

DOI:10.13296/j.1001-1609.hva.2024.12.018

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

黄悦华, 张子豪, 陈庆, 刘兴韬, 涂金童

(三峡大学电气与新能源学院, 湖北 宜昌 443002)

摘要: 为了研究考虑高海拔多环境因素影响下输电线路可听噪声的预测问题,在海拔2 400 m高度点的500 kV同塔双回线路下,搭建了边相外20、30、35 m三处可听噪声观测站,同时利用气象站进行多环境因素指标的数据采集。文中提出了一种基于多头注意力机制(multi-head attention, MHA)的卷积神经网络(convolutional neural network, CNN)—双向长短期记忆网络(bi-directional long short term memory, BiLSTM)模型进行可听噪声预测。首先,采用皮尔逊相关性分析对多种环境因素数据进行相关程度计算比较与剔除;然后,为充分挖掘可听噪声数据中的时序特征,使用CNN对多环境因素数据进行特征提取;再将提取的特征向量输入到BiLSTM中进行训练,并通过在BiLSTM端引入多头注意力机制,使模型学习权重更高的数据特征,从而提升模型预测精度;结果表明,该方法构建的组合模型可以提升考虑多因素特征可听噪声数据的预测精度,且具有较好的泛化性。

关键词: 输电线路可听噪声; 多环境因素; 卷积神经网络; 双向长短期记忆网络; 多头注意力机制

Prediction of Audible Noise of CNN-BiLSTM High Altitude Multi-factor Transmission Line Based on Multi-head Attention Mechanism

HUANG Yuehua, ZHANG Zihao, CHEN Qing, LIU Xingtao, TU Jintong

(College of Electrical Engineering and New Energy, China Three Gorges University, Hubei Yichang 443002, China)

Abstract: To study the prediction of audible noise of transmission lines under the influence of multiple environmental factors at high altitudes, such three audible noise observation stations as 20 m, 30 m and 35 m away from the side phase are set up under the 500 kV double-circuit line on the same tower at the altitude of 2 400 m. At the same time, the meteorological station is used to collect data on multiple environmental factors. In this paper, a kind of convolutional neural network(CNN)-bi-directional long short-term memory(BiLSTM) model based on the multi-head attention(MHA) mechanism is proposed for audible noise prediction. Firstly, the Pearson correlation analysis is used for calculation, comparison and elimination of correlation degree of various environmental factors data. Then, in order to fully mine the temporal features of the audible noise data, CNN is used for feature extraction of the multiple environmental factors data. Then, the extracted feature vectors are input to BiLSTM for training, and the multi-head attention mechanism is introduced at the BiLSTM side to make the model learn data features with higher weight, thus improving the prediction accuracy of the model. The results show that the combined model constructed by this method can improve the prediction accuracy of the audible noise data considering multi-factor features and has good generalization.

Key words: audible noise of transmission line; multi-environmental factors; convolutional neural network; bi-directional long short-term memory; multi-head attention

收稿日期:2024-09-12; 修回日期:2024-11-15

基金项目:国家自然科学基金资助项目(52007103);国家电网有限公司总部科技项目(SGSCDK00HBJS2100038)。

Project Supported by National Natural Science Foundation of China(52007103), Science and Technology Project of the Headquarters of State Grid Corporation (SGSCDK00HBJS2100038).

0 引言

高压输电走廊呈现覆盖地域广、海拔跨度大、气候环境多变等特征,其中高海拔极端差异化环境因素影响是发展输电技术面临的不可避免地问题。一方面,相较于平原地区,高海拔地区的输电线路可听噪声受多环境因素影响。在线路参数相同的情况下,空气密度较低的高海拔输电线路的电晕放电现象更为严重^[1-2],将会影响线路架设区域电磁环境,特别是可听噪声问题^[3]。另一方面,电晕放电产生的可听噪声水平是高海拔超、特高压输电线路结构设计、导线选型、运行维护和线路走廊拆迁范围的主要考虑因素之一。因此,深入开展高海拔电磁环境特性研究,合理预测与控制高海拔地区输电线路的可听噪声水平,对于减小环境影响、提高高压输电实际工程设计水平、推动中国能源远距离输送意义重大。

在考虑海拔对输电线路可听噪声特性影响与预测的研究方面^[4],文[5]提出了交流输电线路 1 dB/300 m 修正系数的线性关系海拔修正方法,但不同导线电晕特性不同,该方法的场景适用性存在较大争议;文[6-8]开展了多个海拔高度点的输电线路可听噪声试验研究工作,通过分析可听噪声数据随海拔变化的规律,分别提出了超高压直流与交流线路可听噪声计算的海拔修正公式;文[9-10]针对某特定海拔高度的特高压直流输电线路展开试验研究,得到了海拔 2 100 m 条件下可听噪声分布规律和水平计算海拔修正系数,提出了考虑气象参数的直流线路无线电干扰和可听噪声的预测式。但现有研究往往以低海拔数据简单外推获得高海拔参数或者采用简单的线性拟合方法计算修正,完全忽视了高海拔地区风速、湿度、太阳辐射、紫外线等气象因素的影响,这种简单外推的预测式未经实测数据检验,工程应用会造成电磁环境参数超标或经济性差的问题。

