



文章编号:1001-9081(2018)04-0949-06

DOI:10.11772/j.issn.1001-9081.2017092158

改进卷积神经网络在遥感图像分类中的应用

刘雨桐*, 李志清, 杨晓玲

(智能计算与信息处理教育部重点实验室(湘潭大学), 湖南 湘潭 411100)

(*通信作者电子邮箱 l77ynt@163.com)

摘要:针对传统卷积神经网络(CNN)稀疏网络结构无法保留全连接网络密集计算的高效性和实验过程中激活函数的经验性选择造成结果不准确或计算量大的问题,提出一种改进卷积神经网络方法对遥感图像进行分类。首先,利用Inception模块的不同尺度卷积核提取图像多尺度特征,然后利用Maxout模型学习隐藏层节点的激活函数,最后通过Softmax方法对图像进行分类。在美国土地使用分类数据集(UCM_LandUse_21)上进行的实验结果表明,在卷积层数相同的情况下,所提方法比传统的CNN方法分类精度提高了约3.66%,比同样也基于多尺度深度卷积神经网络(MS_DCNN)方法分类精度提高了2.11%,比基于低层特征和中层特征的视觉词典等方法分类精度更是提高了10%以上。因此,所提方法具有较高的分类效率,适用于图像分类。

关键词:卷积神经网络; Inception模块; Maxout网络; dropout操作; 遥感图像分类

中图分类号:TP391.41 文献标志码:A

Application of improved convolutional neural network in remote sensing image classification

LIU Yutong*, LI Zhiqing, YANG Xiaoling

(Key Laboratory of Intelligent Computing & Information Processing, Ministry of Education (Xiangtan University), Xiangtan Hunan 411100, China)

Abstract: The sparse network structure for traditional Convolutional Neural Network (CNN) can not preserve the high efficiency of dense network-intensive computing and the empirical selection of the activation function in the experiment process, which leads to inaccurate results or high computational complexity. To solve above problems, an improved CNN method was proposed and applied in remote sensing images classification. Firstly, the multi-scale features of an image was extracted by using different scale convolution kernels of the Inception module, then the activation function of the hidden layer node was studied by using the Maxout model. Finally, the image was classified by the Softmax method. Experiments were conducted on the same US Land Use Classification Data Set 21 (UCM_LandUse_21), and the experimental results showed that the accuracy of the proposed method was about 3.66% and 2.11% higher than that of the traditional CNN method and a Multi-Scale Deep CNN (MS_DCNN) respectively with the same number of convolution layers, and it was also more than 10% higher than that of visual dictionary methods based on low-level features and middle-level features. The proposed method has high classification efficiency and is suitable for image classification.

Key words: Convolutional Neural Network (CNN); Inception module; Maxout network; dropout operation; remote sensing image classification

0 引言

在遥感技术研究中,不论是专业信息的提取、动态变化预测,还是专题地图制作以及遥感数据库的建立都离不开遥感图像的分类。如何高效、准确地对遥感图像进行分类成为该领域的重要研究内容。场景分类是学习将图像映射到语义内容标签的过程。遥感图像分类根据不同的统计方法,可划分为随机统计法和模糊数学方法;根据不同层次的特征提取一般可分为低层特征处理和中层特征处理两大主要方法;根据事先是否需要训练样本,又可分为监督学习、半监督学习^[1]和无监督学习^[2]三大类。低层的特征通常采用场景图像的颜色^[3]、方向梯度^[4]、密度特征^[5]、特征点^[6]、变换域的纹

理^[7]等来描述。由于低层特征泛化性差,目前场景分类方法主要基于中层语义^[8]建模。中层特征指基于统计分布的低层特征与语义的联系,包括语义的属性、对象和局部语义概念(如稀疏表示^[9]和语义概率主题模型^[10])等。目前采用中层语义来进行分类最为广泛的是基于视觉词袋(Bag of Visual Words, BOVW)模型的方法^[11],它将图像视为文档,即若干个没有顺序的“视觉词汇”集合,根据场景的低层特征来提取出互相独立的视觉词汇,然后利用K-Means^[12]等聚类算法合并词义相近的视觉词,构成一个单词表。中层语义场景分类能一定程度地缓解语义鸿沟问题,但基于语义对象组合变换的中层语义对于场景尺度的变化、传感器的拍摄时空和角度的差异缺乏有效的处理措施。

收稿日期:2017-09-05;修回日期:2017-11-30。

作者简介:刘雨桐(1992—),女,湖南岳阳人,硕士研究生,CCF会员,主要研究方向:人工智能、计算机视觉、神经网络、机器学习; 李志清(1975—),男,湖南娄底人,副教授,博士,CCF会员,主要研究方向:人工智能、计算机视觉、神经网络、机器学习; 杨晓玲(1992—),女(土家族),贵州铜仁人,硕士研究生,CCF会员,主要研究方向:计算机视觉、人工智能、图像标注。



