

DOI:10.13364/j.issn.1672-6510.20220119

基于改进 CNN 和 BiGRU 双通道特征融合的 风电机组故障诊断模型

张李炜, 李孝忠

(天津科技大学人工智能学院, 天津 300457)

摘要: 针对风电机组的故障诊断问题, 提出一种基于改进卷积神经网络(convolutional neural network, CNN)和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)双通道特征融合的风电机组故障诊断模型, 该模型有别于传统的串联式结构, 采取了并联式结构将改进的 CNN 和 BiGRU 进行结合. 首先, 利用批量归一化(batch normalization, BN)层代替传统 CNN 中的 Dropout 层, CNN 作为第 1 个通道提取特征; 其次, 给传统 BiGRU 添加 1 个多层感知机神经网络, BiGRU 作为第 2 个通道提取特征; 最后, 通过识别层的特征融合层将两通道连接起来, 利用支持向量机代替传统的 Softmax 层进行故障分类. 实验结果表明, 相较于其他模型, 该模型的准确率更高, 整体效果更好.

关键词: 卷积神经网络; 双向门控循环单元; SCADA 数据; 故障诊断

中图分类号: TP391 **文献标志码:** A **文章编号:** 1672-6510(2023)01-0055-06

Wind Turbine Fault Diagnosis Model Based on Improved CNN and BiGRU Dual Channel Feature Fusion

ZHANG Liwei, LI Xiaozhong

(College of Artificial Intelligence, Tianjin University of Science & Technology, Tianjin 300457, China)

Abstract: Aiming at the problem of wind turbine fault diagnosis, a wind turbine fault diagnosis model based on dual channel feature fusion of improved convolutional neural network(CNN)and bidirectional gated recurrent unit(BiGRU)is proposed in our study. The model is different from the traditional series structure and adopts a parallel structure to combine the improved CNN and BiGRU. Firstly, the batch normalization layer is used to replace the Dropout layer in the traditional CNN, and CNN is used as the first channel to extract features. Secondly, a multi-layer perceptron is added to the traditional BiGRU, and BiGRU is used as the second channel to extract features. Finally, the two channels are connected through the feature fusion layer of the recognition layer, and then the support vector machine is used to replace the traditional Softmax layer for fault classification. The results of the experiments show that compared with other models, this model has higher accuracy and better overall effect.

Key words: convolutional neural network(CNN); bidirectional gated recurrent unit(BiGRU); SCADA data; fault diagnosis

随着世界各国对可再生能源的积极发展, 可再生能源已然成为应用能源的重要组成部分^[1]. 风能作为一种无污染的可再生能源, 具有非常大的发展潜力, 因此, 全球范围内的风电装机容量都在持续增长. 然而, 大部分风电场位于环境恶劣的山区或者沿海地

区, 尤其在沿海地区, 海陆温差大, 风速变化大, 工况变化频繁, 极易导致风电机组发生故障. 完善机组的故障诊断工作能有效维护风电机组的正常运行, 减少经济损失, 促进风能产业的发展^[2].

