

基于 ST-TCN 的太阳能光伏组件故障诊断方法*

李 莎¹, 陈泽华¹, 刘海军²

(1. 太原理工大学 大数据学院, 山西 晋中 030600; 2. 晋能清洁能源有限公司, 山西 太原 030001)

摘 要: 实地调研并收集电站光伏组件常见的故障类型, 并对光伏组件在不同工作状态下的电流特征曲线进行分析, 发现光伏组件的电流数据叠加了复杂的表现特征和高噪声。为能精准诊断光伏组件的故障类型, 提出一种软阈值化的时序卷积神经网络(Soft Thresholding Temporal Convolutional Network, ST-TCN)光伏组件故障诊断模型。ST-TCN 网络使用多个残差模块的膨胀卷积层、ReLU 层、Dropout 层提取电流数值特征和时序特征, 再使用残差模块的软阈值化对所提取的特征降噪, 最终使用全连接层对残差模块提取的特征进行故障诊断分类。实验结果表明, ST-TCN 网络不仅结构简单, 收敛速度快, 而且故障诊断准确率高, 达到 92.99%。

关键词: 光伏组件; 时序卷积神经网络; 软阈值化; 故障诊断

中图分类号: TP207; TM914

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.222585

中文引用格式: 李莎, 陈泽华, 刘海军. 基于 ST-TCN 的太阳能光伏组件故障诊断方法[J]. 电子技术应用, 2022, 48(12): 79-83, 88.

英文引用格式: Li Sha, Chen Zehua, Liu Haijun. Fault diagnosis method of solar panel module based on ST-TCN[J]. Application of Electronic Technique, 2022, 48(12): 79-83, 88.

Fault diagnosis method of solar panel module based on ST-TCN

Li Sha¹, Chen Zehua¹, Liu Haijun²

(1. College of Data Science, Taiyuan University of Technology, Jinzhong 030600, China;

2. Jinneng Clean Energy Co., Ltd., Taiyuan 030001, China)

Abstract: This paper analyzes the current characteristic curves of photovoltaic modules under different working conditions and finds that the current data of photovoltaic modules superpose complex performance characteristics and high noise. In order to accurately diagnose the fault types of photovoltaic modules, a soft thresholding temporal convolutional network (ST-TCN) photovoltaic module fault diagnosis model is proposed. The ST-TCN network uses the dilated convolution layer, ReLU layer, and Dropout layer of multiple residual modules to extract current numerical and time series features, uses the soft thresholding of residual modules to de-noise the extracted features, and finally uses the full connection layer to diagnose and classify the extracted features of residual modules. The experimental results show that the ST-TCN network has a simple structure, fast convergence, and high accuracy in fault diagnosis, reaching 92.99%.

Key words: photovoltaic modules; temporal convolutional network; soft threshold; fault diagnosis

0 引言

光伏电站幅员辽阔, 位置偏远, 维护不易, 精确识别光伏组件的故障类型和物理位置对于维持光伏电站安全高效运行具有极其重要的意义。

当前国内外常用的光伏故障诊断方法包括红外图像法^[1]、I-V 曲线法^[2]、时域反射分析法^[3]、智能法^[4-8]。大型光伏电站一般建设在环境恶劣的郊区, 难以获得光伏组件的红外图像^[8], I-V 曲线法和时域反射分析法对所采集的数据精度要求极高, 基于经济成本考虑, 大型光伏电站所能投入的数据采集设备受限, 因此, 红外图像

法、I-V 曲线法和时域反射分析法不适用于大型光伏电站, 需要电站投入额外的数据采集设备, 增加了光伏电站的运维成本。智能法包括机器学习法和深度学习法, 大型光伏电站的建设规模大, 每天所产生的数据量较大, 机器学习法一般适用于小数据集, 难以适用于大型光伏电站。太阳能光伏电站光伏组件的电流数据可以精准地定位到每一个光伏组件的物理位置, 因此, 提高光伏组件的故障诊断准确率, 要充分挖掘不同故障状态下的电流数据随时间变化的本质特征。文献[6]将时序电压和时序电流绘制成二维特征图, 通过卷积神经网络对二维特征图进行特征提取和分类。卷积神经网络在图像领域的应用效果较好, 但难以提取时序性数据的特征。文献[7]通

