

文章编号:1671-6833(2023)05-0086-07

基于 1DCNN-BiLSTM 的电力电缆故障诊断

高超¹, 刘泽辉¹, 曹栋², 姚利娜²

(1. 国网河南省电力公司电力科学研究院, 河南 郑州 450052; 2. 郑州大学 电气与信息工程学院, 河南 郑州 450001)

摘要: 为了提升电力电缆故障诊断的准确率, 解决电缆故障诊断中过程烦琐、效率低、识别精度不高等问题, 使其能够在电缆故障发生时准确地诊断出故障类型, 提出了一种基于连续卷积神经网络(CNN)和双向长短网络记忆(BiLSTM)的电缆故障检测方法。通过 Simulink 搭建仿真模型, 提取单相接地短路、两相接地短路、两相相间短路、三相短路故障的电压信号, 构建故障样本集。将信号输入到该网络模型, 一维卷积神经网络提取电缆故障信号的局部特征, 双向长短时记忆网络捕捉故障信号时序信息, 基于自动提取的特征实现对电缆故障的诊断。经仿真结果验证, 该方法能够对电力电缆的 4 种短路故障进行识别和分类, 对单相接地短路故障和三相短路故障分类的正确概率达到 97%, 对两相接地短路和两相相间短路分类的正确概率达到 92%, 整体准确率达到 98.37%。通过对损失函数曲线、准确率曲线的分析, 证明该方法能够取得较好的电缆故障诊断效果。最后使用实际数据进行验证, 结果表明该方法具有可行性。

关键词: 电力电缆; 故障诊断; 一维卷积神经网络; 双向长短时记忆网络; 短路

中图分类号: TM732

文献标志码: A

doi:10.13705/j.issn.1671-6833.2023.02.011

随着中国供电系统不断完善, 电力电缆在各个领域得到大量的应用^[1]。但电缆长期工作在地下潮湿的环境, 容易发生短路故障, 可能导致电力设备的损坏和供电网的瘫痪^[2]。因此, 充分认识电缆故障特性、研究电缆故障诊断方法、准确并迅速诊断出电缆故障的类型, 对电网稳定可靠地运行十分重要。最初的工程中, 往往使用离线检测的方法来判断电缆的故障类型, 但这种方法烦琐且耗时长, 需要断电检修, 也会影响非故障区域的用电。随着电力电缆故障诊断技术的发展, 神经网络技术逐渐被应用到电缆故障诊断当中^[3]。任志玲等^[4]通过 Simulink 搭建电缆仿真模型, 然后分别提取出电缆正常状态和故障状态的电压信号特征, 最后使用人工神经网络对电缆故障进行诊断, 能够识别出电缆故障状态信号。近年来, 有专家学者提出了以零序电流来判断电路故障线路的方法, 例如高金峰等^[5]通过小波包变换将各线路的零序电流分解, 把故障选线转化为多分类问题, 成功预测故障线路。这种方法通过提取零序电流的特征量作为判断电缆故障的依据, 但对于实际的电网线路, 会存在消弧线圈的电流补

偿作用、接地电阻的阻值影响等因素, 导致分类的准确率较低。苏立^[6]为了解决地下电缆诊断准确率较低等问题, 提出一种基于 EMD、Hilbert 变换和 SVM 相结合的电缆故障诊断方法, 通过提取信号的时频属性, 然后使用支持向量机算法达到了对电缆故障的分类。

近年来深度学习理论推动了人工智能的发展, 其有效的训练方法和特殊的网络结构, 能较好地挖掘出数据中有利于识别的有效特征, 相对于传统的机器学习, 深度学习在图像处理、信号识别等方面准确率更高, 并且具有更好的泛化性能^[7]。汪颖等^[8]在研究了电缆早期故障的特征之后, 利用卷积神经网络对电缆多种故障进行识别。王坤^[9]研究了电缆在非运行状态下的检测方法, 采用深度学习算法对声音进行降噪处理, 计算电缆故障信号对数功率谱, 将其作为网络训练的数据, 解决了机器学习在声音降噪处理方面的不足。

