

# 基于改进 LSTM-TCN 模型的 海上风电超短期功率预测

符杨<sup>1</sup>, 任子旭<sup>1</sup>, 魏书荣<sup>1\*</sup>, 王洋<sup>2</sup>, 黄玲玲<sup>1</sup>, 贾锋<sup>1</sup>

(1. 上海电力大学电气工程学院, 上海市 杨浦区 200090;

2. 国网江苏省电力有限公司经济技术研究院 江苏省 南京市 210008)

## Ultra-short-term Power Prediction of Offshore Wind Power Based on Improved LSTM-TCN Model

FU Yang<sup>1</sup>, REN Zixu<sup>1</sup>, WEI Shurong<sup>1\*</sup>, WANG Yang<sup>2</sup>, HUANG Lingling<sup>1</sup>, JIA Feng<sup>1</sup>

(1. College of Electrical Engineering, Shanghai University of Electric Power, Yangpu District, Shanghai 200090, China;

2. State Grid Jiangsu Electric Power Co., Ltd., Economic Research Institution, Nanjing 210008, Jiangsu Province, China)

**ABSTRACT:** Accurate prediction of wind power is an important means to realize friendly grid connection of large-scale offshore wind power. Large offshore wind farms have many units with different states. The influence of unit state, wake and space-time characteristics on wind power prediction cannot be ignored. Based on long short-term memory-temporal convolutional network (LSTM-TCN), an ultra-short-term power prediction method for offshore wind power was proposed in this paper, which considered the unit state, the wake of wind turbines and the spatial distribution characteristics of wind farms. Firstly, the influence of unit state and wake data on power prediction was analyzed, and then the deep learning prediction model of wind turbine operation data was established based on LSTM, which realized the mapping of unit health state to operation data, and continuously corrected the unit health state through real-time rolling of data. On this basis, the improved LSTM-TCN model was added with the modules of attention enhancement and random spatial characteristics weakening. Compared with TCN algorithm and LSTM algorithm, the proposed method could improve the accuracy of wind power prediction, especially for the common sudden change of wind speed at sea. This method improved the problem that TCN algorithm over-fits spatial characteristics.

**基金项目:** 国家自然科学基金项目(51907115); 上海市教委自然科学基金重大项目(2021-01-07-00-07-E00122); 上海高校特聘教授(东方学者)岗位计划(TP202066)。

Project Supported by National Natural Science Foundation of China (51907115); Major Natural Science Project of Shanghai Municipal Education Commission (2021-01-07-00-07-E00122); The Program for Professor of Special Appointment (Eastern Scholar) at Shanghai Institutions of Higher Learning (TP202066).

Based on the accurate prediction, it could be further used for coordinated optimization control of units in large-scale offshore wind farms, and thus improving the reliability of offshore wind power output.

**KEY WORDS:** offshore wind power; wind power prediction; unit status; spatio-temporal characteristics; temporal convolutional network

**摘要:** 风功率精确预测是实现大规模海上风电友好并网的重要手段。大型海上风电场机组台数众多, 状态各异。机组状态、尾流影响和时空特性对风功率预测的影响不可忽略。该文基于长短期神经网络(long short-term memory, LSTM)-时间卷积神经网络(temporal convolutional network, TCN), 提出了一种考虑机组状态、风机尾流和场群空间分布特性的海上风电超短期功率预测方法。首先分析了机组状态和尾流数据对于功率预测的影响, 然后基于 LSTM 建立了风电机组运行数据深度学习预测模型, 实现机组健康状态到运行数据的映射, 并通过数据的实时滚动对机组健康状态进行持续修正; 在此基础上, 加入注意力强化和随机空间特性弱化模块的改进 LSTM-TCN 模型。通过实际运行数据算例分析, 相比 TCN 算法、LSTM 算法, 该文方法可提升风功率预测的精度, 尤其对于海上常见的风速骤变工况适应性较强, 对 TCN 算法过于强化空间特性的问题进行改进。以该模型的精确预测为基础, 可进一步用于大规模海上风电场内机组的协调优化控制, 提升海上风电出力可靠性。

**关键词:** 海上风电; 风功率预测; 机组状态; 时空特性; 时间卷积神经网络

## 0 引言

我国海上风资源丰富, 靠近东南沿海负荷中

心，大力发展海上风电是实现 2030 年“碳达峰”、2060 年“碳中和”的重要手段。预计到 2030 年，中国海上风电装机总量将达到 58.8GW，中国将成为世界海上风电累计装机容量最大的国家<sup>[1-3]</sup>。对于我国东南沿海省市，该地区电网属于典型的受端电网，具有直流外送电源接入规模大、电网电力电子化程度高、本地可调节电源容量小等特点。随着大规模随机性和波动性海上风电接入，电网灵活供需失衡、电力实时平衡困难等问题日益凸显<sup>[4-5]</sup>。

对风电功率进行精准预测，并将其纳入调度计划，是提升受端电网的风电接纳能力，改善电力系统运行安全性和经济性的前提<sup>[6]</sup>。在此基础上，提升风功率预测技术的分辨率和准确性可实现风电场内经济优化调度，减少海上风电场的功率波动，提升功率可信度，进一步提供有效的惯性响应和频率支撑。

传统风功率预测一般可以分为物理模型法和统计模型法。对于海上风电来说，海水的比热容高，海上风流热效应及尾流效应显著等因素导致物理模型法预测难以完全适应<sup>[7]</sup>。统计模型法是通过神经网络等发掘发电量与气象信息潜在关联，从而实现预测的方法。文献[8-10]通过支持向量机、人工神经网络、小波神经网络等方法实现了风功率预测建模及预测。文献[11]通过长短期神经网络(long short-term memory, LSTM)对多变量时间序列进行动态建模，实现了风电功率的超短期预测。文献[12]融合传统门控循环单元神经网络和卷积神经网络，提升了模型对原始数据的特征提取和降维能力。文献[13]结合卷积神经网络(convolutional neural networks, CNN)和 LSTM 模型，同时获取风电场内多点风速超短期预测结果，对比传统方法有效提升模型精度。文献[14]引入了不同高度的风速数据，结合 CNN 和双向门控单元进行风速预测。但上述文献并未考虑风机运行的尾流影响，且海上风速波动性更强，风机分布更密集，卷积神经网络在预测时容易过度强化空间特性，导致机组个体特性不明显。

国内外众多学者的研究表明海上风电机组的出力性能与其健康状态联系紧密。文献[15-17]通过比较机组实际运行数据与健康状态模型预测值的残差来实现风机状态评估及故障诊断。文献[18-19]结合概率和模糊理论，依据概率不确定性融合得到综合健康状态指标，量化机组性能的劣化程度。文

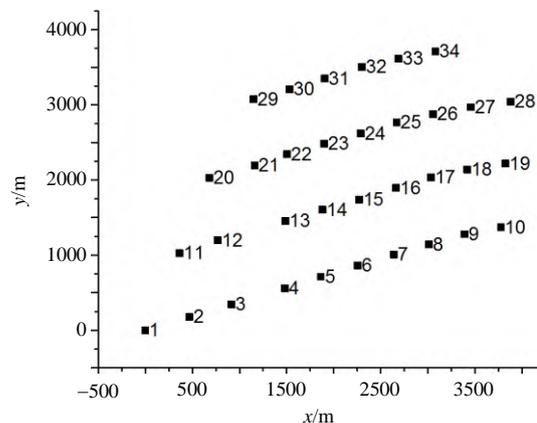
献[20]通过随机矩阵理论评估风电场状态，提出计及风电场状态的风电功率超短期预测方法，有效提升预测精度。但是海上风电机组系统众多，运行参数复杂，此时若仅采用短时相关性分析可能会遗漏部分关键数据，而使用过多数据则会导致网络参数过多，影响训练精度。

