基于多尺度 CNN 模型的多时相 PolSAR 图像作物分类

张伟涛1,王 敏1,郭 交2

(1. 西安电子科技大学 电子工程学院,陕西 西安710071;2. 西北农林科技大学 机械与电子工程学院,陕西 杨凌712100)

摘 要:农作物分类是偏振合成孔径雷达(PolSAR)数据的重要应用之一。由于单时相PolSAR数据获取的信息有限,因此,采用多时相PolSAR数据,其含有农作物生长周期更丰富的特征信息。针对多时相PolSAR数据在极化特征分解时造成的"维数灾难"问题,提出了一种非负性约束稀疏自编码器(NC-SAE)的特征压缩方法,用于对分解后的特征数据进行压缩,以获得分类所需的有效特征。此外,构建了一种多尺度特征分类网络(MSFCN),该网络可以提高农作物的分类性能,且优于目前传统的卷积神经网络和支持向量机方法。通过使用欧空局提供的数据进行仿真实验,对分类结果进行性能评估,并与传统方法比较。实验结果表明:所提的方法具有很好的农业应用前景。

Multi-scale CNN Model for Crop Classification with Multi-temporal Fully PolSAR Images

ZHANG Weitao¹, WANG Min¹, GUO Jiao²

(1.School of Electronic Engineering, Xidian University, Xi'an 710071, Shaanxi, China; 2.College of Mechanical and Electronic Engineering, Northwest A & F University, Yangling 712100, Shaanxi, China)

Abstract: Crop classification is one of the most significant applications of polarimetric synthetic aperture radar (PolSAR) data. Owing to the limited information obtained by single-temporal PolSAR data, multi-temporal data are used in this paper to further provide ample information within various crop growing stages. However, the polarization scattering decomposition of multi-temporal PolSAR data easily causes "dimension disaster". In view of this, a neural network of sparse auto-encoder with non-negativity constraints (NC-SAE) is proposed to compress the data, yielding efficient features for accurate classification. A novel classifier of multi-scale feature classification network (MSFCN) is constructed to improve the classification performance, which is proved to be superior to the popular classifiers of convolutional neural networks (CNN) and supper vector machine (SVM). The performances of the proposed method are evaluated and compared with the traditional methods by using the simulated Sentinel-1 data provided by European Space Agency (ESA). The classification results indicate that the proposed method has a good prospect for agricultural applications.

Key words: crop classification; polarimetric synthetic aperture radar (PolSAR); data compression; autoencoder; multi-scale feature classification network (MSFCN)

0 引言

农作物分类在农业遥感监测中起着重要的作用,是进一步监测农作物生长及产量的前提[14]。因此,农作物分类对于指导农业生产、合理分配农业

资源、保障国家粮食安全具有重要意义[5-7]。

随着遥感技术及其理论的不断进步和发展,已 广泛应用于农作物普查、生长监测、产量预测和灾 害评估等农业领域^[8-10]。偏振合成孔径雷达

收稿日期:2022-03-01;修回日期:2022-03-28

基金项目:国家自然科学基金(62071350)

作者简介: 张伟涛(1983—), 男, 博士, 教授, 博士生导师, 主要研究方向为盲信号处理、张量分析和机器学习与故障诊断。

(Polarimatric Synthetic Aperture Radar, PolSAR)作为微波遥感系统中一种主动遥感技术,具有其他遥感技术无法比拟的优势,其工作条件不受天气和气候限制[11]。近年来,农作物分类研究大多采用单时相 PolSAR数据,然而,由于不同农作物间相同的长势状况,单一时相的 PolSAR 图像很难识别出不同的农作物类别,尤其是在播种时期[12-13]。因此,有必要采集多时相 PolSAR数据用于农作物分类,从而提高分类精度。

