

刘善峰¹ 李哲¹ 陈锦鹏² 卢明¹ 向玲²

基于误差修正的极端天气下风速预测

摘要

精确地预测极端天气下的风速能为配电网防灾抗灾提供重要的指导作用。本文提出基于时间卷积网络(Temporal Convolutional Network, TCN)与双向长短期记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)和误差修正的组合模型对极端天气下的风速进行预测。首先对天气数据进行预处理,用TCN提取多特征数据的时间序列特性,将提取信息输入到BiLSTM中进行风速预测。为进一步提高预测精度,引入变分模态分解(Variational Mode Decomposition, VMD)对误差序列进行分解,分别对分解后的误差子序列构建BiLSTM模型进行误差预测,用误差预测值对风速预测值进行误差修正。结合河南省某地实测天气数据进行实验,仿真结果验证了所提方法能有效预测风速,并在极端天气发生时,对风速具有较高的预测精度。

关键词

风速;时间卷积网络;双向长短期记忆网络;误差修正;变分模态分解;预测

中图分类号 P429;TP183

文献标志码 A

收稿日期 2022-12-06

资助项目 国家电网有限公司科技指南项目(5400-202199555A-0-5-ZN)

作者简介

刘善峰,男,博士,高级工程师,研究方向为极端天气预测、模式识别与电网防灾减灾。179555872@qq.com

陈锦鹏(通信作者),男,硕士生,研究方向为极端天气预测和配电网故障检测。1304859592@qq.com

1 国网河南省电力公司电力科学研究院,郑州,450052

2 华北电力大学 能源动力与机械工程学院,保定,071003

0 引言

大风极端天气是一种突发性灾害,往往在很短时间内会对人类的生产、生活造成较大伤害。风灾会对配电网、电力设备等构成严重威胁。为降低风灾对人类社会带来的负面影响,需要采取必要的预测预警措施。研发极端天气下的风速预测技术,提升风速预报的准确性和时效性,显得尤为重要。风速的准确预测能给防灾减灾方面提供重要的指导作用。

风速预测主要可分为机理驱动法和模型驱动法两种。机理驱动法基于空间相关性和数值天气预报,主要是利用物理信息分析风速特性,通过动力学的方法对风速建立动力学方程从而对风速进行求解。此类方法解析式复杂,计算量大且缺乏对历史数据的利用。而模型驱动法是利用概率模型、机器学习模型或深度学习模型,从历史数据中学习并训练模型,并将已训练好的模型应用到未知数据上^[1]。随着大数据时代的来临,计算机算力的快速提升以及各种模型的出现,模型驱动法在生产中的应用越来越多。

在模型驱动法中,深度学习模型表现尤为亮眼。深度学习是一种广泛的基于数据表示的机器学习方法,拓宽了机器学习的应用领域,延伸了人工智能的服务范围,其中许多应用已成为行业研究热点^[2]。郑征等^[3]将深度学习应用于电力行业中的电力负荷预测,提出一种基于多头注意力(multi-headed attention)的卷积循环神经网络深度学习模型,该模型能有效地对电力消耗进行预测;王朋等^[4]将小波分解技术(Wavelet Transform, WT)与长短期记忆网络(Long Short-Term Memory, LSTM)结合,提出基于小波长短期记忆网络的风电功率超短期概率预测模型,结果表明,将小波分解与深度学习方法结合可以较好地提高预测的精度;吴香华等^[5]将深度学习应用于降水预测模型中,提出一种基于注意力机制、卷积神经网络(Convolutional Neural Network, CNN)和BP神经网络的CNN-Attention-BP组合模型,对降水的预测准确率有较好效果。

众多学者利用深度学习对风速预测模型开展了大量的研究工作,并取得了不错的预测效果。丁仁强等^[6]提出一种SSA-BiLSTM组合模型风速预测方法,对历史风速进行奇异谱分析(Singular Spectrum Analysis, SSA)后利用双向长短期记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)进行预测,预测结果优于LSTM、BiLSTM等单

一模型;王俊等^[7]建立了变分模态分解(Variational Mode Decomposition, VMD)和LSTM的组合模型对风速进行超短期预测,结果表明该模型的预测精度优于其他多种典型风速预测模型,该模型在超短期风速预测方面表现出较好的性能;Moreno等^[8]建立了结合VMD-SSA和LSTM的风速预测模型,获得了较高的预测精度;向玲等^[9]利用自适应噪声完备经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)对风速进行二次分解,并结合LSTM组合模型对风速进行多步预测,结果表明该模型在多步风速预测方面表现出较好的性能;毕贵红等^[10]提出一种基于双模式分解、双通道卷积神经网络和LSTM的组合预测模型,实验结果表明该模型可以有效地提高短期的风速预测精度。

为了充分利用误差序列,进一步提高风速预测准确度,一些研究者在模型预测结果的基础上对其进行误差修正,取得了一定的改善效果。黄元生等^[11]用经验模态分解(Empirical Mode Decomposition, EMD)对风速序列进行分解,利用高斯过程回归(Gaussian Process Regression, GPR)进行风速预测,得到原始预测值和误差序列,对误差序列进行预测,将误差预测值校正原始预测值得到最终预测值,算例表明该方法能提高风速的预测精度。

基于以上研究,针对极端大风天气突发性强、风速变化大、难以准确预测的问题,本文提出一种基于时间卷积网络(Temporal Convolutional Network, TCN)与BiLSTM和误差修正的组合风速预测模型。对于风速、温度等气象因素,利用时间卷积网络提取其特征,再使用BiLSTM模型对风速进行预测。风速预测的研究工作主要集中在提高模型预测精度上,在TCN-BiLSTM组合模型的基础上增加基于变分模态分解(VMD)的误差修正模型,能有效提高模型的预测精度。TCN-BiLSTM模型预测误差包含着风速的信息,但直接对模型误差进行利用预测,所得的误差修正结果对原模型不能起到提升效果的作用。利用VMD对误差序列进行分解后再建立误差修正模型,能有效降低序列的复杂程度,充分利用到误差的序列信息,以进一步改善风速预测精度。

