DOI: 10.3901/JME.2020.08.235

一种改进卷积神经网络模型的焊缝缺陷识别方法^{*}

姜洪权^{1,2} 贺 帅¹ 高建民¹ 王荣喜¹ 高智勇¹
王晓桥³ 夏锋社³ 程 雷¹

- (1. 西安交通大学机械制造系统工程国家重点实验室 西安 710049;
2. 麻省理工学院制造和生产率实验室 剑桥 02139 美国;
3. 陕西省特种设备检验检测研究院 西安 710048)

摘要: 针对传统卷积神经网络(Convolutional neural network, CNN)应用于焊缝缺陷识别时,池化模型适应差及特征选择能力低、以及易导致过拟合问题,提出了一种基于改进卷积神经网络(Improved pooling model and feature selection of CNN, IPFCNN)的焊缝缺陷识别方法。结合焊缝缺陷图像本身的特点,对传统平均池化模型做出改进,提出一种综合考虑池化域与其所在区域特征图分布的池化模型;为增强模型特征选择能力,提出将随机森林与卷积神经网络相结合的强化特征选择方法。以某汽轮机制造过程中焊缝缺陷识别案例对所提方法进行了验证和说明,结果表明提出的池化模型在处理不同特征分布的池化域时具有动态自适应性,并通过提高特征选择能力,使得所提方法比传统 CNN 方法具有更高的缺陷识别率。

关键词: 焊缝缺陷识别; 卷积神经网络; 池化模型; 特征强化选择; 深度学习

中图分类号: TP391

An Improved Convolutional Neural Network for Weld Defect Recognition

JIANG Hongquan^{1,2} HE Shuai¹ GAO Jianmin¹ WANG Rongxi¹ GAO Zhiyong¹
WANG Xiaoqiao³ XIA Fengshe³ CHENG Lei¹

- (1. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049;
2. Laboratory for Manufacturing and Productivity, Massachusetts Institute of Technology, Cambridge, 02139 USA;
3. Shaanxi Special Equipment Inspection and Testing Institute, Xi'an 710048)

Abstract: Aiming at the problems of poor adaptability of pooling model, low feature selection ability and over-fitting when traditional convolutional neural network (CNN) is applied to weld defect recognition, a new method of weld defect recognition based on improved pooling model and feature selection CNN (IPFCNN) is proposed. According to the characteristics of weld defect image, the average pooling model is improved by taking into account the pooling region and its feature distribution. In order to enhance the feature selection ability of the CNN, an enhanced feature selection method combining random forest and CNN is proposed. A case study of weld defect recognition in the manufacturing process of steam turbine is to illustrate the work. The results show that the proposed method IPFCNN has dynamic adaptability in dealing with pooling region with different feature distributions and improving the feature selection ability, and it has higher defect recognition rate than the traditional CNN method.

Key words: weld defect recognition; convolutional neural network; pooling strategy; feature enhancement selection; deep learning

0 前言

汽轮机、船舶等重大复杂装备在制造过程中多采用焊接制造方式,并通过无损射线技术检测缺陷。

因此,以射线检测图像数据为对象,研究高效的缺陷识别技术对保证焊接质量、以及装备使用的可靠性及安全性具有重要的意义。

当前,国内外众多学者对基于射线检测图像的缺陷识别技术进行了研究,传统的技术路线主要包括“缺陷分割-特征提取-特征选择-缺陷识别”等环节过程^[1]。焊缝缺陷分割^[2]主要实现缺陷区域的提取,如改进的 Otsu 法^[3]等;特征提取主要是获得描

^{*} 国家重点研发计划(2017YFF0210502)、陕西省自然科学基金项目(2019JM-214)和陕西省质量人才计划(3211000781)资助项目。20191010 收到初稿,20191001 收到修改稿

