

深度学习在木材加工领域的研究进展

刘英, 庄子龙, 唐敏

(南京林业大学机械电子工程学院, 机电产品包装生物材料国家地方联合工程中心, 南京 210037)

摘要:随着木材加工自动化的快速发展,深度学习技术已在木材加工领域得到运用,它的引入对木材加工企业转型升级、向着智能制造方向发展具有重要意义。概述了深度学习在木材加工领域的研究进展和具体应用,首先介绍了自编码器、深度信念网络、卷积神经网络、生成对抗网络、递归神经网络以及 ViT 6 种典型深度学习模型的模型结构及工作原理,并分析了不同深度学习模型的应用场景以及存在的问题。在此基础上结合具体木材加工领域详细地介绍了深度学习的应用,在原木检尺领域,深度学习方法可以解决自动化材积检测问题;在木材检测领域,深度学习方法为木材树种分类、缺陷识别以及纹理识别提供了有效工具;在木材干燥领域,深度学习方法因其良好的自适应能力可以建立更为精确的木材干燥模型。最后展望了深度学习在木材加工过程中亟待加强研究的方向,以提升深度学习解决木材加工过程中应用问题的广度和深度,提升木材加工产业的智能化水平和生产效率,进一步提高我国木材加工制造企业的科技创新能力,提高企业竞争力。

关键词:深度学习;原木检尺;木材分类与识别;木材干燥;木材加工

中图分类号:TP391.4;S781

文献标志码:A

文章编号:2096-1359(2023)04-0001-09

Research progress on deep learning in wood processing

LIU Ying, ZHUANG Zilong, TANG Min

(College of Mechanical and Electronic Engineering, National Engineering Research Center of Biomaterials for Mechanical and Electrical Packaging Products, Nanjing Forestry University, Nanjing 210037, China)

Abstract: With the rapid development of wood processing automation, deep learning technology has been applied in the field of wood processing. Its introduction is of great significance to the transformation and upgrading of wood processing enterprises and the development of intelligent manufacturing. This paper summarizes the research progress and specific application of deep learning in the field of wood processing. Firstly, the model structure and working principle of six typical deep learning models, including the autoencoder, deep belief network, convolutional neural network, generative adversarial network, recurrent neural network, and Vision Transformer, are introduced, and the application scenarios and existing problems of different deep learning models are analyzed. Autoencoder has the advantages of simple reconstruction, stacking multiple layers and strong generalization, but it has the drawback of long training time. Deep belief network has strong autonomous feature extraction ability and high target recognition accuracy, but it is less applied in the field of wood industries. Convolutional neural network model is usually composed of convolutional layer, pooling layer and fully connected layer, which has translation, rotation, and scaling invariance to input data. Generative adversarial network is an unsupervised generation model, which can be adjusted during the training process of the model. Recursive Neural Network is a neural network based on sequence modeling, and its core feature is cyclic connection, but it has the drawback of gradient disappearance and explosion problems. Vision Transformer, which is used in natural language processing, also used in the image field and has a strong ability to express features but relies on large amounts of data. On this basis, the application of deep learning is introduced in detail in combination with the specific wood processing field. In the field of log scaling, the deep learning method can solve the problem of automatic volume detection. In the field of wood detection, deep learning method provides an effective tool for wood species identification, defect recognition and texture classification. In the field of wood drying, the deep learning method can establish a more accurate wood drying model because of its good adaptive ability. Finally, the future research direction of the deep learning technology in wood processing is prospected to improve the breadth and depth of the deep learning technology, solve the application problems in wood processing, enhance the intelligent level and production efficiency

收稿日期:2022-11-03

修回日期:2023-02-25

基金项目:江苏省重点研发计划(产业前瞻与关键核心技术)项目(BE2019112)。

作者简介:刘英,女,教授,研究方向为木材无损检测、人工智能、图像处理。E-mail:lying_new@163.com

of wood processing industry, further increasing the scientific and technological innovation ability and improving the competitiveness of wood products in domestic and international markets.

Keywords: deep learning; log scaling; wood classification and identification; wood drying; wood manufacturing

木材作为四大基础建筑材料(木材、水泥、钢材和塑料)中唯一的可再生资源,被广泛应用于家具、装修和建筑等领域^[1]。随着对木制品需求量和品质需求的不断攀升,我国木材加工装备自动化程度及加工精度偏低等问题也逐渐显现。同时我国作为典型的少林国家,木材资源储量远远不能满足当前市场需求,木材资源的供应压力日益紧张,迫使木材加工产业向智能制造生产模式发展^[2]。随着深度学习的兴起和不断发展,特别是卷积神经网络、深度信念网络和递归神经网络等深度模型在图像处理等方面大量成果的涌现,相关方法也被逐步应用到木材加工领域,有效提高了木材利用率,推动了木材加工企业的转型升级。笔者简要介绍了6种具有代表性的深度学习模型,重点阐述了深度学习在木材加工领域的研究现状,并对深度学习在木材加工中的发展方向进行了展望。

1 深度学习主要模型

深度学习的概念源于人工神经网络的研究,可理解为深层的神经网络。深度学习通过组合低层特征形成更加抽象的高层表示属性类别或特征,以发现数据的分布式特征表示,免除了高维数据的维度灾难问题。目前深度学习技术逐步应用于加工制造业,成为研究热点,下面简要介绍最为典型的6种基本深度学习模型。

1.1 自编码器

Rumelhart 等^[3]在1986年首次提出了自编码器(autoencoder, AE)的概念,随后, Bourlard 等^[4]对其进行了详细的阐释。AE作为一种典型的无

