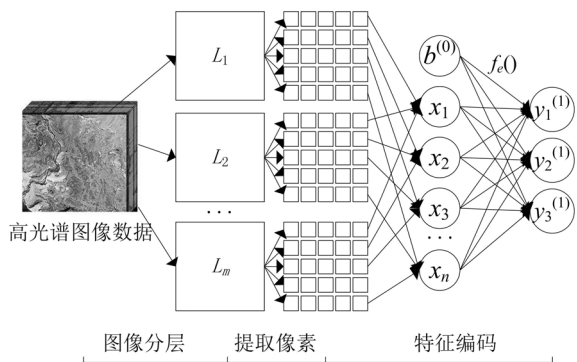


图1 基于 SDAE 的高光谱图像特征编码过程

Fig.1 SDAE-based feature encoding for hyper-spectral images

在解码部分,第  $i+1$  个解码层的输入是第  $i$  个解码层的输出。第  $i$  级解码层的解码函数定义如下:

$$z^{(i+1)} = f_d(\mathbf{W}^{(K-i)}z^{(i)} + \mathbf{b}^{(i+1)}) \quad (2)$$

其中,  $i = (0, \dots, K-1)$ ,  $z^{(0)}$  是解码器的输入,也是最后一个编码层的输出  $y^{(K)}$ 。而最后一层的输

出  $z^{(K)}$  就是原始输入数据  $X$  的重构。

接着,对第 2 级 DAE 网络进行训练,如图 2 所示。输入数据  $x$  通过随机映射被加工成  $\tilde{x}$ 。然后将加工的数据  $\tilde{x}$  编码为  $z$ ,即为经过训练得到的第 2 层特征,  $\vartheta^2 = \{W^{(2)}, b^{(2)}\}$  表示第 2 级 DAE 网络的权重。重复执行该过程,直到获得所有的特征(共有  $K$  级)。




图 2 基于 SDAE 的高光谱图像特征训练过程

Fig.2 SDAE-based feature training for hyper-spectral images

在对原始输入数据进行多层编码和解码操作之后,得到恢复特征  $z^{(K)}$ 。训练网络的目的在于该恢复特征  $z^{(K)}$  可能逼近原始输入数据  $x$ 。使用损失函数  $L(x, z^{(K)})$  表示恢复特征与原始输入数据之间的误差,取所有输出层节点的误差平方和作为损失函数,计算公式如下:

$$L(x, z^{(K)}) = L(X, f_d(f_e(x))) = \sum_{j=1}^m (z_j^{(K)} - x_j)^2 \quad (3)$$

接着,使用随机梯度下降算法对损失函数进行优化。即从特征解码层的输出层开始,反向逐层求出误差函数  $L(z^{(i)}, z^{(i+1)})$  对于每一层(第  $i$  层)的每个权重  $w_j^{(i)}$  的偏导数。权重  $w_j^{(i)}$  的损失函数计算过程如下:

$$\begin{aligned} \frac{\partial L(z^{(i)}, z^{(i+1)})}{\partial w_j^{(i)}} &= \frac{\partial L(z^{(i)}, z^{(i+1)})}{\partial \sum_j w_j^{(i)} z_j^{(i)}} \times \frac{\partial (\sum_j w_j^{(i)} z_j^{(i)})}{\partial w_j^{(i)}} = \\ &= \frac{\partial L(z^{(i)}, z^{(i+1)})}{\partial \sum_j w_j^{(i)} z_j^{(i)}} \times z_j^{(i)} = \\ &= \frac{\partial \sum_{j=1}^m (z_j^{(i+1)} - z_j^{(i)})^2}{\partial \sum_j w_j^{(i)} z_j^{(i)}} \times z_j^{(i)} = \\ &= -z_j^{(i+1)} (1 - z_j^{(i+1)}) \sum_{q \in I(i+1)} \frac{\partial L(z^{(i)}, z^{(i+1)})}{\partial w_q^{(i+1)}} w_q \end{aligned} \quad (4)$$

