

DOI:10.13296/j.1001-1609.hva.2026.05.021

基于 CNN-GRU 的光伏阵列故障诊断方法

卢万杰, 马 磐

(辽宁工程技术大学, 辽宁 葫芦岛 125105)

摘要: 针对光伏阵列故障诊断识别率较低的问题, 文中提出一种基于卷积神经网络(convolutional neural network)与门控循环单元(gate recurrent unit)相结合的光伏阵列故障诊断方法。首先利用 MATLAB/Simulink 软件搭建光伏阵列的仿真模型, 分别模拟出短路、开路、老化、遮阴 4 种典型故障, 并记录其特征参数的数据; 接着将构建好的特征集划分成训练集与测试集输入至 CNN-GRU 识别模型中进行故障类型的诊断。并分别与 CNN、PNN、GRU 等识别模型进行对比。通过仿真实验可知, 文中提出的诊断模型可以更加准确且快速的完成诊断, 诊断率高达 99.5%, 具有较好的故障识别能力。

关键词: 光伏阵列; 卷积神经网络; 门控循环单元; 故障诊断

Fault Diagnosis Method of Photovoltaic Array Based on CNN-GRU

LU Wanjie, MA Pan

(Liaoning Technical University, Liaoning Huludao 125105, China)

Abstract: As for the problem of low fault diagnosis recognition rate of photovoltaic system, in this paper a fault diagnosis method for photovoltaic system based on the combination of convolutional neural network and gate recurrent unit is proposed. First, MATLAB/Simulink software is used to set up the simulation model of photovoltaic system, such four typical faults as short circuit, open circuit, aging and shading are simulated respectively, and the data of its characteristic parameters is recorded. Then, the constructed feature set is classified into the training set and testing set and input into the CNN-GRU recognition model for fault type diagnosis. Comparison with such recognition models as CNN, PNN and GRU is made. It is known through simulation experiments that the diagnostic model proposed in the paper can complete the diagnosis more accurately and quickly, with a diagnosis rate up to 99.5% and also good fault recognition ability.

Key words: photovoltaic array; convolutional neural network; gate recurrent unit; fault diagnosis

0 引言

随着化石能源不断消耗, 人们越来越重视清洁能源的发展^[1-2]。太阳能作为清洁能源的代表, 有着可持续、无污染等特点^[3-6]。光伏阵列作为太阳能转换的基础, 其监测与控制也备受关注。光伏阵列因其所处环境较为复杂, 容易发生故障。因而如何快速的诊断出光伏阵列的故障类别, 减少经济损失是可持续发展光伏产业的基础。

光伏阵列在发生各种故障时, 如短路、开路、老化、遮阴; 其基本参数会出现明显的波动, 而这些波

动的参数既可作为光伏阵列的故障特征。但只观察故障特征集是不能确定其所处的故障类型; 因而需要故障识别模型对其进行分类与预测辨识。在故障辨识模型方面, 国内外研究学者提出了支持向量机(support vector machine, SVM)^[7]、极限学习机(extreme learning machine, ELM)^[8]、多种人工神经网络等方法对故障特征进行分类识别; 这些方法都取得了一些成果, 但也存在一定的局限性; 支持向量机在面对多分类问题时, 需要大量时间调整其参数且分类效率较低; 极限学习机在进行故障诊断时, 其参数需要提前设置; 且参数的设置会直接影响分

收稿日期: 2025-10-05; 修回日期: 2025-12-20

基金项目: 国家自然科学基金项目(51974151); 辽宁省高等学校基本科研项目(LJ242410147033)。

Project Supported by National Natural Science Foundation of China(51974151), Basic Research Projects of Higher Education Institutions in Liaoning Province(LJ242410147033).