本文面向海上风电大规模接入受端电网的友好并网需求，首先通过 LSTM 建立风电机组健康度运行数据预测模型，并通过数据滚动实时更新实现机组健康状态的动态追踪；针对海上风功率预测的特殊需求，提出改进时间卷积神经网络(temporal convolutional network, TCN)模型，加入注意力学习强化模型，实现 SCADA 数据降维；加入随机空间特征弱化模型，提升风机个体特征预测精度。通过改进 LSTM-TCN 模型，综合机组状态、尾流的影响，实现考虑海上空间特性的风功率超短期精确预测，为大规模海上风电的友好并网提供研究基础与数据支撑。

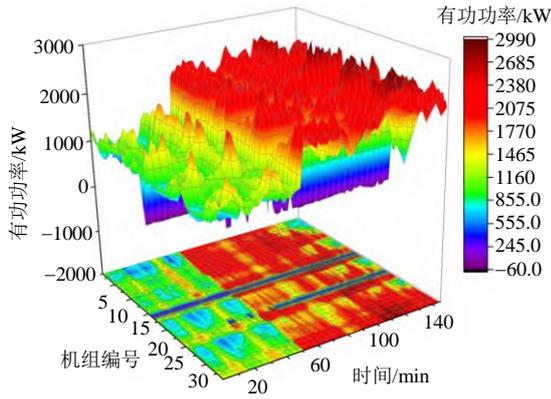
## 1 机组时-空-功率特性分析

海上风电场机组出力受空气流动的时空特性影响，同时上游机组的尾流效应也会影响整个风电场的功率分布，图 1(a)为某海上风电场 34 台机组风机坐标，图 1(b)为 24h 内各机组功率变化 3D 图及其投影。

图 1(b)为风电场 34 台风机 24h 内功率 3D 图及其投影。从投影图纵向来看，风机出力波动呈现与时间强相关的特性，即不同风机的功率变化具有同时性；横向来看，同一时间下，相邻风机往往具有相似的功率波动特性。同时也要考虑上游风机的尾流效应影响，风机的空间位置也在一定程度上影响了单个风机的出力特性。



(a) 风机坐标



(b) 风电场 24h 功率 3D 图

图 1 某海上风电场风机坐标及其 24h 功率 3D 图

Fig. 1 Wind turbine coordinates of an offshore wind farm and its 24h power 3D diagram

### 2 基于改进 LSTM-TCN 的功率预测建模

长短期记忆神经网络(LSTM)是风功率预测常用的方法, LSTM 对于时间序列的预测具有良好的性能<sup>[22]</sup>。但是场内空气流动具有空间特性, 风机空间分布也会影响尾流效应, 忽略这一特性可能会影响预测精度, 其输入输出架构不便于调整, 难以从风电场层面预测单台风机的功率变化; 且 LSTM 在非常长的数据上训练困难, 难以适用于长时间尺度的训练。

时间卷积神经网络(TCN)是一种新型的可以用于解决时间序列预测的算法。同时, TCN 提供了一种统一的方法来分层捕获时空信息。其特点主要为: ①卷积网络不同层之间具有因果关系, 不会遗漏历史信息和使用未来信息。②TCN 每个输出层都可以保持和输入层一样多的长宽被继续传递, 架构可以根据需要调整为任意长度。

#### 2.1 基于 LSTM 的机组状态预测模型

风电机组的功率一方面取决于风速、风向等自然因素, 另一方面也取决于机组状态、健康度等。风电场功率预测时, 场群内机组众多, 机组状态各异, 机组参数与风速等又呈现强相关的时变特性, 因此有必要建立机组参数预测模型, 根据气象天气预报数值, 动态预测机组参数的反馈值, 从而体现机组实时状态。机组状态数据与风速高度相关, 其对于风速数据的响应值可反应机组状态, 且同一风电场内的机组, 其健康度并无明显的空间联系, 本文采用 LSTM 进行机组状态数据的预测。LSTM 模型在风功率预测、电力系统负荷预测等领域已有较多应用, 不再赘述。

#### 2.2 Jensen 尾流模型

Jensen 尾流模型可根据动量损失理论预测尾流场, 其计算方法如式(1)所示。

$$C_{wake} = 1 - (1 - \sqrt{1 - C_t}) \left( \frac{D}{D + 2kx} \right)^2 \left( \frac{A_{overlap}}{A_{wt2}} \right) \quad (1)$$

式中:  $C_t$  为风机推力系数;  $D$  为风机叶轮直径;  $k$  为尾流衰减因子;  $x$  为风机轴向距离;  $A_{overlap}$  为下游风机盘面与上游风机尾流截面的重叠面积;  $A_{wt2}$  为下游风机扫风面积。

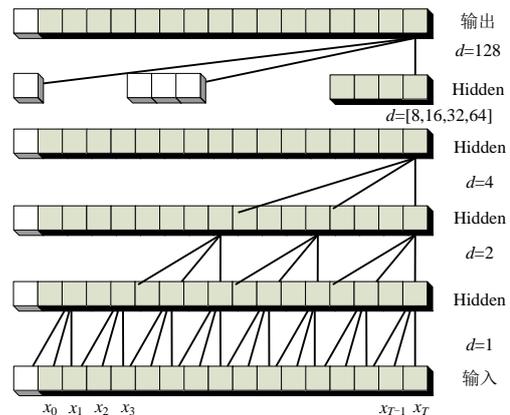
#### 2.3 TCN 网络预测模型

TCN 主要结构可分为适用于序列的因果卷积以及适用于历史数据记忆的膨胀卷积加残差模块模型。由于风电场运行 SCADA 数据时间跨度长, 采用后者以便于记忆更多的历史数据。

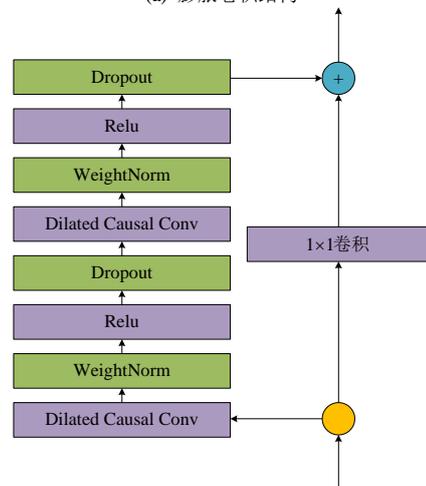
##### 2.3.1 膨胀卷积及残差连接

TCN 的结构如图 2(a)所示, 每个 TCN 层含有  $L$  个卷积层, 扩张卷积计算公式为

$$F(s) = (x * df)(s) = \sum_{i=0}^{k-1} f(i)X_{s-d-i} \quad (2)$$



(a) 膨胀卷积结构



(b) 残差连接结构

图 2 时间卷积神经网络结构

Fig. 2 Structure of temporal convolutional network

式中：其空系数  $d=[1, \dots, 2^L]$ ，图 2 中以 8 层为例，空洞系数  $d=[1, 2, 4, 8, 16, 32, 64, 128]$ ；卷积核大小  $k=3$ ，可感受风机一天内所有数据点。