1 数据预处理

所用天气数据包括风速、温度、湿度、雨量和风速等级5个类型,其中风速等级为非数值数据,不适

用于训练风速预测模型。选择风速、温度、湿度和雨量作为模型输入特征,随后构建新特征并对数据进行预处理。

1.1 构建特征

构建新特征温度差。温度差为该时刻温度与上一个时刻温度的差值,定义为

$$\Delta t = t_1 - t_0, \quad (1)$$

其中, t_1 为该时刻温度, t_0 为上一个时刻温度。

应用斯皮尔曼(Spearman)相关系数进行相关性程度分析。Spearman相关系数是度量两个变量相关性程度的非参数指标^[12],该系数计算时不需要考虑序列的分布规律以及是否线性等,因此适用范围比皮尔逊相关系数更广。变量 x, y 之间的 Spearman 相关系数计算公式如下:

$$\rho_{(xy)} = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2 - 1)} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}, \quad (2)$$

式中: x_i 和 y_i 分别为变量 x, y 进行排序后观测值 i 的取值等级; \bar{x} 和 \bar{y} 分别表示变量 x, y 的平均等级; N 为观察元素的个数; d_i 表示两个变量中观察值 i 的等级差数,由式 $x_i - y_i$ 计算得到; $\rho_{(xy)}$ 表示变量 x, y 的相关性程度,其取值范围为 $[-1, 1]$ 。

新特征温度差与风速的 Spearman 相关系数计算结果为 0.259 2,呈现出一定的相关性,可作为模型的输入特征之一。

1.2 归一化处理

归一化可以提升预测模型的精度,使得到的结果更可靠,同时利于模型收敛,提高模型的训练速度,优化了模型效率。归一化处理后,每个数据都被缩放到 $[0, 1]$ 这个区间。将风速、温度、湿度、雨量和温度差分别采用最大最小值归一化方法进行归一化,如式(3)所示:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (3)$$

式中, x 为需要进行归一化的变量, x' 表示归一化后数据, x_{\max} 和 x_{\min} 分别表示输入变量的最大值和最小值。

2 预测模型分析

利用TCN提取气象因素的特征,再应用BiLSTM

进一步建立特征与风速之间的关系,同时为了进一步改善风速预测效果,提出一种误差修正模型.误差修正模型使用 VMD 对误差序列进行分解,得到若干个子序列后对其分别构建 BiLSTM 模型预测得到误差预测结果,误差修正模型有助于提高精度和增强模型的泛化性能.

2.1 时间卷积网络

时间卷积网络^[13]是一种能够有效处理时间序列数据的网络结构,在特定条件下效果优于传统的神经网络,如 CNN 和 RNN 等.时间卷积网络的基本结构可以表示为一维全卷积网络(FCN)和因果卷积,前者用于保持网络输入与输出的长度相同,后者用于保证历史数据没有泄露.TCN 残差块的基本结构如图 1 所示,主要包括两个扩张因果卷积层,每层扩张因果卷积层后采用权重归一化,将整流线性单元(ReLU)作为激活函数,加入 Dropout 层,同时使用跳跃连接.TCN 结构具有并行性、灵活的感受野、可变的输入长度、梯度较为稳定和更小的内存训练等特点^[14].

TCN 中使用的卷积为扩张因果卷积,如图 2 所示.其中:因果卷积较普通卷积有严格的时间约束,满足了时间顺序上的前后依赖原则;扩张卷积引入了扩张因子,相当于在每两个相邻卷积核之间间隔固定步长,能够用更少的层数获得更长的感受野.因此扩张卷积能够缓解模型太深,难以训练的问题.

扩张卷积运算 F 在时刻 t 的定义为

$$F(t) = (\mathbf{x} * \mathbf{f})(t) = \sum_{i=0}^{k-1} f(i) \cdot x_{t-d \cdot i}, \quad (4)$$

式中, k 为卷积核大小, $*$ 表示卷积, d 为扩张因子,通常其值的大小随卷积层数的增加呈 2 的指数递增.

2.2 双向长短期记忆网络

为解决 RNN 中存在的梯度爆炸和梯度消失的问题,长短期记忆网络(LSTM)^[15]被提出.LSTM 引入了“门”的概念,由输入门、输出门和遗忘门来更新网络,更新过程如下:

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f), \quad (5)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i), \quad (6)$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_c \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c), \quad (7)$$

$$\mathbf{C}_t = \mathbf{f}_t * \mathbf{C}_{t-1} + \mathbf{i}_t * \tilde{\mathbf{C}}_t, \quad (8)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o), \quad (9)$$

$$\mathbf{h}_t = \mathbf{o}_t * \tanh(\mathbf{C}_t), \quad (10)$$

其中: $\mathbf{f}_t, \mathbf{i}_t, \mathbf{C}_t, \mathbf{o}_t$ 分别表示 t 时刻的遗忘门、输入门、细胞状态和输出门; $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_o, \mathbf{W}_c$ 为与输入 \mathbf{x}_t 相连

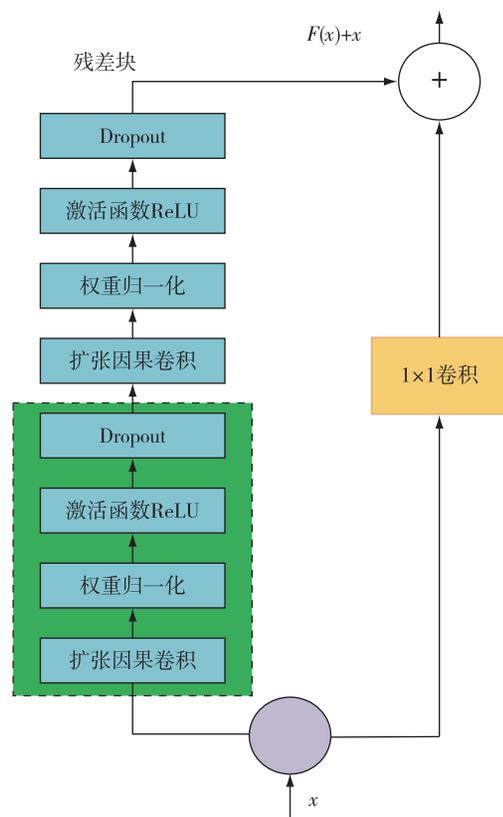


图 1 残差块结构

Fig. 1 Residual block structure

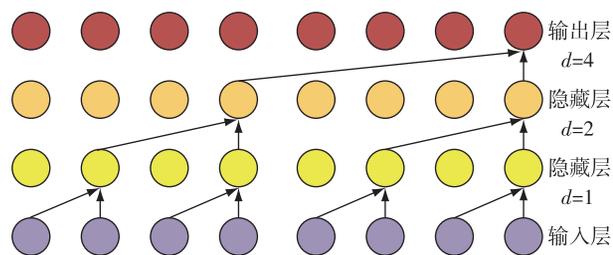


图 2 TCN 扩张卷积结构

Fig. 2 Structure of TCN extended convolution

接的权值矩阵; $\mathbf{b}_f, \mathbf{b}_i, \mathbf{b}_c, \mathbf{b}_o$ 分别表示对应的偏置矩阵; σ 为 sigmoid 函数; \mathbf{h}_t 为 t 时刻的隐藏层输出; \mathbf{x}_t 为 t 时刻的输入; $\tilde{\mathbf{C}}_t$ 表示记忆单元的输入状态; \tanh 为双曲正切函数.