* 基金项目: 国家重点研发计划资助项目(2018YFB1404503)

过长短期记忆神经网络提取电池板参数的时序特征,但模型收敛速度较慢。文献[8]通过 CNN-LSTM 深度学习诊断模型,对故障的诊断效果有很大的提升,但模型结构复杂,网络收敛速度慢。文献[9]提出了时序卷积神经网络,在处理时间序列数据预测问题方面与现存的时序深度学习模型(RNN、LSTM、GRU)相对比性能表现良好。

光伏电站电流数据本质上是时间序列数据,同时因所处环境条件恶劣,数据采集设备精度不够,数据传输设备存在老化现象,因此采集到的电流数据存在很多噪声。如同文献[10]中震动信号,光伏电站支路电流数据也是叠加了复杂表现特征和高噪声的信号,而噪声会对时序卷积神经网络学习性能产生重要负面影响。受文献[9]~[10]启发,本文提出了基于软阈值化的时序卷积神经网络(Soft Thresholding Temporal Convolutional Network, ST-TCN),将软阈值化加入时序卷积神经网络以降低电流特征数据的噪声,提升网络对电流特征数据的学习能力。

ST-TCN 光伏组件故障诊断模型不需要电站增加额外的图像或者数据采集设备,仅利用 ST-TCN 深度学习模型离线学习海量的历史电流数据就可以实现对光伏组件故障的诊断。实验证明,该模型具有结构简单、收敛速度快、故障诊断准确率高的特点。

1 理论基础

1.1 膨胀卷积

膨胀卷积^[11]也称空洞卷积,通过空洞因子(dilation rate, d)增加卷积核的感受野,普通卷积可以等价于空洞因子 $d=1$ 的膨胀卷积。

图 1 是 $d=1$ 的普通卷积和 $d=2$ 的膨胀卷积的对比示意图。其中大框图代表卷积输入特征图,黑色圆点代表卷积核,灰色区域代表卷积后的感受野。普通卷积感受野为 3×3 ,加入空洞因子后的膨胀卷积感受野增大为 5×5 。更大的感受野可以接收到更大范围的原始图像,在计算量不变的条件下能够提取比原始特征矩阵层次更高和更全面的特征。




图 1 普通卷积与膨胀卷积示意图

1.2 残差连接

网络深度越深提取到的特征越抽象,但是随着网络深度的增加,会出现梯度消散、梯度爆炸或网络过拟合

等问题,为了解决由于网络层数过深带来的梯度消散和爆炸、模型过拟合等问题,提出了残差连接,残差连接包含恒等映射和残差学习两部分^[12],图 2 为残差连接示意图。图中 Conv 代表卷积操作。

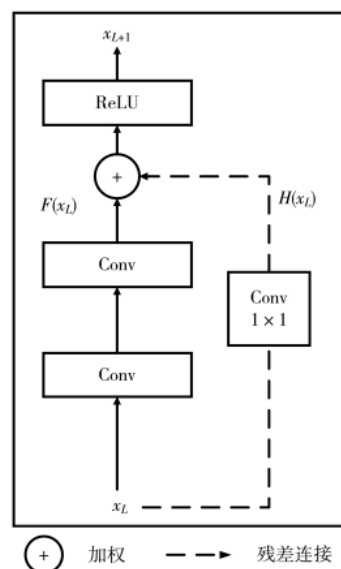


图 2 残差连接示意图

残差连接可定义为输入层和输出层的非线性映射的叠加^[13]:

$$x_{L+1} = \text{Activation}(H(x_L) + F(x_L, W_L)) \quad (1)$$

式中, x_{L+1} 为第 L 层残差块的输出, x_L 为第 L 层残差块的输入, $H(x_L)$ 为第 L 层残差块的恒等映射函数, $F(x_L, W_L)$ 为第 L 层残差块学习的残差函数, W_L 为第 L 层残差块的权重。

2 数据特征及类型

本文研究的实验数据均来源于山西省朔州市应县太阳能光伏电站的电池板组件在实际发电中产生的真实电流数据。该大型太阳能电站由 60 个光伏阵区构成,每个光伏阵区均有 2 个逆变器,每个逆变器下有 7 个汇流箱,每个汇流箱下均包含 15 条光伏支路,每一条光伏支路均串联 21 块电池板^[8]。