如果令  $\varphi_j = -\frac{\partial L(z^{(i)}, z^{(i+1)})}{\partial w_j^{(i)}}$ ,也就是一个输出节点的误差项  $\varphi$  是 SDAE 训练网络误差对该节点输入的偏导数的相反数。得到权重更新公式如下:

$$w_j^{(i)} = w_j^{(i)} - \eta \varphi_j. \quad (5)$$

通过对大量数据进行迭代训练,并更新 SDAE 的特征编码层和特征解码支的网络权重参数,直到权重梯度稳定,此时便可以得到具有高精确度的 SDAE 训练网络模型。此时就可以使用该 SDAE 训练网络模型对高光谱图像数据进行深度特征提取。

## 1.2 多标签逻辑回归

在提取深度特征之后,接下来使用对高光谱图像数据中的每个混合像素进行预测多个类标签。逻辑回归(Logistic regression, LR)是一种非线性模型的分类方法,它根据影响因素来预测某一事物的发生概率<sup>[17]</sup>。本文使用逻辑回归方法对高光谱图像数据中的混合像素进行多标签分类。

首先,将深度学习的激活函数-Sigmoid 函数定义为逻辑回归方法的假设函数,定义如下:

$$S_\theta(x) = \frac{1}{1 + \exp(-W'x - b')} \quad (6)$$

其中,  $\vartheta = \{W', b'\}$ ,输入  $x$  是从 SDAE 网络提取提到的深度特征,输出  $s_\theta(x)$  就是像素的分类结果。

接着,对于二进制分类问题,选择对数似然损失函数作为逻辑回归成本函数,定义如下:

$$C(s_{\vartheta}(x), l) = \begin{cases} -\log(s_{\vartheta}(x)) & l = 1 \\ -\log(1 - s_{\vartheta}(x)) & l = 0 \end{cases} \quad (7)$$

如果  $l=1$ , 则  $s_{\vartheta}(x) = 1$ ,  $C(s_{\vartheta}(x), l) = 0$ , 表示预测值与真实值完全相同; 如果  $s_{\vartheta}(x) \rightarrow 0$ , 则  $C(s_{\vartheta}(x), l) \rightarrow \infty$ , 表示预测误差较大; 如果  $s_{\vartheta}(x) = 0$ , 那么  $P(l=1|x; \vartheta)$ , 则逻辑回归成本很大。因此, 可以合并公式如下:

$$J(\vartheta) = \frac{1}{m} \sum_{i=1}^m C(s_{\vartheta}(x^{(i)}), l^{(i)}) \quad (8)$$

其中,  $l^{(i)}$  表示像素  $x^{(i)}$  的类标签。当  $J^{(\vartheta)}$  函数最小时, 可以得到最小回归参数  $\min_{\vartheta} J(\vartheta)$ 。该最小函数可以通过梯度下降法, 共轭梯度法等进行优化。

可以将高光谱图像数据的多标签分类问题看作是多重二进制分类问题。对于每个类, 通过训练逻辑回归分类器  $s_{\vartheta}^{(i)}(x)$  来预测  $l=i$  的概率。对于每一个新的输入像素数据  $x$ , 如果预测概率大于某个阈值  $\delta$ , 则该类别  $y$  就是分类结果之一。表示如下:

$$s_{\vartheta}^{(i)}(x) > \delta. \quad (9)$$

### 1.3 多标签分类算法描述

在 SDAE 网络中, 由于每个 DAE 编码器分开训练, 因此整个训练过程是分层次串行执行的。经过训练后, 通过重构学习获得整个网络的权重和深度特征。为了实现像素数据的多标签分类, 使用多标签逻辑回归分类器。标签信息仅用于多标签逻辑回归阶段。本文所提出的高光谱图像数据多标签分类算法如图 3 所示。

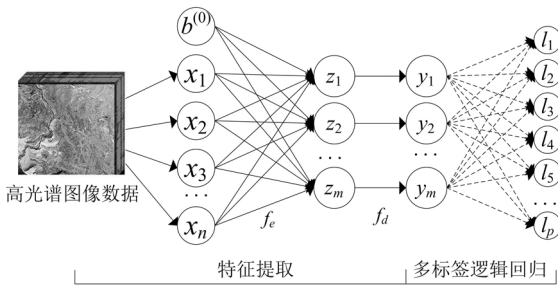


图3 高光谱图像数据多标签分类过程

Fig.3 Multi-label classification of hyperspectral images

算法描述如下:

