

DOI: 10.19650/j.cnki.cjsi.12413267

基于深度迁移学习的超声缺陷识别方法研究*

魏新园^{1,2}, 周京欢¹, 张楠¹, 李丹¹, 顾浩然¹

(1. 安徽工业大学电气与信息工程学院 马鞍山 243032; 2. 安徽省智能破拆装备工程实验室 马鞍山 243032)

摘要: 数据驱动的超声缺陷识别在航空航天和工业制造等领域中应用广泛,但大量实验数据难于获取。软件仿真数据虽易于获取,但与实验数据存在差异,直接应用效果并不理想。对此,提出基于深度迁移学习的超声缺陷识别方法研究。首先同时对试件中的不同形状、尺寸和深度的缺陷进行超声检测实验和超声检测仿真,得到实验数据和仿真数据。进而基于仿真数据建立超声缺陷识别深度学习模型,然后基于少量实验数据利用深度迁移学习方法对所建模型进行迁移学习,从而建立能够对实验数据实现准确缺陷识别的模型,最后对所建模型的预测效果进行实验验证。结果表明,基于仿真数据建立的超声损伤识别模型经过迁移后,缺陷识别准确率和精确率大幅提升,均达到0.956。

关键词: 深度迁移学习; 超声探伤; 缺陷识别

中图分类号: TH164 TN05 TG115.28 文献标识码: A 国家标准学科分类代码: 520.60

Research on ultrasonic defect recognition method based on deep transfer learning

Wei Xinyuan^{1,2}, Zhou Jinghuan¹, Zhang Nan¹, Li Dan¹, Gu Haoran¹

(1. School of Electrical and Information Engineering, Anhui University of Technology, Ma'anshan 243032, China;

2. Anhui Intelligent Demolition Equipment Engineering Laboratory, Ma'anshan 243032, China)

Abstract: Data-driven ultrasonic defect identification is widely used in aerospace and industrial manufacturing. However, obtaining a large amount of experimental data remains challenging. While software-generated simulation data is easier to acquire, it differs significantly from experimental data, leading to suboptimal performance when applied directly. In this paper, the ultrasonic defect recognition method based on deep transfer learning is proposed. Firstly, ultrasonic testing experiments and ultrasonic testing simulations were carried out for defects of different shapes, sizes and depths in the specimen at the same time, generating both experimental and simulation data. Furthermore, a deep learning model for ultrasonic defect recognition was established based on simulation data. Then, a small amount of experimental data was employed to fine-tune the pre-trained model through transfer learning. So as to established a model that can achieve accurate defect recognition on the experimental data. Finally, the prediction effect of the built model was verified through experiments. The results show that after transfer learning, the accuracy and precision of the ultrasonic defect recognition model significantly improved, both achieving a value of 0.956.

Keywords: deep transfer learning; ultrasonic flaw detection; defect identification

0 引言

超声探伤具有广泛应用,如 Zhou 等^[1]通过高周疲劳测试,创建具有不同疲劳损伤程度的试样,并使用超声导波测量技术进行评估。Liu 等^[2]利用超声导波技术检测

铁路轨道上的裂缝,以实现精确的裂纹定位。随着人工智能的发展,深度学习算法在超声探伤的应用越来越广泛。2022 年 Miao 等^[3]提出了一种基于卷积神经网络的焊接缺陷识别方法,大大提高了焊缝缺陷识别效率。2022 年李丹等^[4]提出轻量级卷积神经网络模型,满足工业现场实时检测带钢表面缺陷的要求。2023 年王敏等^[5]提出了

收稿日期: 2024-09-10 Received Date: 2024-09-10

* 基金项目: 安徽省重点研究与开发计划(202204020005)、安徽省高等学校科研研究重点(2022AH050313)、安徽省智能破拆装备工程实验室开放基金(APELIDE2023A008)项目资助

一种基于 SKPE-ShuffleNetv2 的药片缺陷识别算法, 提高了药片在生产过程中缺陷识别精度。2023 年张涛等^[6]提出一种改进算法模型 YOLO-M, 提高了玻璃杯表面缺陷检测速度与精度。2024 年顾桂梅等^[7]引入了一种轻量级神经网络, 提高了对小目标的识别效果。2024 年 Bai 等^[8]针对钢板缺陷尺度大、特征多样、样品不平衡等问题, 提出一种改进的具有编解码结构的缺陷分割网络, 并使用实验验证了其有效性。

