

文章编号: 2095-2163(2022)04-0061-09

中图分类号: TP181

文献标志码: A

基于分层网络与局部约束的高光谱图像分类

张景, 闫德勤, 于佳宁, 刘德山

(辽宁师范大学 计算机与信息技术学院, 辽宁 大连 116029)

摘要: 高光谱图像存在高维度、带间相关性较高的特点, 分类过程中也存在同谱异类的问题。为此, 提出一种基于分层网络与局部约束的高光谱图像分类方法。该方法通过空谱信息训练分层深度网络, 并与局部约束信息结合实现对高维数据的特征提取。同时, 融合训练样本与测试样本的类内相似性, 以提高分类的准确性。在 2 个高光谱数据集 Indian Pines 和 Pavia University 上的实验结果表明, 该算法分类性能比其他分类算法精度上有了较大提高。

关键词: 高光谱图像; 分层深度网络; 局部约束; 相关系数; 稀疏表示

Hyperspectral image classification based on hierarchical network and local constraint

ZHANG Jing, YAN Deqin, YU Jianing, LIU Deshan

(School of Computer and Information Technology, Liaoning Normal University, Dalian Liaoning 116029, China)

【Abstract】 Hyperspectral images have the characteristics of high dimension and high correlation between bands, and there are also difficulties in the classification of the same spectrum and the different region. Therefore, the paper proposes a hyperspectral image classification method based on hierarchical network and local constraints. More precisely, the method trains the hierarchical deep network with space spectrum information and combines with local constraint information to extract features from high dimensional data. At the same time, to improve the accuracy of classification, this method combines the correlation coefficient between the training samples and test samples. Experimental results on two hyperspectral data sets Indian Pines and Pavia University show that the proposed algorithm has better classification performance than other algorithms.

【Key words】 hyperspectral image; hierarchical deep network; local constraint; correlation coefficient; sparse representation

0 引言

高光谱图像(Hyperspectral Image, HSI)是一个三维的数据空间立方体, 包括 2 个空间维和一个光谱维, 其中包含了丰富的地理信息量, 能够清晰地反映出真实的地表情况^[1-2]。近年来, 高光谱图像分类在很多领域都获得了广泛的应用, 如精密农业^[3-6]、地质勘探^[7]、环境监测^[8]、国防科技^[9]等方面。目前, 人们对高光谱图像分类的研究方法主要分为 2 种: 传统分类方法和深度学习方法。稀疏表示分类算法(Sparse Representation Classification, SRC)^[10]是一种传统的分类方法^[11-13], SRC 假设测试样本可以由来自同一类的少量训练样本线性重构, 这一特点使得 SRC 与经典的分类方法, 如 K 近邻(K-Nearest Neighbor, KNN)^[14]、支持向量机

(Support Vector Machine, SVM)^[15]相比更加简洁。稀疏表示分类算法只利用了高光谱图像的光谱信息, 忽略了高光谱图像的空间特征。

Chen 等人^[16-17]提出了联合稀疏表示方法(Joint Sparse Representation Classification, JSRC), 该方法假设局部窗口中的像素可以通过由训练样本构造的字典进行联合稀疏表示。根据表示残差确定每个像素的类别标签, 较好地利用了高光谱图像的空谱信息。JSRC 存在的问题是当像素周围窗口中包含异类像素时, 会对样本的线性表示产生类间影响, Tu 等人^[18-19]提出了结合相似度量 and 联合稀疏表示的分类算法(Correlation Coefficient and Joint Sparse Representation, CCJSR), 通过计算训练样本和测试样本的类内相似度, 同时减少类间干扰, 优化分类的结果。Li 等人^[20]证明了局部性比稀疏性更加关键,

基金项目: 国家自然科学基金(61772250); 辽宁省教育厅科学研究项目(LJ2019014)。

作者简介: 张景(1997-), 女, 硕士研究生, 主要研究方向: 机器学习、模式识别、遥感图像分类; 闫德勤(1962-), 男, 博士, 教授, 主要研究方向: 机器学习、字典学习、深度学习等; 于佳宁(1995-), 女, 硕士研究生, 主要研究方向: 机器学习、模式识别、遥感图像分类; 刘德山(1970-), 男, 教授, 主要研究方向: 机器学习、智能信息处理、模式识别。

通讯作者: 刘德山 Email: deshaneliu@yeah.net

收稿日期: 2021-11-24

在分类中,局部性具有重要作用^[21-24]。传统的稀疏分类方法使用 l_1 范数,与字典原子距离远的样本会丢失欧氏距离信息,造成分类不稳定^[24]。因此,Cui 等人^[25]提出了类依赖稀疏表示分类方法(Class-dependent Sparse Representation Classifier, cdSRC)用于高光谱图像的分类,有效地结合了 KNN 分类器,将欧氏距离和重构误差引入到同一个函数中。然而,当有多个类别与测试样本的类别相似时,利用残差和距离之和来确定标签的方法就不适用了。为了解决这一问题,Zhang 等人^[24]提出了一种局部约束稀疏表示分类方法(Locality-constrained Sparse Representation Classification, LSRC),LSRC 没有使用所有的训练集作为字典,而是选择靠近测试样本的样本构成局部字典,消除了远离测试样本的训练样本。

传统分类方法依赖于专业知识和经验来获取光谱空间特征,而深度学习通过聚合低级信息自动获取高级抽象表示,避免了复杂的特征提取工程。深度学习主要基于深度神经网络(Deep Neural Network, DNN)^[26-29]实现多个神经网络层(每层由多个节点组成),通过网络能够学习输入输出之间的复杂关系^[30-31]。传统的深度学习大多只涉及空谱的噪声滤波,而忽略了光谱的噪声滤波。因此,Zhou 等人^[32]提出了结合高光谱图像特点的光谱空间网络(Spectral-Spatial Network, SSN)。