算法 1: 基于深度学习的高光谱图像数据多

### 标签分类算法

输入:

$K$ : 堆叠降噪自动编码器网络层数量;

$n[d]$ : 每一个隐含层的单元数量;

$D$ : 用于训练的高光谱图像数据;

Labels: 训练标签;

$X$ : 用于测试的高光谱图像数据;

$\delta$ : 逻辑回归分类器阈值。

输出:

$Y$ : 多标签分类结果。

1. 加载训练数据  $D$  和训练标签 Labels;

2. 初始化堆叠降噪自动编码器;

3. for( $i=0$ ;  $i < K$ ;  $i++$ );

4. 特征编码  $y^{(i+1)} = f_e(\mathbf{W}^{(i+1)} y^{(i)} + \mathbf{b}^{(i+1)})$ ;

5. 特征解码  $z^{(i+1)} = f_d(\mathbf{W}^{(K-i)T} z^{(i)} + \mathbf{b}^{(i+1)})$ ;

6. end for;

7. 得到深度特征  $y^{(K)}$  及网络权重  $\vartheta$ ;

8. 加载测试数据  $X$ ;

9. for each  $x$  in  $X$ ;

10. 计算假设函数  $h_{\vartheta}(x) = \frac{1}{1 + \exp(-W'x - b')}$ ;

11. 计算成本函数  $C(h_{\vartheta}(x), y)$ ;

12. 标签预测  $J(\vartheta) = \frac{1}{m} \sum_{i=1}^m C(h_{\vartheta}(x^{(i)}), y^{(i)})$ ;

13. if ( $h_{\vartheta}^{(i)}(x) > \delta$ ) then;

14. 将  $y^{(i)}$  加入类标签集合  $Y \leftarrow y^{(i)}$ ;

15. end if;

16. end for;

17. 返回类标签集合  $Y$ 。

## 2 实验分析

为了验证本文所提出的算法有效性和性能, 分别使用 3 种数据集对所提出的算法进行实验, 分别包括合成数据集、实际数据集和降采样数据集。并选择卷积神经网络 (Convolutional Neural Network, CNN) 算法进行比较。

在实验中, 将高光谱图像数据集根据 1:15 的比例进行随机抽样, 分为训练数据集和测试数据集。堆叠降噪自动编码器网络的隐含层的数量由 3 逐步增加到 8, 每个隐含层中的单元数量为 100。

### 2.1 评估方法

高光谱图像多标签分类的评价标准与文献 [11] 类似。  $T = \{(x_i, Y_i) \mid 1 \leq i \leq p\}$  表示多标

签测试集,其中  $p$  是类别数。对于第  $j$  个类别  $L_j(1 \leq j \leq p)$ ,  $h(x_i)$  是预测标签。4 个评估指标定义如下:

$$\begin{aligned} TP_j &= |\{x_i \mid y_j \in Y_i \wedge y_i \in h(x_i), (x_i, Y_i) \in S\}| \\ FP_j &= |\{x_i \mid y_j \notin Y_i \wedge y_i \in h(x_i), (x_i, Y_i) \in S\}| \\ TN_j &= |\{x_i \mid y_j \notin Y_i \wedge y_i \notin h(x_i), (x_i, Y_i) \in S\}| \\ FN_j &= |\{x_i \mid y_j \in Y_i \wedge y_i \notin h(x_i), (x_i, Y_i) \in S\}| \end{aligned} \quad (10)$$