风电机组的传统故障诊断方法是基于严格的数

收稿日期: 2022-05-10; 修回日期: 2022-08-01

作者简介: 张李炜(1998—), 男, 江苏人, 硕士研究生; 通信作者: 李孝忠, 教授, lixz@tust.edu.cn

学和物理模型的方法,但随着风电机组规模越来越大,设备越来越复杂,很难构建其合适的物理模型.随着传感器、人工智能和深度学习等技术的发展,基于数据驱动的故障诊断技术也逐步得到重视^[3].但是,风电机组监测数据过于复杂,难以提取丰富的特征,导致故障诊断模型的精度不高.目前,国内外风电机组的故障诊断是通过各种方法提高诊断精度,神经网络则是其中研究较多的一种方法.徐健^[4]通过设计一个具有3组卷积-池化层和两层全连接层的深度卷积神经网络(convolutional neural network, CNN)模型,并结合振动信号检测、信号变换实现对风电机组中轴承故障的智能诊断.虽然CNN善于提取空间维度上的特征信息,但是风电机组数据是时序数据,在时间维度上也同样蕴含丰富的特征信息.Kisvari等^[5]系统地提出了一种基于门控循环单元(gated recurrent unit, GRU)深度学习模型的数据预处理与再采样、异常检测与处理、超参数调优等方法,为风力发电预测提出了一种新的数据驱动方法,并对GRU与长短时记忆(long short-term memory, LSTM)网络进行了批判性比较;但是,没有意识到门控循环神经网络在提取空间维度信息能力上表现欠佳.Xiang等^[6]提出了一种基于CNN和改进GRU的级联神经网络模型,从时间和空间两个维度提取监控与数据采集系统(supervisory control and data acquisition, SCADA)的数据用于风电机组的状态检测.但是作为单通道结构,经过CNN卷积后的信息难免会丢失一些时序特征,即使将GRU进行了改进以及添加了注意力机制,提取的时序特征也没有从原信息中得到充分提取.

本研究将双通道结构运用到风电机组故障诊断领域,提出了一种改进的卷积神经网络(CNN)和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)双通道特征融合的风电机组故障诊断模型.在CNN中,采用批量归一化(batch normalization, BN)层替换传统CNN中的Dropout层;在BiGRU中,在其网络层后添加1个多层感知机网络.采取并联式结构,即原数据分别进入CNN和BiGRU两个通道,同时提取风电机组的故障特征,然后两通道提取的特征进入识别层进行特征融合,最后使用支持向量机(support vector machine, SVM)进行分类,采用爱尔兰某地区风电场的SCADA数据进行实验,旨在研究本文模型的可行性和实用性.

1 基础理论

1.1 卷积神经网络

卷积神经网络是一种具有深度神经网络结构且其中包含卷积运算的前馈神经网络,主要由输入层、隐藏层、全连接层和输出层组成,其中最重要的隐藏层主要由卷积层、激活层和池化层组成^[7].

卷积层是CNN具有表征学习能力的关键所在.该层通过卷积操作对输入数据进行特征提取,从而获得不同的表征特征.卷积运算公式可表示为

$$y_j^l = \sum_{i \in M} x_i^{l-1} * w_{ij}^l \quad (1)$$

其中: y_j^l 表示第 l 层第 j 个输出特征图, M 表示所有输入特征图的集合, x_i^{l-1} 表示第 $l-1$ 层第 i 个输入特征图,*表示卷积操作, w_{ij}^l 表示卷积核.

激活层将卷积层的输出进行非线性映射.输出可表示为

$$x_j^l = g(y_j^{l-1} + b_j) \quad (2)$$

其中: $g()$ 表示激活函数, b 表示偏置.

池化层将激活层的输出进行池化操作,即一种降采样操作;主要目的是降低特征面的分辨率,保留有用信息,从而减少冗余的参数和特征.输出可表示为

$$x_j^l = p(x_j^{l-1}) \quad (3)$$

其中 $p()$ 表示池化函数^[8-9].

1.2 门控循环单元

门控循环单元是循环神经网络(recurrent neural network, RNN)的一种.RNN在处理时间序列的数据上有很好的效果,但随着数据量的增大,RNN面临着梯度爆炸或者消失的缺陷^[10].LSTM则是针对这一缺陷而改进的RNN^[11].而GRU与LSTM相似,在达到与LSTM相当的效果下,减少了参数量,提高了训练效率^[12].GRU内部结构的计算公式为

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (4)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (5)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t]) \quad (6)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (7)$$

其中: h_{t-1} 为上一时刻的状态值; x_t 为当前时刻的输入值; r_t 和 z_t 分别为重置门和更新门,通过 h_{t-1} 和 x_t 获取两个门控状态; \tilde{h}_t 为当前时刻节点的即时信息,首先通过重置门 r_t 对 h_{t-1} 进行重置,再与 x_t 进行拼接,

最后通过 \tanh 激活函数得到 \tilde{h}_t ; h_t 为当前单元的输出值,通过更新门 z_t 实现了遗忘和记忆两个步骤; W_r 、 W_z 和 W_h 表示参数矩阵; σ 表示 sigmoid 激活函数. GRU 内部结构示意图见图 1.