以上研究结果表明,在高光谱图像的分类中,基于局部约束的稀疏表示模型尤为重要,充分利用空间信息和光谱信息也必不可少。为取得更优的分类性能,针对 LSRC 对空谱特征结合运用不充分的问题,本文提出了基于分层网络与局部约束的高光谱图像分类方法(Spectral-spatial Network and Locality-constrained Sparse Representation Classification, SLSRC)。本算法能够充分利用高光谱图像的光谱信息和空间信息,根据训练样本和测试样本之间的欧氏距离信息,构造了一个新的稀疏表示字典。为了证明本算法在高光谱图像分类应用中的性能,选取常见的 2 个高光谱图像数据集,Indian Pines、Pavia University 数据集,与 KNN^[14]、SRC^[10]、cdSRC^[25]、LSRC^[24]算法进行综合比较,结果表明本文提出算法在图像分类中表现出较高的分类性能。本文的其余部分安排如下:第 1 节介绍本文所提出的算法;基于分层网络的局部约束字典分类算法;第 2 节对实验结果进行展示和分析;第 3 节对本文进行总结。

1 基于分层网络的局部约束字典分类算法

SLSRC 算法由 2 部分构成,分别为:构建局部约束字典和基于局部约束字典的稀疏表示。第一部分利用分层深度网络完成局部约束字典的构建,第二部分将得到的字典用于稀疏表示,并与相关系数结合进行分类。

1.1 融合深度网络的局部字典构建

本文构建空谱特征学习模型(spectral-spatial feature learning units, SSFL)^[32]来获取数据特征。每一个 SSFL 通过分层形式依次学习光谱特征和空间特征,最终获取高光谱图像的空谱特征。将 SSFL 叠加在一起,上一个 SSFLU 的输出作为下一个 SSFLU 的输入,形成一个多层的深度网络结构,即 SSN,该网络能够获得高光谱图像更优的空谱特征。

SSFLU 使用线性判别分析(Linear Discriminant Analysis, LDA)处理光谱特征学习的过程,空间特征学习是进行空间滤波,使用多个自适应空间滤波器对 LDA 的处理结果,获得同一区域图像的不同尺度表示。LDA 确保同一类像素具有相似的特性,而不管其在空间中的距离有多远,自适应空间滤波则是保证同一类内的相邻像素具有相似的特征。

LDA 通过最大化类间分散的同时最小化类内的分散来获得不同类别数据之间的最大区分度。对于 N 个训练样本 $\mathbf{X} = [x_1, x_2, \dots, x_N] \in R^{d \times N}$,将 K_{spe} 设为此阶段的滤波器数量, $\mathbf{W}_{spe} \in R^{K_{spe} \times d}$ 为滤波器,整体数据的均值 m 可以表示为:

$$m = \frac{1}{N} \sum_{n=1}^N \mathbf{W}_{spe}^T X_n^c \quad (1)$$

对于第 c 类数据,平均值 m_c 为:

$$m_c = \frac{1}{N_c} \sum_{n=1}^{N_c} \mathbf{W}_{spe}^T X_n^c \quad (2)$$

其中, N_c 是 c 类样本总数, X_n^c 为 c 类样本的第 n 个像素,类内离散度矩阵 \mathbf{S}_w 表示为:

$$\mathbf{S}_w = \sum_{c=1}^C p_c \frac{1}{N_c} \sum_{i=1}^{N_c} (\mathbf{W}_{spe}^T X_i^c - m_c) (\mathbf{W}_{spe}^T X_i^c - m_c)^T \quad (3)$$

其中, $p_c = \frac{N_c}{N}$, 类间离散度矩阵 \mathbf{S}_b 可以表示为:

$$\mathbf{S}_b = \sum_{c=1}^C p_c (m_c - m) (m_c - m)^T \quad (4)$$

使用一系列滤波器,最大限度地提高类间散射和类内散射^[33]的比率:

$$\max_{\mathbf{W}_{spe} \in R^{K_{spe} \times d'}} = \frac{\mathbf{W}_{spe}^T \mathbf{S}_b \mathbf{W}_{spe}}{\mathbf{W}_{spe}^T \mathbf{S}_w \mathbf{W}_{spe}} \quad (5)$$

特征向量对应的若干最大特征值 λ , 求解:

$$\mathbf{S}_b \mathbf{W}_{spe} = \lambda \mathbf{S}_w \mathbf{W}_{spe} \quad (6)$$

得出所对应的前 K_{spe} 个光谱特征向量 \mathbf{W}_{spe} , 光谱滤波器 \mathbf{W}_{spe} 可以利用滤波器对 HSI 数据归一化后的每一个像素进行处理形成新的数据集。

对于光谱特征学习的输出数据, SSFLU 使用自适应加权滤波器 (Adeptive Weighted Filter, AWF) 来提取空间特征信息。AWF 是一个块区域内的空间滤波器, 中心像素 (向量) 根据分配给其邻居的权值被生成的特征替换。自适应权重 $W_{spe}^{i,j}$ 可以表示为:

$$W_{spe}^{i,j} = \frac{S_{i,j}}{\sum_1^{m*m} S_{i,j}} \quad (7)$$

其中, $m * m$ 为滤波器的大小; 相似量度 $S_{i,j} =$

$\exp\left\{-\frac{\|p_0 - p_{i,j}\|^2}{\sigma}\right\}$; p_0 为中心像素; $p_{i,j}$ 为第 i 行

j 列像素; σ 可以自适应地确定为 $\sigma = \frac{1}{\text{std}(d)}$, 这里

$d_{(-1) * m+j} = \|p_0 - p_{i,j}\|^2$ 。一旦获得了权重, 通过加权累加相邻像素来生成一个新的中心像素表示, 通过多次堆叠形成新的数据集。在 AWF 中, 定义的滤波器是平滑滤波器, 权重由相似度来定义。这种情况下, 中心像素和其在同一类内的相邻像素之间的权值更大。另一方面, 在一个局部区域内的像素通常代表在 HSI 中相同的材料。因此, 在同一类中获得的像素会变得更相似。由此, AWF 确保了同一个类中的像素具有相似的特性。