其中  $TP_j$ ,  $FP_j$ ,  $TN_j$  和  $FN_j$  分别表示真阳性,假阳性,真阴性和假阴性。可以看出,  $TP_j + FP_j + TN_j + FN_j = p$ 。根据这 4 个指标,可以定义多标签分类的 3 个评估方法如下:

$$\text{Accuracy} = \frac{TP_j + TN_j}{TP_j + TN_j + FP_j + FN_j} \quad (11)$$

$$\text{Precision} = \frac{TP_j}{TP_j + FP_j} \quad (12)$$

$$\text{Recall} = \frac{TP_j}{TP_j + FN_j} \quad (13)$$

## 2.2 合成数据集分析

选用西班牙巴斯克大学的高光谱图像公共数据库<sup>[18]</sup>中选择 3 组高光谱图像数据集,分别是 Indian\_pine、Salinas 和 Pavia。并通过将纯像素数据插入这些数据集,进一步合成纯像素单标签数据,分别如图 4(a)(c)(e)所示。在合成混合像素数据时,根据距离  $d$  对各个像素点  $x_i$  的最近邻居点中的类别  $l$  进行计数,如果  $l > 1$ ,将像素点  $x_i$  合成为混合像素点  $x_i'$ 。然后根据 GIS 数据将混合像素点  $x_i'$  插入数据集合成混合像素多标签数据,分别如图 4(b)(d)(f)所示。

对 3 个合成数据集 Indian\_pine、Salinas 和 Pavia 的实验中,混合像素数据的混合比例为 11.82%。纯像素单标签数据和混合像素单标签数据都使用相同的类别标签。混合像素单标签数据和混合像素多标签数据则使用不同的类别标签。分别使用 SDAE 算法和多标签 CNN 算法对这 3 个合成高光谱数据集进行像素标签分类,计算算法在每个数据集上的正确率的平均值并进行对比。合成高光谱数据的标签分类正确率和召回率对比结果分别如图 5、图 6 所示。

从图 5、图 6 可以看出,纯像素单标签数据和混合像素单标签数据之间的实验结果验证了当单个标签数据中存在混合像素时,分类正确率将会

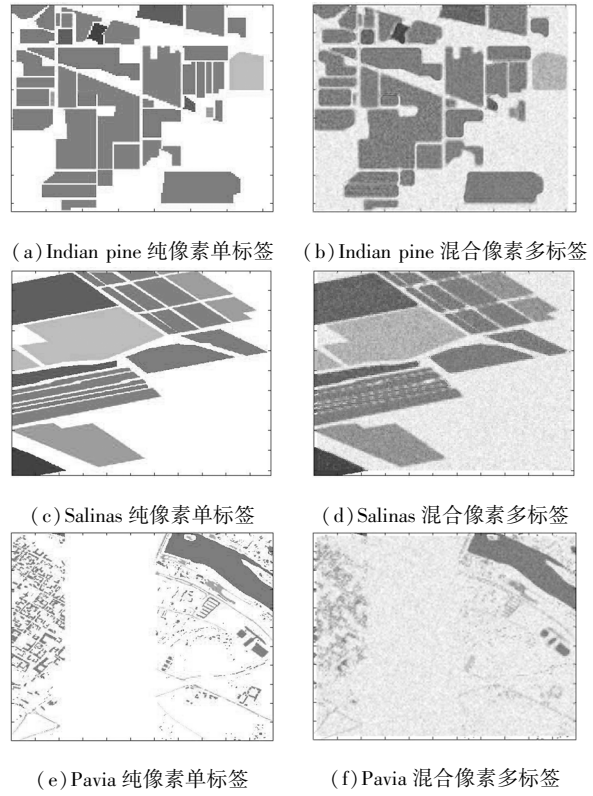


图 4 合成高光谱图像数据集

Fig.4 Synthesized hyperspectral image datasets

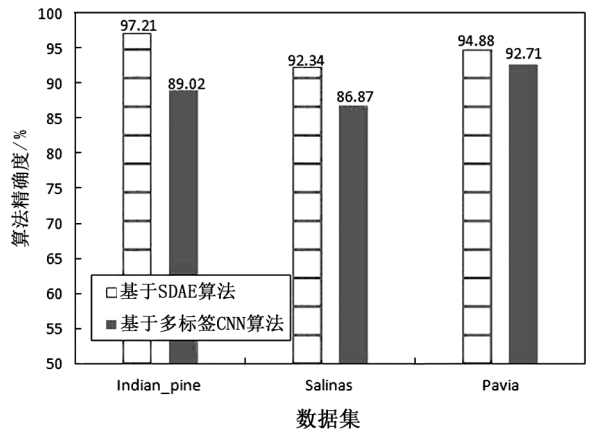


图 5 合成高光谱图像数据标签分类正确率对比

Fig.5 Accuracy comparison of label classification of synthesized hyperspectral image datasets

