

# 基于 CNN-LSTM 及深度学习的风电场时空组合预测模型

廖雪超<sup>1,2</sup>, 陈才圣<sup>1,2</sup>, 伍杰平<sup>1,2</sup>

1. 武汉科技大学计算机科学与技术学院, 湖北 武汉 430065;

2. 智能信息处理与实时工业系统重点实验室, 湖北 武汉 430065

基金项目: 国家自然科学基金(61902285)

通信作者: 陈才圣, chencaisheng@aliyun.com 收稿/录用/修回: 2021-06-29/2021-08-13/2022-04-07

## 摘要

为了更好地预测风电场的风电功率, 提取风电场相邻站点之间时空信息和潜在联系, 提出了一种基于卷积神经网络(CNN)、互信息(mutual information, MI)法、长短时记忆网络(LSTM)、注意力机制(AT)和粒子群优化(PSO)的短期风电场预测模型(MI-CNN-ALSTM-PSO)。CNN用于提取不同站点的空间特征, LSTM则用于获取多个站点的风电数据的时间依赖信息, 据此设计CNN-LSTM时空预测模型, 并结合深度学习算法, 如MI特征选择、AT注意力机制、PSO参数优化, 对模型进一步改进。通过两个海岛风电场的实验数据分析可知, 所提模型具有最优的统计误差, CNN-LSTM模型可以高效提取风电场时空信息并进行时间序列预测, 而结合深度学习算法(MI、AT和PSO)后的组合模型能进一步提高风电功率预测精度和稳定性。

## 关键词

短期风电预测  
卷积神经网络  
特征选择  
长短时记忆网络  
注意力机制  
中图法分类号: TP301  
文献标识码: A

## Combined Spatiotemporal Wind Farm Prediction Model Based on CNN-LSTM and Deep Learning

LIAO Xuechao<sup>1,2</sup>, CHEN Caisheng<sup>1,2</sup>, WU Jieping<sup>1,2</sup>

1. School of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, China;

2. Key Laboratory of Intelligent Information Processing and Real-time Industrial Systems, Wuhan 430065, China

## Abstract

In this study, a combined prediction model based on the mutual information (MI) method, convolutional neural network (CNN), long short-term memory (LSTM) network, attention mechanism (AT), and particle swarm optimization (PSO), is proposed to successfully predict wind farm power and extract the spatiotemporal information and potential connections between the adjacent sites of the wind farm. Here, CNN is used to extract the spatial features of different sites, and LSTM is employed to obtain the time-dependent information of the wind power data from multiple sites. Furthermore, a CNN-LSTM spatiotemporal prediction model is designed and used along with deep learning algorithms, such as MI, AT, and PSO, to further improve the proposed model. The analysis of the experimental data of the two island wind farms reveals that the proposed model achieves the lowest statistical error. The CNN-LSTM model can efficiently extract the spatiotemporal information of the wind farm and perform time series forecasting; moreover, the model combined with deep learning algorithms (MI, AT, and PSO) can further improve the accuracy and stability of wind power forecasting.

## Keywords

short-term wind power  
forecast;  
convolutional neural network;  
feature selection;  
long short-term memory  
network;  
attention mechanism

## 0 引言

在过去的几十年里, 全球风力发电装机容量增长迅速。目前, 风能作为一种清洁、绿色的可再生能源, 被广泛地应用于实际生活中。所以风电场的风电预测为城市建设输送电能与电路建设提供有效参考依据<sup>[1]</sup>。目前风电预测模型可分为三类: 时间序列模型、传统机器学习模型和组合模型<sup>[2]</sup>。时间序列模型对于线性的、平稳的数据预测效果表现较好<sup>[3]</sup>, 但对于非平稳性, 非线性的数据预测效果稍差, 为了改善在非线性和非平稳时间序列的预测效果, 机器学习方法如 TCN 时序卷积, LSTM 长短时记忆神经网络被用于风电预测, 并且效果有所提升。此外, 组合模型比单一机器学习方法的预测效果有进一步提高, 如 He 等<sup>[4]</sup>使用基于集合经验模态分解(EEMD)和最小绝对收缩选择算子-量化回归神经网络(LASSO-QNN)的风电预测组合模型, 对提高风电预测性能, 衡量和降低预测过程不确定性具有较好的能力。Pan 等<sup>[5]</sup>提出将自适应多组鲑鱼群算法(AMSSA)与 BP 神经网络结合的风电功率预测模型, 对风电预测取得较好的预测结果。He 等<sup>[6]</sup>提出了一种基于并行主从(MS)模型的多核并行分位数回归神经网络(MPQRNN)。该算法将所有分位数上的复杂预测任务划分为多个并行子任务, 独立运行在不同的核上, 从而可以充分利用多核 CPU 的性能优势, 提高联合操作模型的计算效率, MPQRNN 不仅可以提高 QRNN 的训练效率, 而且可以获得精确的风电功率预测结果。Niu 等<sup>[7]</sup>提出基于注意的门控递归单元(AGRU)的序列模型, 提高预测的准确性和稳定性。Qu 等<sup>[8]</sup>提出新的混合分解技术(HDT)和改进的花授粉算法(FPA)的 BP 神经网络预测模型, 非常适用于非平稳多步风速预测。Wang 等<sup>[9]</sup>用 K 均值聚类算法处理数值天气预报, 选择对预测精度影响巨大的天气数值作为深度信念网络(DBN)模型的输入, 预测结果优于 BP 神经网络。Jiang 等<sup>[10]</sup>提出了基于增强变分模态分解、深度特征选择和多误差修正的概率风速预测框架, 结果表明该方法具有较好的预测能力, 可能更适用于具有非平稳性和非高斯性的数据。Lu 等<sup>[11]</sup>提出了基于时空(ST)分析的多输出支持向量机(MSVM)模型, 来预测多个风电场的风电功率。Li 等<sup>[12]</sup>提出空间重构(PSR)来重构风动力系统的相空间, 其次使用主成分分析(PCA)最大程度地减少延迟时间和相位尺寸不当所带来的影响, 进而使用资源分配网络(RAN)

建立预测模型, 分析结果表明, 在 48 h 中的预测误差约为 3%, 明显低于其他预测方法所获得的误差, 并且该模型可以预测不同容量、不同海拔高度的涡轮机风电功率。刘洪池<sup>[13]</sup>提出基于 VMD-BPNN 组合模型拟合各特征变量, 对风电功率预测精度提升。Du 等<sup>[14]</sup>提出了一种基于双向长短期(Bi-LSTM)的时间注意编码解码模型处理时间序列问题, 能自适应学习长期依赖和隐藏的相关特征。Li 等<sup>[15]</sup>提出了一种由神经网络、小波变换、特征选择和偏最小二乘回归(PLSR)组成的风电场发电预测的综合方法, 有效克服了风电功率级数的非平稳性, 提高预测精度。Jiang 等<sup>[16]</sup>提出了 V 支持向量机(V-SVM)混合风速预测模型, 选择相邻站点的风速特征作为输入, 并采用杜鹃搜索(CS)算法调整模型参数, 该模型具有良好的非线性拟合能力和更高的精度。

以上方法主要在风速或风电预测过程中, 使用信号分解、权重分配、深度学习和回归模型和参数优化等方法进行研究, 主要根据时间序列的前后依赖关系进行数据预测, 而且大多数风电风速预测方法仅使用单个站点的特征数据, 没有考虑风电场相邻站点特征的潜在时空联系, 忽略其在空间上的特征信息, 使得预测准确性有一定局限性。为了更好地利用多站点时空数据预测风电功率, 本文利用两个风电场的多站点风电数据的时空相关性和深度学习方法进行预测研究。

本文主要考虑风电场多站点时间和空间的综合特征, 提出了基于 CNN-LSTM 和深度学习算法(MI、AT 和 PSO)的时空风电组合预测模型(MI-CNN-ALSTM-PSO)。本文主要工作包括:

1) 原始数据集为多站点多维特征风电数据, 通过 MI 算法对数据集的时间和空间相关性进行分析, 消除数据间的冗余信息, 对原始数据集进行降维。

2) 考虑各站点的数据相关性, 对降维后的数据利用 CNN 卷积模型提取各站点空间信息, 通过 LSTM 获取时间依赖信息, 提出 CNN-LSTM 时空组合预测模型, 该模型比常规组合模型有更好的预测性能。

3) 采用 AT、PSO 等深度学习算法, 对 CNN-LSTM 进行改进, 提出了 MI-CNN-ALSTM-PSO 的组合预测模型, 进一步提高风电功率预测精度和稳定性。