述缺陷的特征集,如边缘特征、基于区域特征^[4]、纹理特征^[5]等;特征选择主要实现去除冗余特征和噪声,而保留有用特征。缺陷识别是在上述基础上对缺陷类型、性质进行有效判别,也是整个缺陷识别技术体系的核心步骤;多采用多源信息融合决策^[6]、贝叶斯^[7]、支持向量机^[8]、模糊逻辑^[9]等模式识别方法。近年来,随着深度学习等 AI 技术发展,基于卷积神经网络(Convolutional neural network, CNN)深度学习的方法已成为图像处理、模式识别等领域的研究热点^[10-16]。现有 CNN 应用技术研究主要包括对 CNN 算法的改进^[17-20]以及针对应用领域的具体问题做出相应的改进^[21-22]两方面。以焊缝图像为基础,利用卷积神经网络进行焊缝缺陷识别,可充分利用其“端到端”的优势,即直接利用包含缺陷的图像进行分析,从而可以克服传统的技术路线各环节中人工处理过程对缺陷识别的不利影响。

然而,在实际应用 CNN 进行焊缝缺陷识别时还存在以下问题:首先,现有池化模型在面对不同特征分布的池化域时,都存在动态自适应性差、部分特征被削弱的问题;再者,焊缝图像中缺陷自身灰度分布与其周边区域的灰度分布有重要的联系,但现有池化模型在特征提取时忽视这种特点,缺乏综合考虑特征图局部特征与特征图全局特征分布的池化模型;此外,传统 CNN 方法容易陷入过拟合,

模型参数的学习往往不够充分,难以达到最优的特征选择,从而影响最终的识别精度。

针对以上问题,本文提出了一种具有改进池化及特征选择模型的卷积神经网络模型及焊缝缺陷识别技术。首先,综合考虑池化域与其所在图像区域特征构建一种新的池化模型;再者,在特征选择过程中,利用随机森林算法对特征重要性进行评估与选择,从而达到强化 CNN 网络模型特征选择能力的目的。最后,通过企业实际案例对所提方法进行说明和验证,结果表明,本文方法有效克服了传统卷积神经网络中存在的不足,提高了卷积神经网络模型池化特征选择的精度以及特征选择的能力,并将本文所提方法应用到焊缝缺陷识别中,取得较传统 CNN 方法更高的分类正确率。

1 传统卷积神经网络方法及问题分析

1.1 传统卷积神经网络理论概述

传统卷积神经网络(CNN)最早由 FUKUSHIMA^[23]在 1980 年提出,典型的 CNN 模型如图 1 所示,主要由输入层、隐层和输出层构成,且在隐层中通常由多个卷积层和下采样层的重复结构以及全连接层组成。CNN 主要通过隐层的卷积和下采样进行特征提取,经过隐层的特征提取可得到一定维度的特征向量,并通过输出层实现分析结果输出。

图 1 典型卷积神经网络模型图

其中,卷积层由卷积核对输入特征图进行卷积运算后再加上偏置项,并通过激活函数激活后得到其输出特征图。由于卷积核的“局部感受”作用,实现了卷积层与输入图像之间的部分连接。下采样层也称为特征映射层,通过对输入特征图进行池化后获得。所谓池化,即指通过选择输入特征图中不同的连续范围作为池化区域,通常取大小为 $n \times n$ 的矩形区域,按照一定的方式选择池化域内的某一特征作为池化区域的特征。常用特征选择模型包括池化模型最大池化和平均池化,最大池化表示选取池化域内最大值为池化域特征,平均池化表示选取池化域内所有特征的平均值作为池化域特征。假设输

