

DOI:10.19651/j.cnki.emt.2519266

基于 INGO\_BiLSTM\_SA 的短期风电功率预测<sup>\*</sup>王海亮<sup>1</sup> 李敏<sup>2</sup> 刘亚翔<sup>1</sup> 郝海霞<sup>3</sup>

(1.中北大学信息中心 太原 030051; 2.中北大学后勤管理部 太原 030051; 3.中北大学信息与通信工程学院 太原 030051)

**摘要:** 为提高短期风电功率预测精度,提出了一种融合单头注意力机制(SA)的双向长短期记忆网络(BiLSTM)和改进的北方苍鹰算法(INGO)调参的风电功率预测模型(INGO\_BiLSTM\_SA)。首先对风电数据进行预处理,采用 Pearson 相关系数法计算各因素和风电功率的相关程度,保留相关程度较高的因素,以提高模型预测精度;其次引入单头注意力机制,用于捕捉时序中的长程依赖关系,增加模型的泛化能力;最后针对 BiLSTM 超参数选择困难的问题,采用融合折射反向学习初始化和正余弦策略的改进的北方苍鹰算法对模型中的隐藏单元数目、最大训练周期和初始学习率 3 个超参数进行寻优,得到最优参数后利用 INGO\_BiLSTM\_SA 模型进行预测。通过新疆某风电站的数据进行实验验证,得到所提模型较原始的 BiLSTM 网络的决定系数提高了 2.08%,均方根误差和平均绝对误差分别降低了 23.0%和 24.8%。

**关键词:** 改进北方苍鹰算法;BiLSTM;单头注意力机制;短期风电功率预测

**中图分类号:** TN91 **文献标识码:** A **国家标准学科分类代码:** 470.4047

## Short-term wind power prediction based on INGO\_BiLSTM\_SA

Wang Hailiang<sup>1</sup> Li Min<sup>2</sup> Liu Yahong<sup>1</sup> Hao Haixia<sup>3</sup>

(1. School of Information Center, North University of China, Taiyuan 030051, China;

2. Logistics Management Department, North University of China, Taiyuan 030051, China;

3. School of Information and Communication Engineering, North University of China, Taiyuan 030051, China)

**Abstract:** To improve the accuracy of short-term wind power prediction, a BiLSTM network integrating a single-head attention mechanism(SA) and an improved northern goshawk algorithm for parameter are proposed. Firstly, wind power data is preprocessed, and the correlation degree between each factor and wind power is calculated by using the Pearson correlation coefficient method. The factors high correlation degree are retained to improve the prediction accuracy of the model. Secondly, a single-headed attention mechanism is introduced to capture long-range dependencies in the sequence, which increases the generalization ability of the model. Finally, in view of the problem of difficult hyperparameter selection of BiLSTM, the improved northern goshawk algorithm which integrated refraction reverse learning initialization and the of positive cosine is used to optimize the three super parameters of the number of hidden units, the maximum training cycle and the initial learning rate in the model, and the INGO\_LSTM\_SA model is used to predict after obtaining the optimal parameters. Experimental verification is carried out through the data of a wind power station in Xinjiang. The coefficient of determination of the proposed model is 2.08% than that of the original BiLSTM network, and the root mean square error and the mean absolute error are reduced by 23.0% and 24.8% respectively.

**Keywords:** INGO;BiLSTM;single-head attention mechanism;short-term wind power prediction

## 0 引言

随着全球对可再生能源需求的不断增长,风电作为一种清洁、可再生的能源形式,在能源结构中的占比日益提

升<sup>[1]</sup>。然而,风电功率的间歇性和不确定性给电网的稳定运行带来了巨大挑战。准确的短期风电功率预测对于优化电网调度、降低运行成本以及提高风电并网效率具有重要意义<sup>[2]</sup>。因此,开发高效、精准的风电功率预测模型已成为

收稿日期:2025-07-03

\* 基金项目:山西省科技成果转化引导专项(202404021301029)资助

当前研究的热点问题<sup>[3-4]</sup>。

国内外众多学者在风电功率预测领域开展了广泛且深入的研究,探索了多种预测方法和模型。这些研究方法主要可以归纳为 3 大类:物理建模方法、统计方法以及深度学习方法。物理建模方法<sup>[5]</sup>基于风电功率曲线、空气动力学、地形地貌等风力发电系统的物理特性建立数学模型,结合风速、风向、温度等气象数据进行功率预测,该方法依赖精确的物理参数,但计算复杂,短期预测精度可能受限。统计方法利用历史风电功率数据与气象观测数据之间的统计关系建立预测模型,如时间序列分析<sup>[6]</sup>、随机森林<sup>[7]</sup>、支持向量机<sup>[8]</sup>等,这类方法计算效率较高,但对数据平稳性和非线性关系的适应性较弱。深度学习采用神经网络从海量历史数据中自动学习风电功率的复杂非线性映射关系,常用的有长短期记忆网络(long short-term memory, LSTM)<sup>[9]</sup>、卷积神经网络(convolutional neural network, CNN)<sup>[10]</sup>、Transformer 模型<sup>[11]</sup>等,该方法能有效捕捉时序依赖和空间特征,预测精度较高。近年来,深度学习因其卓越的非线性建模能力在风电功率预测领域得到广泛应用,然而面对风电功率的强随机性和高度非线性特征,单一的预测模型仍存在较大误差。为此,众多研究者转向采用组合预测模型策略,通过整合不同算法的优势特性,有效提升风电功率预测的准确性和可靠性。