图 1 GRU 内部结构示意图

Fig. 1 Internal structure diagram of GRU

GRU 虽然擅长提取长序列信息,但是它是单向从前往后提取,不考虑从后往前的信息之间的序列联系. BiGRU 正好解决了这一问题^[13-14],通过连接两个定向的独立 GRU,分别处理来自两个方向的信息.

1.3 支持向量机

支持向量机是在统计学基础上发展起来的具有完善数学理论支撑的二分类模型^[15-16]. 它的目的是寻找一个超平面分割样本,并使分割的样本间隔最大化. 超平面的线性方程表示为

$$w^T x + b = 0 \quad (8)$$

其中: $w = (w_1; w_2; \dots; w_d)$ 为法向量,决定了其方向; b 为位移,决定了其与原点之间的距离. 最大间隔就是找到约束参数 w 和 b ,使得间隔最大,即

$$\max_{w,b} \frac{2}{\|w\|}, \text{ s.t. } y_i (w^T x_i + b) \geq 1, i = 1, 2, \dots, m \quad (9)$$

2 本文模型设计

2.1 改进 CNN

在 CNN 训练时,通常先将数据归一化再输入模型进行训练,原因是输入的不同特征值具有不同的分布,即不同特征之间数值差异较大,归一化处理可避免后面的模型训练产生较大的偏离. 深度神经网络的训练过程十分复杂,虽然数据在最开始已经归一化,但是随着数据一层层地输入和输出,也不可避免地会对数据的分布产生改变. 如果不加以修正,数据分布的差异会随着下层网络进一步扩大,最终减缓训练速度,影响模型精度. 这种现象也称为内部协变量偏移^[17]. 本文采用 BN 层^[18]避免这种现象.

在深度神经网络训练过程中,通常会采用

Dropout 层避免出现过拟合现象,而 Dropout 层的处理方法也很直接、简单,即按比例将隐藏层的一部分神经元直接置零,从而避免从过多的神经元中提取重复的特征. 不恰当的比例设定无疑会使训练效果大打折扣. 在使用 BN 层之后,数据进行了归一化,原本通过激活函数没有影响的神经元分布也变得效果明显,所以在通过一个激活函数后,神经元会自动去除或者削弱一些神经元,达到了使用 Dropout 层的效果. 所以,本文用 BN 层代替了 Dropout 层.

2.2 改进 BiGRU

在 BiGRU 模型中,通常在经过 BiGRU 层之后加入 1 层线性层,便于将 BiGRU 的输出值维度线性变换成损失函数的输入值维度. 本文研究的故障诊断为二分类故障诊断,损失函数的输入值维度较低,而 BiGRU 的输出值维度较高,特征较多,不利于损失函数的计算,所以本文在 BiGRU 层之后添加了 1 个 4 层线性层的多层感知机网络,用于提取 BiGRU 的输出值,提高该模型的精度.

2.3 双通道特征融合模型

该模型由 CNN 通道层、BiGRU 通道层和识别层 3 部分组成. CNN 通道层由 2 层卷积层、2 层 BN 层、2 层池化层和 1 个全连接层组成; BiGRU 通道层由 BiGRU 单元和 1 个多层感知机网络组成; 识别层由 1 个特征融合层和 1 个分类层组成. CNN 通道层通过逐层的卷积池化提取 SCADA 数据上空间维度的特征; BiGRU 通道层通过 2 个 GRU 单元提取 2 个方向上时间维度的数据特征; 识别层通过特征融合层将 CNN 通道层和 BiGRU 通道层的特征进行融合. 与传统的 Softmax 层相比, SVM 在小样本条件下具有更好的分类效果和鲁棒性^[19],也更加适合本文研究的二分类故障诊断,所以在分类层用 SVM 代替 Softmax 层对特征进行分类. 具体结构如图 2 所示.

