

基于卷积神经网络的小样本树皮图像识别方法

刘嘉政

(中国林业科学研究院 资源信息研究所,北京 100091)

摘 要:针对在树皮图像分类过程中图像训练数据数量少、识别准确率低的问题,提出一种基于卷积神经网络的小样本树皮图像识别方法。以 5 种常见树种的树皮图像作为研究对象,在基于卷积神经网络的 Inception_v3 模型基础上,对原始数据集进行数据增强的一系列操作,扩大数据集的数量;在此基础上,对所有数据集进行白化处理,以降低数据之间的冗余性,使得特征之间相关性较低;采用 ReLU 激励函数和 Dropout 方法,防止训练时引起的过拟合现象;同时,在模型的最后添加 3 层全连接层,增强模型的特征表达能力,采用 softmax 分类器。最终确定了一个 10 层 CNN 模型:5 个卷积层、2 个池化层、3 个全连接层。结果表明,上述网络模型对数据集的识别准确率为 94%,并且为验证本研究方法的可行性,分别在 MNIST 数据集、ImageNet 数据集、CIFAR-10 数据集进行测试,识别准确率分别为 92%、90%、93%。因此,提出的方法在小样本的识别试验中具有较高的识别准确率和一定的可行性。

关键词:树皮图像;卷积神经网络;Inception_v3;小样本

中图分类号:S789.1 **文献标志码:**A **文章编号:**1001-7461(2019)04-0230-06

Small Sample Bark Image Recognition Method Based on Convolutional Neural Network

LIU Jia-zheng

(Research Institute of Resource Information Techniques, Chinese Academy of Forestry, Beijing 100091, China)

Abstract: Aiming at solving the problems of low image training data and low recognition accuracy in bark image classification process, a small sample bark image recognition method based on convolutional neural network was proposed. The bark images of five common tree species were used as research objects. Based on the Inception_v3 model and convolutional neural network, a series of operations were performed on data enhancement of the original data set, to expand the number of data sets; on this basis, all data sets were whitened to reduce the redundancy between data, so that the correlation between features was decreased; ReLU excitation function and Dropout method were used to prevent over-fitting phenomenon during training. At the same time, three layers of fully connected layers were added at the end of the model to enhance the feature expression ability of the model, and the softmax classifier was used. A 10-layer CNN model was finalized, including 5 convolutional layers, 2 pooled layers, and 3 fully connected layers. The experimental results showed that the above network model had a recognition accuracy of 94% for the data set. In order to verify the feasibility of the proposed method, the MNIST dataset, ImageNet dataset and CIFAR-10 dataset were tested, respectively. The recognition accuracy reached 92%, 90%, and 93%, respectively. Therefore, the proposed method had higher recognition accuracy and certain feasibility in the identification test of small samples.

Key words: bark image; convolutional neural network; Inception_v3; small sample

林业中,通过数字图像对树种种类进行识别,一直是热门的研究领域。目前针对小样本量数据的树种图像识别研究中,主流的方法大体有 2 种:一是基于传统的手动提取特征的机器学习方法。比如多化豫^[1]等为提高机器识别木材准确性,提出了基于 SCN-MSE 的木材图像识别方法,利用 SVM 分类进行识别,提高了樟子松及其树皮的识别率;周熊^[2]等利用多项式函数对木材和树皮进行识别,探索 SVM 分类方法的可行性,取得了理想的识别效果;吴啸天^[3]等通过对小规模木材细胞图像的多个特征进行提取,结合支持向量机(SVM),平均最高识别率达到了 98.11%;扈华^[4]等提出逻辑回归模型对木片和树皮图像进行识别,提高了木片生物能的利用率;李可心^[5]通过提取 14 个特征参数,应用 SOM 神经网络对水曲柳、胡桃楸、黄檗 3 种树木的树皮图像进行识别,识别效果理想。二是基于卷积神经网络的迁移学习自动识别方法。所谓迁移学习,就是将预训练好的网络的强大的特征学习能力迁移到新的图像识别中来。此方法尤其适应于小样本量数据的训练。M. D. Zeiler^[6]等在 ImageNet 数据集上,采用卷积神经网络进行模型预训练,将训练完成的模型可以应用到其他小样本量的图像数据集的训练和识别上,大大提高识别率。A. Sharif^[7]等将卷积神经网络的特征提取能力迁移到新的试验中,取得了不错的效果。但是在林业树种图像识别领域,利用迁移学习方法的研究较少。

