

DOI: 10.19666/j.rlfed.202211272

基于 Bootstrap 误差修正的电力负荷短期 预测深度学习模型

张宇晨, 姜雪松, 李春伟, 刘 森
(东北林业大学工程技术学院, 黑龙江 哈尔滨 150040)

[摘要] 针对负荷数据非线性、强波动性等特点导致数据规律性较弱电力负荷预测模型不准确的问题, 构建基于 Bootstrap 误差修正的 TCN-WOA-BiLSTM-Attention 电力负荷短期预测模型。使用时序卷积神经网络 (TCN) 提取时序特征并通过注意力机制 (Attention 机制) 对特征突出重要信息贡献度, 通过鲸鱼优化算法 (WOA) 寻找双向长短时记忆 (BiLSTM) 神经网络最优超参数以减少人工搜索超参数的负面影响后进行预测; 基于 Bootstrap 分析预测区间误差分布, 通过覆盖率 (PICP) 是否低于对应置信度判断对预测结果进行修正的必要性, 并选取合理修正范围。仿真结果表明, 基于 Bootstrap 方法进行误差修正避免了修正不足及修正过度的问题, 对比将误差序列全部修正的方法更具有科学性, 能最大程度提高模型预测精度。

[关键词] 电力负荷短期预测; Bootstrap; 误差修正; 时序卷积神经网络; 鲸鱼优化算法

[引用本文格式] 张宇晨, 姜雪松, 李春伟, 等. 基于 Bootstrap 误差修正的电力负荷短期预测深度学习模型[J]. 热力发电, 2023, 52(3): 121-129. ZHANG Yuchen, JIANG Xuesong, LI Chunwei, et al. Deep learning model for short-term power load prediction based on Bootstrap error correction[J]. Thermal Power Generation, 2023, 52(3): 121-129.

Deep learning model for short-term power load prediction based on Bootstrap error correction

ZHANG Yuchen, JIANG Xuesong, LI Chunwei, LIU Sen
(College of Engineering and Technology, Northeast Forestry University, Harbin 150040, China)

Abstract: Aiming at the problem of weak internal regularity caused by the characteristics of nonlinear and strong fluctuation of load data, a TCN-WOA-BiLSTM-Attention power load short-term prediction model based on Bootstrap error correction was constructed. Temporal convolutional network (TCN) was used to extract temporal features and the contribution of important information to the features was highlighted through the Attention mechanism. The whale optimization algorithm (WOA) was employed to find the optimal bidirectional long short term memory network (BiLSTM) hyperparameters, thus to reduce the negative impact of manual search hyperparameters and then forecast. Based on Bootstrap analysis on error distribution of the prediction interval, the necessity of correcting the prediction result was judged by whether the PICP was lower than the corresponding confidence, and the reasonable correction range was selected. The results show that, the error correction based on the Bootstrap method can avoid the problem of insufficient correction and excessive correction. Compared with the method of correcting the whole error sequence, it is more scientific and improves the prediction accuracy of the model to the greatest extent.

Key words: short-term power load prediction; Bootstrap; error correction; temporal convolutional neural network; whale optimization algorithm

收稿日期: 2022-11-10 网络首发日期: 2023-01-31

基金项目: 黑龙江省自然科学基金项目 (LH2019E001)

Supported by: Natural Science Foundation of Heilongjiang Province (LH2019E001)

第一作者简介: 张宇晨 (1999), 男, 硕士研究生, 主要研究方向为深度学习在电力负荷分析与预测中的应用, 2359734187@qq.com。

通信作者简介: 姜雪松 (1979), 男, 博士, 副教授, 主要研究方向为工业工程与管理、制造系统工程及信息化、现代机械设计理论与方法, xuesongjiang@nefu.edu.cn。

随着电力基础设施建设不断完善以及居民用电不断增加,电力负荷波动随之增大,提高电力负荷预测精度可以使电网对发电企业电力生产调度任务做出有效指导。因此对短期电力负荷的预测方法进行研究具有重要的现实意义。

随着深度学习快速发展,时间序列预测模型长短时记忆(long short term memory, LSTM)神经网络通过使用记忆细胞克服了参数反传过程中梯度消失或爆炸的问题,但 LSTM 神经网络只通过前馈神经传播进行预测却无法编码从后到前的信息^[1-2]。双向长短时记忆(bidirectional long short term memory, BiLSTM)神经网络通过同时兼顾正向传播以及反向传播,能够充分提取输入序列所有信息,在 LSTM 神经网络的基础上提升了预测的准确率^[3]。时序卷积神经网络(temporal convolutional network, TCN)通过构造多个特征提取器在输入数据中提取局部特征向量,以此弥补 BiLSTM 弱于对局部特征挖掘和识别的不足^[4]。此后神经网络引入注意力机制(attention mechanism)对输入信息进行权重分配突出重要信息贡献度以提高预测精度,被广泛应用于电力领域预测问题^[5]。

