

基于自编码器与时域卷积神经网络算法的配电网 线损分析

刘超, 侯人杰

(江苏大学电气信息工程学院, 江苏镇江 212013)

摘要: 复杂的配电网环境中存在线损计算精确性、实时性不足的问题, 因此提出基于循环神经网络自编码器改进的TCN-BiGRU配电网线损预测方法。选用擅长处理时间序列的TCN神经网络模型作为主干特征提取网络, 在TCN中融入BiGRU单元以有效解决梯度消失问题。在此基础上, 结合循环神经网络自编码器对线损异常值进行无监督分类并标记, 通过softmax损失函数预测线损率异常原因, 并制定相应降损措施, 同时利用改进后的TCN-BiGRU算法对线损进行预测及成因分析。实验结果表明, 与传统的配电网线损预测方法相比, 该线损预测方法的均方根误差相较于传统的EMD-LSTM与PSO-CNN算法分别降低了0.036 99和0.004 02, 在线损成因分析方面的准确率相较于ResNet50与DBN-DNN算法分别提高了1.500%和5.841%, 为分布式电源接入后配电网节能降损、实现电网双碳目标提供了科学的参考依据。

关键词: 循环神经网络自编码器; TCN-BiGRU线损预测算法; 智能电网; 线损异常成因分析; 台区线损预测

DOI: 10.11907/rjdk.241360

开放科学(资源服务)标识码(OSID):



中图分类号: TP391.4

文献标识码: A

文章编号: 1672-7800(2024)009-0063-07

Distribution Network Line Loss Analysis Based on Autoencoder and Time Domain Convolutional Neural Network Algorithm

LIU Chao, HOU Renjie

(School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: In the complex distribution network environment, there are problems of insufficient accuracy and real-time calculation of line loss. This paper proposes an improved TCN-BiGRU distribution line loss prediction method based on recurrent neural network autoencoder. The TCN neural network model, which is good at processing time series, was selected as the backbone feature extraction network, and the BiGRU unit was integrated into the TCN to effectively solve the problem of gradient vanishing. On this basis, combined with the recurrent neural network autoencoder, the line loss outliers were classified and labeled unsupervised, and the causes of the line loss rate anomalies were predicted through the softmax loss function and the corresponding loss reduction measures were formulated. The experimental results show that compared with the traditional distribution network line loss prediction method, the root mean square error of the proposed line loss prediction method is reduced by 0.036 99 and 0.004 02 compared with the traditional EMD-LSTM and PSO-CNN algorithms, respectively, and the accuracy of line loss cause analysis is improved by 1.500% and 5.841% compared with the ResNet50 and DBN-DNN algorithms, respectively. It provides a scientific reference for energy saving and loss reduction in the distribution network after the distributed power generation is connected and the realization of the dual carbon goal of the power grid.

Key Words: recurrent neural network autoencoder; TCN-BiGRU line loss prediction algorithm; smart grid; analysis of the causes of abnormal line loss; prediction of line loss in the substation area

收稿日期: 2024-04-11

扫描二维码阅读全文:



基金项目: 江苏省“六大人才高峰”项目(XXRJ-012)

作者简介: 刘超(1977-), 男, 博士, 江苏大学电气信息工程学院副教授、硕士生导师, 研究方向为基于业务识别的移动互联网QoS管理关键技术; 侯人杰(1996-), 男, 江苏大学电气信息工程学院硕士研究生, 研究方向为配电网线损预测及分析。本文通讯作者: 刘超。

0 引言

在电力系统中,通常用线损率定义电能损耗,用于计算配电网在电力输送、配变电或用户用电环节中出现的线路有功损耗和电能损耗^[1]。线损率作为一种可衡量电网建设水平和经营管理状况的指标,能够真实反映出电力企业的规划水平和电网企业的经济效益,是电力部门日常管理工作中关注的重要内容^[2]。

