

DOI:10.16136/j.joel.2022.07.0738

基于迁移学习的遥感图像场景分类

刘有耀, 陈琪*, 李舒曼

(西安邮电大学 电子工程学院, 陕西 西安 710121)

摘要:在遥感图像场景分类中,基于卷积神经网络(convolutional neural network,CNN)的分类算法存在对训练数据的依赖性,且在缺乏训练数据时分类效果差等问题,提出一种基于迁移学习的分类算法。首先,选取现有的多个CNN预训练模型,利用迁移学习的优势对模型进行微调,目的是提取图像不同的高层特征;然后,融合图像的多种高层特征,使得特征信息更加丰富;最后,将融合后的高层特征输入到基于逻辑回归的遥感图像分类器中,得到遥感影像的分类结果。在UCMerced_LandUse遥感数据集中进行实验,与现有算法进行比较分析,所提算法在3种评价指标上有明显提升。通过分析实验结果表明,该算法在仅有10%的训练数据下,能够达到92.01%的分类准确率和91.61%的Kappa系数。

关键词:遥感影像;场景分类;卷积神经网络;迁移学习;逻辑回归

中图分类号:TP751.1 **文献标识码:**A **文章编号:**1005-0086(2022)07-0709-06

Scene classification of remote sensing image based on transfer learning

LIU Youyao, CHEN Qi*, LI Shuman

(School of Electronics and Engineering, Xi'an University of Posts and Telecommunications, Xi'an, Shaanxi 710121, China)

Abstract:In remote sensing image scene classification, a classification algorithm based on convolutional neural network (CNN) has the dependence on training data, and the classification effect is poor in the absence of training data, and a classification algorithm based on transfer learning is proposed. Firstly, the existing pre-training model of multiple CNN is selected, and the model is fine-tuned by using the advantages of transfer learning to extract the different high-level features of the image, then, the fusion of the image's many high-level features makes the feature information more abundant, and finally, the merged high-level features are input into the remote sensing image classifier based on logical regression, and the classification results of remote sensing images are obtained. Experiments are carried out in remote sensing data sets of UCMerced_LandUse, and the existing algorithms are compared and analyzed, and the proposed algorithms are significantly improved in three evaluation indicators. By analyzing the experimental results, it is shown that the algorithm can achieve 92.01% classification accuracy and 91.61% Kappa coefficient under only 10% of the training data.

Key words: remote sensing image; scene classification; convolutional neural network (CNN); transfer learning; logical regression

1 引言

遥感图像包含的信息可以广泛应用于生活的场景中,如土地、水利等,其中遥感图像场景分类

是遥感领域的重要研究方向之一,因此对其进一步研究有着重要意义。随着遥感技术的发展,遥感图像中的语义信息更加复杂,空间纹理特征更加丰富多样,使得不同场景下图像间存在相似性,

* E-mail:15030634362@163.com

收稿日期:2021-10-27 修订日期:2021-12-21

基金项目:国家自然科学基金(61874087,61834005,61634004)资助项目

相同场景下的图像存在差异性^[1]。遥感图像呈现的一系列特征使得传统的遥感图像分类算法性能较差,导致现有算法无法取得遥感图像的高精度分类,因此提升图像的分类精度取决于特征提取算法和分类算法,通过提取算法获得的信息越丰富,则分类算法得到的性能越好。

迄今为止,遥感图像分类方法主要分为基于无监督学习的分类、基于手工设计特征的分类和基于深度学习的分类这3类算法^[2]。基于无监督学习的分类方法主要属于机器学习算法,由于人工无法干预计算过程,因此这类方法在某些遥感图像中无法得到预期的效果,如主成分分析^[3]、K-means算法等^[4]。基于手工设计特征的分类是根据图像的特点设计并提取固定的特征,可以人工设计所提取的特征,如尺度不变特征变换(scale-invariant feature transform, SIFT)^[5]、视觉词袋特征(bag of visual words, BOVW)等^[6]。该方法在提取特征时存在信息冗余等问题,无法对图像进行正确分类,难以适用复杂图像的高精度分类。