近年来,卷积神经网络(Convolutional Neural Network, CNN)模型^[13-14]在图像分类任务上的应用,大大提高了图像分类精度。随着 ReLU(Rectified Linear Units)和 dropout 操作的出现,以及大数据和 GPU(Graphics Processing Unit)带来的机遇,Alex 在 ImageNet 图像分类挑战上提出的 AlexNet 网络结构模型^[15]赢得了 2012 届 ImageNet 大规模视觉识别挑战赛冠军。与传统的统计学方法相比,神经网络无需对概率模型作出假设,具有极强的学习能力和容错能力,适用于空间模式识别的各种问题。CNN 是针对图像分类及识别任务而特别设计的多层神经网络,是一种深度学习方法。CNN 具有的局部感受野和权值共享特点,能够有效减少训练参数数目,子采样(池化)特点能聚合对不同位置的特征,在降低特征维度的同时还能改善结果(不容易过拟合)。在识别位移、缩放以及其他形式扭曲不变性的二维图像时,CNN 在同一特征映射面上进行权值共享的特点使其能隐式地从训练数据中进行并行学习,这也成为 CNN 相对于神经元全连接网络的一大优势。

本文提出一种改进卷积神经网络的遥感图像分类方法:1)嵌入 Inception 模块,在较高层使用不同尺度的卷积核进行操作,通过扩展网络的宽度来加强网络的特征提取能力。2)采用 Maxout 网络,并结合 dropout 操作来拟合不同的激活函数,使模型在提高图像分类精度的同时,一定程度上降低过拟合的影响。在美国土地使用分类数据集(UCM_LandUse_21)上进行的实验结果表明,与当今前沿遥感图像分类方法相比,本文方法能取得更高的分类精度。

1 卷积神经网络

CNN 是一个多层次的神经网络,一般由输入、特征提取层(多层)以及分类器组成,每层由多个二维相互独立神经元组成。网络通过逐层的特征提取学习输入图像的高层特征,然后将其输入到分类器中对结果进行分类。图 1 为一个对手写体图像进行识别的 CNN 结构 LeNet-5 的模型。

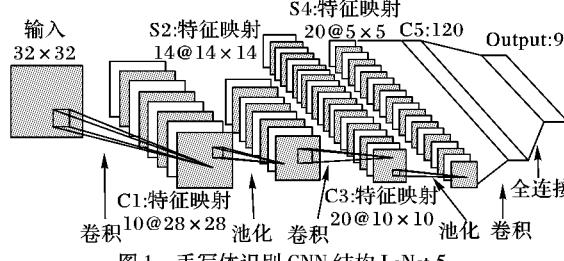


图 1 手写体识别 CNN 结构 LeNet-5

Fig. 1 Handwriting recognition CNN structure LeNet-5

卷积层是 CNN 的特征映射层,具有局部连接和权值共享的特征。这两种特征降低了模型的复杂度,并使参数数量大幅减少。

下采样(池化)层是 CNN 的特征提取层,它将输入中的连续范围作为池化区域,并且只对重复的隐藏单元输出特征进行池化,该操作使 CNN 具有平移不变性。实际上每个用来求局部平均和二次提取的卷积层后都紧跟一个下采样层,这种两次特征提取的结构使 CNN 在对输入样本进行识别时具有较高畸变容忍力。

全连接层将之前提取到的特征进行综合,使图像特征信息由二维降为一维。

输出层(Softmax 神经元层)解决线性多类的分类问题,使

用 Softmax 方法进行分类能在一定程度上提升网络学习速度。Softmax 函数中引入了 K 组参数(\mathbf{w}, \mathbf{b}),相当于引入 K 个分隔超平面, $\max P(Y = j | \mathbf{x}^{(i)}, \theta, b)$ 为最终分类结果(其中: θ 表示模型的可学习参数)。假设函数如下:

$$h_{\theta}(\mathbf{x}^{(i)}) = \begin{bmatrix} p(y^i = 1 | \mathbf{x}^{(i)}; \theta) \\ p(y^i = 2 | \mathbf{x}^{(i)}; \theta) \\ \vdots \\ p(y^i = k | \mathbf{x}^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T \mathbf{x}^{(i)}}} \begin{bmatrix} e^{\theta_1^T \mathbf{x}^{(i)}} \\ e^{\theta_2^T \mathbf{x}^{(i)}} \\ \vdots \\ e^{\theta_k^T \mathbf{x}^{(i)}} \end{bmatrix} \quad (1)$$

