

DOI: 10.13382/j.jemi.B1902756

基于 LDA 和 ELM 的高光谱图像降维与分类方法研究

杨明莉^{1,2,3} 范玉刚^{1,2,3} 李宝芸^{1,2,3}

(1. 昆明理工大学 信息工程与自动化学院 昆明 650500; 2. 昆明理工大学 云南省人工智能重点实验室 昆明 650500;
3. 云南省矿物管道输送工程技术研究中心 昆明 650500)

摘要:高光谱图像具有波段多、波段间相关性强的特点,导致高光谱图像信息冗余,造成维数灾难、难以分类的问题,为此提出了一种基于线性判别分析(LDA)和极限学习机结合的高光谱图像降维分类方法。该方法首先通过 LDA 对高光谱数据进行降维处理,克服高光谱图像信息冗余等问题的同时,尽可能保留图像的特征信息;降低光谱图像维度后,采用极限学习机(ELM)对高光谱遥感图像进行分类识别。所提方法应用于 Pavia University 和 Salinas 高光谱图像处理,分类精度分别达到了 98.78% 和 99.94%,有效提升了高光谱图像的地物分类性能,具有较强的实用性。

关键词:高光谱图像;极限学习机;线性判别分析;降维;分类

中图分类号: TP23; TN952 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on dimensionality reduction and classification of hyperspectral images based on LDA and ELM

Yang Mingli^{1,2,3} Fan Yugang^{1,2,3} Li Baoyun^{1,2,3}

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;
2. Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650500, China;
3. Yunnan Mineral Pipeline Transportation Engineering and Technology Research Center, Kunming 650500, China)

Abstract: Hyperspectral images have the characteristics of multiple bands and strong correlation among bands, which leads to information redundancy of hyperspectral images, resulting in dimensionality disaster and difficulty in classification. Therefore, a dimensionality reduction classification method of hyperspectral images based on LDA and extreme learning machine is proposed. In this method, hyperspectral data are firstly processed by LDA for dimensionality reduction, so as to overcome the problem of hyperspectral image information redundancy and keep the image feature information as far as possible. After reducing the spectral image dimension, ELM is adopted to classify and identify hyperspectral remote sensing images. The method proposed is applied to Pavia University and Salinas hyperspectral image processing, and the classification accuracy reaches 98.78% and 99.94% respectively, which effectively improves the feature classification performance of hyperspectral images and has strong practicability.

Keywords: hyperspectral image; extreme learning machine; linear discriminant analysis; dimensionality reduction; classification

0 引言

高光谱遥感(hyperspectral remote sensing)技术兴起于20世纪80年代,广泛应用于航空航天,遥感科学,生物医学图像,农业,气象等^[1-2],当前已成为遥感领域的前沿技术之一。高光谱图像分类是高光谱遥感图像处理的重要内容,也是近年来一个热门的研究方向^[3]。高光谱

图像反映的是地物分布的复杂情况,由于高光谱图像波段多、波段间剪相关性强、空间分辨率高,因此存在大量冗余数据,产生光谱图像信息冗余问题,需要对高光谱图像进行降维处理^[4-5]。

主成分分析(principal components analysis, PCA)是目前常用的高光谱数据降维处理方法。文献[6]针对高光谱图像数据量大和信息冗余的问题,提出了一种基于PCA与空间分类相结合的方法;文献[7]提出了一种基

于 PCA 的高光谱图像特征提取方法,通过将整个高光谱图像分割成多个具有相似反射率特性的不同均匀区域,对其进行 PCA 降维,得到高光谱图像的低维特征空间;文献[8]针对传统 PCA 降维方法仅依据方差贡献率进行特征提取,无法有效利用高光谱图像本身信息的问题,提出了一种利用信息量改进 PCA 的降维方法。但以上基于 PCA 的降维方法均没有利用样本的类别信息,属于无监督学习,不利于提高高光谱图像识别率。与 PCA 相比,线性判别分析(linear discriminant analysis, LDA)是一种监督学习的线性降维方法,不仅计算量小,同时能够提取出高维数据中的主成分信息,达到提高分类精度的目的。