监督深度学习模型,其优化目标是使输出能够实现输入数据的重构。图1给出了一个3层结构的AE模型,输入层和输出层有相同的维度。该模型可被分为编码器和解码器两部分:编码器将输入 x 压缩为潜在空间表征 h ,解码器将潜在空间表征 h 重构为输出 y 。





图1 自编码器网络结构

Fig. 1 Structure of autoencoder

近年来,AE由于具有重建简单、可堆叠多层和泛化性强等优点,被国内外学者广泛研究与改进。常见的改进方法是对隐含层增加一定的约束条件。AE及其改进模型均被成功应用于各种研究领域,例如目标识别^[5-6]、图像分类^[7-8]和自然语言处理^[9]等,但大部分使用AE的方法都存在训练时间过长的问題。

1.2 深度信念网络

Hinton 等^[10]在2006年首次提出了深度信念网络(deep belief network, DBN)概念,这是一种结合无监督学习和有监督学习的多层概率机器学习模型,由多层受限玻尔兹曼机(restricted boltzmann machine, RBM)堆叠和一层有监督的“反向传播(back propagation, BP)”网络组成。图2为RBM



a) RBM模型结构

b) DBN模型结构

图2 RBM和DBN模型结构

Fig. 2 Structure of RBM and DBN

模型和一个由3层RBM堆叠而成的DBN模型。其中, h 为隐含层神经元的状态向量, v 为可视层神经元的状态向量, b 为隐含层的偏执系数, a 为可视层的偏执系数。DBN的训练过程可分为两个阶段:首先对RBM进行逐层无监督预训练;再用反向传播算法对整个网络进行有监督的调优。这种训练方法使DBN具有较强的自主特征提取能力和较高的目标识别精度。目前DBN已被广泛应用于图像识别^[11-12]、故障诊断^[13]和系统预测^[14-15]等领域,但在木材行业的应用较少。




图3 CNN模型结构

Fig. 3 Structure of CNN

随着计算机硬件的发展,CNN网络的深度逐步加深,VGGNet、ResNet、DenseNet等网络结构被广泛应用于图像分类任务,同时国内外学者对CNN进行了深入研究和改造,提出了全局池化扩张卷积^[17]、坐标注意力机制、深度可分离卷积^[18]、GAF编码算法^[19]和马尔科夫转移场(markov transition field, MTF)^[20]等方法对CNN网络结构进行改进,进一步结合具体任务对图像等二维数据进行分析。以卷积神经网络为骨架的深度学习目标检测算法是当下目标检测算法的研究热点,其主要分为RCNN系列(R-CNN, Fast R-CNN, Faster R-CNN、Mask R-CNN)、YOLO系列(YOLOv1 ~ YOLOv8)以及SSD(single shot multibox detector)算法。

1.4 生成对抗网络

生成对抗网络(generative adversarial network, GAN)^[21]是Goodfellow等在2014年提出的一种非监督式生成模型,其网络结构如图4所示,主要包括生成器(G)和判别器(D),生成器与判别器均由全连接网络构成。GAN的思想来自博弈论中的零和博弈,在模型的训练过程中经过多次的对抗调整,不断更新自身的参数使得损失最小,最终达到了一个纳什均衡状态^[22]。这种独特的对抗性思想使得GAN在多个领域得到迅速发展,同时也使GAN存在梯度消失和模式崩溃等问题。为了解决

1.3 卷积神经网络

卷积神经网络(convolutional neural network, CNN)是根据动物视觉系统的工作方式提出的一种前馈式神经网络。CNN模型通常由卷积层、池化层和全连接层组成,其实质是通过构建多个能够提取输入数据特征的滤波器,对输入数据进行逐层卷积及池化,逐级提取隐藏在数据之中的拓扑结构特征,最终获得输入数据的平移、旋转及缩放不变的特征表示^[16]。图3所示为一个5层CNN模型的具体结构。

这些问题,国内外学者对GAN做出了诸多改进,如引入高斯金字塔和拉普拉斯金字塔^[23],添加了循环机制^[24],嵌入双注意力机制模块^[25]等。生成对抗网络可以用于数据的生成任务,如图像重建、信号重构、数据扩充等。




图4 GAN模型结构

Fig. 4 Structure of GAN

1.5 递归神经网络

递归神经网络(recursive neural network, RNN)^[26]是一种基于序列建模的神经网络,其核心特点是循环连接。不同于DBN和CNN,RNN中各隐含层之间的神经元相互连接,使得隐含层的输入数据包括上一个相邻层和上一时刻当前层的输出数据,因此RNN能够对过去的信息进行记忆。图5所示为一个简化的RNN模型结构。但是传统RNN存在严重的梯度消失现象和爆炸问题,导致RNN无法处理很长的输入序列。为了解决上述问题,长短时记忆模型(long short term memory, LSTM)、门控递归单元(gated recurrent unit, GRU)和最小门控单元(minimal gated unit, MGU)等改进RNN模型被提出并应用。从原理来看,递归神经

网络往往用于存在某种规律的数据建模,如音频信号、时效处理的性能预测等。




图5 简化RNN模型结构

Fig. 5 Structure of simple RNN

1.6 视觉 Transformer

Transformer 是一种主要基于自注意力机制的深

度神经网络,最初应用于自然语言处理领域,它抛弃了传统的 CNN 和 RNN,整个网络由自注意力和前向传播神经网络组成,因而可以实现自由堆叠,在自然语言处理任务中获得了很好的效果。受 Transformer 强大表示能力的启发,研究人员提出对其进行扩展转换到计算机视觉任务,成为深度学习模型中 CNN 以外的另一个经典结构:视觉 Transformer,即 ViT (vision transformer)^[27],其基本结构如图 6 所示。ViT 将输入的图片分为多个小块,将每个小块投影为固定长度的向量输入到 Transformer 结构的编码器中,再经过多层感知机输出判定类别。