王愈轩等<sup>[12]</sup>提出了一种 CNN-LSTM 混合预测模型,其预测精度显著优于单独的 CNN 或 LSTM 模型。然而,该模型在风电功率序列的时间依赖性特征提取方面仍存在不足,未能充分捕捉时序数据中的长期动态关联特性。Li 等<sup>[13]</sup>提出基于双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)和 CNN 结合的预测方法,能够有效捕捉风电功率时间序列中的时序依赖特征。高鹭等<sup>[14]</sup>将注意力机制(attention mechanism, AM)与 BiLSTM 相结合得到 BiLSTM-AM 模型进行预测,预测精度较单个模型有显著提升。王珊珊等<sup>[15]</sup>通过麻雀优化算法(sparrow search algorithm, SSA)对 BiLSTM-AM 模型中的参数进行寻优,并用参数优化后的模型进行风电功率预测,验证了模型的有效性和稳定性,但传统的 SSA 容易陷入局部最优。

为进一步提高短期风电功率预测精度,提出了一种融合单头注意力机制(self-attention, SA)的双向长短期记忆网络(BiLSTM)和改进的北方苍鹰算法(improved northern goshawk optimization, INGO)调参的风电功率预测模型(INGO\_BiLSTM\_SA)。首先对风电数据进行预处理,采用皮尔逊(Pearson)相关系数法计算各因素和风电功率的相关程度,保留相关程度较高的因素,以提高模型预测精度;其次引入单头注意力机制,用于捕捉时序中的长程依赖关系,增加模型的泛化能力;最后针对 BiLSTM 超参数选择困难的问题,采用融合折射反向学习初始化和正余弦策略的改进的北方苍鹰算法对模型中的隐藏单元数目、最大

训练周期和初始学习率 3 个超参数进行寻优,得到最优参数后利用 INGO\_BiLSTM\_SA 模型进行预测。通过新疆某风电站的数据进行实验验证,验证了模型的有效性。

## 1 相关理论和方法

### 1.1 BiLSTM 原理

长短期记忆网络(LSTM)<sup>[16-17]</sup>是对传统循环神经网络(recurrent neural network, RNN)的改进,专门设计用于解决长序列数据中的长期依赖问题。它通过独特的门控结构(包括输入门、遗忘门和输出门)来有效控制信息的流动,从而避免了普通 RNN 在训练过程中常见的梯度消失和梯度膨胀现象。

双向长短期记忆网络(BiLSTM)<sup>[18-19]</sup>是对 LSTM 的改进,它通过并行运行两个方向相反的 LSTM 网络来增强序列建模能力:一个按时间正向处理序列,另一个逆向处理序列。最终将两个方向的输出进行融合,使模型能够同时捕获历史信息和未来信息,从而实现对序列数据的双向特征提取,进一步改善预测性能。BiLSTM 的输出表达式为:

$$\begin{cases} \vec{h}_t = \text{LSTM}_{\text{forward}}(x_t, \vec{h}_{t-1}) \\ \vec{h}_t = \text{LSTM}_{\text{backward}}(x_t, \vec{h}_{t+1}) \\ h_t = [\vec{h}_t, \vec{h}_t] \end{cases} \quad (1)$$

式中:  $x_t$  为  $t$  时刻的输入向量;  $\vec{h}_{t-1}$  为  $t-1$  时间步的前向隐藏状态向量;  $\vec{h}_t$  为生成的  $t$  时间步的前向隐藏状态向量;  $\vec{h}_{t+1}$  为  $t+1$  时间步的后向隐藏状态向量;  $\vec{h}_t$  为生成的  $t$  时间步的后向隐藏状态向量;  $h_t$  为  $t$  时间步的最终输出向量;  $[\cdot, \cdot]$  表示向量的拼接操作。

### 1.2 注意力机制

为了缓解 BiLSTM 在长序列建模中存在的局限性,将其与自注意力机制(SA)<sup>[20]</sup>相结合,得到改进的 BiLSTM\_SA 模型,其模型如图 1 所示。该设计使模型能够分阶段处理时序数据:首先通过 BiLSTM 完成局部特征的提取,再利用注意力机制捕捉全局的长程依赖关系,目的是让模型能够动态地关注输入数据中更重要的部分,从而提高模型对重要信息的敏感度。这种层级式特征提取架构显著提升了模型对复杂时间模式的表征能力,同时增强了泛化性能。




图 1 BiLSTM\_SA 模型

Fig. 1 BiLSTM\_SA model

自注意力机制的计算过程为:

$$\begin{cases} \mathbf{Q} = \mathbf{X}\mathbf{W}_Q \\ \mathbf{K} = \mathbf{X}\mathbf{W}_K \\ \mathbf{V} = \mathbf{X}\mathbf{W}_V \end{cases} \quad (2)$$

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \cdot \mathbf{V} \quad (3)$$

式中:  $\mathbf{X}$  为输入向量序列;  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  分别为查询(Query)、键(Key)和值(Value);  $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V$  是可学习的权重矩阵, 分别对应查询、键和值的变换;  $d_k$  是键向量的维度, 这里  $d_k = 2$ ,  $\sqrt{d_k}$  用于缩放点积, 防止梯度消失; Softmax 是归一化函数, 将向量转换为概率分布; Attention( $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ ) 为注意力输出。

## 2 基于 INGO 参数优化的 BiLSTM-SA 的预测方法

### 2.1 NGO 算法原理

北方苍鹰优化算法(northern goshawk optimization, NGO)<sup>[21]</sup>是模拟北方苍鹰猎食行为的一种优化技术, 这个过程分为两个主要阶段: 首先是探索阶段, 此时苍鹰识别并发起对猎物的攻击; 其次是开发阶段, 这时苍鹰进行追击并应对猎物的逃逸。具体的算法实现细节如下所述。

#### 1) 初始化种群

算法开始时, 随机生成  $N$  只苍鹰, 每只苍鹰的位置表示为:

$$\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{iD}], \quad i = 1, 2, \dots, N \quad (4)$$