受限于单一预测模型对时序性特征的联系抓取不完全。姚程文等^[6]运用卷积神经网络(convolutional neural networks, CNN)提取负荷特征后输入 GRU 进行预测,但 GRU 无法编码从后到前的信息导致预测精度提高有限。王继东等^[7]针对数据规律性不强问题通过注意力机制突出重要信息贡献度后进行预测,结果表明注意力机制可以很好地突出关键特征对预测结果的影响。任建吉等^[8]通过 CNN 结合注意力机制同步提取和突出数据特征和贡献度后进行预测,结果表明相较于单一提取特征模型,同步提取和突出特征后能够解决特征过多导致信息过载问题且模型预测精度更高。虽然上述组合模型通过对数据特征的挖掘和突出提高了预测精度,但预测模型超参数大多是人工搜索进行调整,而基于人工搜索无法保证模型获得最佳的参数组合,且会造成效率低下、耗时长的问题,因此对超参数进行算法寻优成为降低负面影响的热门方法^[9]。

目前大多数负荷预测多为负荷点的预测,即给出待预测点的期望值,忽略了更有价值的区间信息,而区间信息不仅能准确模拟未来数据的变化趋势,还能给出数据的波动范围,常见区间预测方法如分位数回归及 Bootstrap 等^[10-11]。但现有区间预测

文献仅对区间分布进行分析,对少部分预测误差较大而导致的真实值落在预测区间以外情况未进行任何处理,而大多数对预测误差处理如误差修正的预测研究仅考虑对误差序列进行全部修正^[12-13],忽略了对序列中误差不明显的预测点进行修正容易导致误差增加的过度修正现象以及修正不足的问题,因此基于 Bootstrap 分析预测区间误差分布,通过区间覆盖率(PICP)是否低于对应置信度判断对预测结果进行修正的必要性、选取合理修正范围能够提高修正效果。

基于此,本文以 2018 年天池大数据竞赛中某风力发电厂的历史发电负荷数据为研究对象,通过 TCN 算法和注意力机制提取并突出数据特征以解决强随机性负荷数据内部规律性不强及对贡献度较低特征过分关注的问题,使用鲸鱼优化算法(whale optimization algorithm, WOA)对 BiLSTM 预测模型寻优以得到参数最优解,构建 TCN-WOA-BiLSTM-Attention 模型进行预测,提出基于 Bootstrap 分析预测区间误差分布情况并判断误差修正的必要性和修正范围,以避免修正不足和过当问题。

1 模型原理

1.1 TCN 模块

TCN 模型以 CNN 模型为基础,对一维卷积进行变形从而生成更适合提取间隔较长和非连续时序数据的特征信息的卷积网络。与 CNN 相比,TCN 通过因果卷积作为适用序列模型,以空洞卷积(dilated convolution)以及残差模块作为记忆历史以此使模型可以学习更长时段内的信息并最大程度保留原有特征。空洞卷积内部结构如图 1 所示。




图 1 空洞卷积内部结构

Fig.1 Internal structure of dilated convolution

与传统卷积不同，空洞卷积对卷积层的输入序列进行间隔采样，采样间隔由图 1 中 d 控制。通常越高的隐藏层层级设定的 d 的数值越大，因此膨胀卷积使得有效窗口的大小随隐藏层层数呈指数型增长。这样卷积网络用比较少的隐藏层，就可以灵活调整卷积层映射范围的大小。对于输入的时间序列 x ，扩张卷积的计算公式为：

$$F(t) = \sum_{i=0}^{k-1} f(i)x_{t-d-i} \quad (1)$$

式中： $F(t)$ 为经过一次空洞卷积运算后的输出； k 为卷积核尺寸； $f(i)$ 为卷积核中第 i 个元素； x_{t-d-i} 为只对过去的数据进行卷积操作； d 为采样率即窗口系数。

1.2 BiLSTM 模块

BiLSTM 神经网络结构模型为 2 个独立的 LSTM 神经网络对输入序列分别以正序和逆序 2 个方向输入进行特征提取，将提取的特征向量进行拼接后形成的词向量作为该模型的最终特征表达且 BiLSTM 中的 2 个 LSTM 神经网络参数是相互独立的，它们只共享词向量列表，因此 BiLSTM 相较于 LSTM 模型同时拥有过去和将来之间的信息。BiLSTM 模型内部结构如图 2 所示。




图 2 BiLSTM 模型内部结构
Fig.2 Internal structure of the BiLSTM model

BiLSTM 模型单元的传播公式为：

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

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

$$\tilde{C}_t = \text{Relu}(W_c[h_{t-1}, x_t] + b_c) \quad (4)$$

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

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

$$h_t = o_t * \text{Relu}(C_t) \quad (7)$$

式中： f_t 、 i_t 、 o_t 分别为遗忘门、输入门和输出门； x_t 为当前模型输入信息； W_f 、 W_i 、 W_c 、 W_o 分别为各式的权重矩阵； b_f 、 b_i 、 b_c 、 b_o 分别为各式的偏置向量； \tilde{C}_t 和 C_t 分别为隐藏层生成 t 时刻记忆单元的临时状态和新细胞状态； σ 和 Relu 分别为函数和激活函