目前,可听噪声预测方法主要包含模拟计算软件预测方法^[11]和经验公式预测方法^[12-14]。但软件预测缺少可听噪声的差异化频谱数据库,会导致预测精度无法满足不同场景输电线路的实际需求;基于传统数学公式的经验公式预测虽然计算简单,但对于数据具有较强随机性和波动性的预测场景并不适用。输电线路可听噪声预测依赖的历史数据体量较大、时序性强,受多维因素影响使其具有非线性、非平稳性等特征,上述预测方法往往难以满足考虑多维因素特征数据预测的需求。在风电功率

预测^[15]、变压器中溶解气体浓度预测^[16]、短期电力负荷预测^[17]等的时序数据场景中采用了 LSTM 或 BiLSTM 模型进行预测,结果表明该深度神经网络比其他方法预测精度更高,且 BiLSTM 对强调顺序的数据表达能力更强。该类模型也适用于同样具备时序特征的输电线路可听噪声数据预测,但模型复杂的网络结构往往导致训练时间较长,且缺乏对影响因素历史数据中的多维特征的预处理,难以完全描述可听噪声受多因素影响的数据变化规律。而文[18-19]提出一种基于 CNN-BiLSTM 的组合模型,利用 CNN 的卷积核逐层挖掘相邻数据间的共性规律并进行多个特征提取后,再使用 BiLSTM 对应用场景数据进行预测,相较于单一的 BiLSTM 模型,预测精度有明显提升。但在模型训练过程中由于权重分配不均的问题,会造成输入特征中的重要信息丢失,文[20-22]提出了一种基于 CNN-BiLSTM-Attention 的预测模型,并验证了该模型具有更高的预测精度。文[23]提出一种基于多头注意力机制的预测方法,其多头注意力通过对输出结果加权处理,拼接最终结果,使得预测效果更佳,作为一种有效提升可听噪声预测精度的方法。

综上所述,文中提出一种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方法。首先,利用皮尔逊相关性分析方法对可听噪声与其影响因素的相关系数进行计算与比较,并剔除弱相关参数;其次,利用 CNN 网络提取特征向量,再利用 BiLSTM 网络进行双向循环训练;进一步,通过引入多头注意力机制自动为 BiLSTM 端分配相应的权重并进行加权求和,最终输出可听噪声预测结果。最后,利用某交流输电线路实测可听噪声数据进行预测研究,研究结果显示,使用多头注意力机制的 CNN-BiLSTM 模型在多维输入特征数据下相比其他基线模型具有更高的预测准确性。

1 高海拔地区可听噪声数据采集与分析

1.1 可听噪声数据监测站描述

由于高海拔地区输电线路导线发生电晕现象的环境影响因素众多,同时还具有随机性与波动性的特点,导致电晕放电产生的可听噪声水平精细化理论研究非常困难。因此,文中研究主要以周期性监测高海拔可听噪声及其影响因素的数据为基础,并开展规律分析与预测工作。在位于海拔 2 420 m 的四川省凉山州盐源县搭建了长期观测站,该站位于 500 kV 同塔双回线路 315-316 号杆塔之间,周围地势较为平坦,测点地势开阔、周围空旷,可保证测

量工作正常开展,测点场景见图1。按照DL/T 501—2017《高压架空输电线路可听噪声测量方法》要求,分别在边相导线投影外20、30、35 m处布置可听噪声传声器及相关监测设备。




图1 盐源观测站测量现场

Fig. 1 Scenarios of measuring points at Yanyuan station

观测站设备部署及监测线路结构见图2。气象站和天气现象仪分别布置在边相导线投影外30、35 m处,用来获取所处环境的监测数据。气象参数由DAVIS Vantage Pro2 Plus便携式气象站进行采集,通过气象传感器完成各种气象信息数据(如风向、风速、空气温度、空气湿度、气压、雨量等)的自动采集和存储。而对于雨、雪、雾等天气状况以及降雨起始、终止时刻的判别,主要依据CJY-2C/T型天气现象仪测量数据。户外测量设备通过电缆连接的不间断电源(uninterruptible power supply, UPS)持续供电,其获取的海量数据通过有线—无线通信通道传送至多通道分析仪及计算机的数据采集单元,最终采集的数据均通过计算机内置PULSE软件对进行分类存储、分析处理、在线显示和远程读取。




图2 盐源站设备布置情况

Fig. 2 Equipment layout of Yanyuan station

选取监测时间从2022年2月19日开始至2022年6月22日的输电线路可听噪声及其16种潜在环境影响因素的实测数据,每1 min获取一组数据。并对仪器校准时的无效数据以及异常记录数据进行剔除,如,根据GB 3096—2008《声环境质量标准》要求,为减小大风对可听噪声测量结果的异常影响,统计数据中已剔除了风速在5 m/s以上的监测数据。最终,处理得到168 562组有效数据作为本文研究的样本数据集。

