

Journal of System Simulation

Volume 34 | Issue 11

Article 4

11-25-2022

A Wind Turbine Fault Diagnosis Method Based on Siamese Deep Neural Network

Jiarui Liu

College of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; ljr@163.com

Guotian Yang

College of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; ygt@ncepu.edu.cn

Xiaowei Wang

College of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

A Wind Turbine Fault Diagnosis Method Based on Siamese Deep Neural Network

Abstract

Abstract: In order to effectively extract the fault features of time series data in supervisory control and data acquisition (SCADA), considering the advantages of one-dimensional convolutional neural network (1-D CNN) for extracting local time series features and the advantages of long-term memory (LSTM) which can extract long-term dependent features, *a method for fault diagnosis of wind turbines based on 1-D CNN-LSTM is proposed*. To solve the problem of the scarcity of fault samples of wind turbines based on the siamese network architecture, *a wind fault diagnosis method based on siamese 1-D CNN-LSTM is proposed*. The proposed siamese 1-D CNN-LSTM method relies on a small amount of sample data to effectively extract the fault features of the wind turbine. The results show that 1-D CNN-LSTM is better than other existing deep learning methods. When the training samples are insufficient, the proposed siamese 1-D CNN-LSTM can significantly improve the fault diagnosis results.

Keywords

wind turbine, fault diagnosis, deep learning, siamese neural network, few-shot learning

Recommended Citation

Jiarui Liu, Guotian Yang, Xiaowei Wang. A Wind Turbine Fault Diagnosis Method Based on Siamese Deep Neural Network[J]. Journal of System Simulation, 2022, 34(11): 2348-2358.

基于孪生深度神经网络的风电机组故障诊断方法

刘家瑞, 杨国田*, 王孝伟

(华北电力大学 控制与计算机工程学院, 北京 102206)

摘要: 为有效提取风电 SCADA (supervisory control and data acquisition) 中时序数据故障特征, 同时考虑一维卷积神经网络(one-dimensional, convolutional neural network, 1-D CNN) 提取局部时序特征和长短时记忆网络(long short-term memory networks, LSTM) 提取长期依赖特征优势, 提出一种基于 1-D CNN-LSTM 的风电机组故障诊断方法; 针对故障样本稀缺问题, 基于孪生神经网络架构(siamese network), 提出一种基于孪生深度神经网络 siamese 1-D CNN-LSTM 的风电机组故障诊断方法, 依靠少量样本数据对机组故障特征进行有效提取。结果表明: 1-D CNN-LSTM 优于其他现有深度学习方法; 当训练样本不足时, 所提出的 siamese 1-D CNN-LSTM 可以显著提升故障诊断结果。

关键词: 风电机组; 故障诊断; 深度学习; 孪生神经网络; 少样本学习

中图分类号: TM315;TP391 文献标志码: A 文章编号: 1004-731X (2022) 11-2348-11

DOI: 10.16182/j.issn1004731x.joss.21-0261

A Wind Turbine Fault Diagnosis Method Based on Siamese Deep Neural Network

Liu Jiarui, Yang Guotian*, Wang Xiaowei

(College of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: In order to effectively extract the fault features of time series data in supervisory control and data acquisition (SCADA), considering the advantages of one-dimensional convolutional neural network (1-D CNN) for extracting local time series features and the advantages of long-term memory (LSTM) which can extract long-term dependent features, a method for fault diagnosis of wind turbines based on 1-D CNN-LSTM is proposed. To solve the problem of the scarcity of fault samples of wind turbines based on the siamese network architecture, a wind fault diagnosis method based on siamese 1-D CNN-LSTM is proposed. The proposed siamese 1-D CNN-LSTM method relies on a small amount of sample data to effectively extract the fault features of the wind turbine. The results show that 1-D CNN-LSTM is better than other existing deep learning methods. When the training samples are insufficient, the proposed siamese 1-D CNN-LSTM can significantly improve the fault diagnosis results.

Keywords: wind turbine; fault diagnosis; deep learning; siamese neural network; few-shot learning

引言

风能是一种环境友好型的可再生清洁能源, 近年来风电产业发展迅速, 2020 年《全球风能报告》中指出, 2019 年全球新增装机容量 60.4 GW, 累计装机容量达到 650 GW。然而, 与其他发电形式相

比, 由于风电机组运行环境复杂、恶劣, 风电机组经常发生故障, 造成非计划停运, 给风电场运营商带来巨大的维护成本和经济损失。对于陆地风电机组, 由于故障所带来的损失约占风电场总投入的 10%~25%^[1]。而降低运维成本进行最有效的方式就是通过状态检测和故障诊断系统对机组状态监

收稿日期: 2021-03-29 修回日期: 2021-05-11

基金项目: 国家自然科学基金(51677067)

第一作者: 刘家瑞(1993-), 男, 博士生, 研究方向为基于数据驱动的风电机组异常检测、故障诊断等。E-mail: ljr@163.com

通讯作者: 杨国田(1962-), 男, 博士, 教授, 博导, 研究方向为模式识别与智能系统等。E-mail: ygt@ncepu.edu.cn。

控, 主动对相关部件进行维护。

一方面, 风电机组的监控与采集系统(supervisory control and data acquisition, SCADA)和一些状态监控系统, 例如, 振动监测系统^[2]、声学检测方法^[3]等, 提供了海量状态监控数据; 另一方面, 当前人工智能技术、机器学习、深度学习等兴起, 均为基于数据驱动的智能风电机组故障诊断研究提供了基础。相关学者进行了大量研究, 文献[4]在选取了相关 SCADA 参数后, 人为构造 6 种特征作为传统人工神经网络输入, 对偏航齿轮箱故障进行诊断。然而对于基于传统机器学习的风电机组故障诊断方法, 其结果极大取决于人工构建相关特征。深度学习网络, 如深度置信网络(deep belief network, DBN)、深度自编码器(deep auto encoder, DAE)、卷积神经网络(convolutional neural network, CNN)、长短时记忆网络(long short-term memory networks, LSTM)等^[5]具有强大的非线性拟合能力, 可以逐层自动提取深层特征, 属于一种端对端的机器学习方法。近些年, 深度学习在计算机视觉和自然语言处理等^[6]方向上已经取得巨大进步, 基于深度学习对风电机组故障诊断方法同样引起了研究者极大的兴趣并成为研究热点。文献[7]提取轴承多源故障信号特征输入 DAE 进行预训练后, 接入 SoftMax 函数对故障分类。文献[8]提出一种一维卷积神经网络(one-dimensional convolutional neural networks, 1-D CNN)模型, 该模型由卷积层、池化层、全连接层所组成, 可以快速、准确地对发电机早期故障进行诊断。文献[9]建立一种多尺度一维 CNN 的方法对风电机组齿轮箱故障进行有效诊断, 并探究了数据噪声对实验结果的影响。文献[10]使用 LSTM 通过验证 2 个风电故障 SCADA 数据集实现故障诊断, 结果表明该方法能有效辨识机组故障并优于其他机器学习方法。此外作者还探究了数据量对于实验结果的影响。另外一些学者还结合了深度学习和传统机器学习方法, 文献[11]利用 DAE 网络模型和 Xgboost 算法对齿轮箱故障进行诊断。