图6 ViT模型结构

Fig. 6 Structure of ViT

但是 ViT 和多层感知机 MLP (multilayer perceptron) 的研究需要大量数据,是数据渴望型 (data hungry) 的算法。相较 CNN 而言,由于缺少了归纳偏置使得 ViT 在小数据样本上非常依赖正则化和数据增广,当数据集不够大时,ViT 的表现会较同等大小的 ResNet 差一些;但是当提供的数据集足够大时,ViT 就会突破缺少归纳偏置的限制,达到超过 CNN 的效果。正如该方法名称所表现的,本模型用于视觉任务,但是其本身是一种自然语言处理任务向视觉任务迁移的产物,表现出了深度学习技术在不同领域的应用活力。

上述 6 种方法基本囊括了目前最广泛应用深度学习技术的基础形式,可以看出随着深度学习技术的发展,该技术的应用向着更深更广的方向发展。学者们通过在基础神经网络基础结构上增加专门的功能模块如卷积模块、注意力模块等,或根据任务形式对基础形式进行改造,如生成对抗网络、递归神经网络等,将不同模块与不同结构进行组合最终形成了一套复杂的技术体系,可以应对输入的光谱数据、振动信号等一维信息以及彩色图片、强度分布等二维数据,实现端对端的信息提取,从而在不同环境下完成各种任务。

在工业应用场景中,木材作为一种自然材料,

其加工领域的研究是一个广而深的问题:一方面,木材属于自然生长的材料,为了追求其自然的美学价值,需要完成缺陷、纹理、色泽等多个方面的外观检测以保证后续流程中材料的一致性;另一方面,由于木材材料性能的复杂性,其处理过程中的材料性能难以建立有效的解析模型。

这两方面问题导致了在木材加工领域中的原木检尺、木材检测、木材干燥领域中传统方法越难以适应木材加工领域的智能化、自动化需求,因此如何将深度学习技术用于木材加工领域逐渐成为研究的热点。机器视觉与深度学习结合的无损检测技术作为一种低成本、时效性好的方法,将卷积神经网络、自编码器、视觉 Transformer 等技术融合,可以高效地实现检测目标的定位、分类或性能预测等,在木材检测、原木检尺等领域中使用基于深度学习的机器视觉技术以机器代替人工,大大提高工作效率。

将深度学习技术应用于时间序列数据建模也是目前研究的热点。木材干燥过程中木材的时效性能建模采用递归神经网络、深度信念网络等,可以实现更为准确高效的建模效果,从而辅助木材干燥过程的研究,对木材内部的参数进行预测,提高木材干燥的工艺性能。

2 基于深度学习的木材加工研究现状

2.1 原木检尺

锯切作为木材加工的第一步,其下锯的结果将直接影响原木出材率和利用率的高低,其下锯的效率和准确性直接关系到木材行业的经济效益。而在此过程中,原木的外围几何形状既是制约下锯的关键因素,也是实现木材分类和优化排样等的依据。所以对原木形状的精确识别是木材加工业的首要难题。要根据原木图像实现自动化的材积检测,第一步首先要做的就是明确待测原木在图像中所处的位置及所占大小,为了区分原木图像上的背景和目标原木,必须引入目标检测算法。

林耀海等^[28]在利用 YOLOv3-tiny 卷积神经网络对成捆堆放的原木端面图像进行目标检测后计算其端面轮廓的直径,在小样本测试中真检率为 98.79%,具有较好的检测效果和鲁棒性,但该方法更适合检测大径级圆形原木。而为了解决密集小木材的检测难题,杨攀等^[29]基于 Mask R-CNN 从多个维度对木材分割准确性进行定量分析,真检率为 97.989%;丁博文^[30]分别利用 SSD-300 和 YOLO 对成堆板材及原木的横截面进行检测,SSD-300 的平均准确度均高于 YOLO。

深度学习在原木检尺领域中的应用在一定程度上解决了原木端面定位问题,但目前的研究对图像有效区域的进一步处理仍需使用传统的图像处理方法,使得处理过程较为烦琐。为了解决这一问题,可以考虑利用深度学习算法直接对原始图像进行分割,自动剔除图像背景和木材间隙。

2.2 木材检测

2.2.1 木材树种分类

不同树种的木材由于内部结构和组成成分的差异而表现出完全不同的理化特性,如冷杉木纹紧密,难以上色,无法获得较高的美学价值,所以多用于建筑行业,或用于表面装饰要求不高的场合;而黑胡桃木含水率低,耐腐蚀不易变形,价格高昂,往往用于高档家具的制作,这些特性是影响其品质和等级的重要因素,并决定了其用途和经济价值;因此对木材树种的分类识别进行研究具有重要的应用价值。基于深度学习的木材树种分类可以根据获得木材图像的手段分为宏观和细观,基于宏观图像的深度学习方法建立在不同树种木材的颜色、纹理、色泽等宏观特征之上,而基于微观图像的深度学习则以不同树种木材的细胞、纤维结构等细观特征为基础进行分类。

Ding 等^[31]搭建图像采集系统,通过采集山毛榉木、白蜡木、白桦木、樱桃木、杉木板材 5 种树种共 4 179 张实木板材图像,引入注意力机制和空间金字塔池化策略得到 AM-SPPResNet 结构,使用 SVM 对提取到的特征进行树种分类,在测试集上得到 99% 的分类准确率。Zhu 等^[32]在 Faster-RCNN 模型基础上引入感受野增强空间金字塔池化模块和特征金字塔多尺度特征融合模块,构建了基于迁移学习融合模型的木材显微图像识别模型,根据花旗松、西黄松等 10 种木材的微观结构进行分类,分类准确率为 83.8%。Wu 等^[33]使用 Resnet50、Densenet121 以及 MobileNet-V2 对白蜡木、樱桃木、胡桃木等常见的 11 种共计 31 358 张阔叶树种实木板材的宏观图像进行分类,最终均达到了 95% 以上的准确率。

