

DOI: 10.12326/j.2096-9694.2021024

基于改进 LeNet-5 模型的木材表面典型缺陷识别方法研究

张赛, 王应彪, 杨谭, 李明

(西南林业大学机械与交通学院, 云南昆明 650224)



摘要: 针对传统木材缺陷识别方法效率低、精度不高及泛化能力差等问题, 对传统LeNet-5模型进行改进: 通过分别增加卷积层和池化层的层数至4层, 以增加网络深度; 采用批量归一化算法, 以解决内部协变量位移过拟合的问题; 改用Leaky Relu函数作为激活函数, 并加入稀疏分类交叉熵作为损失函数, 使用Adam作为优化器, 来优化网络模型。应用改进LeNet-5模型对辐射松木材常见缺陷(结疤、裂痕)及无缺陷样本集进行识别试验, 结果表明: 相对于传统LeNet-5模型以及VGG19、AlexNet、ResNet-50三种经典模型, 改进LeNet-5模型的训练集准确率最高为99.87%、验证集为99.43%, 运算时间缩短, 木材缺陷识别精度和效率提高。

关键词: 木材缺陷检测; 改进LeNet-5模型; 深度学习; 卷积神经网络

中图分类号: S781.5; TS67 文献标识码: A 文章编号: 2096-9694 (2021) 06-0031-07

Detecting Method of the Wood Surface Defects Based on Modified LeNet-5 Model

ZHANG Sai, WANG Ying-biao, YANG Tan, LI Ming

(School of Machinery and Transportation, Southwest Forestry University, Kunming 650224, Yunnan, China)

Abstract: In order to improve efficiency, accuracy and commonization, the traditional LeNet-5 model was modified for detecting wood surface defects by increasing the number of convolutional layers and the pooling layers to 4 so that the network depth was increased. The batch normalization algorithm was used to solve internal co-variate shift displacement over-fitting problem. Leaky Relu function was used as the activation function, then sparse categorical cross entropy was added as the loss function, as well as Adam was used as the optimizer to enhance the network model. The comparison test was carried out on the samples of *Pinus radiata* with and without classical defects(knots and cracks). The results showed that the modified LeNet-5 model performed best comparing with VGG19, AlexNet and ResNet-50 classic models. The accuracy rate was 99.87%; the verification set was 99.43%; the operation time was reduced, therefore the accuracy and efficiency of detecting wood surface defects were improved.

收稿日期: 2021-03-09; 修改日期: 2021-06-01

基金项目: 国家自然科学基金“基于声发射能量模型的胶合木结构蠕变机理与演变规律研究”(31760182); 国家自然科学基金“基于振动运移的核桃自适应定向破壳机理及果仁损伤状态检测方法”(52165038); 云南省教育厅科学研究基金“基于直线振动的核桃定向输送方式及破壳效果评价”(2019J0186)。

作者简介: 张赛 (1993—), 男, 硕士生。Email: 3507838431@qq.com

通讯作者: 王应彪, 男, 副教授。Email: wybjob@163.com

Key words: wood defect detection; modified LeNet-5 model; deep learning; convolution neural network

在木制品加工和使用过程中,节子、裂纹及色变等缺陷问题直接影响产品质量、生产成本和使用价值^[1]。传统木材缺陷识别方法,如人工检测、超声波检测、X射线检测,不仅费时费力,效率低,而且存在识别准确率低、检测设备成本昂贵以及对实际检测环境要求高等问题,难以满足当下木材表面缺陷识别检测的需求^[2-5]。为了解决上述问题,有必要进行缺陷识别和检测的研究。

近年来随着人工智能软硬件技术的迅速发展,深度学习成为国内外研究的热点,基于深度卷积神经网络的木材缺陷智能识别检测方法研究得到快速发展,并取得较好的研究成果。如:基于优化的卷积神经网络缺陷识别方法,应用于木材缺陷检测的准确率达98.6%^[6];使用Mobile Net的深度模型对木材缺陷进行识别,实现对木材单缺陷与多缺陷的定位功能^[7];增加网络模型结构的深度,采用Xavier初始化方法优化网络模型,也可对木材缺陷进行识别检测^[8]。