这些研究通过引入深度学习, 显著提高了探伤的准确性和效率。然而现阶段研究普遍面临一个问题: 缺陷识别模型对大量实验数据的依赖。而收集大量超声波探伤检测数据难度较大, 且不同场景之间检测数据的通用性较差, 这使得相关研究的发展受到了一定的限制。在此背景下, 仿真技术逐渐成为无损检测技术中的关键辅助工具。

通过仿真能够获取大量的超声探伤数据, 用于构建超声缺陷识别模型。2022 年李灏天等^[9]对成像的过程进行了仿真模拟, 利用改进的支持向量机建立缺陷识别模型。2023 年唐若笠等^[10]基于包含不同管道裂纹等级的有限元仿真数据库, 提出了一种管道裂纹等级识别模型, 取得了较高的识别精度。2024 年何存富等^[11]建立了风机主轴阵列检测仿真模型, 利用仿真数据和全聚焦算法进行了成像检测, 提高了成像质量。此外仿真技术还可以用于检测工艺和探头参数的优化, 提高检测效率^[12-14]。但仿真数据与实验数据之间始终存在一定的差异性, 导致完全基于仿真数据建立的超声缺陷识别模型在实际应用的识别效果难以满足高精度要求。对此, 本文提出一种基于深度迁移学习的超声缺陷识别方法, 以有效解决该难题。

迁移学习的核心思想是将在一个任务上学到的知识迁移到其他任务上, 从而加速新任务的学习过程并提高性能。深度迁移学习使用深度学习模型进行迁移学习, 具备提高训练效率和提升模型性能的优势, 目前深度迁移学习在工业制造领域^[15-17]、农业领域^[18-20]和医疗领域^[21-25]均取得了较好的应用效果。本文首先对不同形状、尺寸和深度的缺陷进行超声检测实验, 获取超声探伤实验数据; 同时对不同形状、尺寸和深度的超声缺陷检测进行仿真分析, 利用数据增强扩充仿真数据, 进而构建基于卷积神经网络的缺陷识别原始模型; 然后利用实验数据对缺陷识别原始模型进行迁移, 获得缺陷识别迁移模型; 最后利用实验数据对缺陷识别迁移模型进行效果验证。

1 基于深度迁移学习的超声缺陷识别方法

1.1 超声缺陷检测基本原理

超声缺陷检测基本原理可以分为脉冲反射法、穿透法和共振法^[26]。本文采用的是脉冲反射法, 即由超声波

探头发射脉冲波到待检测试件内部, 通过观察来自内部缺陷的反射波情况来判断试件内部的缺陷情况, 其原理如图 1 所示。




图 1 脉冲反射法超声缺陷检测基本原理

Fig. 1 Basic principle of ultrasonic defect detection using pulse reflection method

当试件中存在缺陷时, 反射波有始波、缺陷波和一次底波 3 种信号。缺陷波脉冲数量由缺陷的数量确定, 缺陷波的形状和高度受缺陷的大小、形状等因素的影响。

1.2 卷积神经网络

卷积神经网络是一种常用于分类预测的深度学习模型, 常用于超声缺陷识别^[27]。其中卷积层通过卷积运算对超声探伤数据进行卷积操作, 以提取数据中特征。池化层对卷积层输出的特征进行筛选, 本文选用最大池化层进一步筛选特征。

全连接层将池化层输出特征通过权重和偏执映射到缺陷类别, 实现超声探伤缺陷类型的识别。全连接层计算公式为:

$$\mathbf{x}^i = f(\Psi \cdot \mathbf{x}^{i-1} + \mathbf{z}^i) \quad (1)$$

式中: Ψ 表示权重矩阵; $\mathbf{x}^{i-1}$ 和 $\mathbf{x}^i$ 分别表示输入和输出的特征向量; $\mathbf{z}$ 表示偏置向量; f 表示激活函数; i 表示神经网络的层。

输出层将全连接层的输出利用 softmax 函数转换为一个 0~1 之间的值, 表示每个类别的概率值, 概率值越大代表属于该类别的可能性越大, 作为类别预测结果。分类层通常跟在输出层之后, 定义了网络的损失函数和评估指标。