入特征图为 F ,池化域大小为 $n \times n$,设池化过程中移动步长为 n ,则最大池化模型与平均池化模型表达式分别如式(1)和(2)所示

$$S = \max_{i=1, j=1}^n (F_{ij}) \quad (1)$$

$$S = \frac{1}{n^2} \left(\sum_{i=1}^n \sum_{j=1}^n F_{ij} \right) \quad (2)$$

式中, F_{ij} 表示输入特征图在处的特征值; S 表示某一池化域池化后得到的特征值。

全连接层是本层神经元与上层神经元两两连接但本层神经元之间不连接的结构。通过使用全连接

层,可以增强网络的非线性映射能力,同时限制网络规模的大小。

1.2 传统 CNN 方法存在问题分析

由以上 CNN 模型可知,池化是传统 CNN 方法的关键步骤之一^[24]。其中,最大池化与平均池化模型是常用的两种经典模型。如图 2 所示为两种不同特征分布的池化域, v 、 v_1 、 v_2 、 v_3 、 v_4 表示值不相同的像素,空白部分表示像素值为 0。图 2a 所示的特征集中在最大值 v 处,表明该处池化域原图像灰度变化较为明显,即输入特征图在此区域可能包含边缘等灰度变化较为明显的特征;如果对图 2a 池化域使用平均池化方法,则会减弱图像的最大特征表示能力,导致边缘等特征被弱化。同理,图 2b 所示中特征值分布较为均匀,表明输入特征图在此处灰度变化较为平缓,适合采用平均池化模型,若采用最大池化模型可能会引入噪声。因此,传统 CNN 的池化模型不能依据图像特征的不同进行调整,动态自适应性差,导致特征提取不精确^[25]。其次,对于焊缝缺陷图像,其缺陷本身局部灰度分布与缺陷周边区域整体灰度分布有重要联系,但上述最大池化和平均池化模型在特征提取过程并未加以利用。

(a) 局部集中的池化域

(b) 均匀分布的池化域

图 2 两种不同特征分布的池化域

此外, CNN 容易陷入过拟合,模型参数的学习往往不够充分,进而影响分类效果。如图 1 所示,由 CNN 提取到的特征向量中可能含有较多噪声或冗余特征,难以达到最优的特征选择;同时,由于缺乏对特征向量中各特征重要性的度量,从而对最终的识别精度造成影响。

2 基于改进的卷积神经网络焊缝缺陷识别方法

2.1 综合考虑池化域与所在特征图特征分布的池化模型

针对上述经典池化模型在焊缝缺陷识别中存在的问题,本文提出了一种综合考虑池化域与所在特征图特征分布的池化模型,综合考虑了焊缝缺陷图

像中缺陷本身局部灰度分布特征与缺陷周边区域整体灰度分布特征,使得池化模型在面对不同特征分布图像处理时具有一定动态自适应性。基于缺陷图像分布特征的改进池化模型原理如图 3 所示。

图 3 本文池化模型抽象过程

首先将缺陷本身局部区域抽象为池化模型中的池化域,将包含缺陷的图像整体抽象为池化域所在特征图;在以上基础上,利用方差考察池化域与特征图特征分布特点,即基于池化域内特征方差 σ_p 与其所在特征图方差 σ_{FM} 关系分析,构建修正因子 μ 对经典的平均池化模型进行改进,其表达式如式(3)所示

$$S = \begin{cases} \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n F_{ij} & \sigma_p < \sigma_{FM} \\ \frac{\mu}{n^2} \left(\sum_{i=1}^n \sum_{j=1}^n F_{ij} \right) & \sigma_p \geq \sigma_{FM} \end{cases} \quad (3)$$

可以看出,当 $\sigma_p < \sigma_{FM}$ 时,表明该池化域内特征方差较小,池化域内特征分布较为平均,此时模型池化特征提取方式与经典的平均池化模型保持一致;当 $\sigma_p \geq \sigma_{FM}$ 时,表明该池化域内特征方差较大,最大特征值明显,此时引入修正因子 μ 对经典的平均池化模型进行修正。修正因子 μ 为一个比例系数,其分子为池化域内的特征值总和,分母为池化域内的特征值总和与特征极差的差,其表达式如式(4)所示

$$\mu = t_{\text{sum}} / (t_{\text{sum}} - t_{\text{max}} + t_{\text{min}}) \quad (4)$$

式中, t_{sum} 、 t_{max} 、 t_{min} 分别为池化域内特征值之和、最大特征值和最小特征值。

综上所述,本文在构建池化模型过程中考虑了焊缝缺陷本身灰度分布与缺陷周边灰度分布具有重要联系的特点,选用了方差指标考察池化域与特征图的特征分布情况,对于输入特征图中灰度变化较为明显以及较为不明显的区域的特征提取具有一定的动态自适应性,且本文的池化模型兼具最大池化与平均池化的特点。

2.2 随机森林与 CNN 相结合的特征选择方法

针对 CNN 提取到的特征可能存在冗余和噪声

的问题, 本文利用随机森林理论对传统 CNN 模型进行改进, 从而使其具有强化特征选择的功能。随机森林理论的主要思想为: 通过自助采样法(Bootstrap)从原数据集中获得若干个子集, 基于每个子集训练出不同的决策树, 再通过对决策树的集成随机森林^[26-27]。利用随机森林对 CNN 隐层的特征进行重要性, 评估的主要步骤如下。