对于得到的新数据集, 本文利用 KNN 算法来构建局部约束字典。K-近邻 (KNN) 分类器^[34] 是预测测试样本所属类别的最简单方法, 目的是在给定的空间中寻找与测试样本最接近的 K 个训练样本, 并将训练样本的类信息分配给测试样本。在本文中, 对于未知类别的待测样本 $\mathbf{y} = [y_1, y_2, \dots, y_d] \in R^{d \times 1}$ 和训练样本 $\mathbf{X} = [x_1, x_2, \dots, x_n] \in R^{d \times n}$, 使用欧氏距离来估计测试样本 \mathbf{y} 与训练样本 \mathbf{x}_n 之间的距离 d_n , 如式 (8) 所示:

$$d_n = \|\mathbf{y} - \mathbf{x}_n\|_2^2 \quad (8)$$

由此对 d_n 排序, 选取最小的 K 个 d_n 所对应的训练样本作为测试样本 \mathbf{y} 对应的局部约束字典。局部约束字典构建过程如图 1 所示。

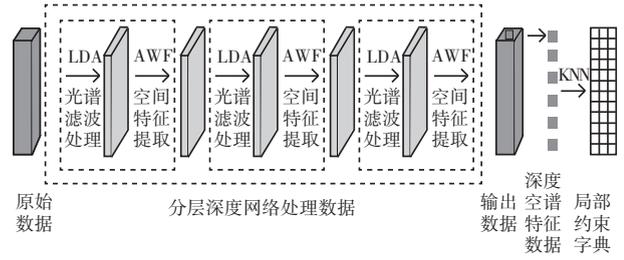


图 1 局部约束字典构建过程

Fig. 1 Construction process of locality-constrained dictionary

1.2 融合分层网络与局部约束字典的稀疏表示

稀疏表示分类方法 (SRC) 在高光谱图像分类中显现出来强大的能力。对于获得的基于分层局部约束的字典 $\mathbf{D} = \{\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_C\} \in R^{b \times N}$, 其中, b 为光谱带的数量, C 为类别数, $N = \sum_{i=1}^C N_i$ 是字典样本的总数, $\mathbf{D}_i = [d_{i1}, d_{i2}, \dots, d_{iN_i}] \in R^{d \times N_i}$ 为第 i 类子字典, $d_{ij} \in R^b$ 为第 i 类子字典中的第 j 个元素。对于任意给定的第 i 类测试样本 \mathbf{y} , 可由第 i 类子字典 \mathbf{D}_i 中样本的线性组合来表示, 即:

$$\mathbf{y} = d_{i1}\alpha_{i1} + d_{i2}\alpha_{i2} + \dots + d_{iN_i}\alpha_{iN_i} = \mathbf{D}_i\boldsymbol{\alpha}_i \quad (9)$$

其中, $\boldsymbol{\alpha}_i$ 为稀疏系数, 在实际应用中, 由于测试样本的未知性, 需要用整个字典 \mathbf{D} 来表示测试样本 \mathbf{y} , 即:

$$\mathbf{y} = \mathbf{D}\boldsymbol{\alpha} \quad (10)$$

其中, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_c]$ 为子字典对应的稀疏系数, $\boldsymbol{\alpha}$ 是一个稀疏矩阵, 即只有第 i 类训练样本所对应的系数为非零值, 通过计算约束问题得到 $\boldsymbol{\alpha}$:

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \|\boldsymbol{\alpha}\|_0, \text{ s.t. } \mathbf{y} = \mathbf{D}\boldsymbol{\alpha} \quad (11)$$

其中, $\|\cdot\|_0$ 表示 l_0 范数, 用来计算 $\boldsymbol{\alpha}$ 中的非零值, 上式求解是 NP (Nondeterministic Polynomial-time) 难问题^[35], SRC 使用正交匹配追踪算法 (Orthogonal Matching Pursuit, OMP)^[36] 求解, OMP 算法选取所有训练集区域迭代选择最优样本、使用所有类中的原子作为字典, 由于 HSI 样本之间具有较强的相关性, 在分类过程中会导致选择多个类中的原子用于线性表示, 而 SRC 的观点是测试样本应该由来自同一类的样本线性表示。因此, 本文使用类依赖的正交匹配追踪算法 (Class-dependent Orthogonal Matching Pursuit, cdOMP)^[25] 分类, 即分别将 OMP 算法应用于第 i 个子字典。在 cdOMP 中, 第 i 类的残差 r_i 是通过计算测试样本 \mathbf{y} 与重构样本 $\hat{\mathbf{y}}_i$ 之间的误差得到的。最后, 将测试样本分布到残差最小的第 i 类:

$$r_i(\mathbf{y}) = \arg \min_{i=1,2,\dots,c} \|\mathbf{y} - \hat{\mathbf{y}}_i\|_2 = \arg \min_{i=1,2,\dots,c} \|\mathbf{y} - \mathbf{D}\hat{\boldsymbol{\alpha}}_i\|_2 \quad (12)$$

在真实的高光谱数据中,局部区域像素存在同谱异类或同类异谱的形式,这些因素将严重影响联合稀疏表示模型的分类性能。相关参数(Correlation Coefficient, Cor)是一种用于确定2个变量相关性的有效度量标准,文献[18]指出不同像素之间的Cor用于确定像素之间是否属于同一类,同一类中的像素通常彼此具有高相关性,反之亦然。本文为客观地增加分层深度网络特征字典与测试样本之间的关联性,将融合联合稀疏表示与相关参数以平衡同谱异类或同类异谱所带来的分类不稳定性。给定测试样本 \mathbf{y} 和第 i 类分层深度网络特征字典 $\mathbf{D}_i = [d_{i1}, d_{i2}, \dots, d_{iN_i}] \in R^{d \times N_i}$,其中 d_{ij} 表示第 i 类第 j 个原子,那么一个字典原子 d_{ij} 与一个测试样本 \mathbf{y} 之间的相关系数 $\rho_{i,j}$ 为:

$$\rho_{i,j} = \frac{\text{cov}(d_{ij}, \mathbf{y})}{\sqrt{\text{var}(d_{ij})} \cdot \sqrt{\text{var}(\mathbf{y})}} = \frac{\sum_{z=1}^d ((d_{ij})_z - \mu_{d_{ij}})(y_z - \mu_y)}{\sqrt{\sum_{z=1}^d ((d_{ij})_z - \mu_{d_{ij}})^2} \cdot \sqrt{\sum_{z=1}^d (y_z - \mu_y)^2}} \quad (13)$$

