

## 基于深度卷积神经网络和多核学习的遥感图像分类方法

王鑫\*<sup>①</sup> 李可<sup>①</sup> 宁晨<sup>②</sup> 黄凤辰<sup>①</sup>

<sup>①</sup>(河海大学计算机与信息学院 南京 211100)

<sup>②</sup>(南京师范大学物理科学与技术学院 南京 210000)

**摘要:** 为解决传统遥感图像分类方法特征提取过程复杂、特征表现力不强等问题, 该文提出一种基于深度卷积神经网络和多核学习的高分辨率遥感图像分类方法。首先基于深度卷积神经网络对遥感图像数据集进行训练, 学习得到两个全连接层的输出将作为遥感图像的两种高层特征; 然后采用多核学习理论训练适合这两种高层特征的核函数, 并将它们映射到高维空间, 实现两种高层特征在高维空间的自适应融合; 最后在多核融合特征的基础上, 设计一种基于多核学习-支持向量机的遥感图像分类器, 对遥感图像进行精确分类。实验结果表明, 与目前已有的基于深度学习的遥感图像分类方法相比, 该算法在分类准确率、误分类率和Kappa系数等性能指标上均有所提升, 在实验测试集上3个指标分别达到了96.43%, 3.57%和96.25%, 取得了令人满意的结果。

**关键词:** 高分辨率遥感图像; 分类; 卷积神经网络; 多核学习

中图分类号: TP751

文献标识码: A

文章编号: 1009-5896(2019)05-1098-08

DOI: [10.11999/JEIT180628](https://doi.org/10.11999/JEIT180628)

## Remote Sensing Image Classification Method Based on Deep Convolution Neural Network and Multi-kernel Learning

WANG Xin<sup>①</sup> LI Ke<sup>①</sup> NING Chen<sup>②</sup> HUANG Fengchen<sup>①</sup>

<sup>①</sup>(College of Computer and Information, Hohai University, Nanjing 211100, China)

<sup>②</sup>(School of Physics and Technology, Nanjing Normal University, Nanjing 210000, China)

**Abstract:** To solve the problems of complex feature extraction process and low characteristic expressiveness of traditional remote sensing image classification methods, a high resolution remote sensing image classification method based on deep convolution neural network and multi-kernel learning is proposed. Firstly, the deep convolution neural network is constructed to train the remote sensing image data set to learn the outputs of two fully connected layers, which are taken as two high-level features of remote sensing images. Then, the multi-kernel learning is used to train the kernel functions for these two high-level features, so that they can be mapped to the high dimensional space, where these two features are fused adaptively. Finally, with the combined features, a remote sensing image classifier based on Multi-Kernel Learning-Support Vector Machine (MKL-SVM) is designed for remote sensing image classification. Experimental results show that compared with the existing deep learning based remote sensing classification methods, the proposed algorithm achieves improved results in terms of classification accuracy, error, and Kappa coefficient. On the experimental test set, the above three indicators reach 96.43%, 3.57%, and 96.25% respectively, and satisfactory results are obtained.

**Key words:** High resolution remote sensing image; Classification; Convolution neural network; Multi-Kernel Learning(MKL)

收稿日期: 2018-06-27; 改回日期: 2018-12-28; 网络出版: 2019-01-03

\*通信作者: 王鑫 wang\_xin@hhu.edu.cn

基金项目: 教育部中央高校基本科研业务费专项资金(2019B15314), 国家自然科学基金(61603124), 江苏省“六大人才高峰”高层次人才项目(XYDXX-007), 江苏省“333高层次人才培养工程”, 江苏政府留学奖学金项目

Foundation Items: Fundamental Research Funds for the Central Universities (2019B15314), The National Natural Science Foundation of China (61603124), Six Talents Peak Project of Jiangsu Province (XYDXX-007), 333 High-Level Talent Training Program of Jiangsu Province, Jiangsu Province Government Scholarship for Studying Abroad