由 Huang 等^[9]提出的极限学习机(extreme learning machine, ELM),其较高的分类准确率和训练效率受到极大关注,并应用于处理高光谱图像的物识别问题^[10-11],文献[12]采用 ELM 对高光谱遥感图像地物识别问题进行处理,利用光谱特性的局部相关性,提出了基于分层结构 ELM 的高光谱分类方法,但该方法未对高光谱数据进行降维处理,无法克服高光谱图像信息冗余问题。

针对以上存在的问题,本文提出了一种基于 LDA-ELM 模型的高光谱图像降维分类方法。采用的基于监督学习的 LDA 降维方法,降低数据维度的同时尽可能保留数据中的特征信息,降维后的数据消除了高光谱图像的冗余信息,采用 ELM 对其进行分类识别,在 Pavia University 和 Salians 两个高光谱图像处理上的应用表明,所提出的方法可以取得更高的分类精度。

1 高光谱图像特征提取与分类方法

1.1 LDA 降维

LDA 是一种监督学习的线性降维方法,它的数据集的每个样本是有类别输出的,投影后类内方差最小,类间方差最大,即投影后每一种类别数据的投影点尽可能的接近,而不同类别数据的类别中心之间的距离尽可能的大^[13]。本文采用有监督学习的 LDA 作为高光谱特征提取的方法,可以提高数据分析过程中的精确度,降低因维度灾难带来的过拟合现象。

LDA 算法利用样本集 X_i 的判别信息,构建同类数据的类内散度矩阵 S_w 和异类数据的类间散度矩阵 S_b , 寻求一个最佳的投影方向,使异类数据的类间散度极大化、同类数据的类内散度极小化,实现最佳样本可区分性。

类内离散度矩阵 S_w 和类间离散度矩阵 S_b 分别定义为^[14-15]:

$$S_w = \sum_{i=1}^L \sum_{j=1}^{l_i} (x_j^i - \bar{x}_i)(x_j^i - \bar{x}_i)^T \quad (1)$$

$$S_b = \sum_{i=1}^L P(i)(x_i^i - \bar{x})(x_i^i - \bar{x})^T \quad (2)$$

式中: $P(i)$ 是第 i 类样本的先验概率; x_i^j 表示第 i 类的第 j 个样本; \bar{x}^i 是第 i 类的均值; L 代表类别个数。 $W \in R^{d \times r}$ 代表投影矩阵,则 LDA 的目标函数可表示为:

$$W_{opt} = \arg \max_w \frac{Tr(W^T S_b W)}{Tr(W^T S_w W)} \quad (3)$$

本文采用 LDA 作为高光谱图像数据的降维方法,可以有效地提取出高维空间中的低维数据结构,有利于提高高光谱图像地物分类的精度。

1.2 ELM

ELM 是由 Huang 等提出的一种新型单隐层前馈神经网络(single-hidden layer feedforward neural network, SLFN),由输入层、隐含层和输出层组成^[16]。结构如图 1 所示,输入层和隐含层的连接权值、隐含层的偏置是随机设定的,隐含层和输出层之间的连接权值 β 通过解方程组方式一次性确定,不再需要迭代调整。整个训练过程只需要调整隐含层神经元的个数及隐含层神经元的激活函数即可^[17]。




图 1 极限学习机模型

Fig. 1 Extreme learning machine model

假设训练集 $X = \{x_i, y_i\}_{i=1}^N$, 有 N 个训练样本,输入样本为:

$$x_i = [x_{i1}, x_{i2}, \dots, x_{id}]^T \in R^d \quad (4)$$

其中, y_i 是样本标签,令隐含层神经元的个数为 L , 则第 j 个隐含层的输出方程为:

$$o_j = \sum_{i=1}^L \beta_{ij} g_i(a_i \cdot x_j + b_i) \quad j = 1, 2, \dots, L \quad (5)$$