因此,本文在现有的研究基础上,提出一种基于卷积神经网络的小样本树皮图像识别方法。采用基于卷积神经网络的迁移学习的模型——Inception_v3,将其强大的特征提取能力移植到本研究的树皮图像识别研究中来,对网络结构进行微调,得到适合本研究的最优模型。为验证提出方法的可行性,在常见的 3 组数据集:MNIST 数据集^[8]、ImageNet 数据集^[9]、CIPAR-10 数据集^[10]上进行测试。最后,与传统的 SVM 法、一般 CNN 法进行比较,取得了理想的识别效果。

1 材料与方法

1.1 研究区概况

研究区为内蒙古大兴安岭,地理坐标为 119°36′30″—125°24′00″E,47°03′40″—53°20′00″N。属于寒温带大陆性季风气候,冬季寒冷干燥,夏季炎热多雨。年平均气温-3.5℃,无霜期 76~120 d,年降水量 300~450 mm。落叶松、白桦、山杨等是这里的主要树种。本文随机划分 60 块试验样地,用于树种图像识别研究。

1.2 数据采集

对落叶松(*Larix gmelinii* (Rupr.) Kuzen.)、白桦(*Betula platyphylla* Suk.)、山杨(*Populus davidiana* Dode)、雪松(*Cedrus deodara* (Roxb.) G. Don)、白皮松(*Pinus bungeana* Zucc.) 5 种树皮图像进行采集,图像均来自于林区设定好的 60 块样地。为保证原始图像数据的自然性和随机性,选择不同时间、不同角度、不同拍摄者、不同拍摄设备对树皮图像进行拍摄。每种树皮各采集原始图像 200 幅,共计 1 000 幅。

1.3 数据预处理

1.3.1 数据集扩增 鉴于采集到的样本数量较少,最直接有效的方法就是对原始数据集进行扩增。常见的数据集扩增方法有旋转任意角度、翻转变换、平移等。为最大限度地保留原始图像信息,本文只采用旋转任意角度和平移来对数据集进行扩增。

旋转任意角度,是指将图像以某一个点为中心旋转 θ 角度,形成一幅新的图像的过程。旋转前后的图像的像素的 RGB 都不会发生改变。因此,本文将图像绕原点旋转。公式如下:

$$\begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_0 \\ y_0 \\ 1 \end{bmatrix} \quad (1)$$

其中, (x, y) 为原图坐标, (x_0, y_0) 为旋转后坐标。

平移操作是指在原图像的所有点都向同一个方向运动,且运动距离相等。平移操作不会改变图像的形状、大小和方向,连结对应点的线段平行且相等。如式(2)所示,假设初始坐标为 (x, y) 的移动距离为 (t_x, t_y) ,分别为 (x_1, y_1) ,则经过平移操作之后,变为:

$$\begin{bmatrix} x_1 & y_1 & 1 \end{bmatrix} = \begin{bmatrix} x & y & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ t_x & t_y & 1 \end{bmatrix} \quad (2)$$

此时,经过旋转和平移之后,扩增了原始数据集,且卷积神经网络对扩增的图像具有一定的旋转平移不变性。此时的数据集数量为每类树皮图像 600 幅,共计 3 000 幅。

1.3.2 数据集增强 对扩增后的数据集进行数据增强操作。由于图像中相邻像素之间具有很强的相关性,在用于训练时,图像输入是冗余的,即增加了网络结构的计算复杂性,又会影响最终的识别精度。因此,本研究决定采用白化操作——PCA 和 ZCA 操作,来降低输入的冗余性。