深度学习的迅速发展为研究者提供了新的想法,研究者在遥感领域的图像场景分类中使用深度学习方法,在特征学习的过程中自动调节权重和偏置,根据输入图像的不同,目的是为了提取出的图像特征更具有代表性,从而得到有效的图像特征。相较于传统的遥感分类算法,使用深度学习进行图像分类能够得到很好的分类精度。

2012年,在对大型通用的数据集 ImageNet 进行分类时,使用卷积神经网络(convolutional neural network, CNN)^[7,8]算法取得了很好的分类结果^[9],由此体现出 CNN 在图像分类方面强大的学习能力。CNN 广泛应用于计算机视觉任务中^[10-13],基于 CNN 的 AlexNet^[14]、视觉几何群网络(visual geometry group network, VGGNet)^[15]、谷歌网络(Google inception network, GoogleNet)^[16]

及深度残差神经网络(deep residual neural network, ResNet)等^[17]深层结构在图像分类任务上效果超群。近年来,研究学者充分发挥 CNN 的优势,为了获得复杂遥感图像的高精度分类,在遥感场景分类中使用 CNN。例如,蔡之灵等^[18]提出对 Inception-V3 加以改进的分类模型,该算法基于 Inception-V3 模型开展研究,在原始模型的全连接层前添加 DropOut 层,使用迁移学习对模型进行训练,最后使用训练好的模型对图像分类,得到分类结果。王鑫等^[19]提出一种改进的基于深度学习的分类算法,算法中搭建了7层的网络模型,对高层特征进行降维处理并融合,使得信息更丰富有效,最后设计逻辑回归浅层分类器,对融合后的特征进行分类。但这类算法在训练过程中存在容易产生过拟合、依赖巨大的训练数据并且训练过程耗时等问题,数据的缺乏是导致这些问题出现的原因之一,也是提升分类精度的制约因素之一,因此研究在较少训练数据情况下的遥感影像场景分类具有巨大的应用价值。

为了解决上述问题,本文的工作重点在于研究深度学习的遥感分类算法,其中工作主要内容如下:

- 1) 在特征提取时,选取现有的多个 CNN 预训练模型,利用迁移学习的优势对模型进行微调,获得图像不同的高层特征,然后将多个高层特征以串联的方式进行融合得到新的组合特征。
- 2) 在对图像进行分类时,训练基于逻辑回归的分类器,并对高层特征进行分类,最终得到遥感图像的分类精度。

通过上述两个方面的研究降低网络模型对训练数据的依赖,同时取得高精度分类性能。

2 基于迁移学习的分类方法

为了降低分类算法对训练数据的依赖性,根据特征提取和图像分类两个方面开展研究,本文提出的算法框图如图1所示。算法中包括3个主要步骤,

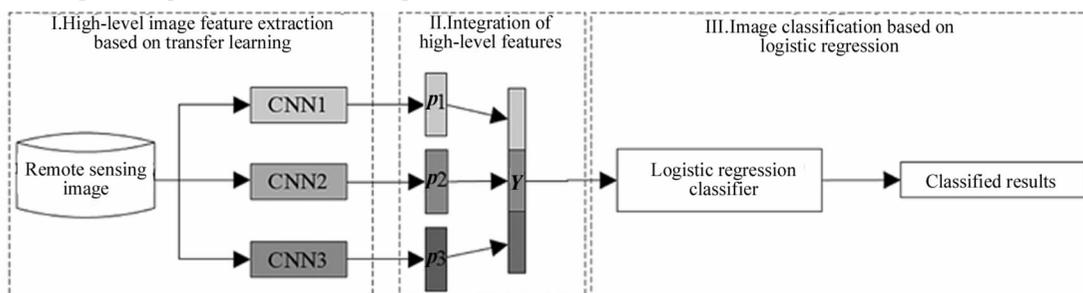


图1 本文算法框架

Fig. 1 Framework of the proposed algorithm

分别是基于迁移学习的图像高层特征提取、高层特征融合和基于逻辑回归的图像分类。本文选择使用3种在自然图像下分类的CNN模型,对遥感图像数据进行数据集划分等预处理,分别输入到3个网络模型中,训练好模型中的参数后,提取出图像的多种高层特征,保证提取特征的多样性;在高层特征融合步骤中,对多种高层特征进行融合;最后将融合后的特征输入到基于逻辑回归的图像分类器中,计算出遥感图像的分类结果。