虽然上述工作已经取得了不错的效果, 但仍存在以下问题: 目前在电缆故障诊断方面, 对于电缆短路故障的智能诊断方面研究相对较少; 故

收稿日期: 2022-09-04; 修订日期: 2022-11-28

基金项目: 国家自然科学基金资助项目(NSFC 61973278)

通信作者: 姚利娜(1977—), 女, 河南开封人, 郑州大学教授, 博士, 博士生导师, 主要从事动态系统的故障诊断与容错控制、电力系统故障诊断、随机分布控制、无人机控制等研究, E-mail: yaolin@zzu.edu.cn。

引用本文: 高超, 刘泽辉, 曹栋, 等. 基于 1DCNN-BiLSTM 的电力电缆故障诊断[J]. 郑州大学学报(工学版), 2023, 44(5): 86-92. (NIU X Y, CHANG C, HAN X L, et al. Fault diagnosis of power cable based on 1DCNN-BiLSTM [J]. Journal of Zhengzhou University (Engineering Science), 2023, 44(5): 86-92.)

障情况与正常情况的电气特征之间的界限较为模糊,导致识别的准确率不高,难以满足实际需求;电流信号是一种时序数据,当前时间的输出与前后状态都有关系,目前的算法没有考虑该情况。

针对上述分析,本文提出了一种基于一维卷积神经网络(one dimensional convolutional neural network,1DCNN)和双向长短时记忆网络(bidirectional long short-term memory network,BiLSTM)的电力电缆故障诊断方法1DCNN-BiLSTM,利用1DCNN提取电缆故障信号的局部特征和BiLSTM捕捉故障信号时序信息的能力,从而实现对电缆故障的诊断。

1 电力电缆故障特征分析

在整个配电网中,电缆发生故障的类型比较多,其中发生概率最高的是短路故障^[10],主要包括单相接地短路、两相接地短路、两相相间短路、三相短路故障。当电缆故障发生时,为了能迅速排除电缆故障,需要研究电缆不同故障的差异,对保证电网运行的可靠性和安全性至关重要。

针对电缆发生单相接地故障,设定A相为故障相,则B相和C相为正常运行状态,故A相接地短路故障的边界条件为

$$\begin{cases} \dot{U}_{fa} = 0; \\ \dot{I}_{fb} = \dot{I}_{fc} = 0. \end{cases} \quad (1)$$

用序分量的形式可表示为

$$\begin{cases} \dot{U}_{fa(1)} + \dot{U}_{fa(2)} + \dot{U}_{fa(0)} = 0; \\ \dot{I}_{fa(1)} = \dot{I}_{fa(2)} = \dot{I}_{fa(0)}. \end{cases} \quad (2)$$

根据式(1)、(2)可以推出A相的正序、负序和零序电流大小相等,电压和为0。A相接地短路的复合序网络如图1所示。




图1 A相接地短路的复合序网络

Figure 1 Composite sequence network with A phase to ground short circuit

由图1可以看出,正序、负序和零序互相串联,所以故障点处各序电流大小相等,用式(3)表示为

$$\dot{I}_{fa(1)} = \dot{I}_{fa(2)} = \dot{I}_{fa(0)} = \frac{\dot{U}_{fa(0)}}{Z_{\Sigma(1)} + Z_{\Sigma(2)} + Z_{\Sigma(0)}}. \quad (3)$$

得出A相的短路电流:

$$\dot{I}_{fa} = \dot{I}_{fa(1)} + \dot{I}_{fa(2)} + \dot{I}_{fa(0)} = \frac{3\dot{U}_{fa(0)}}{Z_{\Sigma(1)} + Z_{\Sigma(2)} + Z_{\Sigma(0)}}. \quad (4)$$