文献[12]使用 LSTM 对风电机组早期异常状态进行辨识后, 通过集成学习算法对机组故障进行分类。

尽管上述基于深度学习方法的风电机组故障诊断已经可以快速准确地对机组故障进行诊断。但是仍然存在如下 2 点不足: ①上述基于深度学习模型的风电机组故障诊断方法, 往往只单独使用 CNN 或 LSTM 方法, 具有一定局限性。以单独使用 CNN 方法为例, 只提取序列局部特征进行故障诊断, 可能忽略了长期依赖特征, 不利于提升模型诊断结果。②充足的数据往往是取得良好故障诊断结果的必要保证, 以上基于学习研究通常需要大量的有监督标签数据, 实际场景中, 数据维度大且故障样本少成为了深度神经网络等机器学习模型面临的首要问题。

针对上述问题, 本文提出一种基于 1-D CNN-LSTM 的混合深度神经网络模型, 在 1-D CNN 提取风电机组 SCADA 序列数据局部时序特征后, 进一步利用 LSTM 对时序特征建模, 对所提取时序特征捕捉长期依赖特征, 最终得到风电机组故障分类结果。同时, 为解决小样本学习问题, 利用孪生神经网络(siamese network)架构, 提出一种基于 siamese 1-D CNN-LSTM 的方法, 使用孪生结构获得基于特征距离的样本相似度, 依据支撑集典型数据样本进行故障类型辨识, 可以在仅有少量样本的情况下, 实现对风电机组故障类型判别, 对于保证风电机组安全高效运行具有重要的实际意义。

1 深度学习模型

基于风电机组 SCADA 数据的故障诊断, 属于基于有监督学习的多变量时间序列分类问题。为此, 本文对深度学习模型 1-D CNN 和 LSTM 进行介绍, 并提出基于 1-D CNN-LSTM 深度学习框架的风电机组故障诊断方法。

1.1 1-D CNN 结构

CNN 已在图像分类、目标检测等任务上取得重大进展^[13]。其核心操作是通过卷积、池化完成对

原始图像局部特征的提取，1-D CNN 则是将卷积、池化应用在时序数据上，其结构如图 1 所示。

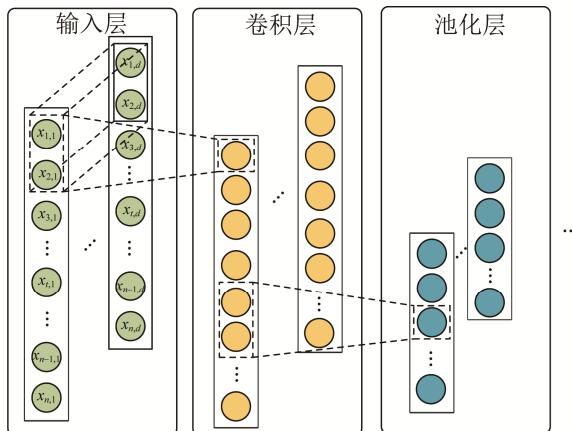


图 1 1-D CNN 卷积-池化操作
Fig. 1 1-D CNN convolution-pooling operation

对于长度为 n 的 SCADA 时序数据 $x = [x_1, x_2, \dots, x_t, \dots, x_n]$ ，其中 $x_t \in R^d$ ， d 为监控参数数量，一维卷积具体以数学形式表达为

$$x_j^l = \sigma\left(\sum_{i=1}^p x_i^{l-1} * k_{ij}^l + b_j^l\right), j = 1, 2, \dots, q \quad (1)$$

式中： x_j^l 和 x_i^{l-1} 为第 l 层的第 j 个输出特征图和第 $l-1$ 层的第 i 个特征图输入； p, q 为卷积输入输出特征图数目； b 为偏置； k 为卷积核并执行卷积操作，最后通过选取 ReLU 函数作为激活函数 σ 完成非线性映射。

池化，则是用来降采样，以保持原始特征并进一步减少过拟合发生，选取最大池化在第 l 层输出表示为

$$x_j^l = \max_{(j-1) \cdot m \leq i \leq j \cdot m} \{x_i^{l-1}\} \quad (2)$$

式中： m 为最大池化尺寸。

1.2 LSTM 结构

LSTM 通过引入遗忘门(f_t)、输入门(i_t)、输出门(o_t)，控制细胞元状态 c_t ，克服了传统循环神经网络在反向传播中存在的梯度消失和爆炸问题。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (7)$$

$$h_t = o_t \odot \tanh(c_t) \quad (8)$$

式中： h 为隐藏层； W_i, W_f, W_o, W_c 为对应 $i_t, f_t, o_t, \tilde{c}_t$ 的权重矩阵； \tilde{c}_t 为细胞状态输入； b_i, b_f, b_o, b_c 为偏置；选取 Sigmoid 函数为激活函数 σ 。LSTM 的结构如图 2 所示。