类与预测结果, 具有较大的偶然性; 大部分的人工神经网络都存在训练时间较长, 容易陷入局部收敛的情况, 并且分类以及预测精度较差。

卷积神经网络是一种带有卷积结构的前馈神经网络^[9-10]; 相较于传统的人工神经网络, 其分类以及预测精度都有大幅度提高^[11-12]; 但是如果只运用CNN进行故障识别, 有可能无法达到预计的效果。所以在此基础上引入门控循环单元, 加强其故障诊断的能力。门控循环单元是一种循环网络, 相较于传统的长短期记忆网络, 其结构以及精确度更为优越, 具有较好的故障分类以及预测能力^[13]。

鉴于此, 文中提出一种基于CNN-GRU的光伏阵列故障诊断方法。首先搭建其光伏阵列的仿真

模型, 分别模拟不同故障类型, 选取其中波动较大的参数作为其故障特征数据, 完成光伏阵列的故障特征提取。接着将构建好的故障特征数据集输入至CNN-GRU识别模型中进行故障类型的识别。通过实验验证, 论文提出的故障诊断模型可以更加准确的完成诊断, 具有更加优越的故障诊断能力。

1 光伏阵列的故障特征提取

在MATLAB/Simulink中建立一个4×3的光伏阵列模型见图1。分别模拟正常、短路、开路、遮阴、老化等5种典型状态, 获取各种状态的特征数据将其组成故障特征集。




图1 光伏阵列模型

Fig. 1 Photovoltaic system model

在正常状态时, 光伏元件正常模拟运行, 短路故障时, 通过短接部分光伏元件来实现, 开路故障时, 断开某一列的光伏元件来实现, 遮阴故障时, 通过调节某一块光伏板的光照强度来实现, 老化故障时, 通过在某一光伏支路中串联小电阻来实现。

在模型中单块的光伏元件参数相同。光伏元件光照取值范围为400~1 000 W/m², 温度取值范围为15~40 ℃, 其具体参数见表1。

表1 光伏阵列基本参数

Table 1 Basic parameters of photovoltaic system

组件参数	数值
开路电压 U_{oc}/V	36.3
短路电流 I_{sc}/A	7.84
最大功率点电压 U_{mp}/V	29
最大功率点电流 I_{mp}/A	7.35
开路电压 U_{oc} 温度系数/(%·℃ ⁻¹)	-0.360 99
短路电流 I_{sc} 温度系数/(%·℃ ⁻¹)	0.102

通过模拟不同状态的故障, 其部分光伏阵列不同状态下的I-U特性曲线与P-U特性曲线见图2、3。




图2 不同故障状态下的I-U特性曲线

Fig. 2 I-U characteristic curves under different fault states

由图2、3可知; 相较于正常运行状态, 在短路故障时, 光伏阵列的开路电压明显减小, 最大功率点电流以及电压也在降低; 在开路故障时, 短路电流降低; 在遮阴故障时, 其I-U特性曲线呈现阶梯状态; P-U特性曲线出现多峰现象, 其短路电流、最大




图3 不同故障状态下的P-U特性曲线

Fig. 3 P-U characteristic curves under different fault states

功率点电压以及电流降低;在老化故障时,最大功率电压与电流有明显变化。

通过以上分析可知光伏阵列在发生各种故障时,其开路电压 U_{oc} 、短路电流 I_{sc} 、最大功率点电压 U_{mp} 、最大功率点电流 I_{mp} 均会或多或少的发生变化,因此选择这4种变化量的数据作为光伏阵列的故障特征集,其部分典型故障特征集见表2。

表2 光伏阵列典型故障特征集

Table 2 Typical fault feature set of photovoltaic system

运行状态	U_{oc}/V	I_{sc}/A	U_{mp}/V	I_{mp}/A
正常	137.88	21.338 76	109.80	19.831 280
短路	120.24	11.596 13	94.68	10.888 300
开路	146.52	10.072 98	121.32	9.460 243
遮阴	139.68	13.568 51	91.44	12.695 970
老化	147.96	22.376 02	113.76	18.839 250

在故障特征集中,各种故障类型的特征数据均为100组,5种运行状态特征数据集共500组,其中300组作为训练集,余下的200作为测试集来测试论文所提出的CNN-GRU识别模型的分类与预测能力。至于此即完成光伏阵列的故障特征提取。

2 CNN-GRU 识别模型

2.1 卷积神经网络

卷积神经网络是一种带有卷积结构的前馈神经网络^[14],其具有较好的故障特征提取能力,可以准确且快速的提取故障信息。他一般由卷积层、池化层、全连接层、输出层组成^[15]。其中卷积层一般用于特征信号的提取^[16-18];池化层是将提取好的特征运用最大值池化、平均值池化等操作进行降维;全连接层是将池化后的特征进行合并,计算预测与分类的结果^[19]。输出层则是输出最终的分类与预测结果。