选取该电站提供的 2018 年 1 月 1 日~2018 年 10 月 31 日 2 个光伏阵区 10 个月的实测电流数据。原始电流数据采样频率为 1 s,一天 24 小时采集 86 400 个时间点。根据电流随日光强度渐变特点,将数据降采样为 1 min 一次。光伏组件工作区间定为 [AM8:00-PM6:00],每天每条支路的有效时间点为 600^[14]。同一个汇流箱下的支路电流数据作为一个处理单元,选取电流平均值 μ 、最大值 \max 、最小值 \min 、方差 σ^2 、标准差 s 、电流值 I_t^k 、电流变化率 ΔI_t 作为提取的 7 个电流特征^[8],式(2)~式(8)为各提取特征的计算过程。

$$\mu = \frac{1}{n} \sum_{k=1}^n I_t^k \quad (2)$$

$$\max = \max(I_t^1, I_t^2, \dots, I_t^n) \quad (3)$$

$$\min = \min(I_t^1, I_t^2, \dots, I_t^n) \quad (4)$$

$$\sigma^2 = \frac{1}{n} \sum_{k=1}^n (I_t^k - \mu)^2 \quad (5)$$

$$s = \sqrt{\frac{1}{n} \sum_{k=1}^n (I_t^k - \mu)^2} \quad (6)$$

$$I = I_t^k \quad (7)$$

$$\Delta I_t = (I_{t+1} - I_t) / \Delta t \quad (8)$$

式中, n 为一个汇流箱下的支路数, I_t^k 为 t 时刻第 k 支路的电路值, Δt 为 1 min。

光伏电站晴天的电流随日照强度变化呈正态曲线; 阴雨天因辐照强弱和风速变化, 电流数据呈现较大程度的波动, 如图 3 所示; 季节的更替甚至云彩的不规律遮挡均会对光伏组件电池板的发电曲线造成影响。因此, 不同类型的故障特征叠加不同的天气特征会呈现出极为复杂的电流表现特征。





图 3 晴天与阴天电流特征曲线对比图


通过对采集到的历史电流数据进行可视化分析和电站运维人员仔细探讨后, 将正常发电状态标签定义为 0, 将故障按照不同类型定义为五大类(1~5, 编号越大, 故障越严重, 处理优先级越高)。其中热斑烧穿或熔断故障容易引发火灾, 处理优先级最高(5), 维保人员需要立即处理; 其次通信线路出现故障会阻碍正常光伏组件的工作状态, 影响光伏电厂的发电效率, 处理优先级较高(4), 条件允许下尽快处理; 此外组件检修(3)、设备启动故障(2)和组件老化(1)不会立即引发安全事故, 维保人员可以暂缓处理。根据电流数据呈现出的 6 种状态, 如图 4 所示, 本文将标签集根据支路状态定义为 6 类。