LSTM 模型只能顺序获取序列的信息,但无法编码从后到前的信息.据此,双向长短期记忆网络作为 LSTM 的改进形式被提出.BiLSTM 由一组正向和后向的 LSTM 构成,在处理时间序列数据时能同时处理正向和逆向的数据,从而获取更多的数据信息.

BiLSTM 模型如图 3 所示,由正向 LSTM 和后向 LSTM 组合而成. $\mathbf{X} = [x_1, x_2, x_3, \dots, x_n]$ 为网络输入数据, $\mathbf{Y} = [y_1, y_2, y_3, \dots, y_n]$ 为网络输出数据,其中 a^f

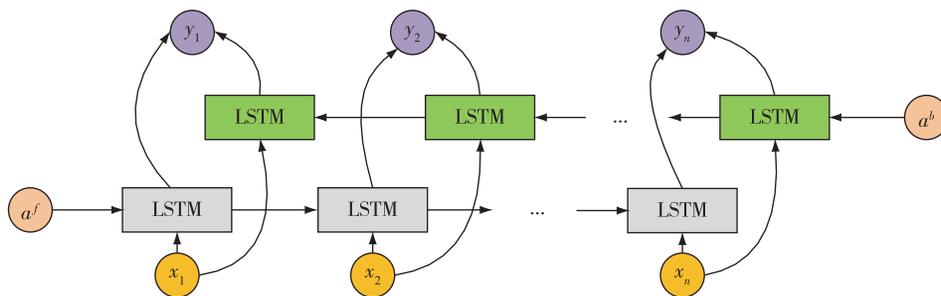


图3 BiLSTM模型的结构

Fig. 3 Structure of BiLSTM model

表示数据正向传播时上一个神经元的输出,而 a^b 表示数据反向传播时上一个神经元的输出,最终输出由正向 LSTM 和后向 LSTM 输出结合获得。

2.3 变分模态分解

变分模态分解(VMD)是 Dragomiretskiy 等^[16]在 2014 年提出的一种自适应、完全非递归的信号处理方法,该方法可以将原始输入信号自适应地分解为根据实际情况预设的 k 个具有不同中心频率和有限带宽的模态分量.VMD 算法可以有效避免模态混叠现象且有较强的鲁棒性,在故障诊断、时间序列分析、信号降噪等许多领域得到了应用^[17-19].VMD 实质是对变分问题的构建和求解,计算过程如下:

2.3.1 构建变分问题

1) 通过 Hilbert 变换求解出 k 个本征模态函数 $u_k(t)$ 的信号及其单边频谱:

$$\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t). \quad (11)$$

2) 对 k 个模态函数对应的中心频率 ω_k 的指数项进行堆叠,将模态函数的频谱调制到基频带:

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t}. \quad (12)$$

3) 通过运用高斯平滑法确定 k 个模态函数的带宽,将目标问题转成求解带约束的变分问题,目标函数为

$$\begin{aligned} \min & \left\{ \sum_k \left\| \partial_t \sum_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}, \\ \text{s.t.} & \sum_k u_k(t) = f(t), \end{aligned} \quad (13)$$

式中, $u_k(t)$ 表示分解获得的 k 个模态函数分量, ω_k 表示 k 个模态函数的中心频率。

2.3.2 求解变分问题

1) 求解变分约束模型最优解时引入了拉格朗日乘子 l 和二次罚函数 α ,把约束性变分问题转化为非

约束性变分问题,转换后的拉格朗日函数为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle [\lambda(t), f(t)] - \sum_k u_k(t) \rangle. \end{aligned} \quad (14)$$

2) 求解模态函数时运用了交替方向乘子算法,通过迭代交替更新 $u_k^{n+1}, \omega_k^{n+1}$ (其中 n 为迭代次数),求解出改进后拉格朗日表达式的“鞍点”,即获得了约束变分模型的最优解.解出的模态分量 u_k 和中心频率 ω_k 如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (15)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}. \quad (16)$$

利用 VMD 分解误差序列,可有效降低误差序列的复杂性,提取误差序列的有效信息,提高误差修正模型的预测精度。

3 风速预测模型

3.1 预测流程

本文所提的风速预测方法流程如下:

- 1) 构建新特征温度差.温度差与风速之间有一定的相关性,为模型提供重要的特征。
- 2) 对风速、温度和湿度等特征进行归一化处理,将数据按 7:1:2 的比例分别划分为训练集、验证集和测试集。
- 3) 用 TCN 提取气象数据的特征, BiLSTM 对所提取的特征进行训练和预测,得到风速的初步预测值。
- 4) 风速真实值 y 减去风速预测值 y_1 得到误差

值,对误差序列进行 VMD 分解,得到 k 个误差子序列.

5)对 k 个误差子序列分别建立 BiLSTM 模型进行误差预测,将 k 个预测值叠加得总误差预测值.

6)风速初步预测值和误差预测值对应相加得到风速的最终预测值.

综上所述,基于误差修正的风速预测模型流程如图 4 所示.