2.1 基于迁移学习的遥感图像高层特征提取

本文的算法是为了降低网络对训练数据样本的依赖,因此对遥感数据集不进行扩增,将数据样本进行标准化处理。将遥感数据样本的原始图像数据按比例缩放,并对数据进行归一化处理,这样能够使数据适合深度学习。

本文算法使用迁移学习的方法,使用现有的Inception、VGG16、Xception 3种网络预训练模型进行研究,上述3种网络模型对自然数据集ImageNet进行分类,结果如表1所示^[20],由表可以看到这3种模型在大型通用数据集上分类效果较好,因此在提取特征方面有较强的优势。

将训练数据样本同时输入到3种预训练网络模型中,为了提取出符合图像的特征,针对不同的预训练网络模型实施不同的训练策略。对Inception网络模型进行网络微调,使得网络模型参数更好地适用于数据量较小的遥感图像数据集,训练完成后移除全连接层,将全连接层前一层的输出作为该模型最终提取的图像特征 $p1$ 。对于VGG16和Xception网络模型,分别移除原本用于分类的全连接层,提取全连接层前一层的输出作为特征 $p2$ 和 $p3$ 。

表1 3种CNN模型在ImageNet数据集上的分类精度

Tab. 1 The classification accuracy of the CNN models on the ImageNet dataset

Network model	Number of layers	Top-1/%	Top-5/%
Inception	159	78.8	94.4
VGG16	23	71.5	90.1
Xception	126	79.0	94.5

2.2 高层特征融合

由于 $p1$ 、 $p2$ 和 $p3$ 属于同一训练样本数据的高层特征,且由不同网络模型中提取得到的,将不同网

络模型中的特征进行融合,可以获得更加丰富的样本信息,因此将3种模型中提取出同一图片的不同高层特征 $p1$ 、 $p2$ 和 $p3$ 以串联方式进行融合,从而获得新的组合特征。融合算法如下:

$$Y = [p1, p2, p3]^T, \quad (1)$$

式中, Y 即从网络模型中提取出的最终高层特征。

2.3 基于逻辑回归的遥感图像分类器

通过得到的特征组合 Y 作为输入来训练基于逻辑回归的遥感图像分类器,不断优化迭代求解模型的参数,训练得到模型的最优参数,最终使用训练好参数的分类器进行分类。该模型的具体步骤如下:

步骤1 逻辑回归中使用sigmoid函数,计算出每一个训练图像样本特征对应于每一类别的概率,计算式如下:

$$pred_i^{\theta} = [1 + e^{-\theta_j}]^{-1}, \quad (2)$$

式中, $pred_i^{\theta}$ 表示该模型预测为第 i 类的概率, θ 表示权重矩阵, Y_j 表示第 j 个图像融合的样本特征。

步骤2 根据式(4)求得的预测类别的理论值,将理论值与真实类别的值计算损失值,使用损失函数的优化算法求解模型的最优参数,不断更新迭代得到能够让损失函数最小化的参数,即得到训练好的逻辑回归分类器。

步骤3 使用步骤2中训练好的逻辑回归分类器对测试数据进行分类,进而将每个测试样本的分类结果与真实标签相比,计算出分类准确率。

3 实验结果和分析

3.1 实验环境和数据

本文算法的实验仿真平台为pycharm,实验环境为CPU主频2.9 GHz,8 G运行内存,使用TensorFlow、keras等深度学习框架,对提出的算法进行实验。数据集使用UCMerced_LandUse公共遥感数据集,该数据集中共包含21类场景,比如河流、农田、飞机、建筑等,每类中有100张大小为 256×256 的彩色图像,共计2100张遥感图像。图2为该数据集各类的样本示例,可以看出该数据集场景复杂,类别多样,以上因素增加了分类的难度。在本文遥感数据集划分时,为了得到能够反映集中趋势的结果,每次进行5组实验,每次从每个类别中随机抽取10张遥感图片作为训练数据,其余为测试数据,即训练数据集占总样本10%。最后得出指标的平均值。