1.3 深度迁移学习

深度迁移学习^[28]利用深度学习方法将从源域(超声探伤仿真数据集)中学到的知识或模式, 有效地迁移到目标域(超声探伤实验数据集)中。设源域为 $D_s = \{(x_i, y_i)\}_{i=1}^{N_s}$, 目标域为 $D_t = \{(x_j, y_j)\}_{j=1}^{N_t}$, 其中 (x_i, y_i) 表示超声探伤数据和缺陷类别的样本数据, N_s 和 N_t 分别表示超声探伤仿真数据集和超声探伤实验数据集中的样本个数。

深度迁移模型的建立过程如图 2 所示。首先基于源域的超声缺陷检测仿真数据集, 采用卷积神经网络算法训练深度学习模型。进而保留训练好的模型中卷积层和

池化层的参数不变,作为特征提取的冻结层;然后利用目标域的超声缺陷检测实验数据集,对全连接层、输出层和

分类层新的神经网络进行迁移训练,从而建立深度迁移模型。




图 2 深度迁移模型的建立过程

Fig. 2 The building process of deep migration model

2 超声波探伤实验与仿真

2.1 超声波探伤实验

本文对不同类型缺陷进行超声探伤检测,不同形状和尺寸的缺陷共 10 种,考虑缺陷的深度则共 32 种缺陷,分别位于 3 个试件中,具体情况如表 1 所示。

表 1 不同缺陷类型具体情况

Table 1 Specific situations of different types of defects

序号	形状	尺寸/mm	深度/mm	编号	所处试件
1	方孔	边长 1	15、20、65、80	F1	方孔缺陷 实验试件
2	方孔	边长 2	35、40、45、60	F2	
3	方孔	边长 4	15、20、65、80	F4	
4	圆孔	直径 1	15、20、65、80	Y1	圆孔缺陷 实验试件
5	圆孔	直径 2	35、40、45、60	Y2	
6	圆孔	直径 4	15、20、65、80	Y4	
7	不规则-1	外接圆直径 2	35、45	B1	不规则缺 陷实验 试件
8	不规则-2	外接圆直径 2	35、45	B2	
9	不规则-3	外接圆直径 2	35、45	B3	
10	不规则-4	外接圆直径 2	35、45	B4	

探伤实验系统如图 3 所示,试件尺寸(单位为 mm)及各类缺陷的位置分布如图 4 所示。




图 3 探伤实验系统

Fig. 3 Flaw detection test system






图 4 缺陷实验试件尺寸及缺陷位置

Fig. 4 Defect test specimen size and defect location diagram


本文对不同类型缺陷(图 4)进行超声检测,具体检测顺序如图 5 所示。考虑缺陷所在试件中深度的影响,得到不同形状、尺寸和深度的共 32 种不同缺陷检测信号。为了提高实验结果的可靠性,本文进行 3 次重复实验,得到共 96 组缺陷检测信号的实验数据,记为 K1 批次。



(a) 方孔缺陷检测顺序
(a) Square hole defects detection sequence



(b) 圆孔缺陷检测顺序
(b) Round hole defect detection sequence



(c) 不规则缺陷检测顺序
(c) Irregular defect detection sequence

图 5 超声缺陷检测实验顺序

Fig. 5 Experimental sequence of ultrasonic defect detection

2.2 超声波探伤仿真

将缺陷试件(图 4)的 CAD 模型导入 COMSOL 软件中进行仿真分析,以得到超声缺陷检测的仿真信号。为了保证与实验的一致性,仿真时设置的参数与实验设备参数一致,包括频率、声速和声程等,如表 2 所示。

表 2 仿真参数设置		
Table 2 Simulation parameter settings		
参数名称	字母	数值
频率/MHz	f_0	2.5
周期/s	T_0	4×10^{-7}
声速/(m · s ⁻¹)	V_0	6 000
波长/mm	H_0	2.4
仿真结束时间/s	T_1	8.35×10^{-5}

仿真时产生超声波的激励函数为常见的以 Hanning 窗调制的正弦函数,其表达式为:

$$\begin{cases} y(t) = 0.5(1 - \cos(2\pi f_0 t)) \sin(2\pi f_0 t), & 0 < t \leq T_0 \\ y(t) = 0, & T_0 < t \leq T_1 \end{cases} \quad (2)$$

同理按照图 5 检测顺序进行超声缺陷检测的仿真分析,得到包含 32 组不同缺陷检测仿真信号的仿真数据,记为 K2 批次。超声发射位置位于图 5 中箭头 2 的仿真过程如图 6 所示。仿真与实验数据如表 3 所示。