式中: a_i 表示第 i 个隐含层节点和输入层节点之间的连接权值; β_{ij} 表示输出层与隐含层之间的连接权值; b_i 表示第 i 个隐含层节点的偏置; g_i 为激活函数。

单隐层神经网络学习的目标是使得输出的误差最小,即存在 β_i, W_i 和 b_i ,使得:

$$t_j = \sum_{i=1}^L b_{ij} g_i(a_i \cdot x_j + b_i) \quad j = 1, 2, \dots, L \quad (6)$$

最小目标误差可以表示为:

$$\sum_{j=1}^N \| o_j - t_j \| = 0 \quad (7)$$

输出目标函数为:

$$y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in \mathbf{R}^m \quad (8)$$

ELM 网络输出 T 为:

$$T = [t_1, t_2, \dots, t_N]_{m \times N} \quad (9)$$

式(6)可以表示为:

$$H\beta = T' \quad (10)$$

式中: T' 为矩阵 T 的转置; H 为 ELM 的隐含层输出矩阵, 式(10)等价于求解 $\min_{\beta} \| H\beta - T' \|$, 从而得到最优输出权重为:

$$\hat{\beta} = H^+ T' \quad (11)$$

式中: H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆矩阵。

目前已有部分工作将 ELM 应用于高光谱遥感图像地物分类的问题中, 且取得了比 BP 神经网络较高的分类精度^[18-19]。

2 高光谱图像地物识别

本文提出了 LDA-ELM 模型用于高光谱图像分类识别, 在识别时先对高光谱高维数据特征进行线性判别分析, 再采用 ELM 方法分类识别, 结合 LDA 降维后的高光谱图像数据特征, 设计 LDA-ELM 模型下高光谱图像降维分类步骤如下。

1) 获取高光谱数据集, 对 L 类高光谱图像进行线性判别分析, 得到降维后的数据集 $[x_{i1}, x_{i2}, \dots, x_{il}]^T$ 。

2) 将降维后的数据集分为训练样本集和测试样本集。

3) 将训练样本集和测试样本集作为 ELM 分类器的输入样本, 先对训练样本集进行 ELM 分类建模, 将训练得到的参数作为测试样本的输入参数, 再对测试样本集进行预测识别, 得到高光谱图像的输出目标函数, $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T$ 即为 ELM 分类结果预测值。

4) 采用高光谱图像常见的分类性能评价指标, 将 LDA-ELM 模型预测结果和其他降维分类方法作对比, 得出高光谱图像最佳分类模型。

本文提出的 LDA-ELM 高光谱图像降维分类模型流程如图 2 所示。

3 实验评价指标

3.1 总体精度(OA)

OA 是对分类结果质量的总体评价, 等于被正确划分的样本数除以样本总数。误差矩阵的主对角线元素为被

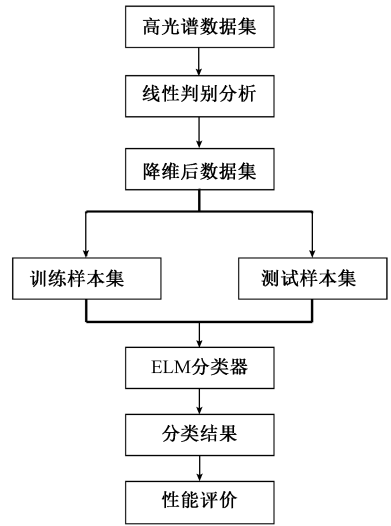


图 2 高光谱图像地物识别过程流程

Fig. 2 Process flow chart of object identification in hyperspectral image

正确分类的样本, 表示被正确分类到对应地物类型中的样本个数。样本总数为地物实际分类中的样本总数。计算公式为^[20]:

$$OA = \frac{\sum_{L=1}^L C_{LL}}{\sum_{L=1}^L \sum_{j=1}^L C_{Lj}} \quad (12)$$

其中, C 表示混淆矩阵, 表示将第 L 类分到第 j 类的样本个数, L 表示类型总数。

3.2 Kappa 系数

Kappa 系数(Kappa coefficient)用来表示分类结果与训练数据之间的吻合程度, 克服了总体分类精度过度依赖样本类别数和样本数量的缺点, 是一种更为客观的评价指标。其计算公式为:

$$Kappa = \frac{(P_0 - P_e)}{1 - P_e} \quad (13)$$

其中:

$$P_0 = OA = \frac{\sum_{L=1}^L C_{LL}}{\sum_{L=1}^L \sum_{j=1}^L C_{Lj}} \quad (14)$$

$$P_e = \sum_{i=1}^L \sum_{j=1}^L \frac{a_i b_j}{n \times n} \quad (15)$$

式中: P_0 是每一类正确分类的样本数量之和除以总样本数, 即总体分类精度; a_1, a_2, \dots, a_k 为每一类的真实样本个数; b_1, b_2, \dots, b_k 为预测出来的每一类的样本个数; n 为总体样本个数。Kappa 系数越大, 分类精度越高。

4 高光谱图像识别实验

本实验以 Pavia University 和 Salinas 高光谱图像数据集为研究对象,由于这两组数据的拍摄场景、样本量、波段数、空间分布率、数据大小等均不相同,且来自两个不同的成像传感器,可以更全面的验证本文方法的有效性。

4.1 Pavia University 数据集

Pavia University 数据集由反射光学系统成像光谱仪 (ROSIS) 在意大利北部的 Pavia 大学于 2013 年拍摄采集的,光谱仪产生 115 个波段,除去大气和水分吸收影响的 12 个低信噪比波段,共取 103 个波段,波长范围为 0.43~0.86 μm ,空间分辨率为 1.3 米,图像大小尺寸为 610×340,包含 9 个地物类别。

4.2 Salinas 数据集

Salinas 数据集由 AVIRIS 传感器在美国加州 Salinas 谷地于 1998 年拍摄采集。光谱仪产生 224 个波段,除去 20 个水吸收明显的波段,共取 204 个波段,波长范围为 0.4~2.5 μm ,空间分辨率为 3.7 m,图像大小尺寸为 512×217,包含 16 个地物类别。

4.3 训练集和测试集划分

1) Pavia University 数据集

本实验从降维后的每类样本中选取 200 个训练样本,100 个测试样本,共计 1 800 个训练样本集和 900 个测试样本集,将其作为 ELM 分类器的输入样本。将训练样本集 1~200 标记为标签 1,301~500 标记为标签 2,601~800 标记为标签 3,以此类推,2401~2600 标记为标签 9;测试样本集 201~300 标记为标签 1,501~600 标记

为标签 2,801~900 标记为标签 3,以此类推,2601~2700 标记为标签 9,共 9 个标签,由此得到本次实验 Pavia University 数据集。

2) Salinas 数据集

对于 Salinas 数据集,采用同样的方法从降维后的每类样本中选取 200 个训练样本,100 个测试样本,共计 3 200 个训练样本集和 1 600 个测试样本集,将其作为 ELM 分类器的输入样本。将训练样本集 1~200 标记为标签 1,301~500 标记为标签 2,601~800 标记为标签 3,以此类推,4501~4700 标记为标签 16;测试样本集 201~300 标记为标签 1,501~600 标记为标签 2,801~900 标记为标签 3,以此类推,4701~4800 标记为标签 16,共 16 个标签,由此得到本次实验 Salinas 数据集。

4.4 LDA、PCA 降维和分类试验分析

本文采用 LDA 和 PCA 对高光谱数据集进行降维,对 Pavia University 和 Salinas 两个高光谱图像数据集进行以下分类验证。图 3 和 4 所示为 Pavia University 和 Salinas 高光谱图像数据集在 LDA 和 PCA 降维方式下,降维特征数和 K 近邻(KNN)、支持向量机(SVM)、ELM 3 种分类方法的精确度关系对比图。对于 Pavia University 数据集,在 LDA 降维方式下,前 15 个降维特征数在 KNN、SVM 和 ELM 分类方式下的 OA 可分别达到 96.22%、96% 和 98.78%;在 PCA 降维方式下,前 20 个降维特征数在 KNN、SVM 和 ELM 分类方式下的 OA 可分别达到 91.44%、96.56% 和 58.78%,而当降维特征数为 5 时,ELM 的分类精度最高达到 95.39%,之后呈急剧下降趋势且达到一定维度时又基本平稳。