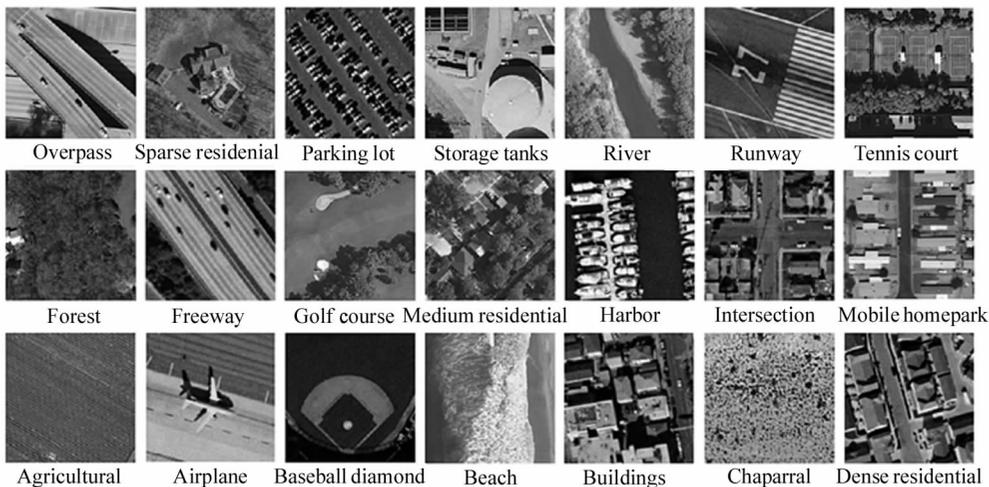


图2 UC Merced_LandUse 数据集示例

Fig. 2 UC Merced_LandUse dataset sample

3.2 结果分析

为了验证本文算法的有效性,在上述实验平台的环境中,分别将本文算法与基于 CNN 的遥感图像分类算法对数据集进行实验,对比分析结果。首先与文献[18]的算法进行对比分析,其次将本文算法与使用 3 种经典的 CNN 模型对遥感图像进行分类。通过对比分类效果,可以体现出本文算法中使用 CNN 模型来进行特征提取的优势。

本文使用 3 种评价指标进行性能评估,分别是测试数据集混淆矩阵、测试数据集分类准确率 *Accuracy* 和 *Kappa* 系数,其中混淆矩阵能够比较预测类别和实际类别的匹配度,通过对混淆矩阵进行分析,可以直观地观察到模型的效果。准确率能够得出预测正确的图片数量占图片总量的比例,其计算方法如式(3)所示。*Kappa* 系数能够很好地检验分类结果的正确性,*Kappa* 系数越高,代表模型正确程度越好,其计算式如式(4)–(5)所示:

$$Accuracy = \frac{TP}{Number}, \quad (3)$$

式中,*TP* 表示遥感图像测试数据样本被算法模型分类为正确的样本数量,*Number* 表示遥感图像测试数据样本总数。

若每类的真实样本个数为 a_1, a_2, \dots, a_N , 预测每类的样本个数为 b_1, b_2, \dots, b_N , 则模型的理论准确值定义为:

$$p_e = \frac{(a_1 \times b_1 + a_2 \times b_2 + \dots + a_N \times b_N)}{Number \times Number}, \quad (4)$$

$$Kappa = \frac{(Accuracy - p_e)}{(1 - p_e)}, \quad (5)$$

式中,*Accuracy* 表示模型准确率, p_e 表示式(4)计算出的理论准确值。

首先,计算本文算法和算法一两种算法的混淆矩阵,其中,算法一是蔡之灵等^[18]提出一种改进的 Inception-V3 遥感图像场景分类模型。结果如图 3 所示。若混淆矩阵所有数据都沿着对角线分布,说明该算法能够对所有数据集进行正确分类。对角线上值的大小与颜色的深浅相对应,对角线上的值越大,表示该类遥感图像分类准确率越高,因此颜色也越深。图 3 中可以看出算法一的混淆矩阵在个别类的分类准确率中存在较大偏差,表明算法一的模型对于个别类的分类性能较差,而在本文算法中,模型在各个类别的分类准确率偏差明显减小,表明本文提出的算法能够更好地拟合图像特征并准确分类。