其中, $\text{var}(d_{ij})$ 、 $\text{var}(\mathbf{y})$ 表示第 i 类第 j 个字典原子与测试样本 \mathbf{y} 之间的方差; $\mu_{d_{ij}}$ 和 μ_y 分别表示字典原子和测试样本的平均值。对所得的所有 ρ_i 进行排序,根据文献[18]选取前 k 个相关系数并取得相应的平均值作为当前字典原子和测试样本之间的相关系数 Cor_i 。公式如下:

$$Cor_i = \frac{1}{k}(\rho_{i1} + \rho_{i2} + \dots + \rho_{ik}) \quad (14)$$

最后,将基于分层深度网络局部字典的稀疏表示与相关系数结合,利用如下公式进行分类:

$$\text{class}(\mathbf{y}) = \arg \min_{i=1,2,\dots,c} (r_i(\mathbf{y}) + \beta(1 - Cor_i(\mathbf{y}))) \quad (15)$$

1.3 算法具体流程

给定高光谱数据,高光谱真实地物矩阵,测试样本,测试样本数据标签矩阵,测试样本索引矩阵,空谱网络层数,光谱滤波器,空间滤波次数,自适应加权滤波器AWF窗口矩阵 \mathbf{Winds} ,分层深度网络特征字典 \mathbf{D} ,类别数 C ,联合稀疏表示窗口大小 $Patch$,相关参数近邻点个数 q ,正则化参数 β 。基于分层网络与局部约束的高光谱图像分类方法流程具体如下。

算法:基于分层网络与局部约束的高光谱图像分类

输入:高光谱数据,高光谱真实地物矩阵,测试样本,测试样本数据标签矩阵,测试样本索引矩阵,空谱网络层数,光谱滤波器,空间滤波次数,自适应加权滤波器AWF窗口矩阵 \mathbf{Winds} ,分层深度网络特征字典 \mathbf{D} ,类别数 C ,联合稀疏表示窗口大小 $Patch$,相关参数近邻点个数 q ,正则化参数 β 。

输出:OA、AA、Kappa系数

步骤1 利用SSN学习空谱特征

1.1 利用LDA提取光谱特征;

1.2 计算出光谱滤波器 \mathbf{W}_{spe} ;

1.3 利用光谱滤波器 \mathbf{W}_{spe} 对高光谱数据进行归一化处理,形成新的数据集 $\mathbf{DataNew}$;

1.4 利用AWF学习空间特征;

1.5 计算空间特征自适应权重 \mathbf{W}_{spa} ;

1.6 利用空间特征自适应权重 \mathbf{W}_{spa} 对邻近像素进行加权求和;

1.7 多次堆叠形成新的空谱特征数据集。

步骤2 利用KNN构建分层位置约束字典

2.1 在LDA投影空间中计算测试样本 \mathbf{y} 和 \mathbf{x} 之间的欧氏距离;

2.2 选取 k 个最近的原子并找到相应的索引;

2.3 根据索引集形成基于局部约束的字典 \mathbf{D} 。

步骤3 利用cdOMP和相关系数进行分类

3.1 对每一个子字典 D_c 分别运用OMP算法;

3.2 利用公式 $\alpha_c = \arg \min \|\mathbf{y} - D_c \boldsymbol{\alpha}\|_2$ 计算每一类的稀疏系数;

3.3 利用公式 $r^c = \arg \min \|\mathbf{y} - D_c \boldsymbol{\alpha}_c\|_2$ 求解每一类的残差;

3.4 利用式(13)、式(14)计算每一类的字典原子和测试样本之间的相关系数;

3.5 利用式(15)进行分类。

2 实验结果与分析

为了验证本文算法的有效性,在2个高光谱图像数据集上进行实验,分别为Indian Pines数据集和Pavia University数据集^[32],并选择经典传统算法KNN、SRC、cdSRC和LSRC进行比较。本文使用总体准确率(OA)、平均准确率(AA)和Kappa系数(Kappa)^[37]三个评价标准来评价算法的分类性能。这里,OA表示正确分类的样本数与测试样本总数的比值,AA是衡量每一类OAs的平均值,Kappa是分类测试样本的百分比,就是由纯偶然的预期的协议数修正的,所有精度均通过5次重复实验获得。

在 2 个数据集上随机选择每个类别的 10% 的标记样本进行训练, 剩余样本用于测试。

2.1 在 Indian Pines 数据集上的实验结果

Indian Pines 数据集是印第安纳州西北部一个区域的高光谱图像。图像大小为 145×145 像素, 每个像素的空间分辨率为 20 m。AVIRIS 传感器在 $0.4 \sim 2.5 \mu\text{m}$ 的光谱范围内产生 220 个波段, 为降低实验误差通常去除 20 个吸水带将光谱带的数量降至 200^[38]。图 2 中给出了波段 17、27 和 50 组成的三波段伪彩色图和真实地面图。由图 2 可知, 该数据集包含 16 个真实类别, 其中大多数为农作物, 如玉米、大豆、小麦、燕麦等。在这个实验中, 剔除训练样本较少的类选择了 12 种作物, 具体样本划分见表 1。

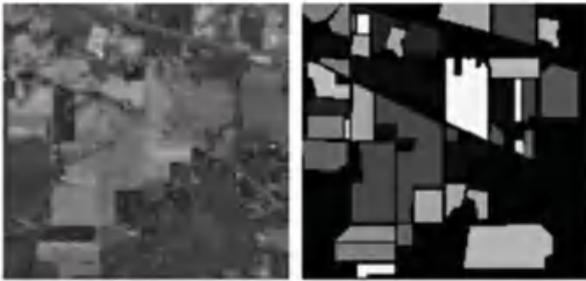


图 2 Indian Pines 数据集三波段伪彩色图和真实地面图

Fig. 2 Three band pseudo color map and real ground map of Indian Pines dataset

表 1 Indian Pines 数据集样本信息

Tab. 1 Indian Pines dataset sample information

名称	训练样本	测试样本	样本总数
Corn-notill	144	1 290	1 434
Corn-mintill	84	750	834
Corn	24	210	234
Grass-pasture	50	447	497
Grass-trees	75	672	747
Hay-windrowed	49	440	489
Soybean-notill	97	871	968
Soybean-mintill	247	2 221	2 468
Soybean-clean	62	552	614
Wheat	22	190	212
Woods	130	1 164	1 294
Buildings-G-T-R	38	342	380
总计	1 022	9 149	10 171

表 2 展示了 Indian Pines 数据集上不同算法的分类准确率, 通过比较 KNN、SRC、cdSRC、LSRC 与本文提出算法的 OA 、 AA 和 $Kappa$ 系数可以很清楚地看到, 本文算法具有最优的分类效果; 相较于传