1.2 高海拔多环境因素相关性分析

高海拔地区影响输电线路可听噪声的环境因素较多,且各种因素对可听噪声影响的强弱程度有所不同,可将其分为直接相关影响因素和间接相关影响因素。在直接影响因素方面,温度、湿度的变化会引起空气密度改变,有利于碰撞电离的产生,造成导线起晕电压的上升或下降,从而影响可听噪声的变化^[8];风速的增加会使导线周围的空间电荷快速电离和复合,导致电晕产生的可听噪声增加;1 min雨量变大时,雨水的存在使周边电场分布发生畸变,且随着雨水的增多,电晕放电加剧,可听噪声变大^[24]。在间接影响因素方面,露点、风向、风寒指数等环境因素会对温度、湿度、风速、1 min雨量造成影响,进而影响可听噪声变化。在可听噪声的预测中若将直接、间接影响因素进行全部考虑会使得计算量增大,因此,在进行可听噪声预测之前,对输入预测模型的环境因素数据进行相关性分析,剔除相关性较低的影响因素,从而有效减小可听噪声预测模型的计算量。皮尔逊相关系数能够准确反应变量间的相关性,文中采用该系数评判可听噪声与其影响因素之间的关系。

设可听噪声数据 p 和某环境影响因素数据 q 的数据集(n 为时间序列长度)形式分别为: $p = \{p_1, p_2, \dots, p_i, \dots, p_n\}$, $q = \{q_1, q_2, \dots, q_i, \dots, q_n\}$,两组数据集之间的皮尔逊相关系数计算为

$$r = \frac{\sum_{i=1}^n (p_i - \bar{p})(q_i - \bar{q})}{\sqrt{\sum_{i=1}^n (p_i - \bar{p})^2} \sqrt{\sum_{i=1}^n (q_i - \bar{q})^2}} \quad (1)$$

式(1)中: $\bar{p}$ 和 $\bar{q}$ 分别为两组数据集的数值均值; r 为皮尔逊相关系数,取值为 $[-1, 1]$ 。 r 的取值区间见表1。由表1可知, r 用来描述 p 和 q 间线性相关强弱的程度,且 r 的绝对值越大, p 和 q 线性相关的程度越强。若 $r > 0$,反映 p 和 q 为正相关关系;若 $r = 0$,则表示 p 和 q 不相关;若 $r < 0$,反映 p 和 q 为负相关关系。

表1 r 值区间

r 值(绝对值)	相关性
0.8~1.0	极强相关
0.6~0.8	强相关
0.4~0.6	中等程度相关
0.2~0.4	弱相关
0.0~0.2	极弱相关或无相关

将采集的16种可能影响因素分别与可听噪声进行皮尔逊相关系数计算,来筛选确定可听噪声的相关影响因素,见图3。在计算过程中,将系数绝对值低于0.2的影响因素进行剔除,由图3可知,可听噪声相关影响因素分别为温度、湿度、露点、风速、风向、风寒指数、炎热指数、太阳辐射、紫外线指数、天气现象、1 min 雨量。各个相关影响因素的特征描述见表2。风向由数字替代为:东(E=1)、南(S=2)、西(W=3)、北(N=4)、东北(NE=5)、东南(SE=6)、西南(SW=7)、西北(NW=8)、东北东(NNE=9)、东东北(ENE=10)、东东南(ESE=11)、南东南(SSE=12)、北西北(NNW=13)、西西北(WNW=14)、西西南(WSW=15)、南西南(SSW=16);天气现象由数字替代为:无降雨=1、小雨=2、中雨=3、大雨=4、小毛毛雨=5、强毛毛雨=6、轻雾=7、浓雾=8、雾霾=9、重度冰雹=10、小雪=11、中雪=12、大雪=13。以便后续预测模型使用。




图3 影响因素相关性分析

Fig. 3 Correlation analysis of influencing factors

2 输电线路可听噪声预测方法

高海拔多环境因素影响下的输电线路可听噪声预测,需要考虑时间维度数据信息关联、数据多维特征有效提取以及海量数据快速处理的问题。CNN 可有效地从多环境因素中提取复杂的局部特征;BiLSTM 可捕捉可听噪声时序数据中的长期依赖

表2 特征参数

参数	数值变化区间	描述
温度/ $^{\circ}\text{C}$	$[-5,30]$	冷热程度的物理量
湿度/%	$[-6,99]$	空气中所含水蒸气量
露点/ $^{\circ}\text{C}$	$[-19,20]$	气压一定的情况下,空气冷却达到饱和时的温度
风速/ $(\text{m}\cdot\text{s}^{-1})$	$[0,5]$	空气相对于测量点的运动速率
风向	—	风吹向测量点的方向
风寒指数/ $(\text{kcal}\cdot\text{m}^{-1})$	$[-5,30]$	表征风速与降温关系的物理量
炎热指数/ $^{\circ}\text{C}$	$[-5,30]$	热应力的舒适指标
太阳辐射/ $(\text{MJ}\cdot\text{m}^{-2})$	$[0,1\ 400]$	太阳以电磁波的形式传递能量
紫外线指数/ $(\text{W}\cdot\text{m}^{-2})$	$[0,16]$	电磁波谱中波长从 10 nm 到 400 nm 辐射的总称
天气现象	—	—
1 min 雨量/mm	$[0,9]$	1 min 雨水降落到测量点的水层深度