根据平衡电压方程和图1,各序电压:

$$\begin{cases} \dot{U}_{fa(1)} = \dot{U}_{f(0)} - Z_{\Sigma(1)} \dot{I}_{fa(1)}; \\ \dot{U}_{fa(2)} = 0 - Z_{\Sigma(2)} \dot{I}_{fa(2)}; \\ \dot{U}_{fa(0)} = 0 - Z_{\Sigma(0)} \dot{I}_{fa(0)}. \end{cases} \quad (5)$$

倘若忽略负荷电阻,B相电压和C相电压可用故障相A相电压表达。即B、C相电压:

$$\begin{cases} \dot{U}_{fb} = a^2 \dot{U}_{fa(1)} + a \dot{U}_{fa(2)} + \dot{U}_{fa(0)}; \\ \dot{U}_{fc} = a \dot{U}_{fa(1)} + a^2 \dot{U}_{fa(2)} + \dot{U}_{fa(0)}. \end{cases} \quad (6)$$

从式(6)可以推出,A相中的电流会增大,但是电压会降低。在通常情况下,A相的线电压会降为0,B、C两相的电压增加到故障发生前电压的 $\sqrt{3}$ 倍。按照同样的方法,可以对两相接地短路、两相相间短路、三相短路故障进行特征分析。

2 一维卷积神经网络

一维卷积神经网络主要是用于处理序列数据的一种特殊的神经网络,主要结构由卷积层、池化层和全连接层组成^[11]。

卷积层的作用是对输入的特定信号进行有效的特征提取,即用一个卷积核依次滑动,对目标输入进行局部的卷积操作,卷积核就是一个权重矩阵。其中一维卷积只有一个空间维度,卷积过程为

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} W_{ij}^l + b_j\right). \quad (7)$$

式中: f 为激活函数; M_j 为输入的操作; l 为输入的长度; X_i^{l-1} 为目标输入的待卷积区域; W_{ij}^l 为卷积核,也称为权重; b_j 为对应卷积核的偏置系数。

池化层也称为采样层,通过对卷积层采样,减少输入数据的维数,提高网络的计算速度。目前最常用的2种池化操作主要有最大池化和平均池化。前者应用比较广泛,其运算表达式为

$$p^l = \max[a^l]. \quad (8)$$

全连接层可以将卷积层和池化层对输入目标提取的局部特征进行整合,从而达到对检测目标的准确识别。同时全连接层可以把多维的输入转化为一维的输出,得到最终的分类结果。

3 双向长短时记忆网络

长短时记忆网络(long short-term memory, LSTM)消除了循环神经网络中出现梯度消失等问

题。由于 LSTM 模型包含记忆单元,可以防止网络出现梯度爆炸的现象。在 LSTM 网络中,记忆单元只能记忆某时刻的输入,对后面的输入无法记忆,而且单层的 LSTM 网络性能较差,需要叠加多层的 LSTM 才能发挥出最佳的性能。而在许多问题中,当前时间的输出不仅与过去时间的状态信息有关,还与未来时间的状态信息有关。基于此,BiLSTM 应运而生^[12],将两个 LSTM 结构相连接,结合了过去和未来的信息,其网络结构如图 2 所示。




图 2 BiLSTM 网络结构
Figure 2 BiLSTM network structure

BiLSTM 网络内部结果主要由两部分组成,即自前向后的 LSTM 层和自后向前的 LSTM 层。前向层和后向层分别对输入的数据进行计算,最后将 2 层计算的结构相结合,便可得到 BiLSTM 网络的输出结果。BiLSTM 网络的计算公式为

$$\begin{cases} h_t = f(w_1x_t + w_2h_{t-1}); \\ h'_t = f(w_3x_t + w_5h'_{t-1}); \\ o_t = g(w_4h_t + w_6h'_t)。 \end{cases} \quad (9)$$

式中: w 表示 BiLSTM 网络中的权重参数; x_t 表示 t 时刻的输入; h_t 表示 t 时刻前向隐藏层的输出; h'_t 表示 t 时刻后向隐藏层的输出; o_t 表示网络最终的输出。