深度学习在原木树种分类领域中的应用多为卷积神经网络,已经能一定程度地解决原木木材树种分类问题,但是对相近树种的分类准确率较低,目前在数据集涵盖的树种类别较少,稀有树种的原木图像数据集更少。为了解决这一问题,可以考虑增加板材树种数据集建设,对不同树种的实木板材数据进行细化扩充,建立完备的实木板材图像数据库。

2.2.2 木材缺陷识别

木材缺陷是呈现在木材上降低其质量并影响其使用的各种缺点。国家标准将木材缺陷分为十大类:节子、变色、腐朽、虫眼、裂纹、树干形状缺陷、木材构造缺陷、伤疤和木材加工缺陷与变形。在木材加工过程中,企业通常按照不同用途的要求限制木材允许存在缺陷的类型、位置、大小和数量,从而将木材划分等级使用,等级对木材的质量和木制品的价格有很大的影响;因此,实现木材缺陷的自动识别、分类分级是提高木材利用率和木制品价值的重要前提。传统木材缺陷的检测方法包括通过 X 射线、超声波、微波和核磁共振等手段采集木材缺陷信息,通过人工设计的特征提取算法如针对一维时序信号的小波变换、针对二维图像的局部二值模式(local binary pattern, LBP)等特征提取方法进行缺陷表征,然后根据缺陷特征进一步检测,但是这些特征提取方法鲁棒性较差,很容易受到客观因素的干扰,不能一直保持较高的检测率。而将深度学习技术与传统检测技术相结合,对采集到的信息进行处理,通过大量的数据进行缺陷信息数据建模,可以提高木材缺陷检测的鲁棒性,实现木材缺陷快速而准确的检测。

基于图像的木材缺陷识别任务经历了缺陷分类到缺陷检测的发展历程,即考虑的问题从图片中包含何种缺陷转变为图片中存在的缺陷在何处、为何种类的问题。在缺陷图像分类方面与树种识别的应用方法类似,VGG 网络模型^[34]、LeNet 网络模型^[35]、ResNet 网络模型^[36]、Densenet 网络模型^[37]等卷积神经网络模型及其改进逐步被应用在木材缺陷检测领域。而随着深度学习算法的发展,基于深度学习的目标检测算法同时提供木材缺陷的种类及位置,为后续加工提供更多的便利,成为更适合木材缺陷检测任务的深度学习算法,Faster R-CNN^[38]、YOLO3、YOLOv4^[39]、YOLOv5^[40]、SSD^[41]等算法的改进被应用于木材缺陷检测。

目前木材缺陷识别与分类领域的应用研究大多采用卷积神经网络模型,可以直接将图像作为输入,避免了大量复杂的前期图像特征提取工作,无需人工设计视觉特征的提取过程,直接获得需要的缺陷坐标及种类,但是需要关注的是目前的检测算法多应用于木材局部图片,对于大幅、长幅图片的处理效果尚不尽如人意。

2.2.3 木材纹理识别

木材纹理是一种不依赖于木材表面颜色或亮度而反映木材表面图像中同质现象的视觉特征,也是木材表面共有的内在特性,可分为直纹理、斜纹理、螺旋纹理、波形纹理和交错纹理等类型。木材纹理直接关系到木材的等级和使用价值,并且木材表面花纹的美观程度也是影响木制品的感官效果和经济效益的重要因素。因此针对木材纹理进行合理的识别与分类具有积极的现实意义。近年来,随着人工智能产业的兴起,深度学习也被运用到了纹理识别与分类中。

Hu 等^[42]利用迁移学习训练 ResNet-18 模型,对木材纹理进行分类,分类准确率达到 96.64%,平均单幅图像分类所需时间为 0.003 s。Loke^[43]通过 LBP 和灰色共生矩阵提取木材纹理中像素到像素的关系属性,并将其作为 CNN 模型的输入层,实验结果表明,分类准确率达到 93.94%。胡忠康等^[44]利用 LBP 提取木材缺陷(节子、裂缝、孔洞)和纹理(直纹、花纹)特征和生成直方图,将其导入 DBN 模型中,识别误差率为 3.59%。另外,木材颜色作为木材表面特征参数的重要组成部分,一些家具和地板制造企业对其一致性有严格要求。为了得到颜色与纹理高度一致的橡胶木板,Liu 等^[45]根据颜色及纹理的不同将橡胶板分为 6 类,并利用基于 SSR 的 CNN 进行实时分类,分类准确率为 94.86%,

单幅图像处理时间为 26.55 ms,ViT^[46]也被应用于实木地板的颜色分选中。

木材纹理需要综合考虑相对颜色、几何形状等特征,传统机器视觉技术需要提取特定的特征如灰度共生矩阵、颜色矩等,然后构造相应的分类算法,从而实现纹理识别颜色分类,但是该方法极其依赖外部环境,鲁棒性差。而深度学习技术提供了一种更为简单高效的检测手段,通过考虑图像全局特征,可以自动实现木材纹理识别,但是需要大量的数据,所以目前大多还是先构造纹理、颜色特征作为深度学习模型的一个先验,然后再使用深度学习分类器进行分类,如果后续研究中有大量数据,则可以直接使用深度学习方法对木材纹理、颜色实现分类。