2.2 门控循环单元

GRU是循环神经网络(RNN)的一种,可以解决RNN中不能长期记忆和反向传播中的梯度问题^[20-23],其作用与长短期记忆网络相似,但结构比其更加简

单且更容易训练^[24-27]。GRU由重置门和更新门构成,其结构图见图4。

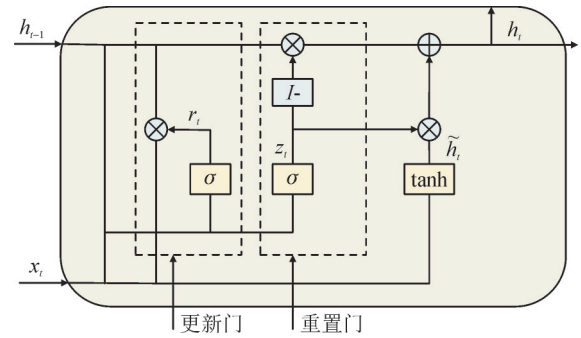


图4 GRU模型结构图

Fig. 4 GRU model structure diagram

数学表达式为:

$$\begin{cases} r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \\ z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \\ \tilde{h} = \phi(W_h \cdot [r_t \times h_{t-1}, x_t]) \\ h_t = (I - z_t) \times h_{t-1} + z_t \times \tilde{h} \end{cases} \quad (1)$$

$$y_t = \sigma(W_o \cdot h_t) \quad (2)$$

式(1)、(2)中: x_t 、 h_{t-1} 、 h_t 、 r_t 、 z_t 、 \tilde{h}_t 、 y_t 分别为输入的特征向量、前一刻时间的记忆变量、当前时间的记忆变量、更新门的情况、重置门的情况、当前时间候选集合的情况、当前时间的输出特征向量; W_r 、 W_z 、 W_h 分别为更新门、重置门、候选集合的权值; W_o 为输出向量与 $[h_{t-1}, x_t]$ 矩阵的权值参数; I 为单位下的矩阵; σ 为 sigmoid 函数; ϕ 为 tanh 函数。 σ 、 ϕ 的定义为:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\phi(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

GRU模型主要是将通过sigmoid函数变换后的 $[h_{t-1}, x_t]$ 矩阵输入到更新门中,来确定前一刻时间的记忆变量的变化程度^[28-31];运用重置门来记录 $(I - z_t)$ 倍的前一刻时间信息,然后利用 z_t 倍的 \tilde{h} 来确定当前时间的信息。最后将两者相加作为其输出的结果。

2.3 CNN-GRU 模型

文中运用的CNN-GRU模型融合了CNN的特征提取能力与GRU的分类预测能力,可以很好地对故障特征信息进行诊断。首先,将含有故障特征信息的数据输入到CNN模型中进行构建;然后将构建好的特征数据集输入至GRU模型进行分类预测训练,通过全连接层计算分类预测结果,使用Softmax分类;最后由输出层输出。其具体流程图见图5。

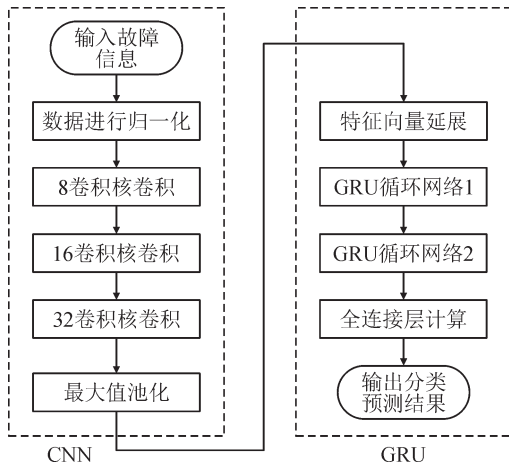


图5 CNN-GRU模型

Fig. 5 CNN-GRU model

其中特征数据归一化为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式(5)中: x 为初始的故障特征数据; x^* 为进行归一化计算后的数据; x_{\min} 、 x_{\max} 为训练特征数据的最小值与最大值。