3 基于 ST-TCN 的光伏组件故障诊断模型

ST-TCN 网络利用 TCN 残差模块的因果卷积^[9]使光伏组件故障诊断结果仅依赖于历史数据, 在应用因果卷

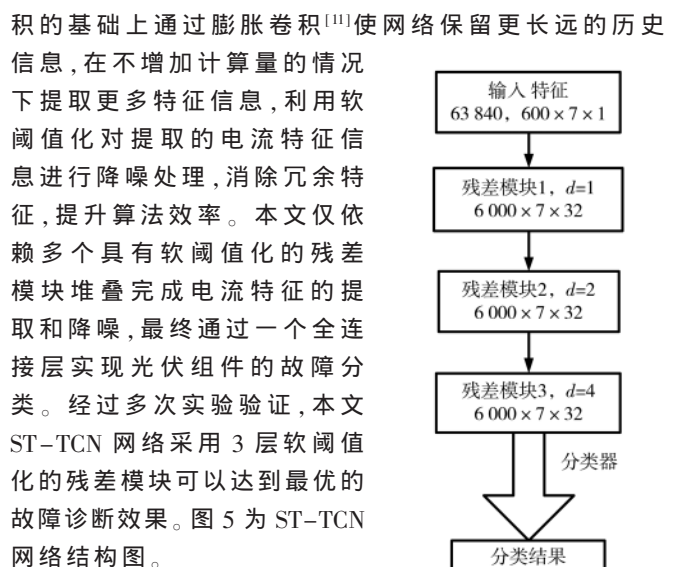


(a) 故障等级 1



(b) 故障等级 2

图 4 不同故障类型的电流曲线特征图



膨胀卷积根据空洞因子 d

决定处理数据的采样间隔, 空

图 5 ST-TCN 网络结构图

洞因子取值由膨胀基数 b 决定,为防止膨胀基数选取过大时,膨胀卷积出现信息遗漏的情况,因此膨胀基数的选取不可以大于卷积核的尺寸,空洞因子 d 的计算过程见式(9)^[9]:

$$d = b^{(i-1)}, k \geq b \quad (9)$$

式中: d 为空洞因子, b 为膨胀基数, i 为第 i 层残差块, k 为卷积核尺寸。

经过具体实验验证,ST-TCN 光伏故障诊断模型选取的最优的参数:膨胀基数 $b=2$,卷积核尺寸为 3,选取 3 层残差模块,每层残差块的空洞因子取值分别为 1、2、4。

ST-TCN 光伏故障诊断模型的残差模块使用两层膨胀卷积提取特征信息,使用 ReLU 激活函数^[9]实现非线性映射,使用 Batch Normalization^[15](BN)和 Dropout 正则化网络,使用软阈值化模块对所学习的特征数据进行降噪处理。图 6 为残差模块结构图。




图 6 残差模块结构图

文献[10]将软阈值化用在深度残差收缩网中以降低大型旋转机器产生的震动信号的噪声,从而增加残差网络对高噪声背景下的大型旋转机器的故障诊断精度。受此启发,本文将软阈值化放入到时序卷积神经网络的残差模块中对光伏电厂采集的电流特征数据进行降噪处理。具体原理和实现过程如下所述:

软阈值化通过设定一个阈值,将与光伏故障诊断无关的特征置 0,保留与光伏故障相关的有效特征,阈值的选取会直接影响 ST-TCN 光伏故障诊断模型的降噪效果,所选阈值需要满足以下 3 个条件:

- (1)取值大于 0;
- (2)必须小于输入信号的最大值;
- (3)阈值根据样本所含噪声含量的变化而变化。

$$\text{soft}(x, t) = \text{sign}(x) \max\{|x| - t, 0\} \quad (10)$$

$$\text{sign} = \begin{cases} 1 & x > 0 \\ -1 & x < 0 \end{cases} \quad (11)$$

式中, x 为特征值, t 为设定的阈值。

ST-TCN 光伏故障诊断模型通过设定软阈值化模块网络,根据输入电流特征样本的不同,自适应地学习与特征样本相关联的阈值,根据学习的阈值对网络残差模块提取的特征进行降噪处理,消除冗余特征对光伏故障诊断精度和速度的影响,提升网络的学习能力。

ST-TCN 网络结构中残差模块内的软阈值化模块详

细结构图如图 7 所示, I^{i-1} 代表第 $i-1$ 层残差模块的输出特征矩阵,同时作为第 i 层残差模块的输入特征矩阵, I^i 代表第 i 层残差模块的输出特征矩阵。图 7 中 Dconv 代表残差模块的膨胀卷积层,BN 代表归一化网络层,虚线代表残差连接,Abs 代表绝对值函数层,FC 为全连接网络层,GAP 代表 GlobalAveragePooling 网络层; D^i 为输入特征矩阵 I^{i-1} 经过残差模块的两遍膨胀卷积、ReLU 激活函数、Batch Normalization 归一化、Dropout 层所获得的输出特征矩阵。