图 6 箭头 2 处的超声检测仿真过程

Fig. 6 Simulation process of ultrasonic detection at arrow 2

表 3 仿真与实验数据批次			
Table 3 Simulation and experimental data batches			
探伤方法	编号	数据组数	说明
实验	K1	96	对图 4 中 32 类缺陷各进行 3 次重复实验
仿真	K2	32	对图 4 中 32 类缺陷各进行 1 次仿真实验

2.3 数据分析

为了直观表现超声检测实验与仿真数据的异同,图5中箭头2的缺陷检测实验数据和仿真数据结果如图7所示。其中A1和A2分别表示实验信号和仿真信号的始波波峰横坐标,B1和B2分别表示实验信号和仿真信号的缺陷波波峰横坐标,C1和C2分别表示实验信号和仿真信号的一次底波波峰横坐标。




图7 仿真信号与实验信号对比

Fig.7 Comparison diagram between simulated signal and experimental signal

从图7可以看出,仿真数据与实验数据中的各波波峰出现位置相同,验证了仿真实验的可靠性,同时这种相似性也是能够实现迁移学习的基础。

但仿真数据与实验数据的始波、缺陷波幅值存在明显差异,这也是本文进行迁移学习所解决的问题。分析可知,造成这种差异的原因在于被测试件存在成分分布不均匀、表面粗糙度不一致的问题,同时超声检测过程会受到实验环境的影响,而仿真分析则不存在这些问题,最终造成仿真数据与实验数据存在明显差异。这种差异性导致基于仿真数据构建的缺陷识别模型难以对实验检测数据实现准确预测。

3 深度迁移学习模型建立与预测效果分析

3.1 数据预处理

为确保卷积神经网络训练的高效性与泛化能力,本文对仿真得到的数据集K2进行数据增强,以保证模型训练充足的数据量。做法是改变仿真信号的整体幅值,将仿真信号向上依次平移5次,每次增加2 dB,可得到32×5=160组数据;将仿真信号向下平移4次,每次减少2 dB,可得到32×4=128组数据。从而将仿真数据集K2样本数量变为原来的10倍,即320组数据,记为K3,扩增后的仿真数据集如表4所示。

表4 扩增后的仿真数据集

Table 4 Amplified simulation data set

数据名称	编号	数据增强方法	包含数据组数	总计
扩增后仿真数据集	K3	幅值不变	32	320
		幅值增加	160	
		幅值减小	128	

3.2 缺陷识别原始模型的建立

将数据集K3输入卷积神经网络建立缺陷识别原始模型,通过梯度下降算法调整卷积神经网络各层的参数以极小化损失函数,建立由仿真数据构建的超声缺陷识别模型。本文采用常用的交叉熵损失函数计算训练模型时的损失,具体如式(3)所示。

$$L = - \frac{1}{M} \sum_{m=1}^M [y_b \ln \hat{y}_b + (1 - y_b) \ln (1 - \hat{y}_b)] \tag{3}$$

式中:M为网格分类数; y_b 为预期输出; $\hat{y}_b$ 为神经网络输出。所建立的卷积神经网络模型的卷积层、池化层数均为2。训练过程采用Adam优化算法,最大训练轮数、初始学习率分别为10和0.001,学习率规则为下降且下降因子为0.5,学习率下降的周期为5。

3.3 缺陷识别原始模型预测效果分析

使用K1数据集对缺陷识别原始模型进行验证。通过式(4)~(7)计算模型的识别准确率(accuracy)、精确率(precision)、召回率(recall)和F1分数(F1 score)来定量评价模型的缺陷识别效果。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{4}$$

$$Precision = \frac{TP}{TP + FP} \tag{5}$$

$$Recall = \frac{TP}{TP + FN} \tag{6}$$

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{7}$$

式中:TP是真阳性样本;TN是真阴性样本;FP是假阳性样本;FN是假阴性样本。

通过计算可得缺陷识别原始模型的预测结果。为了提高计算结果的可靠性,进行15次运行取平均值作为最终结果。由此得到缺陷识别原始模型的预测准确率、精确率、召回率和F1分数分别为0.042、0.042、0.003和0.006。该结果表明基于仿真数据集K3建立的缺陷识别原始模型对实验数据集K1的预测效果较差,分析可知主要原因在于实际实验数据与仿真数据之间存在较大差异。