3 光伏阵列故障诊断结果分析

将200组故障测试数据输入至已经训练完成的CNN-GRU模型中进行故障类型的识别,其中分类标签所代表的故障类型见表3。

表3 标签所代表的故障类型

Table 3 Fault types represented by labels

故障类型	正常状态	短路故障	开路故障	遮阴故障	老化故障
分类标签	1	2	3	4	5

CNN-GRU故障诊断结果见图6。如图6所示,文中所提出的CNN-GRU识别模型在经过一定的训练后,具有较好的故障诊断能力;分类以及预测效果较为优越,可以准确地识别出光伏阵列所处的故障类型。

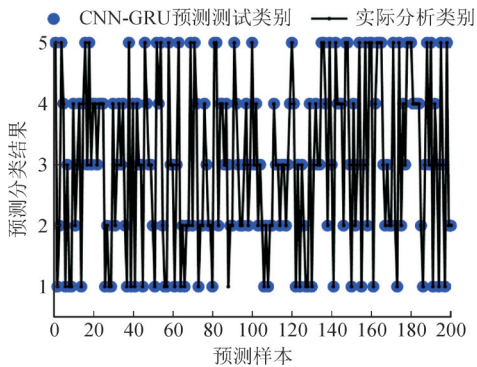


图6 CNN-GRU故障诊断结果

Fig. 6 CNN-GRU fault diagnosis results

为了突出论文所提故障识别模型的优越性,分别采用CNN、PNN、GRU等识别模型与其进行对比;其诊断结果见图6-9、表4。




图7 CNN故障诊断结果

Fig. 7 CNN fault diagnosis results




图8 PNN故障诊断结果

Fig. 8 PNN fault diagnosis results




图9 GRU故障诊断结果

Fig. 9 GRU fault diagnosis results

表4 不同故障诊断模型对比

Table 4 Comparison of different fault diagnosis models

故障诊断模型	故障诊断率/%	训练时间/s	测试时间/s	迭代次数
CNN-GRU	99.5	32.0	0.33	100
CNN	95.5	33.4	0.49	100
PNN	93.5	41.5	0.76	100
GRU	95.0	32.1	0.47	100

图6-9、表4结果表明在4种故障诊断模型之中,CNN-GRU识别模型的诊断率最高,高达99.5%;其诊断模型可以较为准确地诊断出光伏阵列的故障类型,具有较好的故障识别能力。相比于传统的CNN、PNN、GRU等识别模型,文中提出的诊断模型在其故障诊断率、训练与测试时间等方面都有一定

的提高,其故障诊断率分别提高了4%、6%、4.5%。在训练时间方面,CNN-GRU识别模型相较于CNN、PNN、GRU等传统模型分别提高了1.4、9.5、0.1 s,在测试时间方面分别提高了0.16、0.43、0.14 s。

综上所述,文中提出的CNN-GRU故障诊断模型可以更加准确且迅速的诊断出光伏列阵的故障类型,具有好的故障分类与预测能力。

4 结论

文中所提出的基于CNN-GRU的光伏列阵故障诊断方法有以下结论:

1)选取开路电压 U_{oc} 、短路电流 I_{sc} 、最大功率点电压 U_{mp} 、最大功率点电流 I_{mp} 为特征的数据集可以很好的反映光伏阵列的故障情况,为故障诊断模型提供较好的特征信息。

2)运用CNN-GRU识别模型,可以很好的克服常规故障诊断模型所带来的训练与测试时间长、诊断率低等缺点;使故障诊断率达到99.5%以上,具有较高的工程实践价值。

参考文献:

- [1] 武迪,许春雨,宋建成,等. 基于 β 参数的混合控制策略光伏系统MPPT算法研究[J]. 可再生能源,2018,36(1):8-14.
WU Di, XU Chunyu, SONG Jiancheng, et al. Maximum power point tracking algorithm of photovoltaic system based on β -parameter mixed control strategy[J]. Renewable Energy Resources, 2018, 36(1):8-14.
- [2] 王跃,白建波,李建. 光伏发电系统精细化逐时建模方法与应用案例分析[J]. 太阳能,2021(5):59-66.
WANG Yue, BAI Jianbo, LI Jian. Refined hourly modeling method of pv power generation system and analysis of application cases[J]. Solar Energy, 2021(5):59-66.
- [3] 何知衡,杨雯,刘加平. 低纬度海岛太阳能建筑逆热工设计方法[J]. 西安工程大学学报,2024,38(5):70-76.
HE Zhiheng, YANG Wen, LIU Jiaping. Reverse thermal design method for solar buildings on low-latitude islands[J]. Journal of Xi'an Polytechnic University, 2024, 38(5):70-76.
- [4] 董辉,楚帅,葛维春,等.“源-储-荷”多运行域协调控制提升清洁能源消纳能力策略[J]. 电测与仪表,2024,61(5):119-125.
DONG Hui, CHU Shuai, GE Weichun, et al. Strategy of 'source-storage-load' multi-operating domain coordinated control enhancing clean energy consumption capacity[J]. Electrical Measurement & Instrumentation, 2024, 61(5):119-125.
- [5] 蔡阳,黄若楠,何建炜,等.机械辅助式太阳能光催化复合通风室内污染净化分析[J]. 西安工程大学学报,2025,39(1):72-80.
CAI Yang, HUANG Ruonan, HE Jianwei, et al. Purification analysis of indoor air pollutants by mechanical ventilation-assisted solar photocatalytic natural ventilation[J]. Journal of Xi'an Polytechnic University, 2025, 39(1):72-80.
- [6] 刘雅慧,闫伟超,崔鑫,等.太阳能光伏蒸发冷却通风空腔的实验研究[J]. 西安工程大学学报,2024,38(5):28-35.
LIU Yahui, YAN Weichao, CUI Xin, et al. Experimental study of solar photovoltaic evaporative cooling ventilated cavity[J]. Journal of Xi'an Polytechnic University, 2024, 38(5):28-35.
- [7] 周晓华,冯雨辰,胡旭初,等.基于秃鹰搜索算法优化SVM的变压器故障诊断[J]. 南方电网技术,2023,17(6):99-106.
ZHOU Xiaohua, FENG Yuchen, HU Xuchu, et al. Transformer fault diagnosis based on SVM optimized by bald eagle search algorithm[J]. Southern Power System Technology, 2023, 17(6):99-106.
- [8] 刘智宇,郝冬,张妍懿,等.基于GA-ELM算法的燃料电池性能预测模型[J]. 电池,2023,53(3):243-247.
LIU Zhiyu, HAO Dong, ZHANG Yanyi, et al. Fuel cell performance prediction model based on GA-ELM algorithm[J]. Battery Bimonthly, 2023, 53(3):243-247.
- [9] 白雲杰,贾希胜,梁庆海,等.基于PCA-EDT-CNN的柴油发动机故障诊断方法[J]. 机械强度,2022,44(6):1271-1278.
BAI Yunjie, JIA Xisheng, LIANG Qinghai, et al. Fault diagnosis method of diesel engine based on PCA-EDT-CNN[J]. Journal of Mechanical Strength, 2022, 44(6):1271-1278.
- [10] 石怀涛,李宇宁,赵金宝,等.基于压缩采集特征提取与CNN-SVM的滚动轴承的故障诊断[J]. 沈阳建筑大学学报(自然科学版),2022,38(6):1129-1137.
SHI Huaitao, LI Yuning, ZHAO Jinbao, et al. Rolling bearing fault diagnosis method based on the compressed sampling feature extraction and CNN-SVM[J]. Journal of Shenyang Jianzhu University(Natural Science), 2022, 38(6):1129-1137.
- [11] 王燕,梁琦.快速3D-CNN结合深度可分离卷积对高光谱图像分类[J]. 计算机科学与探索,2022,16(12):2860-2869.
WANG Yan, LIANG Qi. Fast 3D-CNN combined with depth separable convolution for hyperspectral image classification[J]. Journal of Frontiers of Computer Science & Technology, 2022, 16(12):2860-2869.
- [12] 徐少平,林珍玉,陈孝国,等.采用多通道浅层CNN构建的多降噪器最优组合模型[J]. 自动化学报,2022,48(11):2797-2811.
XU Shaoping, LIN Zhenyu, CHEN Xiaoguo, et al. Optimal combination of image denoisers using multi-channel shallow convolutional neural network[J]. Acta Automatica Sinica, 2022, 48(11):2797-2811.
- [13] 田斌,葛友铖,梁冰,等.基于CNN-LSTM混合模型的工频磁扰动信号预测[J]. 自动化与仪表,2021,36(11):11-14.
TIAN Bin, GE Youcheng, LIANG Bing, et al. Power frequency magnetic disturbance signal prediction based on CNN-LSTM hybrid model[J]. Automation & Instrumentation, 2021, 36(11):11-14.
- [14] 曾亮,狄飞超,兰欣,等.基于CEEMD-CNN-BiGRU-RF模型的短期风电功率预测[J]. 可再生能源,2022,40(2):190-195.
ZENG Liang, DI Feichao, LAN Xin, et al. Short-term wind power prediction based on CEEMD-CNN-BiGRU-RF model[J]. Renewable Energy Resources, 2022, 40(2):190-195.
- [15] 王琦,邓林峰,赵荣珍.基于改进一维卷积神经网络的滚动轴承故障识别[J]. 振动与冲击,2022,41(3):216-223.