由于对多时相全极化PolSAR数据进行极化特 征分解后的数据直接分类会出现所谓的"维数灾难" 问题,因此,对多时相数据极化分解后的特征进行降 维成为一项重要的工作。主成分分析法(Principle Component Analysis, PCA)[14-15]和局部线性嵌入法 (Locally Linear Embedded, LLE)[16-17] 是解决"维数 灾难"问题常用的特征压缩方法。PCA是一个线性 的数据处理方法,但实际工程中大多数问题都是非 线性的;LLE可以自动从高维数据中提取非线性的 低维特征,但对异常值非常敏感。近年来,随着深度 学习的发展,出现了一些成熟的神经网络结构(如自 编码器[18-19]、稀疏自编码器[20-21]),在特征压缩和图像 分类方面都具有良好的性能。然而,稀疏自编码器 的稀疏性在提取有效分类特征时并没有得到充分的 利用,并且常见的传统卷积神经网络(Convolutional Neural Networks, CNN)[22-23]和支持向量机(Supper Vector Machine, SVM)分类器[24-25]在分类时也不能 获取到压缩特征的多尺度信息。基于上述缺点,农 作物分类性能不能达到实际应用水平。

为了利用多时相 PolSAR 数据对农作物进行分类并且解决"维数灾难"的问题,首先采用了一种非负性约束稀疏自编码器(Sparse Auto-Encoder with Non-negativity Constraints, NC-SAE) 网络进行特征降维,提取有效的极化特征信息。然后,构建了一个多尺度特征分类网络(Multi-scale Feature Classification Network, MSFCN)实现农作物的分类识别,大幅提高了农作物的分类精度。

1 方法

1.1 PolSAR数据结构

全极化合成孔径雷达用于接收目标的后向散射信号,以HH、HV、VH和VV这4种组合方式测量幅值和相位,其中H为水平模式,V为垂直模式。采集

的每个像素的散射信息用一个 2×2 的复矩阵S表示,这些复数关系到入射电场和散射电场:

$$S = \begin{bmatrix} S_{\text{HH}} & S_{\text{HV}} \\ S_{\text{VH}} & S_{\text{VV}} \end{bmatrix} \tag{1}$$

式中: S_{VH} 为垂直发射和水平接收的极化散射因子,同理可定义式中其他参数。

通过对散射矩阵矢量化可以得到目标特征向量,由于PolSAR数据是复对称数据,符合后向散射互易定理,可以将 S_{HV} 近似等于 S_{VH} ,因此,偏振散射矩阵可以重写为Lexicographic散射向量:

$$\boldsymbol{h} = \begin{bmatrix} S_{\text{HH}} & \sqrt{2} S_{\text{HV}} & S_{\text{VV}} \end{bmatrix}^{\text{T}} \tag{2}$$

 S_{HV} 前的尺度因子 $\sqrt{2}$ 的目的是保证跨度计算的一致性。由此计算的偏振协方差矩阵C表示如下:

$$C = hh^{*T} =$$

$$\begin{bmatrix} |S_{\text{HH}}|^2 & \sqrt{2} S_{\text{HH}} S_{\text{HV}}^* & S_{\text{HH}} S_{\text{vv}}^* \\ \sqrt{2} S_{\text{HV}} S_{\text{HH}}^* & 2|S_{\text{HV}}|^2 & \sqrt{2} S_{\text{HV}} S_{\text{VV}}^* \\ S_{\text{VV}} S_{\text{HH}}^* & \sqrt{2} S_{\text{VV}} S_{\text{HV}}^* & |S_{\text{VV}}|^2 \end{bmatrix}$$
(3)

式中:上标*为复数的共轭。

1.2 非负性约束稀疏自编码器(NC-SAE)

NC-SAE是在自编码器的基础上发展而来,是数据表征的无监督学习算法,其目的是使输出值尽可能接近输入值。单层自编码器网络的基本结构由3部分组成:编码器、激活层、解码器。自编码器网络采用最速下降法进行网络训练,最终实现目标函数的最小化,其目标函数为输入与输出之间的重构误差,表示如下:

$$J_{\text{mse}} = \frac{1}{2Q} \sum_{q=1}^{Q} \sum_{i=1}^{n} \left[x_i(q) - z_i(q) \right]^2$$
 (4)