其中: $\frac{1}{\sum_{j=1}^k e^{\theta_j^T \mathbf{x}^{(i)}}}$ 为归一化项。

K 项概率密度分布为:

$$P(y^{(i)} = j | \mathbf{x}; \theta) = \frac{e^{\theta_j^T \mathbf{x}^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T \mathbf{x}^{(i)}}}; j \in \{1, 0\} \quad (2)$$

2 改进 CNN 遥感图像分类方法

2.1 改进 CNN 的结构

本文方法的结构分为三个模块。首先是图片预处理,利用图片生成器在训练时生成大量规定批次的数据来实时进行数据提升。然后,其 CNN 用对每幅图像进行卷积操作,提取该图像的特征。本文方法的卷积操作由三个卷积层(后接最大池化层)以及一个 Inception 模块(后接最大池化层)组成,既有纵向的延伸,又有横向的扩展;而传统 CNN 只有纵向到底加深。最后由 Maxout 网络对卷积操作提取到的特征进行全连接的处理后由分类器对遥感图像进行分类。改进 CNN 整体模型如图 2 所示。

2.2 Inception 结构

传统 CNN 改进方法只强调通过加深网络层数来提高网络特征处理能力,然而单一尺度卷积核无法实现对多尺度特征的利用。本文方法在传统 CNN 中嵌入结合 Network in Network^[15]思想的 Inception 结构。该模块先聚合输入特征,然后利用其非线性变换能力对特征进行再加工和滤波处理,以此实现多尺度特征的利用。

Inception 结构通过并联不同尺度卷积核来增加网络宽度,获取遥感图像中多种尺度特征,从而提高网络特征提取能力。

本文方法嵌入的 Inception 结构如图 3 所示。值得一提的是只有当 Inception 结构所在层数越高、通道数越多时,该方法才能取得更高的效率。因为当使用图 3 中 Inception 模型结构时,其中的 1×1 卷积核将信息进行压缩后再聚合会带来一定程度的信息损失,而模型底层主要提取的是细节特征,细节信息的细微损失很可能给整个模型的图像特征学习带来极大的影响。在对特征进行 3×3 或 5×5 卷积前引入 1×1 卷积核则是为了与上一层的神经元进行全连接,使原本特征图数量的连接数降低到 1×1 卷积的数量,从而提高模型的计算效率。

2.3 Maxout 模型

Maxout 模型实际上是一个使用激活函数的简单前馈网络结构,网络结构上在传统多层感知机(Multi-Layer Perceptron, MLP)网络隐含层前添加了一个隐隐含层,网络结构如图 4 所示。与常用激活函数(Sigmoid^[16]、tanh^[17]等)不



同的是,Maxout 网络不仅可以学到隐层节点间的关系,还能学到每个隐层节点的激活函数。

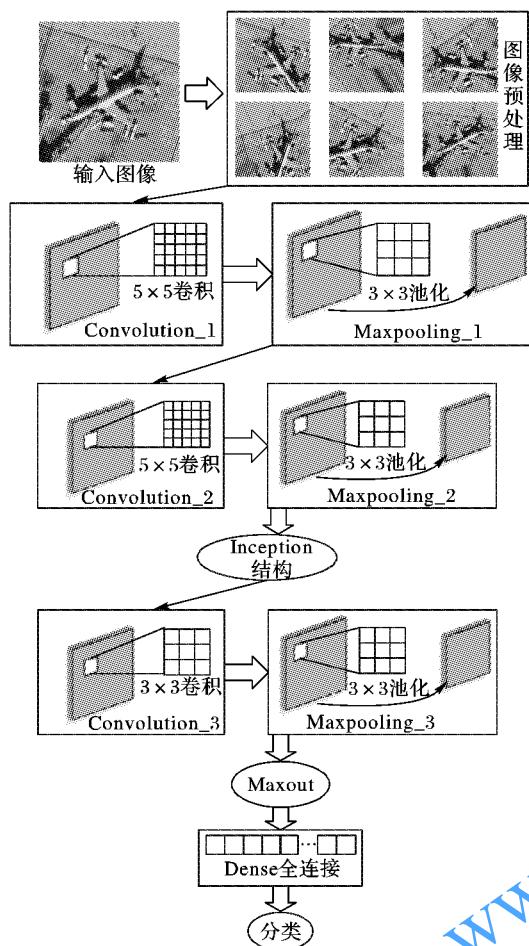


图 2 改进 CNN 结构整体模型

Fig. 2 Overall model structure of improved CNN

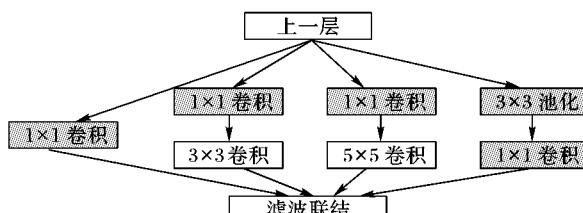
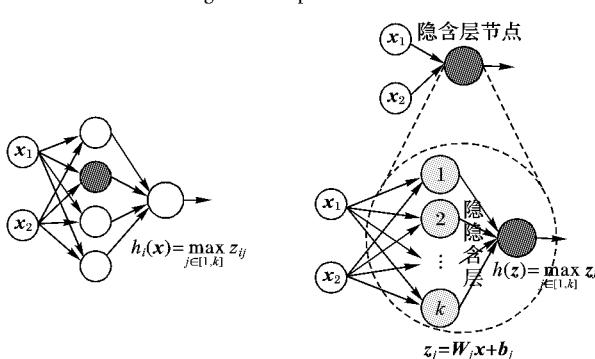