- WANG Qi, DENG Linfeng, ZHAO Rongzhen. Fault recognition of rolling bearing based on improved 1D convolutional neural network [J]. *Journal of Vibration and Shock*, 2022, 41(3):216-223.
- [16] 黄悦华, 张子豪, 陈庆, 等. 基于多头注意力机制的 CNN-BiLSTM 高海拔多因素输电线路可听噪声预测[J]. *高压电器*, 2024, 60(12):160-169.
- HUANG Yuehua, ZHANG Zihao, CHEN Qing, et al. Prediction of audible noise of CNN - BiLSTM high altitude multifactor transmission lines based on multi head attention mechanism[J]. *High voltage Apparatus*, 2024, 60(12):160-169.
- [17] 张天骐, 邹涵, 杨宗方, 等. 基于 CNN-LSTM 的 MIMO-OFDM 信号盲调制识别算法[J]. *信号处理*, 2024, 40(4):747-756.
- ZHANG Tianqi, ZOU Han, YANG Zongfang, et al. Blind modulation recognition algorithm for MIMO-OFDM signal based on CNN-LSTM[J]. *Journal of Signal Processing*, 2024, 40(4):747-756.
- [18] 吴家葆, 曾国辉, 张振华, 等. 基于 K-means 分层聚类的 TCN-GRU 和 LSTM 动态组合光伏短期功率预测[J]. *可再生能源*, 2023, 41(8):1015-1022.
- WU Jiabao, ZENG Guohui, ZHANG Zhenhua, et al. Dynamic combination of TCN - GRU and LSTM photovoltaic short - term power prediction based on K - means hierarchical clustering[J]. *Renewable Energy Resources*, 2023, 41(8):1015-1022.
- [19] 崔杨, 朱晗, 王议坚, 等. 基于 CNN-SAEDN-Res 的短期电力负荷预测方法[J]. *电力自动化设备*, 2024, 44(4):164-170.
- CUI Yang, ZHU Han, WANG Yijian, et al. Short-term power load forecasting method based on CNN-SAEDN-Res[J]. *Electric Power Automation Equipment*, 2024, 44(4):164-170.
- [20] 岳有军, 吴明沅, 王红君, 等. 基于 CNN-GRU-ISSA-XGBoost 的短期光伏功率预测[J]. *南京信息工程大学学报*, 2024, 16(2):231-238.
- YUE Youjun, WU Mingyuan, WANG Hongjun, et al. Short term photovoltaic power prediction based on CNN-GRU-ISSA-XGBoost [J]. *Journal of Nanjing University of Information Science & Technology*, 2024, 16(2):231-238.
- [21] 石庆兰, 束金阳, 李道亮, 等. 基于 BiLSTM-GRU 融合网络的稻虾养殖溶解氧含量预测[J]. *农业机械学报*, 2023, 54(10):364-370.
- SHI Qinglan, SHU Jinyang, LI Daoliang, et al. Dissolved oxygen prediction in rice and shrimp culture based on BiLSTM - GRU fusion neural networks[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(10):364-370.
- [22] 李志刚, 张鑫. CNN-GRU 模型预测高炉煤气产生量[J]. *机械设计与制造*, 2022, 374(4):69-72.
- LI Zhigang, ZHANG Xin. CNN-GRU model predicts blast furnace gas production[J]. *Machinery Design & Manufacture*, 2022, 374(4):69-72.
- [23] 门嘉铨, 樊玉光, 高琳, 等. EMD-Attention-GRU 天然气管网流量组合预测模型[J]. *油气储运*, 2023, 42(10):1193-1200.
- MEN Jiacheng, FAN Yuguang, GAO Lin, et al. Combined flow prediction model for natural gas pipeline network based on EMD-Attention-GRU[J]. *Oil & Gas Storage and Transportation*, 2023, 42(10):1193-1200.