## 1 相关理论和方法

### 1.1 互信息法

在风电场预测过程中, 各风电站点多维特征变

量之间存在一定的相关性。互信息法利用计算互信息函数来确定相关因子,是一种非线性的分析方法,在时间序列预测和特征筛选等领域有着广泛的应用<sup>[17]</sup>。两个随机变量  $x$  和  $y$  的互信息可以定义为

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (1)$$

其中,  $X$ 、 $Y$  为随机变量,  $p(x, y)$  是  $x$  和  $y$  的联合概率密度函数,  $p(x)$  和  $p(y)$  分别是  $x$  和  $y$  的边缘概率密度函数。

### 1.2 卷积神经网络

卷积神经网络 (CNN) 具有强大的空间网格数据处理能力。CNN 卷积过程如图 1 所示,步骤主要包括:

卷积层:其作用是对输入多维特征网格数据进行特征提取,通过滑动窗口数据与卷积核做内积,提取不同位置数据的权重,得到一个新的矩阵,即特征图。

池化层:主要工作是降维采样,通过滑动窗口方式得到计算窗口矩阵的最大值,其作用是逐步降低数据特征的尺寸,减少网络参数,降低运算过程中 CPU 资源耗费,同时也能够有效控制过拟合。通过这种最大值的降维方式,可最大限度激活数据特征,去除干扰项和噪声影响。

全连接层:连接特征图所有神经单元,经隐含层输出结果。




图1 CNN 卷积过程

Fig1 CNN convolution process

### 1.3 LSTM 网络

LSTM 可解决循环神经网络 (recurrent neural network, RNN) 长时间序列训练过程中存在的梯度爆炸、梯度消失与无法长久保存历史信息的问题<sup>[18]</sup>。相比传统循环神经网络, LSTM 能够在更长的历史数据中表现更优的预测性能。LSTM 内部由 3 个独特的门结构和一个用于存储记忆的状态模块组成<sup>[12]</sup>, LSTM 单元结构如图 2 所示,其中  $C_t$  为 LSTM 单元  $t$  时刻状态信息,  $h_t$  为隐含层  $t$  时刻输出,  $f_t$  为  $t$  时刻遗忘门,  $i_t$  为  $t$  时刻输入门,  $\tilde{C}_t$  为当前时刻信息,  $o_t$  为  $t$  时刻输出门,  $\cdot$  表示相乘,  $\oplus$  表

示相加,  $\sigma$  为 sigmoid 激活函数。

1) 遗忘门, 过滤上一时刻单元状态  $C_{t-1}$  遗忘的程度:

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

2) 输入门, 决定哪些信息被加入到本单元中:

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

3)  $t$  时刻单元状态更新, 根据  $f_t$  和  $i_t$  将新的记忆信息有选择性地记录到  $C_t$  中:

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

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

4)  $t$  时刻输出门, 将  $C_t$  激活, 并决定  $C_t$  的输出大小:

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

$$h_t = o_t \tanh C_t \quad (7)$$

其中,  $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$  为各个模块对应的权重矩阵,  $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  为偏置项,  $\sigma$  为 sigmoid 激活函数,  $\tanh$  为双曲正切激活函数, 定义为

$$\sigma(x) = 1/(1 + e^{-x}) \quad (8)$$

$$\tanh x = (e^x - e^{-x})/(e^x + e^{-x}) \quad (9)$$

输出层依据式 (10) 将  $h_t$  经过一个全连接层得到最终的预测值  $y_t$ :

$$y_t = \sigma(W_y h_t + b_y) \quad (10)$$

其中,  $W_y$ 、 $b_y$  分别为权重矩阵和偏置项。

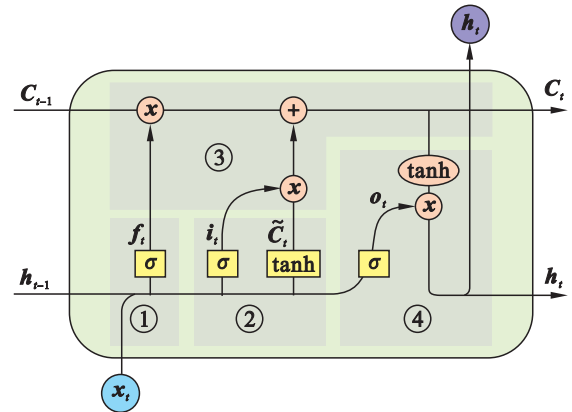


图2 LSTM 内部结构

Fig.2 LSTM internal structure

## 2 系统模型设计

### 2.1 符号描述和实验建模

本文所用多站点多维特征预测风电功率的表述为

$$X = [X^1, X^2, \dots, X^m]^{n \times t} \\ = [X_1, X_2, \dots, X_t] \in \mathbb{R}^{n \times m \times t} \quad (11)$$

其中,  $n$  为观测站点编号,  $t$  是观测时间序列的窗口

长度,  $m$  为数据特征维度, 则  $t$  时刻特征数据描述为

$$\begin{aligned} X_t &= [WP_t^i, WS_t^i, WD_t^i, TE_t^i, PA_t^i, DE_t^i], \\ i &= 1, 2, \dots, n \end{aligned} \quad (12)$$

其中, WP 为风电功率, WS 为风速, WD 为风向, TE 为温度, PA 为气压, DE 为空气密度,  $i$  为站点编号,  $t$  为时间步。

本文多维特征风电功率预测问题, 是对给定观测序列历史数据  $X = [X_1, X_2, \dots, X_{t-1}] (X_t \in \mathbb{R}^{n \times m \times T})$ , 寻找观测历史数据  $X$  和目标预测变量  $Y(t)$  之间的非线性映射关系, 使得  $Y(t) = F(X_1, X_2, \dots, X_{t-1})$ 。

## 2.2 CNN-LSTM 模型

CNN 具有很好的空间网格数据特征提取能力, LSTM 则可以较好地分析时间序列数据间的依赖关系, 因此本文将 CNN 与 LSTM 相结合。针对本文多站点多维特征数据, 将  $n$  个站点  $m$  个特征的数据组成  $n$  行  $m$  列矩阵, 并将  $t$  个时刻的矩阵数据构造为

时间分布层, 以获取更多时间序列数据的步长信息。CNN 模型输入层维度为  $n \times m \times t (6 \times 6 \times 30)$ 。

CNN 卷积层特征图的输出  $\bar{X}_{i,j}$  为

$$\bar{X}_{i,j} = f_{\text{cov}} \left( \sum_{n=0}^k \sum_{m=0}^k w_{n,m} X_{i+n,j+m} + b_{n,m} \right) \quad (13)$$

其中,  $X_{i+n,j+m}$  是输入矩阵的第  $n$  行  $m$  列的值,  $f_{\text{cov}}(\cdot)$  是选择激活函数,  $w_{n,m}$  为卷积核  $n$  行  $m$  列的权重,  $b_{n,m}$  是卷积核偏差,  $k$  为滑动窗口大小。通常输入矩阵使用多个卷积核进行卷积操作。

CNN 池化层则通过  $2 \times 2$  或  $3 \times 3$  过滤器和滑动窗口步长 (stride=2) 进行降维下采样, 最大限度激活权重大的特征, 去除干扰和噪声信息, 再通过展平层将数据展平为一维阵列  $\bar{X}_z (\bar{X}_z = [X_{z1}, X_{z2}, \dots, X_{z(t-1)}])$ , 作为时间序列输入到 LSTM 层。最后, 通过完全连接层和输出层获得目标站点的预测结果, 如图 3 所示。




图 3 CNN-LSTM 组合模型结构

Fig.3 CNN-LSTM combined model structure

## 2.3 MI-CNN-LSTM 模型

文[19]采用 MI 序列选择方法, 实现对称图的特征处理, 有效去除约 50% 的基于模型的特征和 95% 的对称像素, 并且没有明显的损失, 这说明 MI 可以剔除不相关和冗余的信息, 识别最重要的特征。本文多维特征原始数据噪声较多, 直接输入

CNN-LSTM 模型, 会对模型预测性能造成干扰, 因此基于以上 CNN-LSTM 模型, 通过 MI 对原始数据集  $X$  进行特征选择后再作为 CNN 的输入, 从而减少 CNN 卷积的数据维度, 在保持模型预测精度的前提下减少算法消耗, 构造如图 4 所示的 MI-CNN-LSTM 模型。