降低。混合像素多标签数据的分类结果在精确度等方面都高于混合像素单标签数据。因此,实验结果表示为混合像素分配多个标签可以提高高光谱图像数据的分类性能。此外,通过比较本文所提出的基于 SDAE 算法与 CNN 算法之间的分类正确性和召回率,SDAE 算法可以得到比 CNN 算法更好的分类效果。




图 6 合成高光谱图像数据标签分类召回率对比

Fig.6 Recall rate comparison of label classification of synthesized hyperspectral image datasets

### 2.3 真实高光谱图像数据集分析

本实验中数据集来自于美国普渡大学<sup>[19]</sup>的高光谱图像公共数据库公共地理数据库,空间分辨率为 30 m,如图 7(a)所示。由于缺乏真正的高光谱图像多标签数据,本文使用频谱解混合方法来分配混合像素多标签。根据距离  $d$  来计算每个像素点  $x$  的最近邻居中的类别  $l$ ,为  $x_i$  找到对应的类别。图 7(d)为丰度系数,即阈值  $\delta$ 。最后,使用多标签向量替换原有的单标签,如图 7(c)所示。高光谱图像多标签的生成参数见表 1。

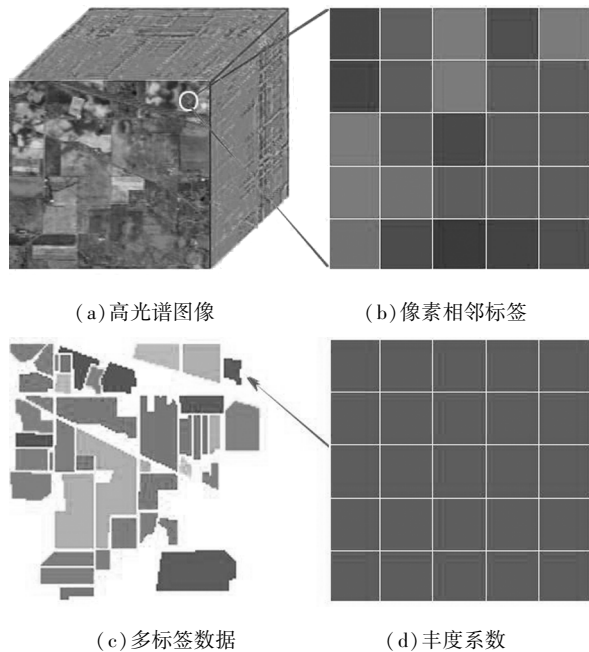


图 7 高光谱图像数据生成多标签数据

Fig.7 Multi-label dataset generated from hyperspectral image dataset

分别使用 SDAE 算法和多标签 CNN 算法对真实高光谱数据集进行像素标签分类,计算各算法在每个数据集上的正确率的平均值并进行对比。实验结果见表 2。

表 1 高光谱图像多标签的生成参数

Tab.1 Multi-label generation parameters of hyperspectral images

单标签	丰度系数	阈值	多标签
0	0		0
0	0.52		1
1	0.02	$H \geq \delta$	1
0	0		0
0	0.01		0

表 2 真实高光谱图像数据标签分类结果对比

Tab.2 Comparison of label classification results of real hyperspectral image datasets