数； h_t 为最终输出值。

1.3 Attention 机制

一般而言模型的参数越多且机制越复杂则模型的拟合能力越强，模型所存储的信息量也越大，但长时序序列输入则会产生梯度弥散和梯度爆炸的问题。因此通过 Attention 机制聚焦于长时序序列中对预测变量影响更大的信息，降低其对预测序列影响较小信息的关注或过滤噪声，就可以解决信息过载问题，提高模型的预测效果和拟合能力。Attention 机制结构如图 3 所示。




图 3 Attention 机制结构
Fig.3 Structure of Attention mechanism

Attention 机制计算公式为：

$$S_t = F(Q, K_t) \quad (8)$$

$$a_t = \text{softmax}(S_t) = \frac{\exp(S_t)}{\sum_{t=1}^n \exp(S_t)} \quad (9)$$

$$\text{Attention}((K, V), Q) = \sum_{t=1}^n a_t h_t \quad (10)$$

式中： S_t 为每个隐藏层输出的得分； Q 为查询匹配； K 为输入值； a_t 为权重系数； n 为数据长度； V 为输出值； h_t 为 BiLSTM 隐藏层输入值；Attention 为 BiLSTM 隐藏层输出各特征的不同权值。

1.4 WOA 模块

WOA 模型通过对座头鲸捕猎时环绕收缩猎物的行为进行模拟，对组合模型参数进行优化得到最优解，由于该算法参数少、操作简单且收敛速度快，被广泛应用于求解优化问题^[4]。该算法主要包括包围捕食、泡网攻击、搜寻食物 3 个阶段。首先通过逐渐搜索行为将猎物包围，逐渐搜索行为计算公式为：

$$D = |CX^*(t) - X(t)| \quad (11)$$

$$\mathbf{X}(t+1) = \mathbf{X}^*(t) - A\mathbf{D} \quad (12)$$

式中： t 为当前迭代； \mathbf{C} 和 \mathbf{A} 为系数向量； \mathbf{X}^* 为当前最优解的位置向量； \mathbf{X} 为当前解的位置向量。

在设计鲸鱼捕食吐气泡行为时，通过收缩包围以及螺旋式更新位置来模拟座头鲸泡网攻击，但座头鲸在收缩包围圈捕杀猎物的同时以螺旋形式游向猎物。为了保证2种攻击方式的同步进行，采取相同概率($p=0.5$)实现收缩包围和螺旋式更新位置。螺旋式更新位置的计算公式为：

$$\mathbf{X}(t+1) = D^l e^{bl} \cos(2\pi l) + \mathbf{X}^*(t) \quad (13)$$

式中： l 为 $[-1,1]$ 之间的随机数； b 为常数。

WOA 模仿座头鲸攻击行为实现局部搜索后通过随机搜索行为实现算法的全局搜索，随机搜索行为计算公式为：

$$D = |\mathbf{C}\mathbf{X}_{\text{rand}}(t) - \mathbf{X}(t)| \quad (14)$$

$$\mathbf{X}(t+1) = \mathbf{X}_{\text{rand}}(t) - A\mathbf{D} \quad (15)$$

式中： \mathbf{X}_{rand} 为随机位置向量。

2 数据处理及预测

2.1 数据预处理

风力发电厂发电负荷主要由风速决定，风电设备所处环境中的气象因素如湿度、温度、降雨等也会使机组部件发生老化，进而降低机组发电效率。因此，将风速、风电设备所处环境气象因素及历史发电负荷作为预测模型输入，这样使预测数据更具有科学性。

风速、温度、湿度、降雨数据等均为彼此互不相关时间序列，为了关联数据历史信息，利用词向量的表示方式，将每一时刻历史发电负荷与其特征相关的特征信息一起串联，构成新的时间序列，即：

$$\mathbf{x}_t = [x_{t,v}, x_{t,T}, x_{t,h}, x_{t,r}, x_{t,p}], t \in [1, n] \quad (16)$$

式中： $x_{t,v}$ 、 $x_{t,T}$ 、 $x_{t,h}$ 、 $x_{t,r}$ 、 $x_{t,p}$ 分别为 t 时刻风力发电机组的风速、温度、湿度、降雨量及历史发电负荷数据。以滑动窗口方式输入数据，根据之后的需要，使用宽度为7的滑动窗口，将构建的时间序列依次传递给神经网络，以发电负荷数据作为单一输出预测数据，即输出数据为 $\hat{x}_{t,p}$ 。由于输入数据的不同特征之间量纲不同，为便于模型训练，本文对输入数据进行归一化处理。