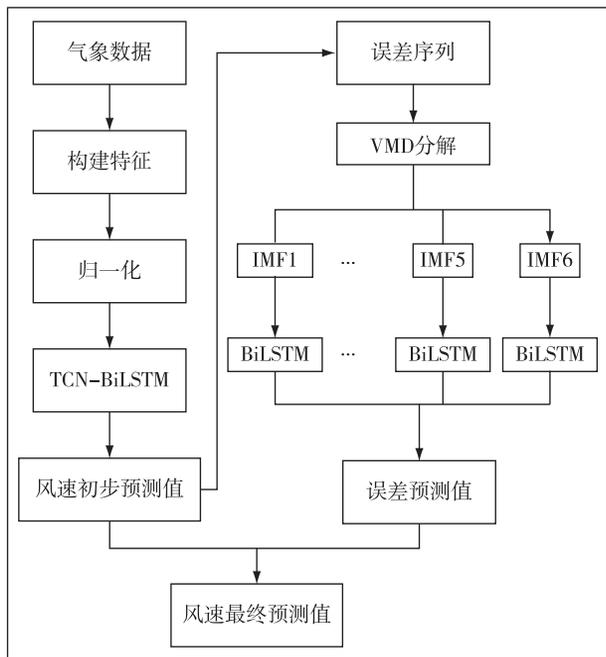


图 4 风速预测流程

Fig. 4 Flow chart for wind speed prediction

3.2 评价指标

为定量分析风速预测结果的准确性,利用误差评价指标对模型预测效果进行评估.选定的评价指

标为平均绝对误差 (MAE)、均方根误差 (RMSE) 和对称平均绝对百分比误差 (SMAPE),以上三个指标值越小说明预测效果越好.三个误差指标计算公式如下所示:

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N | \hat{y}_i - y_i |, \quad (17)$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2}, \quad (18)$$

$$e_{SMAPE} = \frac{1}{N} \sum_{i=1}^N \frac{| \hat{y}_i - y_i |}{(\hat{y}_i + y_i)/2}, \quad (19)$$

式中, N 为预测点总数, \hat{y}_i 和 y_i 分别为第 i 个风速预测值和实际值.

4 算例分析

2021 年 11 月 6—8 日,河南省全省出现大范围降温过程,期间大部分地区伴有大风天气,其中驻马店市某县遭遇恶劣的寒潮大风天气.该地 6—8 日连续 3 d 的温度和风速变化如图 5 所示,在红色部分气温急剧下降,且风速不断上升,该气象变化符合寒潮大风天气的物理变化过程,证实该地遭遇恶劣的寒潮大风天气.据此选择该地为研究对象,进行极端天气下的短时风速预测.

本文风速预报时长为 1 h,即进行提前 1 h 预测.预测模式为滚动预测,滚动循环预测 3 d,共 72 个数据点,并对这 72 个数据进行可视化对比,来验证模型的准确性.

4.1 数据准备

使用河南省驻马店市某县的实测天气历史数据进行实验,时间跨度为 2020 年 7 月 18 日至 2022 年 7 月 18 日.所采集的气象数据包括温度、湿度、雨量、风

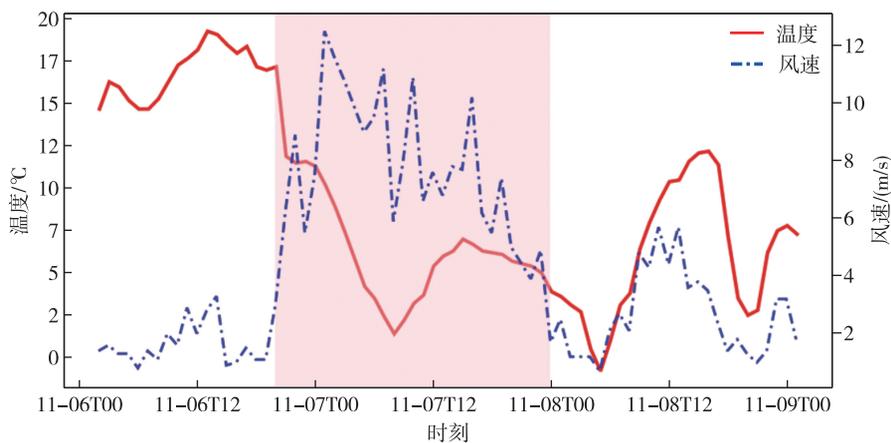


图 5 温度、风速变化曲线

Fig. 5 Variation curves of temperature and wind speed

向和风速等,采样周期为 1 h,2 年合计 16 972 个样本点.选取温度、湿度、风速、雨量和新构建的特征温度差为模型输入特征,对风速进行小时级别的短时预测.

将全部数据分别划分为训练集、验证集和测试集进行算例实验,其中训练集的比例为 70%,用于对模型进行训练,验证集的比例为 10%,用于训练过程

中选取最优参数模型,测试集的比例为 20%,用于对模型进行测试.

风速时间序列如图 6 所示,从图 6 中可以看出风速波动性大、随机性强,用深度学习的方法对数据构建非线性的模型映射关系,对风速预测能取到较好的预测效果.

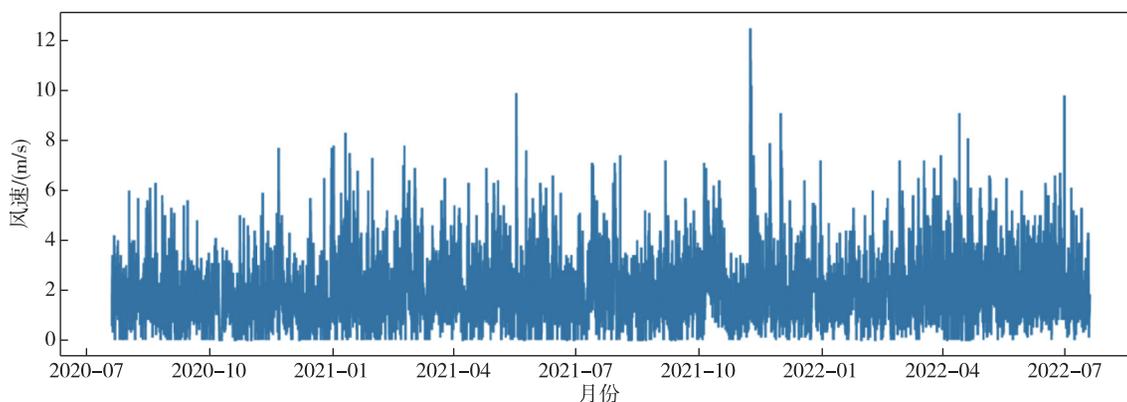


图 6 风速时间序列

Fig. 6 Time series for wind speed

4.2 构建样本

深度学习需要足量的数据支持,驻马店市某县记录的气象数据可利用的数据因素有风速、温度、湿度和雨量.据此,可构建新特征温度差,给模型提供更多的数据.