式中:  $\mathbf{X}_i$  表示第  $i$  只苍鹰的位置;  $x_{ij}$  表示第  $i$  个北方苍鹰第  $j$  维的位置;  $N$  表示种群数量;  $D$  表示问题的维度。

#### 2) 猎物识别攻击阶段

在这个阶段, 每只北方苍鹰会随机选择一个猎物, 并迅速对其展开攻击。北方苍鹰根据选定猎物的位置和适应度更新自身的位置, 如果猎物的适应度更好, 则向猎物位置靠拢, 否则向相反方向移动以探索其他可能的区域。这个过程猎物选择和攻击行为通过式(5)~(7)进行数学描述。在这个阶段, 算法执行全局搜索来寻找最优解的潜在区域。

$$\mathbf{P}_i = \mathbf{X}_k, \quad i = 1, 2, \dots, N; \quad k = 1, 2, \dots, i-1, i+1, \dots, N \quad (5)$$

$$\mathbf{x}_{ij}^{newP1} = \begin{cases} x_{ij} + r(p_{ij} - Ix_{ij}), & F_{P_i} < F_i \\ x_{ij} + r(x_{ij} - p_{ij}), & F_{P_i} \geq F_i \end{cases} \quad (6)$$

$$\mathbf{X}_i = \begin{cases} \mathbf{X}_i^{newP1}, & F_i^{newP1} < F_i \\ \mathbf{X}_i, & F_i^{newP1} \geq F_i \end{cases} \quad (7)$$

式中:  $\mathbf{P}_i$  表示第  $i$  个北方苍鹰的猎物的位置;  $F_{P_i}$  表示第  $i$  个北方苍鹰的猎物的位置的目标函数值;  $\mathbf{X}_i^{newP1}$  表示第  $i$  个北方苍鹰的新位置;  $x_{ij}^{newP1}$  表示第  $i$  个北方苍鹰第  $j$  维的新位置;  $F_i^{newP1}$  表示基于第 1 阶段更新后第  $i$  个北方苍鹰的目标函数值;  $r$  表示  $[0, 1]$  内的随机数;  $I$  表示 1 或 2 的随机整数。

#### 3) 追逐及逃生阶段

在这一过程中, 由于北方苍鹰具有很高的追击速度, 它们能够持续追逐猎物, 并几乎总能在各种情况下捕获猎物。假设狩猎活动发生在一个半径为  $R$  的区域附近, 北方苍鹰的位置更新和猎物的逃避策略可以用式(8)~(10)来描述。通过模拟这种捕猎行为, 算法在搜索空间的局部区域内进行搜索的能力得到了增强。

$$\mathbf{x}_{ij}^{newP2} = x_{ij} + R(2r - 1)x_{ij} \quad (8)$$

$$R = 0.02(1 - \frac{t}{T}) \quad (9)$$

$$\mathbf{X}_i = \begin{cases} \mathbf{X}_i^{newP2}, & F_i^{newP2} < F_i \\ \mathbf{X}_i, & F_i^{newP2} \geq F_i \end{cases} \quad (10)$$

式中:  $t$  表示当前迭代次数;  $T$  表示最大迭代次数;  $\mathbf{X}_i^{newP2}$  表示第  $i$  个北方苍鹰的新位置;  $\mathbf{x}_{ij}^{newP2}$  表示第  $i$  个北方苍鹰第  $j$  维的新位置;  $F_i^{newP2}$  表示基于第 2 阶段更新后第  $i$  个北方苍鹰的目标函数值。

### 2.2 INGO 算法原理

针对 NGO 算法容易陷入局部最优及收敛速度慢等缺点, 进行了改进, 改进策略包括:

#### 1) 采用折射反向学习策略进行初始化

折射反向学习初始化, 是一种利用光的折射原理来优化种群智能算法初始种群的方法。折射反向学习初始化方法通过引入透镜成像的原理, 生成一个反向位置以扩展搜索范围, 从而提升算法的全局搜索能力<sup>[22]</sup>。具体改进策略描述为:

(1) 根据下列公式随机初始化生成一半 ( $N/2$ ) 的初始种群;

$$x_{ij} = lb + rand \times (ub - lb) \quad (11)$$

式中:  $lb$  和  $ub$  分别为搜索的下界和上界。

(2) 根据折射反向学习生成另一半 ( $N/2$ ) 的初始种群, 该策略实施的公式为:

$$x'_{ij} = \frac{lb + ub}{2} + \frac{lb + ub}{2 \times k} - \frac{x_{ij}}{k} \quad (12)$$

式中:  $k$  是一个常数, 用于控制折射的程度。

(3) 将(1)和(2)生成的初始种群放到一起形成新的初始种群, 该种群个数为  $N$ 。

#### 2) 正余弦策略进行勘探阶段的位置更新

正余弦算法是一种创新的随机优化方法, 它利用正弦和余弦函数所具有的波动性和周期性特性来实现算子的设计目标来搜索和迭代最优解, 通过调整正弦和余弦函数的参数, 可以在算法的不同阶段引入不同的搜索倾向, 从而实现对探索与开发的动态平衡, 具有参数少、结构简单、易实现、收敛速度快等优点<sup>[23]</sup>。正余弦策略搜索当  $r_1 \sin(r_2)$  和  $r_1 \cos(r_2)$  的值在  $-1 \sim 1$ , 搜索采用局部开发; 当值  $> 1$  或者  $< -1$  时, 搜索采用全局开发。本文用正余弦策略替换原始北方苍鹰算法第 1 阶段的位置更新公式, 其实现公式如式(13)~(15)所示。