关系与不同时段的信息;引入多头注意力机制可有效地提高预测模型的计算速度。因此,在可听噪声时序预测任务中,结合三者优势并使用串联方式形成的组合模型 CNN-BiLSTM-MHA,可更全面地理解可听噪声数据的结构和关联,捕捉数据局部和全局的信息,同时提升数据预测的速度与精度。

如图4所示,对输电线路可听噪声预测时需要考虑的多维环境因素进行分析和筛选,选取了温度、湿度、露点、风速、风向等11种环境因素变量构成多维特征输入。首先,11维环境影响因素特征的时间序列作为1D-CNN模型的输入,通过卷积层融合多维环境变量,并经过池化层减少特征维度,对数据序列进行数据融合与特征提取;在池化层后接入Dropout层,使模型中的神经元随机停止工作来防止过拟合,提高模型的泛化能力。然后,选用BiLSTM网络对CNN池化层输出的特征序列进行双向循环训练,在时间维度上提取可听噪声变化特征,并实现输电线路可听噪声初步预测。进一步地,通过多头注意力机制获取时间序列数据信息,使模型集中学习更重要的数据特征,并为重要的特征分量赋予更大的权重,使模型获得更全面、更细致的特征信息。最后,通过全连接层输出最后结果。

2.1 基于CNN的特征提取技术

CNN模型利用局部连接和权值共享的方法,通




图4 基于多头注意力机制的CNN-BiLSTM模型预测流程图

Fig. 4 Flow chart of CNN-BiLSTM model prediction based on multi-head attention mechanism

过滑动窗口的方式局部感知数据,可有效地从环境因素中提取复杂的局部特征。CNN基本结构见图5。主要由输入层、卷积层、池化层和全连接层组成^[22]。在卷积层中,利用卷积核进行数据的有效非线性局部特征提取,通过神经元的局部连接和卷积核的权值共享,可以显著减少训练过程中所需的参数数量,并提高模型的训练速度。池化层通过压缩提取的特征并生成更重要的特征信息,可减轻模型过拟合程度、提高特征数据的提取效率。

2.2 BiLSTM网络的预测模型

LSTM是一种广泛应用于时间序列预测的神经网络,其可让时间序列中的关键信息进行有效的更新和传递。其模型结构见图6,其中包含控制记忆单元状态的遗忘门、输入门和输出门。遗忘门用于选择性地遗忘记忆单元状态中的无用历史信息,输




图5 CNN模型结构

Fig. 5 CNN model structure

入门决定当前输入数据对记忆单元状态的影响程度,输出门决定输出信息。LSTM网络计算过程为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_x \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \quad (5)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = O_t \otimes \tanh C_t \quad (7)$$

式(2)-(7)中: x_t 为输入序列; h_{t-1} 为 $t-1$ 时刻的隐藏层状态; f_t 、 i_t 、 O_t 分别为 t 时刻遗忘门、输入门、输出门的状态; C_{t-1} 为 $t-1$ 时刻的细胞状态; $\tilde{C}$ 为输入门 t 时刻记忆单元的临时状态; C_t 为得到新细胞状态; W_f 、 W_i 、 W_x 、 W_o 分别为遗忘门、输入门、细胞状态、输出门的权重矩阵; b_f 、 b_i 、 b_c 、 b_o 分别为遗忘门、输入门、细胞状态、输出门的偏置项; h_t 为输出值; $\sigma(\cdot)$ 为 sigmoid 激活函数; $\tanh$ 为双曲正切激活函数; $\otimes$ 为 Hadamard 乘法。




图6 LSTM记忆单元结构

Fig. 6 Structure of LSTM memory cell

然而,输电线路可听噪声在LSTM模型预测中按照时间序列从前到后进行传播训练,此方法无法充分挖掘出数据间的内在联系,而BiLSTM模型由前向传播和反向传播的双向循环结构组合,使得过去和未来的隐藏层状态都可以进行递归反馈。其结构见图7。BiLSTM网络通过合理利用前、后时刻

信息,充分挖掘当前时刻与过去、未来时刻数据的内在联系,能够有效提升可听噪声数据的利用率。




图7 BiLSTM网络模型结构

Fig. 7 Structure of BiLSTM network model

前向 LSTM、后向 LSTM 的隐藏层更新状态以及 BiLSTM 最终输出过程为

$$\begin{cases} h_t^R = f^R(\omega_1 x_t + \omega_2 h_{t-1}^R) \\ h_t^L = f^L(\omega_3 x_t + \omega_4 h_{t+1}^L) \\ y_t = f(\omega_5 h_t^R + \omega_6 h_t^L) \end{cases} \quad (8)$$

式(8)中: h_t^R 、 h_t^L 分别为 t 时刻的前向传播层、后向传播层的输出; ω_1 、 ω_3 分别为输入层到前向和后向传播层的权值矩阵; ω_2 、 ω_4 分别为前向、后向传播层到自身传播层的权值矩阵; ω_5 、 ω_6 分别为前向和后向传播层到输出层的权值矩阵; y_t 为最终输出门的输出值; f^R 、 f^L 为前向 LSTM 层和后向 LSTM 层的激活函数; 函数 f 为对前向、后向传播结果进行拼接的函数。