## 1 引言

遥感图像分类是遥感图像处理的重要研究方向, 能为遥感图像其他应用提供坚实的分析数据。现阶段, 高分辨率遥感图像分类研究较多关注的是分类器的设计和改进, 而遥感图像特征提取的准确性和有效性对分类精度和效率也有着非常重要的影响。如何针对高分辨率遥感图像, 提取高准确度和高鲁棒性的特征仍是目前遥感图像分类中一个亟待攻克的难题<sup>[1-3]</sup>。近年来, 深度学习作为机器学习的一个全新理论, 被引入图像处理和模式识别领域, 用于解决图像分类<sup>[4]</sup>、目标识别<sup>[5]</sup>、自然语言处理<sup>[6]</sup>、语音识别<sup>[7]</sup>等问题。

通过对深度学习的研究, 研究学者们发现深度学习模型的深层次直接决定了其对数据的刻画能力, 深度学习得到的特征数据能良好地表示原始输入数据。对比基于深度学习和传统机器学习的图像分类方法可以发现: 在本质上这些方法类似, 都是在高维空间中, 根据待处理样本的特征对其进行分类。然而, 深度学习方法的表达能力远远高于传统的机器学习方法, 它能从少数样本数据集中有力地提取数据的本质特征。深度学习通过学习一种深层非线性结构将输入数据特征进行分层表示, 实现将数据低层特征抽象成有益于分类的高层特征。随着深度学习研究的不断深入, 各种深度学习模型也不断完善, 使得深度学习更有利于挖掘数据的局部和全局特征, 且这些特征更具代表性, 这在理论上为基于深度学习的图像分类问题带来了一个全新的研究思路。

目前, 已有研究学者将深度学习应用于遥感图像分类问题。基于深度学习提取得到的遥感图像特征具有抗过拟合性、图像平移、旋转和扭曲鲁棒性等优良品质。例如, 文献<sup>[8]</sup>提出一种基于深度学习的遥感图像分类方法。文献<sup>[9]</sup>提出一种基于卷积神经网络的遥感图像分类方法。文献<sup>[10]</sup>提出一种基于卷积神经网络的遥感图像飞机目标分类方法。文献<sup>[11]</sup>提出一种基于卷积神经网络的遥感图像舰船目标检测方法。上述方法在一定程度上都实现了遥感图像的分类, 但这些方法大都采用某一种深度学习特征进行分类, 且需人工调整分类器参数<sup>[12-18]</sup>, 因此, 仍存在未能有效融合多种深度特征、分类器参数选择困难的问题。

本文充分考虑深度学习的优势, 提出一种基于深度卷积神经网络和多核学习的遥感图像分类方法。首先基于深度卷积神经网络对遥感图像数据集进行训练, 学习得到两个全连接层的输出将作为遥感图像的两种高层特征; 其次, 采用多核学习理论训练

适合这两种高层特征的核函数, 并将它们映射到高维空间, 实现高层特征在高维空间的自适应融合; 最后, 在多核融合特征基础上, 设计一种基于多核学习-支持向量机(Multi-Kernel Learning-Support Vector Machine, MKL-SVM)的遥感图像分类器, 对图像进行精确分类。

与传统遥感图像分类方法相比, 本文所提算法具有两个优点: (1) 本文方法针对卷积神经网络两个全连接层提取到的特征, 采用多核学习方法将它们在核空间中自适应融合, 融合后的特征可进一步加强特征的表现力和鲁棒性; (2) 本文方法采用多核学习-支持向量机分类器对遥感图像进行分类, 可通过多核学习得到分类器的最优参数, 无需人工测试调整参数, 优化了分类过程。

## 2 基于深度卷积神经网络和多核学习的高分辨率遥感图像分类算法

本文所提方法框图如图1所示。

### 2.1 基于深度卷积神经网络的遥感图像高层特征提取

为提取遥感图像的深度特征, 首先搭建和训练一个7层卷积神经网络, 然后提取该网络的第6层和第7层两个全连接层的特征, 将它们作为遥感图像两种不同的高层特征。具体步骤如下:

(1) 构建多类遥感图像样本数据集  $Im = [Im_1, Im_2, \dots, Im_N]$ , 并制作相应的样本标签  $La = [La_1, La_2, \dots, La_N]$ , 其中  $N$  表示有  $N$  类遥感图像,  $Im_i (i=1, 2, \dots, N)$  表示第  $i$  类遥感图像的集合,  $La_i$  表示第  $i$  类遥感图像的标签集合。

(2) 将数据集分为训练集部分  $Tr$  和测试集部分  $Te$ 。针对数据集中每类遥感图像, 设其样本总数为  $n$ , 从中随机抽取  $m$  张图像构建训练集, 其余  $n - m$  张图像构建测试集, 则有:  $Tr = [Tr_1, Tr_2, \dots, Tr_N]$ ,  $Te = [Te_1, Te_2, \dots, Te_N]$ , 其中,  $Tr_i$  表示第  $i$  类遥感图像的训练集合, 它包含了  $m$  张图像,  $Te_i$  表示第  $i$  类遥感图像的测试集合, 它包含  $n - m$  张图像。

(3) 搭建一个7层的卷积神经网络, 其中, 前5层分别用  $L1 \sim L5$  表示。  $L1, L2$  和  $L5$  分别包含卷积层和池化层,  $L3$  和  $L4$  分别只有1个卷积层, 第6层和第7层, 称为全连接层, 分别用  $fc6$  和  $fc7$  表示。搭建好的网络结构如图2所示。

(4) 利用遥感图像样本进行卷积神经网络训练。首先, 将遥感图像训练集输入搭建好的网络中, 前向计算卷积神经网络每个神经元的输出值。假设第  $l$  层为卷积层, 则第  $l$  层第  $j$  个特征图  $y_j^l$  计算公式为

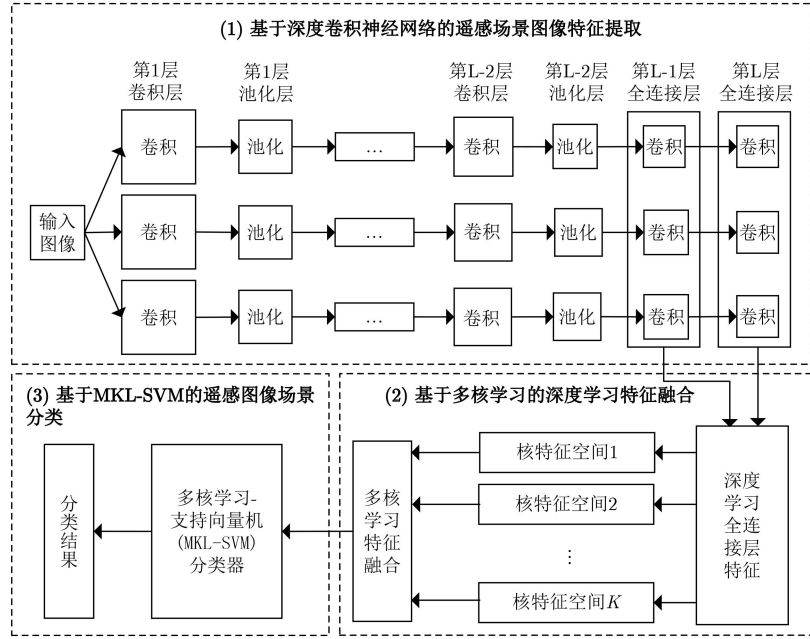


图1 本文算法的框图




图2 搭建的7层卷积神经网络

$$y_j^l = f \left( \sum_{i \in M^{l-1}} y_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (1)$$

其中, \*表示卷积操作,  $y_i^{l-1}$ 为第 $l-1$ 层第 $i$ 个特征图,  $k_{ij}^l$ 表示 $y_i^{l-1}$ 和 $y_j^l$ 之间用于连接的卷积核,  $b_j^l$ 表示 $y_j^l$ 的偏置,  $f(\cdot)$ 表示线性整流激活函数ReLU,  $M^{l-1}$ 表示第 $l-1$ 层特征图的个数。