(1) 对每一棵决策树, 选择相应的袋外数据(Out of bag, OOB), 计算袋外数据误差, 记为 errOOB1 。

所谓袋外数据是指通过重复抽样获得数据建立决策树时, 那些始终没有被抽中用于建立决策树的样本数据。当该部分数据用于对决策树的性能进行评估时, 计算得到的模型预测错误率称为袋外数据误差。

(2) 随机对袋外数据 OOB 所有样本的特征 X 加

入噪声干扰(可以随机改变样本在特征 X 处的值 Bootstrap), 再次计算袋外数据误差, 记为 errOOB2 。

(3) 假设森林中有 N 棵树, 则

$$\text{特征 } X \text{ 的重要性} = \Sigma(\text{errOOB2} - \text{errOOB1}) / N$$

如果加入随机噪声后, 袋外数据准确率大幅度下降(即 errOOB2 上升), 说明特征 X 对于样本的预测结果有很大影响, 即特征 X 的重要程度比较高。

综上所述, 如图 4 所示为本文强化特征选择的 CNN 模型图。该模型与传统的 CNN 模型相比, 在全连接层与输出层之间添加了一层特征选择层。特征选择层的作用是利用随机森林理论对 CNN 隐层提取的特征进行评估, 计算各特征的相应重要性权重, 获得带权重的特征向量。最后, 将所得到的带权重的特征向量送入分类器, 实现焊缝缺陷的识别。

图 4 本文强化特征选择的 CNN 模型图

2.3 基于改进卷积神经网络的缺陷类型识别流程

综合第 2.1 节和第 2.2 节所述, 本文提出的基于改进卷积神经网络模型(IPFCNN)的焊缝缺陷类型识别流程如图 5 所示, 主要包括步骤 A、B、C 三步。其中步骤 A 构建特定架构卷积神经网络中, 所谓特定架构即子步骤 A1 构建改进池化模型即综合考虑池化域与图像特征分布的池化模型, 以及子步骤 A2 构建强化的特征选择方法。步骤 A 中构建好特定架构的卷积神经网络后, 在步骤 B 中, 以最小化代价函数为目标迭代, 训练形成步骤 A 中所述的焊缝缺陷识别神经网络。最后, 在步骤 C 中, 将待识别底片输入到步骤 B 中训练好的卷积神经网络中, 实现缺陷类型的自动识别。

图 5 本文方法缺陷识别流程图

3 实例分析

3.1 实例数据集概述

本文选用来自某汽轮机生产过程的焊缝缺陷图像作为试验数据集。由于焊缝缺陷图像较大, 其中感兴趣区域即缺陷区域相对整张焊缝图像较小, 如果直接将焊缝图像作为 CNN 的输入训练网络模型, CNN 难以聚焦于焊缝缺陷区域的特征, 网络模型训

练难度较大。因此, 本文对原始焊缝图像做出预处理, 截取原始焊缝图像中 32×32 像素大小的包含缺陷及其周边焊缝图像的区域作为感兴趣区域, 如图 6 所示, 并将感兴趣区域的图像作为神经网络的输入。本文选取 1 116 张感兴趣区域焊缝图像, 其中包括 268 张裂纹图像, 120 张未融合图像, 288 张未焊透图像, 104 张条形缺陷图像, 168 张圆形缺陷, 168 张无缺陷图像共 6 大类图像。各类图像按照 4 : 1

的比例划分为训练集与测试集，共得到 892 张图像用于训练，224 张图像用于测试。

图 6 部分试验图像数据

3.2 本文提出的改进 CNN 模型构建

为验证本文方法提出的池化模型以及特征选择方法的有效性，分别构建名为 CNN-A 和 CNN-B 的模型，模型结构分别如图 7a、7b 所示，其中数字的单位均为像素大小。其中，CNN-B 模型为在 CNN-A 的基础上增加了对 FC6 特征层的特征选择处理。在以上 CNN-A 与 CNN-B 两种模型结构基础上，按照