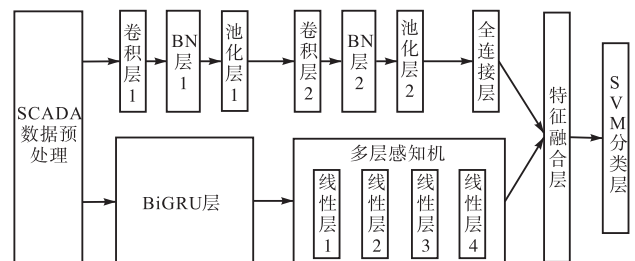


图 2 改进 CNN 和 BiGRU 双通道特征融合的故障诊断结构图

Fig. 2 Structure diagram of fault diagnosis of improved CNN and BiGRU dual channel feature fusion

3 实验

3.1 数据集

实验环节采用的数据为爱尔兰某地区风力发电场 2014 年 5 月 1 日至 2015 年 4 月 9 日的 SCADA 数据, 包括 49 028 条机组的运营数据(每条数据有 63 个特征信息)、27 398 条风能转换器和 1 850 条远程终端单元的状态数据. 风能转换器的状态数据为与机组本身状态直接相关的数据, 远程终端单元的状态数据为机组与电网之间的功率控制数据. 该数据集包含了正常工况下和异常情况下的运行数据. 本文分别针对交流器馈电和发电机励磁两种故障进行诊断, 下文简称故障 A 与故障 B.

3.2 数据预处理与参数选择

对原始的 SCADA 数据进行预处理, 将一些不合理的、可能会影响模型精度的数据进行剔除, 例如停机维护或者保养过程中产生的无效数据、在传感器传输过程中产生的异常数据等. 将预处理后的数据结合状态数据对机组进行故障类型标记.

根据靳志杰等^[20]的经验, 选取运营数据 63 个特征中的 27 个特征作为本文的研究数据, 具体特征见表 1. 改进的 CNN 中, 根据 27 个特征, 将第 1 个卷积层的卷积核设为 10×10 , 卷积核数量为 64 个; 将第 2 个卷积层的卷积核设为 17×17 , 卷积核数量为 128 个; 卷积层激活函数均为 ReLU 函数. 改进的 BiGRU 中, 隐层神经元为 4 个, 激活函数为 tanh 函数; 多层感知机网络层由 4 层 64 个神经元的线性层组成. 具体参数见表 2.

表 1 选取的特征

Tab. 1 Selected features

序号	具体特征	序号	具体特征
1	1号转子温度	15	控制柜温度
2	2号转子温度	16	变压器温度
3	1号定子温度	17	整流柜温度
4	2号定子温度	18	变流器柜风扇温度
5	变桨柜叶片 A 温度	19	前轴承温度
6	变桨柜叶片 B 温度	20	后轴承温度
7	变桨柜叶片 C 温度	21	机舱机柜温度
8	1号机舱环境温度	22	偏航逆变器机柜温度
9	2号机舱环境温度	23	桨距角
10	环境温度	24	平均风速
11	轮毂温度	25	转速
12	塔筒温度	26	有功功率
13	机舱温度	27	无功功率

表 2 模型参数

Tab. 2 Model parameter

编号	网络层	神经元	卷积核	激活函数	Dropout
1	卷积层 1	64	10×10	ReLU	—
2	BN 层 1	64	—	—	—
3	池化层 1	—	1×1	—	—
4	卷积层 2	128	17×17	ReLU	—
5	BN 层 2	128	—	—	—
6	池化层 2	—	2×2	—	—
7	全连接层	64×4	—	ReLU	0.5
8	BiGRU 层	4	—	tanh	—
9	多层感知机	64×4	—	ReLU	0.5

3.3 BN 层与 Dropout 层消融实验

BN 层替代 Dropout 层在计算机视觉的 CNN 中较为常见, 但大多数为二维 CNN, 而本文使用的是一维 CNN, 其中加入 BN 层替代 Dropout 层, 在风电机组故障诊断领域中较为少见, 所以进行了 BN 层与 Dropout 层的消融实验, 实验结果见表 3. 在 Dropout 层的 drop 值设为 0 和 0.5 时, 评价指标相差不大; 在分别加上 BN 层后, drop 值为 0.5 时, 在精确率上稍有提升, 而 drop 值为 0 时, 准确率与精确率有较大提升, 所以本文在 CNN 模型中使用 BN 层替代 Dropout 层.