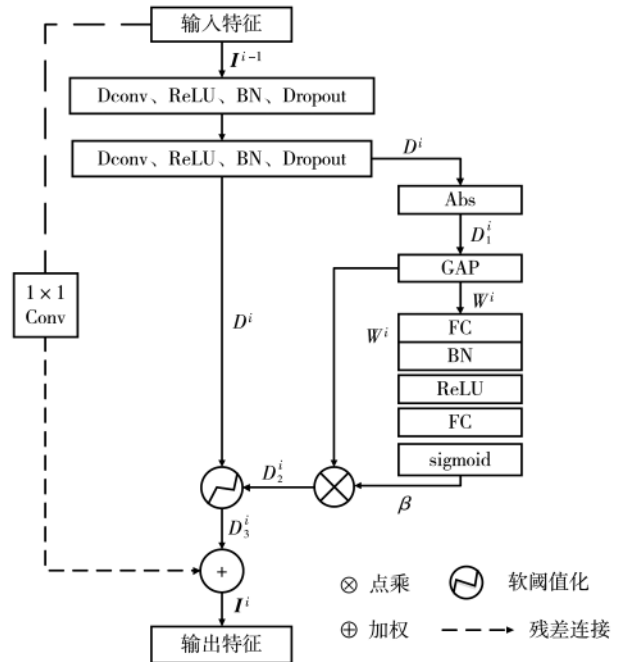


图 7 软阈值化模块结构图

4 实验验证

4.1 实验环境

实验环境为 Linux 系统,使用 8 块 Tesla T4 显卡,用 Tensorflow-GPU1.12.0 深度学习框架,优化器为 Adam,学习率为 0.000 09,损失函数为 categorical_crossentropy, Batch Size 为 100,训练迭代次数为 60 次;模型训练实验与对比实验均采用相同的实验环境。

4.2 实验评估指标

本文选择准确率 (Accuracy)、F1-score 分数、海明距离 (Ham_distance) 评估模型的质量。其中准确率越高,模型对样本判断正确的比重越大;F1-score 分数越高,模型的性能越好;海明距离越接近 0,模型预测结果与真实结果的距离越接近。

$$\text{Accuracy} = \frac{T}{Z} \quad (12)$$

$$\text{Precision}_i = \frac{\text{TP}_i}{\text{TP}_i + \text{FP}_i} \times W_i \quad (13)$$

$$\text{Recall}_i = \frac{\text{TP}_i}{\text{TP}_i + \text{FN}_i} \times W_i \quad (14)$$

$$F1\text{-score} = \sum_{i=0}^5 \frac{2 \cdot \text{Precision}_i \cdot \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad (15)$$

式中, T 为标签预测正确的样本数目, Z 为测试集样本的总数目, TP_i 为实际为 i 类样本被预测为 i 类样本的样本数, FP_i 为实际为其他类样本被预测为 i 类样本的样本数, FN_i 为实际为 i 类样本被预测为其他类样本的样本数, W_i 为各类标签所占权重, 共有 6 类标签。

4.3 实验结果及分析

为验证基于 ST-TCN 光伏组件故障诊断模型性能的优越性和软阈值模块对于信号特征降噪的有效性, 以太阳能电站在实际发电中产生的真实电流数据为实验数据。将 16 光伏阵区 10 个月的数据集作为训练集, 将 17 光伏阵区 10 个月的数据集作为测试集。训练集和测试集均为 10 个月累计 304 天的电流数据, 每天 210 条支路, 共计 127 680 条支路数据, 其中故障支路数为 48 371。在同样的实验条件下, 将 ST-TCN 与 TCN 模型、CNN 模型、LSTM 模型、CNN-LSTM 模型进行对比实验。图 8 所示为各模型在训练迭代次数 100 内的准确率变化趋势。




图 8 各模型准确率变化趋势

表 1 列出了各种方法的性能指标, 在测试样本集上, ST-TCN 模型在准确率、F1-score 分数、海明距离表现最优。相对于传统的 CNN 网络仅学习电流数值特征忽略时序特征, LSTM 网络充分学习了电流随时间变化而变化的时序特征, 各项指标均有一定提升。相对于 LSTM 仅考虑电流时序性的网络结构, CNN-LSTM 网络使用 CNN 对特征进行提取, 使用 LSTM 保留时序特征, 模型的效果有一定的提升, 但是, CNN-LSTM 模型结构复杂, 网络的 LSTM 采用串行计算方式, 导致模型收敛速度慢。TCN 网络采用膨胀卷积作为核心计算单元, 堆叠的残差模块和膨胀卷积相结合, 跨时域提取信息, 能够更好地捕捉数据时序上的依赖关系, 同时使用膨胀卷积和残差连接使得网络在融合更多信息的同时保留底层的细节特征信息, 对电流特征信息的提取更全面, 从实验结果看,