目前深度卷积神经网络在木材缺陷识别与检测中应用较多,但传统算法模型过于简单,使用的样本数据量少,存在一定的局限性,且需要对缺陷图片进行复杂的预处理,网络泛化能力低^[9]。针对以上问题,本研究基于经典CNN架构的传统LeNet-5模型构建改进神经网络模型,并将此模型应用于辐射松木材缺陷识别,与VGG19、AlexNet、ResNet-50三种经典模型^[10-14]进行对比分析,旨在为木材表面缺陷的高效智能检测提供理论支持。

1 材料与方法

1.1 木材缺陷样本图片采集

木材缺陷样本图片采集装置(图1a),线阵工业相机(分辨率2 048 dpi×2 048 dpi),该装置通过传送带输送木材到指定位置,触发光电传感器从而获得脉冲信号,控制线阵工业相机拍摄木材缺陷图片。为减少自然环境对拍摄环境的影响,增加了LED光源设置,拍摄得到木材样本图片(图1b)。木材缺陷样本图片来源于某木工机械制造厂在线采集的辐射松(*Pinus radiata*)木材样本。

木材缺陷集样本总数为888张,其中结疤308张、裂痕199张、无缺陷381张,结疤缺陷不规则,形态各异,裂痕缺陷大小不一。




图1 样本采集装置及图片

Fig.1 Wood sample pictures and image collecting devices

1.2 样本预处理

网络训练时需要大量的数据,以增加网络的泛化能力。试验通过随机上下翻转、左右旋转、亮度变换等图像扩展算法增加样本数量,将原始图像扩充为8 880张,且采取中值滤波降低图像噪声干扰,同时还能很好地保持图像边缘。经扩展降噪、扩展处理后的部分图像数据如图2所示。

由于木材缺陷特征复杂不规则,且缺陷位置分布不均,采集图片数据像素大小不等,而卷积神经网络的输入数据为多维张量,因此将图像裁剪转换为224×224像素大小,同时进行归一化处理,并按8:2的比例,随机选取7 104张木材缺陷图片作为训练集,其余1 776张作为验证集,建立

扩充后的木材缺陷数据样本库，其中训练集用于训练网络，验证集用于验证网络模型的准确性。



图2 扩展后的部分缺陷图片
Fig.2 Defect image data set extension

2 模型构建

本研究对基于经典卷积神经网络的传统 LeNet-5 模型进行改进，构建深度学习架构。

2.1 改进 LeNet-5 模型

传统 LeNet-5 模型网络结构见图 3，共有 7 层（2 层卷积层、2 层池化层、2 层全连接层、1 层输出层）^[15]，每层都包含可训练参数，其输入层为 32×32 像素的灰度图，C1 层使用 5×5 大小的卷积核，滑动步长为 1 来抽取图像的特征，通过对输入的图像作卷积得到 6×28×28 尺寸大小的特征图，卷积核的数量为 6，图像大小为 28×28；C1 为 28×28 卷积层，S2 为 14×14 池化层，C3 为 10×10 卷积层，S4 为 5×5 池化层，C5 为全卷积层，F6 为全连接层，使用径向基函数（RBF）进行识别分类。




图3 传统 LeNet-5 模型网络结构示意图
Fig.3 Schematic diagram of traditional LeNet-5 model network structure

传统 LeNet-5 模型的输入为 32×32 像素的灰度图，但由于木材缺陷特征过于复杂，其图像的像素值偏大，因此在多次试验后，采用尺寸为 224 像素×224 像素×3 的图像作为改进 LeNet-5 模型的输入，其中 3 为 RGB 的通道数。通过改变卷积层与