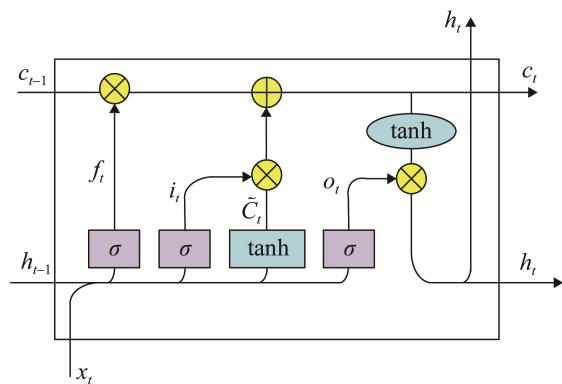


图 2 LSTM 内部结构
Fig. 2 LSTM internal structure

1.3 基于 1-D CNN-LSTM 的风电机组故障诊断方法

为进一步提取 SCADA 时序数据中长期依赖特征，本文使用 1-D CNN 提取局部序列数据特征后直接作为 LSTM 模型输入，结构如图 3 所示。

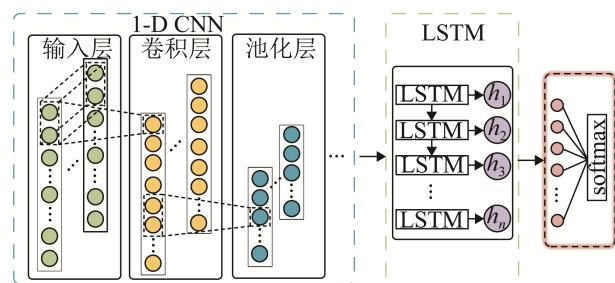


图 3 1-D CNN-LSTM 网络结构
Fig. 3 Structure of 1-D CNN-LSTM

为对相应风电机组故障进行分类，1-D CNN-LSTM 模型最后输出为 softmax 函数，得到不同故障概率向量，其中第 i 类故障概率表示为

$$y_i = \exp(a_i) / \sum_{k=1}^{N_f} \exp(a_k) \quad (9)$$

式中: N_f 为故障类型总数; a 为 LSTM 隐藏层输出。模型损失函数则选取交叉熵损失函数训练:

$$L_1 = -\sum_{i=1}^{N_f} \hat{y}_i \ln(y_i) \quad (10)$$

式中: \hat{y}_i 为第 i 个故障真实独热编码标签。

训练过程中使用自适应矩估计方法(adaptive moment estimation, Adam)^[14]进行优化, 通过最小化损失函数更新网络权重。整体超参数主要通过网格法进行确定, 模型结构详细参数(超参数)如表 1 所示。

表 1 1-D CNN-LSTM 模型超参数
Table 1 1-D CNN-LSTM hyperparameters

参数	取值	参数	取值
卷积层 1	$1 \times 5 @ 64, S=1$	softmax	Nf
池化层 1	$1 \times 2, S=2$	激活函数	ReLU
卷积层 2	$1 \times 3 @ 32, S=1$	batch size	32
池化层 2	$1 \times 2, S=2$	迭代次数	50
LSTM	64	优化器	Adam
全连接层	80	学习率	0.01
drop out	0.3		

注: @为卷积核数目, S 为滑动步数。

2 基于孪生深度神经网络的风电机组故障诊断

为解决风电机组 SCADA 训练数据不足即小样本学习问题, 本文应用孪生结构, 并结合所提出的 1-D CNN-LSTM 深度神经网络, 提出基于 siamese 1-D CNN-LSTM 风电机组故障诊断方法, 使前文所提出 1-D CNN-LSTM 提取出时序特征更具备判别性, 该框架实现使用少量训练样本数据对风电机组故障诊断。

文献[15]提出了 siamese network 架构, 用来解决签名认证, 为基于少样本学习的深度学习提供可能, 在遥感图像分类^[16], 场景识别^[17]等视觉问题方面也有广泛应用。孪生网络是一类包含 2 个相同模型参数子神经网络, 其目的是衡量输入样本经

子网络所提取特征向量后的相似性, 使子网络提取特征更具备判别性。网络前向传播计算一对输入样本 x_1, x_2 (也称支撑集样本)经子网络特征映射 $G(x_1)$ 和 $G(x_2)$ 相似性, 当输入样本为 2 个子网络输入相同类别样本时, 对应标签为 1, 使最后一层特征映射向量的 $G(x_1)$ 和 $G(x_2)$ 距离函数尽可能相近; 当输入样本为不同类别样本时, 对应标签为 0, 使得特征向量距离函数尽可能远离。即相同类样本对构成的输入数据单元为 $(x_1, x_2, 1)$, 而不同时为 $(x_1, x_2, 0)$ 。具体定义相似性度量为

$$E(x_1, x_2) = \|G(x_1) - G(x_2)\| \quad (11)$$

孪生网络使用采用对比损失函数(contrastive loss)进行训练:

$$L_2 = \frac{1}{2N} \sum_{n=1}^N (\tilde{y}E^2 + (1-\tilde{y})\max(\text{margin} - E, 0)^2) \quad (12)$$

式中: margin 为设定的阈值, 默认值为 2; \tilde{y} 为支撑集对应标签; N 为支撑集数量。

该框架基于少量训练数据, 使用孪生结构对输入 1-D CNN-LSTM 进行预训练, 最终接入 softmax 函数, 并与真实故障标签, 通过交叉熵损失函数进行微调, 最终得到风电机组输出故障类别。该框架仍然使用 Adam 算法进行优化, batch size 设为 8, 初始学习率设为 0.01, 迭代次数设置为 100。基于 siamese 1-D CNN-LSTM 风电机组故障诊断模型整体框架如图 4 所示, 具体建模步骤如下:

(1) 数据预处理与样本构造。对收集到的风电 SCADA 数据进行预处理后, 使用滑动时间窗口法构建深度学习模型训练集, 验证集和测试集。从训练集选取部分样本构建样本对形成支撑集。

(2) 建立 1-D CNN-LSTM 子网络模型。确定 1-D CNN-LSTM 模型结构超参数, 建立基于 1-D CNN-LSTM 的风电机组故障诊断模型, 并选取其作为孪生网络的子网络。

(3) 建立 siamese 1-D CNN-LSTM 预训练。确定 siamese 1-D CNN-LSTM 网络超参数, 使用 contrastive loss 函数对孪生网络进行预训练。