图 3 Inception 结构

Fig. 3 Inception structure



(a) 传统MLP网络模型

图 4 传统 MLP 网络模型和 Maxout 网络模型

Fig. 4 Traditional MLP network model and Maxout network model

对于给定输入 $\mathbf{x} \in \mathbb{R}^d$ (\mathbf{x} 表示上一层的状态), Maxout 函数在隐藏层实现功能为:

$$h_i(\mathbf{x}) = \max(z_{ij}); j \in [1, k] \quad (3)$$

$$z_{ij} = \mathbf{x}^T \mathbf{W}_{\dots j} + b_j; \mathbf{W} \in \mathbb{R}^{d \times m \times k}, \mathbf{b} \in \mathbb{R}^{m \times k} \quad (4)$$

其中: \mathbf{W} 和 \mathbf{b} 是需要学习的参数矩阵; d 表示输入层节点的个数; m 表示隐含层节点数量; k 指每个隐含层节点对应的“隐隐含层”节点数。隐含层的 Maxout 节点输入值为 k 个“隐隐含层”节点中的最大输出值。

任意凸函数能被以任意精度的分段线性函数拟合,而“隐隐含层”的 k 个节点在不同取值范围的最大输出值有局部线性特征,可判定 Maxout 网络能拟合任意凸函数。结合 dropout 操作可促进 Maxout 网络优化,因为在 Maxout 网络中每个“隐隐含层”节点都对输出进行预测,但每个 Maxout 单元只学习该网络预测的最大值,这使网络每次都只能学到相同的预测。改变 dropout 操作的参数能决定输入被映射在分段线性函数的哪一段,让 Maxout 网络在输入处有更大的线性区域,从而保证 Maxout 单元学习到不同的输出特征,同时减少 Maxout 单元最大化滤波器的变化。

3 实验

3.1 实验数据集

UCM_LandUse_21 数据集^[18]为美国土地使用分类数据集,它包含 21 种土地使用场景类型,每种类型中有 $256 \times 256 \times 3$ 尺寸的 100 幅场景图(见图 5)。高光谱遥感图像维数高、训练样本有限以及场景混合度大等特点给该数据集的分类带来了巨大的困难。遥感图像的场景是以其使用功能定义来分类的,也就是说一幅图像中存在多种土地覆盖类型,所以分类难度比一般场景分类大。例如:图 5(t) 中有图 5(f)、图 5(r) 以及图 5(n) 这三种土地覆盖。

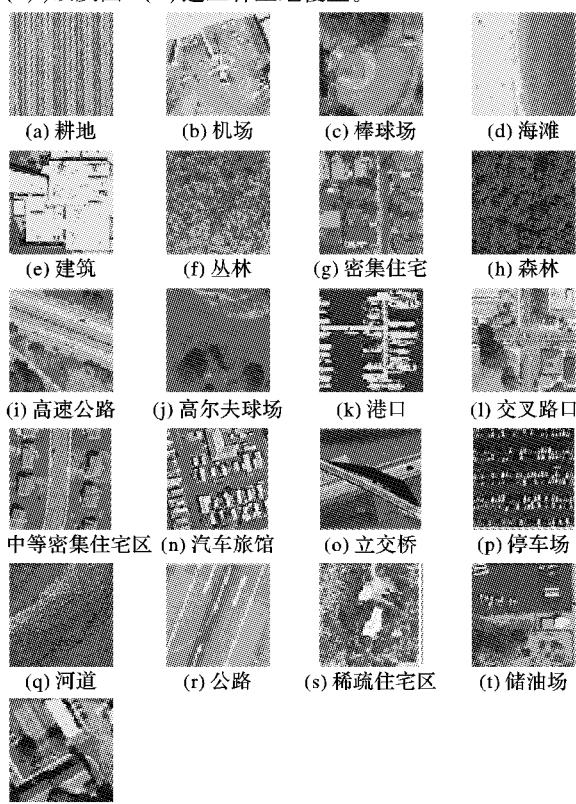


图 5 UCM_LandUse_21 类遥感图像场景示例

Fig. 5 Remote sensing image examples of UCM_LandUse_21



3.2 图像预处理

在用 CNN 对图像进行训练前,先对图像进行归一化等预处理,将数据映射到输出层的激活函数值域(0,1)区间内。由于遥感图像获取难,训练数据有限,本文方法对归一化后的数据进行一系列的随机变换(旋转、移动、缩放、翻转等方式)来对模型训练样本进行扩展。每次训练时数据生成器会无限生成数据,直到达到规定的次数 epoch 为止。每个 epoch 将生成一个批次的图像数据。进行扩展后的图像数据有利于抑制过拟合,提高模型的泛化能力。