$$x_{ij}(t+1) = \begin{cases} \lambda \cdot x_{ij}(t) + r_1 \cdot \sin(r_2) \cdot |r_3 \cdot \\ \mathbf{P}_j(t) - x_{ij}(t)|, r_4 > 0.5 \\ \lambda \cdot x_{ij}(t) + r_1 \cdot \cos(r_2) \cdot |r_3 \cdot \\ \mathbf{P}_j(t) - x_{ij}(t)|, r_4 \leq 0.5 \end{cases} \quad (13)$$

$$r_1 = \left[ 1 - \left( \frac{t}{T} \right)^a \right]^{\frac{1}{a}} \quad (14)$$

$$\lambda = \frac{e^{\frac{t}{T}} - 1}{e - 1} \quad (15)$$

式中:  $t$  为当前迭代次数;  $x_{ij}(t)$  表示第  $i$  个北方苍鹰在第  $t$  次迭代时第  $j$  维的位置;  $\mathbf{P}_j(t)$  表示第  $t$  次迭代时的最优解在第  $j$  维的分量;  $T$  为最大迭代次数;  $r_1, r_2, r_3, r_4$  为随机参数,  $r_1$  由上述更新函数确定;  $a$  为  $>1$  的常数;  $r_2 \sim U[0, 2\pi], r_3 \in (0, \infty), r_4 \sim U[0, 1]$ 。

### 3) 改进开发阶段的狩猎半径 $R$

原始步长搜索因子呈线性递减趋势,不利于进一步平衡北方苍鹰算法的全局搜索和局部开发能力,因此对其进行改进,改进公式为:

$$R = 0.1 - \frac{e^{\frac{t}{T}} - 1}{e - 1} \quad (16)$$

原始步长搜索因子随迭代次数线性递减,并且收敛速度是固定的,限制了算法的探索能力,使其容易陷入局部极值;改进后的步长搜索因子随迭代次数非线性变化,在初期迭代时减小较慢,随着迭代次数的增加,减小的速度逐渐加快,这有助于在搜索初期进行更广泛的探索,而在后期进行更精细的搜索,从而更好的平衡探索和开发。

## 2.3 基于INGO的BiLSTM\_SA参数寻优

在BiLSTM\_SA模型中,隐含层神经元个数、训练次数等超参数的选取对预测精度具有重要影响。如果仅凭经验随意选择参数,可能无法充分发挥模型的性能潜力;而若采用网格搜索等穷举式优化方法,虽然可以找到最优参数组合,但会带来极高的计算成本和时间消耗。隐藏层单元数目是决定BiLSTM模型容量的核心参数,单元过少,模型无法捕捉风电功率序列中复杂的时空依赖关系,导致欠拟合;单元过多,则极易在有限的训练数据上过拟合,并显著增加计算成本。初始学习率是控制模型收敛速度和最终性能的重要参数,学习率过大可能导致训练过程在最优解附近震荡甚至发散;学习率过小则会导致收敛速度极慢,甚至陷入局部最优。最大训练周期直接关系到模型的收敛状态和过拟合风险,训练周期不足,模型未充分学习;训练周期过多,模型会对训练数据过度学习导致泛化能力下降。因此,采用INGO智能优化算法,对BiLSTM\_SA模型中的隐藏单元数目、初始学习率和最大训练周期3个超参数进行寻优,寻优过程如图2所示。

## 2.4 基于INGO\_BiLSTM\_SA的风电功率预测

基于INGO\_BiLSTM\_SA的风电功率预测过程分为数据预处理、BiLSTM\_SA和INGO这3部分。在数据预处理

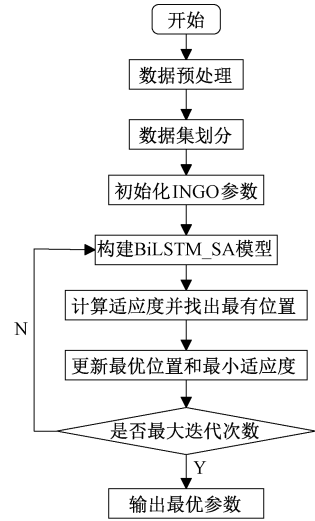


图2 超参数优化流程

Fig. 2 Hyperparameter optimization process

理阶段,首先采用Pearson相关系数法进行特征选择,剔除与目标变量相关性较弱的特征。首先,从风电场系统中提取风电数据,通过滑动窗口技术构建6个历史时间步输入、1个未来时间步输出的时序样本。然后采用INGO算法对BiLSTM\_SA网络的3个关键超参数(隐藏单元数、最大训练周期数、初始学习率)进行优化,以验证集均方根误差作为适应度函数。获得最优参数组合后,构建包含单头自注意力机制的BiLSTM\_SA预测模型。最后对风电功率数据进行模型训练与测试集预测,最终输出优化后的预测结果。具体实现流程如图3所示。

## 3 实验方法与结果分析

### 3.1 数据集分析

本研究实验数据选取新疆某风电站的数据进行实验验证,该数据集包含2019年3月1日~3月31日的风电数据,数据集中包含以下特征:气压、温度、湿度、测风塔在10、30、50、70 m高度的风速、轮毂高度风速、轮毂高度风向、测风塔在10、30、50、70 m高度的风向,以及历史实际发电功率,采样间隔15 min,总共有2976组数据。然后对原始数据进行重构,以生成适合时间序列预测的输入和目标数据,延时步长为6,预测步长为1,因此重构后的数据有2970组,选取前70%的数据作为训练集,30%的数据作为测试集。

### 3.2 评价指标

为了评估不同模型预测的性能,采用均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和决定系数( $R^2$ )作为评价指标。其中RMSE、MAE和MAPE值越小,说明预测值与真实值误差较小,预测效果好;  $R^2$ 越接近于1,说明预测精度越