2.2.4 木材数据集扩充

在木材缺陷分类与识别过程中,往往存在木材训练集样本较少的问题。深度学习模型的训练依赖大量的数据,但木材图像的采集装置比较昂贵,并且人工标注数据十分耗费精力和成本,很容易导致样本分布不均和多样性差,从而影响后续的检测精度。而对抗生成网络凭借对抗生成机制具有无限生成新样本的能力,很好地解决了训练数据不足的问题。

Tang 等^[47]开发了一种双自动编码器生成对抗网络(dual auto-encoder GAN,DAGAN)来解决木材缺陷样本失衡问题,该模型采用跳跃连接和双编码器结构,具有良好的图像重建能力和训练稳定性。针对源图像和目标图像不匹配的问题,通常采用循环对抗生成网络(cycleGAN)模型进行图像生成。如 Li 等^[48]利用 cycleGAN 交换 3 种木材(杨树、桦树和松树)的纹理和颜色特征,合成了新的木材缺陷(裂纹、虫蛀)图像,在不影响数据集的情况下解决了木材缺陷类别分布失衡的问题。但是 DAGAN 和 cycleGAN 均存在合成图像的分辨率较低的问题,而基于渐进生长生成对抗网络(progressing growing GAN,PGGAN)在合成高分辨率图像方面具有明显优势,Hu 等^[49]利用 PGGAN 合成了分辨率为 512×512 的木材缺陷(活节、死节和虫眼)图像来扩展数据集,与传统的样本拓展方法(旋转、镜像和仿射变换等)相比,PGGAN 能扩展缺陷的细节,从而提高了缺陷图像的多样性和平衡样本分布。

木材的检测研究过程往往受到数据集的限制,木材的缺陷具有随机性,而且不同种类缺陷出现的频率也不同,对抗生成神经网络作为一种生成数据

的手段,使用对抗生成网络生成数据,可以缓解木材缺陷分布不均的问题;进一步的也可以通过对抗生成网络对树种鉴定任务的数据集进行扩充,降低树种鉴定任务数据集制作带来的经济需求。

2.3 木材干燥

木材干燥是指在一定条件下排除木材中水分的处理过程,是木材加工中的关键工序。对木材进行正确合理的干燥处理,可以提高其力学强度,改善其物理性能,防止出现翘曲开裂和腐朽霉变等问题。木材干燥属于超微细结构的非稳态传热传质过程,木材结构复杂又具有多样性和变异性,因此建立理想的符合实际干燥过程的数学模型十分困难,传统辨识方法所建的模型往往由于太复杂而难以实现或因过多的条件简化而造成偏差。而深度学习作为更贴近人类大脑的神经网络学习算法,具有良好的并行处理和自适应能力,已在木材干燥中得到应用。

张冬妍等^[50]提出了一种基于深度递归神经网络(deep recursive neural network, DRNN)的木材干燥模型辨识方法,与机理建模和传统的系统辨识方法相比,能更好地反映系统的动态行为。另外,木材的含水率对木材干燥的质量有着较大的影响。在干燥窑中对木材进行干燥时,干燥窑内的温度和湿度是影响木材含水率检测的主要因素。因此大多研究者针对上述影响因素进行研究。夏春江等^[51]提出了一种基于 DBN 的木材含水率检测系统辨识模型,可以根据实际测量得到的温湿度和木材电阻率来实现对应木材含水率的预测输出。Li 等^[52]构建了木材含水率在线检测融合系统,分别利用 BP 神经网络和动态循环神经网络建立了两种预测木材含水率的单一模型,并利用算术平均和递归估计算法对其进行融合,提高了系统的可靠性和实时性。另外,夏春江等^[53]利用 DBN 对传统的 PID 控制算法进行改进,能够近似非线性对象,实验结果表明, DBN-PID 算法对木材干燥窑内参数(温度、相对湿度、木材电阻率和含水率)的检测精度比 BP-PID 算法的更高。

目前深度学习方法在木材干燥过程中的应用较少,常用的方法主要为机器学习方法,如 BP 神经网络、模糊算法和蚁群算法等,但这些方法的求解精度不高。随着木材含水率检测设备精度要求的提高和更多智能融合方法的出现,应考虑将深度学习方法与常用方法相融合并应用于木材干燥过程中,以提高木材干燥过程模型的准确度并获得更好的温湿度控制效果。

3 展 望

作为人工智能技术的重要组成部分,基于深度学习的新理论、新方法、新技术迅速发展,解决了 BP 网络、SVM 等浅层学习无法克服样本量大、易于陷入局部最优的问题。目前深度学习虽然在木材加工领域有了一些研究成果,但是在其产业化方面还存在一定的差距,需要从以下 3 个方面去推进深度学习技术的应用:

1) 以现有技术为基础,探索不同智能算法与深度学习技术的相互渗透。以现有木材加工企业为基础,获取足量木材加工工艺数据,建立完备的木材加工产业数据库。利用不同算法优化深度学习模型网络结构,扬长避短,研究出精度高、求解速度快、自适应性强且更具鲁棒性的混合求解方法。

2) 硬件软件相结合,提升深度学习技术的速度与精度。深度学习是基于大数据的技术,硬件平台的计算能力决定了该技术的速度与精度,因此将深度学习技术应用于木材加工领域需要更为先进的运算平台,对硬件的稳定性与可靠性提出了更高的需求。

3) 研发木材智能加工装备,促进深度学习在木材加工中的应用拓展。将深度学习在木材加工领域的理论研究成果应用于实际生产中,研发木材智能加工装备,建立完善木材加工智能生产体系,提高智能化水平。目前我国在木材加工领域的研究及推广应用还相对滞后,应该积极研究拓宽深度学习技术在木材加工领域的应用范围,并将其他行业及领域不断出现的新技术借鉴和引入木材加工产业,引领木材加工产业向智能制造生产模式转型升级。