图 4 MI-CNN-LSTM 组合模型结构

Fig.4 MI-CNN-LSTM combined model structure

## 2.4 MI-CNN-ALSTM 模型

在传统 LSTM 模型中, LSTM 层通过全连接层连到输出层。本文则将 LSTM 与注意力机制相结

合, 在 LSTM 隐含层的最后一个时刻加入注意力机制; 其结构如图 5 所示; 利用注意力机制将 LSTM 层  $t$  时刻的隐含层输出与模型最终预测结果相关

联,注意力机制层使用的激活函数为 softmax 函数,其作用计算隐含层向量的权重;而输出层采用的激活函数为 sigmoid 函数,其作用把向量映射到输出。文[20]中的 LSTM-Attention 方法能有效分析输入输出的相关性,以获得更多重要时间的整体特征,通过学习特征权重,提高网络表示能力。而本文要解决的是风电数据非线性导致预测结果不稳定的问题。

ALSTM 则依据式(14)得到注意力向量  $G_t$ :

$$G_t = \varphi(W_h h_t + b_h) \quad (14)$$

其中,  $\varphi(x)$  为 softmax 激活函数,  $W_h$  为权重向量,  $b_h$  为偏置项。然后依据式(15)将  $G_t$  与  $h_t$  作元素乘法,得到注意力层的输出:

$$\hat{h}_t = h_t G_t \quad (15)$$

最后,将  $\hat{h}_t$  作为后面 LSTM 输出层的输入,并得到最终的预测值:

$$y_t = \sigma(W_y \hat{h}_t + b_y) \quad (16)$$

在 2.3 节 MI-CNN-LSTM 基础上,通过对 LSTM

添加注意力机制,得到图 6 所示的 MI-CNN-ALSTM 模型。

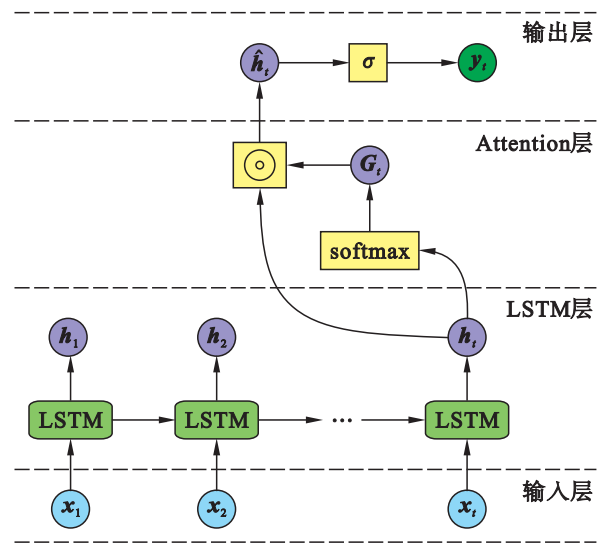


图 5 ALSTM 模型结构

Fig.5 ALSTM model structure




图 6 MI-CNN-ALSTM 组合模型结构

Fig.6 MI-CNN-ALSTM combined model structure

## 2.5 PSO 参数优化

在使用 CNN 和 LSTM 对多维特征进行预测过程中, CNN 滤波器个数 ( $n_f$ )、CNN 卷积核 ( $n_k$ )、LSTM 隐含层 ( $n_l$ )、LSTM 迭代次数 ( $n_b$ ) 等参数对模型预测性能影响较大,需对以上超参数进行优化。本文利用 PSO 对组合模型进行的以上参数进行寻优,采用不同参数对测试集进行迭代预测,并通过评价指标均方根差 (root mean square error, RMSE) 作为粒子最优解的评估标准,找到最优参数,从而得到最优的风电预测结果。PSO 算法流程如图 7 所示,具体步骤为:

**步骤 1 初始化。**在范围内随机初始化粒子参数  $P_i = \{n_f, n_k, n_l, n_b\}$ ,并定义初始种群的粒子,赋予其初始速度和位置。

**步骤 2 迭代。**每个粒子在探索空间中单独的搜寻最优解,并将其记录为当前最优解。迭代函数如式(17)所示,其中  $v_i$  是粒子在  $i$  次迭代的速度,

$c_1$  和  $c_2$  是学习因子,  $\text{rand}(\cdot)$  是介于 (0, 1) 之间的随机数,粒子通过追寻局部最优解  $\text{pbest}(P_i)$  和全局最优解  $\text{gbest}(P_i)$  来确定后续位置。式(18)中  $x_i$  是粒子在第  $i$  次迭代更新位置。

$$v_{i+1} = v_i + c_1 \text{rand}(\cdot) (\text{pbest}(P_i) - x_i) + c_2 \text{rand}(\cdot) (\text{gbest}(P_i) - x_i) \quad (17)$$

$$x_{i+1} = x_i + v_{i+1} \quad (18)$$

**步骤 3 寻优。**每个粒子单独进行寻优,并将当前最优解与整个粒子群里的其他粒子共享,找到最优的那个最优解作为参数粒子群的全局最优解。

**步骤 4 评估。**每次迭代对组合模型进行训练并计算出预测值及误差值 RMSE。

**步骤 5 停止迭代。**模型在搜索过程中达到最大迭代次数且满足 RMSE 最优则停止,否则返回步骤 2 继续更新粒子。

## 2.6 MI-CNN-ALSTM-PSO 组合模型

综上,本文提出了一种基于以上算法的短期风

电组合预测模型 MI-CNN-LSTM-AT-PSO, 模型整体结构如图 8 所示。

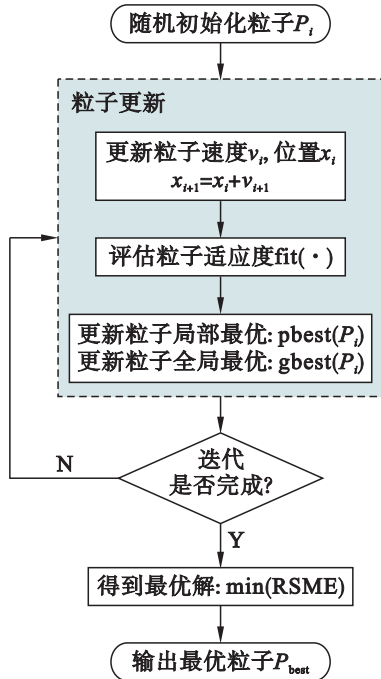


图 7 PSO 算法流程

Fig.7 PSO algorithm flow

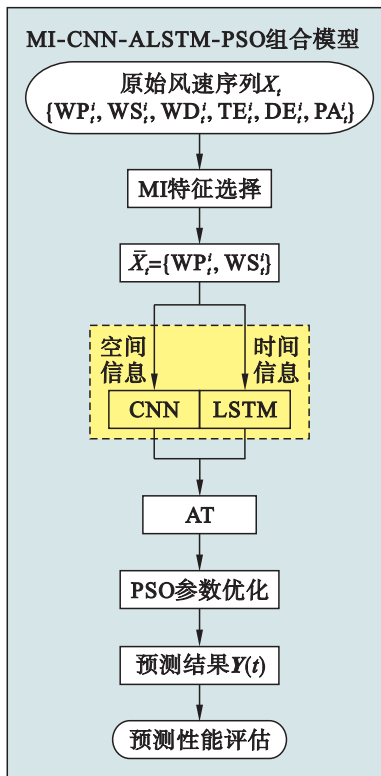


图 8 MI-CNN-ALSTM-PSO 组合模型结构

Fig.8 MI-CNN-ALSTM-PSO combined model structure

组合模型的主要包括:

1) MI 互信息: 将过去  $t$  小时内  $n$  个站点的  $m$

维特征作为输入数据 ( $6 \times 6 \times 30 = 1\ 080$ ), 利用 MI 对原始数据 (1 080 维) 进行时间维度的初步特征选择, 得到其中权重最高的前 360 维数据, 组成  $6 \times 2 \times 30$  的网格数据。

2) CNN 卷积: 对 MI 特征选择后的数据, 进行卷积与池化, 充分提取数据空间特征, 数据展平成具有时序特征与空间特征的一维阵列, 作为 LSTM 的输入。

3) CNN-LSTM 模型: CNN 提取多站点空间信息, LSTM 获时间序列记忆信息, CNN-LSTM 模型充分考虑风电场各站点的时间和空间信息, 进一步提高多站点预测能力。

4) AT 注意力机制: 通过结合了局部 AT 机制的 LSTM-AT 模型, 对 LSTM 隐藏层学习权重, 进一步注意 LSTM 在最后时刻的输出, 提高预测能力。