### 2.3.2 残差链接

神经网络的表达能力随着网络深度的增加逐渐增强，但是网络结构的深度的增加导致梯度消失、梯度爆炸等一系列问题，残差连接(skip connect, SC)很好地解决了深度神经网络的退化问题，同等层数的前提下残差网络也收敛得更快，这使得前馈神经网络可以采用更深的设计<sup>[23]</sup>。除此之外，去除个别神经网络层，残差网络的表现不会受到显著影响<sup>[23]</sup>。

图 2(b)为残差链接结构图，Dropout 表示在神经元传播过程中，让某个神经元的激活值以一定概率停止工作，从而增强模型的泛化性；Relu 表示线性整流函数，用作神经网络的激活函数；Weight Norm 表示对权重值归一化；Dilated Causal Conv 表示空洞卷积层。

式(3)—(4)表示 TCN 激活函数：

$$\hat{S}_t^{(j,l)} = f(W^{(1)}S_{t-s}^{(j,l-1)} + W^{(2)}S_t^{(j,l-1)} + b) \quad (3)$$

$$S_t^{(j,l)} = S_t^{(j,l-1)} + V\hat{S}_t^{(j,l)} + e \quad (4)$$

式中： $W^{(1)}$ 、 $W^{(2)}$ 为对应输入的权重矩阵； $b$ 为偏置向量； $S_{(i,j)}$ 为第  $j$  块第  $i$  层的激活函数；式(2)表示  $t$  时刻膨胀卷积的结果；式(4)表示加入残差后的结果。

## 2.4 改进 TCN 网络

海上 SCADA 系统记录机组参数种类多，时间跨度长，相关性分析结果难以全面覆盖，所以仅通过相关性分析筛选一定时间尺度下与功率具有强相关的机组参数容易损失关键数据，影响预测精度。若使用全部数据训练，则数据集维度过大，神经网络产生大量参数，训练缓慢，甚至导致维数灾。

TCN 对于空间特征的捕捉效果显著，但是卷积网络容易过度强化数据的空间特性，削弱个体特征。本文针对海上风电功率预测的特殊应用场景，在传统 TCN 网络的基础上，分别从注意力学习强化、随机空间特征弱化两个方面进行改进。

### 2.4.1 注意力学习强化

首先在通道层对输入数据进行乱序(shuffle, S)，再引入全局平均池化层(globalaveragepool, G)，原矩阵  $A$  与输出矩阵  $B$  关系可表示为

$$B = G[S(A)] \quad (5)$$

式中： $S$ 为乱序； $G$ 为平均全局池化。

$$C = N\{L[M_k(B)]\} \quad (6)$$

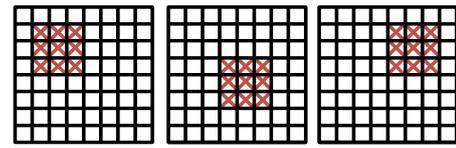
式中： $N$ 为标准化； $L$ 为线性化； $M$ 为多层感知器(MLP)，可以减少通道数量，其感知比定义为输出通道与输入通道之比， $k=C_{out}/C_{in}$ 。

通过注意强化模型可以降低原始数据维数，减少无关的机组数据，简化训练模型，增加神经网络层数。

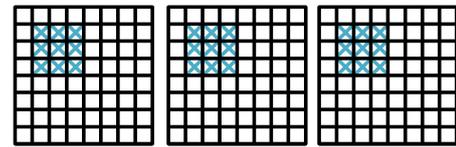
### 2.4.2 随机空间特性弱化

2018 年 Golnaz 等提出了一种针对卷积层的正则化方法 DropBlock，可有效提升神经网络精度<sup>[24]</sup>。

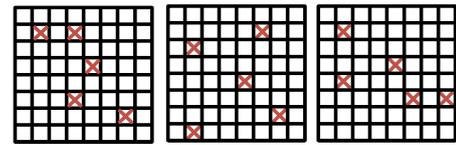
DropBlock 的常见结构如图 3(a)—(c)所示，针



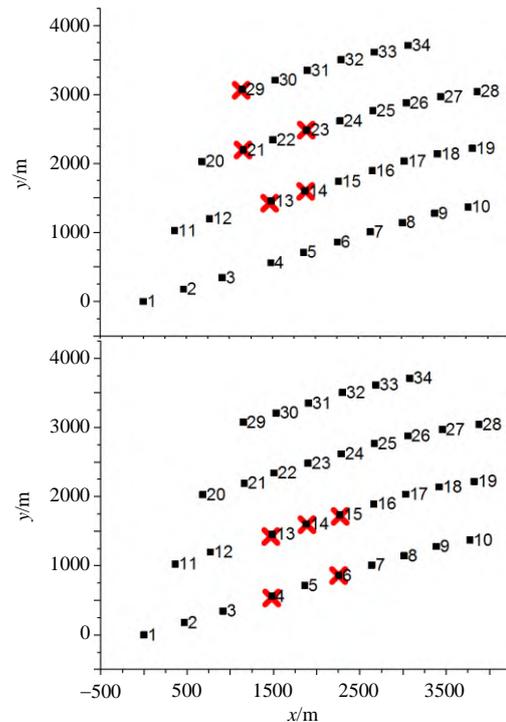
(a) DropBlock



(b) 批量 DropBlock



(c) 随机 DropBlock



(d) 随机风机 DropBlock

图 3 DropBlock 结构

Fig. 3 Structure of the DropBlock

对海上风功率预测特定需求，本文设定了一种 DropBlock 的特殊形式，如图 3(d)，即在丢弃特征时随机选取一台风机，丢弃与其几何距离最近的 5 台风机数据，丢弃率约为 15%。

### 2.5 改进 TCN 网络模型结构

图 4 为改进 TCN 模型结构示意图，原始数据

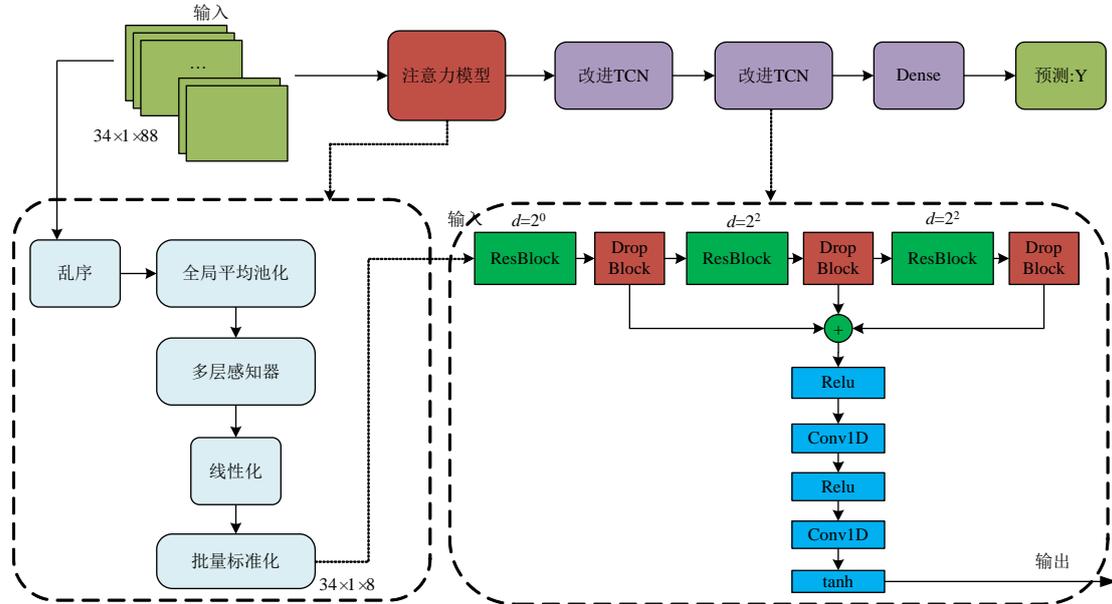


图 4 改进 TCN 模型结构

Fig. 4 Model structure of improved TCN

### 2.6 损失函数选择

平均绝对误差(mean absolute error, MAE)为绝对误差的平均值，以  $M$  表示，可以很好的反应预测值误差的实际情况。其计算方法为

$$M = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (7)$$

由于海上风电场运行时间长，采样频率密集，数据众多，可能存在大量异常数据，而 MAE 对于异常数据有较强的鲁棒性。同时变速率学习可有效改善 MAE 梯度固定的缺陷。