实验过程中随机选取每类场景图像数据的 80% 作为训练数据,其余 20% 为测试数据。

3.3 CNN 结构参数设置及卷积操作可视化

本文方法所改进的 CNN 网络层结构参数如表 1 所示。

表 1 改进 CNN 网络参数

Tab. 1 Improved CNN network parameters

层	类型	特征图	卷积核	池化
0	输入	256×256	—	—
C1	卷积	4@85×85	5×5 (步长:3)	3×3 (步长:2)
C2	卷积	16@40×40	3×3 (步长:1)	3×3 (步长:2)
I3_1	(Inception) 卷积	16@20×20	1×1 (步长:1)	—
I3_2	(Inception) 卷积	16@20×20	1×1,3×3 (步长:1)	—
I3_3	(Inception) 卷积	16@20×20	1×1,5×5 (步长:1)	—
I3_4	(Inception) 卷积	16@20×20	1×1 (步长:1)	3×3 (步长:1)
C3	卷积	48@10×10	3×3 (步长:1)	3×3 (步长:2)
MD5	Maxout 全连接	512@1×1	1×1 (步长:1)	—
D6	全连接	21@1×1	1×1 (步长:1)	—

CNN 在网络中对从底层提取到的线、角等特征进行传递,并在网络的高层开始识别更复杂的特征,该特性使 CNN 更擅长识别图像中的物体。图 6 为一张机场遥感图像在本文方法所提模型中经过各个卷积层特征处理后的部分结果,展示 CNN 在各个阶段进行图像处理的情况。由图 6 可见,在卷积操作下,图像的背景激活度逐渐变小,模型在 C1 和 C2 层中提取到的基本上是颜色、边缘等底层特征,在 I3 层呈现更多的是飞机等地标性纹理特征,而在 C4 层卷积处理后所呈现的特征则已经无法通过肉眼辨认。

3.4 改进 CNN 分类能力分析

为分析本文方法的 Inception 模块和 Maxout 模块对分类效果的影响,本文对传统 CNN、加入 Inception 模块的方法(In_CNN)、同时结合 Inception 模块和 Maxout 网络的方法(InM_CNN)以及在 InM_CNN 加入 dropout 操作后的本文方法在同样的数据集 UCM_LandUse_21 进行分类实验。图 7 展现了这四种方法的正确率随 epoch 的增加而变化,可见:传统 CNN 的分类正确率最低;加入 Inception 模块后的 In_CNN 正确率在一定程度上得到了提升;加入 Maxout 层后的 InM_CNN,正确率虽然在 epoch 为 400 之前有明显提高,但之后震荡较大