首先,降低图像特征之间的相关性,采用 PCA 白化操作。对数据进行降旋转操作: $x_{mt}^i = U^T X^i$,用以消除输入特征 x^i 之间的相关性。为使得每个输

入特征具有单位方差,直接使用 $\frac{1}{\sqrt{\lambda_i}}$ 作为缩放因子来缩放每个特征,因此,PCA 白化后的数据如式(3)所示。

$$x_{PCAwhite,i} = \frac{x_{mt,i}}{\sqrt{\lambda_i}} \tag{3}$$

此时的 $x_{PCAwhite,i}$ 是经过 PCA 白化操作之后的结果,不同特征之间不相关且均具有单位方差。

其次,对 PCA 处理后的数据进行 ZCA 操作。所谓 ZCA 白化,是对 PCA 白化基础上进行一个旋转操作,使得白化后的数据更加接近于原始数据。ZCA 白化首先通过 PCA 去除了各个特征之间的相关性,然后是输入特征具有单位方差,此时得到 PCA 白化后的处理结果,然后再把数据旋转回去,得到 ZCA 白化的处理结果,感觉这个过程让数据的特征之间具有一定的相关性。最终,ZCA 白化的结果为 $x_{ZCAwhite} = Ux_{PCAwhite}$ 。

通过数据集扩增和增强操作之后,本研究试验数据集建立完毕。将每类树皮图像随机挑选 100 幅组成测试集,剩余部分作为训练集。另外,为验证本文方法的可行性,分别在 MNIST 数据集、ImageNet 数据集、CIFAR-10 数据集进行测试。

MNIST 数据集:包含 0~9 共 10 个手写数字的共计 70 000 张的灰度图像数据集,其中每张图像包含 28×28 个像素点。每个类别从训练集共计选取 2 500 幅,测试集选取 500 幅。

ImageNet 数据集:包含 1 400 多万幅图像,涵盖 2 万多个种类,是目前深度学习图像处理领域最大的数据集。由于只是用于比较本文方法的有效性,只选取 10 类图像,每类平均选取图像,训练集共计 2 500 幅,测试集共计 500 幅。

CIFAR-10 数据集:由 10 个类组成,共计 60 000 个彩色图像,图像大小为 32×32 。同样,与 ImageNet 数据集一样,每类平均选取图像,训练集共计 2 500 幅,测试集共计 500 幅(表 1)。

表 1 试验数据集

Table 1 Experimental dataset

数据集	训练集/幅	测试集/幅	种类
本研究试验数据集	2 500	500	5
MNIST	2 500	500	10
CIFAR	2 500	500	10
ImageNet	2 500	500	10

1.4 卷积神经网络

常见的卷积神经网络模型结构一般包含输入层、卷积层、池化层、全连接层、输出层等^[11],其结构如图 1 所示。




图 1 卷积神经网络结构

Fig. 1 Convolutional neural network structure

1.4.1 网络结构设计 输入层:是数据集进行识别的入口,会输出一个向量作为卷积操作的输入值。本文的输入数据为 RGB 树皮图像,图像大小设定为 224×224 ,以方便卷积操作。

卷积层:通过卷积操作完成线性映射,是一种局部操作^[12]。通俗来讲,卷积,输入图像、输出图像的特征。卷积层其实就是一系列的滤波器的叠加,每个滤波器都可以看作是一个特征模板,利用这个模板再通过卷积计算的定义就可以计算出 1 幅新图像,新图像就会将此滤波器所代表的特征体现出来,再加 1 个偏置项,赋值给激励函数,则实现了一个特征的提取。卷积运算如式(4)所示。

$$I_j^l = \sum_i I_i^{l-1} \otimes k_{ij}^{l-1} + b_j^l \tag{4}$$

式中, I_j^l 为第 l 层卷积层产生的第 j 个特征图, k_{ij}^{l-1} 表示卷积核数目, \otimes 表示卷积运算, b_j^l 为偏置项。