均方根误差(root mean squared error, RMSE)是预测值与真实值偏差的平方与观测次数  $n$  比值的平方根，以  $R$  表示，常用来衡量预测值与真实值之间的偏差，是风功率预测常用的评价指标之一。

$$R = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (8)$$

分位数回归是回归分析的常用方法之一，是通过求取样本到回归曲线的垂直距离加权求和得到的，以  $Q$  表示。其公式为

$$Q = \frac{1}{n} \left[ \sum_{i: Y_i \geq \xi, au} \tau (y_i - \hat{y}_i)^2 + \sum_{i: Y_i < \xi, au} (1 - \tau) (y_i - \hat{y}_i)^2 \right] \quad (9)$$

通过注意力学习模型(attention learning module, ALM)强化后，将输入数据通道数降低 91%，减少了网络模型参数，提升训练速度；接着进入 2 层考虑随机空间特征弱化的改进 TCN 模型，在考虑风速时空特性的基础上，强化了机组的个体特征；最后通过全连接层(dense)输出预测结果。

式中： $\tau$ 为拟合曲线之上的样本权重； $(1-\tau)$ 为拟合曲线之下的样本权重。

### 2.7 预测流程

机组状态自投产以来一般为动态劣化的过程，使用短时数据训练机组状态模型可更好的拟合风机近期的健康状态。而对于风功率预测模型，应采用长时间尺度的数据以求使神经网络模型获取到更多工况，以增加预测精度。

本文所构建的模型预测流程如图 5 所示。

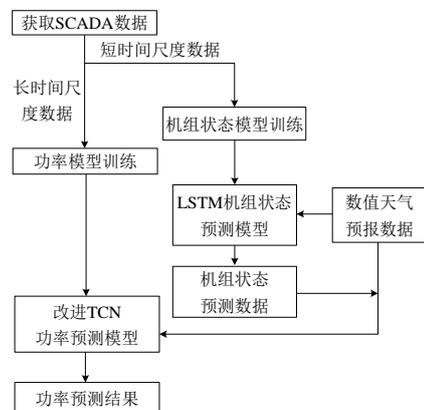


图 5 改进 LSTM-TCN 模型预测流程图

Fig. 5 Prediction structure of improved LSTM-TCN model

1) 获取 SCADA 数据, 30 天内数据划分为长时间尺度数据, 24h 内数据划分为短时间尺度数据。同时划分训练集和验证集, 时间序列上前 90% 数据划分为训练集, 后 10% 数据划分为验证集。

2) 长时间尺度数据用于训练功率预测模型, 短时间尺度数据用于训练机组状态模型。

3) 通过数值天气预报结合机组状态模型, 预测机组状态数据, 作为功率预测模型的输入数据。

4) 结合数值天气预报数据、机组状态预测数据, 通过功率预测模型预测机组输出功率。

### 3 运行数据分析

#### 3.1 数据标准化处理

本文选择上海地区某海上风电场数据进行分析, TCN 功率预测模型采用该风电场 34 台机组 2018 年 6 月 SCADA 数据进行训练。机组状态模型采用各机组 24h 前相关数据进行训练。在进行神经网络训练时, 加入桨距角数据便于学习超出额定风速时的机组功率特性, 以及风向正弦值以强化数据的空间特性<sup>[25]</sup>。

SCADA 数据间隔采样时间为 10min, 使用采样间隔变换的方法统一时间间隔为 15min<sup>[26]</sup>。

风机 SCADA 数据可能包含大量异常数据和重复数据, 向模型输入过多重复数据可能会导致计算复杂化, 并可能导致不必要的输出。数据的标准化是将未处理的数据转化成相似尺度的方法, 这有助于提升模型训练的收敛速度和预测精度。

标准差标准化(zero-mean normalization, ZN)是常用的标准化方法, 这种方法基于原始数据的均值和标准差进行数据的标准化, 标准差标准化方法适用于数据的最大值和最小值未知的情况, 或有超出取值范围的离群数据的情况。其转化函数为

$$x^* = \frac{x - \mu}{\sigma} \quad (10)$$

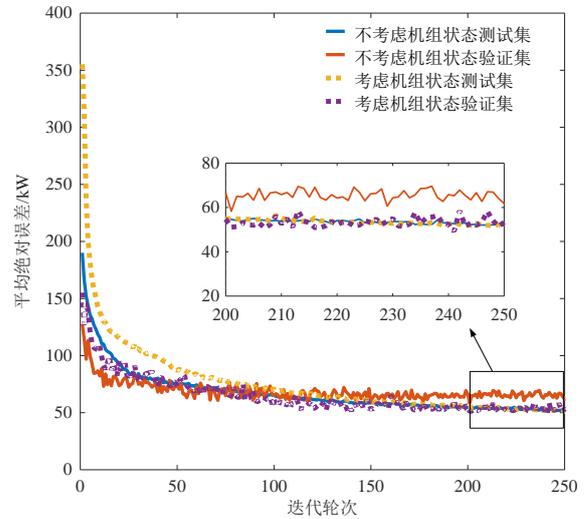
式中:  $\mu$  为所有样本数据的均值;  $\sigma$  为所有样本数据的标准差。标准差标准化处理后的数据在 0 到 1 之间, 符合标准正态分布。

#### 3.2 机组状态及尾流影响分析

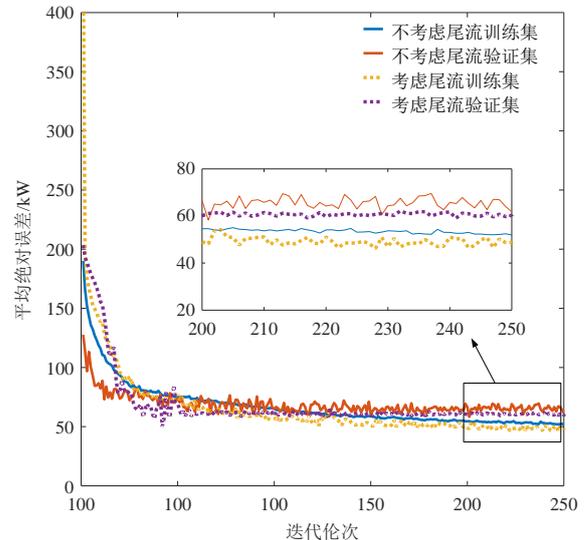
本节通过用考虑机组状态与未考虑机组状态的数据集、考虑尾流与未考虑尾流的数据集训练同一 TCN 网络来比较机组状态数据对于机组功率预测的影响。