2.3 多头注意力机制

针对 BiLSTM 模型训练过程中,因序列过长而丢失信息的问题,因此引入多头注意力机制作为 BiLSTM 的补充,更有效地对存在关联性的时间序列长距离数据特征进行挖掘。其将 BiLSTM 输出的向量通过 3 次不同的映射操作分别转换成 3 个维度均为 d_k 的输入矩阵: 查询 Q (Query)、键 K (Key) 和值 V (Value),其注意力输出矩阵为

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

式(9)中, d_k 为各键的特征维度,用于权重缩放,经 softmax 归一化至 $[0, 1]$ 区间。

多头注意力机制将时间序列分为 h 个子空间,每个头对子空间进行自注意力计算,进而增强其表达能力。然后,将 h 个头的结果进行拼接和集成,得到多个 head, 将每个 head 进行拼接,通过线性变换得到最终结果。

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (10)$$

式(10)中, W_i^Q 、 W_i^K 、 W_i^V 分别表示 Q 、 K 、 V 的权重矩阵。

$$MultiHead(Q, K, V) = \text{Concat}(head_1, \dots, head_h)W^o \quad (11)$$

式(11)中: W^o 表示线性变换的权重; $head_i$ 表示多头注意力模块中的第 i 个头; Concat 代表拼接操作; $MultiHead(Q, K, V)$ 为最后输出结果,能够从不同空间学习到更多的特征信息,多头注意力将原来单个自注意力结构扩展为 h 个,其模型结构见图 8。




图8 多头注意力机制结构

Fig. 8 Multi headed attention mechanism structure

3 实验分析

本实验硬件平台为 11th Gen Intel(R) Core(TM) i7 - 11800H @ 2.30GHz, 显卡为 NVIDIA GeForce GTX 3060 Laptop GPU, 软件程序基于 pytorch 深度学习库采用 python 编写。

为验证文中预测模型对预测精度提升的有效性,分别建立 BiLSTM、CNN-BiLSTM、BiLSTM-MHA、CNN-BiLSTM-MHA 模型进行预测实验对比。将数据集按照 6:2:2 的比例进行训练集、验证集、测试集的划分,其中验证集被用于训练过程中的参数调整,测试集则作为最后的模型评估。

为消除不同量纲对预测结果的影响,需要对表 2 中的温度、湿度、露点、风速等 11 种特征数据以及可听噪声数据进行归一化处理。采用文[25]的 min-max 标准化将数据归一化到 $[0, 1]$, 利用归一化后的数据输入预测模型得到的预测结果,再对其进行反归一化,得到真实的预测结果。

采用预测模型中常使用的评价指标: 均方根误差 RMSE (root mean square error)、平均绝对误差 MAE (mean absolute error) 和平均绝对百分比误差 MAPE (mean absolute percentage error) 对模型性能进行评估,计算公式见文[26]。

3.1 参数设置对模型的影响

由于模型为组合改进模型,所以各个模型参数设置的适配性会对模型性能产生较大影响,因此必须对预测模型各个网络层的参数设置进行实验。首先,单独采用 BiLSTM 模型对可听噪声数据进行训练,分析 BiLSTM 网络神经元个数对模型预测结

果的影响,确定 BiLSTM 网络的最佳参数,其预测结果见表3。从表3可知,当 BiLSTM 神经元个数为64时 $RMSE$ 、 MAE 、 $MAPE$ 值表现最好。然后, BiLSTM 网络参数不变,通过分析 CNN 网络中卷积核的数量以及卷积步长,可以研究其对模型预测结果的影响,并找出 CNN 特征提取模块的最佳参数配置。将卷积步长设置为1,不断调整卷积核个数进行多次训练,其预测结果见表4。由表4可知,当卷积核个数为128时模型效果最好。不同卷积步长下 CNN-BiLSTM 模型预测结果见表5。由表5可知,当卷积核个数为128,卷积步长为1时,模型性能最好。同理可得到池化层尺寸为2,步长为1。最终确定所提预测模型以及其他对比预测模型在验证集上的最佳参数设置见表6。

表3 不同神经元下 BiLSTM 模型的预测结果

Table 3 Prediction results of BiLSTM model under different neurons

神经元个数	$RMSE$	MAE	$MAPE$
8	2.576	0.958	0.109
16	2.482	0.952	0.092
32	2.592	0.838	0.081
64	2.254	0.661	0.075
128	2.730	0.739	0.113

表4 不同卷积核下 CNN-BiLSTM 模型的预测结果

Table 4 Prediction results of CNN-BiLSTM model under different convolution kernels

卷积核个数	$RMSE$	MAE	$MAPE$
8	2.781	0.636	0.093
16	2.530	0.639	0.135
32	2.618	0.475	0.079
64	2.498	0.532	0.103
128	2.249	0.430	0.068