本研究卷积层均采用 ReLU 激励函数^[13],卷积核大小分别设定为 7×7 、 3×3 ,步长设置为 2。为了保证卷积操作后得到的特征子图不变,在 4 个边缘均扩充 1 像素。

池化层:缩减矩阵尺寸,减少网络权重参数,加快模型的计算速度,同时也有防过拟合的作用。本文模型在卷积层之间加入池化层,采用最大池化采样法^[14],达到数据降维的目的。

全连接层:可以看作是卷积、池化操作之后,将局部特征重新通过权重矩阵组装成完整的图,尤其是用到了全部的局部特征,故叫做全连接。本研究设置 3 层全连接层,增强特征表达能力。在最后一层全连接层中,还加入 Dropout 层^[15],防止训练过拟合。

除以上所述,在第 4、第 5 层卷积层之间,加入 LRN 层,进行局部归一化,起到侧抑制的作用。

1.4.2 Softmax 分类器 分类器采用 Softmax^[16]。Softmax 分类器主要解决多分类的问题,适合类别之间相互排斥的情况。假设给定样本集 $\{(x^1, y^1), (x^2, y^2), \dots, (x^a, y^a)\}$,对于给定的样本输入 x ,输入一个 c 维的向量,它每一种分类所出现结果的概率为 $p(y=i|x)$,假设 $g_\theta(x)$ 如下:

$$g_\theta(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1|x^{(i)}; \theta) \\ p(y^{(i)} = 2|x^{(i)}; \theta) \\ \dots \\ p(y^{(i)} = c|x^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^c e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \dots \\ e^{\theta_c^T x^{(i)}} \end{bmatrix} \tag{5}$$

式中, $\theta_1, \theta_2, \dots, \theta_c$ 表示模型的参数, 他们所有的概率相加为 1。加入规则项, Softmax 分类器的代价函数^[17]为:

$$V(\theta) = -\frac{1}{a} \left[\sum_{i=1}^a \sum_{j=1}^c 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{j=1}^c e^{\theta_j^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^c \sum_{j=0}^n \theta_{ij}^2 \tag{6}$$

其中, $V(\theta)$ 进行最小化, 从而完成 softmax 的分类回归。

1.5 迁移学习

在小样本数据的条件下, 由于数据量的不足, 导致参与 CNN 模型训练时, 会导致训练过拟合, 得不到理想的识别效果。因此, 迁移学习成为时下小样本数据识别的最佳方法选择。迁移学习是一种将已知研究知识应用于相关领域但未知的研究上来的方法^[18-19]。选用 Inception_v3^[20] 作为下一步迁移学习的源训练模型, 然后将模型参数迁移到本文树皮数