目前,线损率的传统计算方法包括平均电流法、损失因数法及等值电阻法等,但其与配电网耗电模型结果出入较大,计算精度和数据稳定性都偏低^[3-4]。文献[5]提出一种采用负荷电量计算低压配电台区理论线损的牛顿拉普逊法,文献[6-7]提出的回归分析方法在台区线损计算中也有应用。文献[8]提出一种基于粒子群算法优化支持向量回归的方法,该方法的计算精度更高,可以一定程度上避免局部最优。文献[9]利用自适应遗传算法优化BP神经网络,实现配电网线损预测,具有更高的准确性。文献[10]针对因线路分布复杂、终端数目庞大等带来的低压台区理论线损计算困难的问题,提出一种基于深度置信网络(Deep Belief Network, DBN)的低压台区理论线损计算新方法;文献[11]通过研究台区负载率的特性,提出一种基于台区负载率的快速线损测算方法;文献[12]针对台区线损异常判断的片面性和局限性,在研究聚类算法和线损率数据特性的基础上,提出一种基于k-means聚类算法的线损异常辨别方法。文献[13]采用免疫遗传算法优化人工神经网络,扩大了神经网络的权值搜索空间,提高了网络系统的学习效率和精度。

以上对台区线损的研究相较于传统方法提高了准确率与计算效率,但仍存在一系列问题:①计算方法大多基于用户电能表实抄电量,十分依赖网络结构、线路型号和长度、截面积等信息;②对线路分布复杂、管理质量参差不齐的台区计算准确率相对较低;③大多集中在线损预测和线损成因分析的其中一个研究层面,尚未建立完善的配电网线损预测网络结构。

针对上述问题,本文提出基于自编码器与时域卷积神经网络算法的配电网台区线损率分析模型,结合台区历史数据特征进行成因分析,建立基于多特征量的线损识别模型,从而提高台区线损预测精度。

1 模型设计

1.1 主干网络模型架构

TCN-BiGRU算法是一种结合了时序卷积网络(Temporal Convolutional Networks, TCN)和双向门控循环单元(Bidirectional Gated Recurrent Unit, BiGRU)的深度学习架构,适合处理时间序列数据的预测任务^[14]。

TCN-BiGRU的网络结构由TCN网络层^[15]、自注意力模块(Self Attention)^[16]、BiGRU模块^[17]、自回归函数(Autoregressive, AR)^[18]以及输出层组成。该网络工作的基本流程为:在输入层将原始序列平均切分为7份,再分别输入到相同的TCN网络层中,以捕捉序列之间的长期依赖。然后将TCN网络输出的隐含特征经过一个自注意力模块,给予相应权重后输入到BiGRU中,用于捕获数据间的短期依赖。最后该模型将神经网络和AR模块的输出相加产生最终的预测。TCN-BiGRU网络结构如图1所示。

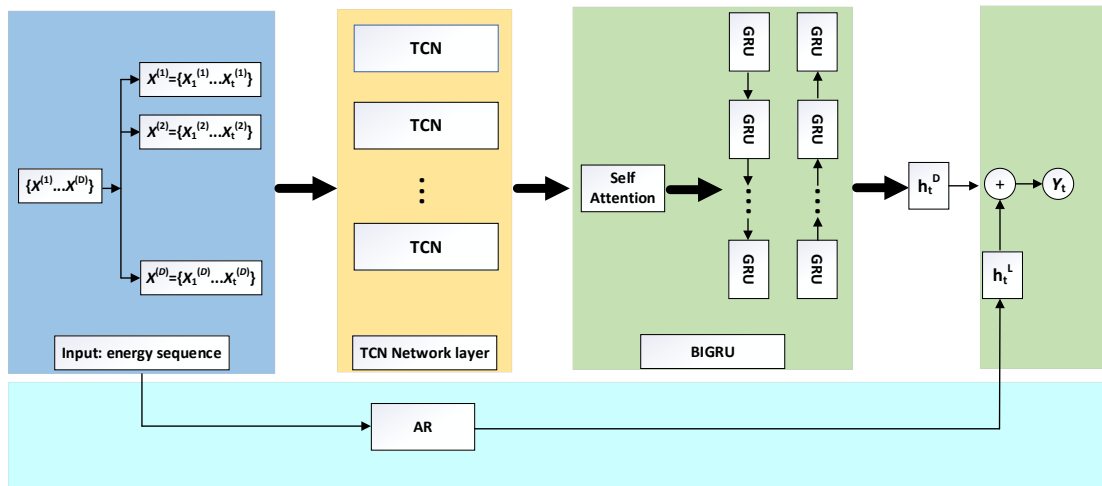


Fig. 1 Network structure of TCN-BiGRU

图1 TCN-BiGRU网络结构

其中,TCN的网络结构主要由多个层级组成,每一层都包含一系列运算和操作。卷积层使用膨胀因果卷积(Dilated Causal Conv),即当前层的值只依赖于上一层的值,而且还具备空洞卷积的特性,使得每一层对上一层信息的提取是跳跃式的,且逐层膨胀率以2的指数增长^[19]。

