

基于 IDBO-TCN-LSTM 的短期光伏功率预测

周新宇, 姜志航, 白峻铭, 梁宏涛

(青岛科技大学 信息科学技术学院, 山东 青岛 266011)

摘要:为了解决光伏功率预测中存在的不稳定性和波动性问题,以及长短期记忆网络(LSTM)在参数确定方面的困难,该文提出了一种基于改进蜣螂优化算法(IDBO)、时间卷积网络(TCN)和长短期记忆网络相结合的短期光伏功率组合预测模型。首先,利用 Tent 混沌反向学习策略对蜣螂算法的种群进行初始化,以提高算法的探索能力和多样性;引入莱维飞行和动态权重因子更新解决原始算法收敛慢和易陷入局部最优的问题;引入高斯-柯西变异对最优个体进行扰动,增强全局搜索能力。其次,选择获得感受野更大的 TCN 作为特征提取层,以捕捉更加复杂的时间序列模式。最后,采用改进蜣螂优化算法优化 LSTM 网络模型的参数设置,建立 IDBO-TCN-LSTM 组合预测模型并在澳大利亚光伏数据集上进行仿真实验。对比结果显示,该模型在处理短期光伏预测任务的预测精度上优于其他模型。

关键词:蜣螂优化算法; Tent 映射; Levy 飞行; 变异策略; 光伏功率预测; 深度学习

中图分类号: TP305

文献标识码: A

文章编号: 1673-629X(2025)07-0125-08

doi: 10.20165/j.cnki.ISSN1673-629X.2025.0044

Short-term PV Power Prediction Based on IDBO-TCN-LSTM

ZHOU Xin-yu, JIANG Zhi-hang, BAI Jun-ming, LIANG Hong-tao

(School of Information Science and Technology, Qingdao University of Science and Technology,
Qingdao 266011, China)

Abstract: In order to solve the instability and volatility problems in PV power prediction, as well as the difficulties in parameter determination of long-short-term memory networks (LSTM), we propose a short-term PV power portfolio prediction model based on the combination of the improved dung beetle optimization algorithm (IDBO), temporal convolutional network (TCN) and long-short-term memory networks. Firstly, the population of the dung beetle algorithm is initialized using the Tent chaotic inverse learning strategy to improve the exploratory ability and diversity of the algorithm; Lévy flights and dynamic weight factor updating are introduced to solve the shortcomings of the original algorithm, which is slow to converge and prone to fall into local optimums; Gaussian-Cauchy variation is introduced to perturb the optimal individuals and enhance the global search ability. Secondly, the TCN, which obtains a larger sensory field, is selected as the feature extraction layer to capture more complex time series patterns. Finally, the improved dung beetle optimization algorithm is used to optimize the parameter settings of the LSTM network model, and the combined IDBO-TCN-LSTM prediction model is established and simulation experiments are carried out on an Australian photovoltaic (PV) dataset. The comparative results show that the prediction accuracy of the proposed model is better than that of other models in dealing with short-term PV prediction tasks.

Key words: dung beetle optimization algorithm; Tent mapping; Levy flight; variational strategy; photovoltaic power prediction; deep learning

0 引言

作为最具前景的可再生能源之一,光伏因其丰富的储量以及清洁环保的特点,受到了全球各国的高度关注。光伏发电正逐步成为全球能源转型中的重要组成部分。然而,光伏发电受太阳辐射、温度等不可控的气象因素影响较大,往往会产生剧烈波动。大规模的

光伏并网威胁到电力系统的稳定性,进而影响电网的安全性。为确保新型电力系统的稳定高效运行,提升光伏功率预测精度已成为亟待解决的关键问题。

当前,用于预测领域的技术主要是人工智能方法^[1-2],用于预测短期光伏发电功率的人工智能方法主要是机器学习。机器学习包括传统机器学习和深度

收稿日期: 2024-10-24

修回日期: 2025-02-26

基金项目: 山东省产教融合研究生联合培养示范基地项目(2020-19)