- [24] 郭士杰, 卢世杰, 耿艳利, 等. 融合 VIT 与 CNN 注意力机制的面部疼痛评估算法研究[J]. *计算机工程与应用*, 2024, 60(15):277-283.
- GUO Shijie, LU Shijie, GENG Yanli, et al. Facial pain assessment algorithm fusing VIT and CNN attention mechanism[J]. *Computer Engineering and Applications*, 2024, 60(15):277-283.
- [25] 彭瑾坤, 武文华, 顾乃建, 等. 基于 CNN 的卫星内部结构频域响应间接测量方法[J]. *航天器环境工程*, 2023, 40(4):400-407.
- PENG Jinkun, WU Wenhua, GU Naijian, et al. An indirect method for measuring frequency domain response of satellite internal structure based on convolutional neural network[J]. *Spacecraft Environment Engineering*, 2023, 40(4):400-407.
- [26] 王崧瑶, 张智晟. 基于量子加权 GRU 神经网络的电力系统短期负荷预测[J]. *电力系统及其自动化学报*, 2022, 34(1):1-7.
- WANG Songyao, ZHANG Zhisheng. Short-term load forecasting of power systems based on quantum weighted GRU neural network[J]. *Proceedings of the CSU-EPSA*, 2022, 34(1):1-7.
- [27] 冯裕祺, 李辉, 李利娟, 等. 基于 CNN-GRU 的光伏电站电压轨迹预测[J]. *中国电力*, 2022, 55(7):163-171.
- FENG Yuqi, LI Hui, LI Lijuan, et al. Voltage trajectory prediction of photovoltaic power station based on CNN - GRU[J]. *Electric Power*, 2022, 55(7):163-171.
- [28] 马立玲, 郭建, 汪首坤, 等. 基于改进 CNN-GRU 网络的多源传感器故障诊断方法[J]. *北京理工大学学报*, 2021, 41(12):1245-1252.
- MA Liling, GUO Jian, WANG Shoukun, et al. Multi-source sensor fault diagnosis method based on improved CNN - GRU network[J]. *Transactions of Beijing Institute of Technology*, 2021, 41(12):1245-1252.
- [29] 周璨, 杨栋, 魏松杰. 融合 GRU 和 CNN 的轻量级网络入侵检测模型[J]. *计算机系统应用*, 2023, 32(8):162-170.
- ZHOU Can, YANG Dong, WEI Songjie. Integrating GRU and CNN for light - weighted model in network intrusion detection[J]. *Computer Systems & Applications*, 2023, 32(8):162-170.
- [30] 昌千琳, 罗永捷, 王强钢, 等. 基于 I - V 曲线全局特征提取的光伏组串 Swin-Transformer 故障诊断方法[J]. *电工技术学报*, 2025, 40(23):7664-7676.
- CHANG Qianlin, LUO Yongjie, WANG Qianggang, et al. Fault diagnosis method for photovoltaic string based on global I - V curve feature extraction using swin transformer[J]. *Transactions of China Electrotechnical Society*, 2025, 40(23):7664-7676.
- [31] 张安安, 谢琳悒, 杨威. 基于 CNN-GRU 组合神经网络的锂电池寿命预测模型研究[J]. *电测与仪表*, 2025, 62(7):77-84.
- ZHANG An'an, XIE Linxing, YANG Wei. Research on lithium battery life prediction model based on CNN-GRU combined neural network[J]. *Electrical Measurement & Instrumentation*, 2025, 62(7):77-84.
- 卢万杰(1979—), 女, 博士, 副教授, 研究方向为人工智能控制、设备故障诊断(通信作者)(E-mail: luwanjie0912@126.com)。
- 马馨(1999—), 男, 硕士研究生, 研究方向为电力系统故障诊断(E-mail: 1326309303@qq.com)。