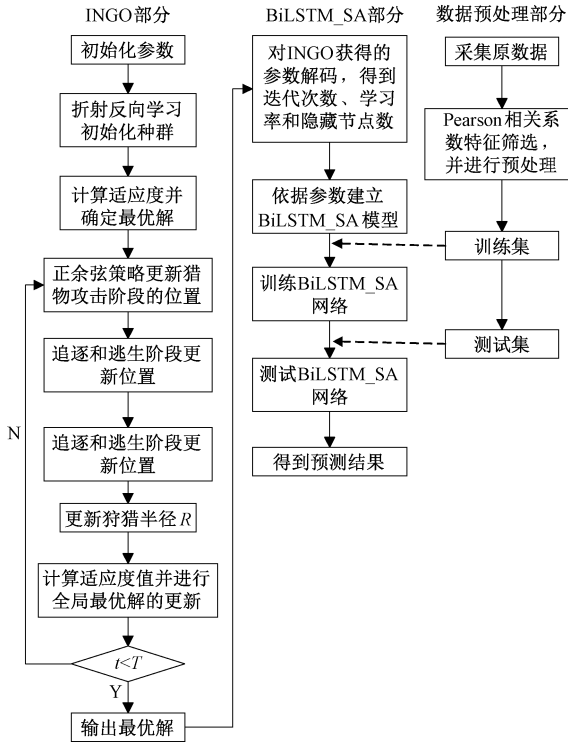


图 3 风电功率预测流程图

Fig. 3 Wind power prediction process chart

高。具体计算公式为：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$MAPE = n \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (19)$$

$$R^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (20)$$

式中： $n$  为样本容量； $\hat{y}_i$  为实际功率值； $y_i$  为预测值； $\bar{y}$  为样本均值。

### 3.3 数据预处理

因影响风电功率的影响因素较多，采用 Pearson 相关系数法对影响因素进行相关性分析，保留相关性强的因素，以相关系数的绝对值判断相关程度的高低，将相关系数绝对值低于 0.3 的因素去除，具体分析结果如图 4 所示。

根据结果可得，测风塔 50 m 风向、温度、气压和湿度与风电功率相关性较低，将其剔除。为了验证 Pearson 相关系数法剔除无关变量的有效性，选取 BiLSTM 模型作为对比，实验结果如表 1 所示，结果表明经过变量筛选后，模型的预测性能较原始特征集有明显改善。




图 4 相关系数

Fig. 4 Correlation coefficient

### 3.4 自相关分析确定延时步长

为了科学确定延时步长，对风电功率时间序列进行了自相关分析，自相关函数图清晰地展示了序列自身在不同延时步长下的相关性强度，如图 5 所示。

由图 5 可以看到，在延时步长  $< 20$  时，风电功率序列的自相关性随着延时步长的增加而逐渐衰减。基于分析，选择延时步长为 6，对应的滞后时间为 1.5 h，该延时步长的自相关系数为 0.852 6，表明其与当前时刻存在强相关

表1 原数据集与Pearson筛选数据集预测指标对比

Table 1 Comparison of prediction indicators between the original dataset and the Pearson filtered dataset

预测模型	RMSE / kW	MAE / kW	MAPE / %	$R^2$
BiLSTM	14.38	9.72	79.04	94.65
BiLSTM_Pearson	13.70	8.95	64.25	95.14




图5 风电功率自相关分析图

Fig. 5 Wind power auto correlation analysis chart

性,能为模型提供有效的上下文信息。此选择在信息量与复杂度间取得了最佳平衡:相较于更短步长,它能更充分地捕捉短期动态特征而非瞬时波动;而与更长步长相比,则避免了引入冗余噪声及不必要的计算负担。同时,该时间尺度也契合电力系统实时调度的实际需求,使模型预测更具应用价值。

### 3.5 实验与预测结果分析

#### 1) 不同注意力机制对比

本文采用的注意力机制为单头、2个键和查询通道的自注意力机制,为了验证单头注意力机制较多头注意力机制的优越性,将其与2头、4个键和查询通道的自注意力机制和4头、8个键和查询通道的自注意力机制进行了对比实验,同时将其与文献[13]中的传统序列注意力机制也进行了对比,实验结果如表2所示。

表2 不同注意力机制下预测指标对比

Table 2 Comparison of prediction indicators under different attention mechanisms

预测模型	RMSE / kW	MAE / kW	MAPE / %	$R^2$
BiLSTM+SA(1,2)	12.44	8.20	63.16	96.00
BiLSTM+SA(2,4)	12.77	8.34	65.01	95.78
BiLSTM+SA(4,8)	12.62	8.14	48.86	95.88
BiLSTM+AM	12.68	8.34	61.70	95.84

通过表2可以看出,对于不同头的自注意力机制,单头注意力模型在RMSE与 $R^2$ 两个关键指标上均表现最佳,同时其MAE也极具竞争力。这表明该模型在整体预

测精度和对数据方差的解释能力上最为出色。尽管4头模型在MAPE上优势明显,但其RMSE更高,意味着它可能产生了更多不愿见到的大偏差预测点。此外,模型性能并未随注意力头数增加而单调提升,双头模型各项指标反而全面下降,这证实了对于本任务,结构简洁的单头注意力在有效捕捉关键时序特征的同时,避免了多头结构可能带来的过拟合与参数冗余问题,是实现精度与稳健性最佳平衡的选择。本文的模型相较BiLSTM-AM模型在RMSE、MAE和 $R^2$ 这三个指标上均处于优势,意味着其预测的绝对误差更小,对数据整体的拟合度更高,尽管MAPE略高,表明其预测的相对误差略差一些,但整体而言,本文的模型性能更具优势。