采用某海上风电场 34 台机组 2018 年 6 月数据

进行训练, 前 90% 数据划分为测试集, 后 10% 数据为训练集训练集。训练 250 次后平均绝对误差收敛性如图 6 所示。



(a) 是否考虑机组状态对比图



(b) 是否考虑尾流对比图

图 6 是否考虑机组状态、尾流对比图

Fig. 6 Whether to consider the comparison chart of unit status and wake flow

不考虑机组状态时, 数据集含有风速、风向、变桨角度及待预测的风电功率。考虑机组状态时加入 LSTM 机组状态模型预测结果, 这其中包含 SCADA 系统中的所有数据, 并通过注意力模型筛选弱相关数据。从图 6(a)中可以看出, 不考虑机组状态时, 数据量小, 网络收敛速度更快。但是在约 100 次训练之后出现了过拟合的情况, 其训练集与测试集 MAE 差距明显。

考虑机组状态影响时, 数据量增多, 神经网络参数相应增加, 在训练开始时收敛速度慢, 但是经过一段时间训练后, 其训练集误差与不考虑机组状态相当, 且其测试集预测误差与训练集基本一致, 几

乎无过拟合的情况。

考虑尾流影响的数据集在不考虑机组状态数据集中加入了尾流数据,同样进行250次训练(图6(b))。可以看出尾流数据同样可以改善过拟合现象,但MAE仍有一定偏差。在功率预测时可同时采用机组状态和尾流数据的模型,以提升预测精度。

### 3.3 改进TCN模型评价分析

为验证时空特性对于机组功率预测的影响,本节将改进TCN与传统TCN方法、以及时间序列常用预测方法LSTM对比。LSTM采用单台机组分别预测功率的方式,规避时空特性的影响。所有算法均训练250个循环。

图7(a)为风电场各机组一天内真实功率热力图,图7(b)为本文算法预测结果,图7(c)为TCN算法预测结果。可以看出,本文方法与TCN预测等功率线明晰、且与真实数据基本一致,说明其对于0~100min、800~1000min两段风速高峰以及机组出力的空间特性均实现了较好捕捉。但在图7中红色、白色框线两处细节可以看出,TCN预测结果过度拟合了风功率的空间特性,在边界细节处表现不佳,

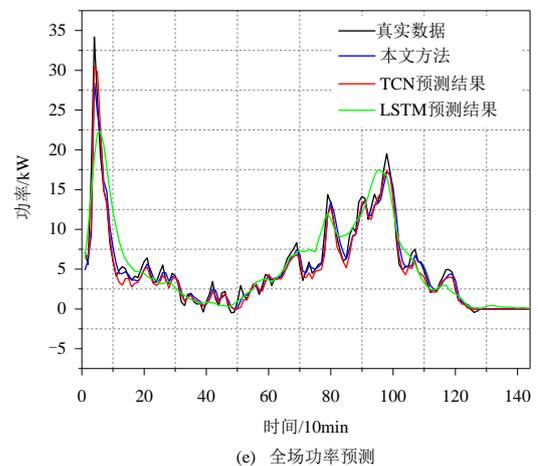
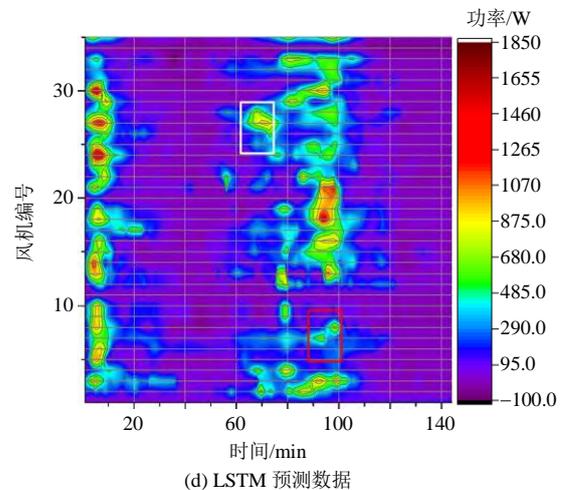
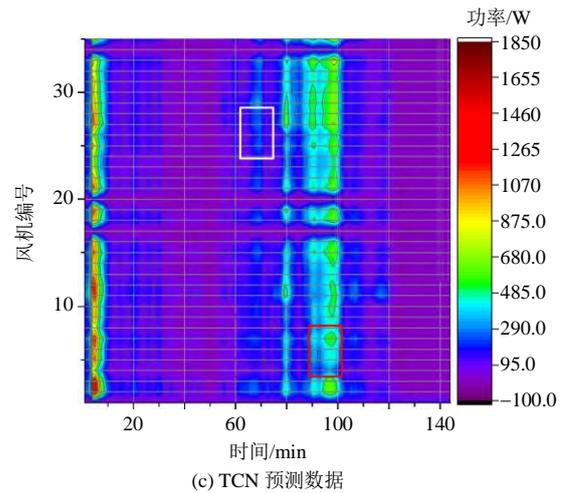
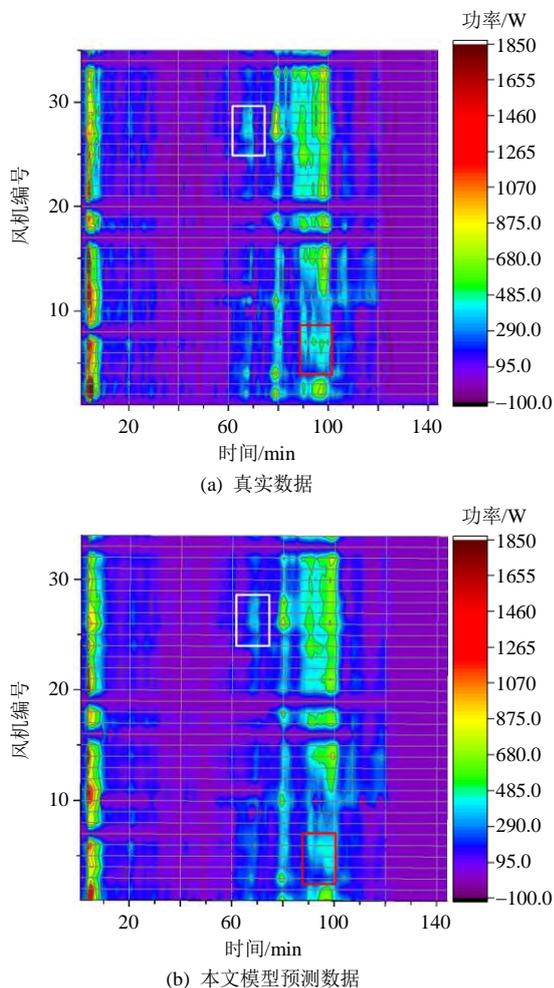


图7 改进TCN、TCN与LSTM算例对比

Fig. 7 Comparison of improved TCN, TCN, and LSTM examples

本文方法相比TCN提升了机组个体的预测细节。

图7(d)为单机LSTM预测结果。LSTM模型等功率线边界模糊,场群空间特性的还原能力弱于前两种方法,对于峰值预测误差较大。同时,对于11号、20号机组的工况识别出现明显误差,这是由于LSTM对于长时间数据的训练能力不足。

图7(e)为全场功率预测结果比较,可以看出,

在都考虑机组状态影响时，本文方法预测误差最小，且准确还原了风速骤变引起的风功率波动，TCN 模型与本文模型性能接近。由于风电场集群的平滑效应，LSTM 虽可以预测整场出力趋势，但是对于风速骤变的响应差于 TCN 模型；其预测精度可用于制定发电计划，难以满足更高分辨率的风功率预测需求。