参考文献(References):

- [1] 吴义强. 木材科学与技术研究新进展[J]. 中南林业科技大学学报, 2021, 41(1): 1-28. DOI: 10.14067/j.cnki.1673-923x.2021.01.001.
WU Y Q. Newly advances in wood science and technology[J]. Journal of Central South University of Forestry & Technology, 2021, 41(1): 1-28.
- [2] 张英豪, 奉国强. 中国木材供需现状与趋势[J]. 林业经济, 2015, 37(2): 68-72. DOI: 10.13843/j.cnki.lyjj.2015.02.011.
ZHANG Y H, FENG G Q. China's timber supply and demand: status and trend[J]. Forestry Economics, 2015, 37(2): 68-72.
- [3] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536. DOI: 10.1038/323533a0.
- [4] BOURLARD H, KAMP Y. Auto-association by multilayer perceptrons and singular value decomposition[J]. Biological Cybernetics, 1988, 59(4): 291-294. DOI: 10.1007/BF00332918.
- [5] 鞠东豪, 李宇, 王宇杰, 等. 基于堆栈稀疏去噪自编码器神经

- 网络的舰船辐射噪声目标识别算法研究[J]. 振动与冲击, 2021, 40(24): 50–56, 74. DOI: 10.13465/j.cnki.jvs.2021.24.007.
- JU D H, LI Y, WANG Y J, et al. A stack sparse denoising auto-encoder-based neural network approach for ship radiated noise target recognition[J]. Journal of Vibration and Shock, 2021, 40(24): 50–56, 74.
- [6] LIAO L Y, DU L, CHEN J. Class factorized complex variational auto-encoder for HRR radar target recognition[J]. Signal Processing, 2021, 182: 107932. DOI: 10.1016/j.sigpro.2020.107932.
- [7] 赵鹏, 汪纯燕, 张思颖, 等. 一种基于融合重构的子空间学习的零样本图像分类方法[J]. 计算机学报, 2021, 44(2): 409–421. DOI: 10.11897/SP.J.1016.2021.00409.
- ZHAO P, WANG C Y, ZHANG S Y, et al. A zero-shot image classification method based on subspace learning with the fusion of reconstruction[J]. Chinese Journal of Computers, 2021, 44(2): 409–421.
- [8] 王雪松, 张翰林, 程玉虎. 基于自编码器和超图的半监督宽度学习系统[J]. 电子学报, 2022, 50(3): 533–539. DOI: 10.12263/DZXB.20210105.
- WANG X S, ZHANG H L, CHENG Y H. Autoencoder and hypergraph-based semi-supervised broad learning system[J]. Acta Electronica Sinica, 2022, 50(3): 533–539.
- [9] 王勇超, 周灵智, 赵亚萍, 等. 自动扩充关键词语义信息的诗歌生成算法[J/OL]. 计算机科学与探索, 2022[2022-08-03]. <https://kns.cnki.net/kcms/detail/11.5602.TP.20220117.1625.002.html>.
- WANG Y C, ZHOU L Z, ZHAO Y P, et al. Poetry generation algorithm with automatic expansion of keyword semantic information[J/OL]. Journal of Frontiers of Computer Science and Technology, 2022[2022-08-03]. <https://kns.cnki.net/kcms/detail/11.5602.TP.20220117.1625.002.html>.
- [10] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527–1554. DOI: 10.1162/neco.2006.18.7.1527.
- [11] 王功明. 深度信念网络结构优化设计方法与应用[D]. 北京: 北京工业大学, 2019.
- WANG G M. Optimization design for deep belief network and its applications [D]. Beijing: Beijing University of Technology, 2019.
- [12] 吕海峰, 蒲宝明. 一种改进的深度信念网络算法[J]. 小型微型计算机系统, 2022, 43(6): 1240–1244. DOI: 10.20009/j.cnki.21-1106/TP.2022-0186.
- LYU H F, PU B M. Improved deep belief network algorithm[J]. Journal of Chinese Computer Systems, 2022, 43(6): 1240–1244.
- [13] 李锦键, 王兴贵, 杨维满, 等. 基于改进递归深度信念网络的 CSP 电站短期出力预测[J]. 太阳能学报, 2022, 43(7): 225–232. DOI: 10.19912/j.0254-0096.tynxb.2020-1079.
- LI J J, WANG X G, YANG W M, et al. CSP station output power short-term forecast based on improved RNN-DBN[J]. Acta Energaie Solaris Sinica, 2022, 43(7): 225–232.
- [14] WANG H M, LIU P Z. Image recognition based on improved convolutional deep belief network model[J]. Multimedia Tools and Applications, 2021, 80(2): 2031–2045. DOI: 10.1007/s11042-019-08300-x.