3.4 缺陷识别迁移模型的建立

为了解决 3.3 小节预测结果差的问题, 基于 1.3 节深度迁移学习的理论方法, 对 3.2 节所建立的缺陷识别原始模型进行迁移学习, 流程如图 8 所示。




图 8 基于深度迁移学习的缺陷识别模型建模过程
Fig. 8 Modeling process of defect identification model based on deep transfer learning

将 K1 数据集划分为训练集和测试集, 划分比例为 2:1。利用训练集数据对缺陷识别原始模型进行迁移学习, 即保留缺陷识别原始模型中 2 层卷积层和 2 层池化层的参数不变, 并对全连接层、输出层和分类层新的神经网络进行迁移训练。设置全连接层的权重学习率因子和偏置学习率因子的值均为 20, 采用 Adam 算法进行训练, 最大训练轮数和初始学习率分别为 60 和 0.005, 学习率规则为下降且下降因子为 0.5, 学习率下降的周期为 40。通过训练可建立缺陷识别迁移模型。

3.5 缺陷识别迁移模型预测效果分析

使用 K1 数据集随机划分出的测试集对建立好的缺陷识别迁移模型进行预测效果分析。同理可得缺陷识别迁移模型的预测准确率、精确率、召回率和 F1 分数分别为 0.956、0.956、0.934 和 0.942。迁移前后缺陷识别结果对比如图 9 所示。




图 9 迁移前后缺陷识别效果对比

由图 9 可明显观察出, 缺陷识别迁移模型的预测结果明显优于迁移前的卷积神经网络模型, 由此证明了本研究提基于深度迁移学习的超声缺陷识别方法的优越性。

4 结 论

本研究针对超声缺陷识别中面临的依赖大量实验数据的问题, 提出了一种基于迁移学习的超声缺陷识别方法。该方法利用少量实验数据对基于仿真数据构建的超声损伤识别模型进行迁移学习, 建立缺陷识别迁移模型, 并利用实验数据对模型预测效果进行验证。经过计算, 所建立的缺陷识别迁移模型的平均识别准确率为 0.956, 平均精确率为 0.956, 平均召回率为 0.934, 平均 F1 值为 0.942, 由此说明了本研究所提方法的有效性。本文所提基于深度迁移学习的超声缺陷识别方法能够有效解决超声探伤仿真数据与实验数据存在较大差异的问题, 大大降低了超声损伤智能识别的成本和难度。与目前常用的超声成像技术相比, 本研究所提方法的主要优势在于准确率、检测效率高, 便于工程应用。

本研究利用实验数据对基于仿真数据建立的缺陷识别模型进行迁移学习, 得到缺陷识别迁移模型。但受实验设备和时间的限制, 本研究主要方法集中在单一类型的超声信号上, 而多种模态的超声信号则更加有利于提高缺陷识别准确率。因此, 下一步工作将研究多模态超声数据的融合识别技术, 以及如何在模型中加入对噪声的鲁棒性处理机制, 以提高模型在实际复杂环境下的适应性。

参考文献

[1] ZHOU T, XUE CH L, LYU X J, et al. High-cycle fatigue damage evaluation based on hysteresis nonlinearity using ultrasonic guided waves [J]. Ultrasonics, 2024, 147: 107519.

[2] LIU J J, LUO H, HU H, et al. Enhancing crack detection in railway tracks through AI-optimized ultrasonic guided wave modes [J]. Biomimetic Intelligence and Robotics. 2024, 4: 100175.

[3] MIAO R, SHAN ZH T, ZHOU Q Y, et al. Real-time defect identification of narrow overlap welds and application based on convolutional neural networks [J]. Journal of Manufacturing Systems, 2022, 62: 800-810.

[4] 李丹, 王慢慢, 刘俊德, 等. 基于轻量级卷积神经网络的带钢表面缺陷识别 [J]. 仪器仪表学报, 2022, 43(3): 240-248.


LI D, WANG M M, LIU J D, et al. Steel surface defect recognition based on a lightweight convolutional neural

Fig. 9 Comparison of defect identification effects before and after transfer learning