表5 不同卷积步长下 CNN-BiLSTM 模型预测结果

Table 5 Prediction results of CNN-BiLSTM model under different convolution steps

卷积步长	$RMSE$	MAE	$MAPE$
1	2.396	0.347	0.069
2	2.583	0.583	0.078
3	3.146	0.625	0.102

3.2 不同预测模型结果对比

4种预测模型对可听噪声边相导线投影外20、30、35 m 预测结果的评价指标见图9(a)~(c)。由图9(a)可以看出,与 BiLSTM、CNN-BiLSTM、BiLSTM-MHA 相比,文中所提模型的 $RMSE$ 分别降低了0.230、0.182、0.371, MAE 分别降低了0.087、0.214、0.337, $MAPE$ 分别降低了0.015、0.021、0.034。类似

表6 不同模型的参数设置情况

Table 6 Parameter settings of different models

参数	BiLSTM	CNN-BiLSTM	BiLSTM-MHA	CNN-BiLSTM-MHA
学习率	0.001	0.001	0.001	0.001
迭代次数	200	200	200	200
Batch size	64	64	64	64
丢弃率	—	0.2	—	0.2
卷积核个数	—	128	—	128
卷积步长	—	1	—	1
池化层尺寸	—	2	—	2
池化层步长	—	1	—	1
BiLSTM 神经元个数	64	64	64	64
优化器	Adam	Adam	Adam	Adam

地,边相导线投影外30、35 m 预测结果的评价指标见图9(b)、(c)。文中所提 CNN-BiLSTM-MHA 预测模型均保持最优的评价指标。

不同模型训练过程参数对比见表7。由表7可知, CNN-BiLSTM 模型和 CNN-BiLSTM-MHA 模型训练时间相对较短,这是因为模型中均有卷积和池化操作,对输入数据进行特征筛选与提取,大大降低了输入数据的复杂性。对比4种训练模型参数数量可知, CNN-BiLSTM 和 BiLSTM-MHA 的参数数量明显小于 BiLSTM,证明模型中添加 CNN 或 Multi-head Attention 模块,可以有效降低算法运行所需的计算量和占用的内存量,另外, Multi-head Attention 进行权重分配后的参数数量明显低于 CNN 提取特征后的参数数量。与其他预测模型相比,本文所提基于多头注意力机制的 CNN-BiLSTM 模型在 $RMSE$ 、 MAE 、 $MAPE$ 和训练时间指标上均为最优的。

针对不同的监测时序长度的数据预测场景,分别采用4种预测模型进行可听噪声预测,以边相外20 m数据集为例,由于数据量过于庞大,因此每20 min 选取一个点进行展示,其结果和实测值曲线见图10(a)~(c)。整体来看, BiLSTM 和 BiLSTM-MHA 预测值与实测值匹配效果较差;而文中模型不论是在长期预测或短期预测中,其预测结果精度均优于其他模型。从图10(a)、(b)中可以看出,文中模型的可听噪声预测曲线波峰和波谷区域的波动性最小,在曲线上升和下降阶段能很好的预测可听噪声变化的规律。从图10(c)中1 h 的预测数据可以看出,可听噪声在25~35 dB 水平的数值预测中,使用 CNN 网络后,预测曲线变得更加平滑,而且相比于只有 BiLSTM 模型, CNN-BiLSTM 模型在捕捉可听噪声数




图9 不同测量距离场景的评价指标情况

Fig. 9 Evaluation indicators of different measurement distance scenarios

据的变化趋势方面表现更为出色,具有更高效的时序依赖关联拟合能力,能够深度挖掘更充分的时序信息。从20~40 dB水平的数值预测中,由多头注意力机制进行权重分配之后的 CNN-BiLSTM-MHA 组合模型在数据剧烈波动区域的预测精度更佳。

3.3 模型泛化性验证

为了进一步验证文中所提基于多头注意力机

表7 不同模型训练过程参数对比
Table 7 Comparison of training process parameters of different models

参数	BiLSTM	CNN-BiLSTM	BiLSTM-MHA	CNN-BiLSTM-MHA
训练时间/min	138.2	117.4	133.4	114.5
模型参数	434 016	331 009	215 921	269 441




图10 不同预测模型结果对比图

Fig. 10 Comparison of the results of different prediction models

制的 CNN-BiLSTM 组合模型的可听噪声预测方法的适用性,本节将基于边相导线投影外 30、35 m 处可听噪声数据集进行验证。利用边相导线投影外 20 m 的数据作为训练集对文中模型进行训练,利用训练好的模型对边相导线投影外 30、35 m 数据进行预测,其预测结果见图 11-12。由图 11-12 可知,以随机选取的典型日的数据量为例,每 20 min 取

一个点进行展示,文中所提组合预测模型对30、35 m数据集预测值曲线与实测值匹配度较高,均能实现较好的预测。




图11 30 m处数据集预测结果

Fig. 11 Prediction results of data set at 30 m




图12 35 m处数据集预测结果

Fig. 12 Prediction results of data set at 35 m

4 结论

文中构建一种基于多头注意力机制的CNN-BiLSTM的可听噪声预测模型,主要得到以下结论:

1)针对可听噪声受多因素影响的问题,通过皮尔逊系数对影响因素进行相关性分析,得出可听噪声的相关影响因素共11种。

2)将时间序列预测模型与深度学习网络相结合,解决了传统时间序列方法不能拟合多变量的复合关系,以及传统人工建模方法存在过拟合的不足。

3)结合CNN与MHA的优点,以实测数据作为实际算例进行了验证分析。文中模型相较于BiLSTM、CNN-BiLSTM、BiLSTM-MHA进行对比可知, $RMSE$ 、 MAE 、 $MAPE$ 最低,且无论用于长期预测或短期预测,文中模型预测精度均优于其他模型。

4)利用边相外20 m的数据对模型进行训练,使用训练好的模型对边相外30、35 m的数据进行预测,以此验证了模型的泛化性。

参考文献:

[1] BIAN X M, WANG L M, LIU Y P, et al. High altitude effect on corona inception voltages of DC power transmission conductors based on the mobile corona cage[J]. IEEE Transactions on Power Delivery, 2013, 28(3): 1971-1973.
[2] 齐磊,符瑜科,李小萌,等. 气压和湿度对复合电压下

换流阀高压电极起晕电压影响试验[J]. 高电压技术, 2019, 45(1): 82-90.

QI Lei, FU Yuke, LI Xiaomeng, et al. Effects of air pressure and humidity on corona onset voltage of high voltage electrode of converter valve under combined AC and DC voltage[J]. High Voltage Engineering, 2019, 45(1): 82-90.

[3] 张海兵,吴海涛,胡琴,等. 架空输电线路可听噪声问题综述[J]. 高压电器, 2022, 58(5): 1-6.

ZHANG Haibing, WU Haitao, HU Qin, et al. Review of audible noise of overhead transmission lines[J]. High Voltage Apparatus, 2022, 58(5): 1-6.

[4] 李振华,程紫熠,陈兴新,等. 基于EMD-XGBoost模型的交流输电线路可听噪声有效数据预测方法研究[J]. 高压电器, 2023, 59(6): 180-187.

LI Zhenhua, CHENG Ziyi, CHEN Xingxin, et al. Study on predication method of audible noise valid data for AC transmission lines[J]. High Voltage Apparatus, 2023, 59(6): 180-187.

[5] 唐剑,何金良,刘云鹏,等. 海拔对导线交流电晕可听噪声影响的电晕笼试验结果与分析[J]. 中国电机工程学报, 2010, 30(4): 105-111.

TANG Jian, HE Jinliang, LIU Yunpeng, et al. Test result-sand analysis of altitude-change effect on audible noise of AC corona occurring on conductors with corona-test cage [J]. Proceedings of the CSEE, 2010, 30(4): 105-111.

[6] ZHAO L X, LU J Y, CUI X, et al. The altitude effect and correction of audible noise for HVDC transmission lines[J]. IEEE Transactions on Power Delivery, 2017, 32(4): 1954-1963.

[7] 赵录兴,小布穷,谢莉,等. 海拔对直流输电线路可听噪声及其频谱特性影响的试验研究[J]. 中国电机工程学报, 2020, 40(21): 7132-7143.

ZHAO Luxing, XIAO Buqiong, XIE Li, et al. Experimental study of the influence of altitude on audible noise and its spectrum characteristics for DC transmission line[J]. Proceedings of the CSEE, 2020, 40(21): 7132-7142.

[8] 张业茂,万保权,周兵,等. 特高压输电线路可听噪声长期测试数据的统计分析[J]. 中国电机工程学报, 2017, 37(20): 6136-6144.

ZHANG Yemao, WAN Baoquan, ZHOU Bing, et al. Statistic analysis of long-term measured data of audible noise on UHV AC transmission lines[J]. Proceedings of the CSEE, 2017, 37(20): 6136-6144.

[9] 王国利,李敏,刘磊,等. 高海拔特高压直流线路电磁环境特性研究[J]. 高电压技术, 2018, 44(1): 264-274.

WANG Guoli, LI Min, LIU Lei, et al. Electromagnetic environment characteristics of UHVDC transmission line in high altitude area[J]. High Voltage Engineering, 2018, 44(1): 264-274.

[10] 饶宏,李瑞海,曾嵘,等. 高海拔特高压直流输电工程电磁环境[M]. 北京:中国电力出版社, 2015: 68-90.