算法	SDAE	多标签 CNN
Accuracy	97.13	90.31
Precision	83.49	76.24
Recall	70.21	61.29

### 2.4 真实高光谱图像数据集分析

为了确保真实的高光谱图像数据中含有混合像素,特别是那些具有高空间分辨率的机载信号,对真实的高光谱图像数据进行降采样以产生混合像素。数据集由英国曼彻斯特大学高光谱图像数据库提供<sup>[20]</sup>,其空间分辨率为 0.8 m。降采样数据的多标签由原始单标签组成。降采样数据效果如图 8 所示。



图 8 真实高光谱图像数据降采样

Fig.8 Down-sampling of real hyperspectral image datasets

分别使用 SDAE 算法和多标签 CNN 算法对降采样高光谱数据集进行像素标签分类,计算各算法在每个数据集上的正确率的平均值并进行对比。实验结果见表 3。

表 3 降采样高光谱数据标签分类结果对比

Tab. 3 Comparison of label classification results of down-sampled hyperspectral image datasets

算法	SDAE	多标签 CNN
Accuracy	94.12	89.71
Precision	82.82	72.18
Recall	86.19	71.73

从实验结果可以看出,在相同的训练和测试数据下,SDAE 算法的各项评估指标都优于多标签 CNN 算法。CNN 算法的特征提取是属于有监督学习,训练效果依赖于训练样本的选取,容易出现过拟合现象。即训练得到的网络权重在训练样本中取得很高的精确度,但在测试样本中的分类效果很低。同时,当训练样本中的正负样本比例不平衡时,容易出现 Accuracy 值很高,但 Precision

和 Recall 值不高。虽然整体精确度很高,但可能某一些类别的特征被大部分正确分类了,而另一些类别的特征并没有被分类正确。与 CNN 算法相比,SDAE 算法依赖于特征本身而不是预设置的特征标签,更注重于特征自身及特征之间的关系的学习。并且,SDAE 通过对数据随机化引入噪声,然后通过训练网络识别出噪声之中的特征,尝试重构这些数据来进行学习。因此,经过实验对比可以证实,SDAE 算法可以得到比 CNN 算法更好的分类效果。

### 3 结论

本文提出了一种新型的基于深度学习的高光谱图像多标签分类算法,用以更好地分析高光谱图像数据中的混合像素。使用堆叠降噪自动编码器网络对图像特征进行学习得到深层特征,并将各层特征传递给多标签逻辑回归分类器,为每个混合像素分配多个标签。通过对合成高光谱图像数据、真实高光谱图像数据和降采样数据分别进行对比实验,结果充分证明了所提出算法能够对高光谱图像数据进行高效的多标签分类。

### 参考文献:

- [1] 崔宾阁,吴子宾,秦学川,等.基于改进标签传播算法的高光谱图像半监督分类[J].山东科技大学学报,2016,35(6): 101-107.
- [2] 舒速.基于分水岭分割的高光谱图像分类算法研究[D].南京:南京师范大学,2015.
- [3] COVERT M, HART P E. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1):21-27.
- [4] CHAPELLE O, HAFFNER P, VAPNIK V N. Support vector machines for histogram-based image classification[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 1055-1064.
- [5] 邢晨.基于深度学习的高光谱遥感图像分类[D].武汉:中国地质大学,2016.
- [6] LIANG H, LI Q. Hyperspectral imagery classification using sparse representations of convolutional neural network features[J]. Remote Sensing, 2016, 8(2): 1-16.
- [7] 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): 298-306.
- [8] 王曙.深度学习算法研究及其在图像分类上的应用[D].南京:南京邮电大学,2016.
- [9] 高耀东,侯凌燕,杨大利.基于多标签学习的卷积神经网络的图像标注方法[J].计算机应用,2017,37(1): 228-232.
- [10] 陈智.基于卷积神经网络的多标签场景分类[D].济南:山东大学,2015.
- [11] CHEN Xing, MA Li, YANGXiaoquan. Stacked denoise autoencoder based feature extraction and classification for hyperspectral images[J]. Journal of Sensors, 2016(2): 112-119.
- [12] 尹宝才,王文通,王立春.深度学习研究综述[J].北京工业大学学报,2015(1):48-59.
- [13] 胡文瑜,蔡文培.数据挖掘取样方法的衡量与选用研究[J].福建工程学院学报,2011,9(4):351-356.
- [14] HU W, HUANG Y, LI W. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015(2): 21-28.
- [15] READ J, PEREZ-CRUZ Perez-Cruz. Deep learning for multi-label classification[J]. Machine Learning, 2014, 85(3): 333-359.