式中:Q为训练样本数;x(q)为第q个样本的输入数据;z(q)为第q个样本的重构输出。

NC-SAE 是在自编码器的目标函数上增加2个约束项进行实现。第一个约束项为稀疏约束:

$$\Omega_{\rm s} = \sum_{i=1}^{m} \rho \log \left(\frac{\rho}{\overline{\rho}_i} \right) + (1 - \rho) \log \left(\frac{1 - \rho}{1 - \overline{\rho}_i} \right) \quad (5)$$

该约束使网络训练过程具有较快的收敛速度^[19]。稀疏约束项的目的是通过限制隐藏层的激活神经元个数来增加网络的稀疏性,通常使用KL(Kullback-Leibler)散度函数表示。

可以看出: 当 ρ (稀疏参数)和 $\bar{\rho}$ (平均激活值)趋于相等时, Ω ,趋于0; 当两者相差越大时, Ω ,较大。

第2个约束项为非负性约束,其有利于避免网络训练过程中的过拟合现象,计算式如下:

$$\Phi_{w} = \frac{1}{2} \sum_{l=1}^{L} \sum_{i=1}^{m} \sum_{j=1}^{n} [\phi(w_{ji}^{(l)})]$$
 (6)

$$\phi(w_{ji}^{(l)}) = \begin{cases} (w_{ji}^{(l)})^2, w_{ji} < 0\\ 0, w_{ji} \ge 0 \end{cases}$$
 (7)

式中:w为权值;l为层数。

综上所述,NC-SAE的目标函数表示如下:

$$E = J_{\text{mse}} + \alpha \Phi_w + \beta \Omega_s \tag{8}$$

式中: α 为非负性约束项的系数; β 为稀疏约束项的系数。

采用最速下降法更新式(8)目标函数中的权重和偏置,计算式如下:

$$w(k+1) = w(k) - \eta \frac{\partial E}{\partial w(k)}$$

$$b(k+1) = b(k) - \eta \frac{\partial E}{\partial b(k)}$$
(9)

式中: k为迭代次数; n 为学习率。

采用误差反向传播算法计算式(9)中的偏导数。 在解码过程时,目标函数对权值的偏导数为

$$\frac{\partial E}{\partial w_{ii}^{(2)}} = \frac{\partial J_{\text{mse}}}{\partial w_{ii}^{(2)}} + \alpha \frac{\partial \Phi_{\text{w}}}{\partial w_{ii}^{(2)}} + \beta \frac{\partial \Omega_{\text{s}}}{\partial w_{ii}^{(2)}}$$
(10)

为了阐明偏导数的计算过程,将神经元误差 δ 定义为目标函数对每个神经元权值的导数,即 $\delta \triangle \partial E/\partial a$,使用链式法则求解 $\delta^{(2)}$ 如下:

$$\begin{split} \delta_{i}^{(2)} &= \frac{\partial J_{\text{mse}}}{\partial z_{i}} \frac{\partial z_{i}}{\partial a_{i}^{(2)}} = \\ &= \frac{1}{Q} \sum_{q=1}^{Q} \left[z_{i}(q) - x_{i}(q) \right] f' \left[a_{i}^{(2)}(q) \right] \end{split} \tag{11}$$

式中: $f'(\bullet)$ 为 $f(\bullet)$ 的偏导数。

 $f(\cdot)$ 是一个 sigmoid 函数, 一般选取 logsig 函数, 如下所示:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{12}$$