模型采用滑动时间窗口的预测方式,如图 7 所示,即输入 16 h 的气象数据,输出 1 h 的风速预测值.采用滑动时间窗口的方式,能把整个数据集划分为若干个 5×16 的矩阵向量(温度、湿度、风速、雨量和温度差 5 个输入特征,16 h 的气象数据),对这个矩阵进行归一化后输入到模型中进行训练预测.



图 7 滑动窗口结构

Fig. 7 Slide window structure

4.3 TCN-BiLSTM 模型预测

多维气象数据直接输入 BiLSTM 神经网络进行

预测时,由于网络不能有效地提取多维数据特征信息,会导致预测效果欠佳.而时间卷积网络针对多维信息可以有效提取特征,通过扩张因果卷积对多维数据进行卷积运算,提取最关键的特征.初始化的卷积核在一次次反向传播迭代过程中,参数会不断得到更新,进而逼近所期望的真实解.通过这种方式,可以实现多维数据到一维数据的映射,即气象数据经过 TCN 提取特征之后会生成一个特征向量,该向量包含着原始数据的关键信息.

通过 TCN 提取气象因素和变量之间的相关特征,BiLSTM 进一步建立提取的特征与风速之间的关系,即将提取到的特征张量处理成一维向量输入到全连接层,全连接层直接输出下一时刻风速预测值.TCN-BiLSTM 模型以下一时刻即下一小时的风速为预测目标.

所搭建的 TCN-BiLSTM 模型主要结构包括三个 TCN 残差块、一个 BiLSTM 层以及一个全连接层.根据经验、文献及试验,模型的各层网络超参数设置如下:每个残差块的卷积层包含 16 个卷积核,卷积核的大小为 3,三个残差块的扩张因子分别为 1、2、4,Dropout 值设置为 0.4,时间步数为 16,处理数据的批次大小为 128,模型训练的 epoch 数为 100.

TCN-BiLSTM 模型流程如图 8 所示,其中带底色部分(虚线框内)为模型主要结构,残差块即为 TCN.

将数据分别划分为训练集、验证集和测试集进行算例实验,其中训练集的比例为 70%,用于对模型进行训练,验证集的比例为 10%,用于训练过程中选取最优参数模型,测试集的比例为 20%,用于对模型进行测试,获得风速初始预测值.

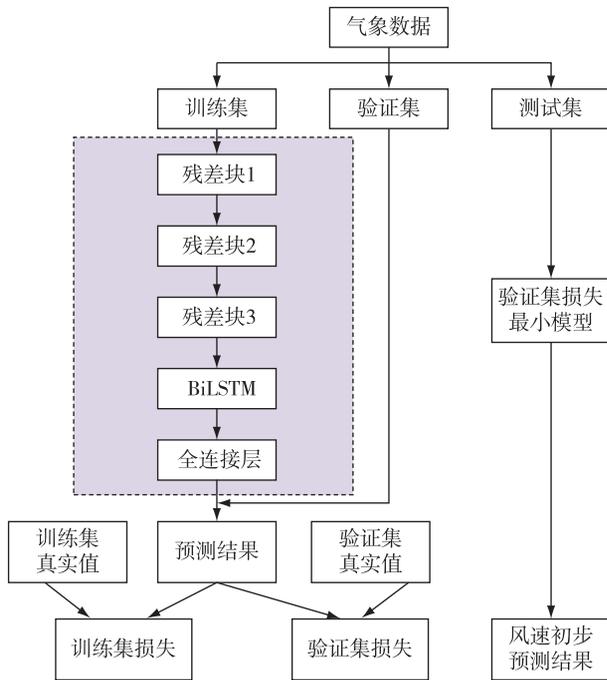


图 8 TCN-BiLSTM 模型预测流程
Fig. 8 Flow chart for wind speed prediction based on TCN-BiLSTM

4.4 VMD 分解误差序列

误差序列由训练集、测试集和验证集得到,随着 TCN-BiLSTM 预测模型不断输出风速预测值,误差序列也在不断更新.误差序列计算公式如下:

$$e(t) = y(t) - \hat{y}(t), \quad (20)$$

式中, $y(t)$ 为真实风速值, $\hat{y}(t)$ 为风速预测值.

由式(20) 计算获得误差序列,利用 VMD 分解误差序列,其中分解时通过归一化中心频率观察法^[20] 确定合适的分解子序列个数.分别取 k 为 3 到 7,对误差序列进行分解,分解后得到的各个模式分量的归一化中心频率如表 1 所示.可观察发现,中心频率最小值逐渐减小且趋于稳定,中心频率最大值逐渐变大且趋于稳定.当 $k=6$ 时,中心频率最大值和最小值都保持相对稳定,考虑当 $k>7$ 时会出现过分解的情况,因此,将序列分解个数选择为 $k=6$.其他参数如惩罚因子 α 、保真度系数 τ 和收敛停止条件 ϵ 使用默认值即 $\alpha=2\ 000$, $\tau=0$, $\omega=1\times 10^{-7}$. VMD 算法分解后的子序列如图 9 所示.为了便于观察,可视化每一个子序列的前 2 000 个点,可以看到低频部分的 IMF1 分量是误差序列的趋势项,显示了误差的总体变化趋势.