4 1DCNN-BiLSTM 模型

虽然 1DCNN 和 BiLSTM 网络在电缆故障诊断准确率都取得了不错的效果,但是这 2 种网络都存在不足:1DCNN 可以很好地适应电力电缆故障信号的一维特性,并且能有效地提取出电缆故障信号的局部特征,但没有考虑到故障信号的时序性,不能解决故障信号长期依赖问题;BiLSTM 网络能解决长期依赖问题,但特征提取能力相对较弱。如果将 1DCNN 提取到的特征传输到 BiLSTM 网络中,网络对电缆故障诊断的准确率更高^[13]。基于此,本文将 1DCNN 和 BiLSTM 的优点相结合,设计一种基于 1DCNN-BiLSTM 电缆故障诊断模型,如图 3 所示。

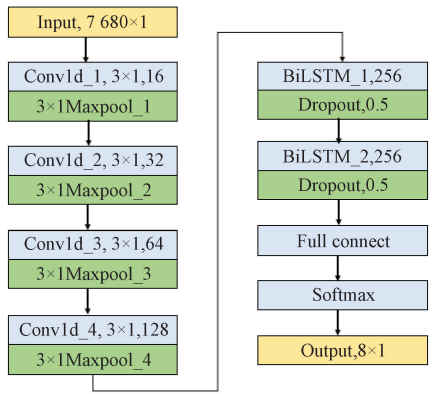


图 3 1DCNN 与 BiLSTM 网络融合模型
Figure 3 1DCNN and BiLSTM network fusion model

1DCNN 层可以使用较少的处理资源进行特征提取,将识别出的特征排列在稀疏矩阵中,从而更好地识别特征之间的相关性,减少参数数量,缩短大量训练时间。BiLSTM 层用于学习正向和反向时间序列数据,隐藏层使用 2 个具有相同输入并连接到相同输出的单元,一个处理正向时间序列,另一个处理反向时间序列。两者相结合,在提高训练时间的同时,还能更好地学习特征,实现对大跨度时间序列数据的精准识别。

具体的算法流程如图 4 所示。1DCNN 和 BiLSTM 网络融合模型,输入层输入的数据为 7 680×1。卷积的部分是由 4 层卷积层和 4 层池化层组成,卷

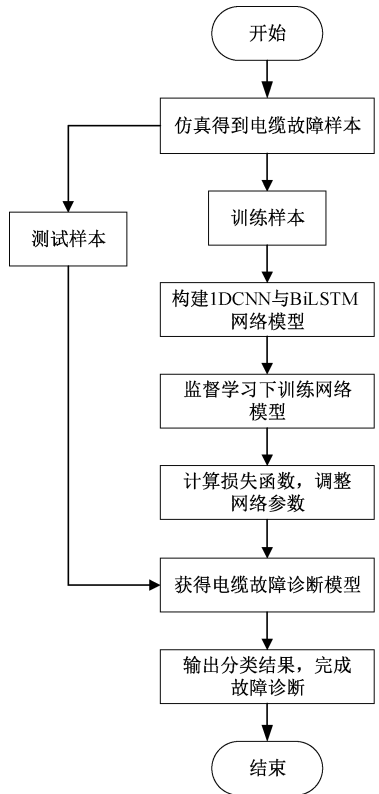


图 4 算法流程图
Figure 4 Algorithm flow chart

积核的尺寸均为 3,每一层卷积核的个数分别为 16、32、64、128。卷积网络后面是连接 2 层 BiLSTM 层,隐藏节点设定 256 个。每个 BiLSTM 层后面均连接 1 层 Dropout 层,Dropout 层的概率设置为 0.5。BiLSTM 网络后面连接全连接层,然后经过 Softmax 输出电缆故障类别。