据集上进行下一步微调训练^[21]。

1.6 评价标准

采用测试准确率来作为评定识别结果的依据。此时,

$$\text{测试准确率} = \frac{\text{测试正确的图像数量}}{\text{测试图像总数量}}$$

测试准确率越高, 说明识别性效果越好, 本文方法就越有效。

2 结果与分析

在 Windows 8 系统上, 基于开源深度学习框架 TensorFlow^[22], 采用 Python3 编写, 代码运行平台为 Pycharm。

2.1 白化结果

图 2 中(a)和(b)分别给出了任意 9 幅树皮图像的原始图像和白化后的结果。

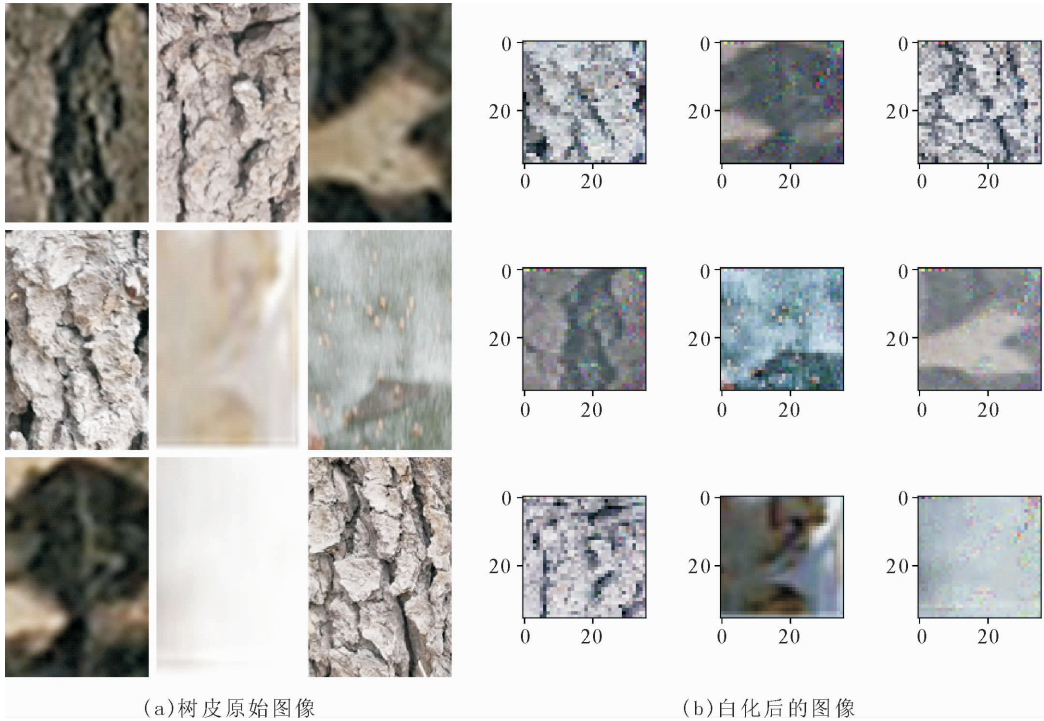


图 2 原始图像(a)与白化处理图像(b)
Fig. 2 Original images (a) and whitened images (b)

2.2 白化处理对试验结果的影响

将原始数据集与经过白化操作处理的数据集进行训练比较, 通过图 3 可以看出, 经过白化处理的数据集识别精度明显提高。由此表明, 试验前对原始数据集进行的预处理操作, 是有必要的。使得所有特征具有相同方差的同时, 特征与特征之间的相关性降低, 减少冗余信息, 从而提高了识别精度。

2.3 Dropout 层设置对试验结果的影响

在最后一层全连接层中设置 Dropout 层, 以防

止训练过拟合。Dropout 层参数的设置将影响最终的训练结果, 因此, 将参数分别取 0.1、0.2、0.3、0.4、0.5, 比较 5 种设置的试验结果(表 2)。结果表明, 当参数设置为 0.5 时, 训练准确率达到 94%, 较其他 4 种设置准确率大大提高。

2.4 全连接层设置对试验结果的影响

对网络结构进行改进, 为增强特征表达能力, 将原来的单层全连接层改为 3 层, 表 3 为单层全连接层和 3 层全连接层在数据集预处理前后的识别结

果。结果表明,3 层全连接层的识别准确率高 于单 层全连接层的准确率。




图 3 原始数据集与白化处理数据集试验结果比较
Fig. 3 Comparison of experimental results between original dataset and whitening dataset

2.5 传统方法识别结果

采用传统的支持向量机(SVM)和一般 CNN 方法对 5 种树皮图像数据集进行识别,预处理前和预处理后的识别结果如表 4 所示。从表 4 结果来看,传统的 SVM 法,过度依赖手动对树皮图像特征进行提取,误差较大,且耗费时间和资源,识别结果较

低;一般的 CNN 法,由于是小样本条件下,无法满足训练要求,识别结果虽然比 SVM 要高,但依然难以达到本文的识别要求。本文方法的识别结果优于上述 2 种方法。