其次将本文算法、基于 VGG16、Inception 和 Xception 预训练网络下的遥感图像分类算法以及文献[18]算法的分类准确率 *Accuracy* 和 *Kappa* 系数进行比较,可以体现出本文算法中使用 CNN 模型进行特征提取的优势。计算出的平均分类准确率 *Accuracy* 和平均 *Kappa* 系数如表 2 所示,由表可知,当训练数据只有 10% 且不进行数据扩充时,本文算法的平均分类准确率 *Accuracy* 和平均 *Kappa* 系数明显高于其他对比算法,验证本文算法适合于少量训练样本下遥感图像的场景分类。

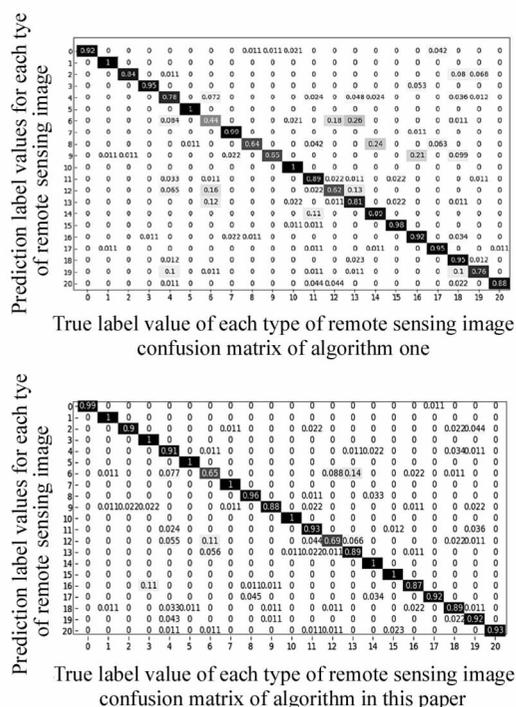


图 3 两种算法的混淆矩阵

Fig. 3 Confusion matrix of two algorithms

表 2 不同算法的评价指标值比较

Tab. 2 Comparison of evaluation index values of different algorithms

Algorithm	Accuracy	Kappa
Inception	0.686 9	0.703 3
VGG16	0.753 7	0.771 1
Xception	0.725 7	0.746 1
An improved Inception-V3 classification model ^[18]	0.848 6	0.841 1
The algorithm of this paper	0.920 1	0.916 1

4 结 论

本文提出一种基于迁移学习的遥感图像分类算法,利用迁移学习的优势,同时融合多种图像特征,增加特征的多样性,最后使用逻辑回归浅层分类器进行分类,提高分类精度。在 UCMerced_LandUse 遥感数据集中进行实验,通过实验结果与基于 CNN 的分类算法进行比较,本文算法在仅有 10% 的训练数据下,能够对遥感图像进行正确分类,在 3 种评价指标上优于对比算法,并且能够达到 92.01% 的平均分类准确率和 91.61% 的平均 Kappa 系数,证明了本文算法的有效性。在使用迁移学习方法时,对预训练网络模型的选择以及选取合适的高层特征是下一步研究的工作方向和重点。

参考文献:

[1] YU D H, ZHANG B M, ZHAO C, et al. Joint convolutional neural network and integrated learning remote sensing image scene classification[J]. Journal of Remote Sensing, 2020, 24(6): 717-727.

余东行, 张保明, 赵传, 等. 联合卷积神经网络与集成学习的遥感影像场景分类[J]. 遥感学报, 2020, 24(6): 717-727.

[2] CHENG G, HAN J, LU X. Remote sensing image scene classification; benchmark and state of the art[J]. Proceedings of the IEEE, 2017, 105(10): 1865-1883.