5 仿真结果分析

5.1 实验数据的获取

本文利用 Simulink 搭建 10 kV 配电网仿真模型。电源为 10 kV 三相交流电源,频率设置为工频 50 Hz。电缆模块使用的是 PI 型等效电路三相模块。参考实际电缆参数,正序参数设置: $R_1 = 0.27 \Omega/\text{km}$, $L_1 = 0.26 \text{ mH}/\text{km}$, $C_1 = 0.339 \mu\text{F}/\text{km}$ 。零序参数设置: $R_0 = 2.7 \Omega/\text{km}$, $L_0 = 1.02 \text{ mH}/\text{km}$, $C_0 = 0.28 \mu\text{F}/\text{km}$ 。负载模块选用的是三相串联电阻和电感模块。故障发生的位置设在 2 条电缆线路中间,长度均为 5 km,电缆线路上的负载均相等。

本文针对电缆线路上单相接地短路、两相接地短路、两相相间短路、三相短路故障电压信号进行采集,在电缆运行开始后 0.05 s 时加入故障点,电缆持续运行到 0.2 s 结束。采集到的故障电压信号如图 5 所示。

故障信号采样频率为 12.8 kHz,采样时间为 0.2 s,系统正常运行状态 0.05 s 后施加故障,每次仿真对

电压采样 2 560 个点,每条线路具有三相,每条线路采集 7 680 个点,即每个样本的长度为 7 680。一共得到 8 831 个样本。对得到的样本集按照 4:1 进行划分,即 80% 用作训练样本,20% 用作测试样本。各类信号样本采集的数量如表 1 所示。

表 1 各类信号样本采集数量

Table 1 Collection quantity of various signal samples	
故障类型	样本数量
单相接地短路	2 350
两相接地短路	2 161
两相相间短路	2 247
三相短路	2 073

5.2 实验结果

本文中的网络模型是基于 Keras 搭建的,Keras 里面包含大量的深度学习模型。实验中的样本数据标签使用 one_hot 进行处理,然后批量地输入到网络中。因为本文采集的电缆故障数据样本较多,共计 8 831 个样本数据,倘若全部加载到计算机中进行训练,可能会导致网络训练速度较慢,所以批尺寸设置为 128,学习率设置为 0.001。在神经网络对故障信号识别能力进行评估时,通常采用损失函数曲线和准确率曲线。损失函数可以计算出网络模型的预测值和真实值之间的误差。误差越小,说明网络对目标预测越准确。准确率是最常见的一个对网络分类的评估指标。准确率越高,说明网络对目标分