2.2 基于 TCN-WOA-BiLSTM-Attention 预测模型

结合 WOA 可解决 BiLSTM 在样本训练中由于随机选取超参数而导致输出结果相差较大的问题。

通过 WOA 寻找最优超参数，可提高 BiLSTM 模型用于预测时的精准度及平稳性。结合 WOA 的 BiLSTM 模型流程如图4所示。

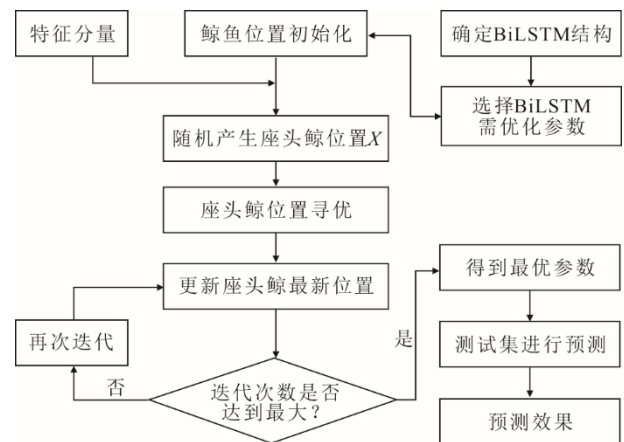


图4 WOA 优化 BiLSTM 流程
Fig.4 The BiLSTM process optimized by WOA

通过 TCN 对输入序列抓取长时的依赖信息，将提取的依赖信息输入 WOA-BiLSTM 模块中通过正反2个方向对特征向量进行提取，同时利用注意力机制对 WOA-BiLSTM 模块输入信息进行权重分配以突出重要信息贡献度后进行预测，构建基于 TCN-WOA-BiLSTM-Attention 预测模型。基于 WOA 的 TCN-BiLSTM-Attention 预测模型的基本流程分为3步：

1) 首先进行数据预处理，然后通过词向量的方式将风速、风电设备所处环境的气象因素及历史负荷等信息串联为输入向量，构成全新时间序列并进行标准化处理；

2) 通过 TCN 挖掘数据特征和消除噪声及不稳定因素，产生特征序列，并输入至 WOA-BiLSTM 预测模块；

3) 利用注意力机制对 WOA-BiLSTM 预测模块中特征序列进一步突出重要信息贡献度后进行预测。

2.3 基于 Bootstrap 方法的置信区间估计及误差修正

Bootstrap 方法是一类非参数区间预测方法，其实质是对观测信息进行再抽样，进而对总体的分布特性进行统计推断^[15]。该方法充分利用给定的观测信息，不需要模型其他的假设和增加新的观测，并且具有稳健性和效率高的特点，其预测区间上下界计算公式为：

$$U^{(a)}(x_t) = \hat{f}(x_t) + Z_{1-\frac{2}{a}} \sqrt{\hat{\sigma}_y^2(x_t) + \hat{\sigma}_\varepsilon^2(x_t)} \quad (17)$$

$$L^{(a)}(x_t) = \hat{f}(x_t) - Z_{1-\frac{\alpha}{2}} \sqrt{\hat{\sigma}_y^2(x_t) + \hat{\sigma}_\varepsilon^2(x_t)} \quad (18)$$

式中： $U^{(a)}(x_t)$ 为预测区间上界； $L^{(a)}(x_t)$ 为预测区间下界； $\hat{f}(x_t)$ 为真实回归均值的估计值； $\hat{\sigma}_y^2(x_t)$ 为模型预测值不确定性方差； $\hat{\sigma}_\varepsilon^2(x_t)$ 为噪声方差； $Z_{1-\frac{\alpha}{2}}$ 为标准正态分布的临界值。

为了解决预测误差修正不足以及修正过度的问题，首先通过 Bootstrap 方法构建预测区间并分析区间误差分布情况；然后判断区间覆盖率（PICP）指标是否低于对置信度，若低于则表明有较多预测值落在区间外，总体预测误差较大，需对真实值落在预测区间外的点进行修正，反之则不需修正；最后分析不同置信度区间下误差修正情况并选取最佳修正效果的预测值。区间预测及误差修正流程如图 5 所示。

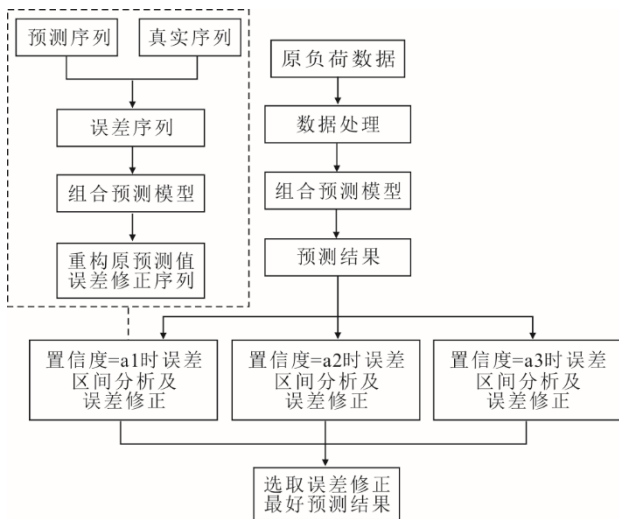


图 5 区间预测及误差修正流程

Fig.5 Flow of interval prediction and error correction

2.4 评价指标

均方根误差（ δ_{RMSE} ）、平均相对百分比误差（ δ_{MAPE} ）2 个指标常用于回归任务，且误差取值越小则表示模型预测精度越高。本文使用上述评价指标对预测结果进行评价，其计算公式分别为：

$$\delta_{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (19)$$

$$\delta_{MAPE} = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \right) \quad (20)$$