- network[J]. Chinese Journal of Scientific Instrument, 2022,43(3):240-248.
- [5] 王敏,王康,孙硕,等. 基于 SKPE-ShuffleNetv2 的药片缺陷识别方法[J]. 国外电子测量技术,2023,42(6):188-195.
- WANG M, WANG K, SUN SH, et al. Pill defect identification method based on SKPE-ShuffleNetv2[J]. Foreign Electronic Measurement Technology, 2023, 42(6):188-195.
- [6] 张涛,谢探阳,李玉梅,等. 基于改进 YOLOv4 算法的玻璃杯缺陷识别方法研究[J]. 电子测量技术,2023,46(2):46-51.
- ZHANG T, XIE T Y, LI Y M, et al. Research on glass defect recognition method based on improved YOLOv4[J]. Electronic Measurement Technology, 2023, 46(2):46-51.
- [7] 顾桂梅,王小亮. 深度学习的接触网小目标缺陷识别研究[J]. 电子测量与仪器学报,2024,38(4):151-160.
- GU G M, WANG X L. Identification of the catenary small target defects in deep learning[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4):151-160.
- [8] BAI D X, LI G F, DU J, et al. Depth feature fusion based surface defect region identification method for steel plate manufacturing[J]. Computers and Electrical Engineering, 2024, 116: 109166.
- [9] 李灏天,刘晓宙,何爱军. 基于机器学习和超声成像的缺陷识别与分析[J]. 南京大学学报(自然科学), 2022,58(4):670-679.
- LI H T, LIU X ZH, HE AI J. Defect recognition and analysis based on Machine learning and ultrasonic imaging[J]. Journal of Nanjing University (Natural Science), 2022,58(4):670-679.
- [10] 唐若笠,张尚煜,伍文君. 基于一维卷积神经网络的超声导波管道裂纹识别方法[J]. 振动与冲击,2023,42(5):183-189.
- TANG R L, ZHANG SH Y, WU W J. Crack identification method of ultrasonic guided wave pipeline based on MS-1D CNN[J]. Journal of Vibration and Shock, 2023,42(5):183-189.
- [11] 何存富,黄星都,程俊,等. 风机主轴表面开口裂纹全聚焦成像技术研究[J]. 应用基础与工程科学学报, 2024,32(2):488-501.
- HE C F, HUANG X D, CHENG J, et al. Research on total focusing imaging method for surface breaking cracks of wind turbine main shaft[J]. Journal of Basic Science and Engineering, 2024,32(2):488-501.
- [12] 何慈武,杨萌萌,龙晋恒,等. 小径薄壁管座角焊缝典型缺陷的超声相控阵 CIVA 仿真研究[J]. 中国机械工程,2022,33(9):1065-1072.
- HE C W, YANG M M, LONG J H, et al. Ultrasonic phased array CIVA simulation of typical defects in fillet welds of small-diameter thin-walled tube bases[J]. China Mechanical Engineering, 2022,33(9):1065-1072.
- [13] LIU Y, PENG ZH X, LIU SH, et al. Numerical simulation of laser ultrasonic detection of the surface microdefects on laser powder bed fusion additive manufactured 316L stainless steel[J]. Theoretical and Applied Mechanics Letters. 2022, 12: 100398.
- [14] LEYMARIE N, IMPERIALE A, FORTUNA T, et al. Comparisons of ray and finite element simulations of ultrasonic wave fields in smoothly inhomogeneous austenitic welds of thick-walled components[J]. NDT & E International, 2024, 147: 103177.
- [15] 杨胜康,孔宪光,王奇斌,等. 基于多源域深度迁移学习的机械故障诊断[J]. 振动与冲击,2022,41(9):32-40.
- YANG SH K, KONG X G, WANG Q B, et al. Mechanical fault diagnosis based on multi-source domain deep transfer learning[J]. Journal of Vibration and Shock, 2022,41(9):32-40.
- [16] CHE CH CH, WANG H W, XIONG M L, et al. Few-shot fatigue damage evaluation of aircraft structure using neural augmentation and deep transfer learning[J]. Engineering Failure Analysis, 2023,148:107185.
- [17] 张立豪,李鹏,刘轩宇. 基于深度迁移学习的变工况气体泄漏检测[J]. 仪器仪表学报,2023,44(6):177-187.
- ZHANG L H, LI P, LIU X Y. Gas leak detection for variable conditions based on deep transfer learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(6):177-187.
- [18] 李振冲,周波,张绿云,等. 在复杂背景下应用迁移学习技术优化木薯叶疾病识别与分析的研究[J]. 黑龙江粮食, 2024(6):74-77.
- LI ZH CH, ZHOU B, ZHANG L Y, et al. Study on application of transfer learning technology to optimize cassava leaf disease recognition and analysis under complex background[J]. Journal of Heilongjiang Grain, 2024(6):74-77.
- [19] KHAN I, SOHAIL S S, MADSEN D Ø, et al. Deep transfer learning for fine-grained maize leaf disease classification[J]. Journal of Agriculture and Food