4.5 误差修正模型

将误差子序列归一化后分别输入到 BiLSTM 模型中进行训练并预测,获得最终误差预测值.根据试验,BiLSTM 模型的超参数设置如表 2 所示.最后将

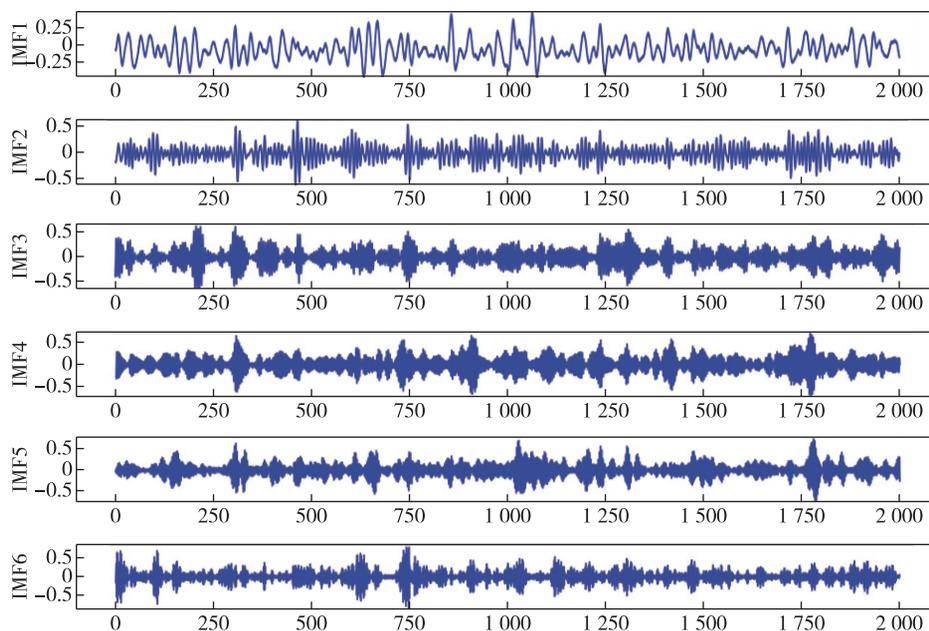


图 9 误差子序列

Fig. 9 Error subsequences

误差序列预测结果与 TCN-BiLSTM 模型风速预测结果进行加法运算,即将 t 时刻的风速预测结果与 t 时刻的误差预测值相加,得到原风速预测结果基础上优化的预测结果即为最终风速预测结果。

表 1 不同 k 值时 VMD 分解后的归一化中心频率

Table 1 Normalized center frequencies after VMD for different k values 10^{-3}

k	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7
3	45.824	170.771	361.644				
4	44.212	163.569	271.357	409.334			
5	42.079	150.279	238.441	334.119	429.198		
6	31.736	98.766	171.495	258.982	348.229	436.031	
7	29.567	95.172	166.876	240.644	316.316	385.882	457.165

表 2 BiLSTM 超参数及取值

Table 2 Hyperparameter values of BiLSTM

超参数	取值
时间步长	16
批次大小	32
BiLSTM 层数	1
隐藏层单元数	128
学习率	0.001

4.6 结果分析

图 10 为驻马店市某县 2021 年 11 月 6—8 日的风速预测曲线,预测时间范围为 00:00—23:00,风速短时预测的时间尺度为 1 h,滚动预测 72 h.结合图 10 和历史天气数据可知,在用于实验的 3 d 天气数据中,平均风速超过 10.8 m/s 的点有 5 个.根据天气预报业务规范,预报业务中一般以平均风力达到 6 级(≥ 10.8 m/s)作为大风标准(除台风和雷暴大风外),数据证实该县遭遇大风极端天气。

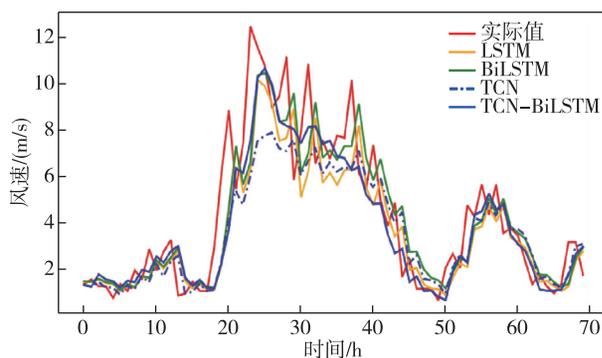


图 10 对比模型预测曲线

Fig. 10 Wind speed prediction result comparison between the proposed method and deep learning models

为验证 TCN-BiLSTM 组合模型预测性能,分别建立了 LSTM、BiLSTM、TCN 三个深度学习模型作为对比.计算各模型的误差指标,如表 3 所示。

表 3 各模型的误差指标结果

Table 3 Error indices comparison with deep learning models

模型	RMSE	MAE	SMAPE/%
LSTM	1.782 8	1.265 2	32.71
BiLSTM	1.692 6	1.229 5	32.87
TCN	1.822 8	1.261 2	32.52
TCN-BiLSTM	1.505 9	1.028 2	28.97

由表 3 可以看出,TCN 和 LSTM 模型预测效果相近.LSTM 模型的 RMSE 为 1.782 8,MAE 为 1.265 2, SMAPE 为 32.71%,而 BiLSTM 模型的 RMSE、MAE、SMAPE 分别为 1.692 6、1.229 5 和 32.87%,BiLSTM 模型比 LSTM 模型的 RMSE 减少了 5.06%,MAE 降低了 2.82%,SMAPE 基本一致,说明双向长短期记忆网络较于长短期网络能提取更多的信息,预测效果要略好.组合模型 TCN-BiLSTM 三个误差指标相较三个单一模型有了较大提升,TCN-BiLSTM 的 RMSE、MAE 和 SMAPE 相比 BiLSTM 分别减少了 11.03%、18.95%和 11.86%,说明 TCN 对气象数据起到了特征提取的作用,提高了预测精度。

为验证所提误差修正模型的有效性,选择模型 1、模型 2 与所提误差修正模型进行对比分析.模型 1 将未经过分解的原始误差序列输入到 BiLSTM 模型中进行训练预测;模型 2 先用 CEEMDAN 方法对误差序列进行分解,随后分别构建 BiLSTM 模型进行训练预测;本文方法为基于 VMD 分解的误差修正模型.将三个模型分别训练预测得到误差预测结果,叠加误差预测结果与原模型预测结果得到最终风速预测结果,各模型的误差指标如表 4 所示、预测效果如图 11 所示。

表 4 误差指标结果

Table 4 Error indices comparison between error correction models

模型	RMSE	MAE	SMAPE/%
TCN-BiLSTM	1.505 9	1.028 2	28.97
模型 1	1.512 5	1.179 5	35.43
模型 2	1.132 6	0.867 4	25.14
本文方法	0.632 9	0.447 4	13.46