式中： y_t 为负荷数据真实值； \hat{y}_t 为负荷数据预测值； N 为预测样本量。

对于误差预测区间评价指标，本文针对可靠性

评判标准选取 δ_{PICP} 以及预测区间宽度（ δ_{PINAW} ）进行评价。 δ_{PICP} 表示实际数值落入预测区间的整体概率，该数值越大表明预测模型越准确，区间越可靠，而 δ_{PINAW} 表示所构造的预测区间的平均宽度，该数值越小表明预测区间宽度越窄。其计算公式分别为：

$$\delta_{PICP} = \frac{1}{n} \sum_{t=1}^N c_t \quad (21)$$

$$\delta_{PINAW} = \frac{1}{NR} \sum_{t=1}^N (U_t - L_t) \quad (22)$$

式中：当真实值 $y_t \in (L_t, U_t)$ 时 $c_t=1=1$ ，否则 $c_t=0$ ； R 为负荷实际值的范围。

3 案例分析

为验证基于 TCN-WOA-BiLSTM-Attention 组合模型的有效性，本文采用 2018 年天池大数据竞赛中某风力发电机组所处环境的温度、湿度、风速、降雨及其历史发电负荷指标作为模型的原始样本集。以 15 min 采样 1 个点，每天取 96 个点，每个指标各 2 880 条数据，其中历史发电负荷数据波动频率较高，谷值和峰值没有固定区间。历史发电负荷数据如图 6 所示。




图 6 电力负荷数据

Fig.6 Power load data

由图 6 可以发现，该负荷数据不仅呈非平稳性、强随机性等特点，且包含噪声。为了防止预测过程产生过拟合现象，本文采用 7:3 的比例选取前 1 824 个点共计 19 天作为训练集，768 个点共计 8 天作为验证集，最后 288 个点共计 3 天作为预测集。

3.1 预测模型结构设计

本文采用人工搜索方法初步设定 TCN 初始参数滤波器个数为 64 个，大小为 5，因果卷积层为

3 层, 每层空洞因子为 $2n$ 不变, 通过 WOA 确定 BiLSTM 学习率、隐藏层层数、神经元个数、Dense 层神经元数、每批特征变量输入个数和模型迭代次数的最优值。预测模块步长为 10, 激活函数为 Relu, Dropout 层选取 0.2, WOA 初始参数设定为鲸鱼种群规模为 30, 最大迭代次数为 100 次。BiLSTM 参数寻优结果见表 1。

表 1 BiLSTM 参数寻优结果
Tab.1 Optimization results of BiLSTM parameters

模型结构	模型参数设置
学习率	0.007 769
隐藏层层数	2
BiLSTM 神经元个数	5, 5
Dense 曾神经元个数	22
批特征向量输入个数	97
模型迭代次数	70

为了分析 TCN 滤波器个数、大小对预测精度的影响, 保持 BiLSTM 最优参数不变的前提下, 确定 TCN 最优参数。调整 TCN 后模型预测结果误差见表 2。由表 2 可知, 适当增加 TCN 的卷积核个数及卷积核大小, 可以提高预测精度, 但当 TCN 卷积核个数达 64 以及 TCN 卷积核达到 7 时, 出现过拟合现象, 均方根误差和平均相对百分比误差分别上升 0.33 和 0.02 百分点, 因此 TCN 最优参数中因果卷积层为 3 层, 滤波器个数为 64 个, 大小为 5。

表 2 TCN 参数调整结果对比
Tab.2 Comparison of TCN parameter adjustment results

卷积核/个	卷积核大小	δ_{RMSE}	$\delta_{MAPE}/\%$
32	1	73.55	1.46
32	3	70.84	1.42
64	1	64.78	1.34
64	3	63.53	1.33
64	5	60.91	1.30
64	7	61.24	1.32

3.2 预测结果及分析

为了验证基于 TCN-WOA-BiLSTM-Attention 模型预测可行性, 首先将 TCN-BiLSTM-Attention 与支持向量机 (SVM)、BP 神经网络、LSTM、CNN-LSTM 模型进行比较, 随后将本文模型与 TCN-GA-BiLSTM-Attention、TCN-PSO-BiLSTM-Attention 模型进行比较。为了避免预测偶然性事件的发生, 本文进行 10 次重复实验, 将 10 次实验结果进行算术平均, 以提高模型预测的可靠性。各模型预测结果对比见表 3、表 4。由表 3 和表 4 可见, TCN-BiLSTM-Attention 相较于 SVM、BP、LSTM 和 CNN-LSTM

组合模型, 均方根误差分别降低了 228.62、79.29、47.19、19.50; 平均相对百分比误差分别降低了 4.91 百分点、2.00 百分点、1.06 百分点、0.30 百分点。