表 1 模型测试结果对比

模型	准确率/%	F1-score	Ham_distance
CNN	82.78	0.755 6	0.057 3
LSTM	87.74	0.865 7	0.040 8
CNN-LSTM	90.09	0.889 5	0.033 0
TCN	91.59	0.906 5	0.029 0
ST-TCN	92.99	0.927 5	0.023 3

TCN 的故障诊断效果优于 CNN、LSTM、CNN-LSTM 模型。相对于 TCN 模型, ST-TCN 模型在传统 TCN 的基础上增加了软阈值化模块, 对残差模块提取的特征信息进行降噪处理, 进一步优化了网络所提取的特征信息, 提升了网络的学习能力, ST-TCN 模型在训练迭代次数为 60 次时故障诊断准确率最高, 为 92.99%, F1-score 分数为 0.927 5, 海明距离为 0.023 3, 与其他模型相对比, 诊断效果最优。

5 结论

针对太阳能电站光伏组件电流数据叠加复杂的表现特征和高噪声, 提出了一种基于 ST-TCN 的太阳能光伏组件故障诊断模型。在不考虑环境外部因素和组件内部因素条件下, 仅依靠电流数据对光伏组件所处的工作状态进行诊断, 主要创新工作包括: 将 TCN 应用于太阳能光伏组件故障诊断, 在经典 TCN 模型的残差模块中增加软阈值化, 对提取的特征信息进行降噪处理。

通过实验验证了 ST-TCN 模型在光伏组件故障诊断领域的高效性, 仅依靠电站历史电流数据对光伏组件的实际工作状态进行诊断, 改进并扩展了深度学习算法在清洁能源领域的应用, 对于保障光伏电厂平稳运行和节省运维成本均具有实际意义。

参考文献

- [1] 蒋琳, 苏建徽, 施永, 等. 基于红外热图像处理的光伏阵列热斑检测方法[J]. 太阳能学报, 2020, 41(8): 180-184.
- [2] 马铭遥, 张志祥, 刘恒, 等. 基于 I-V 特性分析的晶硅光伏组件故障诊断[J]. 太阳能学报, 2021, 42(6): 130-137.
- [3] 吴春华, 胡雅, 李智华, 等. 基于 SSTDR 的光伏系统直流母线电弧故障在线监测与定位[J]. 中国电机工程学报, 2020, 40(8): 2725-2734.
- [4] 叶进, 卢泉, 王钰淞, 等. 基于级联随机森林的光伏故障诊断模型研究[J]. 太阳能学报, 2021, 42(3): 358-362.
- [5] 刘圣洋, 冬雷, 王晓晓, 等. 基于高斯核模糊 C 均值聚类的光伏阵列故障诊断方法[J]. 太阳能学报, 2021, 42(5): 286-294.
- [6] LU X Y, LIN P J, CHENG S Y, et al. Fault diagnosis for photovoltaic array based on convolutional neural network and electrical time series graph[J]. Energy Conversion and Management, 2019, 196: 950-965.
- [7] 张文军, 林永君, 李静, 等. 基于长短期记忆神经网络的光伏阵列故障诊断[J]. 热力发电, 2021, 50(6): 60-68.

(下转第 88 页)

企业带来真正意义上的生产自动化,以及质量控制标准化、品质化和自动化。该系统已在某家电企业实现转化推广,应用效果很好,质量不良产品检出率提升 30%,减少因质量问题返厂维修带来的成本浪费 1.5 亿元;同时生产效率提升 10%,降低人工成本 235 万元/年,直接经济效益和社会效益显著。

5 结论

随着人工智能技术的发展,提升产线自动化、生产智能化、数据数字化是智能制造的发展方向,迫切需要完善产品生产周期的“生产档案”。基于 5G+MEC 的智能化质量检测检测系统通过 5G 大带宽、MEC、切片等技术,让家电企业产品检测模式产生变化,减少低效环节,有效提高企业生产效率以及产品质量,降低企业人工成本,提升产业链协作效率。同时,系统融合 MES 系统数据、产品物料数据、市场反馈追踪数据,形成产品全生命周期质量追溯体系,可智能判定分析市场质量反馈,给员工提供有理有据的产品质量评定结果,进而有效降低产品质量纠纷。