#### 2) 基准模型对比

为了验证所提模型的优越性能,选取了五种模型作为对比基准,包括反向传播神经网络(back propagation, BP)、循环神经网络(recurrent neural network, RNN)、门控循环单元(gated recurrent unit, GRU)、卷积神经网络(convolutional neural networks, CNN)和随机森林(random forest, RF)。各种模型的预测值对比如图6所示,评价指标对比如图7和表3所示。




图6 不同基准模型预测结果对比

Fig. 6 Comparison of prediction results of different benchmark models




图7 不同基准模型误差柱状图对比

Fig. 7 Error bar chart comparison of different benchmark models

通过图6对比基准模型与本文提出的模型的预测结果与实际观测曲线可以发现,本文模型在预测风电功率波动特征方面表现出显著优势,该模型的预测曲线与实际值

表 3 不同基准模型的评价指标对比

Table 3 Comparison of evaluation indicators for different benchmark models

预测模型	RMSE /	MAE /	MAPE /	$R^2$
	kW	kW	%	
BP	11.49	8.00	82.84	96.58
RNN	17.03	11.23	71.50	92.49
GRU	17.24	11.69	94.97	92.31
CNN	13.02	9.19	114.28	95.62
RF	11.60	7.07	30.24	96.52
INGO_BiLSTM_SA	10.55	6.73	44.17	97.12

曲线的吻合程度最佳,充分证明了其在预测精度上的优越性。

通过图 7 可以看到,本文模型误差评价指标明显低于其他模型。由表 3 可以看出,本文模型对比各基准方法展现出显著的性能优势。具体而言,在  $R^2$  指标上,本方法较五种对比模型分别提升了 0.56%、5.01%、5.21%、1.57% 和 0.62%;同时, RMSE 指标则相应降低了 8.18%、38.05%、38.81%、18.97% 和 9.05%, MAE 指标分别降低了 15.88%、40.07%、42.43%、26.77% 和 4.81%。特别地,在 MAPE 指标方面,本方法较 BP、RNN、GRU 和 CNN 分别降低了 46.68%、38.22%、53.49%、61.35%,体现了模型在控制相对误差的有效性。尽管 RF 模型在 MAPE 指标上表现更优,但综合考量 RMSE、 $R^2$  等关键指标,本文模型在这两个核心指标上均取得最优值,说明本文模型在避免极端预测误差、提升整体预测精度方面具有明显优势。这些数据充分表明,该模型不仅在拟合优度方面取得显著进步,同时实现了预测误差的大幅降低,整体性能明显优于其他对比方法。

3) 组合模型对比

为了验证各模型组件对风电功率预测性能的贡献。将 INGO\_BiLSTM\_SA 模型与 LSTM、BiLSTM、BiLSTM\_SA 和 NGO\_BiLSTM\_SA 模型的预测效果进行消融实验对比,通过图 8 展示了各模型预测结果与实际风电功率值的对比情况,同时图 9 展示了各误差指标的分布,表 4 呈现了评价指标具体情况。这种实验设计有效验证了模型各改进模块对预测精度提升的具体作用。

由图 8、图 9 可以看出,BiLSTM 模型相比基础 LSTM 模型展现出更优的性能表现,无论是在曲线拟合度还是各误差指标上,BiLSTM 都取得了更好的结果,这验证了双向结构能更有效地捕捉风电功率数据的前后时序特征。当引入注意力机制并结合 INGO 算法参数优化后,模型的预测精度得到进一步提升,具体表现为误差值显著降低,预测曲线与实际值的吻合程度明显改善。进一步,对 INGO 算法进行改进后,模型的预测精度又有一些提升同时误差小幅下降,验证了改进算法进行预测的优越性。

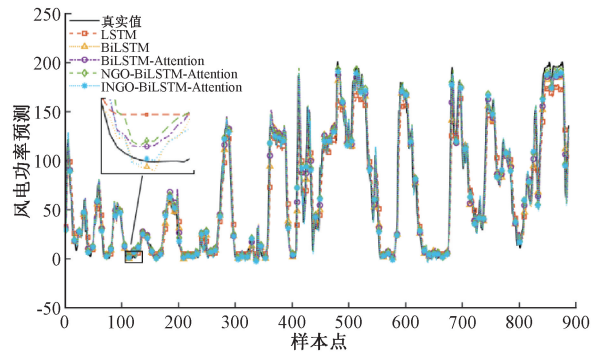


图 8 组合模型预测结果对比

Fig. 8 Comparison of combined model prediction results

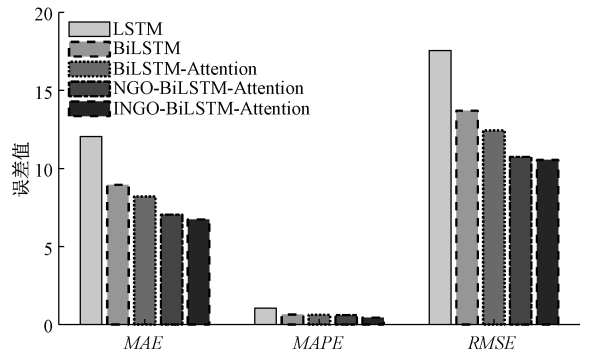


图 9 组合模型不同误差指标对比

Fig. 9 Comparison of different error metrics of the composite model

表 4 组合模型的评价指标对比

Table 4 Comparison of evaluation metrics for composite models

预测模型	RMSE /	MAE /	MAPE /	$R^2$
	kW	kW	%	
LSTM	17.56	12.06	104.84	92.02
BiLSTM	13.70	8.95	64.25	95.14
BiLSTM_SA	12.44	8.20	63.16	96.00
NGO_BiLSTM_SA	10.75	7.05	61.13	97.01
INGO_BiLSTM_SA	10.55	6.73	44.17	97.12