[3] HOTELLING H. Analysis of a complex of statistical variables into principal components[J]. Journal of Educational Psychology, 1933, 24(6): 417-520.

[4] LIU H R. Research on the classification of remote sensing images based on K-Means and their transmission systems [D]. Beijing: Beijing University of Posts and Telecommunications, 2017.

刘浩然. 基于 K-Means 的遥感图像分类及其传输系统的研究[D]. 北京: 北京邮电大学, 2017.

[5] SIRMACEK B, UNSALAN C. Urban-area and building detection using SIFT keypoints and graph theory[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(4): 1156-1167.

[6] YANG Y, NEWSAM S. Bag-of-visual-words and spatial extensions for land-use classification[C]//SIGSPATIAL International Conference on Advances in Geographic Information Systems, November 3-5, 2010, San Jose, California, USA. New York: ACM, 2010: 270-279.

[7] RAZAVIAN A S, AZIZPOUR H, SULLIVAN J, et al. CNN features off-the-shelf; an astounding baseline for recognition[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014, 1403: 512-519.

[8] HERSHEY S, CHAUDHURI S, ELLIS D, et al. CNN architectures for large-scale audio classification[J]. ICASSP 2017-2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), March 05-09, 2017, New Orleans, LA, USA. New York: IEEE, 2017: 131-135.

[9] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, Florida, USA. New York: IEEE, 2009: 248-255.

[10] ZOU Q, NI L, ZHANG T, et al. Deep learning based feature selection for remote sensing scene classification[J].

- IEEE Geoscience and Remote Sensing Letters, 2015, 12(11):2321-2325.
- [11] GE Y, JIANG S L, YE F M, et al. Remote sensing image retrieval based on CNN feature[J]. Remote Sensing of Land and Resources, 2019, 31(1):49-57.
葛芸, 江顺亮, 叶发茂, 等. 聚合 CNN 特征的遥感图像检索[J]. 国土资源遥感, 2019, 31(1):49-57.
- [12] WENG Q, MAO Z, LIN J, et al. Land-use classification via extreme learning classifier based on deep convolutional features[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5):704-708.
- [13] QIAN X L, LI J, CHENG G, et al. Evaluation of the effect of feature extraction strategy on scene classification performance of high resolution remote sensing images[J]. Journal of Remote Sensing, 2018, 22(5):758-776.
钱晓亮, 李佳, 程琳, 等. 特征提取策略对高分辨率遥感图像场景分类性能影响的评估[J]. 遥感学报, 2018, 22(5):758-776.
- [14] DANG Y, ZHANG J X, DENG K Z, et al. Land cover classification and evaluation of remote sensing images based on depth learning AlexNet[J]. Journal of Earth Information Science, 2017, 19(11):1530-1537.
党宇, 张继贤, 邓喀中, 等. 基于深度学习 AlexNet 的遥感影像地表覆盖分类评价研究[J]. 地球信息科学学报, 2017, 19(11):1530-1537.
- [15] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-04)[2021-10-27]. <https://doi.org/10.48550/arXiv.1409.1556>.
- [16] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 07-12, 2015, Boston, MA, USA. New York: IEEE, 2015:1-9.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York, IEEE, 2016:770-778.
- [18] CAI Z L, WENG Q, YE S Z, et al. High score remote sensing image scene classification based on Inception-V3 mode[J]. Remote Sensing of Land and Resources, 2020, 32(3):80-89.
蔡之灵, 翁谦, 叶少珍, 等. 基于 Inception-V3 模型的高分遥感影像场景分类[J]. 国土资源遥感, 2020, 32(3):80-89.
- [19] WANG X, LI K, XU M J, et al. An improved depth learning based remote sensing image classification Algorithm [J]. Computer Applications, 2019, 39(2):382-387.
王鑫, 李可, 徐明君, 等. 改进的基于深度学习的遥感图像分类算法[J]. 计算机应用, 2019, 39(2):382-387.
- [20] Keras. CholletF. (2015-03-28) [2021-10-27]. <https://github.com/fchollet/keras>.

作者简介:

陈琪 (1996—), 女, 硕士研究生, 主要从事图像处理的研究.