表 3 BN 层与 Dropout 层消融实验

Tab. 3 Ablation experiment of BN layer and Dropout layer

类型	准确率	精确率	召回率	F_1 值
drop = 0.5	0.92	0.71	0.99	0.83
drop = 0	0.91	0.70	0.98	0.82
drop = 0.5 + BN	0.92	0.73	1.00	0.84
drop = 0 + BN	0.95	0.80	1.00	0.89

3.4 模型训练停止条件

正常神经网络模型训练时都是在模型损失函数的参数 Loss 值不再下降时认为该模型已经收敛, 模型训练则可以停止了. 但是, 本文在进行模型训练时发现, CNN 网络的 Loss 值下降很快, 很容易达到收敛; GRU 网络的 Loss 值下降很缓慢, 在训练次数 (epochs) 很多时才能收敛; 而且模型并不是在收敛时精确率最高, 说明已经出现了一定程度的过拟合. 因此, 本文采取早停技术避免过拟合, 提高训练效率. 针对故障 A 和故障 B, 分别对改进的 CNN 和 BiGRU 在收敛值附近采取 9 个 Loss 值上限, 使用准确率、精确率、召回率和 F_1 值作为评价指标, 结果如图 3—图 6 所示.

由图 3 可知: 故障 A 在改进的 CNN 中, 准确率在 Loss 值为 0.030 之后趋于平稳, 但精确率与 F_1 值在 Loss 值为 0.030 和 0.029 处达到最高, 之后开始下

降,整体的召回率除了 Loss 值为 0.032 处较低,其他均接近 1. 在考虑训练效率之后,故障 A 在改进的 CNN 中选择 0.030 为 Loss 值的上限.




图3 故障A在改进的CNN中Loss值的评价指标

Fig. 3 Evaluation indicator of Loss in fault A in improved CNN

由图4可知:故障A在改进的BiGRU中,准确率和召回率整体趋于平稳,精确率与F₁值在Loss值为0.050时达到最高,所以故障A在改进的BiGRU中选择0.050为Loss值的上限.




图4 故障A在改进的BiGRU中Loss值的评价指标

Fig. 4 Evaluation indicator of Loss in fault A in improved BiGRU




图5 故障B在改进的CNN中Loss值的评价指标

Fig. 5 Evaluation indicator of Loss in fault B in improved CNN

由图5可知:故障B在改进的CNN中,准确率整体趋于平稳,精确率在Loss值为0.027处达到最高,但其召回率远低于其他值,所以不考虑该值.精

确率第二高在Loss值为0.030处,其召回率和F₁值相较于前后值均为最高;所以故障B在改进的CNN中选择0.030为Loss值的上限.




图6 故障B在改进的BiGRU中Loss值的评价指标

Fig. 6 Evaluation indicator of Loss in fault B in improved BiGRU

由图6可知:故障B在改进的BiGRU中,准确率和召回率整体趋于平稳,精确率与F₁值在Loss值为0.036和0.034处达到最高.在考虑训练效率之后,故障A在改进的BiGRU中选择0.036为Loss值的上限.

3.5 模型诊断

根据3.4节Loss值的上限选择每个模型最优的训练次数;测试样本与训练样本划分比例为2:8;将神经网络输出的特征向量通过线性层转换成与样本标签一样的维度,通过MSELoss损失函数计算两者之间的Loss值;然后采用Adam优化器进行优化;SVM的目标函数为式(8)所示超平面的线性方程;Sklearn库中SVM的惩罚系数采用网格搜索与交叉验证方法从1、10、100这3个系数中选择最优的系数,参数项kernel为linear;硬件方面,均在NVIDIA的Tesla K80显卡上进行训练和测试.针对故障A和故障B分别对改进的CNN和BiGRU进行训练,然后进入双通道CNN-BiGRU进行故障诊断,最终与原CNN、原BiGRU和单通道CNN-BiGRU进行对比.除了上述4个评价指标,再添加1个耗时指标(以秒为单位),结果见表4.