- [15] 刘琼, 李宗贤, 孙富春, 等. 基于深度信念卷积神经网络的图像识别与分类[J]. 清华大学学报(自然科学版), 2018, 58(9): 781–787. DOI: 10.16511/j.cnki.qhdxxb.2018.22.034.
- LIU Q, LI Z X, SUN F C, et al. Image recognition and classification by deep belief-convolutional neural networks[J]. Journal of Tsinghua University (Science and Technology), 2018, 58(9): 781–787.
- [16] 严春满, 王铖. 卷积神经网络模型发展及应用[J]. 计算机科学与探索, 2021, 15(1): 27–46. DOI: 10.3778/j.issn.1673-9418.2008016.
- YAN C M, WANG C. Development and application of convolutional neural network model[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(1): 27–46.
- [17] ZHANG S W, ZHANG S B, ZHANG C L, et al. Cucumber leaf disease identification with global pooling dilated convolutional neural network[J]. Computers and Electronics in Agriculture, 2019, 162: 422–430. DOI: 10.1016/j.compag.2019.03.012.
- [18] 孙龙清, 王新龙, 王泊宁, 等. 基于 ResNet-CA 的鱼群饱腹程度识别方法[J]. 农业机械学报, 2022, 53(S2): 219–225, 277.
- SUN L Q, WANG X L, WANG B N, et al. Identification method of fish satiation level based on ResNet-CA[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(S2): 219–225, 277.
- [19] 李淑艳, 李若晨, 温昌凯, 等. 基于 GAF-DenseNet 的拖拉机旋耕作业质量预测[J/OL]. 农业机械学报, 2022[2022-10-02]. <https://kns.cnki.net/kcms/detail/11.1964.s.20220812.1020.004.html>.
- LI S Y, LI R C, WEN C K, et al. Quality prediction of tractor rotary tillage based on GAF-DenseNet[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2022[2022-10-02]. <https://kns.cnki.net/kcms/detail/11.1964.s.20220812.1020.004.html>.
- [20] LEI C L, XUE L L, JIAO M X, et al. Rolling bearing fault diagnosis by Markov transition field and multi-dimension convolutional neural network[J]. Measurement Science and Technology, 2022, 33(11): 114009. DOI: 10.1088/1361-6501/ac87c4.
- [21] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139–144. DOI: 10.1145/3422622.
- [22] 梁俊杰, 韦舰晶, 蒋正锋. 生成对抗网络 GAN 综述[J]. 计算机科学与探索, 2020, 14(1): 1–17. DOI: 10.3778/j.issn.1673-9418.1910026.
- LIANG J J, WEI J J, JIANG Z F. Generative adversarial networks GAN overview[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(1): 1–17.
- [23] DENTON E, CHINTALA S, SZLAM A, et al. Deep generative image models using a Laplacian pyramid of adversarial networks[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 1. December 7–12, 2015, Montreal, Canada. New York: ACM, 2015: 1486–1494. DOI: 10.5555/2969239.2969405.
- [24] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE International Conference on Computer Vision (ICCV). October 22–29, 2017, Venice, Italy. IEEE, 2017: 2242–2251. DOI: 10.1109/ICCV.2017.244.
- [25] 李培育, 张雅丽. 基于改进 SRGAN 模型的人脸图像超分辨率重建研究[J/OL]. 计算机工程, 2022[2022-09-25]. <https://doi.org/10.19678/j.issn.1000-3428.0064174>.
- LI P Y, ZHANG Y L. Research on face image super-resolution reconstruction based on improved SRGAN Model[J/OL]. Computer Engineering, 2022[2022-09-25]. <https://doi.org/10.19678/j.issn.1000-3428.0064174>.
- [26] BIANCHINI M, GORI M, SARTI L, et al. Recursive processing of cyclic graphs[J]. IEEE Transactions on Neural Networks, 2006, 17(1): 10–18. DOI: 10.1109/TNN.2005.860873.
- [27] HAN K, WANG Y H, CHEN H T, et al. A survey on vision transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(1): 87–110. DOI: 10.1109/TPAMI.2022.3152247.