通过表 4 可以得到,本文提出的 INGO\_BiLSTM\_SA 模型较传统 LSTM、BiLSTM、BiLSTM\_SA 及 NGO\_BiLSTM\_SA 模型展现出显著优势。该模型在  $R^2$  指标上分别提升了 5.54%、2.08%、1.17% 和 0.11%,同时 RMSE 指标相应降低了 39.92%、22.99%、15.19% 和 1.86%, MAE 指标分别降低了 44.20%、24.80%、17.93% 和 4.54%。这一结果不仅证实了所提方法具有更高的预测精度和更稳定的误差控制能力,同时也验证了模型架构改进的有效性:(1)双向结构 BiLSTM 较单向 LSTM 能显著提升预测性能;(2)注意力机制的引入进一步优化了模型表现;(3)INGO 算法参数调优最终使模型能够更精准地捕捉风电功率的时序变化特征,

从而获得最优的预测效果。

#### 4) 不同算法优化模型对比

为了验证本文所提 INGO 算法的有效性,选用蜣螂优化算法(dung beetle optimizer, DBO)、灰狼优化算法(grey wolf optimization, GWO)、麻雀搜索算法(sparrow search algorithm, SSA)和粒子群算法(particle swarm optimization, PSO)进行对比,实验结果如表 5 所示,误差 MAE 和决定系数  $R^2$  的二维图如图 10 所示。

表 5 不同算法优化模型预测对比

Table 5 Comparison of different algorithm optimization model prediction

预测模型	RMSE / kW	MAE / kW	MAPE / %	$R^2$
DBO	10.70	7.07	61.26	97.04
GWO	10.67	6.77	44.87	97.05
SSA	10.68	6.82	43.58	97.05
PSO	10.61	6.77	45.05	97.08
INGO	10.55	6.73	44.17	97.12




图 10 误差精度二维图

Fig. 10 Error precision two-dimensional chart

由表 5 可得,INGO 算法优化 BiLSTM\_SA 模型进行风电功率预测的决定系数  $R^2$  最高,较其他 4 种算法分别提升了 0.08%、0.07%、0.07% 和 0.04%。同时伴随着误差的降低,MAE 指标分别降低了 4.80%、0.50%、1.32% 和 0.50%。由图 10 可得,INGO 算法相比其他算法有着更小的 MAE 值和更大的  $R^2$  值,表示其有更好的预测能力,而且预测误差更小。

## 4 结 论

本文构建了一种融合单头注意力机制(SA)的双向长短期记忆网络(BiLSTM)与改进北方苍鹰算法(INGO)调参的风电功率预测模型(INGO\_BiLSTM\_SA)。采用 Pearson 相关系数法实现特征筛选,有效剔除了冗余特征,显著降低了模型计算复杂度,并提升了预测精度;引入的

单头注意力机制有效捕捉了时序数据中的长程依赖关系,增强了模型的泛化能力;通过改进的北方苍鹰算法优化了 BiLSTM 模型中的超参数,进一步提升了模型性能。基于新疆某风电站数据的实验结果表明,所提模型相较于传统 BiLSTM 网络,其决定系数提高了 2.08%,均方根误差和平均绝对误差分别降低了 23.0% 和 24.8%,验证了模型的有效性和优越性。针对目前风电数据的不断增长,未来可以进一步改进数据处理算法,消除冗余数据,在降低时间复杂度的同时提高预测准确率;还可以探索更多的自适应算法结合深度学习技术,进一步提升模型预测的精度。

## 参考文献

- [1] 蒲晓云,杨靖,杨兴,等. 基于参数优化和 QR 的短期风电功率预测[J]. 电子测量技术,2025, 48(16): 88-98. PU X Y, YANG J, YANG X, et al. Short-term wind power prediction based on parameter optimization and QR[J]. Electronic Measurement Technology, 2025, 48(16): 88-98.
- [2] CHANCHAM C, WAEWSAK J, GAGNON Y. Offshore wind resource assessment and wind power plant optimization in the Gulf of Thailand[J]. Energy, 2017, 139:706-731.
- [3] 孙荣富,张涛,和青,等. 风电功率预测关键技术及应用综述[J]. 高电压技术,2021,47(4):1129-1143. SUN R F, ZHANG T, HE Q, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021,47(4):1129-1143.
- [4] 张登攀,兰征,杜怡衡. 基于 PCHIP-VMD 数据分析与 SSA-LSTM 模型的短期风电功率预测[J]. 电子测量与仪器学报, 2025,39(5):251-261. ZHANG D P, LAN ZH, DU Y H. Short-term wind power fo recasting based on PCHIP-VMD data analysis and SSA-LSTM model [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 251-261.
- [5] 邬永,王冰,陈玉全,等. 融合精细化气象因素与物理约束的深度学习模型在短期风电功率预测中的应用[J]. 电网技术,2024,48(4):1455-1468. WU Y, WANG B, CHEN Y Q, et al. Application of deep learning model integrating refined meteorological factors and physical constraints in short-term wind power prediction [J]. Power System Technology, 2024, 48(4): 1455-1468.
- [6] 杨婷,陈黎来,李世纪,等. 基于主成分分析-线性回归的光伏发电功率预测研究[J]. 南京工程学院学报(自然科学版),2022,20(1):77-83. YANG T, CHEN L L, LI SH J, et al. Research on photovoltaic power prediction based on principal component analysis and linear regression[J]. Journal of Nanjing Institute of Technology (Natural Science Edition), 2022, 20(1): 77-83.
- [7] WANG Z H, CHI D W. Research on wind power prediction model based on random forest and SVR[J].