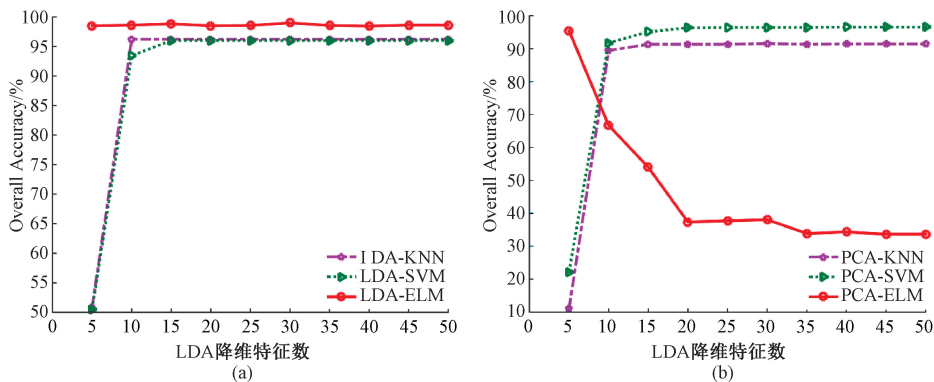


图3 Pavia University 数据集降维特征数和 KNN、SVM、ELM 三种分类方法的精确度关系对比

Fig. 3 Comparison diagram of the accuracy relationship between the dimensionality reduction feature number of Pavia University dataset and KNN, SVM and ELM classification methods

对于 Salinas 数据集,在 LDA 降维方式下,前 20 个降维特征数在 KNN、SVM 和 ELM 分类方式下的 OA 可分别

达到 99%、99.31% 和 99.94%;在 PCA 降维方式下,前 20 个降维特征数在 KNN 和 SVM 分类方式下的 OA 可分别




图 4 Salinas 数据集降维特征数和 KNN、SVM、ELM 三种分类方法的精确度关系对比

Fig. 4 Comparison diagram of the accuracy relationship between the dimensionality reduction feature number of Salinas dataset and KNN, SVM and ELM classification methods

达到 96.44% 和 98.88%，而当降维特征数为 5 时，ELM 的分类精度最高达到了 98.44%，之后呈急剧下降趋势且达到一定维度时又基本平稳。

此外，在两类数据集上 PCA-ELM 算法的分类精度在某个最佳降维特征数时分类精度达到最高，之后随着降维特征数的增加呈现急剧下降的趋势，如图 3(b) 和图 4(b) 所示，表明高光谱图像随着维数的增加，会导致维数灾难的问题。此时需要增加更多的训练样本的数量，来避免此现象的发生。

5 实验结果对比分析

本实验中 SVM 的参数为 $c = 1.2$, $g = 2.8$ ；在 Pavia University 和 Salinas 两类高光谱图像数据集中选择 KNN 分类器 K 值的大小分别为 8 和 2；ELM 的激活函数 g_i 为 Sigmoid 函数，隐含层节点个数为 100。

本文将 LDA-ELM 与其他降维分类方法进行比较，在不进行降维、LDA 和 PCA 降维方式下对其进行分类，分

类方法包括 KNN、SVM 和 ELM。表 1 和 2 分别给出了两个高光谱图像数据集在不同降维分类方式下的分类正确率对比结果。该表列出了测试集总样本个数、被正确分类的样本个数、测试集总体分类精度、Kappa 系数。由对比结果可以得到以下结论。

1) ELM 在不进行数据降维时分类精度最差，在 Pavia University 和 Salinas 两个高光谱图像数据集上分类精确度分别为 53.22% 和 73.31%，Kappa 系数分别为 0.502 8 和 0.720 3。