在故障A中,改进的CNN相较于原CNN,在准确率、精确率和F₁值上有了较大的提高,训练时间缩短,说明BN层在CNN上有着较好的效果.改进的BiGRU相较于原BiGRU的提升幅度较小,在准确率、精确率和F₁值上只有小幅度的提升,毕竟在没有改进BiGRU内部网络结构的基础上,只在后面添加1个多层感知神经网络进一步提取特征.单通道CNN-BiGRU由改进的CNN结合BiGRU串联结构组成,

相较于改进的 CNN, 仅在精确率和 F_1 值上有一定的提高, 但训练时长增加明显. 而本文提出的双通道

CNN-BiGRU 的准确率、精确率、召回率和 F_1 值均为最高, 仅在耗时上相较于其他模型较长.

表 4 故障诊断结果

Tab. 4 Results of fault diagnosis

故障类型	模型算法	准确率	精确率	召回率	F_1 值	耗时/s
故障 A	原 CNN	0.92	0.71	0.99	0.83	416
	原 BiGRU	0.90	0.68	0.99	0.81	1 508
	改进的 CNN	0.95	0.80	1.00	0.89	383
	改进的 BiGRU	0.92	0.74	0.97	0.84	1 010
	单通道 CNN-BiGRU	0.95	0.82	0.99	0.90	1 012
	双通道 CNN-BiGRU	0.96	0.83	1.00	0.90	1 435
故障 B	原 CNN	0.93	0.73	1.00	0.85	523
	原 BiGRU	0.92	0.72	1.00	0.84	737
	改进的 CNN	0.94	0.79	0.95	0.86	252
	改进的 BiGRU	0.94	0.77	0.99	0.87	1 119
	单通道 CNN-BiGRU	0.94	0.80	0.94	0.87	2 492
	双通道 CNN-BiGRU	0.95	0.81	0.96	0.88	1 476

在故障 B 中, 改进的 CNN 和 BiGRU 相较于原模型均有一定程度的提高. 单通道 CNN-BiGRU 在准确率上略有提高, 但训练时长大幅增长, 提升效果不大. 而双通道 CNN-BiGRU 的准确率、精确率和 F_1 值均为最高, 仅在召回率上稍低于其他模型.

4 结 语

本文提出了一种基于改进 CNN 和 BiGRU 双通道特征融合的风电机组故障诊断模型, 分别对传统的 CNN 和 BiGRU 进行改进, 采取有别于传统串联式结构的并联式结构, 将两个改进后的模型作为两个通道分别对 SCADA 数据进行特征提取, 然后通过识别层的特征融合层将两通道提取的数据进行融合, 最后通过识别层的 SVM 进行分类, 实现风电机组的故障诊断. 但是, 本文模型是针对风电机组中的某一故障进行诊断, 风电机组可能同时发生多个故障, 所以后续工作还需要针对多故障情况进行研究.

参考文献:

- [1] 叶祎旒, 李艳婷. 基于 CNN-集成学习的多风电机组故障诊断[J]. 工业工程, 2022, 25(1): 136-143.
- [2] KONG Z, TANG B, DENG L, et al. Condition monitoring of wind turbines based on spatio-temporal fusion of SCADA data by convolutional neural networks and gated recurrent units[J]. Renewable energy, 2020, 146: 760-768.
- [3] PANG Y, HE Q, JIANG G, et al. Spatio-temporal fusion neural network for multi-class fault diagnosis of wind turbines based on SCADA data[J]. Renewable energy, 2020, 161: 510-524.
- [4] 徐健. 基于卷积神经网络的风电机组轴承故障诊断方法研究[D]. 杭州: 浙江大学, 2020.
- [5] KISVARI A, LIN Z, LIU X. Wind power forecasting: a data-driven method along with gated recurrent neural network[J]. Renewable energy, 2021, 163: 1895-1909.
- [6] XIANG L, YANG X, HU A, et al. Condition monitoring and anomaly detection of wind turbine based on cascaded and bidirectional deep learning networks[J]. Applied energy, 2022, 305: 117925.
- [7] 吴春志, 江鹏程, 冯辅周, 等. 基于一维卷积神经网络的齿轮箱故障诊断[J]. 振动与冲击, 2018, 37(22): 51-56.
- [8] YAO D, LI B, LIU H, et al. Remaining useful life prediction of roller bearings based on improved 1D-CNN and simple recurrent unit[J]. Measurement, 2021, 175: 109166.
- [9] 张龙, 徐天鹏, 王朝兵, 等. 基于卷积门控循环网络的齿轮箱故障诊断[J]. 吉林大学学报(工学版), 2022, 52(2): 368-376.
- [10] 薛阳, 王琳, 王舒, 等. 一种结合 CNN 和 GRU 网络的超短期风电预测模型[J]. 可再生能源, 2019, 37(3): 456-462.
- [11] XIANG L, WANG P, YANG X, et al. Fault detection of wind turbine based on SCADA data analysis using CNN and LSTM with attention mechanism[J]. Measurement, 2021, 175: 109094.
- [12] 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.