相似地,编码过程的神经元误差 $\delta_i^{(1)}$ 可计算如下:

$$\delta_{i}^{(1)} = \sum_{j=1}^{n} \frac{\partial J_{\text{mse}}}{\partial a_{j}^{(2)}} \frac{\partial a_{j}^{(2)}}{\partial y_{i}} \frac{\partial y_{i}}{\partial a_{i}^{(1)}} + \beta \frac{\partial \Omega_{\text{s}}}{\partial y_{i}} \frac{\partial y_{i}}{\partial a_{i}^{(1)}} = f'(a_{i}^{(1)}) \sum_{j=1}^{n} \delta_{j}^{(2)} w_{ji}^{(2)} + \frac{\beta}{Q} \sum_{q=1}^{Q} f'[a_{i}^{(1)}(q)] \left(\frac{1-\rho}{1-\bar{\rho}_{i}} - \frac{\rho}{\bar{\rho}_{i}}\right)$$

$$i = 1, 2, ..., m$$
(13)

此时,式(10)可表示为

$$\frac{\partial E}{\partial w_{ii}^{(2)}} = \delta_i^{(2)} y_j + \alpha r(w_{ij}^{(2)})$$
 (14)

然后,对编码过程的偏导数求解如下:

$$\frac{\partial E}{\partial w_{ii}^{(1)}} = \delta_i^{(1)} x_j + \alpha r(w_{ij}^{(1)})$$
 (15)

编码过程和解码过程目标函数对偏置的导数 计算如下:

$$\frac{\partial E}{\partial b^{(l)}} = \delta^{(l)}, l = 1, 2 \tag{16}$$

1.3 多尺度特征分类网络

提出的 MSFCN 的网络结构如图 1 所示,其主要包括 3 个部分:多尺度特征提取、特征融合、分类。首先,利用卷积层中多个不同大小的卷积核提取不同尺度的特征信息;然后,将获取的不同尺度的特征信息使用 concat 层进行融合作为分类层的输入数据;最后,采用 softmax 层进行分类。因此, MSFCN不仅利用卷积层中的不同卷积核提取多尺度特征信息,而且可以捕捉到特征图之间的细微差别。

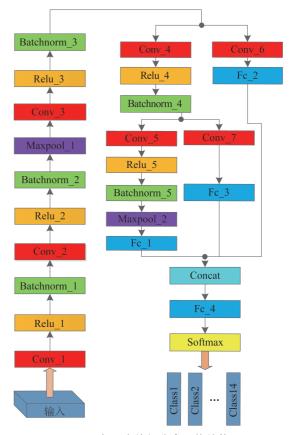


图 1 多尺度特征分类网络结构

Fig. 1 Architecture of MSFCN

2 实验及结果

2.1 实验数据介绍

使用的实验数据由欧洲航天局提供,主要用于评估所提方法的分类性能。实验区域位于加拿大萨斯克切温省东南部的 Indian Head 小镇,是一个约为 14 km×19 km 的矩形区域。该区域共包含 14 种不同类型的农作物和一个"非农作物"类别,"非农作物"类别可能是城镇、道路或天然植被区等非农作物地物。实验区域各农作物数据的具体信息见表1。

表 1 研究区农作物类型及其信息统计

Tab. 1 Information statistics of crops in the study area

文缩写	像素数量	44 Jaly 25 40 /1 2	1.11.707
	かかみ里	种植面积/hm²	占比/%
Unk	1 323 612	13 236	39.12
Len	217 186	2 172	6.42
Duw	101 299	1 013	2.99
Spw	577 109	5 771	17.05
Fip	255 108	2 551	7.54
Oat	70 643	706	2.09
Can	459 096	4 591	13.57
Gra	23 452	235	0.69
Mip	15 799	158	0.47
Mih	28 756	288	0.85
Bar	108 133	1 081	3.20
Suf	22 445	224	0.66
Fla	131 296	1 313	3.88
Cas	47 202	472	1.39
Chf	2 682	27	0.08
_	3 383 818	33 838	100.00
	Len Duw Spw Fip Oat Can Gra Mip Mih Bar Suf Fla Cas	Len 217 186 Duw 101 299 Spw 577 109 Fip 255 108 Oat 70 643 Can 459 096 Gra 23 452 Mip 15 799 Mih 28 756 Bar 108 133 Suf 22 445 Fla 131 296 Cas 47 202 Chf 2 682	Len 217 186 2 172 Duw 101 299 1 013 Spw 577 109 5 771 Fip 255 108 2 551 Oat 70 643 706 Can 459 096 4 591 Gra 23 452 235 Mip 15 799 158 Mih 28 756 288 Bar 108 133 1 081 Suf 22 445 224 Fla 131 296 1 313 Cas 47 202 472 Chf 2 682 27