2.6 研究方法在不同数据集上的识别效果

为验证本研究方法的可行性,除在自建数据集上测试以外,分别在 MNIST 数据集、ImageNet 数据集、CIFAR-10 数据集进行测试。从图 4 可以看出,在自建数据集上,识别效率达 94%,达到了识别的目的。另外,在其他 3 个数据集的识别上,也取得了理想的识别效果。总体来说,在本研究试验环境下,本文方法准确率较高,鲁棒性较强。

表 2 不同 Dropout 参数设置对试验结果的影响

Table 2 Effect of different Dropout parameter settings on experimental results

参数设置	训练准确率/%
0.1	0.82
0.2	0.82
0.3	0.85
0.4	0.89
0.5	0.94

表 3 不同层数的全连接层设置的识别结果

Table 3 Identification results of the full connection layer settings of different layers

单层全连接层			3 层全连接层		
树种种类	预处理前	预处理后	树种种类	预处理前	预处理后
落叶松	85.2	90.2	落叶松	92.5	94.8
白桦	85.9	90.8	白桦	91.5	93.5
山杨	86.2	91.2	山杨	92.3	94.1
雪松	84.9	92.3	雪松	92.3	94.5
白皮松	86.2	90.5	白皮松	92.9	94.3

表 4 基于 SVM 和一般 CNN 的树皮图像识别结果

Table 4 Bark image recognition results based on SVM and general CNN

SVM			一般 CNN		
树种种类	预处理前	预处理后	树种种类	预处理前	预处理后
落叶松	51.3	55.2	落叶松	70.5	78.2
白桦	50.2	58.2	白桦	72.8	78.9
山杨	52.8	56.9	山杨	73.2	76.7
雪松	54.3	59.2	雪松	74.2	77.1
白皮松	50.2	59.8	白皮松	75.1	78.2

3 结论与讨论

本研究是在小样本条件下,通过对原始数据集进行扩增和数据增强操作,然后基于卷积神经网络和迁移学习方法,对 5 种常见树种的树皮图像进行识别,取得了不错的识别效果。

通过对原始数据进行白化操作,目的是去除输

入数据中的冗余信息,使得图像特征之间相关性降低,尤其是 ZCA 操作,最大程度上使得白化后的数据接近于最原始的数据特征,即加快了模型的计算效率,又大大提高了最终的识别准确率。

本文引入迁移学习的思想,通过采用在大的数据集上预训练完成的 inception_v3 模型,再迁移到本研究试验条件下,即防止小样本条件下训练过程




图 4 本方法在不同数据集上的试验结果

Fig. 4 Experimental results of the method in this paper on different data sets

发生过拟合现象,又达到预想的识别目的。

为验证本文方法的有效性,首先与传统的 SVM、CNN 方法作比较,识别率远高于上述 2 种方法;其次分别在 MNIST 数据集、ImageNet 数据集、CIFAR-10 数据集进行测试,均取得了不错的识别效果。

尽管本研究提出的方法取得了理想的识别结果,但是否能够应用到其他树种的树皮图像识别,还需要进一步验证。另外,CNN 作为近年来图像识别领域发展最快的方法,展现出了强大的特征提取能力。下一步工作的重点将是,在增大样本量种类和数量的基础上,继续对网络结构进行优化和改进,为林业智能识别树种提供可行的技术支持。

参考文献:

[1] 多化像,孙泉雄,袁云海. 基于图像处理提高木材识别准确性的新方法[J]. 西北林学院学报,2017,32(1):244-247.
DUO H Y,SUN X X,YUAN Y M. Improvement of Wood i-
dentification accuracy based on image processing[J]. Journal of
Northwest Forestry University,2017,32(1):244-247. (in Chi-
nese)

[2] 周熊,多化琼,王振柱,等. 基于图像处理和 SVM 探索木材与
树皮的新识别参数[J]. 西北林学院学报,2014,29(5):199-
202.
ZHOU X,DUO H Q,WANG Z Z, *et al.* New recognition pa-
rameters of wood and bark rate based on image processing and
the SVM[J]. Journal of Northwest Forestry University,2014,
29(5):199-202. (in Chinese)

[3] 吴啸天. 基于多特征提取和 SVM 分类器的木材显微识别[J].
陕西林业科技,2017(5):11-14.
WU X T. Wood microscopic recognition based on feature ex-
traction and SVM classifiers[J]. Shaanxi Forest Science and
Technology,2017(5):11-14. (in Chinese)

[4] 扈华,付学良. 基于逻辑回归模型的木片和树皮的图像识别
[J]. 计算机应用与软件,2015,32(5):189-192.