- EAI Endorsed Transactions on the Energy Web, 2024. DOI:10.4108/ew.5758.
- [8] LIU Y W, LI L L, LIU J Q. Short-term wind power output prediction using hybrid-enhanced seagull optimization algorithm and support vector machine: A high-precision method [J]. International Journal of Green Energy, 2024, 21(12): 2858-2871.
- [9] TANG F. Short-term wind power prediction based on improved sparrow search algorithm optimized long short-term memory with peephole connections [J]. Wind Engineering, 2025, 49(1): 71-90.
- [10] MULEWA S, PARMAR A, DE A. A novel Bagged-CNN architecture for short-term wind power forecasting[J]. International Journal of Green Energy, 2024, 21(12): 2712-2723.
- [11] 徐武, 范鑫豪, 沈智方, 等. 多尺度特征提取的 Transformer 短期风电功率预测 [J]. 太阳能学报, 2025, 46(2): 640-648.  
XU W, FAN X H, SHEN ZH F, et al. Short-term wind power prediction using transformer with multi-scale feature extraction [J]. Acta Energiæ Solaris Sinica, 2025, 46(2): 640-648.
- [12] 王愈轩, 刘尔佳, 黄永章. 基于 CNN-LSTM-lightGBM 组合的超短期风电功率预测方法 [J]. 科学技术与工程, 2022, 22(36): 16067-16074.  
WANG Y X, LIU ER J, HUANG Y ZH. An ultra-short-term wind power prediction method based on CNN-LSTM-lightGBM combination [J]. Science Technology and Engineering, 2022, 22 (36): 16067-16074.
- [13] LI ZH, XU R S, LUO X R, et al. Short-term wind power prediction based on modal reconstruction and CNN-BiLSTM [J]. Energy Reports, 2023, 9: 6449-6460.
- [14] 高鹭, 孔繁苗, 张飞, 等. 基于 IPSO-BiLSTM-AM 模型的超短期风电功率预测方法 [J]. 智慧电力, 2022, 50(4): 27-34.  
GAO L, KONG F M, ZHANG F, et al. Ultra short-term wind power prediction method based on IPSO BiLSTM-AM model [J]. Smart Power, 2022, 50(4): 27-34.
- [15] 王珊珊, 吴霓, 何嘉文, 等. 基于 SSA-BiLSTM-AT 的短期风电功率预测 [J]. 湖北工业大学学报, 2024, 39(5): 25-30.  
WANG SH SH, WU N, HE J W, et al. Short term wind power prediction based on SSA-BiLSTM-AT model [J]. Journal of Hubei University of Technology, 2024, 39(5): 25-30.
- [16] 郜宁, 高晓霞, 吴茂乾, 等. 基于 LSTM 的风电机组轮前风速映射方法研究 [J]. 中国测试, 2025, 51(5): 155-161.  
GAO N, GAO X X, WU M Q, et al. Research on wind speed mapping method in front of wind turbine based on LSTM [J]. China Measurement & Test, 2025, 51(5): 155-161.
- [17] ZHAO L P, WU K Y. Mach number prediction for a wind tunnel based on the CNN-LSTM-Attention method [J]. Instrumentation, 2023, 10(4): 64-82.
- [18] LIU H, ZHANG X Y, YANG Y X, et al. Hourly traffic flow forecasting using a new hybrid modelling method [J]. Journal of Central South University, 2022, 29: 1389-1402.
- [19] 王雨虹, 王志中, 付华, 等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究 [J]. 仪器仪表学报, 2022, 43(3): 87-97.  
WANG Y H, WANG ZH ZH, FU H, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [20] 张昊立, 张菁, 倪建辉, 等. 引入注意力机制的 LSTM-FCN 海上风电功率预测 [J]. 太阳能学报, 2024, 45(6): 444-450.  
ZHANG H L, ZHANG J, NI J H, et al. LSTM-FCN offshore wind power forecasting with introduction of attention mechanism [J]. Acta Energiæ Solaris Sinica, 2024, 45(6): 444-450.
- [21] DEHGhani M, HUBÁLOVSKY S, TROJOVSKY P. Northern goshawk optimization: A new swarm-based algorithm for solving optimization problems [J]. IEEE Access, 2021, 9: 162059-162080.
- [22] 王宗山, 于洪伟, 王杰, 等. 基于正交设计的折射反向学习樽海鞘群算法 [J]. 哈尔滨工业大学学报, 2022, 54(11): 122-136.  
WANG Z SH, YU H W, WANG J, et al. Salp swarm algorithm based on orthogonal refracted opposition-based learning [J]. Journal of Harbin Institute of Technology, 2022, 54(11): 122-136.
- [23] 魏锋涛, 张洋洋, 黎俊宇, 等. 基于动态分级策略的改进正弦余弦算法 [J]. 系统工程与电子技术, 2021, 43(6): 1596-1605.  
WEI F T, ZHANG Y Y, LI J Y, et al. Improved sine cosine algorithm based on dynamic classification strategy [J]. Systems Engineering and Electronics, 2021, 43(6): 1596-1605.

## 作者简介

王海亮, 硕士, 实验师, 主要研究方向为大数据分析、通信数据分析及互联网体系结构。

E-mail: whl@nuc.edu.cn

李敏, 硕士, 工程师, 主要研究方向为控制工程、通信数据分析及互联网体系结构。

E-mail: lm@nuc.edu.cn

刘亚翊, 硕士, 工程师, 主要研究方向为大数据应用分析、通信数据分析及互联网体系结构。

E-mail: lyh@nuc.edu.cn

郝海霞(通信作者), 博士, 讲师, 主要研究方向为智能算法、计算机视觉。

E-mail: haohx43@163.com