实验所用的 PolSAR 数据是利用欧空局发射的 Radarsar-2 卫星采集的真实数据,通过模拟还未发射的 Sentinel-1 系统参数而生成的仿真数据。数据采集时间分别是 2009年4月21日、5月15日、6月8日、7月2日、7月26日、8月19日和9月12日,这7个时间段的 PolSAR数据几乎涵盖了实验区域所有农作物的从播种到收割的整个生长周期。对单个时相的 PolSAR数据使用极化特征分解方法进行特征分解,可以获得36维特征。因此,7个时相的 PolSAR数据一共可以获得252维特征信息。

2.2 分类结果评估参数

为了对分类结果进行精确的评估与分析,使用

整体分类精度(Overall Accuracy,OA)和 Kappa 系数进行结果对比。其中,整体分类精度 OA表示正确分类的样本数与样本总数之比,具体计算式如下:

$$OA = \frac{M}{N} \tag{17}$$

式中: M 为分类正确的样本数; N 为所有样本的总数。

Kappa 系数:常见计算分类精度的算法,来源于一致性检验,用于评价分类算法的分类性能,它是衡量预测输出与地面真实值一致性的标准,有效避免了因某一类目标地物分类精度高而导致整体分类精度高,进而误以为模型分类效果好的情况。整体分类精度仅涉及正确预测的样本数,与之不同的是,Kappa 系数考虑了位于混淆矩阵非对角线上的各种缺失和误分类样本,其计算式如下:

$$k_{\text{Kappa}} = \frac{OA - P}{1 - P}, \ P = \frac{1}{N^2} \sum_{i}^{K} Z_{ii} Z_{ii}$$
 (18)

式中:OA 为整体分类精度;N为待分类目标的样本总数;K为待分类目标的类别数;Z为分类算法的混淆矩阵; Z_i 为混淆矩阵第i行所有列的值之和; Z_i 为混淆矩阵第i列所有行的值之和。

2.3 实验结果及分析

本文对提出的特征降维方法、分类网络与传统的降维方法和分类方法进行了比较分析。首先利用所提的NC-SAE以及传统的LLE、PCA、S-SAE等特征降维方法,对极化分解后的252维特征进行降维,从而获得9维特征;然后将降维后的9维特征分别输入SVM、CNN和MSFCN分类器进行分类,每个分类器的训练样本选择总样本的1%。

不同分类器的分类结果和误差如图 2 所示。对于 CNN和MSFCN分类网络,其输入样本尺寸也会影响农作物的分类性能,因此,对不同输入样本大小下的分类结果也进行了比较,整个实验结果见表 2。

结合图2和表2中的分类结果,得出如下结论:

1)与传统的LLE、PCA降维方法相比,使用NC-SAE和S-SAE降维方法获取的特征信息进行分类的农作物总体分类精度提高了6%以上,虽然NC-SAE和S-SAE的分类精度几乎相同,但是这2个自编码器的网络结构不同。提出的NC-SAE是一个单层网络,而S-SAE是将3个自编码器依次连接而成的三层网络,因此,NC-SAE的计算复杂度更低。