模型 1 的误差序列未经分解处理,叠加误差预测结果后风速预测效果反而降低,模型 2 以及本文

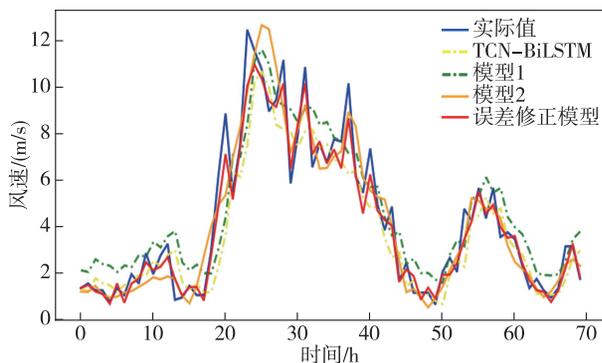


图 11 误差模型对比

Fig. 11 Wind speed prediction result comparison between error correction models

误差修正模型均对误差原始序列进行分解,降低了误差序列的复杂程度.根据误差指标可以看出模型 2 的 RMSE、MAE 和 SMAPE 分别为 1.132 6、0.867 4 和 25.14%,较原始模型分别降低了 24.79%、15.64%和 13.22%;基于误差修正的风速预测模型的 RMSE 为 0.632 9, MAE 为 0.447 4, SMAPE 为 13.46%,分别比未经误差修正的 TCN-BiLSTM 组合模型降低了 57.97%、56.48%和 53.55%.对比上述 3 个模型可以得出:对误差序列进行分解预测,误差模型对风速预测的精度有提升;分解方法中 VMD 效果优于 CEEMDAN,本文方法对原模型的预测结果起到了较好的校正作用,能有效拟合极端天气下的大风风速,体现了方法的有效性.

本文预测方法在 TCN-BiLSTM 组合模型的基础上加入了误差修正模型,由图 11 可以看出,该方法的风速曲线相比于组合模型 TCN-BiLSTM 更贴近真实风速.在第 1~15 个时间点以及第 50~72 个时间点时,该地为正常天气,风速较小,风速变化趋势较为平缓,此时构建的 LSTM、BiLSTM、TCN 和 TCN-BiLSTM 以及误差修正模型均能有效预测出风速,预测精度较高.而在第 16~49 个时间点时,该地遭遇了极端天气,风速有一个急剧上升的过程,风速变化剧烈.由图 10 可以看出 LSTM、TCN 和 TCN-BiLSTM 等模型此时预测的风速仅能部分拟合真实风速的变化趋势,且预测值与真实值相差较大;对比图 11 中 TCN-BiLSTM 组合模型和误差修正预测模型,可知误差修正模型在极端天气下能有效拟合风速急剧的变化趋势,且能较为准确地预测出风速,相比 TCN-BiLSTM 模型有了较大的性能提升,极端天气下的风速预测结果与真实数据更加吻合.

为了进一步评价模型的预测性能,添加了两种

最新风速预测算法进行对比分析. CEEMDAN-Res-GRU 是一种基于模式分解、残差网络和门控循环单元网络 (Gated Recurrent Unit, GRU) 的风速预测模型, Transformer 为当前热门的预测模型.由表 5 可得,本文方法的三种误差评价指标均优于 CEEMDAN-Res-GRU 模型和 Transformer 模型.图 12 预测曲线也可以看出本文方法预测曲线更贴近真实风速,基于误差修正的风速预测模型具有更好的预测效果和模型鲁棒性.

表 5 模型误差指标对比结果

Table 5 Error indices comparison between the proposed method and novel models

模型	RMSE	MAE	SMAPE/%
CEEMDAN-Res-GRU	0.941 5	0.718 4	20.89
Transformer	1.534 6	1.064 0	29.01
本文方法	0.632 9	0.447 4	13.46

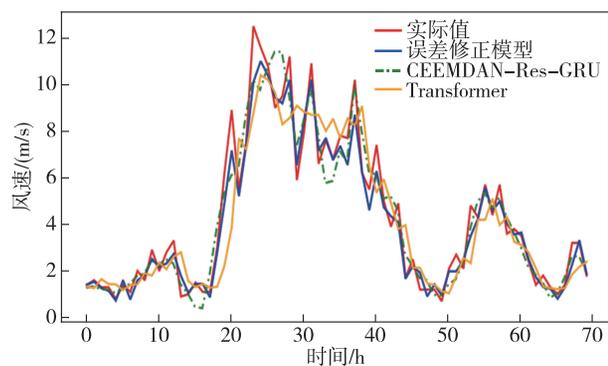


图 12 模型预测对比

Fig. 12 Wind speed prediction result comparison between the proposed method and novel models

5 结语

由于大风极端天气具有突发性,且风速变化急剧,难以对风速进行准确预测.针对此问题,本文提出一种基于 TCN-BiLSTM 和误差修正的风速预测模型,通过算例和模型对比得到以下结论:

1) TCN 能有效提取时间序列数据的特征,经 TCN 提取特征后再构建 BiLSTM 模型对风速进行预测,能使模型的预测精度更高.

2) 误差序列带有风速的信息,对误差序列进行 VMD 分解后构建误差修正模型,误差修正机制能进一步提高极端天气下的风速预测精度.

3) 极端天气下风速急剧变化时,本文模型更能追踪风速的变化趋势,预测值较其他模型更加准确.