池化层的网络结构，以便更快地提取缺陷的特征，并使用最大池化层替代平均池化层。传统 LeNet-5 模型使用线性整流函数（ReLU）作为激活函数，在网络训练时，无法识别 0 以下的权重，从而出现神经元“死亡”的现象，导致训练异常。本研究改用 Leaky Relu 函数作为激活函数，当神经元未激活时，仍会有一个小梯度的非零值输出^[16]，并使用自适应矩估计函数 Adam 算法替代随机梯度下降算法（SGD）作为优化器，最后使用 SoftMax 作为网络的分类器。改进与传统 LeNet-5 模型的参数对比列于表 1。

表 1 改进与传统 LeNet-5 模型参数

Tab.1 Parameters of modified and traditional LeNet-5 models

模型	传统 LeNet-5	改进 LeNet-5
输入层像素	32×32	224×244×3
卷积层数	3	7
池化层数	2	4
卷积核步长	5×5、2×2	2×2、3×3
卷积核数	6、16、120	6、16、32、128
激活函数	ReLU	Leaky Relu
优化器算法	SGD	Adam

改进 LeNet-5 模型的结构见图 4，包括 1 个输入层、7 个卷积层（Conv）、4 个最大池化层（Pool）、1 个平坦层（Flatten）、1 个全连接层（FC）、1 个输出层（SoftMax），其中输入层为 224×224 像素的图像样本数据，在经过两次卷积和一次最大池化后图像数据变为 109×109 像素，而后再经过多次卷积和最大池化后最终变成 10×10×128 像素的三阶矩阵，由于全连接层的输入为一维向量，通过添加平坦层（Flatten）将 10×10 的三阶矩阵重置为 12 800 维的向量。

在每层卷积和全连接层后加入批量归一化处理以防止过拟合，并采用 Leaky Relu 作为激活函数，克服由于网络变深导致的梯度消失；使用稀疏分类交叉熵作为损失函数，并使用自适应矩估计函数 Adam 作为优化器来优化网络模型。最后采用 SoftMax 作为分类函数，实现对辐射松木材 3 种样本缺陷的分类识别，其改进后的网络模型各层参数见表 2。部分卷积和池化特征图的可视化数据见图 5，采用窄卷积作为卷积运算的填充模式，以达到增加卷积神经网络模型泛化能力的目的。




图 4 改进 LeNet-5 模型网络结构

Fig.4 The network structure of modified LeNet-5 model

表 2 改进 LeNet-5 模型卷积神经网络结构参数

Tab.2 Convolution neural network structure parameters of modified LeNet-5 model

层数	名称	卷积核数	步长	输出	层数	名称	卷积核数	步长	输出
1	Input	-	-	224×224×3	9	Pool3	2×2	2	24×24×32
2	Conv1	3×3	1	220×220×6	10	Conv6	3×3	1	22×22×128
3	Conv2	3×3	1	218×218×6	11	Conv7	3×3	1	20×20×128
4	Pool1	2×2	2	109×109×6	12	Pool4	2×2	2	10×10×128
5	Conv3	5×5	1	105×105×16	13	Flatten	-	-	12 800
6	Conv4	3×3	1	103×103×16	14	FC1	-	-	64
7	Pool2	2×2	2	51×51×16	15	SoftMax	-	-	3
8	Conv5	3×3	1	49×49×32					




图 5 卷积和池化特征图的可视化效果

Fig.5 Visualization of convolution and pooling features

2.2 批量归一化

为解决卷积神经网络中容易出现过拟合的现象，考虑到使用 Dropout 或 L2 正则化方法需对超参数进行复杂调节，因此本研究采用批量归一化^[17]算法。该算法是通过解决内部协变量位移防止卷积神经网络过程中出现的过拟合现象；在训练过程中无需对超参数进行复杂的调节，就可达到快速