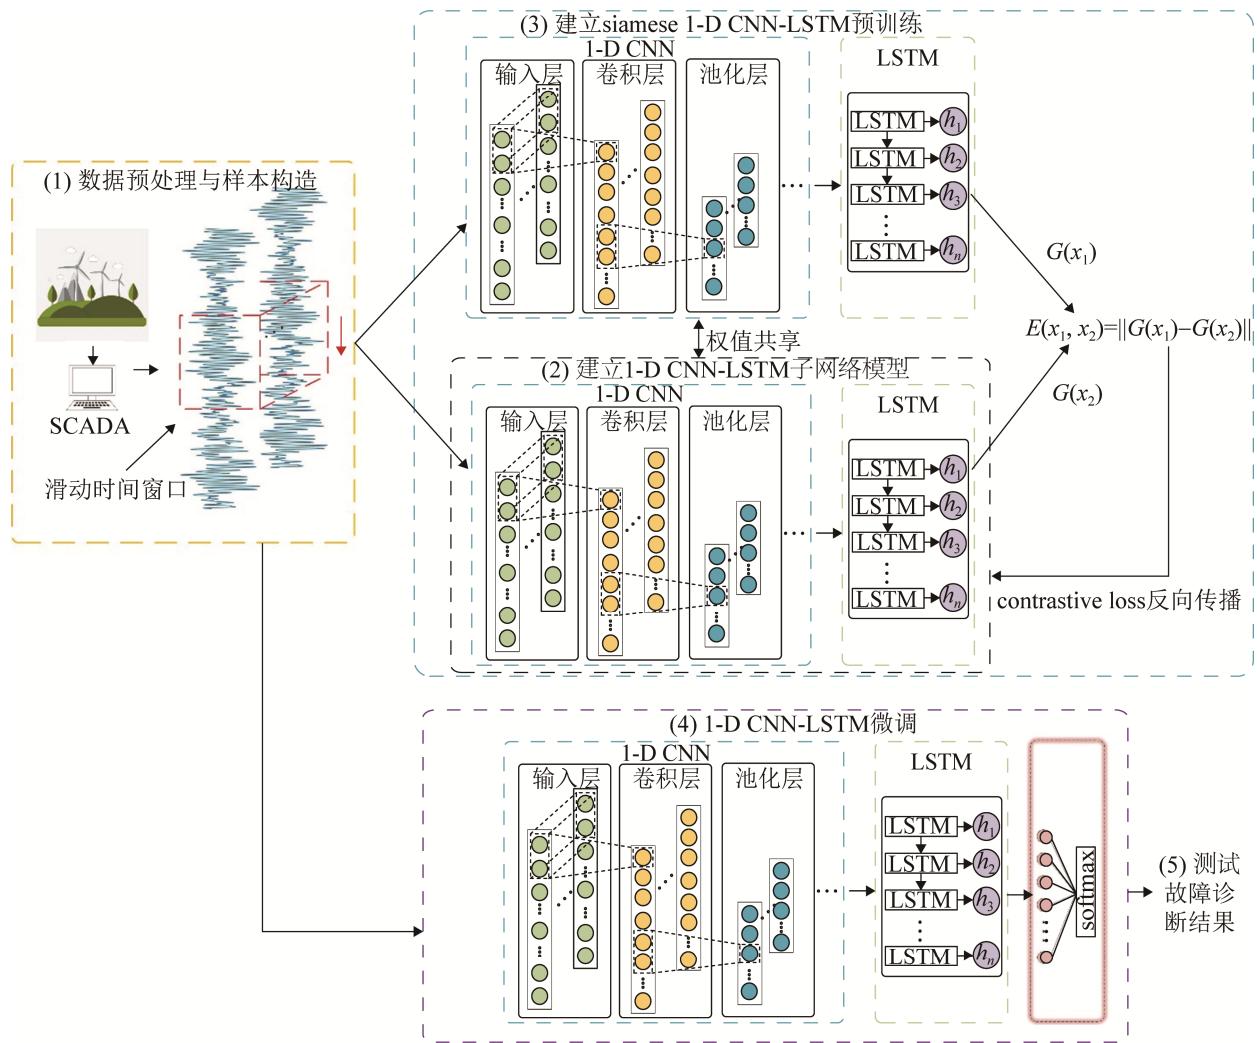


图4 基于 siamese 1-D CNN-LSTM 的风电机组故障诊断方法框架

Fig. 4 Framework of wind turbine fault diagnosis method based on siamese 1-D CNN-LSTM

(4) 1-D CNN-LSTM 微调。得到经训练过的 siamese 1-D CNN-LSTM 的子网络参数，固定参数在 1-D CNN-LSTM 模型上，最后通过训练集真实风电故障样本标签对 1-D CNN-LSTM 全连接层参数进行参数微调。

(5) 测试故障诊断结果。在测试集上得到模型的故障诊断结果对风电机组故障进行辨识。

3 实例分析

为有效验证所提出模型，本文采用 2 个数据集对模型进行实验，2 个数据集分别为中国工业大数据竞赛-风电机组结冰故障公开数据集(数据集 A)和中国北方某地区风场内实际风电机组故障数据

集(数据集 B)。搭建深度学习训练平台配置如下：主频 3.7-GHz i7 CPU，16 GB 内存，NVIDIA GTX 1080 独立显卡，Window 10 操作系统，并利用基于 Python 的深度学习库 Keras 搭建神经网络。

3.1 数据预处理和样本构造

在对深度学习模型训练前，需要对原始风电机组 SCADA 数据进行数据预处理和样本构造。以数据集 A 为例，该 SCADA 数据集共记录了 2017-11—2018-01 期间 2 台同型号 3 MW 直驱型机组运行连续和离散过程数据共 26 维，采样周期为 7 s，故障类型分为结冰和正常状态；数据集 B 是来自北方某风场 4 台相近位置同型号 2 MW 双馈型

机组 SCADA 系统, 监测信号共 45 维, 采样周期 60 s, 共 4 类故障(轴承异常, 通地泄露故障, 叶片损坏, 发电机异常), 机组故障的发生往往是渐变的过程, 根据 SCADA 系统故障报警记录, 选取机组故障停机前 12 h 采集数据, 分别标记为对应故障类别标签。选取机组额定风速下机组运行数据, 对缺失值、重复值、异常值进行删除, 使用滑动均值(数据集 A 窗口大小为 35 s, 数据集 B 窗口大小为 300 s)进行滤波。随后通过 Pearson 相关系数去除相关性较大特征, 最终获得的监测参数, 如表 2 所示。

表 2 SCADA 监测参数描述
Table 2 Description of SCADA monitoring parameters

数据集 A	数据集 B
风速($m \cdot s^{-1}$)	风速($m \cdot s^{-1}$)
桨距角(°)	桨距角(°)
偏航位置(°)	内部功率(kW)
网侧功率(kW)	功率因数(%)
无功功率(var)	频率(Hz)
发电机转速(rpm)	发电机电压(V)
环境温度(°C)	发电机输出(kW)
机舱温度(°C)	发电机转速(rpm)
发电机转子温度(°C)	齿轮箱轴承温度(°C)