5) PSO 参数选优: 采用 PSO 算法对 CNN 和 LSTM 模型关键参数进行寻优, 找到最优解。

### 3 实验及分析

#### 3.1 实验数据集

实验数据来源美国国家可再生能源实验室 (NERL), 取自圣克鲁斯岛 (约西经  $120^\circ$ , 北纬  $34^\circ$ ) 风电场和圣米格尔岛 (约西经  $120^\circ$ , 北纬  $34^\circ$ ) 风电场。从 2019 年 7 月 28 日至 2019 年 10 月 5 日 (10 000 条数据), 数据集采样时间间隔为 10 min。本实验数据集可在美国国家可再生能源实验室 (NERL) 官网获得: <https://www.nerl.com>。

所选风电场位于太平洋西南岸, 地势西北低东南高, 其主导风向为西北方向, 风电站的研究区域和分布如表 1 和图 9 所示。

表 1 站点位置信息

Tab.1 Site location information

A 区			B 区		
站点	西经	北纬	站点	西经	北纬
			B2	120.184	33.909
A3	120.301	34.033	B3	120.136	33.903
A4	120.370	34.034	B4	120.094	33.914
A5	120.433	34.017	B5	120.129	33.885
A6	120.412	34.023	B6	120.108	33.891
			B7	120.087	33.896
A8	120.460	34.029	B8	120.066	33.902
A9	120.334	34.062	B9	120.045	33.907
A10	120.467	34.046	B10	120.024	33.912
A11	120.446	34.052	B11	120.003	33.918
A12	120.425	34.057	B12	119.982	33.923
A13	120.404	34.063	B13	120.039	33.890
A14	120.376	34.051	B14	120.060	33.884




图9 站点示意图

Fig.9 Schematic diagram of the site

选取 A8 和 B8 站点作为目标站点，其风电数据如图 10 和图 11 所示，实验采用前 8 000 条数据(蓝色部分)作为训练集，后 2 000 条数据(红色部分)作为测试集。从中可以看出该站点风电数据有如下特点：

1) 风电数据具有高随机性与波动性。

2) 该区域地理位置比较特殊，位于海上岛屿，风速变化强烈，风向难以捉摸，大气环境也变化无常。

### 3.2 数据处理与分析

#### 1) 归一化

将有量纲的原始数据集变换为 0 ~ 1 范围之内无量纲的标量，这样不仅可以使后续模型处理更加快速，而且便于把不同单位或量级的指标能够进行比较和加权。

$$y = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (19)$$

其中， $x$  为每一时刻的特征数据， $x_{\min}$  为该特征的最小值， $x_{\max}$  为该特征最大值。

#### 2) 数据相关性

图 12 为 A8 站点的风速和风电功率的趋势对比，从变化趋势可知，风电和风速数据具有一致的同步变化趋势。




图 10 A 区 A8 站点风电数据

Fig.10 Wind power data of site A8 in area A




图 11 B 区 B8 站点风电数据

Fig.11 Wind power data of site B8 in area B




图 12 A8 站点实际风电风速

Fig.12 Actual wind power wind speed at site A8

图 13 为 A 区各站点风电功率和 A8 站的实际风电功率数据趋势对比。从中可知，A 区各站点实际风电数据具有高度同步性。

表 2 为 A 区站点与目标站点距离和目标站点 WP

的相关性分析, 其中, Pearson、Spearman、Kendall 分别表示皮尔森相关系数、斯皮尔曼相关系数和步德尔相关系数。从表 2 可看出, 临近 A8 站点的特征, 与其相关性较大。反之, 则相关性较小, 风电数据相关性与距离成正相关。通过 A 区各站点的风电数据相关性分析可知, A5、A6、A8、A10、A11、A12 站点距离和相关性具有良好的参考性, 因此用这些站点的相关数据进行预测。




图 13 各站点实际风电数据

Fig.13 Actual wind power data of each site

表 2 A 区各个站点风电与预测点风电的相关性

Tab.2 Correlation between wind power at each site in Zone A and wind power at forecast points

站点	与 A8 距离 /km	与 A8 的相关系数		
		Pearson	Spearman	Kendall
A10	2.032	0.997 8	0.998 3	0.967 5
A11	2.869	0.996 1	0.996 9	0.953 8
A5	2.820	0.994 1	0.995 3	0.953 8
A6	4.509	0.986 4	0.986 1	0.898 9
A12	4.534	0.982 1	0.989 0	0.911 3
A13	6.425	0.966 7	0.977 1	0.871 2
A14	8.116	0.931 8	0.954 7	0.816 4
A4	8.375	0.879 8	0.937 3	0.782 5
A9	12.162	0.929	0.952 9	0.813 3
A3	14.787	0.950 3	0.965 7	0.839 3

B 区站点相关性分析如表 3 所示, 同理 B 区选用 B8 作为待预测中心站点, 选用 B6 ~ B10、B13 站点的相关数据进行预测。


表 3 B 区各个站点风电与预测点风电的相关性

Tab.3 Correlation between wind power at each site in Zone B and wind power at forecast points


站点	与 B8 距离 /km	与 B8 的相关系数		
		Pearson	Spearman	Kendall
B9	2.029	0.968 5	0.820 5	0.785 5
B7	2.045	0.961 7	0.784 2	0.729 3
B13	2.857	0.886 4	0.810 5	0.761
B10	4.045	0.923 3	0.704 9	0.666 3
B6	4.059	0.790 7	0.605 2	0.515 8
B12	8.114	0.930 0	0.598 6	0.554 1
B11	6.061	0.930 5	0.606 1	0.564 2
B5	6.089	0.558 0	0.476 5	0.380 2

### 3) 风电自相关性分析

为了确定后续预测模型的时间步长, 本文采用自相关函数 (AutoCorrelation Function, ACF) 和偏自相关函数 (Partial AutoCorrelation Function, PACF) 准确分析本次实验所用风电数据的自相关步长。从图 14 可以看出, 在风电数据区间内, ACF 图特征是拖尾, 而 PACF 图特征是截尾, 因此该风电数据满足回归模型的预测特性, 而从 ACF 图中可以看出风电数据在滞后 30 步左右的时间进入置信区间, 所以时间序列模型的时间步初步定为 30 步。



(a) 风电数据 ACF 图



(b) 风速数据 PACF 图

图 14 A 区风电和风速数据 ACF 和 PACF 图

Fig.14 ACF and PACF diagrams of wind power and wind speed data in Zone A

### 4) 特征维度

表 4 为多维特征相关性分析, 可以看出风电和风速具有高度相关性、风向也是影响风电一个重要因素, 而密度气压等, 影响风电的程度微乎其微。

### 3.3 评价指标

在本次实验中使用 3 种评价指标:

平均绝对误差:

$$MAE = \frac{1}{N} \sum_{t=1}^N |y(t) - \hat{y}(t)| \quad (20)$$

平均方根误差:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2} \quad (21)$$

平均绝对标度误差:

$$MASE = \frac{N-1}{N} \sum_{t=1}^N \frac{|y(t) - \hat{y}(t)|}{\sum_{t=2}^N |y(t) - \hat{y}(t-1)|} \quad (22)$$

其中,  $N$  为风电数据总数,  $y(t)$  为  $t$  时刻风电站点记录风电数据,  $\hat{y}(t)$  为  $t$  时刻风电预测值。三种评价指标值越小, 说明模型预测精度越高。

表4 预测站点特征相关性对比  
Tab.4 Correlation comparison of predicted site features

特征	A 区相关系数			B 区相关系数		
	Pearson	Spearman	Kendall	Pearson	Spearman	Kendall
风电	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0
风向	0.453 8	0.541 2	0.510 8	0.337 6	0.468 0	0.337 6
风速	0.950 0	0.758 7	0.844 8	0.996 3	0.999 0	0.996 2
温度	0.252 8	0.143 5	0.103 7	0.057 5	0.079 7	0.057 5
密度	-0.078 8	-0.030 1	-0.020 5	0.018 9	0.032 8	0.018 9
压强	-0.011 2	0.025 7	0.019 6	-0.011 4	-0.011 2	-0.011 4

3.4 对比实验基准模型

为了充分说明本文提出的 MI-CNN-ALSTM-PSO 组合模型的预测有效性和优越性,本节采用表 5 中 10 个对比模型用于作实验对比。

表5 实验对比基准模型  
Tab.5 Experimental comparison of benchmark models

序号	模型	描述
M1	ARIMA	差分自回归移动平均
M2	SVR	支持向量回归
M3	TCN	时间卷积网络
M4	LSTM	长短时记忆网络
M5	VMD-LSTM	VMD 分解 + LSTM
M6	EEMD-LSTM	EEMD 分解 + LSTM
M7	CNN-LSTM	CNN 卷积 + LSTM
M8	MI-CNN-LSTM	MI 互信息 + CNN + LSTM
M9	MI-CNN-ALSTM	MI 互信息 + CNN + LSTM + AT
M10	MI-CNN-ALSTM-PSO	本文所提组合模型