假设第 $l$ 层为池化层, 则第 $l$ 层第 $j$ 个特征图 $y_j^l$ 的计算公式为

$$y_j^l = f \left( \beta_j^l \cdot \text{dn} \left( y_j^{l-1} \right) + b_j^l \right) \quad (2)$$

其中,  $\beta_j^l$ 表示 $y_j^l$ 的池化参数,  $y_j^{l-1}$ 表示第 $l-1$ 层第 $j$ 个特征图,  $\text{dn}(\cdot)$ 表示池化函数。

假设第 $l$ 层为全连接层, 则第 $l$ 层第 $j$ 个特征图 $y_j^l$ 的计算公式为

$$y_j^l = f \left( y^{l-1} + b_j^l \right) \quad (3)$$

其中,  $y^{l-1}$ 表示第 $l-1$ 层所有特征图的加权结果。

其次, 反向计算卷积神经网络整体损失函数。设遥感图像训练集中任一带标签样本 $I_i (i = 1, 2, \dots, N \times m)$ , 其中 $N$ 表示有 $N$ 类遥感图像,  $m$ 表示每一类包括 $m$ 个测试图像。 $I_i$ 的标签实际是一一对多标签

$$L_i^k = \begin{cases} 1, & I_i \text{实际属于第} k \text{类} \\ 0, & I_i \text{实际不属于第} k \text{类} \end{cases}, i = 1, 2, \dots, N \quad (4)$$

对于标签样本 $I_i$ , 若卷积神经网络将其判别为第 $k$ 类的概率为 $t_i^k, k = 1, 2, \dots, N$ , 则定义其误差为 $E_i$

$$E_i = \frac{1}{2} \sum_{k=1}^N \left( t_i^k - L_i^k \right)^2 \quad (5)$$

基于所有训练样本的误差, 计算卷积神经网络的损失函数 $E_0$

$$E_0 = \sum_{i=1}^{N \times m} E_i = \frac{1}{2} \sum_{i=1}^{N \times m} \sum_{k=1}^N (t_i^k - L_i^k)^2 \quad (6)$$

最后,采用梯度下降法最小化损失函数,并更新网络中各个参数。训练卷积神经网络的目的是寻找最优的参数,以最小化损失函数 $E_0$ 。卷积神经网络的参数是 $k_{ij}^l, \beta_j^l$ 和 $b_j^l$ ,若用 $W$ 表示上述3种参数,则 $W = (k_{ij}^l, \beta_j^l, b_j^l)$ ,通过遥感图像训练集训练卷积神经网络后,可找到一组参数 $W^*$ ,使得

$$W^* = \arg \min_W E_0 \quad (7)$$

采用梯度下降算法更新卷积神经网络的参数 $W$ ,同时最小化损失函数 $E_0$

$$W^{(i)} = W^{(i-1)} - \alpha \left. \frac{\partial E_0}{\partial W} \right|_{W=W^{(i)}} \quad (8)$$

其中, $\alpha$ 表示卷积神经网络的学习率,决定了每步调整的幅度, $W^{(i)}$ 表示第 $i$ 组更新的参数, $W^{(i-1)}$ 表示第 $i-1$ 组参数, $\frac{\partial E_0}{\partial W}$ 表示损失函数 $E_0$ 对参数 $W$ 求偏导。

(5)根据式(3),得到fc6层输出结果fe\_fc6,包含了fc6层计算得到的所有特征图。

(6)根据式(3),得到fc7层输出结果fe\_fc7,包含了fc7层计算得到的所有特征图。

(7)最后,将fe\_fc6和fe\_fc7将作为遥感图像的两种不同的高层特征。

## 2.2 基于多核学习的深度特征自适应融合

将学习所得遥感图像深度特征,在多核学习框架中进行自适应融合。多核学习是通过选择最优的基本核与核函数权重,选出最佳核函数组合来进行分类,从而得到输入图像的良好表达。考虑到核函数的参数会影响模型的复杂程度及多核学习融合分类的效果,因此本文设计采用参数较少,且在SVM分类中性能普遍取得良好的径向基核函数作为基本核函数<sup>[19]</sup>