为消除不同物理意义和量纲带来的影响, 采用 min-max 归一化法将原始数据归一化在[0,1]之间, 计算公式为

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (13)$$

随后, 滑动窗口法对经过预处理后的风电 SCADA 时序数据进行样本构造, 处理后的样本格式为[数据量, 时间窗口长度, 输入维度], 并输入至不同深度学习模型。其中时间窗口长度选择 50, 重叠度 10%。针对训练样本不足即小样本学习问题, 需要随机选取不同比例原始训练数据作为新训练集(子训练集), 具体占比选择 1%, 5% 的原始训练集数据作为子训练集, 对于子训练集中每一个样本, 又分别在同类数据中和异类数据随机选择一个数据组成数据对, 进而构成支撑集, 具体本文所使用 SCADA 数据集划分细节, 如表 3 所示。

表 3 数据集划分
Table 3 Data set division

数 据 集	数 据 	训练	测试	子训练集	训练集
		(70%)	(30%)	1(5%)	2(1%)
A	1 261 (正常: 631, 结冰: 630)	883	378	57 (114)	11 (22)
B	10 267 (轴承异常: 1 768, 通地泄露故障: 2 483, 7 181 叶片损坏: 2 618, 发电机异常: 3 398)	3 086	3 086	359 (718)	71 (142)

3.2 模型评价

为了更加全面地对故障诊断实验结果进行评价, 除使用准确率(Accuracy)作为故障识别结果, 本文还使用了基于查准率(Precision), 查全率(Recall), 调和分数(F1score)。对于不同类别故障, 模型诊断有结果为: 正类被预测为正类(true positive, TP); 负类被预测成正类(false positive, FP); 负类被预测成负类(true negative, TN); 正类被预测成负类(false negative, FN)。

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (14)$$

$$Precision = \frac{TP}{TP+FP} \quad (15)$$

$$Recall = \frac{TP}{TP+FN} \quad (16)$$

$$F1score = \frac{(1+\beta^2)TP}{(1+\beta^2)TP+FP+FN} \quad (17)$$

式中: $\beta=1$ 。

3.3 基于 1-D CNN-LSTM 模型验证

实验中, 现有基于深度学习模型的风电机组故障诊断方法 1-D CNN 和 LSTM 被选取为对比模型, 与本文提出的 1-D CNN-LSTM 进行对比。其中 1-D CNN 模型与 1-D CNN-LSTM 中 1-D CNN 结构参数相同, 并接入 2 层全连接层(64, 32), 以 softmax 函数输出; LSTM 与 1-D CNN-LSTM 中 LSTM 参数结构相同隐藏层节点选取为 64, 其余超参数设置相同, 并进行 5 次随机实验。不同深度学习模型对数据集 A 和 B 的故障诊断结果, 如表 4 所示。

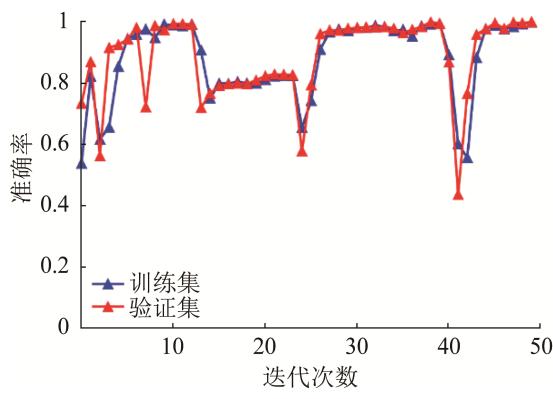
表 4 不同深度学习故障识别结果

Table 4 Fault diagnosis results of different deep learning methods

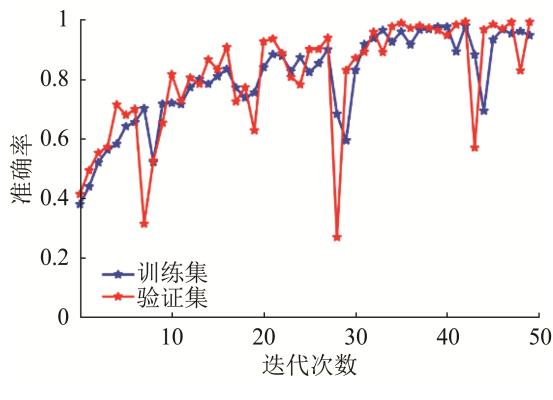
数据集	模型	Precision	Recall	F1score	Accuracy
A	LSTM	0.837±0.030 9	0.871±0.025 9	0.853±0.038 7	0.858±0.035 3
	1-D CNN	0.912±0.018 7	0.904±0.026 8	0.904±0.025 1	0.908±0.025 6
	1-D CNN-LSTM	0.922±0.009 2	0.925±0.012 4	0.921±0.016 0	0.923±0.010 1
B	LSTM	0.951±0.014 1	0.934±0.019 4	0.938±0.016 4	0.947±0.023 5
	1-D CNN	0.974±0.008 9	0.966±0.005 9	0.968±0.007 1	0.969±0.008 9
	1-D CNN-LSTM	0.979±0.005 5	0.971±0.003 7	0.974±0.004 1	0.986±0.002 7

本文提出的 1-D CNN-LSTM 均优于其他单独使用 1-D CNN 或 LSTM 对风电机组故障的模型在 4 种评价分数上的识别结果，可以对机组故障进行全面准确地诊断，对于数据集 A，F1score 可以达到 0.921；对于数据集 B 可以达到 0.974。以数据集 B 为例，其训练过程曲线，如图 5 所示。