表 1 所示的池化模型方式构建新的 CNN i ($i=1, 2, \dots, 5$)。

表 1 CNN i 模型构建方式表

CNN 模型名称	模型结构	池化模型
CNN1	CNN-A 型	平均池化
CNN2	CNN-A 型	最大池化
CNN3	CNN-A 型	本文池化
CNN4	CNN-B 型	最大池化
CNN5	CNN-B 型	本文池化

基于表 1 所示的 CNN 模型，可以进行以下试验验证：① 通过 CNN1、CNN2 和 CNN3 的识别结果，可验证本文池化模型的有效性；② 通过 CNN2 和 CNN4 的识别结果对比，可验证在最大池化模型的基础上本文提出的特征选择方法的有效性；③ 通过 CNN5 识别结果及相关对比分析，可验证本文所提出的基于改进 CNN 的焊缝缺陷识别方法的有效性。

图 7 CNN-A 和 CNN-B 模型结构图

3.3 试验结果分析

对第 3.2 节中试验验证第①部分进行验证：采用本文试验数据集，在 CNN1、CNN2、CNN3 上进行实验，记录在不同迭代次数下，3 种模型上缺陷的正确识别率，识别结果如图 8 所示。

由图 8 可知，在各模型迭代次为 60 次以后，

采用本文方法池化模型的 CNN3 较最大池化模型的 CNN1 和平均池化模型的 CNN2，均取得了较高的正确识别率，证明本文方法的池化模型在选择池化特征时具有更高的精度，提取的特征能更好地对图像进行描述，有利于缺陷识别率的提升。

图 8 CNN1、CNN 2、CNN 3 不同迭代次数下的识别率

表 2 特征权重表

特征编号	特征权重						
1~7	0	0.007 2	0.008 6	0.010 0	0.014 0	0.006 5	0.017 1
8~14	0.013 1	0	0.005 6	0	0.009 0	0.029 2	0.004 0
15~21	0.017 2	0.017 7	0.005 8	0.008 1	0.008 0	0.031 4	0.002 1
22~28	0.004 1	0.002 4	0.033 9	0.032 5	0.003 2	0.016 9	0.026 2
29~35	0.017 6	0	0.012 8	0.000 8	0.000 9	0	0.006 5
36~42	0	0.002 5	0.001 5	0.002 1	0	0	0.007 8
43~49	0.083 2	0.012 2	0	0	0.007 4	0.009 4	0.026 2
50~56	0.001 3	0.001 2	0	0.000 9	0.071 1	0.001 3	0
57~63	0.005 8	0.013 2	0.007 3	0.016 0	0.014 3	0	0.002 7
64~70	0	0.201 8	0	0	0.017 6	0.002 7	0.009 0
71~77	0.002 4	0.019 9	0.005 8	0.002 0	0.022 5	0.001 1	0.033 9
78~84	0.005 7	0	0.000 2	0.004 2	0.006 2	0.000 3	0.004 7

“Dropout”方法暂时丢弃某些神经元，然而在“Dropout”随机丢弃神经元的过程中，可能将某些重要特征的神经元丢弃，这一过程具有一定的盲目性；且在训练过程中需要对淘汰神经元的数量进行选择，给训练带来一定的难度。本文的特征选择过程，可根据特征的重要性有选择地丢弃某些神经元，既起到了评估特征重要性的作用，又对神经元进行了有选择的丢弃。

采用本文试验数据集，在 CNN2、CNN4、CNN5 上进行试验，训练过程在不同迭代次数下，3 种模型上缺陷的正确识别率，识别结果见图 9。

从图 9 的试验结果可以证明，将随机算法对特征理解与神经网络相结合对特征进行选择后，可使模型的正确识别率进一步提高。并且本文所改进 CNN 模型相较于传统 CNN 模型对于焊缝缺陷具有更高的正确识别率。

4 结论

本文提出了一种新的 CNN 模型及缺陷识别方

对第 3.2 节中试验验证第②、③部分进行验证：本文训练集中共 892 张图像，CNN4、CNN5 在 FC6 层从每张图像共提取到 84 个特征。则在使用批量梯度下降法训练神经网络的过程中，在每次迭代中，FC 层可以提取到一个维度为 892×84 维的特征集合 T 。采用随机森林对特征集合 T 中的各特征进行重要性评估，可以获得各特征的重要性权重，如表 2 所示为 CNN5 在终止迭代次数 200 次时各特征的权重(结果保留 4 位小数)。