表 1 为 1 号机组 3 种算法 4h 预测误差比较，均采用 MAE、RMSE、相关系数来衡量模型的有效性，比较可得本文算法精度高于传统 TCN 模型和 LSTM 模型，在单机超短期功率预测时效果良好，24h 预测误差采用 6 次 4h 滚动预测得出，结果见附录 A1。

表 1 1 号机组 3 种算法前 4h 平均功率预测误差比较

Table 1 Comparison of prediction errors of three algorithms in the first 4 hours of unit 1

对比	M/kW	M 百分比	R/kW	R 百分比	相关系数
本文算法	87.77	9.65	102.14	11.23	93.08
TCN	92.54	10.17	124.97	13.74	91.06
LSTM	119.36	13.12	139.70	15.36	88.96

表 2 为 3 种算法全场功率预测误差比较，比较指标同表 1。

表 2 3 种算法前 4h 全场平均功率预测误差比较

Table 2 Comparison of prediction errors of full-field average power in the first 4 hours of three algorithms

对比	M/kW	M 百分比	R/kW	R 百分比	相关系数
本文算法	777.63	8.79	998.65	11.29	95.35
TCN	966.89	10.93	1500.50	16.97	92.53
LSTM	1498.74	16.95	2064.12	23.34	80.32

在全场预测时，本文算法误差略有下降，这是由于 1) 本文算法对机组个体特征的提取性能更强；2) 部分机组存在停机工况。TCN 算法在个体和场群预测时，误差基本一致，但场群功率较高，R 百分比相应略微提升。而 LSTM 由于预测时采用的单台机组分别预测，单机功率叠加得到场群功率的方法，表现明显差于其他两种算法。6 次滚动预测得出的 24h 误差表格见附录 A2。

### 3.4 置信区间宽度比较

受海上风功率的强不确定性的限制，在海上风电场为电力系统提供频率支撑时，精准预测风电场出力一定置信区间下的上下限尤为重要。

一方面，这有助于确定风电场功率波动范围，保障电力系统安全稳定运行；另一方面，可用于评估风电场功率极限，进而确定电力系统调度和风电

场内协调控制指令，有助于降低系统运行成本和提高风电场效益。

本节选择分位数回归函数作为 3 种算法损失函数，选取 95% 置信区间，3 种算法均训练 250 个循环，结果如图 8 所示。

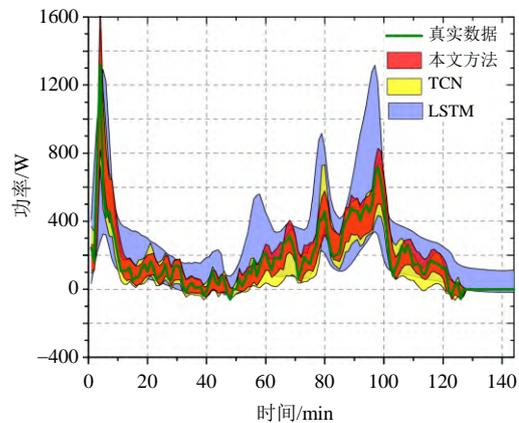


图 8 95% 置信区间下单机功率预测比较

Fig. 8 Comparison of single machine power prediction under 95% confidence interval

图 8 为 95% 置信度约束下，19 号机组本文方法与 TCN、LSTM 预测区间比较。在单机风功率预测时，相同置信度的约束下，本文算法及 TCN 算法对于前 100min 的风速骤增，优越性明显，且其区间包络线较好的还原了真实数据的波动特性，且上边界准确预测到了 1300min 后的停机动作。TCN 算法与本文方法在置信区间的预测上性能接近，但本文方法预测区间更窄。

LSTM 预测区间较宽，包络线较为平滑，丢失了部分风功率波动信息，LSTM 预测上限也难以准确反应约 1300min 后的停机工况。

图 9 为全场功率预测比较，LSTM 在预测时采用单台机组分别预测再叠加的方法，其预测区间缺

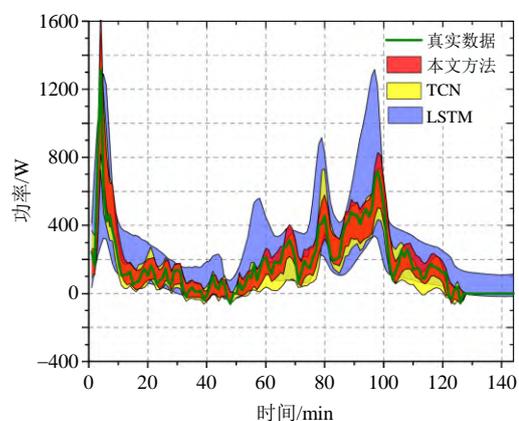


图 9 95% 置信区间下 TCN 与 LSTM 全场功率预测比较  
Fig. 9 Comparison of full-field power prediction between TCN and LSTM under 95% confidence interval

失了重要的风速波动信息；本文方法和 TCN 算法整场功率预测时，包络线仍能较好的还原真实数据波动，本文算法预测区间略小于 TCN 算法。

不论是在单机还是整场预测上，本文方法的预测区间宽度更窄，性能更加优越。

### 3.5 模型训练时间比较

本文算例在基于 AMD Ryzen 7 3700X 8C-16T 处理器、32GB 内存、Nvidia GeForce GTX 1660 的 PC 平台进行，运行环境为基于 python 的 Tensorflow-gpu 2.3.0。

如 3.1 节所述，本文算例中功率预测模型选取的是 30 天的数据进行训练，属长时间尺度数据，同时加入高维度的机组状态数据，训练数据量庞大。表 3 为本文算法与 TCN、LSTM 算法训练时间比较，所有算法均训练 250 个循环，由于 LSTM 模型为各个机组单独训练，其结果为一次训练时间乘以 34 计算所得。

表 3 模型训练时间比较

Table 3 Comparison of model training time

模型	训练时间/min
本文算法	18.3
TCN	203.6
LSTM	158.4

在工程应用时，3 种方法只需使用训练好的模型，定期进行更新即可。对于预测阶段 3 种方法均可在秒级快速得出预测结果，故此处仅比较模型的训练速度。本文算法通过引入注意力强化机制，降低模型训练数据维度，大幅缩短了训练时间。而 TCN 与 LSTM 需要 2h 以上的训练时间。

## 4 结论

随着东南沿海电网非同步电源比例的增加，亟须提升海上风电并网功率的可靠性。本文提出了一种基于改进 LSTM-TCN 算法的超短期风功率预测方法，得到如下结论：

1) 在模型的训练数据中考虑机组状态数据及尾流数据，可改善模型的过拟合现象，有效提升预测精度。

2) 基于 TCN 算法获取机组时空特性，通过强化注意力模型实现了机组数据降维，弱化机组的空间特性，改进了传统 TCN 对于空间特性过度强化的问题，减小单台机组预测平均绝对误差 0.5%。

3) 通过算例分析，本文提出的改进 LSTM-TCN

算法与传统 TCN 算法相比，减小全场预测平均绝对误差 2%、有效减小预测区间。同等计算条件下，缩短 90% 模型训练时间。

所提方法可用于大型海上风电场的精准调度，后续工作将开展基于预测结果的大规模海上风电场群优化运行，进而为电网提供高可靠的频率支撑，提升以新能源为主体的新型电力系统稳定性。