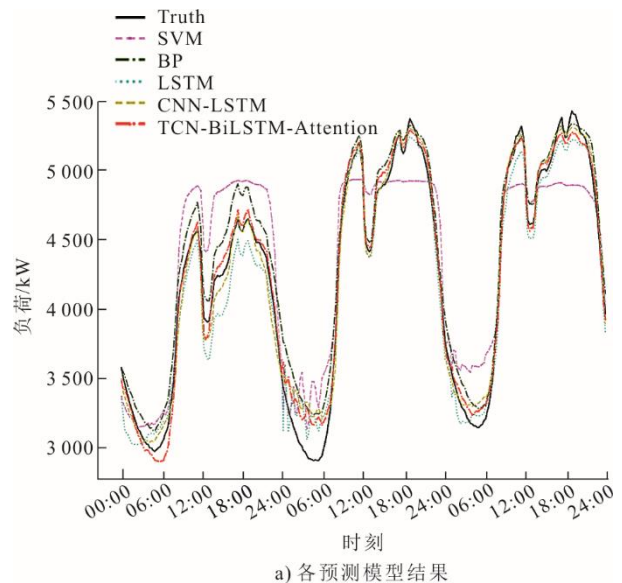
表 3 各模型预测结果精度对比
Tab.3 The accuracy of each prediction model

模型	δ_{RMSE}	$\delta_{MAPE}/\%$
SVM	323.54	6.83
BP	174.21	3.92
LSTM	142.11	2.98
CNN-LSTM	114.42	2.22
TCN-BiLSTM-Attention	94.92	1.92

表 4 各模型优化后预测结果精度对比
Tab.4 The precision of prediction result of each model after optimization

模型	δ_{RMSE}	$\delta_{MAPE}/\%$
TCN-GA-BiLSTM-Attention	87.19	1.80
TCN-PSO-BiLSTM-Attention	82.23	1.38
本文提出预测模型	60.91	1.30

本文提出预测模型与 TCN-GA-BiLSTM-Attention、TCN-PSO-BiLSTM-Attention 模型相比, 均方根误差降低了 26.28、21.32, 平均相对百分比误差降低了 0.50 百分点、0.08 百分点。图 7 为根据以上数据绘制的各模型预测结果对比。由图 7a) 可见, 相较于其他 4 个模型, TCN-BiLSTM-Attention 模型在波谷、波峰区域预测结果与真实曲线拟合最好, 但所有预测模型在第 2 天 03:00—06:00 期间预测误差较为明显。其原因在于凌晨期间用电需求降低, 风力发电企业为保证发电到用电端净负荷保持在一个较为平稳的状态而降低风电机组的功率, 致使发电负荷数据呈现骤降趋势, 此时基于人工经验对预测模型参数进行设定后预测会出现过拟合现象。



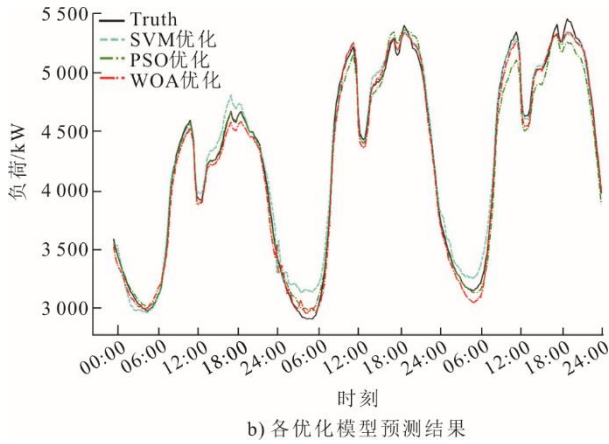


图7 预测模型效果对比

Fig.7 The prediction effect of each model

而对比分析图 7b)中本文提出模型预测曲线与其他 2 条优化后预测曲线可知, 3 条曲线在波峰、波谷尤其在第 2 天 03:00—06:00 期间也能够较好拟合真实曲线。相较于未优化前预测模型, 均方根误差分别降低 34.01、12.69、7.73, 平均相对百分比误差分别降低 0.62 百分点、0.54 百分点、0.12 百分点, 但 WOA 模型更关注神经网络宏观结构的递归型搜索空间, 能够搜索到高性能模型参数, 效果最好。本文提出模型均方根误差和平均相对百分比误差分别为 60.91 和 1.30 百分点, 相较于所有预测模型最优, 证明了本文提出的组合模型在电力负荷预测问题上的优越性。

3.3 区间预测结果分析及修正效果对比

由于风力发电机组周围的天气变化具有很大的随机性, 分析发电负荷的预测区间范围更具有意义, 因此本文采用 Bootstrap 方法分析提出的组合模型的预测误差分布, 求解负荷概率区间。分别讨论置信度为 80%、90% 和 95% 条件下负荷的分布情况, 区间预测结果如图 8 所示。从图 8 可知, 虽然传统的点预测模型可反映未来负荷的变化趋势, 但通过 Bootstrap 对区间进行预测可靠度更高, 不仅能准确模拟未来负荷的变化趋势, 还能给出负荷的波动范围。从图 8 还可看出, 随着置信水平的增大, 预测平均宽度增大, 覆盖实测负荷数据的效果更佳, 但由于负荷数据的强随机性特点, 本文预测模型在数据波动大的区域(第 2 天 03:00—06:00)的预测反应迟缓, 导致谷值的捕捉能力欠佳, 故部分预测区间覆盖率不能达到指定置信度。

为进一步验证 Bootstrap 区间预测模型的优劣, 采用区间覆盖率 PICP 和预测区间宽度 PINAW 2 个评价指标进行评判, 模型在不同置信水平下的区间