由表 2 可知，84 维特征中有 16 维的特征权重为 0，相当于在特征选择过程中丢弃了这 16 维特征所在的神经元。此外，传统神经网络在训练过程中，出于减少训练时间与防治过拟合的目的，往往采用

图 9 三种池化模型在不同迭代次数下的识别率

法，通过改进经典的池化模型，并将传统特征评价方法与 CNN 相结合对特征进行选择，扩展了传统 CNN 模型构建方式，提高了其模式识别能力；并通过缺陷识别实例验证了本文方法的有效性，主要结论如下。

(1) 本文所提的池化模型，针对不同特征分布

的池化域具有一定的动态自适应性,可更好地提取目标区域特征且不会引入噪声。

(2) 提出将随机森林与 CNN 相结合,强化了模型的特征选择能力,并降低了训练过程中 Dropout 的盲目性。

(3) 采用本文所提池化模型以及特征选择方法所构建的 IPFCNN 方法应用于焊缝缺陷识别中,比传统 CNN 方法具有更高的识别率;同时,可以拓展到其他模式识别应用领域,具有通用性。

参 考 文 献

- [1] 余永维, 殷国富, 殷鹰, 等. 基于深度学习网络的射线图像缺陷识别方法[J]. 仪器仪表学报, 2014, 35(9): 2012-2019.
YU Yongwei, YIN Guofu, YIN Ying, et al. Defect recognition for radiographic image based on deep learning network[J]. Chinese Journal of Scientific Instrument, 2014, 35(9): 2012-2019.
- [2] HAN Liu, GUO Runyuan. Detection and identification of SAWH pipe weld defects based on X-ray image and CNN[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 247-256.
- [3] MALARVEL M. An improved version of Otsu's method for segmentation of weld defects on X-radiography images[J]. Optik-International Journal for Light and Electron Optics, 2017, 109: 109-118.
- [4] NAFAA N, DJEMEL Z, LATIFA H. Fusion-based shape descriptor for weld defect radiographic image: retrieval[J]. International Journal of Advanced Manufacturing Technology, 2013, 68(9): 2815-2832.
- [5] JIANG Hongquan, ZHAO Yalin, GAO Jianmin, et al. Weld defect classification based on texture features and principal component analysis[J]. Insight, 2016, 58(4): 194-200.
- [6] JIANG Hongquan, WANG Rongxi, GAO Zhiyong, et al. Classification of weld defects based on the analytical hierarchy process and Dempster-Shafer evidence theory[J]. Journal of Intelligent Manufacturing, 2017(6): 1-12.
- [7] GOUMEIDANE A B, BOUZAIENI A, NACEREDDINE N, et al. Bayesian networks-based defects classes discrimination in weld radiographic images[C]// International Conference on Computer Analysis of Images & Patterns. Springer, Malta, 2015.
- [8] MEKHALFA F, NACEREDDINE N. Multiclass classification of weld defects in radiographic images based on support vector machines[C]// Tenth International Conference on Signal-image Technology & Internet-based Systems. IEEE Computer Society, 2014, Marrakech, Morocco.
- [9] BANIUKIEWICZ P. Automated defect recognition and identification in digital radiography[J]. Journal of Nondestructive Evaluation, 2013, 33(3): 1-8.
- [10] 卢泓宇, 张敏, 刘奕群, 等. 卷积神经网络特征重要性分析及增强特征选择模型[J]. 软件学报, 2017, 28(11): 2879-2890.
LU Hongyu, ZHANG Min, LIU Yiqun, et al. Convolution neural network feature importance analysis and feature selection enhanced model[J]. Journal of Software, 2017, 28(11): 2879-2890.
- [11] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9): 1904-1916.
- [12] CHEN Junwen, LIU Zhigang, WANG Hongrui, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network[J]. IEEE Transactions on Instrumentation & Measurement, 2018, 67(2): 257-269.
- [13] LUO Hengliang, YANG Yi, TONG Bei, et al. Traffic sign recognition using a multi-task convolutional neural network[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 19(4): 1100-1111.
- [14] WANG Lihua, ZHAO Xiaoping, WU Jiaxin, et al. Motor fault diagnosis based on short-time Fourier transform and convolutional neural network[J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1357-1368.
- [15] 姜洪开, 邵海东, 李兴球. 基于深度学习的飞行器智能故障诊断方法[J]. 机械工程学报, 2019, 55(7): 27-34.
JIANG Hongkai, SHAO Haidong, LI Xingqiu. Deep learning theory with application in intelligent fault diagnosis of aircraft[J]. Journal of Mechanical Engineering, 2019, 55(7): 27-34.
- [16] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7): 9-18.
HU Niaoqing, CHEN Huipeng, CHENG Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks[J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18.
- [17] WANG Yunfeng, ZHOU Wengang, ZHANG Qilin, et al. Weighted multi-region convolutional neural network for action recognition with low-latency online prediction[C]// 2018 IEEE International Conference on Multimedia & Expo Workshops (ICMEW), July 23-27 San Diego, 2018.
- [18] WU Xiang, HE Ran, SUN Zhenan, et al. A light CNN for deep face representation with noisy labels[J]. IEEE