该结构使得TCN能够有效地处理时间序列数据,并捕捉其中的长期依赖关系。TCN还采用残差模块(Residual Block)来跨层传递信息,有助于解决梯度消失问题,提升模型性能^[20]。BiGRU由两个独立的GRU层组成,一个沿正向处理序列,另一个沿反向处理序列。这种双向结构使

得 BiGRU 能够捕捉到序列中的长距离依赖关系,从而提高模型性能。BiGRU 模型的数学原理可用式(1)表示,分别表示从左到右和从右到左的隐藏状态, X_t 表示输入序列中的第 t 个元素。将两个方向的隐藏状态拼接在一起,计算方法如式(1)~式(3)所示:

$$\vec{h}_t = GRU(\vec{h}_{t-1}, x_t) \tag{1}$$

$$\overleftarrow{h}_t = GRU(\overleftarrow{h}_{t+1}, x_t) \tag{2}$$

$$h_t = [\vec{h}_t; \overleftarrow{h}_t] \tag{3}$$




Fig. 2 Bidirectional gated cycle unit

图2 双向门控循环单元

1.2 改进算法

1.2.1 循环神经网络自编码器

本文使用循环神经网络自编码器充当线损成因特征检测器,对用户表的线损异常值进行无监督分类并标记。循环神经网络自编码器(RNN-based Autoencoder)是一种特殊的神经网络架构,其结合了循环神经网络(Recurrent Neural Network, RNN)的自编码器(Autoencoder)概念,适用于学习无标记序列数据,在学习过程中通过尝试从编码中重新生成输入数据来验证和细化编码^[21]。循环神经网络自编码器主要由两部分组成:编码器(Encoder)和解码器(Decoder)。编码器负责接收输入序列,并通过压缩这些数据创建一个低维度的表示,该过程称为编码。然后,解码器接收此低维度的表示,并尝试恢复出原始的输入序列,该过程称为解码。编码器—解码器架构如图3所示。




Fig. 3 Encoder-decoder architecture

图3 编码器—解码器架构

在无监督预训练阶段,RNN 自编码器通过自学习得到原始数据的压缩和分布式表征。其网络结构是由一个时间步长为 28 维的输入层、一个中间隐含的 RNN 网络层和一个输出层构成。输出向量维度与输入层的神经元个数相等,且训练样本集合的标签值为输入值,即无标签值。输入层到 RNN 单元之间的映射为编码过程,向量到 RNN 单元之间的映射为解码过程。在输出向量后,添加 softmax 分类器转换为概率分布,从而实现分类功能,对应预测线

损的 7 种成因。在有监督微调训练阶段,经过无监督预训练得到的 RNN 自编码器进一步利用有标签的数据进行微调,使用反向传播算法和 Adam 优化器更新模型权重与偏置项,使模型在训练数据上的损失函数最小化^[22-23]。通过这两个阶段的训练,RNN 自编码器能够学习到线损异常数据各类成因的有效表示,以供后续预测算法使用。RNN 编码器网络结构如图 4 所示。

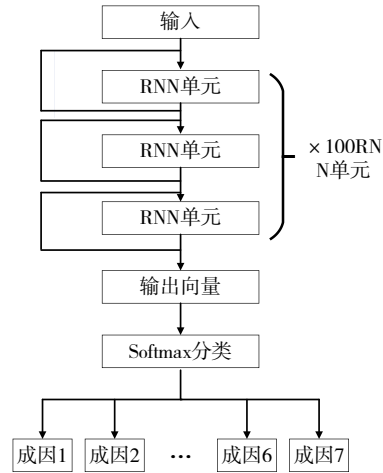


Fig. 4 RNN autoencoder network structure

图4 RNN 自编码器网络结构

1.2.2 改进后的 TCN-BiGRU 网络

台区用电总表数据是包含供电、售电、线损数据的时序数据。用户表是接入总表的用户分表数据,包含用电量、电流、电压以及温湿度环境数据。将总表数据序列合并成一个张量后送入 TCN-BiGRU 网络,输出线损预测偏差特征。同时,加入用户表特征与环境特征序列进行特征融合,输入 RNN 自编码器,通过后接一个 softmax 激活函数来归一化输出最终的线损成因概率。