- [28] 林耀海, 赵洪璐, 杨泽灿, 等. 结合深度学习与 Hough 变换的等长原木材积检测系统[J]. 林业工程学报, 2021, 6(1): 136-142. DOI: 10.13360/j.issn.2096-1359.202003022.
- LIN Y H, ZHAO H L, YANG Z C, et al. An equal length log volume inspection system using deep-learning and Hough transformation[J]. Journal of Forestry Engineering, 2021, 6(1): 136-142.
- [29] 杨攀, 郑积仕, 冯芝清, 等. 基于 Mask R-CNN 的密集木材检测分割方法[J]. 林业工程学报, 2022, 7(2): 135-142. DOI: 10.13360/j.issn.2096-1359.202106001.
- YANG P, ZHENG J S, FENG Z Q, et al. Research on detection and segmentation methods of dense-stacked logs using Mask R-CNN[J]. Journal of Forestry Engineering, 2022, 7(2): 135-142.
- [30] 丁博文. 基于计算机视觉的木材检尺系统[D]. 北京: 北京交通大学, 2018.
- DING B W. A wood measuring system based on computer vision[D]. Beijing: Beijing Jiaotong University, 2018.
- [31] DING F L, LIU Y, ZHUANG Z L, et al. A sawn timber tree species recognition method based on AM-SPPResNet[J]. Sensors (Basel, Switzerland), 2021, 21(11): 3699. DOI: 10.3390/s21113699.
- [32] ZHU M, WANG J C, WANG A C, et al. Multi-fusion approach for wood microscopic images identification based on deep transfer learning[J]. Applied Sciences, 2021, 11(16): 7639. DOI: 10.3390/app11167639.
- [33] WU F Y, GAZO R, HAVIAROVA E, et al. Wood identification based on longitudinal section images by using deep learning[J]. Wood Science and Technology, 2021, 55(2): 553-563. DOI: 10.1007/s00226-021-01261-1.
- [34] 贺婷. 面向实木板材优选加工的缺陷智能检测方法及应用研究[D]. 南京: 南京林业大学, 2020.
- HE T. Intelligent defect detection method and its application for optimal processing of solid wood plates[D]. Nanjing: Nanjing Forestry University, 2020.
- [35] 陈龙现, 葛浙东, 罗瑞, 等. 基于 CNN 的木材内部 CT 图像缺陷辨识[J]. 林业科学, 2018, 54(11): 127-133. DOI: 10.11707/j.1001-7488.20181118.
- CHEN L X, GE Z D, LUO R, et al. Identification of CT image defects in wood based on convolution neural network[J]. Scientia Silvae Sinicae, 2018, 54(11): 127-133.
- [36] GAO M Y, QI D W, MU H B, et al. A transfer residual neural network based on ResNet-34 for detection of wood knot defects[J]. Forests, 2021, 12(2): 212. DOI: 10.3390/f12020212.
- [37] JUNG S Y, TSAI Y H, CHIU W Y, et al. Defect detection on randomly textured surfaces by convolutional neural networks[C]//2018 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM). July 9-12, 2018, Auckland, New Zealand. IEEE, 2018: 1456-1461. DOI: 10.1109/AIM.2018.8452361.
- [38] URBONAS A, RAUDONIS V, MASKELIŪNAS R, et al. Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning[J]. Applied Sciences, 2019, 9(22): 4898. DOI: 10.3390/app9224898.
- [39] 王勇, 张伟, 高锐, 等. 基于 YOLOv4 的结构用锯材表面缺陷识别[J]. 林业工程学报, 2021, 6(4): 120-126. DOI: 10.13360/j.issn.2096-1359.202010009.
- WANG Y, ZHANG W, GAO R, et al. Research on surface defect recognition of structural sawn timber using YOLOv4[J]. Journal of Forestry Engineering, 2021, 6(4): 120-126.
- [40] FANG Y M, GUO X X, CHEN K, et al. Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 model[J]. BioResources, 2021, 16(3): 5390-5406. DOI: 10.15376/biores.16.3.5390-5406.
- [41] DING F L, ZHUANG Z L, LIU Y, et al. Detecting defects on solid wood panels based on an improved SSD algorithm[J]. Sensors (Basel, Switzerland), 2020, 20(18): 5315. DOI: 10.3390/s20185315.
- [42] HU J F, SONG W L, ZHANG W, et al. Deep learning for use in lumber classification tasks[J]. Wood Science and Technology, 2019, 53(2): 505-517. DOI: 10.1007/s00226-019-01086-z.
- [43] LOKE K S. Texture recognition using a novel input layer for deep convolutional neural network[C]//2018 IEEE 3rd International Conference on Communication and Information Systems (ICCIS). December 28-30, 2018, Singapore. IEEE, 2019: 14-17. DOI: 10.1109/ICOMIS.2018.8645055.
- [44] 胡忠康, 刘英, 周晓林, 等. 基于深度置信网络的实木板材缺陷及纹理识别研究[J]. 计算机应用研究, 2019, 36(12): 3889-3892. DOI: 10.19734/j.issn.1001-3695.2018.07.0438.
- HU Z K, LIU Y, ZHOU X L, et al. Research on defects and textures recognition of solid wood lumbers based on deep belief network[J]. Application Research of Computers, 2019, 36(12): 3889-3892.
- [45] LIU S H, JIANG W B, WU L H, et al. Real-time classification of rubber wood boards using an SSR-based CNN[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 8725-8734. DOI: 10.1109/TIM.2020.3001370.
- [46] ZHUANG Z L, LIU Y, YANG Y T, et al. Color regression and sorting system of solid wood floor[J]. Forests, 2022, 13(9): 1454. DOI: 10.3390/f13091454.
- [47] TANG T W, KUO W H, LAN J H, et al. Anomaly detection neural network with dual auto-encoders GAN and its industrial inspection applications[J]. Sensors (Basel, Switzerland), 2020, 20(12): 3336. DOI: 10.3390/s20123336.
- [48] LI D J, XIE W B, WANG B G, et al. Data augmentation and layered deformable mask R-CNN-based detection of wood defects[J]. IEEE Access, 2021, 9: 108162-108174. DOI: 10.1109/ACCESS.2021.3101247.
- [49] HU K, WANG B J, SHEN Y, et al. Defect identification method for poplar veneer based on progressive growing generated adversarial network and MASK R-CNN model[J]. BioResources, 2020, 15(2): 3041-3052. DOI: 10.15376/biores.15.2.3041-3052.
- [50] 张冬妍, 胡昆仑, 赵真非. 基于动态递归神经网络的木材干燥模型辨识[J]. 森林工程, 2003, 19(6): 10-12. DOI: 10.16270/j.cnki.slge.2003.06.005.
- ZHANG D Y, HU K L, ZHAO Z F. Identification of wood drying based on dynamical recurrent neural networks[J]. Forest Engineering, 2003, 19(6): 10-12.
- [51] 夏春江, 王培良, 张媛. 基于深度学习的木材含水率预测[J]. 杭州电子科技大学学报(自然科学版), 2015, 35(1): 31-35. DOI: 10.13954/j.cnki.hdu.2015.01.006.
- XIA C J, WANG P L, ZHANG Y. Prediction of moisture content of wood based on deep learning[J]. Journal of Hangzhou Dianzi University (Natural Sciences), 2015, 35(1): 31-35.
- [52] LI J, SUN L P, LIU D S. An on-line measuring fusion model of lumber moisture content based on data fusion algorithm[C]//2007 International Conference on Wavelet Analysis and Pattern Recognition. November 2-4, 2007, Beijing. IEEE, 2008: 691-694. DOI: 10.1109/ICWAPR.2007.4420757.
- [53] 夏春江, 王培良. 基于 DBN-PID 的木材干燥窑参数检测系统[J]. 计算机测量与控制, 2015, 23(1): 99-101, 105. DOI: 10.16526/j.cnki.11-4762/tp.2015.01.087.
- XIA C J, WANG P L. Detecting system of wood dry kilns' parameters based on DBN-PID[J]. Computer Measurement & Control, 2015, 23(1): 99-101, 105.