与其他 2 种深度学习方法相比，1-D CNN-LSTM 更加平滑、稳定，且上升迅速在迭代次数为 10 时准确率即达到 0.9 以上。



(a) LSTM



(b) 1-D CNN

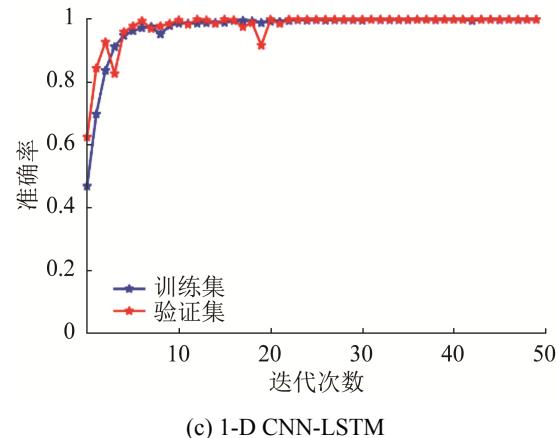


图 5 基于数据集 B 的深度学习训练曲线
Fig. 5 Deep learning training curve based on data set B

3.4 基于孪生深度神经网络结果验证

针对小样本学习问题，使用孪生深度神经网络结构 siamese 1-D CNN, siamese-LSTM, siamese 1-D CNN-LSTM，与前文所使用深度学习模型 1-D CNN, LSTM, 1-D CNN-LSTM 进行对比，如图 6 所示。

由图 6 可以看出，当选取部分原始训练集数据进行训练即训练样本不足时，深度学习方法 1-D CNN, LSTM 及前文所提出的 1-D CNN-LSTM 均不能对风电机组故障进行全面有效诊断，且测试结果不稳定。以数据集 B 为例，当选取 1% 和 5% 数据时，1-D CNN-LSTM 方法所取得准确率仅有 0.595 和 0.845，明显低于前文 3.3 中结果。针对小样本问题，在使用孪生网络结构对深度学习模型进行预训练后，测试结果均有不同程度提升，特别是使用 5% 数据时，不同深度学习模型故障诊断结果与前文数据量充足时所得结果相当。为进一步证明孪生结构有效性，也对微调过程与直接训练 1-D CNN-LSTM 训练过程进行了对比，如图 7 所示。