(过拟合),正确率下降了近 6%;而本文方法一定程度上抑制了过拟合的影响,分类正确率在后期也能稳步增长,达到了最好的分类效果。

由此可见,本文对 CNN 进行的所有改进都是合理有效的。

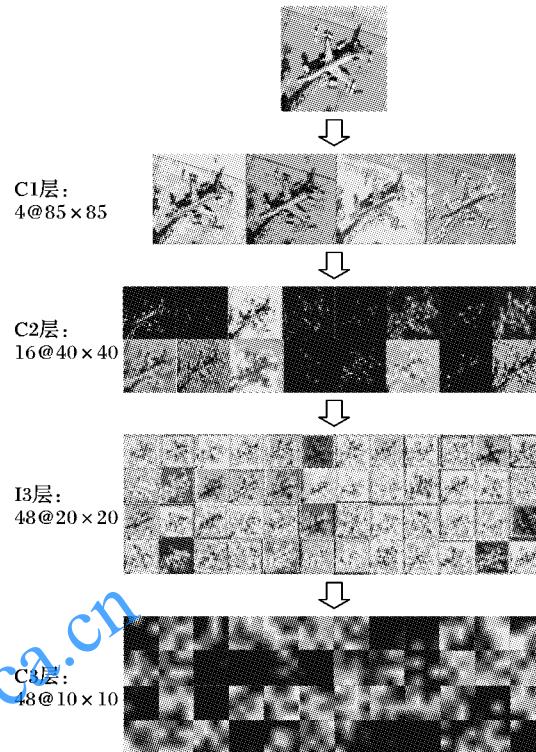


图 6 卷积层操作可视化
Fig. 6 Visualization of convolution layer operation

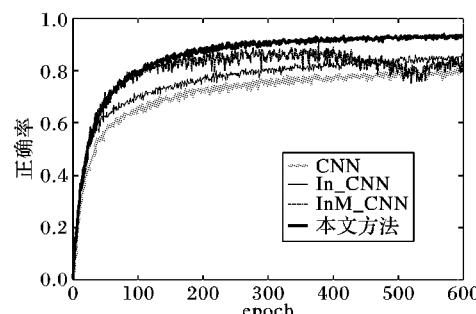


图 7 本文方法与三种方法分类正确率对比

Fig. 7 Classification accuracy comparison among the proposed method and other three CNN methods

3.5 实验与分析

图 8 的分类结果混淆矩阵直观展现了在本文方法下每类场景的分类正确率以及该场景错判为其他场景的情况。图 8 中的分类正确率为 5 次独立重复实验后所得的平均值,总体分类正确率达到了 93.45%。

由图 8 可见本文方法对 UCM_LandUse_21 数据集中耕地、机场、丛林、高尔夫球场、立交桥等纹理差异小的场景分类准确率较高,对建筑、港口、中等密集住宅区等分类准确率较低,说明本文方法对存在二义性,即对纹理差异较小的图像分类效果还有待改善。

为验证本文方法分类优势,通过 UCM_LandUse_21 数据集,将本文方法与近几年具有代表性的几种方法作对比。其分类结果如表 2 所示。



由表2可见,中层视觉词典学习方法所得分类正确率高于以低层特征进行学习的BOVW和支持向量机算法。基于神经网络的算法(ConvNet、MNCC、基于多尺度深度卷积神经网络(Multi-Scale Deep CNN, MS_DCNN)、本文方法)的分类正确率均较高,而中层特征混合了稀疏编码后其分类正确率也得到了一定的提升,分类效果甚至超过了部分神经网络算法,但本文方法分类正确率明显高于其他文献所提方法,因此本文对传统CNN的改进使其图像分类能力得到了显著提升。

表2 不同方法对UCM_LandUse_21数据集的平均分类精度

Tab. 2 Average classification accuracy of dataset UCM_LandUse_21 by different methods

方法	分类精度/%
BOVW ^[18]	76.81 ± 0.41
BOVW + SCK ^[18]	77.71 ± 0.63
空间金字塔匹配 ^[19]	77.70 ± 0.90
SVM-LDA ^[20]	80.33 ± 0.71
中层视觉词典学习 ^[20]	82.72 ± 1.18
MNCC ^[21]	88.26 ± 1.81
ConvNet ^[22]	89.39 ± 1.73
稀疏编码 + 中层特征 ^[23]	89.82 ± 1.67
MS_DCNN ^[24]	91.34 ± 1.29
本文方法	93.45 ± 1.23

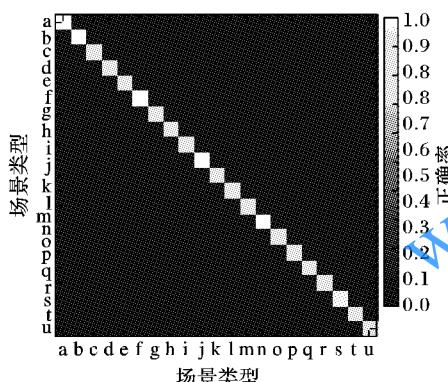


图8 UCM_LandUse_21 场景分类混淆矩阵

Fig. 8 Category confusion matrix for UCM_LandUse_21 scene

表2中的MS_DCNN方法^[24]同样也以深度卷积神经网络为框架并且都利用了多尺度特征,不过该方法是在图像预处理阶段利用controlet变换对图像进行多尺度分解来获得多尺度特征的,并未改变传统卷积神经网络的结构,而且MS_DCNN的分类精度最为接近本文方法,因此本文将该方法与本文方法训练过程中分类精度曲线的变化进行对比。分类准确率的对比如图9所示。

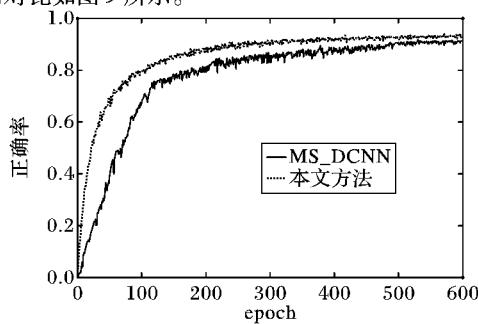


图9 本文方法与MS_DCNN方法的分类正确率对比

Fig. 9 Classification accuracy comparison between the proposed method and MS_DCNN method