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\mu^2}\right) \quad (9)$$

其中, $x_i$ 表示第 $i$ 张遥感图像在多核某一尺度下fc6层的特征向量fe\_fc6, $x_j$ 表示第 $j$ 张遥感图像在多核某一尺度下fc7层的特征向量fe\_fc7, $\mu$ 表示带宽参数。

构建 $M = 10$ 个尺度的核函数,由这些核函数生成融合核。将遥感图像两种不同类型的高层特征分别分配固定权重的核函数进行融合,通过融合核函数将其映射到统一核空间。为实现两个全连接层特征在核空间中的自适应融合,设计如下多核融合策略

$$k(x_i, x_j) = \sum_{m=1}^M \beta_m K_m(x_i, x_j) \quad (10)$$

其中, $k(x_i, x_j)$ 为组合后的核函数, $\beta_m$ 表示各子核对应的权重, $\sum_{m=1}^M \beta_m = 1, \beta_m \geq 0$ 。在式(10)的多核学习框架下,样本图像在特征空间中的表示问题转化为基本核与核函数权重的选择问题。利用多核学习训练的过程,实际上是优化多个基本核函数的线性组合并利用半无限线性规划训练算法得到最优权重 $\beta_m$ 的过程。

## 2.3 基于多核学习-支持向量机的高分辨率遥感图像分类器

在多核融合后的特征的基础上,设计MKL-SVM分类器

$$g(x_j) = \text{sign}\left(\sum_{i=1}^{\text{Num}} a_i y_i \sum_{m=1}^M \beta_m K_m(x_i, x_j) + b\right) \quad (11)$$

其中, $K_m(x_i, x_j)$ 表示第 $m$ 个核函数, $g(x_j)$ 为第 $j$ 张图像的预测标签值, $a_i$ 表示优化参数, $y_i$ 表示训练样本的标签, $b$ 为多核分类面的最优偏置,Num表示训练样本的个数。训练集输入时,Num为 $N \times m$ ;测试集输入时,Num为 $N \times (n-m)$ 。

将测试集Te中遥感图像融合后的特征输入到训练好的MKL-SVM分类器中,经过该分类器的每一张图像都会得到一个预测标签值 $pl_j$ ,即为分类结果。将测试集中所有图像的预测值 $pl_j$ 与其原始标签值La相比,可得到遥感图像分类准确率。

## 3 实验和分析

为验证本算法的有效性,在CPU主频为2.5 GHz、内存为4 GB、仿真软件为Python 2.7、深度学习框架为Caffe的PC机上对本算法进行了实验。实验图像为遥感图像公共数据集UCMerced\_LandUse,该数据集包含了21类遥感图像,每类遥感图像共100张,从每类遥感图像中随机抽取80张作为训练集,其余20张作为测试集。图3给出了部分示例。

### 3.1 基于卷积神经网络的遥感图像特征提取

在给出本算法分类结果前,首先通过卷积神经网络可视化,来进一步说明基于深度学习遥感图像特征提取的本质。如图4所示,为本文搭建的卷积神经网络的第1层卷积层(conv1)中各卷积核可视化结果。

接着从遥感数据集中选取1张遥感图像样本,进行可视化展示。以第19类中的图像storagetanks95为例(如图5(a)),经过本文卷积神经网络conv1层,学习得到的特征图如图5(b)所示;经过conv2层,学习得到的特征图如图5(c)所示;经过conv3层,