改进后模型的网络结构如图 5 所示。模型输出的分支既包含预测的线损偏差,又包括线损成因概率。

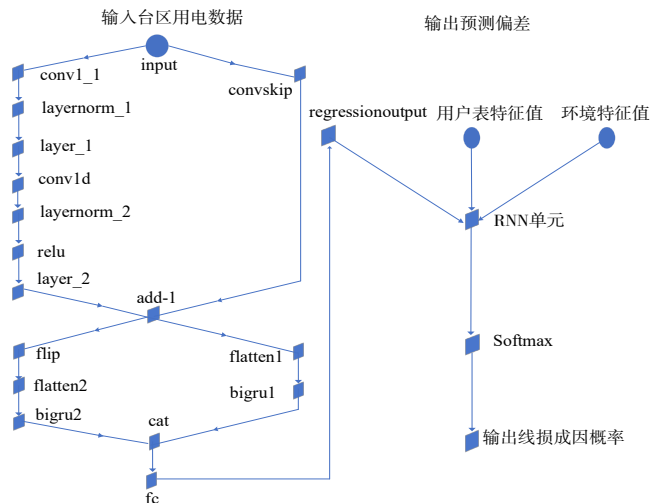


Fig. 5 Improved network structure of TCN-BiGRU algorithm

图5 改进的 TCN-BiGRU 算法网络结构

2 实验数据与平台

2.1 数据集准备

本文选用的数据是2023年某市的23 410组中低压配电网线路数据,由用电信息采集系统提供数据,主要构成包括主站系统、终端设备、电能表以及通信系统。其中,电能表包括台区总表和居民用户表,用于记录用户的用电情况。本文研究的用电原始数据均是从用电信息管理系统导出,台区表由日期、供电量、售电量、实际线损率、理论线损率以及两者偏差构成。

数据示例如表1所示。

台区理论线损率的计算方式一般使用等值电阻法,主要根据相关配电设备的参数与输电距离进行计算,其中配电设备参数包括设备型号、长度、截面积、单位电阻、单位电抗。对应的平均线损如表2所示。

对于导出的居民用电表,重点对线损异常发生后的线损成因排查工作记录作了数据标注,以便进一步使用机器学习算法进行成因预测分析。

Table 1 Station power supply line loss and deviation

表1 台区供电线损及偏差

日期	供电量/kWh	售电量/kWh	实际线损率	理论线损率	偏差
8.15	253.6	246.72	2.71	2.720 8	-0.010 8
8.16	325.6	314.55	3.39	2.720 8	0.669 2
8.17	369.2	353.58	4.23	2.720 8	1.509 2
8.18	438.0	412.86	5.74	2.720 8	3.019 2
8.19	1 293.2	1 248.78	3.43	2.720 8	0.709 2
8.20	282.8	272.17	3.76	2.720 8	1.039 2
8.21	165.2	162.36	1.72	2.720 8	-1.000 8

Table 2 Station equipment parameters and theoretical line loss rate

表2 台区设备参数及理论线损率

设备型号	长度/m	截面积/ mm ²	单位电阻/ Ω/km	单位电抗/ Ω/km	理论线损率
LGJ-35	97	35	0.823 0	0.399 0	
LGJ-150/25	16	150	0.198 9	0.353 4	
LGJ-150/25	19	150	0.198 9	0.353 4	
LGJ-150/25	12	150	0.198 9	0.353 4	0.694 6
LGJ-150/25	10	150	0.198 9	0.353 4	
LGJ-150/25	23	150	0.198 9	0.353 4	
LGJ-150/25	23	150	0.198 9	0.353 4	

表3中列出了主要的7种线损异常成因。

Table 3 Abnormal data of cause of consumer power line loss by users

表3 用户用电线损成因异常数据

成因	供电半径/m	时间	电流/A	电压/V	表计步长/kWh
末梢大电量	900	2023/8/18 21:00	42,0,0	206.3,0,0	1.94
表计进线开关冻结	100	2023/4/4 1:15:00	0,0,0	0,0,0	0
电缆分支箱接线异常	0	2023/5/12 16:30	0,0,0	218,218,218	0
时差表计	400	2023/12/31 0:00	0,0,0	0,0,0	-20.32
表计失压	500	2024/1/7 21:15:00	0,0,0	34,33,31	0.01
表计烧坏	250	2024/1/8 18:30	37,0,0	228.8,235.3,233.3	5.43
短路跳闸	300	2024/1/4 17:30	0,0,0	233.5,235.1,235.1	0