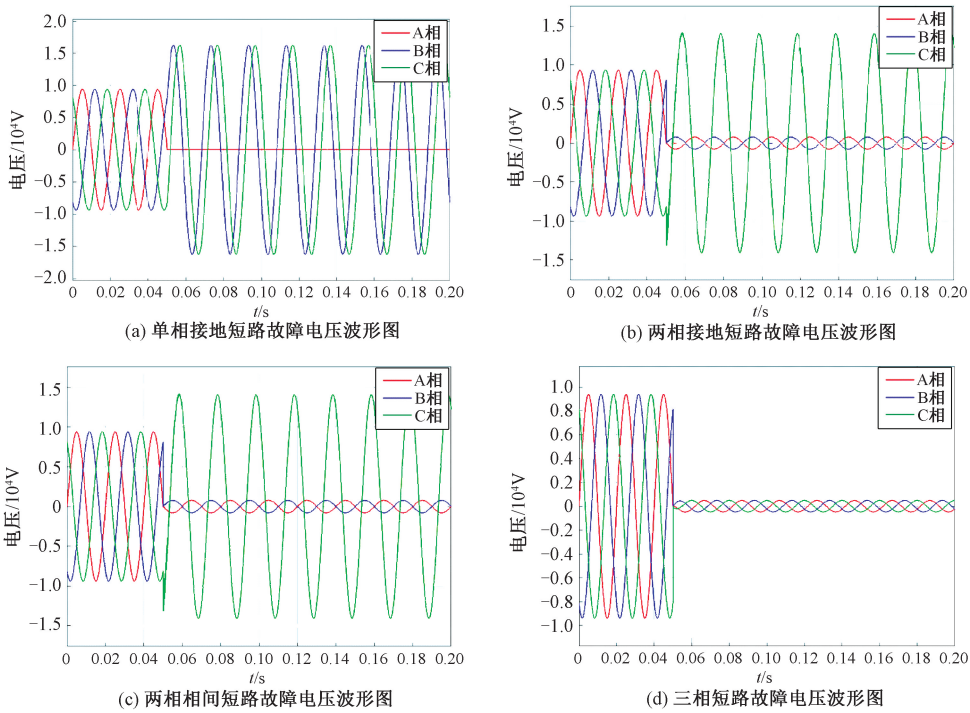


图 5 电缆各种故障电压波形

Figure 5 Various fault voltage waveforms of cables

类越准确。将本文中提出的 1DCNN-BiLSTM 的网络模型分别与 1DCNN 网络模型和 BiLSTM 网络模型进

行实验对比,损失函数曲线如图 6 所示,准确率曲线如图 7 所示,混淆矩阵如图 8 所示。




图 6 各种网络模型的损失函数曲线

Figure 6 Loss function curves of various network models




图 7 各种网络模型的准确率曲线图

Figure 7 Accuracy curves of various network models




图 8 1DCNN-BiLSTM 网络模型的混淆矩阵

Figure 8 Confusion matrix of 1DCNN-BiLSTM network

从图 6 可以看出,随着迭代次数的不断增加,3 种网络的损失函数曲线均不断下降。从损失函数曲线下下降速度来看,1DCNN-BiLSTM 网络明显快于 1DCNN 和 BiLSTM 网络,而且 1DCNN-BiLSTM 网络曲线更平滑,最终的损失函数的值最小。由此可以看出,1DCNN-BiLSTM 对电力电缆故障诊断的性能要优于其他 2 种网络。

从图 7 可以看出,随着 3 种网络进行 500 次的迭代训练,3 种网络模型的准确率曲线均不断上升。从准确率曲线上升速度来看,1DCNN-BiLSTM 网络上升的速度明显优于 1DCNN 和 BiLSTM 网络,而且 1DCNN-BiLSTM 网络最终的准确率也要大于另外 2

种网络,并且准确率曲线也比较平滑。由于 1DCNN-BiLSTM 网络模型不仅具有较强的特征提取能力,还可以双向地获取电缆故障时序信息,因此对电缆正确样本分类的准确率也更高,得出的最终准确率也较高。

在图 8 中,纵坐标表示电缆故障信号的真实类别,横坐标表示网络对电缆故障信号的预测类别。矩阵上对角线的数值表示电缆故障信号被正确分类的概率。从图 8 可以看出,1DCNN-BiLSTM 对单相接地短路和三相短路故障正确分类的概率达到 97%,对两相接地短路和两相相间短路分类正确概率较低,但总体正确分类的概率均到达 92% 以上,说明利用 1DCNN-BiLSTM 对电缆故障进行诊断是完全可行的。

6 实际数据验证

为了验证 1DCNN-BiLSTM 模型在实际中的电缆故障数据集上同样具有较好的故障诊断的能力,本节将采用公开电缆故障数据集对该模型进行验证,测试该模型的泛化能力。

采用的电缆故障公开数据集是由 Riley Alden 发布在谷歌数据库中的数据,包含欧洲某公用事业公司在 2014—2019 年 10 kV 电力电缆的在线监测

数据。从中抽选出和仿真中相同的电缆故障类型,包括电缆正常运行时的电压信号、电缆单相接地电压故障信号和电缆两相接地短路电压故障信号。公开数据集中电缆故障样本大小均为 3 072×1。数据集中样本的数量如表 2 所示。

表 2 公开数据集中样本的数量

Table 2 Number of samples in the public data set	
故障类型	样本数量
正常运行	638
单相接地短路	316
两相接地短路	137

为了体现 1DCNN-BiLSTM 模型相对其他几种网络模型在电缆故障诊断的优势,将几种网络模型进行实验对比,结果如表 3 所示。

表 3 网络模型准确率对比

Table 3 Comparison of accuracy of network model		
网络模型	网络层数	准确率/%
1DCNN	4	88.45
LSTM	4	90.72
BiLSTM	2	91.14
1DCNN-BiLSTM	4+2	93.51