的收敛效果，有效地提高网络训练速度，增强网络的泛化能力和鲁棒性。

3 结果与分析

3.1 试验平台

试验所用计算机具体配置为：Intel Core i7-10700 GPU@ 2.90GHz，NVIDIA Ge-force GTX

2070S 显示适配器, 16GB DDR4 内存系统, 环境配置: Anaconda3 + Tensorflow2.0 + VS2017 + Python3.7+cuda10.0+cudnn10.0, 并使用 GPU (RTX 2070S 8G) 来加速网络模型的训练, 卷积神经网络可训练的相关参数, 见表3。

表3 卷积神经网络可训练的相关参数

Tab.3 Relevant parameters of convolution neural network that can be executed

参数名称	改进 LeNet-5	传统 LeNet-5	VGG19	ResNet-50	AlexNet
训练轮次	20	36	30	40	30
初始学习率	0.0001	0.00001	0.0005	0.0005	0.0005
移动平均衰减率	0.9	0.9	0.9	0.9	0.9

3.2 网络训练

将训练集的 7 104 张木材缺陷图像, 对改进后 LeNet-5 模型进行训练, 设置初始学习率为 0.0001; 训练次数为 20, 动量系数为 0.1, 训练和验证的批次尺寸大小为 32, 传统 LeNet-5 模型及其他模型的训练和验证的批次大小设为 32, 动量参数设置为 0.9, 其他重要参数 (训练轮次、初始学习率、移动平均衰减率) 设置见表 3。改进 LeNet-5 模型采用自适应矩估计 (Adam) 算法迭代过程来优化网络模型, 可以有效降低损失函数的数值; 在每次训练结束后, 根据已损失函数的值, 调整优化器的学习率和移动平均衰减率, 改变全连接层 (FC1) 神经的元个数, 使模型的准确率呈上升趋势, 损失值为下降趋势, 直到准确率达到期望值后, 结束调节超参数。改进模型准确率和损失值曲线如图 6 所示。

图 6 显示, 经过 20 次迭代后, 本研究的网络模型的准确率和损失值趋于稳定, 训练集和验证集的准确率分别为 99.87% 和 99.43%, 说明木材缺陷的识别在本模型方法上具有很好的识别效果。

3.3 模型对比分析

5 种模型准确率和损失值曲线对比结果见图 7。5 种网络模型训练集准确率值对比, 见表 4。

图 7 显示, 改进 LeNet-5 模型相比于 VGG19、ResNet-50、AlexNet 模型, 曲线较为平滑、波动小, 模型收敛速度快, 在 20 次训练后准确率和损失值趋于稳定。




图6 改进 LeNet-5 模型准确率与损失值曲线
Fig.6 Accuracy and loss curves of the modified LeNet-5 model network structure




图7 5种模型准确率与损失值曲线对比结果
Fig.7 Comparison results of accuracy and loss curves of five models

表 4 显示, 迭代 36 次后, 传统 LeNet-5 模型达到收敛, 木材缺陷训练集与验证集的识别准确率为 98.24% 和 97.84%, 低于改进 LeNet-5 模型, 因此改进后的模型有效地提高了木材缺陷的识别率。

改进 LeNet-5 模型平均每轮的迭代时间为 26.30 s, 比传统 LeNet-5 模型平均每轮迭代时间短。调整 VGG19、ResNet50、AlexNet 三种经典深

度卷积神经网络模型的全连接层的神经元个数后，对比发现，改进网络模型的结构参数最少，识别准确率最高；虽然改进 LeNet-5 模型训练每轮时间比 AlexNet（21.87 s）长，但训练集和验证集的准确率均高于 AlexNet 模型。VGG19 的训练集准确率在三种经典模型中最高（99.52%），但验证集的准确率低于 AlexNet，而 ResNet-50 模型的验证集准确率最低。

表4 5种网络模型训练集准确率值对比
Tab.4 Verification accuracy of 5 network models
executing data sets