- RAO Hong, LI Ruihai, ZENG Rong, et al. Electromagnetic environment of UHVDC transmission project at high altitude[M]. Beijing: China Electric Power Press, 2015: 68-90.
- [11] 倪园, 张广洲, 张小武, 等. 特高压交流试验基地的噪声评估与治理[J]. 高电压技术, 2009, 35(8): 1856-1861.
- NI Yuan, ZHANG Guangzhou, ZHANG Xiaowu, et al. Assessment and treatment of noise in UHV AC test base[J]. High Voltage Engineering, 2009, 35(8): 1856-1861.
- [12] PERRY D E, CHARTIER V L, REINER G L. BPA 1 100 kV transmission system development corona and electric field studies[J]. IEEE Transactions on Power Apparatus and Systems, 1979, 98(5): 1728-1738.
- [13] 俞集辉, 杨越, 何健, 等. 对AC UHV输电线附近可听噪声预测公式的评估[J]. 高电压技术, 2009, 35(3): 451-456.
- YU Jihui, YANG Yue, HE Jian, et al. Evaluation of audible noise predicting formulas for AC UHV transmission lines[J]. High Voltage Engineering, 2009, 35(3): 451-456.
- [14] WAN B, HE W, PEI C, et al. Audible noise performance of conductor bundles based on cage test results and comparison with long term data[J]. Energies, 2017, 10(7): 958.
- [15] 高鹭, 孔繁苗, 张飞, 等. 基于IPSO-BiLSTM-AM模型的超短期风电功率预测方法[J]. 智慧电力, 2022, 50(4): 27-34.
- GAO Lu, KONG Fanmiao, ZHANG Fei, et al. An ultra-short-term wind power prediction method based on IPSO-BiLSTM-AM model[J]. Smart Power, 2022, 50(4): 27-34.
- [16] 陈铁, 陈一夫, 李咸善, 等. 基于CEEMDAN-SG-BiLSTM的变压器油中溶解气体浓度预测[J]. 高压电器, 2023, 59(12): 174-181.
- CHEN Tie, CHEN Yifu, LI Xianshan, et al. Prediction method for dissolved gas in power transformer oil based on CEEMDAN - SG - BiLSTM[J]. High Voltage Apparatus, 2023, 59(12): 174-181.
- [17] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度CNN-BiLSTM-Attention的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140.
- OUYANG Fulian, WANG Jun, ZHOU Hangxia. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN - BiLSTM - Attention[J]. Power System Protection and Control, 2023, 51(2): 132-140.
- [18] 梁海峰, 袁芑, 高亚静. 基于CNN-Bi-LSTM网络的锂离子电池剩余使用寿命预测[J]. 电力自动化设备, 2021, 41(10): 213-219.
- LIANG Haifeng, YUAN Peng, GAO Yajing. Remaining service life prediction of lithium-ion battery based on CNN-Bi - LSTM network[J]. Electric Power Automation Equipment, 2021, 41(10): 213-219.
- [19] 彭道刚, 朱琪, 车权, 等. 基于CNN-LSTM神经网络的电网调度火电厂短期存煤预测[J]. 电力自动化设备, 2021, 41(6): 127-132.
- PENG Daogang, ZHU Qi, CHE Quan, et al. Short-term coal storage forecasting of thermal power plant for power grid dispatching based on CNN - LSTM neural network[J]. Electric Power Automation Equipment, 2021, 41(6): 127-132.
- [20] WANG L, DENG X, GE P, et al. CNN-BiLSTM-attention model in forecasting wave height over south-east China seas[J]. CMC-Computers Materials & Continua, 2022, 73(1): 2151-2168.
- [21] QU D, WANG S, LIU H, et al. A car-following model based on trajectory data for connected and automated vehicles to predict trajectory of human-driven vehicles[J]. Sustainability, 2022, 14(12): 7045.
- [22] SHAN L, LIU Y, TANG M, et al. CNN-BiLSTM hybrid neural networks with attention mechanism for well log prediction[J]. Journal of Petroleum Science and Engineering, 2021(205): 108838.
- [23] 聂磊, 徐诗奕, 张吕凡, 等. 基于多头注意力机制的飞机发动机寿命预测研究[J]. 推进技术, 2023(8): 192-200.
- NIE Lei, XU Shiyi, ZHANG Lüfan, et al. Remaining useful life prediction of aeroengine based on multi-head attention[J]. Journal of Propulsion Technology, 2023(8): 192-200.
- [24] 刘元庆, 杨晓洪, 姜脉哲, 等. 淋雨后高压直流导线电晕产生的可听噪声特性[J]. 电工技术学报, 2020, 35(s2): 371-376.
- LIU Yuanqing, YANG Xiaohong, JIANG Maizhe, et al. The characteristics of audible noise produced by corona of HVDC conductors after raining[J]. Transactions of China Electrotechnical Society, 2020, 5(s2): 371-376.
- [25] 任建吉, 位慧慧, 邹卓霖, 等. 基于CNN-BiLSTM-Attention的超短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(8): 108-116.
- REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on CNN - BiLSTM - Attention[J]. Power System Protection and Control, 2022, 50(8): 108-116.
- [26] WANG T, FU L, ZHOU Y, et al. Service price forecasting of urban charging infrastructure by using deep stacked CNN-BiGRU network[J]. Engineering Applications of Artificial Intelligence, 2022(116): 105445.

黄悦华(1972—), 男, 教授, 主要从事智能电网、新能源微电网、综合能源系统等(E-mail: hyh@ctgu.edu.cn)。

张子豪(1998—), 男, 硕士研究生, 主要从事电磁环境、深度学习在输电线路的应用等(E-mail: zhangzihao0724@163.com)。

陈庆(1989—), 女, 博士研究生, 主要从事人工智能在电力系统应用、智能电网等(通信作者)(E-mail: chenqing20190808@163.com)。