统的 KNN 算法, 总体准确率 OA 提高了约 29%; 相较于相对传统的 cdSRC 算法, 总体准确率 OA 提高了大约 15%; 相较于较新的 LSRC 算法, 总体准确率 OA 提高了大约 9%。Indian Pines 数据集不同方法分类对照结果如图 3 所示。由图 3 可以清晰地看出, 与对照算法相比, SLSRC 算法的分类结果中噪音较少, 类间结构清晰。

表 2 Indian Pines 数据集相关算法分类准确率

Tab. 2 Classification accuracy of Indian Pines dataset correlation algorithm

名称	KNN	SRC	cdSRC	LSRC	SLSRC
Corn-notill	55.27	65.10	76.06	82.49	97.42
Corn-mintill	55.86	58.20	65.51	80.02	91.11
Corn	00.46	48.10	71.56	71.56	97.62
Grass-pasture	64.89	94.37	93.06	90.82	97.27
Grass-trees	100	53.91	97.61	96.42	97.26
Hay-windrowed	98.13	97.45	100	100	99.31
Soybean-notill	82.68	63.94	79.67	80.71	96.67
Soybean-mintill	74.27	75.76	81.17	90.00	97.58
Soybean-clean	46.90	68.88	76.49	90.59	96.10
Wheat	92.43	95.33	99.37	99.47	95.65
Woods	97.62	92.46	95.96	97.59	98.22
Buildings-G-T-R	70.22	72.28	73.09	72.80	87.92
OA	68.42	72.29	82.58	88.46	97.15
AA	59.43	73.53	83.58	79.61	96.07
$Kappa$	63.34	69.39	80.12	86.78	96.75

2.2 在 Pavia University 数据集上的实验结果

Pavia University 数据集是由帕维亚大学通过反射光学系统成像光谱仪 ROSIS 采集的帕维亚大学的城市图像, 各图像大小为 610×340 像素, 每个像素的空间分辨率为 1.3 m。ROSI 传感器在 $0.43 \sim 0.86 \mu\text{m}$ 的光谱范围内产生 115 个波段, 为降低实验误差通常去除 12 个最嘈杂的频段将光谱带的数量降至 103^[38]。图 4 中给出了 Pavia University 数据集三波段伪彩色图和真实地面图。由图 4 可知, 该数据集包含 9 个真实类别, 其中大多数建筑材料, 如沥青、砾石、裸土、彩绘金属板等。在实验中, 根据论文通常对 9 类真实数据选取 10% 作为训练样本, 总计 3 921 个, 其余 38 855 个数据作为测试样本, 具体样本划分见表 3。

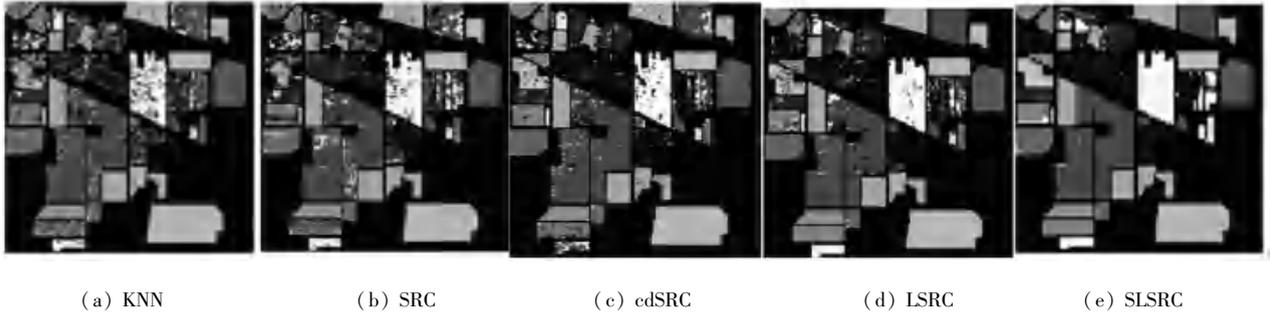


图3 Indian Pines 数据集不同方法分类对照图

Fig. 3 Comparison of different classification methods of Indian Pines dataset

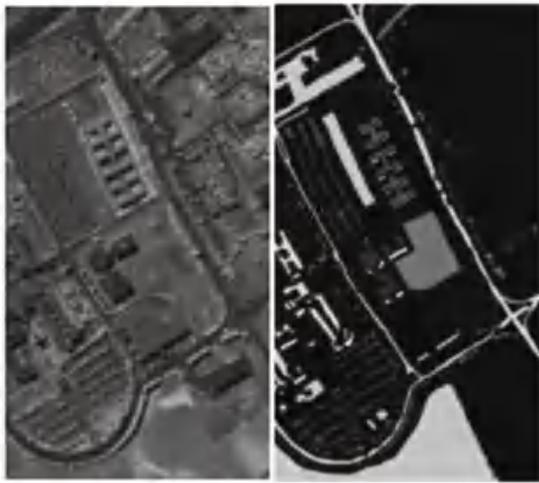


图4 Pavia University 数据集三波段伪彩色图和真实地面图

Fig. 4 Three band pseudo color map and real ground map of Pavia University dataset

表3 Pavia University 数据集样本信息

Tab. 3 Pavia University dataset sample information

名称	训练样本	测试样本	样本总数
Asphalt	548	6 083	6 631
Meadows	540	18 109	18 649
Gravel	392	1 707	2 099
Trees	524	2 540	3 064
Painted metal Sheets	265	1 080	1 345
Bare Soil	532	4 497	5 029
Bitumen	375	955	1 330
Self-Blocking Bricks	514	3 168	3 682
Shadows	231	716	947
总计	3 921	38 855	42 776

表4展示了Pavia University数据集上不同算法的分类准确率,通过比较KNN、SRC、cdSRC、LSRC与本文提出算法OA、AA和Kappa系数可以很清楚地看到,本文算法具有最优的分类效果,相较于传统

的KNN算法,总体准确率OA提高了约15%;相较于相对传统的cdSRC算法,总体准确率OA提高了大约13%;相较于较新的LSRC算法,总体准确率OA提高了大约9%。Pavia University数据集不同方法分类对照结果如图5所示。由图5可以清晰地看出,与对照算法相比,SLSRC算法的分类结果中噪音较少,类间结构清晰。