各个模型主要参数设置如表 6 所示。对比结果如图 15、图 16 各实验模型对比所示。

3.5 预测模型实验数据分析

本节主要对组合预测模型的 MI 互信息、CNN 卷积、ALSTM、PSO 粒子群优化算法几个部分算法和预测模型,进行实验验证和对比分析。

3.5.1 CNN-LSTM 卷积模型

图 15(a)和图 16(a)分别为 A 区、B 区 CNN-LSTM 与 ARIMA、TCN、SVM、LSTM、EEMD-LSTM 等模型预测结果对比。实验结果表明,CNN 可以更好地提取各个站点的相关数据信息,增加了 CNN 卷积后的 LSTM 模型预测效果最优。各种模型预测指标对比如表 7 所示,CNN-LSTM 的 10 组平均误差指标 MAE、RMSE 和 MASE 分别为 0.196、0.414、0.356,比单一的 LSTM、VMD-LSTM、EEMD-LSTM、TCN 模型误差有明显降低,从图 15(c)、图 15(d)、图 16(c)、图 16(d)中可知,CNN-LSTM 的预测数据

比其他模型的预测数据更接近与蓝色的“预测值 = 实际值”基准线,说明 CNN-LSTM 有更高的预测精度。

表6 模型主要参数  
Tab.6 Main parameters of the model

模型	主要参数	说明
ARIMA	$p = 30$	自相关阶数
	$q = 0$	移动平均阶数
SVR	Kernel function	径向基函数
	$C = 1$	RBF 惩罚因子
LSTM	$n_i = 30$	输入层节点数
	$n_h = 10$	隐含层节点数
	$n_o = 1$	输出层节点数
	$e = 0.01$	学习率
	$b = 24$	批次大小
TCN	epoch = 100	训练迭代次数
	Kernel-size = 2	卷积核
	DENSE = 1	全连接
CNN	activation = relu	激活函数
	filters = 128	滤波器
MI	Kernel-size = 4	卷积核
	$n = 360$	特征维度数
ATTENTION	$n_a = 10$	AT 层节点个数

3.5.2 MI-CNN-LSTM 模型

表 8 为 MI 特征选择并采用 MI-CNN-LSTM 模型预测的结果对比。MI 选择 1 080 意味着无特征选择变化,当 MI 选择特征维度为 900 时,其预测指标 RMSE 为 0.398,此时其中 WP、WS、WD、TE 为 180 维,DE 为 19 维,PA 为 161 维,相比 CNN-LSTM (1 080 维)模型预测误差降低 4%。选择 180 维数据时,WP 为 180 维,站点只有 A8、A10、A11 三个站点,其他站点数据没有参与卷积过程,空间相关性数据大打折扣,其误差 RMSE 为 0.312,而选择 360 维数据时,WP、WS 均为 180 维,各站点数均

为 60 维, 其预测结果最好 (RMSE = 0.265)。说明其他特征维度输入到 CNN-LSTM 模型中存在数据

冗余, 影响预测结果。这也与前文 3.2 节的相关性分析得到的结果相似。

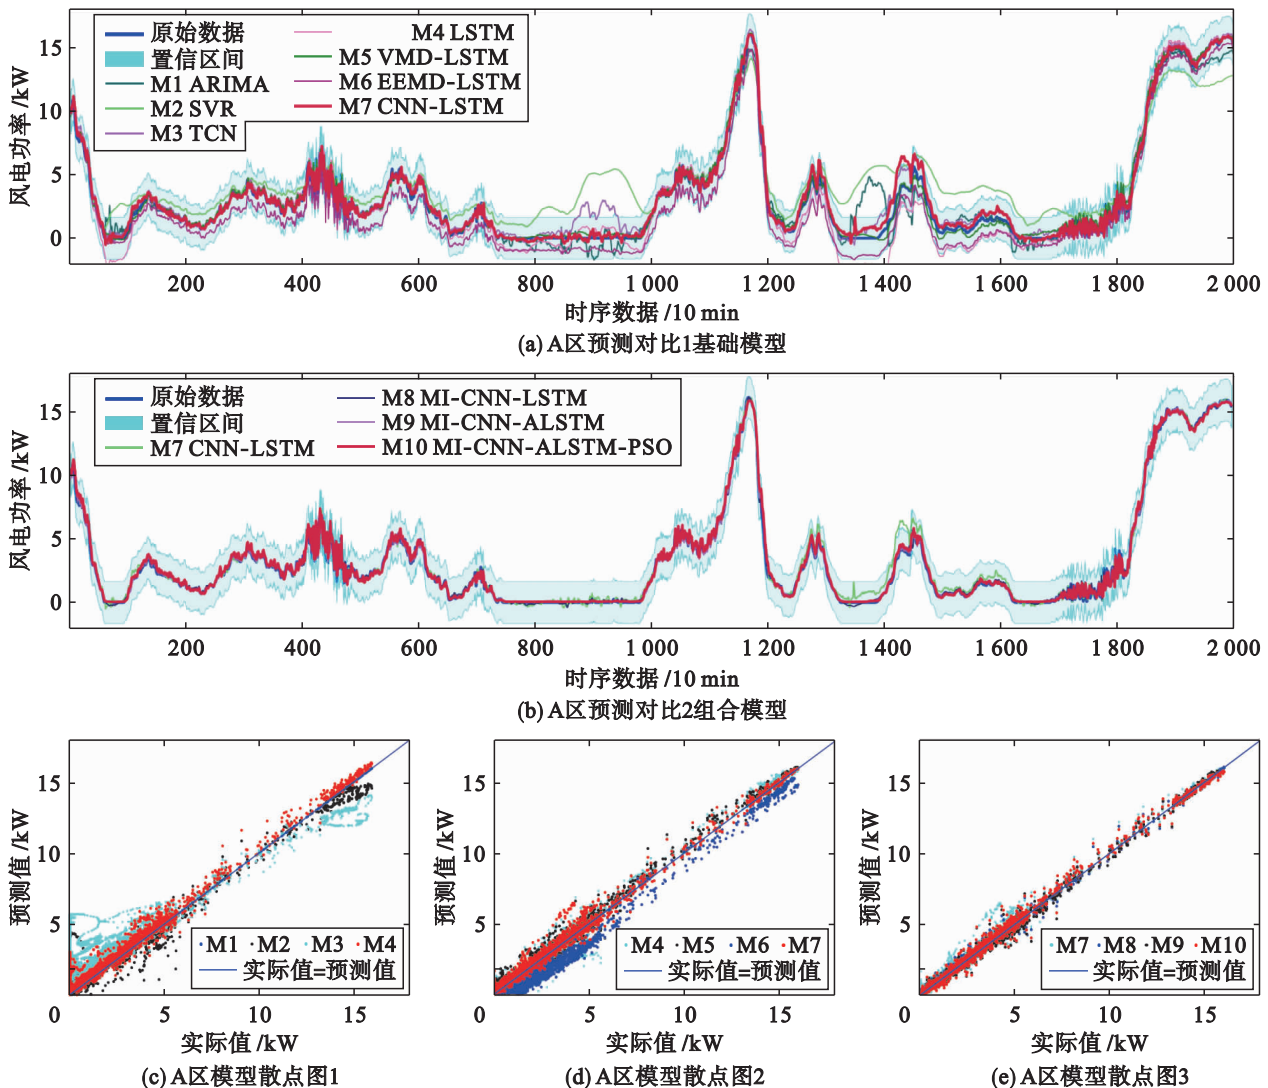


图 15 A 区预测模型对比

Fig.15 Comparison of prediction models in Zone A

表 9 给出了 A 区 MI 特征选择 360 维数据的 MI 权重前 60 维数据,  $WS(t-1)$  为预测站点风电的上一时刻风速,  $WP(t-1)$  为预测站点风电的上一时刻风电, 其中前 20 维特征都是 A5、A8、A10、A11 站点的风电和风速, 这也说明 MI 特征选择的结果与表 8 各站点距离和特征相关性分析得到的结果相似。

根据图 15(e) 中 A 区预测的散点图可知, MI-CNN-LSTM 的预测数据结果比 CNN-LSTM 的更接近于蓝色的基准线, 说明 MI-CNN-LSTM 更具有有效性和稳定性, 从表 7 的预测结果误差指标也可以看出, MI-CNN-LSTM 的最终误差指标 MAE、RMSE 和 MASE 分别为 0.060、0.265、0.164, 其误差指标比