- Transactions on Information Forensics & Security, 2018, 13(11): 2884-2896.
- [19] KHUMAIDI A, YUNIARNO E M, PURNOMO M H. Welding defect classification based on convolution neural network (CNN) and Gaussian kernel[C]// International Seminar on Intelligent Technology and ITS Applications, August 28-29, 2017, Surabaya, 2017: 261-265.
- [20] XU Juefei, BODDETI V N, SAVVIDES M. Local binary convolutional neural networks[C]// IEEE Conference on Computer Vision and Pattern Recognition, July 22-25, 2017, Hawaii, 2017: 4284-4293.
- [21] 王俊, 郑彤, 雷鹏, 等. 基于卷积神经网络的手势动作雷达识别方法[J]. 北京航空航天大学学报, 2018, 44(6): 4-10.
WANG Jun, ZHENG Tong, LEI Peng, et al. Hand gesture recognition method by radar based on convolutional neural network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(6): 4-10.
- [22] 唐浩, 黄伟鹏, 李哲媛, 等. 基于改进的卷积神经网络的负面表情识别方法[J]. 华中科技大学学报, 2015(s1): 457-460.
TANG Hao, HUANG Weipeng, LI Zheyuan, et al. Negative facial expression recognition based on convolutional neural network[J]. Journal of Huazhong University of Science and Technology, 2015(s1): 457-460.
- [23] FUKUSHIMA K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position[J]. Biological Cybernetics, 1980, 36(4): 193-202.
- [24] KIRA K, RENDELL L A. The feature selection problem: traditional methods and a new algorithm[C]// Tenth National Conference on Artificial Intelligence. AAAI Press, 1992: 129-134.
- [25] 刘万军, 梁雪剑, 曲海成. 不同池化模型的卷积神经网络学习性能研究[J]. 中国图象图形学报, 2016, 21(9): 1178-1190.
LIU Wanjun, LIANG Xuejian, QU Haicheng. Learning performance of convolutional neural networks with different pooling models[J]. Journal of Image and Graphics, 2016, 21(9): 1178-1190.
- [26] MURSALIN M, ZHANG Y, CHEN Y, et al. Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier[J]. Neurocomputing, 2017, 241: 204-214.
- [27] 赵帅, 黄亦翔, 王浩任, 等. 基于随机森林与主成分分析的刀具磨损评估[J]. 机械工程学报, 2017, 53(21): 181-189.
ZHAO Shuai, HUANG Yixiang, WANG Haoren, et al. Random forest and principle components analysis based on health assessment methodology for tool wear[J]. Journal of Mechanical Engineering, 2017, 53(21): 181-189.

作者简介: 姜洪权, 男, 1978 年出生, 博士, 副教授, 博士研究生导师。主要研究方向为制造质量及服役质量理论与提升技术, 工业大数据分析与应用。

E-mail: hqjiang@mail.xjtu.edu.cn

王荣喜(通信作者), 男, 1985 年出生, 博士(后), 助理研究员。主要研究方向为数据驱动的复杂装备服役质量安全与可靠性控制技术, 工业大数据分析技术。

E-mail: rongxiwang@163.com