2) 对比所有方法，本文所提的 LDA-ELM 模型在 Pavia University 和 Salinas 两个高光谱图像数据集上均取得了最好的分类效果，总体分类精度分别达到了 98.78% 和 99.94%，相比于 PCA-KNN 分别提高了 7.34% 和 3.50%，Kappa 系数也达到最大，分别为 0.986 3 和 0.998 7。

3) 在降维方式中，LDA 降维后的分类精度要优于采用 PCA 降维后的分类精度。

表 1 Pavia University 数据集在不同分类方法下的实验结果对比

Table 1 Comparison of experimental results of Pavia University datasets under different classification methods

数据降维方式	数据分类方式	总样本个数	正确分类样本个数	测试集 OA/%	Kappa 系数
不进行数据降维	KNN	900	842	93.56	0.928 1
	SVM	900	877	97.44	0.971 3
	ELM	900	479	53.22	0.502 8
LDA	KNN	900	866	96.22	0.957 7
	SVM	900	864	96.00	0.955 2
	ELM	900	889	98.78	0.986 3
PCA	KNN	900	823	91.44	0.904 8
	SVM	900	869	96.56	0.961 4
	ELM	900	529	58.78	0.559 0

表 2 Salinas 数据集在不同分类方法下的实验结果对比

Table 2 Comparison of experimental results of Salinas datasets under different classification methods

数据降维方式	数据分类方式	总样本个数	正确分类样本个数	测试集 OA/%	Kappa 系数
不进行数据降维	KNN	1 600	1 542	96.38	0.961 4
	SVM	1 600	1 586	99.13	0.990 7
	ELM	1 600	1 173	73.31	0.720 3
LDA	KNN	1 600	1 584	99.00	0.989 3
	SVM	1 600	1 589	99.31	0.992 7
	ELM	1 600	1 599	99.94	0.998 7
PCA	KNN	1 600	1 543	96.44	0.962 1
	SVM	1 600	1 582	98.88	0.988 0
	ELM	1 600	1 575	98.44	0.983 4

6 结 论

本文提出了一种基于 LDA-ELM 模型的高光谱图像降维分类方法,该方法利用 LDA 降低高光谱图像的数据维度,消除高光谱图像的冗余信息,提取高光谱图像特征;对特征向量构成的数据集采用 ELM 进行地物分类识别。在 Pavia University 和 Salinas 两个高光谱数据集上的实验结果表明,该模型在提高分类精度的同时保持了高效性,因此该算法具有较大的实际意义。

参考文献

- [1] WU Z B, SHI L L, LI J, et al. GPU parallel implementation of spatially adaptive hyperspectral image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(4): 1131-1143.
- [2] DENG Y J, LI H C, PAN L, et al. Modified tensor locality preserving projection for dimensionality reduction of hyperspectral images [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(2): 277-281.
- [3] HE N, PAO M E, FANG L, et al. Feature extraction with multiscale covariance maps for hyperspectral image classification [J]. IEEE Trans. Geosci. Remote Sens., 2018, 57(2): 755-769.
- [4] PU H, CHEN Z, WANG B, et al. A Novel Spatial-spectral Similarity Measure of Dimensionality Reduction and Classification of Hyperspectral Imagery [J]. IEEE transactions on Geoscience and Remote Sensing, 2014, 52(11): 7008-7022.
- [5] 赵勇,李怀宇.基于通用距离测量的机器学习方法用于图像分类和聚类[J].电子测量技术,2017,40(9): 136-140.
ZHAO Y, LI H Y. Machine learning method based on general distance measurement is used for image classification and clustering [J]. Electronic Measurement Technique, 2017, 40(9): 136-140.
- [6] 王一宁,陈善学,桂成名.一种结合空谱聚类的高光谱图像快速压缩算法 [J]. 电讯技术, 2017, 57(3): 263-269.
WANG Y N, CHECN S X, GUI C M. A fast compression algorithm for hyperspectral images combined with spatial clustering [J]. Telecommunications Technology, 2017, 57(3): 263-269.
- [7] JIANG J J, MA J Y, CHEN C, et al. A Super pixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, doi: 10.1109/TGRS.2018.2828029.
- [8] 任智伟,吴玲达.基于信息量改进主成分分析的高光谱图像特征提取方法 [J]. 兵器装备工程学报, 2018, 39(7): 151-154.
REN ZH W, WU L D. An improved principal component analysis (pca) based method for feature extraction of hyperspectral images [J]. Journal of ordnance and equipment engineering, 2018, 39(7): 151-154.
- [9] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [10] HE N, PAOLETTE M. E, FANG L, et al. Feature extraction with multiscale covariance maps for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(2): 755-769.
- [11] BA T L, THAI T L H. Hyperspectral image classification based on average spectral-spatial features and improved hierarchical-ELM [J]. Infrared Physics and Technology, 2019, 102: 1-8.
- [12] 李铁,张新君.极限学习机在高光谱遥感图像分类中的应用 [J]. 光电工程, 2016, 43(11): 62-68, 75.
LI T, ZHANG X J. Application of extreme learning machine in classification of hyperspectral remote sensing images [J]. Photoelectric Engineering, 2016, 43(11): 62-68, 75.