此外,考虑到全年室外的环境因素,收集了国家气象科学数据中心公布的江苏省盐城市全年的温湿度数据,数据样例如表4所示。其中,平均温度为最高温度与最低温度的平均,平均相对湿度是将每天02时、08时、14时、20时4次测量的相对湿度求平均,精确到1%。

Table 4 Temperature and humidity environmental data

表4 温湿度环境数据

日期	平均温度/°C	平均相对湿度/RH
8.15	29.9	72.6%
9.15	22.9	85.4%
10.15	17.5	65.3%

将系统导出以及收集的数据按以上规则重新整理,通过噪声添加与混合样本的方式进行数据增强。噪声添加通过向台区线损表中添加随机噪声,以增加数据集线损成因的多样性和模拟实际场景中的成因数据异常,提高模型的鲁棒性。混合样本的操作方式将不同台区设备的理论线损数据混合在一起,生成具有更广泛配电网线损特征的数据集,有助于模型学习不同台区设备参数之间的共性和差异,提高其泛化能力。处理后的整体数据集划分如表5所示。

Table 5 Data set partitioning

表5 数据集划分

数据集	数据量	训练集 占比/%	验证集 占比/%	测试集 占比/%
台区供电线损	23 410			
台区电网理论线损率	100 800	70	15	15
用户用电数据	67 200			
温湿度环境	67 200			

2.2 实验平台

算法模型的训练服务器搭载2张Nvidia Tesla T4 16 GB显存的显卡,训练采用多GPU并行的任务分配策略。操作系统版本为Ubuntu 20.04,实验程序代码使用Python语言在JupyterLab中编写运行。

3 实验结果分析

3.1 线损预测算法模型训练

将2.1所述的用电原始数据集划分为70%的训练集、15%的测试集以及15%的验证集,编写程序在服务器上对改进后的网络结构进行40周期的训练。为了保证卷积操作中的边缘信息不受损失,以及参数更新不受梯度消失的

伸缩变换影响,故选用如表 6 所示的模型训练参数。模型训练损失如图 6 所示。

Table 6 Model training parameter

表 6 模型训练参数

参数	数值
TCN 卷积核大小	7×7
步长	2
填充方式	SAME
正则化参数	L2
优化器	adam
批处理大小	50
动量	0.92
学习率	0.000 1
RNN 自编码器输入序列	14

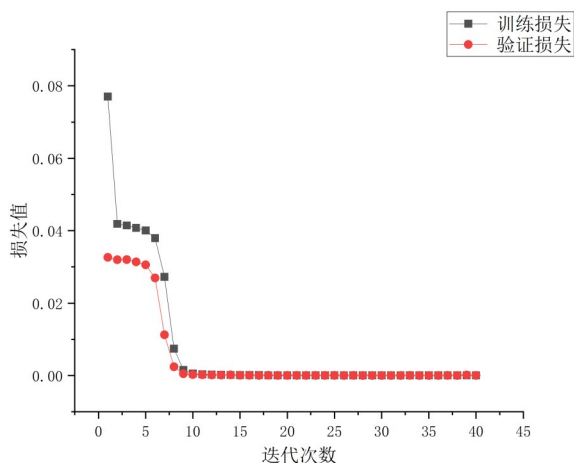


Fig. 6 Model training loss

图 6 模型训练损失

在训练过程中,模型优化目标是 minimized 预测输出与真实值之间的差距。20 轮训练后,线损率偏差序列的预测结果可达到 96.3%。图 7 使用 R² 值评估模型对线损成因类别的拟合程度,其值越接近 1,说明模型的拟合效果越好。图示 R² 值为 0.998 501 956 788 754 1, RMSE 为 0.006 875 911 639 443 464,说明模型能够很好地捕捉数据的趋势和模式。图 8 横坐标表示预测结果的数值范围及分布情况,纵坐标表示每个数值范围内的样本频率,即模型对这些数值的预测在测试数据中出现的次数。

3.2 模型推理结果与分析

在算法验证环节,首先将测试台区设备参数输入 3.1 节训练得出的理论线损模型,预测出理论线损率如表 7 所示,与标定的理论线损的误差为 5.78%。

将预测出的理论线损与表 8 中的测试供电、售电数据参数作为第一项输入,输入前文训练得出的 TCN-BiGRU 线损预测算法。第二项输入为表 9 中的用户表数据以及环境特征。