CNN-LSTM 模型降低约 70%、36% 和 50%。图 16(e) 中 B 区站点预测结果同样说明了 MI-CNN-LSTM 的预测效果更好。

### 3.5.3 MI-CNN-ALSTM 模型

MI-CNN-LSTM-AT 组合模型对网格数据进行卷积, 并对 LSTM 结构进行改进, 增加局部 AT。从表 7 可以看出, MI-CNN-LSTM-AT 的误差指标 MAE, RMSE, MASE 分别为 0.058、0.247、0.152, 比 MI-CNN-LSTM 模型的误差指标低 8%、10%、7%; 由图 15(b) 和图 16(b) 两种模型预测对比图可知: 当风电数据波动性较大 (预测区间 400 ~ 600, 1 200 ~ 1 600), 添加注意机制的 MI-CNN-ALSTM 模型的预测精度和稳定性明显优于 MI-CNN-LSTM, 从图 17 的预测

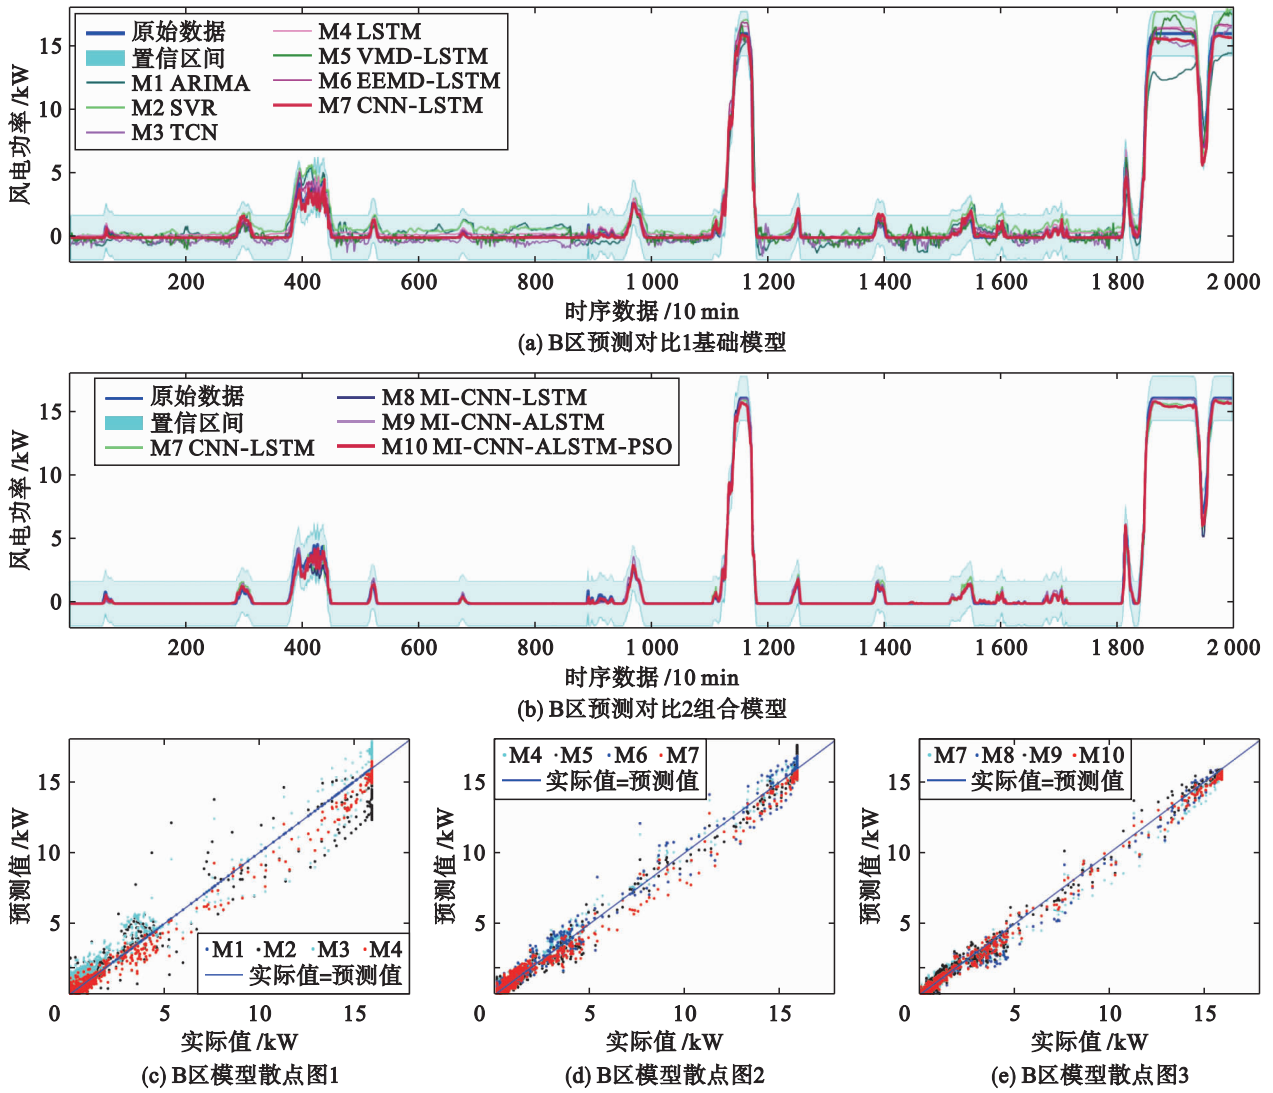


图 16 B 区预测模型对比

Fig.16 Comparison of prediction models in Zone B

表 7 A 区站、B 区站预测模型误差对比

Tab.7 Comparison of prediction model errors of stations in Zone A and Zone B

单位: kW

序号	模型	A 区站点			B 区站点		
		MAE	RMSE	MASE	MAE	RMSE	MASE
1	ARIMA	0.512	0.826	1.148	1.015	1.007	0.636
2	SVR	3.889	1.972	1.486	3.622	1.789	1.203
3	TCN	0.473	0.728	0.583	0.359	0.581	0.235
4	LSTM	0.389	0.624	0.399	0.338	0.481	0.379
5	VMD-LSTM	0.271	0.519	0.369	0.122	0.389	0.278
6	EEMD-LSTM	0.232	0.482	0.342	0.118	0.368	0.264
7	CNN-LSTM	0.196	0.414	0.356	0.108	0.322	0.137
8	MI-CNN-LSTM	0.060	0.265	0.164	0.095	0.252	0.128
9	MI-CNN-ALSTM	0.058	0.247	0.152	0.053	0.229	0.148
10	MI-CNN-ALSTM-PSO	<b>0.048</b>	<b>0.223</b>	<b>0.129</b>	<b>0.051</b>	<b>0.213</b>	<b>0.135</b>

表 8 MI 特征维度选择分析  
Tab.8 MI feature dimension selection analysis

特征	180 维	360 维	540 维	720 维	900 维	1 080 维
WP	180	180	180	180	180	180
WS	0	180	180	180	180	180
WD	0	0	171	180	180	180
TE	0	0	9	180	180	180
DE	0	0	0	0	19	180
PA	0	0	0	0	161	180
A5	0	60	92	120	150	180
A6	0	60	90	120	162	180
A8	60	60	86	120	144	180
A10	60	60	89	120	149	180
A11	60	60	89	120	148	180
A12	0	60	94	120	147	180
数据维度	$6 \times 1 \times 30$	$6 \times 2 \times 30$	$6 \times 3 \times 30$	$6 \times 4 \times 30$	$6 \times 5 \times 30$	$6 \times 6 \times 30$
RMSE	0.312	0.265	0.336	0.355	0.398	0.414