从表 3 分析可知,4 种网络模型对公开数据集中电缆故障诊断的准确率最低的是 1DCNN 网络,仅为 88.45%,LSTM 和 BiLSTM 网络对电缆故障诊断的准确率相对较高。而 1DCNN-BiLSTM 模型不仅具有特征提取能力还可以双向捕捉电缆故障时序信息,该网络模型诊断的准确率达到 93.51%。

为了验证改进双向长短时记忆网络模型对公开数据集中电缆故障的分类能力,得出混淆矩阵如图 9 所示。




图 9 公开数据集上 1DCNN-BiLSTM 模型的混淆矩阵
Figure 9 Confusion matrix of 1DCNN-BiLSTM network model on public data set

从图 9 中可以得出,由于现场采集的数据可能会被其他信号干扰,公开数据集上电缆被正确分类

的概率低于仿真中采集的数据集,但整体上仍取得不错的分类效果。其中,对正常运行样本正确分类的概率最高,达到了 96%,单相接地短路被分类的正确率最低,只有 89%,两相接地短路故障被正确分类的概率为 97%。

7 结论

(1)提出一种基于 1DCNN-BiLSTM 的电力电缆故障诊断方法,将 1DCNN 和 BiLSTM 网络相结合,利用 1DCNN 较强的特征提取能力,提取出电缆故障信号中的特征量,再利用 BiLSTM 网络具有时序捕捉的能力,从而提高网络的准确率,使准确率达到 98.37%,取得较好的电缆故障诊断效果。

(2)通过将 1DCNN-BiLSTM 网络模型分别与 1DCNN 和 BiLSTM 网络作对比,从网络的损失函数曲线和准确率曲线的实验结果可知,1DCNN-BiLSTM 网络对电缆诊断的性能优于其他 2 种网络。

(3)为了证明改进双向长短时记忆网络模型对实际电缆故障数据的诊断能力,采用公开数据集对网络进行测试,实验结果显示该模型对实际电缆故障样本同样具有分类能力。

参考文献:

[1] 黄夏,梁日干,杨毅,等. 配电电缆故障诊断方法研究[J]. 电工技术, 2021(7): 72-73.
HUANG X, LIANG R G, YANG Y, et al. Research on fault diagnosis method of distribution cable[J]. Electric engineering, 2021(7): 72-73.

[2] 张伟,何邦乐,王东源,等. LIRA 在输电缆故障诊断中的研究与应用[J]. 电力大数据, 2021, 24(11): 23-31.
ZHANG W, HE B L, WANG D Y, et al. Research and application of LIRA in transmission cable fault diagnosis [J]. Power Systems and Big Data, 2021, 24(11): 23-31.

[3] 肖旰,周莉,李敬兆,等. 基于 EEMD 融合 BAS-CNN 的高压电缆故障诊断[J]. 电子测量技术, 2022, 45(4): 160-167.
XIAO G, ZHOU L, LI J Z, et al. High-voltage cable fault diagnosis based on EEMD and BAS-CNN[J]. Electronic Measurement Technology, 2022, 45(4): 160-167.

[4] 任志玲,张媛媛. 矿下电缆故障诊断的能量熵和 PSO-BP 算法[J]. 系统仿真学报, 2015, 27(5): 1044-1049.
REN Z L, ZHANG Y Y. Energy entropy and particle swarm optimization BP neural network of fault diagnosis techniques of coal mine cable[J]. Journal of System Sim-

ulation, 2015, 27(5): 1044-1049.

[5] 高金峰, 秦瑜瑞, 殷红德. 基于小波包变换和支持向量机的故障选线方法[J]. 郑州大学学报(工学版), 2020, 41(1): 63-69.

GAO J F, QIN Y R, YIN H D. Fault line selection based on wavelet packet transform and support vector machine [J]. Journal of Zhengzhou University (Engineering Science), 2020, 41(1): 63-69.