表4 Pavia University 数据集相关算法分类准确率

Tab. 4 Classification accuracy of Pavia University dataset correlation algorithm

名称	KNN	SRC	cdSRC	LSRC	SLSRC
Asphalt	78.97	78.18	90.58	90.63	99.31
Meadows	99.05	95.40	95.59	96.71	99.88
Gravel	60.45	62.46	68.60	72.31	99.57
Trees	79.15	85.46	86.11	89.55	99.74
Painted metal Sheets	99.17	99.66	99.83	99.83	100
Bare Soil	43.87	55.01	78.32	80.33	99.93
Bitumen	80.28	75.52	80.70	83.62	100
Self-Blocking Bricks	86.08	75.55	80.26	80.29	98.49
Shadows	93.77	88.14	99.53	99.76	99.88
OA	84.32	83.32	86.22	90.48	99.66
AA	80.09	79.50	89.62	88.12	99.65
Kappa	78.55	77.52	85.63	87.31	99.56

2.3 参数分析

在本节中,将分析参数如何影响SLSRC的性能。利用本文提出的SLSRC算法分类时,存在3个参数:稀疏度 S 、近邻点个数 K 和正则化参数 λ 影响实验结果。本文依据文献[18],固定 S 和 K ,采取控制变量法调整第三个参数 λ ,通过比较OA的值选取最优的参数。在Indian Pines数据集上,固定 $S=20$, $K=6$,在Pavia University数据集上,固定 $S=20$, $K=6$,分别在2个数据集上选取 λ ,如图6所示,给出2个实验的实验结果。

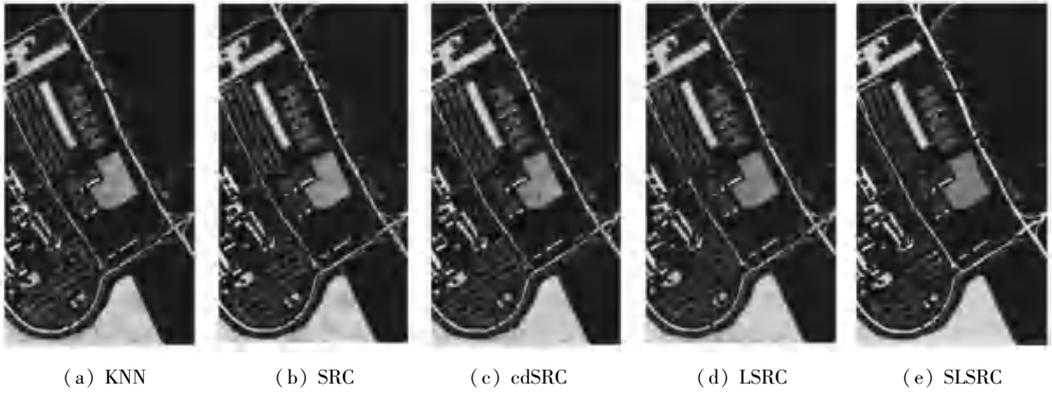
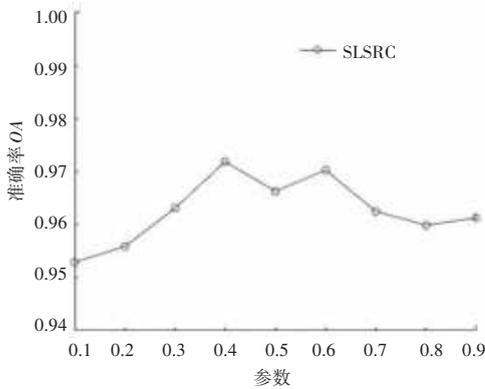
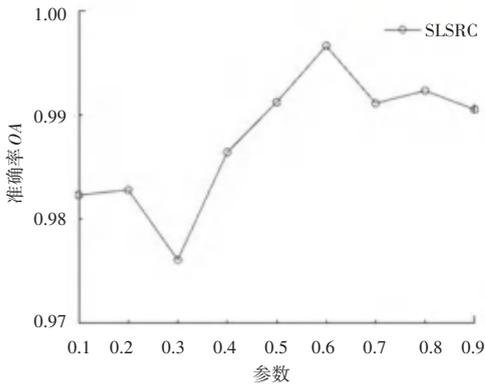


图 5 Pavia University 数据集不同方法分类对照图

Fig. 5 Comparison of different classification methods in Pavia University dataset



(a) Indian Pines 数据集



(b) Pavia University 数据集

图 6 不同参数取值在 2 个数据集对分类准确率的影响

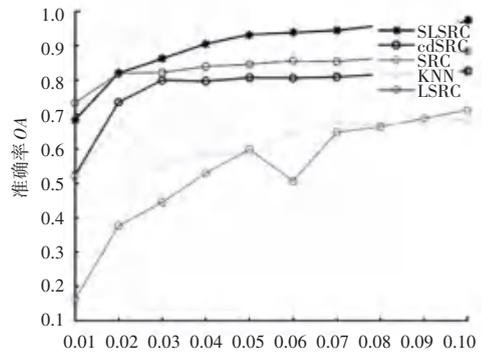
Fig. 6 Influence of different parameter values on classification accuracy in two data sets

从图 6 可以看出,在 Indian Pines 数据集上当 $\lambda = 0.4$ 时,OA 取得最大值,即 $\lambda = 0.4$ 时分类结果精度最高;在 Pavia University 数据集上当 $\lambda = 0.6$ 时,OA 取得最大值,即 $\lambda = 0.6$ 时本算法的分类精度最高。本算法的性能可以通过改变参数进行调整。

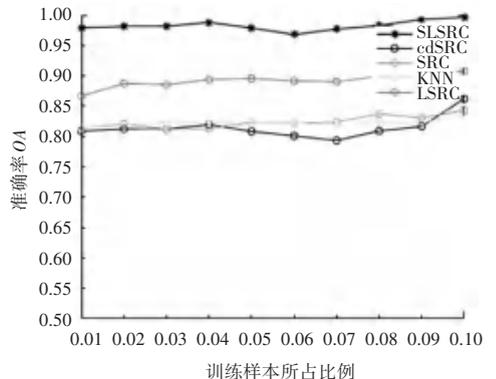
2.4 训练样本选取的影响

为了验证 KNN、SRC、cdSRC、LSRC 以及本文算法在不同训练样本个数下的分类性能,分别在

Indiana Pines 和 Pavia University 两个数据集上进行实验。在 Indian Pines 和 Pavia University 数据集上都分别随机选取该类样本数的 1%、2%、3%、4%、5%、6%、7%、8%、9%、10% 作为训练样本,每类剩下的样本用作测试样本。将实验的总体分类准确度作为评价指标。实验结果如图 7 所示。