### 致谢

本文在完成的过程中，受到“电气工程”上海市 II 类高原学科及上海市电站自动化技术重点实验室提供的实验设备支持，在此表示衷心感谢。

### 参考文献

- [1] Joyce LEE, Feng Zhao. Global Offshore Wind Report 2020[R]. Brussels Belgium: Global Wind Energy Council, 2020.
- [2] 邓银秋, 汪震, 韩俊飞, 等. 适用于海上风电接入的多端柔直网内不平衡功率优化分配控制策略[J]. 中国电机工程学报, 2020, 40(8): 2406-2415.  
DENG Yinqiu, WANG Zhen, HAN Junfei, et al. Control strategy on optimal redistribution of unbalanced power for offshore wind farms integrated VSC-MTDC[J]. Proceedings of the CSEE, 2020, 40(8): 2406-2415(in Chinese).
- [3] 朱磊, 黄河, 高松, 等. 计及风电消纳的电动汽车负荷优化配置研究[J]. 中国电机工程学报, 2021, 41(S1): 194-203.  
ZHU Lei, HUANG He, HE Yuhuan, et al. Research on optimal load allocation of electric vehicle considering wind power consumption[J]. Proceedings of the CSEE, 2021, 41(S1): 194-203(in Chinese).
- [4] 崔杨, 邓贵波, 赵钰婷, 等. 考虑源荷低碳特性互补的含风电电力系统经济调度[J]. 中国电机工程学报, 2021, 41(14): 4799-4815.  
CUI Yang, DENG Guibo, ZHAO Yuting, et al. Economic dispatch of power system with wind power considering the complementarity of low-carbon characteristics of source side and load side[J]. Proceedings of the CSEE, 2021, 41(14): 4799-4815(in Chinese).
- [5] 王涛, 王廷涛, 刘芮, 等. 计及动态频率响应约束的高比例风电电力系统机组组合模型[J]. 高压技术, 2021, 47(10): 3463-3479.  
WANG Tao, WANG Yantao, LIU Rui, et al. Unit commitment model of high proportion wind power system considering dynamic frequency response constraints[J]. High Voltage Engineering 2021, 47(10): 3463-3479(in Chinese).
- [6] 王勃, 刘纯, 张俊, 等. 基于 Monte-Carlo 方法的风电

- 功率预测不确定性估计[J]. 高电压技术, 2015, 41(10): 3385-3391.
- WANG Bo, LIU Chun, ZHANG Jun, et al. Uncertainty evaluation of wind power prediction based on monte-carlo method[J]. High Voltage Engineering, 2015, 41(10): 3385-3391(in Chinese).
- [7] 彭晓涛, 贾继超, 周际城, 等. 优化风电惯性响应的变比例系数调速策略[J]. 中国电机工程学报, 2018, 38(19): 5625-5635.
- PENG Xiaotao, JIA Jichao, ZHOU Jicheng, et al. Speed regulation strategy based on variable proportion coefficient for optimizing inertial response of wind generator[J]. Proceedings of the CSEE, 2018, 38(19): 5625-5635(in Chinese).
- [8] 刘吉臻, 姚琦, 柳玉, 等. 风火联合调度的风电场一次调频控制策略研究[J]. 中国电机工程学报, 2017, 37(12): 3462-3469.
- LIU Jizhen, YAO Qi, LIU Yu, et al. Wind farm primary frequency control strategy based on wind & thermal power joint control[J]. Proceedings of the CSEE, 2017, 37(12): 3462-3469(in Chinese).
- [9] 李世春, 黄悦华, 王凌云, 等. 基于转速控制的双馈风电机组一次调频辅助控制系统建模[J]. 中国电机工程学报, 2017, 37(24): 7077-7086.
- LI Shichun, HUANG Yuehua, WANG Lingyun, et al. Modeling Primary frequency regulation auxiliary control system of doubly fed induction generator based on rotor speed control[J]. Proceedings of the CSEE, 2017, 37(24): 7077-7086(in Chinese).
- [10] 符杨, 郑紫宸, 时帅, 等. 考虑气象相似性与数值天气预报修正的海上风功率预测[J]. 电网技术, 2019, 43(4): 1253-1259.
- FU Yang, ZHENG Zichen, SHI Shuai, et al. Offshore wind power forecasting considering meteorological similarity and NWP correction[J]. Power System Technology, 2019, 43(4): 1253-1259(in Chinese).
- [11] 刘爱国, 薛云涛, 胡江鹭, 等. 基于 GA 优化 SVM 的风电功率的超短期预测[J]. 电力系统保护与控制, 2015, 43(2): 90-95.
- LIU Aiguo, XUE Yuntao, HU Jianglu, et al. Ultra-short-term wind power forecasting based on SVM optimized by GA[J]. Power System Protection and Control, 2015, 43(2): 90-95(in Chinese).
- [12] 彭怀午, 刘方锐, 杨晓峰. 基于人工神经网络的风电场短期功率预测[J]. 太阳能学报, 2011, 32(8): 1245-1250.
- PENG Huaiwu, LIU Fangrui, YANG Xiaofeng. Short term wind power forecasting based on artificial neural network [J]. Acta Energeiae Solaris Sinica, 2011, 32(8): 1245-1250(in Chinese).
- [13] 梁超, 刘永前, 周家慷, 等. 基于卷积循环神经网络的风电场内多点位风速预测方法[J]. 电网技术, 2021, 45(2): 534-541.
- LIANG Chao, LIU Yongqian, ZHOU Jiakang, et al. Wind speed prediction at multi-locations based on combination of recurrent and convolutional neural networks[J]. Power System Technology, 2021, 45(2): 534-541(in Chinese).
- [14] 凡航, 张雪敏, 梅生伟, 等. 基于时空神经网络的风电场超短期风速预测模型[J]. 电力系统自动化, 2021, 45(1): 28-35.
- FAN Hang, ZHANG Xuemin, MEI Shengwei, et al. Ultra-short-term wind speed prediction model for wind farms based on spatiotemporal neural network[J]. Automation of Electric Power Systems, 2021, 45(1): 28-35(in Chinese).
- [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(in Chinese).
- [16] 牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备, 2018, 38(5): 36-42.
- NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 36-42(in Chinese).
- [17] 韩爽, 孟航, 刘永前, 等. 增量处理双隐层 BP 神经网络风电功率预测模型[J]. 太阳能学报, 2015, 36(9): 2238-2244.
- HAN Shuang, MENG Hang, LIU Yongqian, et al. Study on optimization of bp neural network wind power prediction model with two hidden layers[J]. Acta Energeiae Solaris Sinica, 2015, 36(9): 2238-2244(in Chinese).
- [18] 刘军, 汪继勇. 基于风电机组健康状态的风电场功率分配研究[J]. 电力系统保护与控制, 2020, 48(20): 106-113.
- LIU Jun, WANG Jiyong. Research on power distribution of a wind farm based on the healthy state of wind turbines[J]. Power System Protection and Control, 2020, 48(20): 106-113(in Chinese).
- [19] 乔福宇, 马良玉, 马永光. 基于功率曲线分析与神经网络的风电机组故障预警方法[J]. 中国测试, 2020, 46(8): 44-50.
- QIAO Fuyu, MA Liangyu, MA Yongguang. Wind turbine fault early warning method based on power curve analysis and neural network[J]. China Measurement & Test, 2020, 46(8): 44-50(in Chinese).
- [20] 杨茂, 周宜. 计及风电场状态的风电功率超短期预测[J]. 中国电机工程学报, 2019, 39(5): 1259-1267.