[6] 苏立. 基于 HHT 变换和 FOALSSVM 的电缆故障诊断[J]. 计算机与现代化, 2017(9): 96-101, 105.

SU L. Cable fault diagnosis based on HHT transform and FOALSSVM [J]. Computer and Modernization, 2017 (9): 96-101, 105.

[7] 林伟, 罗群, 陈龔斌. 基于深度学习算法的大型飞机电缆故障识别[J]. 机械设计与制造工程, 2022, 51 (1): 62-66.

LIN W, LUO Q, CHEN Y B. Cable fault identification of large aircraft based on deep learning algorithm[J]. Machine Design and Manufacturing Engineering, 2022, 51 (1): 62-66.

[8] 汪颖, 卢宏, 杨晓梅, 等. 堆叠自动编码器与 S 变换相结合的电缆早期故障识别方法[J]. 电力自动化设备, 2018, 38(8): 117-124.

WANG Y, LU H, YANG X M, et al. Cable incipient fault identification based on stacked autoencoder and S-transform [J]. Electric Power Automation Equipment, 2018, 38(8): 117-124.

[9] 王坤. 基于深度学习的电力电缆故障定位技术[D]. 西安: 西安电子科技大学, 2020.

WANG K. Power cable fault location technology based on deep learning[D]. Xi'an: Xidian University, 2020.

[10] 唐金锐, 尹项根, 张哲, 等. 配电网故障自动定位技术研究综述[J]. 电力自动化设备, 2013, 33(5): 7-13.

TANG J R, YIN X G, ZHANG Z, et al. Survey of fault location technology for distribution networks[J]. Electric Power Automation Equipment, 2013, 33(5): 7-13.

[11] ALBERTO R, MARKUS H, FRANCO S, et al. A study on the effects of recursive convolutional layers in convolutional neural networks[J]. Neurocomputing, 2021, 460: 59-70.

[12] MESHRAM S, KUMAR M A. Long short-term memory network for learning sentences similarity using deep contextual embeddings[J]. International Journal of Information Technology, 2021, 13: 1633-1641.

[13] 卜佑军, 张桥, 陈博, 等. 基于 CNN 和 BiLSTM 的钓鱼 URL 检测技术研究[J]. 郑州大学学报(工学版), 2021, 42(6): 14-20.

BU Y J, ZHANG Q, CHEN B, et al. Research on phishing URL detection technology based on CNN-BiLSTM [J]. Journal of Zhengzhou University (Engineering Science), 2021, 42(6): 14-20.

Fault Diagnosis of Power Cable Based on 1DCNN-BiLSTM

GAO Chao¹, LIU Zehui¹, CAO Dong², YAO Lina²

(1. State Grid Henan Electric Power Company Economic and Technological Research Institute, Zhengzhou 450052, China; 2. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In order to improve the accuracy of fault diagnosis of power cable failure to ensure a cable fault detection method based on convolution neural network (CNN) and bi-directional long short term memory (BiLSTM) was proposed in this paper. The simulation model was built through Simulink to extract the voltage signals of single-phase ground short circuit, two-phase ground short circuit, two-phase phase short circuit and three-phase short circuit faults, and to generate the fault sample. Then the fault voltage signals were input into the network model, to obtain the local features through CNN, to obtain the fault signal timing information through BiLSTM, and to realize the diagnosis of cable fault based on the automatically extracted features. The simulation results showed that this method could accurately classify the four short-circuit faults of power cables, the accuracy rate of single-phase grounding short-circuit fault and three-phase short-circuit fault was 97%, the accuracy rate of two-phase ground short circuit and two-phase short circuit was 92%, and the overall accuracy rate was 98.37%. In addition, through the analysis of loss function curve and accuracy curve, it was proved that this method could achieve better cable fault diagnosis effectiveness. Finally, the actual data was used to verify the feasibility of the method.

Keywords: power cable; fault diagnosis; one-dimensional convolutional neural network; bidirectional long short-term memory network; short circuit