- Research, 2024, 16: 101148.
- [20] 张凤, 张锦水, 段雅鸣, 等. 迁移深度卷积神经网络模型秋粮作物泛化识别[J]. 遥感学报, 2024, 28(3): 661-676.
- ZHANG F, ZHANG J SH, DUAN Y M, et al. Transferring deep convolutional neural network models for generalization mapping of autumn crops[J]. National Remote Sensing Bulletin, 2024, 28(3): 661-676.
- [21] 郑雯, 沈琪浩, 任佳. 基于 Improved DR-Net 算法的糖尿病视网膜病变识别与分级[J]. 光学学报, 2021, 41(22): 72-83.
- ZHENG W, SHEN Q H, REN J. Recognition and classification of diabetic retinopathy based on Improved DR-Net algorithm[J]. Acta Optica Sinica, 2021, 41(22): 72-83.
- [22] 杨涌, 秦小林, 林小光, 等. 基于数据增强和深度学习的特定患者癫痫检测分析方法[J]. 生物医学工程学杂志, 2022, 39(2): 293-300.
- YANG Y, QIN X L, LIN X G, et al. Epilepsy detection and analysis method for specific patient based on data augmentation and deep learning[J]. Journal of Biomedical Engineering, 2022, 39(2): 293-300.
- [23] MAGESHKUMAR N, LAKSHMANAN L. Intelligent data deduplication with deep transfer learning enabled classification model for cloud-based healthcare system[J]. Expert Systems with Applications, 2023, 215: 119257.
- [24] SALEH A W, GUPTA G, KHAN S B, et al. An Alzheimer's disease classification model using transfer learning Densenet with embedded healthcare decision support system[J]. Decision Analytics Journal, 2023, 9: 100348.
- [25] 茶兴增, 张月, 张翼飞, 等. 基于两阶卷积神经网络训练有限心电数据的心脏骤停早期分类识别算法[J]. 生物医学工程学杂志, 2024, 41(4): 692-699.
- CHA X Z, ZHANG Y, ZHANG Y F, et al. Early classification and recognition algorithm for sudden cardiac arrest based on limited electrocardiogram data trained with a two-stages convolutional neural network[J]. Journal of Biomedical Engineering, 2024, 41(4): 692-699.
- [26] 李国华, 吴森. 现代无损检测与评价[M]. 北京: 化学工业出版社, 2009.
- LI G H, WU M. Modern nondestructive testing and evaluation[M]. Beijing: Chemical Industry Press, 2009.
- [27] 魏新园, 周京欢, 钱牧云, 等. 随机森林算法在超声缺陷识别中的应用研究[J]. 电子测量与仪器学报, 2024, 38(5): 47-55.
- WEI X Y, ZHOU J H, QIAN M Y, et al. Research on the application of random forest algorithm in ultrasonic defect recognition[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(5): 47-55.
- [28] 钟聃, 李铁虎, 李诚. 基于深度迁移学习的复杂机场场景飞机目标检测方法[J]. 光子学报, 2024, 53(4): 228-238.
- ZHONG D, LI T H, LI CH. Enhancing aircraft object detection in complex airport scenes using deep transfer learning[J]. Acta Photonica Sinica, 2024, 53(4): 228-238.

作者简介



魏新园, 2015 年于合肥工业大学获得学士学位, 2020 年于合肥工业大学获得博士学位, 现为安徽工业大学教师, 硕士生导师, 主要研究方向为精密数控机床精度保障技术、智能感知技术。

E-mail: weixy@ahut.edu.cn

Wei Xinyuan received his B.Sc. degree and Ph.D. degree both from the Hefei University of Technology in 2015 and 2020, respectively. He is currently a teacher and M.Sc. supervisor at the Anhui University of Technology. His main research interests are precision CNC machine tools accuracy assurance technology, intelligent perception technology, and machine learning.



李丹 (通信作者), 2008 年于南京航空航天大学获得博士学位, 现为安徽工业大学教授, 主要研究方向为图像处理、机器视觉和自主导航。

E-mail: lidan@ahut.edu.cn

Li Dan (Corresponding author) received her Ph.D. degree from Nanjing University of Aeronautics and Astronautics in 2008. She is currently a professor at Anhui University of Technology. Her main research interests include image processing, machine vision and autonomous navigation.