参考文献

References

- [1] 冉靖,张智刚,梁志峰,等.风电场风速和发电功率预测方法综述[J].数理统计与管理,2020,39(6):1045-1059
RAN Jing, ZHANG Zhigang, LIANG Zhifeng, et al. Review of wind speed and wind power prediction methods [J]. Journal of Applied Statistics and Management, 2020, 39(6): 1045-1059
- [2] 史加荣,马媛媛.深度学习的研究进展与发展[J].计算机工程与应用,2018,54(10):1-10
SHI Jiarong, MA Yuanyuan. Research progress and development of deep learning [J]. Computer Engineering and Applications, 2018, 54(10): 1-10
- [3] 郑征,谭磊,周楠,等.基于多头注意力卷积网络的电力负荷预测[J].南京信息工程大学学报(自然科学版),2022,14(5):535-542
ZHENG Zheng, TAN Lei, ZHOU Nan, et al. Power load prediction based on multi-headed attentional convolutional network [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2022, 14(5): 535-542
- [4] 王朋,孙永辉,翟苏巍,等.基于小波长短期记忆网络的风电功率超短期概率预测[J].南京信息工程大学学报(自然科学版),2019,11(4):460-466
WANG Peng, SUN Yonghui, ZHAI Suwei, et al. Ultra-short-term probability prediction of wind power based on wavelet decomposition and long short-term memory network [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2019, 11(4): 460-466
- [5] 吴香华,华亚婕,官元红,等.基于CNN-Attention-BP的降水发生预测研究[J].南京信息工程大学学报(自然科学版),2022,14(2):148-155
WU Xianghua, HUA Yajie, GUAN Yuanhong, et al. Application of CNN-Attention-BP to precipitation forecast [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2022, 14(2): 148-155
- [6] 丁仁强,周武能,程航洋,等.基于深度学习框架SSA-BiLSTM网络的风速预测[J].计算机与数字工程,2020,48(11):2578-2583,2594
DING Renqiang, ZHOU Wuneng, CHENG Hangyang, et al. A novel method based on SSA-BiLSTM networks under deep learning framework for wind speed forecasting [J]. Computer and Digital Engineering, 2020, 48(11): 2578-2583, 2594
- [7] 王俊,李霞,周肯东,等.基于VMD和LSTM的超短期风速预测[J].电力系统保护与控制,2020,48(11):45-52
WANG Jun, LI Xia, ZHOU Xidong, et al. Ultra-short-term wind speed prediction based on VMD-LSTM [J]. Power System Protection and Control, 2020, 48(11): 45-52
- [8] Moreno S R, Silva R G D, Mariani V C, et al. Multi-step wind speed forecasting based on hybrid multi-stage decomposition model and long short-term memory neural network [J]. Energy Conversion and Management, 2020, 213: 112869
- [9] 向玲,刘佳宁,苏浩,等.基于CEEMDAN二次分解和LSTM的风速多步预测研究[J].太阳能学报,2022,43(8):334-339
XIANG Ling, LIU Jianing, SU Hao, et al. Research on multi-step wind speed forecast based on CEEMDAN secondary decomposition and LSTM [J]. Acta Energetica Solaris Sinica, 2022, 43(8): 334-339
- [10] 毕贵红,赵鑫,李璐,等.双模式分解CNN-LSTM集成的短期风速预测模型[J].太阳能学报,2023,44(3):191-197
BI Guihong, ZHAO Xin, LI Lu, et al. Dual-mode decomposition CNN-LSTM integrated short-term wind speed forecasting model [J]. Acta Energetica Solaris Sinica, 2023, 44(3): 191-197
- [11] 黄元生,杨磊,高冲,等.基于经验模态分解和误差校正的短期风速预测[J].智慧电力,2020,48(1):35-41
HUANG Yuansheng, YANG Lei, GAO Chong, et al. Short term wind speed prediction based on EMD and error correction [J]. Smart Power, 2020, 48(1): 35-41
- [12] Xiao C W, Ye J Q, Esteves R M, et al. Using Spearman's correlation coefficients for exploratory data analysis on big dataset [J]. Concurrency and Computation: Practice & Experience, 2016, 28(14): 3866-3878
- [13] Bai S, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J]. arXiv e-print, 2018, arXiv: 1803. 01271
- [14] 金涛,王晓峰,田润澜,等.基于改进1DCNN+TCN的雷达辐射源快速识别方法[J].系统工程与电子技术,2022,44(2):463-469
JIN Tao, WANG Xiaofeng, TIAN Runlan, et al. Rapid recognition method of radar emitter based on improved 1DCNN+TCN [J]. Systems Engineering and Electronics, 2022, 44(2): 463-469
- [15] 朱乔木,李弘毅,王子琪,等.基于长短期记忆网络的风电场发电功率超短期预测[J].电网技术,2017,41(12):3797-3802
ZHU Qiaomu, LI Hongyi, WANG Ziqi, et al. Short-term wind power forecasting based on LSTM [J]. Power System Technology, 2017, 41(12): 3797-3802
- [16] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544
- [17] 张舟.基于变分模态分解和梯度提升树的数控机床滚动轴承故障诊断研究[D].武汉:华中科技大学,2020
ZHANG Zhou. Rolling bearing fault diagnosis of CNC machine tool based on variational mode decomposition and gradient boosting decision tree [D]. Wuhan: Huazhong University of Science and Technology, 2020
- [18] 姜涛.基于变分模态分解神经网络模型时间序列预测[D].大连:大连理工大学,2020
JIANG Tao. Time series prediction of neural network model based on variational modal decomposition [D]. Dalian: Dalian University of Technology, 2020
- [19] 彭亚雄,刘广进,苏莹,等.基于变分模态分解算法的隧道爆破振动信号光滑降噪模型[J].振动与冲击,2021,40(24):173-179

PENG Yaxiong, LIU Guangjin, SU Ying, et al. A smooth denoising model of tunnel blasting vibration signal based on VMD [J]. Journal of Vibration and Shock, 2021, 40 (24):173-179

[20] 杨大为,冯辅周,赵永东,等.VMD 样本熵特征提取方法及其在行星变速箱故障诊断中的应用[J].振动与

冲击,2018,37(16):198-205

YANG Dawei, FENG Fuzhou, ZHAO Yongdong, et al. A VMD sample entropy feature extraction method and its application in planetary gearbox fault diagnosis [J]. Journal of Vibration and Shock, 2018, 37(16):198-205

Wind speed prediction in extreme weather based on error correction

LIU Shanfeng¹ LI Zhe¹ CHEN Jinpeng² LU Ming¹ XIANG Ling²

¹ Electric Power Research Institute of State Grid Henan Electric Power Company, Zhengzhou 450052, China

² School of Energy Power and Mechanical Engineering, North China Electric Power University, Baoding 071003, China

Abstract Accurate prediction of wind speed in extreme weather can provide important guidance for distribution network to enhance disaster prevention and resilience. This paper proposes a method based on Temporal Convolutional Network (TCN), Bi-directional Long Short-Term Memory (BiLSTM) and error correction for wind speed prediction in extreme weather. First, the time series characteristics of multi-feature weather data are extracted by TCN, and then input into BiLSTM for wind speed prediction. To further improve the prediction accuracy, Variational Mode Decomposition (VMD) is introduced to decompose the error sequence, and BiLSTM models are constructed to perform error prediction for the decomposed error subsequences respectively. Then the error prediction value is used to correct the wind speed prediction value. Finally, simulations are carried out for a place of Henan province, and the results show that compared with measured weather data, the proposed method can effectively predict wind speed with high accuracy when extreme weather occurs.

Key words wind speed; temporal convolutional network (TCN); bi-directional long short-term memory (BiLSTM); error correction; variational mode decomposition (VMD); prediction