算法模型最终的输出为台区未来一段时间的预测偏差值,并对各项偏差值的线损成因进行概率分析,对比了 7、14、28 天的输入序列。每天的用户输入为 9 条 15 min 的间隔输入,输出序列的准确度对比如图 9 所示。当输入 14




Fig. 7 R² of prediction of all samples

图 7 所有样本预测 R²




Fig. 8 Line loss cause inference prediction distribution

图 8 线损成因推理预测分布

Table 7 Input parameters of station equipment

表 7 台区设备参数输入

设备型号	长度/m	截面积/ mm ²	单位电阻/ Ω/km	单位电抗/ Ω/km	预测理论线损率
LGJ-35	97	35	0.823 0	0.399 0	0.654 3 (误差 5.78%)
LGJ-35	97	35	0.823 0	0.399 0	
LGJ-35	97	35	0.823 0	0.399 0	
LGJ-35	97	35	0.823 0	0.399 0	
LGJ-35	97	35	0.823 0	0.399 0	
LGJ-150/25	16	150	0.198 9	0.353 4	
LGJ-150/25	19	150	0.198 9	0.353 4	
LGJ-150/25	12	150	0.198 9	0.353 4	
LGJ-150/25	10	150	0.198 9	0.353 4	
LGJ-150/25	23	150	0.198 9	0.353 4	
LGJ-150/25	23	150	0.198 9	0.353 4	

日的数据作为自编码器的输入序列,模型输出序列预测与真值偏差不影响线损异常与否的分类判别。

3.3 验证实验结果分析

改进后的 TCN-BiGRU 算法与其他线损预测算法的 RMSE 比较如表 10 所示。

改进后的 TCN-BiGRU 算法与其他线损成因算法的准确率比较如表 11 所示。

实验结果表明,与传统的配电网线损预测方法相比,

Table 8 Input1: test data of stage

表8 输入1:台区测试数据

日期	供电量/kWh	售电量/kWh	实际线损率	理论线损率	偏差
1.1	244.6	241.19	1.39	2.720 8	-1.330 8
1.2	229.6	217.53	5.26	2.720 8	2.539 2
1.3	263.5	255.38	3.08	2.720 8	0.359 2
1.4	394.0	382.86	2.83	2.720 8	0.109 2
1.5	1 293.2	1 248.78	3.43	2.720 8	0.709 2
1.6	282.8	272.17	3.76	2.720 8	1.039 2
1.7	155.8	151.29	2.89	2.720 8	0.169 2

Table 9 Input2: test data of user table

表9 输入2:用户表测试数据

时间	供电半径/m	温度/°C	湿度/RH	电流/A	电压/V	表计步长/kWh
2023/1/1 21:00	250	3	43%	33.536,0,0	206.3,0,0	0.06
2023/1/1 21:15	250	3	43%	1.768,0,0	225.5,0,0	0.22
2023/1/1 21:30	250	3	43%	1.752,0,0	225.6,0,0	0.03
2023/1/1 21:45	250	3	43%	1.784,0,0	225.3,0,0	0.03
2023/1/1 22:00	250	3	43%	35.672,0,0	225.2,0,0	0.33
2023/1/1 22:15	250	3	43%	37.124,0,0	228.8,0,0	0.50
2023/1/1 22:30	250	3	43%	36.256,0,0	233.5,0,0	0.52




Fig. 9 Comparison of output sequence accuracy

图9 输出序列准确度比较

Table 10 Comparison of RMSE among the improved TCN-BiGRU algorithm and other line loss prediction algorithms

表10 改进后的TCN-BiGRU算法与其他线损预测算法RMSE比较

指标	EMD-LSTM	PSO-CNN	改进后的TCN-BiGRU
RMSE	0.043 87	0.010 90	0.006 88

Table 11 Comparison of the accuracy among the improved TCN-BiGRU algorithm and other line loss cause algorithms

表11 改进后的TCN-BiGRU算法与其他线损成因算法准确率比较

指标	ResNet50	DBN-DNN	改进后的TCN-BiGRU
准确率/%	95.600	91.259	97.100

本文提出的线损预测方法的均方根误差相较于传统的LSTM与PSO-CNN算法分别降低了0.002 04和0.004 02,针对线损成因分析的准确率相较于ResNet50与DBN-DNN算法分别提高了1.500%和5.841%,具体体现在以下两方面:

(1)融合环境特征的线损成因分析相比单独使用循环

神经网络对用户表进行成因分析的准确率得到明显提升,进一步验证了台区总线损与分表用户的关联关系。

(2)在推理阶段根据7、14、28天的输入序列,且每天的用户输入为9条间隔15 min的输入,其中加入了环境特征信息的14天范围预测的线损异常分类值最高,说明本文算法针对台区用电各项数据进行小批量高频次地实时分析预测,有助于提高配电网的管理效率。

4 结语

针对目前台区线损计算精度不足、线损成因分析困难、台区缺乏精益化管理等问题,提出基于自编码器与时域卷积神经网络算法的配电网线损分析算法。首先在TCN中融入BiGRU单元,提升线损的预测精度;然后结合循环神经网络自编码器,可以有效捕捉序列数据时间依赖性和复杂结构的特点,对线损异常值进行无监督分类并标记,通过softmax损失函数预测线损率异常原因并及时制定降损措施。实验结果表明,改进后的TCN-BiGRU算法不仅实现了对线损的合理预测,而且提高了线损成因的判定概率。然而,对于小电量损失的台区还存在易漏查、忽略的情况。后续将引入理论线损计算和两率偏差的筛选条件,将对大量台区的电气数据参数及线损数据进行训练,并结合现场情况评估真实性。

参考文献:

- [1] LI H M. Application research of intelligent robot inspection system in substation [D]. Guangzhou: Guangdong University of Technology, 2020. 李焕明. 智能机器人巡检系统在变电站的应用研究[D]. 广州: 广东工业大学, 2020.
- [2] ZHONG X Q, CHEN J, JIANG M M, et al. Station line loss analysis method based on deep learning [J]. Power Grid Technology, 2020, 44(2): 769-774. 钟小强, 陈杰, 蒋敏敏, 等. 基于深度学习的台区线损分析方法[J]. 电网技术, 2020, 44(2): 769-774.
- [3] ZHANG Q, MA W, FU J, et al. Calculation method of line loss of medium voltage distribution network planning state [J]. Electrical Technology, 2018, 19(2): 42-45. 张勤, 马玮, 付锦, 等. 中压配电网规划态线损计算方法[J]. 电气技术, 2018, 19(2): 42-45.
- [4] CHEN D Z, GUO Z Z. Theoretical line loss calculation of distribution network based on load acquisition and matched power flow method [J]. Power Grid Technology, 2005(1): 80-84. 陈得治, 郭志忠. 基于负荷获取和匹配潮流方法的配电网理论线损计算[J]. 电网技术, 2005(1): 80-84.
- [5] ZOU Y F, MEI F, LI Y, et al. Research on reasonable line loss prediction model of station area based on data mining technology [J]. Electric Power Demand Side Management, 2015, 4(17): 25-29. 邹云峰, 梅飞, 李悦, 等. 基于数据挖掘技术的台区合理线损预测模型研究[J]. 电力需求侧管理, 2015, 4(17): 25-29.
- [6] YANG Q Y, REN G L. Calculation and analysis of line loss in distribution network [J]. Proceedings of the CSEE, 1985(1): 61-65. 杨期余, 任国梁. 配电网的线损计算与分析[J]. 中国电机工程学报,