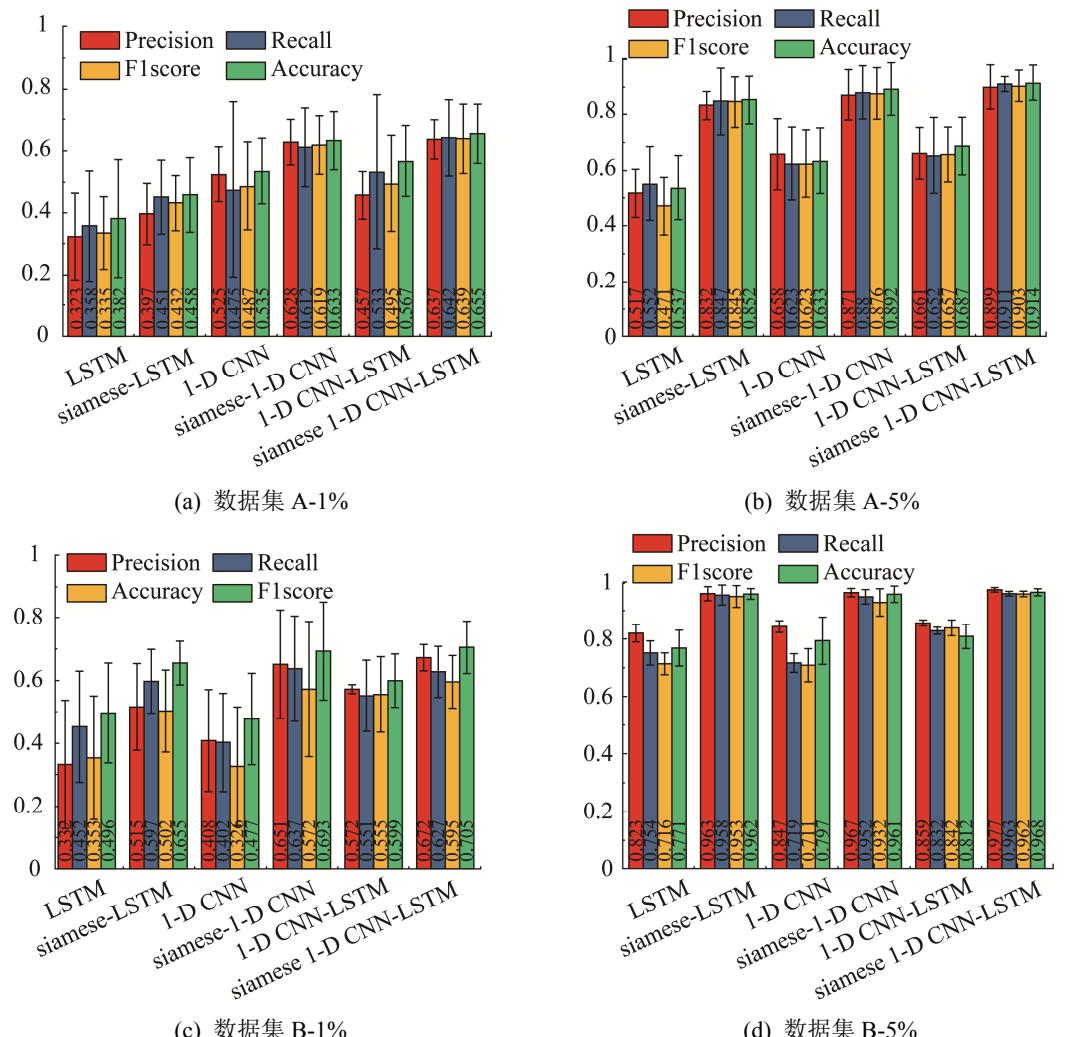


图 6 基于小样本的深度学习模型故障诊断结果

Fig. 6 Fault diagnosis results of deep learning model based on small samples

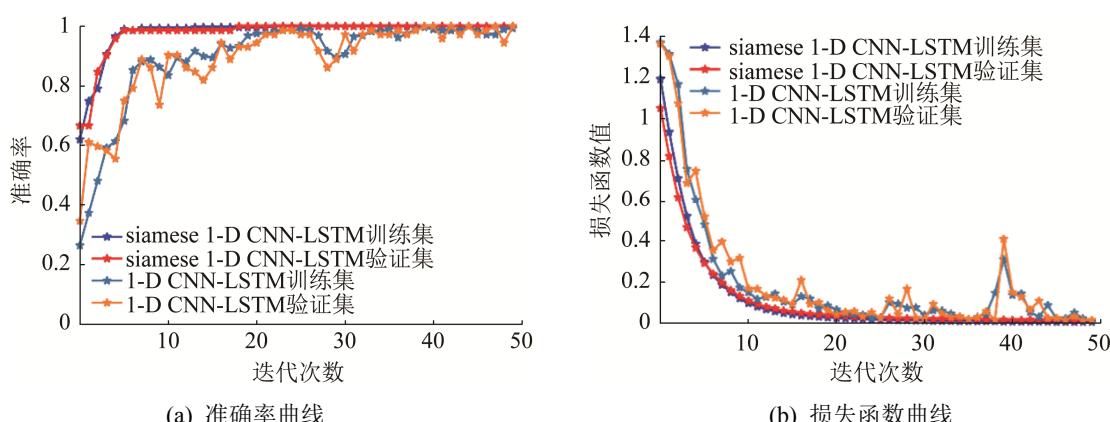


图 7 Siamese 1-D CNN-LSTM 和 1-D CNN-LSTM 训练过程对比

Fig. 7 Comparison of siamese 1-D CNN-LSTM and 1-D CNN-LSTM training process

根据图 7, 相比于直接对 1-D CNN-LSTM 进行训练, 使用孪生结构训练后的 1-D CNN-LSTM 在

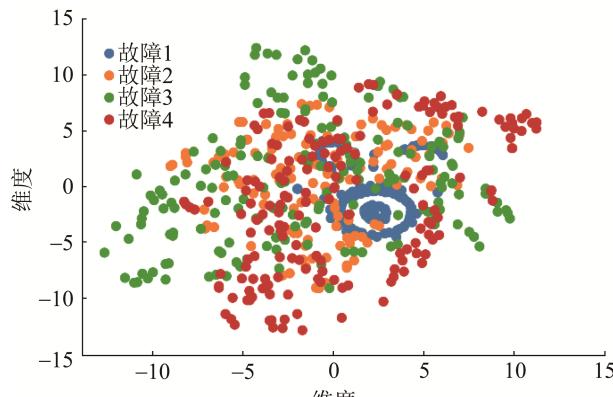
初始损失函数值更低, 初始准确更高, 说明经过孪生结构预训练的 1-D CNN-LSTM 模型在训练初始

时, 已经提取故障特征, 可以对故障进行一定程度上的判别, siamese 1-D CNN-LSTM 的训练过程也更为平滑稳定。同时本文也使用 t-SNE 方法可视化对深度学习模型提取的故障数据特征进行显示, 如图 8 所示。

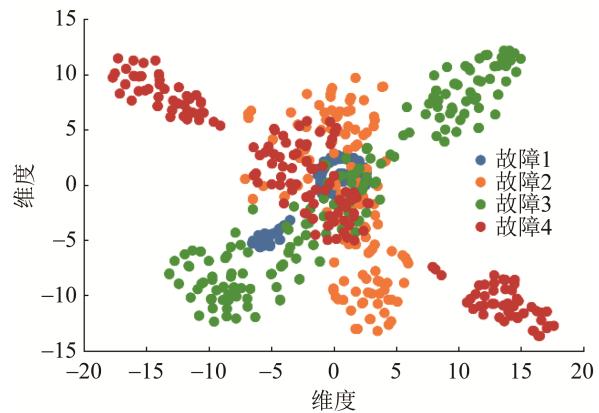
通过可视化特征可以看出, 与 1-D CNN-LSTM 相比, siamese 1-D CNN-LSTM 具有较强的特征提

取能力, 可以使相同类别数据聚集, 不同类别数据远离, 使故障数据特征更具备判别性。此外, 基于孪生结构的 siamese 1-D CNN, siamese-LSTM 较原始 1-D CNN 和 LSTM 模型, 诊断结果有显著提升。

除欧式距离外, 本文进一步探究了曼哈顿距离、切比雪夫距离作为 E 时, siamese 1-D CNN-LSTM 的风机故障诊断结果, 如图 9 所示。



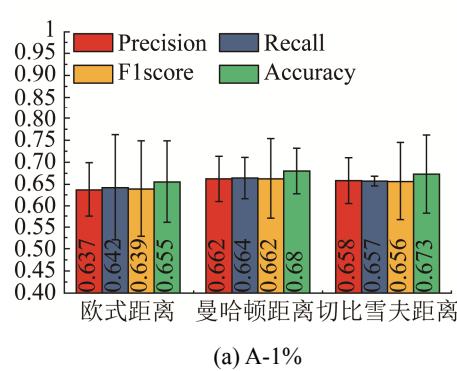
(a) 1-D CNN-LSTM



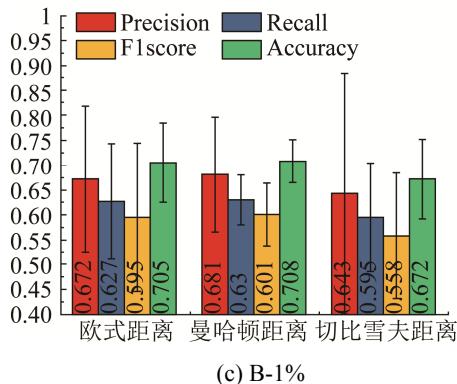
(b) Siamese 1-D CNN-LSTM

图 8 t-SNE 数据特征显示

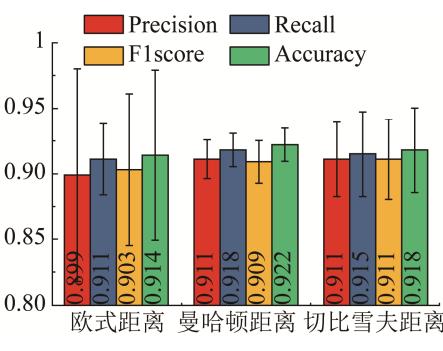
Fig. 8 t-SNE feature display



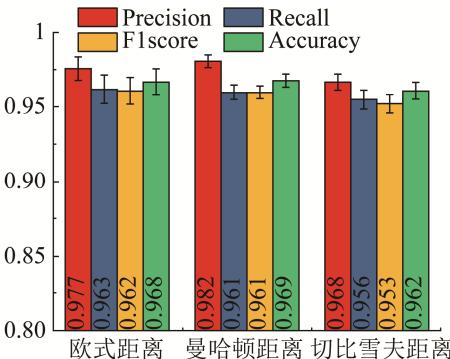
(a) A-1%



(c) B-1%



(b) A-5%



(d) B-5%

图 9 不同距离函数下 siamese 1-D CNN-LSTM 故障诊断结果

Fig. 9 Siamese 1-D CNN-LSTM fault diagnosis results under different distance functions