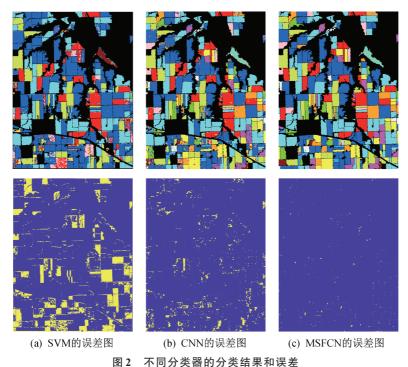


图 2 小问刀关品的刀关组未和误左

Fig. 2 Classification results by different classifiers

表 2 不同方法的分类精度统计

Tab. 2 Classification accuracy of different methods

方法	输入样本大小	分类精度	
		OA/%	Kappa/%
LLE+SVM	_	65.51	55.48
S-SAE+SVM	_	78.48	72.92
PCA+CNN	15×15	87.92	85.23
	35×35	96.10	95.30
S-SAE+CNN	15×15	94.24	93.03
	35×35	98.25	97.90
S-SAE+MSFCN	15×15	96.11	95.32
	35×35	99.06	98.87
NC-SAE+CNN	15×15	94.23	93.05
	35×35	97.91	97.48
NC-SAE+MSFCN	15×15	95.21	94.21
	35×35	99.33	99.19

- 2)比较不同分类器的分类性能,由图2可以清楚地看出MSFCN的分类效果比其他分类网络更好。同时,由表2可以得出,MSFCN网络的整体分类精度OA比SVM和CNN分别高21%和12%。
- 3) CNN和MSFCN网络的输入大小对分类性能也有一定的影响,增大输入大小可以显著提高农作物的分类精度。通过实验证明,建议在实际应用中选择中等大小尺寸35×35。

4)分析农作物分类的整个实验过程,通过对比表 2 中的结果可以得出,所提出的 NC-SAE 与 MSFCN结合的方法可以获得最好的分类性能。

3 结束语

本文构建了一种新的 MSFCN用于完成对多时相 PolSAR 数据的分类。为了解决维数灾难问题,提出了一种改进的自编码器 NC-SAE,用于对多时相 PolSAR 数据的极化散射特征降维。与此同时,利用 欧空局提供的 Sentinel-1 系统模拟多时相 PolSAR 数据和实验区域的地面真实值对所提方法进行分类性能评估。与传统的分类方法 SVM 和 CNN 相比,最终分类结果表明:对于多时相 PolSAR 数据的农作物分类,所提方法 MSFCN 网络的分类性能最优。

此外,对于提出的多时相PolSAR数据农作物分类方法,还可以进行进一步的研究。首先,对于NC-SAE的超参数,直接使用S-SAE方法的经验值,但不一定是NC-SAE方法在特征降维时的最优值,因此,NC-SAE最优值的选取值得后续继续研究;其次,使用了2个阶段(特征压缩和作物分类)实现对多时相农作物数据的分类,对此也可以进行优化,研究出更简便的方法,即使用一个独立网络实现多时相PolSAR数据的农作物分类,将进一步简化分类过程,减少计算量。