(a) Indian Pines 数据集



(b) Pavia University 数据集

图 7 相同训练样本个数下各种算法的分类准确率

Fig. 7 Classification accuracy of various algorithms under the same number of training samples

根据图 7 得出,在 Indiana Pines 和 Pavia University 两个数据集上选取总样本的 1%~10% 作为训练样本时,分类的准确率逐渐上升,其中,当训练样本占

总样本的10%时准确率最高,故本文选取每类样本的10%作为训练样本,其余样本作为测试样本。由图7可以清晰地看出,从样本的1%~10%本文提出算法的准确率都明显高于经典的SRC算法、KNN算法和较为新颖的LSRC算法,再一次证明了本文算法的有效性。

3 结束语

本文提出了基于分层网络与局部约束的高光谱图像分类方法,首先利用分层深度网络提取高光谱图像的空谱特征信息,得到新数据集,然后计算原子间的欧氏距离,并根据K近邻算法选取前K个距离最近的原子得出基于局部约束的字典,最后计算训练样本和测试样本间的相关系数,结合基于局部约束的字典与稀疏表示进行分类。选取2个高光谱数据集实验,由本文提出算法与KNN、SRC、cdSRC、LSRC算法的对比实验表明,本算法具有更优的分类性能。同时,在不同训练样本的选择下进行了分析对比,由此进一步验证了新算法具有更稳定、更好的分类性能。本算法主要论证了空谱信息结合在高光谱图像分类中的重要作用。在进一步的研究中,将针对局部约束字典的构建进行更深入的研究,更好地利用表示学习算法对高光谱图像进行分类。

参考文献

[1] 成宝芝,赵春晖,张丽丽,等.联合空间预处理与谱聚类的协同稀疏高光谱异常检测[J].光学学报,2017,37(04):304-314.

[2] LI J, MARPU P R, PLAZA A, et al. Generalized composite kernel framework for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(9): 4816-4829.

[3] RESHMA S, VENI S. Comparative analysis of classification techniques for crop classification using airborne hyperspectral data [C]//2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET). Chennai, India: IEEE, 2017: 2272-2276.

[4] WEI Lifei, YU Ming, LIANG Yajing, et al. Precise crop classification using spectral-spatial-location fusion based on conditional random fields for UAV-Borne hyperspectral remote sensing imagery[J]. International Journal of Remote Sensing, 2019, 11(17): 2011.

[5] GAIKWAD S V, VIBHUTE A D, KALE K V, et al. Identification and classification of water stressed crops using hyperspectral data: A case study of Paithan Tehsil [C]//Proceedings of 2nd International Conference on Communication, Computing and Networking. Singapore:Springer, 2019: 911-919.

[6] CABALLERO D, CALVINI R, AMIGO J M. Hyperspectral imaging in crop fields: precision agriculture[M]//Data Handling in Science and Technology.USA:Elsevier, 2020, 32: 453-473.

[7] CUI Jing, YAN Bokun, DONG Xinfeng, et al. Temperature and

emissivity separation and mineral mapping based on airborne TASI hyperspectral thermal infrared data [J]. International Journal of Applied Earth Observation and Geoinformation 2015, 40 :19-28.

[8] CAMPS-VALLS G, TUIA D, BRUZZONE L, et al. Advances in hyperspectral image classification: earth monitoring with statistical learning methods[J]. IEEE Signal Processing Magazine, 2013, 31(1): 45-54.

[9] LUFT L, NEUMANN C, FREUDE M, et al. Hyperspectral modeling of ecological indicators—a new approach for monitoring former military training areas[J]. Ecological Indicators, 2014, 46: 264-285.

[10] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 31(2): 210-227.

[11] HUO Lianzhi, ZHAO Lijun, TANG Ping. Hyperspectral image classification with sparse representation classifier and active learning [C]//2016 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Los Angeles, CA, USA;IEEE, 2016: 1-5.

[12] TOKSÖZ M A, ULUSOY I. Hyperspectral image classification via basic thresholding classifier [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(7): 4039-4051.

[13] GAN Le, DU Peijun, XIA Junshi, et al. Kernel fused representation-based classifier for hyperspectral imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 684-688.

[14] MA Li, CRAWFORD M M, TIAN Jinwen. Local manifold learning-based k-nearest-neighbor for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(11): 4099-4109.

[15] 刘勇进,刘梅娇,张伟伟.支持向量机推广拉格朗日方法的探究[J].辽宁师范大学学报(自然科学版),2019,42(01):5-15.

[16] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification using dictionary-based sparse representation [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3973-3985.

[17] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification via kernel sparse representation [C]//2011 18th IEEE International Conference on Image Processing. Brussels, Belgium: IEEE, 2011: 1233-1236.

[18] TU Bing, ZHANG Xiaofei, KANG Xudong, et al. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(3): 340-344.

[19] TU Bing, KUANG Wenlan, ZHAO Guangzhe, et al. Hyperspectral image classification by combining local binary pattern and joint sparse representation [J]. International Journal of Remote Sensing, 2019, 40(24): 9484-9500.

[20] LI Wei, DU Qian, ZHANG Fan, et al. Collaborative-representation-based nearest neighbor classifier for hyperspectral imagery [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 12(2): 389-393.

[21] YU Kai, ZHANG Tong, GONG Yihong. Nonlinear learning using local coordinate coding [C]//Advances in Neural Information Processing Systems. Vancouver, British Columbia, Canada: dblp, 2009, 22: 2223-2231.