- [13] PENG J T, ZHOU Y C, CHEN C L, et al. Region-kernel-based support vector machines for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53 (9): 4810-4824.
- [14] YUAN H L, TANG Y Y, LU Y, et al. Spectral-spatial classification of hyperspectral image based on discriminant analysis [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6):2035-2043.
- [15] WANG Q, MENG Z T, LI X L. Locality adaptive discriminant analysis for spectral-spatial classification of hyperspectral images [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(11): 2077-2081.
- [16] LUO X, XU Y, WANG W, et al. Towards enhancing stacked extreme learning machine with sparse autoencoder by correntropy [J]. Journal of the Franklin Institute, 2018, 355(4):1945-1966.
- [17] 赵超, 陈肇泉, 王斌, 等. 基于互信息和 IGSA 优化 ELM 的重整芳烃收率软测量 [J]. 仪器仪表学报, 2019, 40(3):255-263.
ZHAO CH, CHEN ZH Q, WANG B, et al. Soft measurement of reforming aromatics yield based on mutual information and IGSA optimization ELM [J]. Journal of Instrumentation, 2019, 40(3):255-263.
- [18] 吴春晓, 行鸿彦, 张漪俊. 基于 BP 神经网络的地温推演模型 [J]. 电子测量与仪器学报, 2017, 31(10): 1561-1567.
WU CH X, HANG H Y, ZHANG Y J. A model of ground temperature deduction based on BP neural network [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(10): 1561-1567.

- [19] 邵南平, 向春生, 唐岚, 李占东. 基于 AdaBoost BP 神经网络的无参考图像质量评价的研究 [J]. 国外电子测量技术, 2017, 36(11):108-113.
SHAO N P, XIANG C S, TANG L, et al. Study on the quality evaluation of unreferenced images based on AdaBoost BP neural network [J]. Foreign Electronic Measurement Technology, 2017, 36(11):108-113.
- [20] 吕飞, 韩敏. 基于深度极限学习机的高光谱遥感影像分类研究 [J]. 大连理工大学学报, 2018, 58(2): 166-173.
LV F, HAN M. Classification of hyperspectral remote sensing images based on deep limit learning machine [J]. Journal of Dalian University of Technology, 2018, 58(2):166-173.

作者简介



杨明莉, 现为昆明理工大学硕士研究生, 主要研究方向为图像处理、模式识别。

E-mail: 153422136@qq.com

Yang Mingli is a M. Sc. candidate at Kunming University of Science and Technology now. Her main research interest includes image processing and pattern recognition.



范玉刚, 现为昆明理工大学副教授, 主要研究方向为基于机器学习的智能信息处理、数据挖掘、图像处理等。

E-mail: ygf@qq.com

Fan Yugang is an associate professor at Kunming University of Science and Technology. His main research interests include intelligent information processing, data mining and image processing based on machine learning and so on.