- YANG Mao, ZHOU Yi. Ultra-short-term prediction of wind power considering wind farm status[J]. Proceedings of the CSEE, 2019, 39(5): 1259-1267(in Chinese).
- [21] JIN Hui, YANG Libin, GAN Jiatian, et al. Risk assessment of grid frequency deviation related to correlation considering wind speed and wind direction in a wind farm[C]//Proceedings of the 2nd IEEE Conference on Energy Internet and Energy System Integration(EI2). Beijing, China: IEEE, 2018.
- [22] BANIK A, BEHERA C, Sarathkumar T V, et al. Uncertain wind power forecasting using LSTM-based prediction interval[J]. IET Renewable Power Generation, 2020, 14(14): 2657-2667.
- [23] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016.
- [24] GHIASI G, LIN T Y, LE Q V. Dropblock: a regularization method for convolutional networks[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal, Canada: Curran Associates Inc, 2018.
- [25] 马然, 栗文义, 齐咏生. 基于风功率数据的风电机组性能预测与健康状态评估[J]. 可再生能源, 2019, 37(8): 1252-1259.
- MA Ran, LI Wenyi, Qi Yongsheng. Performance degradation prognostic and health assessment using wind power data for wind turbine generation unit[J]. Renewable Energy Resources, 2019, 37(8): 1252-1259(in Chinese).
- [26] 周宜. 大数据背景下的风电功率超短期预测[D]. 吉林: 东北电力大学, 2019.
- ZHOU Yi. Wind power ultra-short-term prediction in the background of big data[D]. Jilin: Northeast Electric Power University, 2019(in Chinese).

## 附录A 单机及全场平均功率预测误差比较

表A1 1号机组3种算法24h平均功率预测误差比较

Table A1 Comparison of prediction errors of three algorithms in the 24 hours of unit 1

模型	MAE/%				RMSE/%				相关系数			
	4h	8h	12h	24h	4h	8h	12h	24h	4h	8h	12h	24h
本文算法	9.65	9.21	9.33	8.97	11.23	10.78	11.04	10.81	93.08	93.76	92.53	93.84
TCN	10.17	10.22	10.65	10.11	13.74	14.62	14.81	13.94	91.06	90.63	90.30	91.29
LSTM	13.12	12.36	13.53	12.63	15.36	14.96	15.83	15.13	88.96	89.44	87.72	88.63

表A2 3种算法24h全场平均功率预测误差比较

Table A2 Comparison of 24-hour full-field average power prediction errors of three algorithms

模型	MAE/%				RMSE/%				相关系数			
	4h	8h	12h	24h	4h	8h	12h	24h	4h	8h	12h	24h
本文算法	8.79	8.47	8.61	8.16	11.29	10.89	11.57	10.61	95.35	95.72	95.44	96.18
TCN	10.93	10.19	10.77	9.76	16.97	15.76	16.15	14.88	90.53	91.63	90.60	92.02
LSTM	16.95	15.25	15.62	14.02	23.34	21.67	22.66	21.71	80.32	82.27	81.31	84.48



符杨

在线出版日期: 2021-07-27。

收稿日期: 2021-04-08。

作者简介:

符杨(1968), 男, 博士, 教授, 主要从事电力系统分析、风力发电并网技术研究及海上风电优化设计研究, mfudong@126.com;

任子旭(1993), 男, 博士研究生, 研究方向为海上风力发电系统故障辨识、海上风电场优化控制技术, 605211514@qq.com;

\*通信作者: 魏书荣(1980), 女, 博士, 教授, 主要从事海上风电优化规划与故障诊断研究, wsrmal@163.com。

(实习编辑 张文鑫)

# Ultra-short-term Power Prediction of Offshore Wind Power Based on Improved LSTM-TCN Model

FU Yang<sup>1</sup>, REN Zixu<sup>1</sup>, WEI Shurong<sup>1</sup>, WANG Yang<sup>2</sup>, HUANG Lingling<sup>1</sup>, JIA Feng<sup>1</sup>

(1. Shanghai University of Electric Power; 2. State Grid Jiangsu Electric Power Co., Ltd., Economic Research Institution)

**KEY WORDS:** offshore wind power; wind power prediction; unit status; spatio-temporal characteristics; temporal convolutional network

Accurate prediction of wind power is an important means to realize friendly grid connection of large-scale offshore wind power. In this paper, the unit state prediction model based on LSTM is established, and the wake data is added. Secondly, an ultra-short-term power prediction method based on improved TCN considering the spatio-temporal characteristics of field groups is proposed. Based on obtaining the spatio-temporal characteristics of units by TCN, the attention model is strengthened to reduce the dimension of unit data, weaken the spatial characteristics of random unit, and improve the prediction accuracy of single unit.

To verify the influence of spatio-temporal characteristics on unit power prediction, Fig. 1 shows the comparison results between improved TCN and traditional TCN method, as well as LSTM, a common time series prediction method. LSTM adopts the method of forecasting power of single unit separately to avoid the influence of time and space characteristics. All algorithms train 250 epochs.

Fig. 1(a) shows the real power heat diagram of

each unit in the wind farm in one day, Fig. 1(b) shows the result of improved TCN, and Fig. 1(c) shows the result of TCN. The method in this paper is clear with the equal power line predicted by TCN, and is basically consistent with the real data, which shows that it can well capture the spatial characteristics of wind speed peak and unit output. TCN prediction results over-fit the spatial characteristics of wind power, and do not perform well at boundary details. Compared with TCN, method in this paper improves the prediction details of individual units. Fig. 1(d) shows the result of LSTM. LSTM model has fuzzy boundary of equal power line, its ability to restore the spatial characteristics of field group is weaker than the previous two methods, and its error is larger in peak conditions.

Table 1 shows the comparison of 4-hour prediction errors of the three algorithms for Unit 1. MAE, RMSE and correlation coefficient are used to measure the effectiveness of the model. The comparison results show that the accuracy of the proposed algorithm is higher than that of traditional TCN model and LSTM model.

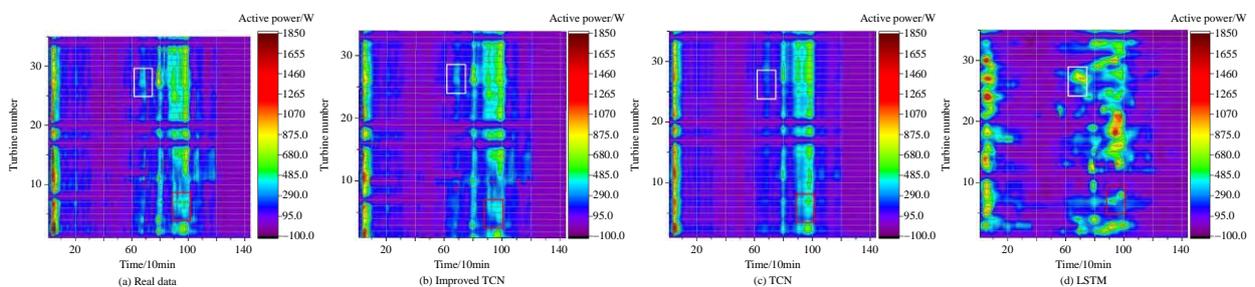


Fig. 1 Comparison of improved TCN, TCN, and LSTM examples

Table 1 Comparison of prediction errors of three algorithms in the first 4 hours of Unit 1

	MAE/kW	MAE/%	RMSE/kW	RMSE/%	Correlation coefficient
Improved TCN	87.77	9.65	102.14	11.23	93.08
TCN	92.54	10.17	124.97	13.74	91.06
LSTM	119.36	13.12	139.70	15.36	88.96