可见,本文方法经过较少的迭代次数就能达到80%以上的正确率,而MS_DCNN相对较慢;因此,从正确率的提升速度和最后的正确率来说,本文方法都优于该方法。

4 结语

本文方法通过改进CNN模型直接对图片进行特征提取,通过Inception模块的不同尺度卷积核来增加CNN网络的宽度,从而提高网络特征提取的能力,实现对多尺度特征的利用。Maxout网络结合dropout操作可消除激活函数选择的不确定性,减少参数确定带来的计算步骤和抑制过拟合的影响。实验结果表明,本文对CNN的每项改进都合理有效,并且本文在UCM_LandUse_21数据集上取得了较好的分类效果。如何减少本文方法对存在二义性的图像的误分率是下一步的研究方向。

参考文献(References)

- [1] 蔡月红,朱倩,孙萍,等.基于属性选择的半监督短文本分类算法[J].计算机应用,2010,30(4): 1015–1018.(CAI Y H, ZHU Q, SUN P, et al. Semi supervised short text categorization based on attribute selection [J]. Journal of Computer Applications, 2010, 30 (4): 1015 – 1018.)
- [2] 修驰,宋柔.基于无监督学习的专业领域分词歧义消解方法[J].计算机应用,2013,33(3): 780–783.(XIU C, SONG R. Disambiguation of domain word segmentation based on unsupervised learning [J]. Journal of Computer Applications, 2013, 33(3): 780 – 783.)
- [3] 张永库,李云峰,孙劲光.综合颜色和形状特征聚类的图像检索[J].计算机应用,2014,34(12): 3549–3553.(ZHANG Y K, LI Y F, SUN J G. Image retrieval based on clustering according to color and shape features [J]. Journal of Computer Applications, 2014, 34(12): 3549 – 3553.)
- [4] LI Z, HU D W, ZHOU Z T. Scene recognition combining structural and textural features [J]. Science China Information Sciences, 2013, 56(7): 1–14.
- [5] ZHANG F, DU B, ZHANG L. Saliency-guided unsupervised feature learning for scene classification [J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 53(4): 2175 – 2184.
- [6] ZHU X, MA C, LIU B, et al. Target classification using SIFT sequence scale invariants [J]. Journal of Systems Engineering and Electronics, 2012, 23(5): 633 – 639.
- [7] AKOCLU L, TONG H, KOUTRA D. Graph based anomaly detection and description: a survey [J]. Data Mining and Knowledge Discovery, 2015, 29(3): 626 – 688.
- [8] 吴航,刘保真,苏卫华,等.视觉地形分类的词袋框架综述[J].中国图象图形报,2016,21(10): 1276 – 1288.(WU H, LIU B Z, SU W H, et al. Bag of words for visual terrain classification: a comprehensive study[J]. Journal of Image and Graphics, 2016, 21 (10): 1276 – 1288.)
- [9] LI E, DU P, SAMAT A, et al. Mid-level feature representation via sparse autoencoder for remotely sensed scene classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2016, 10(3): 1068 – 1081.
- [10] SINGH A, PARMANAND, SAURABH. Survey on pLSA based scene classification techniques[C]// Proceedings of the 2014 5th International Conference on Confluence the Next Generation Information Technology Summit. Piscataway, NJ: IEEE, 2014: 555 –