预测评价对比结果见表 5。从表 5 可知, 随着置信水平增大, PICP 和 PINAW 的值都会增大, 相较于置信度为 80% 和 90% 的情况下, 置信度为 95% 的 PICP 分别增加了 19.44 百分点、7.73 百分点, PINAW 分别增加了 0.013、0.028。




图8 区间预测结果

Fig.8 The interval prediction results

表 5 不同置信度区间预测评价对比
Tab.5 The prediction evaluation in different confidence intervals

置信度/%	$\delta_{PICP}/\%$	δ_{PINAW}
80	77.43	0.053
90	89.14	0.068
95	96.87	0.081

对于覆盖率没能达到给定的置信度如 80% 和 90% 的情况, 可能是由负荷的预测偏差造成的。因此, 本文通过误差修正模块对少部分会落在预测区间以外的预测值进行修正, 将真实值与此类预测值相减构建误差序列, 将误差序列导入本文提出组合预测模型进行重新预测, 将误差预测结果与原预测结果求和, 以此重构预测序列, 不同置信度的修正效果误差对比见表 6。

由表 6 可知, 当对置信度为 95% 的情况进行修正时, 误差修正存在过当现象, 与未修正相比较, 均方根误差与平均相对百分比误差分别提高 3.67、0.02 百分点, 与前文所述覆盖率达到给定置信度后进行修正可能导致修正过度的问题一致。置信度为 90% 时, 因为与 PICP 相差不大, 所以导致修正效果

不明显。而当置信度为 80% 时模型拟合能力最好, 相较于未进行修正以及置信度为 90% 时, 均方根误差分别降低了 10.62、9.70, 平均相对百分比误差分别降低了 0.07 百分点、0.06 百分点。证明了本文提出的误差修正方法相较于未考虑修正过度和修正不足问题的方法, 对误差序列修正效果更好, 不同置信度模型修正效果对比如图 9 所示。

表 6 不同置信度的修正效果误差对比
Tab.6 The correction effect accuracy with different confidence values

置信度/%	δ_{RMSE}	$\delta_{MAPE}/\%$
未修正	60.91	1.30
80	50.29	1.23
90	59.99	1.29
95	64.58	1.32

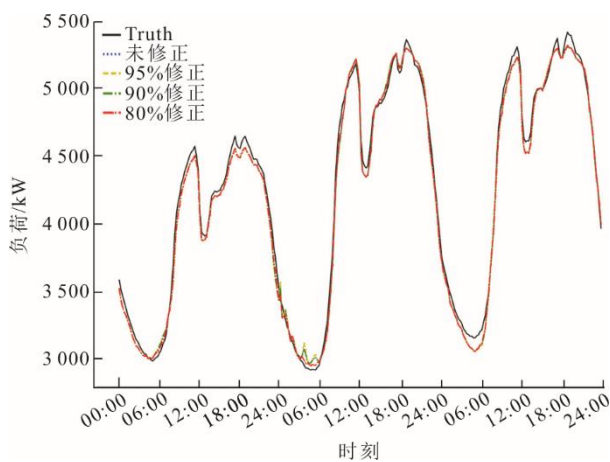


图 9 不同置信度模型修正效果对比

Fig.9 The correction effects of different confidence models

4 结 论

1) 本文提出一种基于 Bootstrap 误差修正的 TCN-WOA-BiLSTM-Attention 预测模型, 通过词向量将风速、风电设备所处环境的气象因素及历史负荷数据串联成向量作为输入序列后使用 TCN 提取时序特征, 通过 WOA 寻找 BiLSTM 最优超参数, 将得到的时序特征输入 WOA-BiLSTM 预测模块并以 Attention 机制对 WOA-BiLSTM 输入特征突出重要信息贡献度后进行负荷预测。针对发电负荷数据点预测误差的修正效果问题, 基于 Bootstrap 分析发电负荷数据点预测的误差区间分布情况, 通过 PICP 是否低于对应置信度判断对预测结果进行修正的必要性以及选取合理修正范围。

2) 与单一预测算法相比, 通过 TCN 及 Attention 机制对输入数据提取特征后预测效果更佳。通过

WOA 算法对预测模型进行寻优后能够最大限度降低人为因素对预测误差产生的负面影响。

3) Bootstrap 对区间进行预测可靠度更高, 不仅能准确模拟未来负荷的变化趋势, 还能给出负荷的波动范围, 且通过 PICP 是否低于对应置信度判断对预测结果进行修正的必要性以及选取合理修正范围能够最大化提高误差修正效果。

[参 考 文 献]