由图 9 可以看出, 在不同距离函数下, siamese 1-D CNN-LSTM 在数据集 A-5% 和 B-5% 上, 故障诊断结果差别并不明显; 在数据集 A-1% 和 B-1% 上, 使用曼哈顿距离函数的诊断结果略优于其他 2 种距离函数。

4 结论

本文提出一种基于 1-D CNN-LSTM 的风电机组故障诊断方法, 同时提取 SCADA 时序数据局部特征和长期依赖特征; 针对小样本问题, 提出了 siamese 1-D CNN-LSTM 模型。基于 2 个真实风电机组 SCADA 故障数据集进行实验验证, 结果表明: 与其他深度学习模型相比, 1-D CNN-LSTM 可进一步提升故障诊断结果; 依靠少量样本, 基于孪生架构的 siamese 1-D CNN-LSTM 提高了故障诊断结果, 并达到较高评价分数, 为基于少量数据实现风电机组故障诊断提供了可行方案。

参考文献:

- [1] 陈雪峰, 郭艳婕, 许才彬, 等. 风电装备故障诊断与健康监测研究综述[J]. 中国机械工程, 2020, 31(2): 175-189.
Chen Xuefeng, Guo Yanjie, Xu Caibin, et al. Review of Fault Diagnosis and Health Monitoring for Wind Power Equipment[J]. China Mechanical Engineering, 2020, 31(2): 175-189.
- [2] Wang J, Qiao W, Qu L. Wind Turbine Bearing Fault Diagnosis Based on Sparse Representation of Condition Monitoring Signals[J]. IEEE Transactions on Industry Applications (S0093-9994), 2019, 55(2): 1844-1852.
- [3] Liu Z , Wang X , Zhang L. Fault Diagnosis of Industrial Wind Turbine Blade Bearing Using Acoustic Emission Analysis[J]. IEEE Transactions on Instrumentation and Measurement (S0018-9456), 2020, 69(9): 6630-6639.
- [4] 邓子豪, 李录平, 杨波, 等. 基于 SCADA 数据特征提取的风电机组偏航齿轮箱故障诊断方法研究[J]. 动力工程学报, 2021, 41(1): 43-50.
Deng Zihao, Li Luping, Yang bo, et al. Research on Fault Diagnosis Method of Wind Turbine Yaw Gearbox Based on SCADA Data Feature Extraction[J]. Journal of Power Engineering, 2021, 41(1): 43-50.
- [5] 余萍, 曹洁. 深度学习在故障诊断与预测中的应用[J]. 计算机工程与应用, 2020, 56(3): 1-18.
Yu Ping, Cao Jie. Deep Learning Approach and Its Application in Fault Diagnosis and Prognosis[J]. Computer Engineering and Applications, 2020, 56(3): 1-18.
- [6] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature (S0028-0836), 2015, 521(7553): 436-444.
- [7] 吴定会, 祝志超, 韩欣宏. 基于 BO-SDAE 多源信号的风电机组轴承故障诊断[J]. 系统仿真学报, 2021, 33(5): 1148-1156.
Wu Dinghui, Zhu Zhichao, Han Xinhong. Wind Turbine Bearing Fault Diagnosis Based on BO-SDAE Multi-source Signals[J]. Journal of System Simulation, 2021, 33(5): 1148-1156.
- [8] Ince T, Kiranyaz S, Eren L, et al. Real-Time Motor Fault Detection by 1D Convolutional Neural Networks[J]. IEEE Transactions on Industrial Electronics (S0278-0046), 2016, 63(11): 7067-7075.
- [9] Jiang G, He H, Yan J, et al. Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine Gearbox[J]. IEEE Transactions on Industrial Electronics (S0278-0046), 2018, 66(4): 3196-3207.
- [10] Lei J, Liu C, Jiang D. Fault Diagnosis of Wind Turbine Based on Long Short-term Memory Networks[J]. Renewable Energy, 2019, 133(4): 422-432.
- [11] 赵洪山, 闫西慧, 王桂兰, 等. 应用深度自编码网络和 XGBoost 的风电机组发电机故障诊断[J]. 电力系统自动化, 2019, 43(1): 81-90.
Zhao Hongshan, Yan Xihui, Wang Guilan, et al. Fault Diagnosis of Wind Turbine Generator Based on Deep Autoencoder Network and XGBoost[J]. Automation of Electric Power Systems, 2019, 43(1): 81-90.
- [12] 魏书荣, 张鑫, 符杨, 等. 基于 GRA-LSTM-Stacking 模型的海上双馈风力发电机早期故障预警与诊断[J]. 中国电机工程学报, 2021, 41(7): 2373-2383.
Wei Shurong, Zhang Xin, Fu Yang, et al. Early Fault Warning and Diagnosis of Offshore Doubly-fed Wind Turbines Based on GRA-LSTM-Stacking Model[J]. Proceedings of the Chinese Society of Electrical Engineering, 2021, 41(7): 2373-2383.
- [13] 罗会兰, 陈鸿坤. 基于深度学习的目标检测研究综述[J]. 电子学报, 2020, 48(6): 1230-1239.
Luo Huilan, Chen Hongkun. A Survey of Research on Target Detection Based on Deep Learning[J]. Acta Electronica Sinica, 2020, 48(6): 1230-1239.
- [14] Kingma D P, Ba J L. Adam: A Method for Stochastic Optimization[C]// 3rd International Conference on

- Learning Representations, ICLR 2015 Conference Track Proceedings. New York: ACM, 2015: 1-15.
- [15] Bromley J, Guyon I, Lecun Y, et al. Signature Verification Using a “Siamese” Time Delay Neural Network[C]// Advances in Neural Information Processing Systems 6, 7th NIPS Conference. Cambridge, MA: MIT, 1993: 669.
- [16] Liu X, Zhou Y, Zhao J, et al. Siamese Convolutional Neural Networks for Remote Sensing Scene Classification[J]. IEEE Geoscience and Remote Sensing Letters (S1545-598X), 2019, 69(9): 6630-6639.
- [17] Yin H, Wang Y, Ding X, et al. 3D LiDAR-Based Global Localization Using Siamese Neural Network[J]. IEEE Transactions on Intelligent Transportation Systems (S1524-9050), 2019, 21(4): 1380-1392.