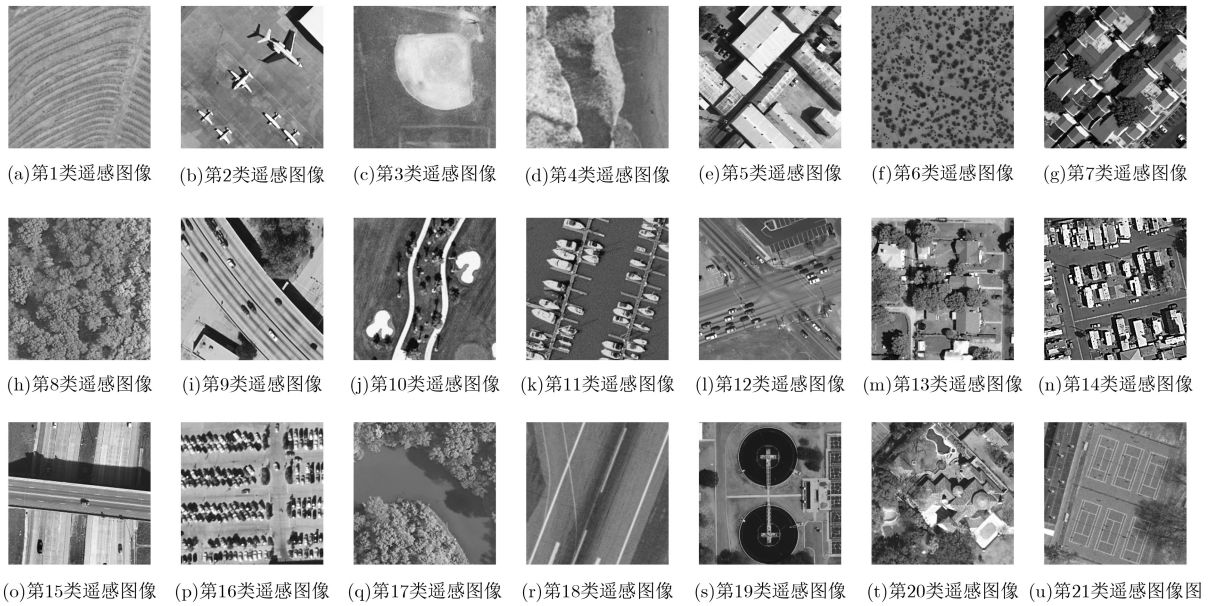


图 3 21类高分辨率遥感图像示例




图 4 conv1中96个卷积核可视化结果

学习得到的特征图如图5(d)所示；经过conv4层，学习得到的特征图如图5(e)所示；经过conv5层，学习得到的特征图如图5(f)所示。需指出的是：conv1层共得到96个特征图；conv2层共得到256个特征图；conv3层和conv4层分别有384个特征图；conv5层得到256个特征图，为方便展示，这里仅显示每层前25张特征图。从图5可见，第1层卷积层conv1学习得到的是遥感图像底层特征，包括图像颜色、物体轮廓等，第2层卷积层conv2是第1层学习得到的特征的组合，之后的卷积层学习得到的特征则更加抽象化和概念化。