- [1] 余洋, 陈庚, 余佳磊, 等. 基于聚类和长短期记忆神经网络的光热电站并网电力预测[J]. 热力发电, 2021, 50(9): 128-136.
YU Yang, CHEN Geng, YU Jialei, et al. Grid-connected power forecasting of concentrating solar power plants based on clustering and long short-term memory neural network[J]. Thermal Power Generation, 2021, 50(9): 128-136.
- [2] 刘钢, 金铁群, 曹旭, 等. 基于深度学习和混沌优化的燃机电站机组热电负荷优化分配[J]. 热力发电, 2022, 51(2): 178-182.
LIU Gang, JIN Yiqun, CAO Xu, et al. Load optimal distribution of combined heat and power in gas turbine power plant using deep learning and chaotic optimization method[J]. Thermal Power Generation, 2022, 51(2): 178-182.
- [3] 廖清阳, 王军, 胡凯强, 等. 基于深度并行 CNN-BiLSTM 的能源互联网电负荷和热负荷联合预测模型[J]. 中国测试, 2022, 48(4): 146-153.
LIAO Qingyang, WANG Jun, HU Kaiqiang, et al. Joint forecasting model of electrical load and thermal load based on deep parallel CNN-BiLSTM in energy internet[J]. China Measurement & Test, 2022, 48(4): 146-153.
- [4] 郑豪丰, 杨国华, 康文军, 等. 基于多负荷特征和 TCN-GRU 神经网络的负荷预测[J]. 中国电力, 2022, 55(11): 142-148.
ZHENG Haofeng, YANG Guohua, KANG Wenjun, et al. Load forecasting based on multiple load features and TCN-GRU neural network[J]. Electric Power, 2022, 55(11): 142-148.
- [5] 王华彪, 李小勇. 基于融合注意力机制改进双向长短期记忆网络在电动汽车充电负荷中的预测研究[J]. 电网与清洁能源, 2022, 38(6): 104-112.
WANG Huabiao, LI Xiaoyong. Prediction of electric vehicle charging load based on integrating Attention mechanism to improve BiLSTM[J]. Power System and Clean Energy, 2022, 38(6): 104-112.
- [6] 姚程文, 杨苹, 刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
YAO Chengwen, YANG Ping, LIU Zejian. Load forecasting method based on CNN-GRU hybrid neural network[J]. Power System Technology, 2020, 44(9): 3416-3424.
- [7] 王继东, 杜冲. 基于 Attention-BiLSTM 神经网络和气象数据修正的短期负荷预测模型[J]. 电力自动化设备, 2022, 42(4): 172-177.
WANG Jidong, DU Chong. Short-term load prediction model based on Attention-BiLSTM neural network and meteorological data correction[J]. Electric Power Automation Equipment, 2022, 42(4): 172-177.

- [8] 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.
- [9] 王金玉, 金宏哲, 王海生, 等. ISSA 优化 Attention 双向 LSTM 的短期电力负荷预测[J]. 电力系统及其自动化学报, 2022, 34(5): 111-117.
WANG Jinyu, JIN Hongzhe, WANG Haisheng, et al. Short-term power load prediction of bidirectional LSTM with ISSA optimization Attention mechanism[J]. Proceedings of the CSU-EPSC, 2022, 34(5): 111-117.
- [10] 宋绍剑, 罗世坚, 李国进, 等. 基于 MPA-LSTM 模型和 Bootstrap 方法的短期光伏功率区间预测[J]. 广西大学学报(自然科学版), 2022, 47(4): 986-997.
SONG Shaojian, LUO Shijian, LI Guojin, et al. A short-term PV power interval forecasting based on MPA-LSTM network model and Bootstrap method[J]. Journal of Guangxi University (Natural Science Edition), 2022, 47(4): 986-997.
- [11] 唐戈, 余一平, 秦川, 等. 基于 CNN-LSTM 分位数回归的母线负荷日前区间预测[J]. 电力工程技术, 2021, 40(4): 123-129.
TANG Ge, YU Yiping, QIN Chuan, et al. Day-ahead interval prediction of bus load based on CNN-LSTM quantile regression[J]. Electric Power Engineering Technology, 2021, 40(4): 123-129.
- [12] 伍骏杰, 张倩, 陈凡, 等. 计及误差修正的变分模态分解-长短期记忆神经网络短期负荷预测[J]. 科学与技术工程, 2022, 22(12): 4828-4834.
WU Junjie, ZHANG Qian, CHEN Fan, et al. Short-term load forecasting with error correction and variational mode decomposition-long short-term memory[J]. Science Technology and Engineering, 2022, 22(12): 4828-4834.
- [13] 丁婷婷, 杨明, 于一潇, 等. 基于误差修正的短期风电功率集成预测方法[J]. 高电压技术, 2022, 48(2): 488-496.
DING Tingting, YANG Ming, YU Yixiao, et al. Short-term wind power integration prediction method based on error correction[J]. High Voltage Engineering, 2022, 48(2): 488-496.
- [14] 徐建中, 晏福. 改进鲸鱼优化算法在电力负荷调度中的应用[J]. 运筹与管理, 2020, 29(9): 149-159.
XU Jianzhong, YAN Fu. The application of improved whale optimization algorithm in power load dispatching[J]. Operations Research and Management, 2020, 29(9): 149-159.
- [15] 李凯, 任炳昱, 关涛, 等. 帷幕灌浆量区间预测的 Bootstrap-IGWO-SVM 模型研究[J]. 水力发电学报, 2022, 41(10): 18-29.
LI Kai, REN Bingyu, GUAN Tao, et al. Curtain grouting cement interval prediction using Bootstrap-IGWO-SVM model[J]. Journal of Hydroelectric Engineering, 2022, 41(10): 18-29.

(责任编辑 杜亚勤)