- 1985(1):61-65.
- [7] YANG X T. Theoretical calculation and analysis of power network line loss [M]. Beijing: Water Resources and Electric Power Press, 1985.
杨秀台. 电力网线损的理论计算和分析[M]. 北京:水利电力出版社, 1985.
- [8] XU R Z, WANG Y F. Theoretical line loss calculation method of distribution network based on particle swarm optimization support vector regression [J]. Electric Power Automation Equipment, 2012, 32(5): 86-89,93.
徐荔枝, 王宇飞. 粒子群优化的支持向量回归机计算配电网理论线损方法[J]. 电力自动化设备, 2012, 32(5): 86-89,93.
- [9] ZHANG Y T, WANG Z Z, LIU L P, et al. Line loss prediction of 10 kV distribution network based on grey correlation analysis and improved neural network [J]. Power Grid Technology, 2019, 43(4): 1404-1410.
张义涛, 王泽忠, 刘丽平, 等. 基于灰色关联分析和改进神经网络的10 kV配电网线损预测[J]. 电网技术, 2019, 43(4): 1404-1410.
- [10] MA L Y, LIU J H, LU Z G, et al. Theoretical line loss calculation method in low voltage region based on deep confidence network [J]. Electric Power Automation Equipment, 2020, 40(8):140-146.
马丽叶, 刘建恒, 卢志刚, 等. 基于深度置信网络的低压台区理论线损计算方法[J]. 电力自动化设备, 2020, 40(8):140-146.
- [11] WU K C, QU Y, CHEN Q, et al. Calculation and method of fast line loss considering station load ratio [J]. Guangdong Electric Power, 2020, 33(11): 51-59.
吴科成, 曲毅, 陈荃, 等. 考虑台区负载率的快速线损测算与方法[J]. 广东电力, 2020, 33(11): 51-59.
- [12] CHEN H T, CAI H, LI X, et al. Detection method of line loss anomaly in low pressure region based on k-means clustering algorithm [J]. China Southern Power Grid Technology, 2019, 13(2):2-6.
陈洪涛, 蔡慧, 李熊, 等. 基于k-means聚类算法的低压台区线损异常辨别方法[J]. 南方电网技术, 2019, 13(2):2-6.
- [13] LI X Q, ZHAO L N, MENG Q R, et al. Theoretical line loss calculation of distribution network based on IGA optimization [J]. Journal of Electric Power Systems and Automation, 2009, 21(5): 87-91.
李秀卿, 赵丽娜, 孟庆然, 等. IGA优化的神经网络计算配电网理论线损[J]. 电力系统及其自动化学报, 2009, 21(5):87-91.
- [14] LIU S Q, LI S, MIAO J G, et al. Health status assessment of lithium-ion batteries based on TCN-BiGRU [J]. Electronic Measurement Technology, 2023, 46(23): 68-76.
刘少卿, 李帅, 苗建国, 等. 基于TCN-BiGRU的锂离子电池健康状态评估[J]. 电子测量技术, 2023, 46(23):68-76.
- [15] ZHANG J F, YE L, WANG L. Deformation prediction method of concrete dam based on TCN and transfer learning [J]. Yellow River, 2024, 46(4):142-147.
张健飞, 叶亮, 王磊. 基于TCN和迁移学习的混凝土坝变形预测方法[J]. 人民黄河, 2024, 46(4):142-147.
- [16] SUN Y G, WU F, YAO J F, et al. Multi-scale self-attention feature fusion method for tea disease detection [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12):308-315.
孙艳歌, 吴飞, 姚建峰, 等. 多尺度自注意力特征融合的茶叶病害检测方法[J]. 农业机械学报, 2023, 54(12):308-315.
- [17] WEI X, WANG Z F. Human activity recognition model based on multi-scale convolution and BiGRU networks [J]. Journal of Computer Applications, 2023, 43(S2):72-76.
魏雄, 王子樊. 融合多尺度卷积和BiGRU网络的人类活动识别模型[J]. 计算机应用, 2023, 43(S2):72-76.
- [18] ZHOU Y. Research on online video surveillance based on vector autoregression model [D]. Shanghai: East China Normal University, 2023.
周悦. 基于向量自回归模型的在线视频监控研究[D]. 上海:华东师范大学, 2023.
- [19] ZHANG Z Z. Research on location method of water pipe network leakage period based on time domain convolution and position regression [D]. Xi'an: Xi'an University of Technology, 2024.
张珍珍. 基于时域卷积和位置回归的水管网渗漏时段定位方法研究[D]. 西安:西安理工大学, 2024.
- [20] WANG X T, WANG X, SUN Z X. Network traffic anomaly detection model based on multi-scale memory residual network [J]. Computer Science, 2022, 49(8): 314-322.
王馨彤, 王璇, 孙知信. 基于多尺度记忆残差网络的网络流量异常检测模型[J]. 计算机科学, 2022, 49(8):314-322.
- [21] HE M Q. Research and application of component remaining life prediction based on recurrent neural network autoencoder [D]. Beijing: Beijing Jiaotong University, 2023.
何孟琪. 基于循环神经网络自编码器的零部件剩余寿命预测研究与应用[D]. 北京:北京交通大学, 2023.
- [22] LI T J, SUN J H, WANG L. An intelligent optimization method of motion management system based on BP neural network [J]. Neural Computing and Applications, 2021, 33(2): 707-722.
- [23] LIU H D, LI X C, ZHANG W H, et al. Research on the application of improved Adam optimizer in gas emission prediction [J]. Industrial and Mining Automation, 2023, 49(12): 25-32.
刘海东, 李星诚, 张文豪, 等. 改进Adam优化器在瓦斯涌出量预测中的应用研究[J]. 工矿自动化, 2023, 49(12):25-32.

(责任编辑:黄健)