(下转第 69 页)

- IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2017: 1251–1258.
- [20] LIN Y, ZHENG L, ZHENG Z, et al. Improving person re-identification by attribute and identity learning[J]. Pattern recognition, 2019, 95: 151–161.
- [21] AGRAWAL R, SRIKANT R. Fast algorithms for mining association rules[C]//Proceedings of the 20th International Conference on Very Large Data Bases. San Francisco: Morgan Kaufmann Publishers Inc., 1994, 1215: 487–499.
- [22] 柴岩, 张京辉, 鲁新新. 最小支持度为区间值的加权 Apriori 算法[J]. 辽宁工程技术大学学报(自然科学版), 2016, 35(12): 1512–1516.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 770–778.
- [24] SARFRAZ M S, SCHUMANN A, WANG Y, et al. Deep view-sensitive pedestrian attribute inference in an end-to-end model[EB/OL]. [2022-04-01]. <http://arxiv.org/abs/1707.06089v1>.
- [25] JI Z, HE E, WANG H, et al. Image-attribute reciprocally guided attention network for pedestrian attribute recognition[J]. Pattern recognition letters, 2019, 120: 89–95.
- [26] 李娜, 武阳阳, 刘颖, 等. 基于多尺度注意力网络的行人属性识别算法[J]. 激光与光电子学进展, 2021, 58(4): 290–296.
- [27] 王林, 李聪会. 基于多级注意力跳跃连接网络的行人属性识别[J]. 计算机工程, 2021, 47(2): 314–320.
- [28] 张再腾, 张荣芬, 刘宇红. 基于多尺度残差注意网络的轻量级行人属性识别算法[J/OL]. 控制与决策: 1–10[2022-04-01]. DOI:10.13195/j.kzyjc.2021.0411.

责任编辑: 郎婧

(上接第 60 页)

- [13] 王朋鹤. 基于双向门控循环神经网络的风电机组状态检测[D]. 保定: 华北电力大学, 2021.
- [14] 杨云, 丁磊, 张昊宇. 改进一维卷积神经网络与双向门控循环单元的轴承故障诊断研究[J/OL]. 机械科学与技术: 1–8[2022-04-11]. DOI:10.13433/j.cnki.1003-8728.20200638.
- [15] 沈艳霞, 周文晶, 纪志成, 等. 基于小波包与 SVM 的风电变频器故障诊断[J]. 太阳能学报, 2015, 36(4): 785–791.
- [16] 朱永超, 朱才朝, 宋朝省, 等. PCA-PSO/GS-SVM 组合方法在风电齿轮箱故障预测中的应用研究[J]. 太阳能学报, 2021, 42(3): 35–42.
- [17] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[J]. Journal of machine learning research, 2015, 37: 448–456.
- [18] 刘秀丽, 徐小力. 基于深度信念网络的风电机组齿轮箱故障诊断方法[J]. 可再生能源, 2017, 35(12): 1862–1868.
- [19] SUN W, ZHAO R, YAN R, et al. Convolutional discriminative feature learning for induction motor fault diagnosis[J]. IEEE Transactions on industrial informatics, 2017, 13(3): 1350–1359.
- [20] 靳志杰, 霍志红, 许昌, 等. 基于特征选择和 XGBoost 的风电机组故障诊断[J]. 可再生能源, 2021, 39(3): 353–358.

责任编辑: 郎婧