表 9 MI 特征选择结果  
Tab.9 MI feature selection results

序号	特征	序号	特征	序号	特征	序号	特征	序号	特征	序号	特征
1	A8WS( $t-1$ )	11	A10WS( $t-2$ )	21	A11WS( $t-3$ )	31	A11WP( $t-4$ )	41	A10WP( $t-5$ )	51	A5WP( $t-5$ )
2	A8WP( $t-1$ )	12	A10WP( $t-2$ )	22	A11WP( $t-3$ )	32	A12WS( $t-1$ )	42	A8WP( $t-5$ )	52	A12WP( $t-3$ )
3	A10WS( $t-1$ )	13	A11WS( $t-2$ )	23	A5WS( $t-3$ )	33	A6WP( $t-1$ )	43	A6WP( $t-2$ )	53	A10WS( $t-6$ )
4	A10WP( $t-1$ )	14	A11WP( $t-2$ )	24	A8WS( $t-4$ )	34	A5WS( $t-4$ )	44	A11WS( $t-5$ )	54	A8WS( $t-6$ )
5	A11WS( $t-1$ )	15	A5WS( $t-2$ )	25	A5WP( $t-3$ )	35	A12WP( $t-1$ )	45	A12WP( $t-2$ )	55	A11WS( $t-6$ )
6	A11WP( $t-1$ )	16	A8WS( $t-3$ )	26	A10WS( $t-4$ )	36	A8WS( $t-5$ )	46	A11WP( $t-5$ )	56	A10WP( $t-6$ )
7	A8WS( $t-2$ )	17	A5WP( $t-2$ )	27	A8WP( $t-4$ )	37	A5WP( $t-4$ )	47	A6WS( $t-3$ )	57	A8WP( $t-6$ )
8	A8WP( $t-2$ )	18	A8WP( $t-3$ )	28	A10WP( $t-4$ )	38	A6WS( $t-2$ )	48	A5WS( $t-5$ )	58	A6WS( $t-4$ )
9	A5WS( $t-1$ )	19	A10WS( $t-3$ )	29	A11WS( $t-4$ )	39	A10WS( $t-5$ )	49	A12WS( $t-3$ )	59	A11WP( $t-6$ )
10	A5WP( $t-1$ )	20	A10WP( $t-3$ )	30	A6WS( $t-1$ )	40	A12WS( $t-2$ )	50	A6WP( $t-3$ )	60	A12WS( $t-4$ )

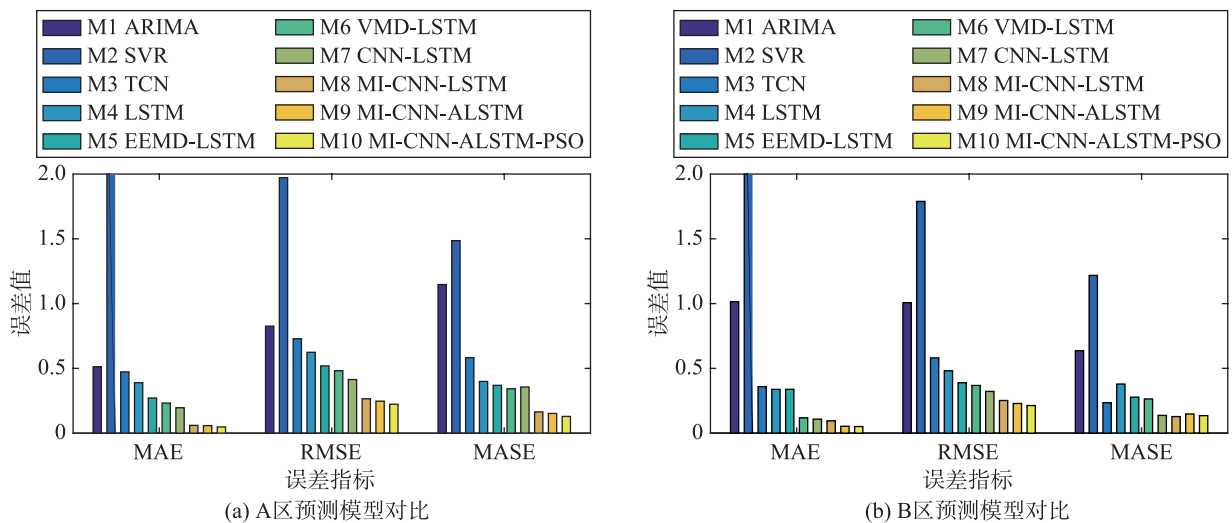


图 17 模型预测误差对比

Fig.17 Comparison of model prediction errors

误差对比柱状图中也可以看出, MI-CNN-ALSTM 所有评价指标在两个区域的预测误差均为最优。

### 3.5.4 MI-CNN-ALSTM-PSO 参数寻优

表 10 为 PSO 粒子群参数寻优的过程与结果, 当模型中参数  $P_i = \{n_f, n_k, n_L, n_b\}$  分别为 46、2、37、64 时, 模型预测精度最高(表 10 中加黑部分), 误差最小, 故选择该组参数作为模型训练参数。

### 3.6 组合模型预测精度与稳定性分析

利用模型 M3 ~ M10 对 A 区和 B 区站点风电数据分别进行 20 组预测实验, 并对实验结果的误差指

标 RMSE 进行对比, 图 18 和图 19 为 20 组预测结果的箱线图对比。从图中可以看出: 1) CNN-LSTM 的预测误差 RMSE 平均数为 0.48, 优于 EEMD-LSTM、VMD-LSTM 和 TCN, 可以说明 CNN 卷积在处理空间上多站点特征联系方面明显优于信号分解。2) 增加 AT 和 MI 的 MI-CNN-ALSTM 模型平均误差 RMSE 为 0.24, 预测效果也有明显提升。3) 从稳定性的角度来看, 本文所提出的模型经过 PSO 粒子群算法优化之后, 其标准差为 0.021 比 MI-CNN-ALSTM 标准差 0.025 稳定, 更容易训练出更优的模型。

表 10 PSO 粒子群参数寻优

Tab.10 PSO particle swarm parameter optimization

序号	$n_f$	$n_k$	$n_L$	$n_b$	MSE	RMSE	MAE
1	28	2	32	55	0.058 6	0.242 1	0.165 4
2	96	2	29	92	0.080 2	0.283 2	0.190 1
3	58	4	16	29	0.060 0	0.244 9	0.152 2
4	78	4	39	76	0.053 4	0.231 1	0.156 8
5	86	4	47	63	0.073 5	0.271 1	0.176 6
6	79	4	22	94	0.051 7	0.227 5	0.147 4
7	92	3	48	75	0.063 6	0.252 2	0.179 4
8	33	2	17	26	0.060 4	0.245 8	0.163 2
9	47	3	22	60	0.065 6	0.256 0	0.171 6
10	20	5	50	57	0.063 5	0.252 0	0.161 8
11	38	1	28	95	0.062 7	0.250 4	0.162 1
12	29	1	43	39	0.058 5	0.241 8	0.171 2
<b>13</b>	<b>46</b>	<b>2</b>	<b>37</b>	<b>64</b>	<b>0.051 2</b>	<b>0.223 4</b>	<b>0.145 9</b>
14	61	1	10	30	0.064 2	0.253 5	0.174 3
15	100	4	50	90	0.058 4	0.241 7	0.154 6
16	21	1	35	100	0.054 3	0.233 0	0.147 4
17	58	5	50	87	0.055 2	0.235 0	0.148 8
18	52	5	48	91	0.054 6	0.233 7	0.154 2
19	28	5	31	81	0.052 4	0.229 0	0.143 7
20	77	5	50	99	0.060 7	0.246 3	0.169 7




图 18 A 区稳定性对比

Fig.18 Comparison of stability in area A

据, 如 DE、PA 特征几乎可以忽略不计。对提取后数据进行预测, 实验效果提升明显。




图 19 B 区稳定性对比

Fig.19 Comparison of stability in area B

### 3.7 实验总结

综合上述 A 区和 B 区的对比实验数据, 可以得到如下结论:

1) MI 作用: 经过 MI 特征提取, 消除冗余数

2) 传统模型: ARIMA 统计模型能大概预测风电的主要趋势, 但是总是在急剧变化的阶段容易丢失,

不能很好捕捉时序信息; 而 SVR 与 LSTM 单个模型虽然能捕捉风电功率的时序信息, 但是在预测时存在滞后问题。TCN、VMD-LSTM 和 EEMD-LSTM 等模型在多站点建立相关模型预测, 也难以捕捉其空间相关性, 并且算法时间开销较大, 预测效果也不好。

3) CNN-LSTM 模型: 通过将各站点组成的网格卷积进行卷积, CNN 卷积可提取多站点的空间信息, 建立多站点之间的联系, 同时与 LSTM 结合, 又能保证时间特征上的完整性。CNN-LSTM 充分结合两个模型的算法优势, 提高风电预测性能。

4) MI-CNN-ALSTM 模型: 从表 3 可以看出, 模型经过 MI 特征选择后, 以 CNN-LSTM 为基础, 在其输出单元最后时刻增加注意力机制, 使输出时更加关注上一时刻的权重特征, 从而进一步提高预测能力。