[5] 李可心,戚大伟,牟洪波,等. 基于灰度共生矩阵与 SOM 神经
网络的树皮纹理特征识别[J]. 森林工程,2017,33(3):24-27.

[6] ZEILER M D,FERGUS R. Visualizing and understanding con-

volutional networks[C]//European Conference on Computer
Vision, Springer, Cham, 2014:818-833.

[7] SHARIF R A,AZIZPOUR H,SULLIVAN J, *et al.* CNN fea-
tures off-the-shelf:an astounding baseline for recognition[C]//
Proceedings of the IEEE Conference on Computer Vision and
Pattern Recognition Workshops,2014:806-813.

[8] MOHAPATRA R K,MAJHI B,JENA S K. Classification per-
formance analysis of MNIST Dataset utilizing a Multi-resolu-
tion Technique[C]//Computing, Communication and Security
(ICCCS),2015 International Conference on. IEEE,2015:1-5.

[9] HE K,ZHANG X,REN S, *et al.* Delving deep into rectifiers:
Surpassing human-level performance on imagenet classification
[C]//Proceedings of the IEEE International Conference on
Computer Vision,2015:1026-1034.

[10] KRIZHEVSKY A,NAIR V,HINTON G. The CIFAR-10 dataset
[J]. online: <http://www.cs.toronto.edu/kriz/cifar.html>,2014.

[11] HUBEL D H,WIESEL T N. Receptive fields,binocular inter-
action and functional architecture in the cat's visual cortex
[J]. The Journal of Physiology,1962,160(1):106-154.

[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.

[13] DAHL G E,SAINATH T N,HINTON G E. Improving deep
neural networks for LVCSR using rectified linear units and
dropout[C]//Acoustics, Speech and Signal Processing (IC-
ASSP),2013 IEEE International Conference on. IEEE,2013:
8609-8613.

[14] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学
报,2017,40(6):1229-1251.

[15] SRIVASTAVA N,HINTON G,KRIZHEVSKY A, *et al.*
Dropout:a simple way to prevent neural networks from over-
fitting[J]. The Journal of Machine Learning Research,2014,
15(1):1929-1958.

[16] RUSSAKOVSKY O,DENG J,SU H, *et al.* Imagenet large
scale visual recognition challenge[J]. International Journal of
Computer Vision,2015,115(3):211-252.

[17] 李彦冬,郝宗波,雷航. 卷积神经网络研究综述[J]. 计算机应
用,2016,36(9):2508-2515.

[18] 石祥滨,房雪键,张德园,等. 基于深度学习混合模型迁移学习
的图像分类[J]. 系统仿真学报,2016,28(1):167-173.

[19] 王琢,汪雅婷,宋文龙,等. 基于深度学习的叶片图像分割算法
[J]. 森林工程,2019,35(1):42-46.
WANG Z,WANG Y T,SONG W L, *et al.* The leaf image
segmentation algorithm based on deep learning[J]. Forsty
Engineering,2019,35(1):42-46. (in Chinese)

[20] YOSINSKI J,CLUNE J,BENGIO Y, *et al.* How transferable
are features in deep neural networks? [C]//Advances in
Neural Information Processing Systems,2014:3320-3328.

[21] PAN S J,YANG Q. A survey on transfer learning[J]. IEEE
Transactions on Knowledge and Data Engineering,2010,22
(10):1345-1359.

[22] ABADI M,BARHAM P,CHEN J, *et al.* Tensorflow:a sys-
tem for large-scale machine learning[C]//OSDI,2016,16:
265-283.