- [6] KAO S C, HO C. Monitoring a process of exponentially distributed characteristics through minimizing the sum of the squared differences[J]. *Quality & Quantity*, 2007, 41(1): 137-149.
- [7] CHEN J, TIAN J. Real-time multi-modal rigid registration based on a novel symmetric-SIFT descriptor [J]. *Progress in Natural Science: Materials International*, 2008, 19(5): 643-651.
- [8] BARRERA F, LUMBRERAS F, SAPPA A D. Multispectral piecewise planar stereo using Manhattan-world assumption[J]. *Pattern Recognition Letter*, 2013, 34(1): 52-61.
- [9] 侯北平, 朱文, 马连伟, 等. 基于形状特征的移动目标实时分类研究[J]. *仪器仪表学报*, 2010, 31(8): 1819-1825.
- [10] LINDEBERG T. Edge detection and ridge detection with automatic scale selection[J]. *International Journal of Computer Vision*, 1998, 30(2): 117-154.
- [11] LOWE D G. Distinctive image features from scale-invariant key points[J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [12] 王永明, 王贵锦. 图像局部不变性特征与描述[M]. 北京: 国防工业出版社, 2010.
- [13] 傅卫平, 秦川, 刘佳. 基于 SIFT 算法的图像目标匹配与定位[J]. *仪器仪表学报*, 2011, 32(1): 163-169.
- [14] 郑永斌, 黄新生, 丰松江. SIFT 和旋转不变 LBP 相结合的图像匹配算法[J]. *计算机辅助设计与图形学学报*, 2010, 22(2): 286-292.
- [15] BAUER J, SUNDERHAUF N, PROTZEL P. Comparing several implementations of two recently published feature detectors [C]. *Proceedings of the international conference on intelligence and autonomous systems*, Toulouse, France, 2007.
- [16] 高素青, 谭勋军, 黄承夏. 一种基于 SURF 的图像配准改进算法[J]. *解放军理工大学学报(自然科学版)*, 2013, 14(4): 372-376.
- [17] 陈艺虾, 孙权森, 徐焕宇, 等. SURF 算法和 RANSAC 算法相结合的遥感图像匹配方法[J]. *计算机科学与探索*, 2012, 6(9): 822-828.

(特约编辑: 黄家瑜)

(上接第 270 页)

- [16] 王宪保, 何文秀, 王辛刚, 等. 基于堆叠降噪自动编码器的胶囊缺陷检测方法[J]. *计算机科学*, 2016, 43(2): 64-67.
- [17] VIKTOR S, STEVEN V. Hyperspectral image Classification with convolutional neural networks[C]. *Proceedings of the 23rd ACM International Conference on Multimedia (MM' 15)*. 2015: 1159-1162.
- [18] PaginaDel Usuario. Grupo de Inteligencia Computacional. Universidad del Pais Vasco[Z/OL]. [http://www.ehu.es/ccwin-tco/index.php?title=Conjuntos\\_de\\_datos\\_3D](http://www.ehu.es/ccwin-tco/index.php?title=Conjuntos_de_datos_3D). 2008.
- [19] BAUMGARDNERMF, BIEHLL, LANDGREBEDA. Landgrebe. Band AVIRIS Hyperspectral Image Data Set[Z/OL]. <https://purr.purdue.edu/publications/1947>. 1992.
- [20] FOSTERD H, Amano K, FOSTERMJ. Hyperspectral Images of Natural Scenes[Z/OL]. [http://personalpages.manchester.ac.uk/staff/d.h.foster/Hyperspectral\\_images\\_of\\_natural\\_scenes\\_02.html](http://personalpages.manchester.ac.uk/staff/d.h.foster/Hyperspectral_images_of_natural_scenes_02.html). 2002.

(特约编辑: 黄家瑜)