模型种类	迭代次数/ 次	平均迭代 时间/s	训练集准 确率/%	验证集准 确率/%
传统 LeNet-5	36	28.00	98.24	97.84
改进 LeNet-5	20	26.30	99.87	99.43
VGG19	30	74.03	99.52	98.24
ResNet-50	40	56.75	99.49	95.17
AlexNet	30	21.87	99.30	98.98

分析其原因，传统 LeNet-5 模型网络模型结构简单，网络泛化能力低，使用 ReLU 作为激活函数时，无法识别 0 以下的权重，导致训练异常，达不到预期的效果，其他模型卷积核步长、卷积核的

数量过大，训练所消耗的时间长，同时网络的深度过深，容易出现梯度爆炸，影响训练的准确率，而改进 LeNet-5 模型能够有效地解决这些问题。综上，改进 LeNet-5 模型在本次试验的木材缺陷数据集上具有较好的识别效果。

3.4 模型预测试验

为了验证模型的可行性，将上述已训练完成的改进 LeNet-5 模型以 mymodel.h5 的文件形式保存，便于稳定加载模型不受其他因素的影响。对木材缺陷图像预测识别之前，需要对木材缺陷数据集预处理：首先将原始缺陷（结疤、裂痕）及无缺陷图像共 888 张作为预测数据集，存储在同一个文件夹下并将其顺序打乱；其次采用双线性插值法，将木材缺陷图像压缩为训练时的输入相同大小为 224×224 像素的 RGB 图像；最后对缺陷图像进行归一化处理为 0~1 之间的数值。

在 Windows10 专业版的环境下，tensorflow2.0 框架下，以 python3 为编程语言，加载模型文件，进行辐射松木材缺陷图像的预测，具体见图 8。




图8 木材缺陷及无损样本检测图
Fig.8 Wood defects and non-destructive sample prediction chart

如图8所示为检测15张木材缺陷图, 每张图上方标注的knot、crack、texture对应结疤、裂痕、无缺陷, 数字为识别的准确率。从图8中结果可以看出, 该模型能够准确地预测出木材缺陷的种类, 其中结疤、无缺陷的预测正确率较高, 而裂痕的预测正确率略低(表5)。

表5 木材缺陷预测识别率

Tab.5 Wood defect detection accuracy data

种类	识别正确个数	正确率/%	识别错误个数	错误率/%
结疤	308	98	5	2
裂痕	199	94	10	6
无缺陷	381	100	0	0

4 结论

本研究对经典CNN架构的传统LeNet-5模型进行改进, 通过增加网络层数, 同时用批量归一化算法解决内部协变量位移及过拟合的问题, 改用Leaky Relu函数作为激活函数, 并加入稀疏分类交叉熵作为损失函数, 使用Adam作为优化器来优化网络模型。通过辐射松木材常见缺陷及无缺陷图片样本试验发现, 改进LeNet-5模型能够有效地提取木材缺陷特征, 相比传统LeNet-5模型、VGG19、ResNet-50和AlexNet模型, 改进LeNet-5模型减少了参数数目, 降低了训练时间, 提高了木材缺陷识别精度, 对木材缺陷图片预测的识别正确率高, 能有效地预测出结疤、裂痕两种木材缺陷及无缺陷木材样本集。本试验仅对辐射松木材的两种缺陷及无缺陷样本集进行预测识别, 在下一步的研究中, 可以增加木材的种类、增加缺陷的适用性, 为木材表面缺陷智能识别提供一种精准有效的方法。

参考文献:

- [1] 范佳楠, 刘英, 杨雨图, 等. 机器视觉在木材缺陷检测领域应用研究进展[J]. 世界林业研究, 2020,33(3):32-37.
FAN J N, LIU Y, YANG Y T, et al. Research progress in the application of machine vision to wood defect detection[J]. World Forestry Research, 2020,33(3):32-37.
- [2] 丁伟彪, 王宝金. 木材缺陷检测技术研究概况与发展趋势[J]. 林业机械与木工设备, 2019,47(1):4-8.
DING W B, WANG B J. Research and development trend of wood defect detection technology[J]. Forestry Machinery & Woodworking Equipment, 2019,47(1):4-8.
- [3] 赵鹏, 赵匀, 陈广胜. 基于3D扫描技术的木材缺陷量化分析[J]. 农业工程学报, 2017,33(7):171-176.
ZHAO P, ZHAO Y, CHEN G S. Quantitative analysis of wood defect based on 3D scanning technique[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017,33(7):171-176.
- [4] 王立扬, 张瑜, 沈群, 薛勇. 基于改进型LeNet-5的苹果自动分级方法[J]. 中国农机化学报, 2020,41(7):105-110.
WANG L Y, ZHANG Y, SHEN Q, et al. Automatic detecting and grading method of apples based on improved LeNet-5[J]. Journal of Chinese Agricultural Mechanization, 2020,41(7):105-110.
- [5] 萧嘉奕, 马艳, 周竹, 方益明. 基于Faster R-CNN模型的木材表面节子缺陷检测[J]. 木材工业, 2020,34(2):45-48.
XIAO J Y, MA Y, ZHOU Z, et al. Detection of timber surface knots based on faster R-CNN[J]. Chinese Journal of Wood Science and Technology, 2020, 34(2):45-48.
- [6] 刘英, 周晓林, 胡忠康, 等. 基于优化卷积神经网络的木材缺陷检测[J]. 林业工程学报, 2019,4(1):115-120.
LIU Y, ZHOU X L, HU Z K, et al. Wood defect recognition based on optimized convolution neural network algorithm[J]. Journal of Forestry Engineering, 2019, 4(1):115-120.
- [7] 李若尘, 朱悠翔, 孙卫民, 等. 基于深度学习的木材缺陷图像的识别与定位[J]. 数据采集与处理, 2020,35(3):494-505.
LI R C, ZHU Y X, SUN W M, et al. Recognition and localization of wood defect image based on deep learning[J]. Journal of Data Acquisition and Processing, 2020,35(3):494-505.
- [8] TING H, YING L, YABIN Y, et al. Application of deep convolutional neural network on feature extraction and detection of wood defects[J]. Measurement, DOI:10.1016/j.measurement.2019.107357.
- [9] 肖雨晴, 杨慧敏, 王柯欣, 易强. 卷积神经网络在木材缺陷检测应用中的研究进展[J]. 木材科学与技术, 2021,35(3):12-18.
XIAO Y Q, YANG H M, WANG K X, et al. Research progress of convolutional neural networks in the application of wood defect detection[J]. Chinese Journal of Wood Science and Technology, 2021, 35(3):12-18.
- [10] Kumar A, Gandhi C P, Zhou Y, et al. Improved deep convolution neural network (CNN) for the identification of defects in the centrifugal pump using acoustic images[J]. Applied Acoustics, DOI: 10.1016/j.apacoust.2020.107399.
- [11] Khan A, Sohail A, Zahoor U, et al. A survey of the recent architectures of deep convolutional neural networks[J]. Artificial Intelligence Review, DOI:10.1007/s10462-020-09825-6.
- [12] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks: NIPS[J]. Communications of the ACM, 2017: DOI:10.1145/3065386.
- [13] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014. DOI: https://ui.adsabs.harvard.edu/abs/2014arXiv1409.1556S.
- [14] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]. USA: IEEE, 2016.
- [15] Lecun Y, Bottou L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998,86(11):2278-2324.
- [16] 张力超, 马蓉, 张鑫. 改进的LeNet-5模型在苹果图像识别中的应用[J]. 计算机工程与设计, 2018,39(11):3570-3575.
ZHANG L C, MA R, ZHANG Y X. Application of improved LeNet-5 model in Apple image recognition[J]. Computer Engineering and Design, 2018, 39(11): 3570-3575.
- [17] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[J]. JMLR.org, 2015.
(本文编校 孟凡丹、向 琴)