参考文献

- [1] 马洪源,肖子玉,卜忠贵,等.5G 边缘计算技术及应用展望[J].电信科学,2019,35(6):114-123.
- [2] 吕小兵,李守卿,罗飞,等.基于 5G 和边缘计算技术的智能仓储数字化管理平台[J].装备制造技术,2020(12):195-198.
- [3] 陈娟,黄梓阳.基于 5G 与 MEC 的高校图书馆网络规划与应用服务构建[J].无线互联科技,2021,18(13):33-35.
- [4] 肖刚,葛履.基于深度学习的机器视觉在制造业质量检测中的应用研究[J].数据,2021(12):56-60.
- [5] 董石磊,赵婧博.面向工业场景的 5G 专网解决方案研究[J].电信科学,2021,37(11):97-103.

- [6] 陈晓敏,赵涛涛,袁雪腾,等.“5G+工业互联网”时代的高端装备智能制造[J].南通大学学报(自然科学版),2021,20(3):1-12.
- [7] 夏文霞,庞伶俐,李冬冬,等.OPC UA 与 5G 融合在工业测试床的应用[J].制造业自动化,2020,42(7):74-78.
- [8] 刘仁寰.机器视觉技术在工业智能化生产中的应用[J].电子技术,2021,50(8):76-77.
- [9] 顾旭.基于视觉的工件表面质量检测系统的设计与实现[D].沈阳:中国科学院沈阳计算技术研究所,2021.
- [10] 付艳.基于面向 5G 网络的边缘计算技术研究[J].通信技术,2019,52(10):2416-2419.
- [11] 袁宇清,王浩,林泽兵,等.基于 5G 的边缘计算网关及其在电网中的应用[J].自动化应用,2020(6):61-63.
- [12] 陈志宏,王明晓.计算机视觉在智慧安防中的应用[J].电信科学,2021,37(8):142-147.
- [13] 曲岩嵩,张禹.基于视觉的工业产品参数质量检测[J].信息技术与信息化,2021(3):147-149.
- [14] 张维杰,景大智,鲁效平,等.基于 5G+MEC 的工业互联网测试床研究[J].信息通信技术与政策,2020(7):83-87.
- [15] 张呈宇,李红五,屈阳,等.面向工业互联网的 5G 边缘计算发展与应用[J].电信科学,2021,37(1):129-136.

(收稿日期:2022-01-27)

作者简介:

王超(1986-),男,博士,高级工程师,主要研究方向:智能制造、工业互联网及钢铁轧制技术。

鲁效平(1981-),通信作者,男,博士,教授级高级工程师,主要研究方向:智能制造、工业互联网以及新能源机械机电控制,E-mail:wangchao.zyy@haier.com。



扫码下载电子文档

(上接第 83 页)

- [8] 程起泽,陈泽华,张云钦,等.基于 CNN-LSTM 的太阳能光伏组件故障诊断研究[J].电子技术应用,2020,46(4):66-70.
- [9] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv:1803.01271, 2018.
- [10] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7):4681-4690.
- [11] FANG Y C, LI Y F, TU X K, et al. Face completion with hybrid dilated convolution[J]. Signal Processing: Image Communication, 2020, 80:115664.
- [12] HE K M, ZHANG X Y, REN S P, et al. Identity mappings in deep residual networks[J]. Computer Vision-ECCV 2016, PTIV, 2016, 9908:630-645.
- [13] HE K M, ZHANG X Y, REN S P, et al. Deep residual

learning for image recognition[J]. arXiv:1512.03385, 2015.

- [14] 程起泽.基于深度学习的光伏电站太阳能电池组件故障检测方法[D].太原:太原理工大学,2020.
- [15] KHARGHANIAN R, PEIRAVI A, MORADI F, et al. Pain detection using batch normalized discriminant restricted Boltzmann machine layers[J]. Journal of Visual Communication and Image Representation, 2021, 76:1047-3203.

(收稿日期:2022-01-22)

作者简介:

李莎(1996-),女,硕士研究生,主要研究方向:工业大数据、人工智能。

陈泽华(1974-),通信作者,女,博士,教授,主要研究方向:智能信息处理与工业大数据、粒计算与知识发现,E-mail:zehuachen@163.com。

刘海军(1972-),男,博士,中级工程师,主要研究方向:可再生能源在平价时代发展方向、低成本发电技术。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所