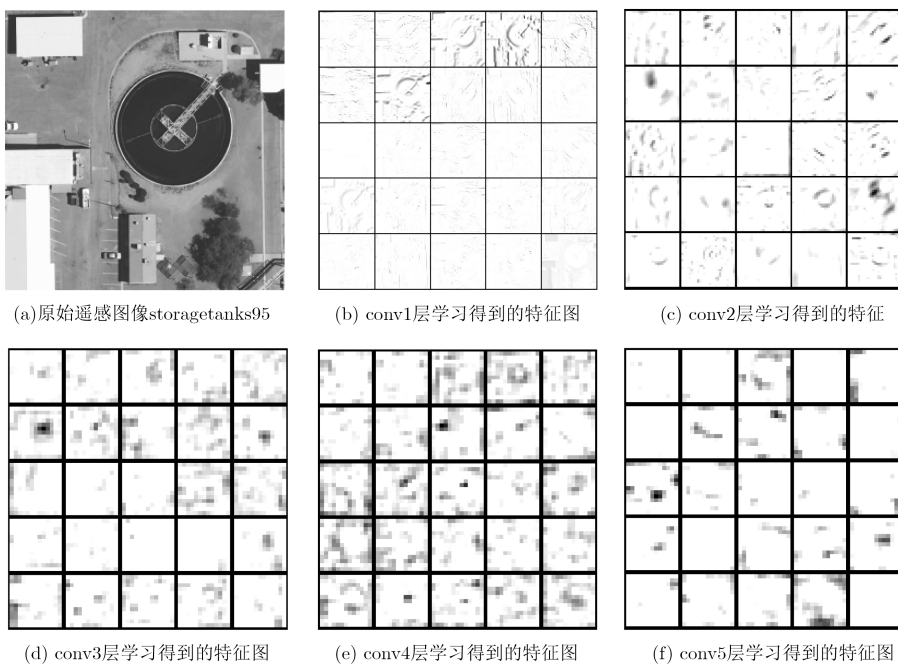


图 5 各卷积层学习得到的特征图



感图像的标签值,纵轴表示每类遥感图像的真实标签值,颜色较深的对角线上的值表示每类遥感图像的分类准确率,颜色越深代表其准确率越高。可见,比较算法1在个别类别上存在一些比较严重的误差,比较算法2在分类误差上有所改进,而本文算法分类准确率最高。

其次,计算3种算法的分类准确率Ac、误分类率Er、及Kappa系数。其中,Kappa系数越高,表明算法整体分类精度越好。

$$Ac = TP/Nr \quad (12)$$

其中,TP表示遥感图像测试集中被正确分类的图像数,Nr表示遥感图像测试集中图像总数。

$$Er = 1 - Ac = FP/Nr \quad (13)$$

其中,FP表示遥感图像测试集中被错误分类的图像数。

Kappa系数定义为

$$Kappa = (Ac - P_e)/(1 - P_e) \quad (14)$$

其中,

$$P_e = \frac{\gamma_1 \times \eta_1 + \gamma_2 \times \eta_2 + \dots + \gamma_N \times \eta_N}{Nr \times Nr} \quad (15)$$

其中, $\gamma_1, \gamma_2, \dots, \gamma_N$ 表示每类样本实际个数, $\eta_1, \eta_2, \dots, \eta_N$ 表示预测得到的每类样本个数。

最终,3种算法的分类准确率Ac、误分类率Er和Kappa系数,如表1所示。由表可见,本文所提遥感图像分类方法在准确率、误分类率和Kappa系数上都明显优于另外两种算法。

表1 3种算法各分类性能指标值

指标	算法1	算法2	本文算法
Ac	0.8808	0.9337	<b>0.9643</b>
Er	0.1192	0.0663	<b>0.0357</b>
Kappa系数	0.8748	0.9304	<b>0.9625</b>

## 4 结论

本文提出一种基于深度卷积神经网络和多核学习的遥感图像分类方法,其优势在于:(1)充分挖掘多种深度学习特征;(2)实现不同特征的自适应融合;(3)设计精确的多核学习-支持向量机遥感图像分类器,从而有效解决了现有基于深度学习的遥感图像分类方法未能有效融合多种深度特征、分类器参数选择困难等难题。

## 参考文献

- [1] WANG Xin, SHEN Siqiu, NING Chen, *et al.* Multi-class remote sensing objects recognition based on discriminative sparse representation[J]. *Applied Optics*, 2016, 55(6): 1381–1394. doi: 10.1364/ao.55.001381.
- [2] WANG Xin, XIONG Xingnan, NING Chen, *et al.* Integration of heterogeneous features for remote sensing scene classification[J]. *Journal of Applied Remote Sensing*, 2018, 12(1): 15–23. doi: 10.1117/1.jrs.12.015023.
- [3] NING Chen, LIU Wenbo, ZHANG Gong, *et al.* Enhanced synthetic aperture radar automatic target recognition method based on novel features[J]. *Applied Optics*, 2016, 55(31): 8893–8904. doi: 10.1364/ao.55.008893.
- [4] 冯子勇. 基于深度学习的图像特征学习和分类方法的研究及应用[D]. [博士学位], 华南理工大学, 2016.
- [5] 林妙真. 基于深度学习的人脸识别研究[D]. [硕士学位论文], 大连理工大学, 2013.
- [6] 奚雪峰, 周国栋. 面向自然语言处理的深度学习研究[J]. *自动化学报*, 2016, 42(10): 1445–1465. doi: 10.16383/j.aas.2016.c150682.
- [7] 张建华. 基于深度学习的语音识别应用研究[D]. [硕士学位论文], 北京邮电大学, 2015.
- [8] 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): 306–314. doi: 10.3788/AOS201636.0428001.
- [9] 曲景影, 孙显, 高鑫. 基于CNN模型的高分辨率遥感图像目标识别[J]. *国外电子测量技术*, 2016, 35(8): 45–50. doi: 10.19652/j.cnki.femt.2016.08.011.
- [10] 周敏, 史振威, 丁火平. 遥感图像飞机目标分类的卷积神经网络方法[J]. *中国图象图形学报*, 2017, 22(5): 702–708. doi: 10.11834/jig.160595.