[22] MA Jiayi, ZHAO Ji, JIANG Junjun, et al. Locality preserving matching [J]. International Journal of Computer Vision, 2019, 127

- (5): 512–531.
- [23] WANG Jinjun, YANG Jianchao, YU Kai, et al. Locality constrained linear coding for image classification [C]// 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Francisco, CA, USA: IEEE, 2010: 3360–3367.
- [24] ZHANG Y, MA Y, DAI X, et al. Locality-constrained sparse representation for hyperspectral image classification [J]. *Information Sciences*, 2021, 546: 858–870.
- [25] CUI Minshan, PRASAD S. Class-dependent sparse representation classifier for robust hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 53(5): 2683–2695.
- [26] CAO Xianghai, GE Yiming, LI Renjie, et al. Hyperspectral imagery classification with deep metric learning [J]. *Neurocomputing*, 2019, 356: 217–227.
- [27] ZHANG Zixing, GEIGER J, POHJALAINEN J, et al. Deep learning for environmentally robust speech recognition: An overview of recent developments [J]. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2018, 9(5): 49.1–49.28.
- [28] IZBASSAROVA A, DUISEMBAY A, JAMES A P. Speech recognition application using Deep Learning Neural Network [M]//JAMES A. Deep learning classifiers with memristive networks. modeling and optimization in science and technologies. Cham; Springer, 2020, 14: 69–79.
- [29] YOUNG T, HAZARIKA D, PORIA S, et al. Recent trends in deep learning based natural language processing [J]. *IEEE Computational Intelligence Magazine*, 2018, 13(3): 55–75.
- [30] RATLE F, CAMPS-VALLS G, WESTON J. Semisupervised neural networks for efficient hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(5): 2271–2282.
- [31] ZHONG Yanfei, ZHANG Liangpei. An adaptive artificial immune network for supervised classification of multi-/hyperspectral remote sensing imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3): 894–909.
- [32] ZHOU Yicong, WEI Yantao. Learning hierarchical spectral-spatial features for hyperspectral image classification [J]. *IEEE Transactions on Cybernetics*, 2015, 46(7): 1667–1678.
- [33] 刘德山, 楚永贺, 闫德勤. 正则化流形信息极端学习机 [J]. *通信学报*, 2016, 37(11): 57–67.
- [34] SAMANIEGO L, BARDOSSY A, SCHULZ K. Supervised classification of remotely sensed imagery using a modified k-NN technique [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(7): 2112–2125.
- [35] DAVIS G, MALLAT S, AVELLANEDA M. Adaptive greedy approximations [J]. *Constructive approximation*, 1997, 13(1): 57–98.
- [36] MALLAT S G, ZHANG Zhifeng. Matching pursuits with time-frequency dictionaries [J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3397–3415.
- [37] RICHARDS J A, JIA X. Remote sensing digital image analysis [M]. 3rd ed. Berlin, Germany: Springer-Verlag, 2006.
- [38] GUALTIERI J A, CROMP R F. Support vector machines for hyperspectral remote sensing classification [C]//27th AIPR Workshop: Advances in Computer-Assisted Recognition. Washington, DC: Society of Photo-Optical Instrumentation Engineers (SPIE), 1999, 3584: 221–232.

(上接第60页)

- [3] BOX G E P, PIERCE D A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models [J]. *Journal of the American Statistical Association*, 1970, 65(332): 1509–1526.
- [4] ENGLE R F. Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation [J]. *Econometrica*, 1982, 50(4): 987–1007.
- [5] BOLLERSLEV T. Generalized autoregressive conditional heteroskedasticity [J]. *North-Holland*, 1986, 31(3): 307–327.
- [6] FRANSES P H, DIJK V D. Forecasting stock market volatility using (non-linear) garch models [J]. *Journal of Forecasting*, 1996, 15(3): 229–235.
- [7] ADEBIYI A A, ADEWUMI A O, AYO C K. Comparison of arima and artificial neural networks models for stock price prediction [J]. *Journal of Applied Mathematics*, 2014, 2: 1–7.
- [8] PATEL J, SHAH S, THAKKAR P, et al. Predicting stock market index using fusion of machine learning techniques [J]. *Expert Systems with Applications*, 2015, 42(4): 2162–2172.
- [9] 邓乃扬, 田英杰. 数据挖掘中的新方法-支持向量机 [M]. 北京: 科学出版社, 2004.
- [10] LEE S W, KIM H Y. Stock market forecasting with super-high dimensional time-series data using convlstm, trend sampling, and specialized data augmentation [J]. *Expert Systems With Applications*, 2020, 161(1): 113704.
- [11] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural computation*, 1997, 9(8): 1735–1780.
- [12] FELIX G A, SCHMIDHUBER J, CUMMINS F. Learning to forget: Continual prediction with LSTM [J]. *Neural Computation*, 2000, 12(10): 2451–2471.
- [13] KIM H Y, WON C H. Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple garch-type models [J]. *Expert Systems with Applications*, 2018, 103(8): 25–37.
- [14] WEI Bao, JUN Yue, Yulei Rao. A deep learning framework for financial time series using stacked auto encoders and long-short term memory [J]. *Plos One*, 2017, 12(7): 1–24.
- [15] CHUNG H, SHIN K S. Genetic algorithm-optimized long short-term memory network for stock market prediction [J]. *Sustainability*, 2018, 10(10): 1–18.
- [16] 王宇胜, 陈德旺, 蔡俊鹏, 等. 基于 LSTM-SVR 的锂电池健康状态预测研究 [J]. *电源技术*, 2020, 44(12): 1784–1787.
- [17] 田贤忠, 顾思义, 胡安娜. 结合模糊控制的时序数据预测循环神经网络 [J]. *小型微型计算机系统*, 2021, 42(02): 241–245.
- [18] 史建楠, 邹俊忠, 张见, 等. 基于 DMD-LSTM 模型的股票价格时间序列预测研究 [J]. *计算机应用研究*, 2020, 37(03): 662–666.
- [19] LEE C H L, LIU A, CHEN W S. Pattern discovery of fuzzy time series for financial prediction [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2006, 18(5): 613–625.
- [20] NARANJO R, SANTOS M. Fuzzy candlesticks forecasting using pattern recognition for stock markets [M]//GRANA M, LÓPEZ-GUEDE J, ETXANIZ O, et al. International Joint Conference SOCO'16-CISIS'16-ICEUTE'16. SOCO 2016, CISIS 2016, ICEUTE 2016. Advances in Intelligent Systems and Computing. Cham; Springer, 2016, 527: 323–333.