5) MI-CNN-ALSTM-PSO 模型: 主要作用包括: (1) 针对非稳定性风电数据, 强化模型自适应能力; (2) 针对空间多站点多维特征的数据特点, 有效提取周边站点空间信息, 能够更加准确的预测; (3) 基于 PSO 优化的 MI-CNN-ALSTM 模型更具有

稳定性。

## 4 结论

本文提出了一种由 MI、CNN、LSTM、AT 和 PSO 组合而成的新型短期风电场预测模型。为了验证本模型在短期风速预测上的效果, 本文对两个区域风电场(A 区和 B 区)实验对比, 结果表明, 本文所提组合模型在两个区域风电场均表现最优, 并可显著增强模型预测的稳定性。本文通过 CNN 提取风电场的空间特征, 通过 LSTM 对站点的风电时间序列进行预测, 据此设计 CNN-LSTM 时空预测模型, 并加以 MI、AT、PSO 等深度学习算法对模型进一步优化, 为深度学习时间预测分析方面提供一个研究方向。然而, 所提模型仍有更宽广的研究思路和深入方向, 如多站点空间距离在网格数据的如何体现, 各站点权重的分配如何合理, 考虑更广泛影响风电功率预测的外部条件和内部条件, 如海岛附近的洋流、风电涡轮机、叶片材质等, 从而进一步提高区域风能预测能力和风能的利用效率。

## 参考文献

- [1] 陶玉波, 陈昊, 秦晓辉, 等. 短期风电功率预测概念和模型与方法[J]. 电力工程技术, 2018, 37(5): 7-13.  
Tao Y B, Chen H, Qin X H, et al. Short-term wind power forecasting concepts, models and methods[J]. Electric Power Engineering Technology, 2018, 37(5): 7-13.
- [2] 颜宏文, 卢格宇. CEEMD-WT 和 CNN 在短期风速预测中的应用研究[J]. 计算机工程与应用, 2018, 54(9): 224-230.  
Yan H W, Lu G Y. Application of CEEMD-WT and CNN in short-term wind speed prediction[J]. Computer Engineering and Applications, 2018, 54(9): 224-230.
- [3] Wang J Z, Hu J M. A robust combination approach for short-term wind speed forecasting and analysis-combination of the ARIMA (autoregressive integrated moving average), ELM (extreme learning machine), SVM (support vector machine) and LSSVM (least square SVM) forecasts using a GPR (gaussian process regression) model[J]. Energy, 2015, 93: 41-56.
- [4] He Y Y, Wang Y. Short-term wind power prediction based on EEMD-LASSO-QRNN model[J/OL]. Applied Soft Computing Journal, 2021, 105 [2021-05-11]. <https://linkinghub.elsevier.com/retrieve/pii/S1568494621002118>. DOI: 10.1016/j.asoc.2021.107288.
- [5] Pan J S, Shan J, Zheng S G, et al. Wind power prediction based on neural network with optimization of adaptive multi-group SALP swarm algorithm[J]. Cluster Computing, 2021, 24: 2083-2098.
- [6] He Y Y, Zhang W Y. Probability density forecasting of wind power based on multi-core parallel quantile regression neural network[J/OL]. Knowledge Based Systems, 2020, 209 [2021-05-23]. <https://linkinghub.elsevier.com/retrieve/pii/S0950705120305608>. DOI:10.1016/j.knosys.2020.106431.
- [7] Niu Z W, Yu Z Y, Tan W H, et al. Wind power forecasting using attention-based gated recurrent unit network[J/OL]. Energy, 2020, 196 [2021-04-10]. <https://linkinghub.elsevier.com/retrieve/pii/S0360544220301882>. DOI:10.1016/j.energy.2020.117081.
- [8] Qu Z X, Mao W Q, Zhang K Q, et al. Multi-step wind speed forecasting based on a hybrid decomposition technique and an improved back-propagation neural network[J]. Renewable Energy, 2019, 133: 919-929.
- [9] Wang K J, Qi X X, Liu H D, et al. Deep belief network based *k*-means cluster approach for short-term wind power forecasting[J]. Energy, 2018, 165: 840-852.
- [10] Jiang Y, Zhao N, Peng L L, et al. A new hybrid framework for probabilistic wind speed prediction using deep feature selection

- and multi-error modification[J/OL]. *Energy Conversion and Management*, 2019, 199[2021-05-23]. <https://linkinghub.elsevier.com/retrieve/pii/S0196890419309872>. DOI:10.1016/j.enconman.2019.111981.
- [11] Lu P, Ye L, Zhong W Z, et al. A novel spatio-temporal wind power forecasting framework based on multi-output support vector machine and optimization strategy[J/OL]. *Journal of Cleaner Production*, 2020, 254[2021-03-04]. <https://linkinghub.elsevier.com/retrieve/pii/S0959652620300408>. DOI:10.1016/j.jclepro.2020.119993.
- [12] Li H, Romero C E, Zheng Y, et al. Wind power forecasting based on principle component phase space reconstruction[J]. *Renewable Energy*, 2015, 81: 737-744.
- [13] 刘洪池. 基于 VMD 分解和 mRMR 特征信息选择的风功率预测[D]. 西安: 西安理工大学, 2020.  
Liu H C. Wind power prediction based on VMD decomposition and mRMR feature information selection[D]. Xi'an: Xi'an University of Technology, 2020.
- [14] Du S D, Li T R, Yang Y, et al. Multivariate time series forecasting via attention-based encoder-decoder framework[J]. *Neurocomputing*, 2020, 388: 269-279.
- [15] Li S, Wang P, Goel L. Wind power forecasting using neural network ensembles with feature selection[J]. *IEEE Transactions on Sustainable Energy*, 2015, 6(4): 1447-1456.
- [16] Jiang P, Wang Y, Wang J Z. Short-term wind speed forecasting using a hybrid mode[J]. *Energy*, 2017, 119: 561-577.
- [17] Song X F, Zhang Y, Gong D W. Feature selection using bare-bones particle swarm optimization with mutual information[J/OL]. *Pattern Recognition*, 2020, 112[2021-03-22]. <https://linkinghub.elsevier.com/retrieve/pii/S0031320320306075>. DOI: 10.1016/j.patcog.2020.107804.
- [18] Gers F A, Schraudolph N N, Jürgen S. Learning precise timing with LSTM recurrent networks[J]. *Journal of Machine Learning Research*, 2003, 3(1): 115-143.
- [19] Guo B F, Nixon M S. Gait feature subset selection by mutual information[J]. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Human*, 2009, 39(1): 36-46.
- [20] 钱勇生, 邵洁, 季欣欣, 等. 基于 LSTM-Attention 网络的短期风电功率预测[J]. *电机与控制应用*, 2019, 46(9): 95-100.  
Qian Y S, Shao J, Ji X X, et al. Short-term wind power prediction based on LSTM-Attention network[J]. *Motor and Control Application*, 2019, 46(9): 95-100.

## 作者简介

廖雪超(1979-), 男, 硕士, 副教授。研究领域为计算机应用, 控制理论, 控制工程与数据挖掘。  
陈才圣(1995-), 男, 硕士生。研究领域为计算机应用, 控制理论, 控制工程与数据挖掘。  
伍杰平(1998-), 男, 硕士生。研究领域为计算机应用, 控制理论, 控制工程与数据挖掘。

(上接第 497 页)

- [20] Yuan H, Bi J, Tan W, et al. TTSA: An effective scheduling approach for delay bounded tasks in hybrid clouds[J]. *IEEE Transactions on Cybernetics*, 2017, 47(11): 3658-3668.
- [21] Wang D, Tan D, Lei L. Particle swarm optimization algorithm: An overview[J]. *Soft Computing*, 2018, 22(2): 387-408.
- [22] Wu J Z, Cao Z Y, Zhang Y J, et al. Edge-cloud collaborative computation offloading model based on improved partial swarm optimization in MEC[C]//IEEE 25th International Conference on Parallel and Distributed Systems. Piscataway, USA: IEEE, 2019: 959-962.
- [23] Yuan H, Jing B, Wei T, et al. Temporal task scheduling with constrained service delay for profit maximization in hybrid clouds[J]. *IEEE Transactions on Automation Science and Engineering*, 2017, 14(1): 337-348.

## 作者简介

李开言(1996-), 男, 硕士生。研究领域为智能控制, 工业互联网。  
王亚刚(1967-), 男, 博士, 教授, 博士生导师。研究领域为系统辨识, 先进过程控制, 智能机器人等。  
张涛(1998-), 男, 硕士生。研究领域为生物仪器, 工业互联网等。