ZHOU Min, SHI Zhenwei, and DING Huoping. Aircraft

- classification in remote-sensing images using convolutional neural networks[J]. *Journal of Image and Graphics*, 2017, 22(5): 702–708. doi: [10.11834/jig.160595](https://doi.org/10.11834/jig.160595).
- [11] 黄洁, 姜志国, 张浩鹏, 等. 基于卷积神经网络的遥感图像舰船目标检测[J]. 北京航空航天大学学报, 2017, 43(9): 1841–1848. doi: [10.13700/j.bh.1001-5965.2016.0755](https://doi.org/10.13700/j.bh.1001-5965.2016.0755).  
HUANG Jie, JIANG Zhiguo, ZHANG Haopeng, *et al.* Ship object detection in remote sensing images using convolutional neural networks[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2017, 43(9): 1841–1848. doi: [10.13700/j.bh.1001-5965.2016.0755](https://doi.org/10.13700/j.bh.1001-5965.2016.0755).
- [12] LECUN Y, BOTTOU L, BENGIO Y, *et al.* Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278–2324. doi: [10.1109/5.726791](https://doi.org/10.1109/5.726791).
- [13] GAO Ligang, CHEN Paiyu, and YU Shimeng. Demonstration of convolution kernel operation on resistive crosspoint array[J]. *IEEE Electron Device Letters*, 2016, 7(7): 870–873. doi: [10.1109/LED.2016.2573140](https://doi.org/10.1109/LED.2016.2573140).
- [14] GIRSHICK R, IANDOLA F, DARRELL T, *et al.* Deformable part models are convolutional neural networks[C]. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA, 2015: 437–446. doi: [10.1109/CVPR.2015.7298641](https://doi.org/10.1109/CVPR.2015.7298641).
- [15] HINTON G E. How neural networks learn from experience[J]. *Scientific American*, 1992, 267(3): 145–151. doi: [10.1038/scientificamerican0992-144](https://doi.org/10.1038/scientificamerican0992-144).
- [16] BOUVRIE J. Notes on convolutional neural networks[R]. Massachusetts: Center for biological and computational learning, 2006: 38–44.
- [17] RUMELHAR T D E, HINTON G E, and WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533–536. doi: [10.1038/323533a0](https://doi.org/10.1038/323533a0).
- [18] KRIZHEVSKY A, SUTSKEVER I, and HINTON G E. ImageNet classification with deep convolutional neural networks[C]. Proceedings of Advances in Neural Information Processing Systems 25, Lake Tahoe, USA, 2012: 1097–1105. doi: [10.1145/3065386](https://doi.org/10.1145/3065386).
- [19] NING Chen, LIU Wenbo, and WANG Xin. Infrared object recognition based on monogenic features and multiple kernel learning[C]. The 2018 IEEE International Conference on Image, Vision and Computing. Chongqing, China, 2018: 204–208.
- 王 鑫: 女, 1981年生, 副教授, 研究方向为图像处理、模式识别、计算机视觉、机器学习.
- 李 可: 女, 1996年生, 硕士生, 研究方向为深度学习理论.
- 宁 晨: 男, 1978年生, 讲师, 研究方向为机器学习和模式识别.
- 黄凤辰: 男, 1964年生, 副教授, 研究方向为图像处理和分