参考文献

- [1] KOLOTII A, KUSSUL N, SHELESTOV A, et al. Comparison of biophysical and satellite predictors for wheat yield forecasting in Ukraine[C]// In Proceedings of 2015 36th International Symposium on Remote Sensing of Environment. 2015: 11-15.
- [2] BORYAN C, YANG Z W, MUELLER R, et al. Monitoring US agriculture: the US department of agriculture, national agricultural statistics service, cropland data layer program [J]. Geocarto Int, 2011, 26: 341-358.
- [3] ZEYADA H, EZZ M, NASR A, et al. Evaluation of the discrimination capability of full polarimetric SAR data for crop classification [J]. International Journal of Remote Sensing, 2016, 37: 2585-2603.
- [4] 吴炳方,蒙继华,李强子.国外农情遥感监测系统现状与启示[J].地球科学进展,2010,25(10):1003-1012.
- [5] TYCZEWSKA A, WOZNIAK E, GRACZ J, et al. Towards food security: current state and future prospects of agrobiotechnology[J]. Trends Biotechnol, 2018, 36: 1219-1229.
- [6] 陈仲新,任建强,唐华俊,等.农业遥感研究应用进展与展望[J].遥感学报,2016,20(5):748-767.
- [7] 王馨爽,陈尔学,李增元,等.多时相双极化合成孔径雷 达干涉测量土地覆盖分类方法[J].测绘学报,2015,44 (5):533-540.
- [8] ORYNBAIKYZY A, GESSNER U, CONRAD C. Crop type classification using a combination of optical and radar remote sensing data: a review [J]. International Journal of Remote Sensing, 2019, 40: 6553-6595.
- [9] KUSSUL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data [J]. IEEE Geosci Remote Sens Lett, 2017, 14: 778-782.
- [10] LI H, ZHANG C, ATKINSON P M, et al. Crop classification from full-year fully-polarimetric L-band UAVSAR time-series using the Random Forest algorithm [J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 87: 102032.
- [11] 陈筠力,刘艳阳,陈重华,等.天基干涉合成孔径雷达技术发展与展望[J].上海航天,2021,38(3):96-108.
- [12] SKRIVER H, et al. Crop classification using short-revisit multitemporal SAR data [J]. IEEE J Sel Top Appl Earth Observe Remote Sens, 2011, 4: 423-431.
- [13] ZHOU Y, LUO J, FENG L, et al. Long-short-termmemory-based crop classification using high-resolution

- optical images and multi-temporal SAR data [J]. GIScience & Remote Sensing, 2019, 56: 1170-1191.
- [14] BASCONES D, GONZALEZ C, MOZOS D. Hyperspectral image compression using vector quantization, PCA and JPEG2000 [J]. Remote Sens, 2018, 10(6): 907.
- [15] WANG L. Research on distributed parallel dimensionality reduction algorithm based on PCA algorithm [C]// Proceedings of 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). 2019: 1363-1367.
- [16] 邱建荣,罗汉.改进的局部线性嵌入算法及其应用[J]. 计算机工程与应用,2020,56(3):176-179.
- [17] MIN X P, WANG H, YANG Z W, et al. Relevant component locally linear embedding dimensionality reduction for gene expression data analysis [J]. Metallurgical & Mining Industry, 2015, 4: 186-194.
- [18] XIE G S, ZHANG X Y, LIU C L. Efficient feature coding based on auto-encoder network for image classification [C]// Proceedings of Computer Vision-ACCV 2014. 2015; 628-642.
- [19] ABOLHASANZADEH B. Nonlinear dimensionality reduction for intrusion detection using auto-encoder bottleneck features [C]// Proceedings of 2015 7th Conference on Information and Knowledge Technology (IKT). 2015: 1-5.
- [20] GUO J, NING H L J, HAN W, et al. Feature dimension reduction using stacked sparse auto-encoders for crop classification with multi-temporal, quad-pol SAR data[J]. Remote Sens, 2020, 12: 321.
- [21] REN K, YE H, GU G, et al. Pulses classification based on sparse auto-encoders neural networks [J]. IEEE Access, 2019, 7: 92651-92660.
- [22] 杜兰,刘彬,王燕,等.基于卷积神经网络的SAR图像目标检测算法[J].电子与信息学报,2016,38(12):3018-3025.
- [23] 卢丹,孙永岩,郑幸飞,等.面向星上目标提取的卷积神经网络优化技术[J].上海航天,2021,38(1):105-112.
- [24] NGUYEN-THANH S, CHI-FARN C, CHENG R, et al. Assessment of sentinel-1A data for rice crop classification using random forests and support vector machines [J]. Geocarto International, 2018, 33(6): 587-601.
- [25] 葛辰杰,陆志沣,洪泽华,等.基于支持向量回归与多核 集成的红外成像导引头抗干扰性能评估方法[J].上海 航天,2019,36(5):94-98.