- 560.
- [11] ZHAO L J, TANG P, HUO L Z. Land-use scene classification using a concentric circle-structured multiscale bag-of-visual-words model[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2015, 7(12): 4620–4631.
- [12] 傅德胜, 周辰. 基于密度的改进 K 均值算法及实现[J]. 计算机应用, 2011, 31(2): 432–434. (FU D S, ZHOU C. Improved K-means algorithm and its implementation based on density [J]. Journal of Computer Applications, 2011, 31(2): 432–434.)
- [13] TURAGA S C, MURRAY J F, JAIN V, et al. Convolutional networks can learn to generate affinity graphs for image segmentation [J]. Neural Computation, 2010, 22(2): 511–538.
- [14] PINTO N, DOUKHAN D, DICARLO J J, et al. A high-throughput screening approach to discovering good forms of biologically inspired visual representation [J]. PLoS Computational Biology, 2009, 5(11): e1000579.
- [15] PANG Y, SUN M, JIANG X, et al. Convolution in convolution for network in network[J]. IEEE Transactions on Neural Networks & Learning Systems, 2016, PP(99): 1–11.
- [16] 王朔琛, 汪西莉. 参数自适应的半监督复合核支持向量机图像分类[J]. 计算机应用, 2015, 35(10): 2974–2979. (WANG S C, WANG X L. Semi-supervised composite kernel support vector machine image classification with adaptive parameters[J]. Journal of Computer Applications, 2015, 35(10): 2974–2979.)
- [17] 柴瑞敏, 曹振基. 基于改进的稀疏深度信念网络的人脸识别方法[J]. 计算机应用研究, 2015, 32(7): 2179–2183. (CAI R M, CAO Z J. Face recognition algorithm based on improved sparse deep belief networks [J]. Application Research of Computers, 2015, 32(7): 2179–2183.)
- [18] YANG Y, NEWSAM S. Bag-of-visual-words and spatial extensions for land-use classification[C]// GIS 2010: Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM, 2010: 270–279.
- [19] LU F X, HUANG J. Beyond bag of latent topics: spatial pyramid matching for scene category recognition[J]. Frontiers of Information Technology & Electronic Engineering, 2015, 16(10): 817–829.
- [20] ZHANG F, DU B, ZHANG L. Saliency-guided unsupervised feature learning for scene classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 53(4): 2175–2184.
- [21] 刘扬, 付征叶, 郑逢斌. 基于神经认知计算模型的高分辨率遥感图像场景分类[J]. 系统工程与电子技术, 2015, 37(11): 2623–2633. (LIU Y, FU Z Y, ZHENG F B. Scene classification of high-resolution remote sensing image based on multimedia neural cognitive computing [J]. Systems Engineering and Electronics, 2015, 37(11): 2623–2633.)
- [22] NOGUEIRA K, MIRANDA W O, SANTOS J A D. Improving spatial feature representation from aerial scenes by using convolutional networks[C]// Proceedings of the 2015 28th SIBGRAPI Conference on Graphics, Patterns and Images. Piscataway, NJ: IEEE, 2015: 289–296.
- [23] LI E, DU P, SAMAT A, et al. Mid-level feature representation via sparse autoencoder for remotely sensed scene classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2016, PP(99): 1–14.
- [24] 许夙晖, 蔡晓冬, 赵鹏, 等. 利用多尺度特征与深度网络对遥感影像进行场景分类[J]. 测绘学报, 2016, 45(7): 834–840. (XU S H, MU X D, ZHAO P, et al. Scene classification of remote sensing image based on multi-scale feature and deep neural network [J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(7): 834–840.)

LIU Yutong, born in 1992, M. S. candidate. Her research interests include artificial intelligence, computer vision, neural network, machine learning.

LI Zhiqing, born in 1975, Ph. D., associate professor. His research interests include artificial intelligence, computer vision, neural network, machine learning.

YANG Xiaoling, born in 1992, M. S. candidate. Her research interests include computer vision, artificial intelligence, image annotation.

(上接第 948 页)

- [12] DOMINGOS P. MetaCost: a general method for making classifiers cost-sensitive[C]// KDD 1999: Proceedings of the Fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 1999: 155–164.
- [13] 王金婉. 面向在线不均衡数据分类的极限学习机算法研究[D]. 新乡: 河南师范大学, 2016: 13–25. (WANG J W. Research on extreme learning machine for online sequential imbalanced data classification[D]. Xinxiang: Henan Normal University, 2016: 13–25.)
- [14] 毛文涛, 王金婉, 何玲, 等. 面向贯序不均衡数据的混合采样极限学习机[J]. 计算机应用, 2015, 35(8): 2221–2226. (MAO W T, WANG J W, HE L, et al. Hybrid sampling extreme learning machine for sequential imbalanced data[J]. Journal of Computer Applications, 2015, 35(8): 2221–2226.)
- [15] 毛文涛, 田杨阳, 王金婉, 等. 面向贯序不均衡分类的粒度极限学习机[J]. 控制与决策, 2016, 31(12): 2147–2154. (MAO W T, TIAN Y Y, WANG J W, et al. Granular extreme learning machine for sequential imbalanced data[J]. Control and Decision, 2016, 31(12): 2147–2154.)
- [16] ADANKON M M, CHERIET M. Support vector machine[J]. Computer Science, 2002, 1(4): 1–28.
- [17] 谷琼, 袁磊, 宁彬, 等. 一种基于混合重取样策略的非均衡数据集分类算法[J]. 计算机工程与科学, 2012, 34(10): 128–134. (GU Q, YUAN L, NING B, et al. A novel classification algorithm for imbalanced datasets based on hybrid resampling strategy [J]. Computer Engineering and Science, 2012, 34(10): 128–134.)
- ZHOU Yuhaao**, born in 1992, M. S. candidate. His research interests include big data development in oil and gas fields, artificial intelligence in oil and gas fields.
- ZHANG Hongling**, born in 1966, M. S., associate professor. Her research interests include big data development in oil and gas fields, numerical simulation of oil and gas fields.
- LI Fangfei**, born in 1998. Her research interests include photographic enhancement, computer vision.
- QI Peng**, born in 1993, M. S. candidate. His research interests include heavy oil development, big data development in oil and gas fields.