作者简介: 周新宇(2000-),女,硕士研究生,研究方向为智能优化算法、能源互联网;通讯作者: 梁宏涛(1979-),男,博士,副教授,研究方向为数据挖掘、能源互联网。

学习。与前者相比,深度学习具有显著的优势,能够有效地解决庞大的数据分析集及复杂性的挑战。近年来, BP^[3]、LSTM^[4]等神经网络技术已成为解决时间序列问题的重要手段。戴长春^[5]提出改进 DBO-BiLSTM-GRU 模型。白隆^[6]提出 TCN-AM-BiGRU 光伏短期功率预测方法,采用改进的信号分解方法处理数据。姜建国^[7]提出 IDBO-LSTM 预测模型。文献^[8]提出一种基于改进自适应因子与精英反向学习策略的改进灰狼算法(IGWO),用以优化长短期记忆网络(LSTM)预测模型。文献^[9]提出一种融合多策略改进的红尾鹰优化算法(Improved Red-Tailed Hawk optimizer, IRTH)。文献^[10]使用 Pearson 相关系数提取了影响光伏功率的特征,并将分组数据输入 GRU 网络进行训练。宋绍剑^[11]提出 SSA-DRSN-TCN 模型。Chen Hailang 等^[12]利用相关性检验剔除了一些无关特征,之后通过 LSTM 模型进行预测,有效提高了预测精度。

尽管上述模型取得了较好的预测精度,但由于时间序列的复杂性,单一模型无法充分捕捉时间序列中的复杂模式,因此结合卷积神经网络和递归神经网络的混合模型得到了广泛应用。时培明^[13]提出 TCN-BiLSTM-Attention-ESN 混合模型。文献^[14]运用聚类分析并建立 VMD-LTWDBO-BiLSTM 日前预测模型以捕捉光伏出力的连续性特征。文献^[15]利用卷积神经网络深度挖掘数据的空间特征,再结合长短期记忆神经网络进行预测。Zhang 等人^[16]提出一种基于变异模式分解(VMD)、卷积神经网络(CNN)和双向门控递归单元(BiGRU)的综合多变量模型。龙小慧等人^[17]使用 CNN-BiGRU-ATTENTION 神经网络进行预测,解决了单一模型预测精度低、预测效果不稳定等问题。王东风^[18]提出一种综合太阳辐射模型及深度学习的 SRM-CNN-LSTM 光伏功率预测模型。文献^[19]使用变分模态分解并引入了堆叠的双向长短期记忆网络和 Luong 注意力机制,使网络更加精密。

这些模型结合了 CNN 提取特征和 LSTM、GRU 进行预测的优势。然而,普通卷积网络的卷积核大小固定,处理长时间序列时需要更深的层,导致梯度消失等问题,影响预测结果。时间卷积网络(TCN)于 2018 年由 Bai 等人^[20]提出,与 CNN 和递归神经网络相比,TCN 可以并行处理多个时间序列信息,减少计算资源消耗。

综上所述,为提高光伏发电预测精度,该文采用 IDBO 算法对 LSTM 的关键参数(包括最大迭代次数、初始学习率以及隐藏层神经元数)进行自动寻优。此外,为进一步增强 LSTM 模型的预测能力,还引入了 TCN 网络作为特征提取器。TCN 网络能够高效捕捉

时间序列数据中的局部和全局特征,为 LSTM 模型提供更为丰富和有价值的特征输入。结合 LSTM 模型强大的时间序列处理能力,通过 TCN 提取的特征,能够更准确地进行光伏功率预测。

1 基础理论

1.1 蜣螂优化算法

蜣螂优化算法^[21]是 2023 年 Xue 提出的一种群体智能优化算法,具有寻优能力强、收敛速度快的特点。它的原理是根据蜣螂种群的滚球、跳舞、觅食、繁殖、偷窃行为进行更新而达到寻优的目的,分为滚球蜣螂、繁育蜣螂、小蜣螂、偷窃蜣螂。分别按照四种规则进行更新,更新规则如下:

1.1.1 滚球蜣螂

在没有障碍物的情况下,蜣螂会将动物粪便滚成球状,并通过天体线索进行导航。滚球蜣螂的位置更新公式可以表示为:

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x$$

$$\Delta x = |x_i(t) - X^W| \quad (1)$$

其中, t 表示当前迭代次数, $x_i(t)$ 表示第 i 只蜣螂在 t 次迭代时的位置, k 是偏转系数, $b \in (0, 1)$, α 为 -1 或 1, X^W 表示全局最差位置, Δx 用来模拟光强。

当遇到障碍物时,蜣螂利用跳舞行为来找到新的路径,之后通过切线函数计算新的滚动方向,并在方向确定后继续滚动。蜣螂跳舞行为的位置可以表示为:

$$x_i(t+1) = x_i(t) + \tan \theta |x_i(t) - x_i(t-1)| \quad (2)$$

其中, $\theta \in [0, \pi]$, θ 为 $0, \pi/2, \pi$, 则不更新。

1.1.2 繁育蜣螂

边界选择策略,旨在模拟雌性蜣螂选择产卵区域的过程。其数学模型可表示为:

$$L_b^* = \max(X^* \times (1 - R), L_b)$$

$$U_b^* = \min(X^* \times (1 - R), U_b) \quad (3)$$

其中, X^* 表示当前最佳位置, L_b^* 和 U_b^* 分别代表产卵区域的下界和上界,惯性权值 $R = 1 - t/T_{\max}$, 其中 T_{\max} 表示最大迭代次数, L_b 和 U_b 则指优化问题的下界和上界。

在每个迭代周期中,蜣螂的位置会发生变化,其数学模型可以表示如下:

$$B_i(t+1) = X^* + b_1 \times (B_i(t) - L_b^*) + b_2 \times (B_i(t) - U_b^*) \quad (4)$$

其中, $B_i(t)$ 是第 t 次迭代时第 i 个繁育蜣螂的位置, b_1 和 b_2 表示两个独立的随机向量,每个随机向量包含 D 个分量,并且 D 被称为优化问题的维度参数。

1.1.3 小蜣螂

刚成虫外出寻找食物的蜣螂称为小蜣螂,用于确

定最佳觅食区域的边界和更新个体位置的数学模型表示如下:

$$\begin{aligned} L_b^b &= \max(X^b \times (1 - R), L_b) \\ U_b^b &= \min(X^b \times (1 - R), U_b) \end{aligned} \quad (5)$$

其中, X^b 表示先前群体的局部最优位置, L_b^b 和 U_b^b 分别表示最佳搜索范围的下限和上限。因此, 小蜣螂的位置可以表示为:

$$\begin{aligned} x_i(t+1) &= x_i(t) + C_1 \times (x_i(t) - L_b^b) + \\ &C_2 \times (x_i(t) - U_b^b) \end{aligned} \quad (6)$$

其中, $x_i(t)$ 表示第 i 只小蜣螂在第 t 次迭代的位置信息, C_1 表示符合正态分布的随机数, C_2 表示落在 (0, 1) 的随机向量。

1.1.4 偷窃蜣螂

从其他蜣螂获取粪球的行为被称为“偷窃蜣螂”。

偷窃蜣螂的行为表明周围区域是获取食物的最佳位置, 因此可以视为理想的食物来源。偷窃蜣螂的位置可以表示为:

$$\begin{aligned} x_i(t+1) &= X^b + S \times g \times (|x_i(t) - \\ &X^b| + |x_i(t) - X^b|) \end{aligned} \quad (7)$$

其中, $x_i(t)$ 表示第 i 只偷窃蜣螂在 t 次迭代时的位置信息, g 表示一个符合正态分布的随机选择向量, 该向量的维度为 D , S 是常数。

1.2 时序卷积网络

时间卷积网络 (Temporal Convolutional Network, TCN) 是基于卷积神经网络架构的一种改进, 具有强大的时间序列信息挖掘能力。时间卷积网络的核心结构融合了因果卷积, 同时引入了扩张因果卷积和残差模块, 进一步增强了模型的性能。

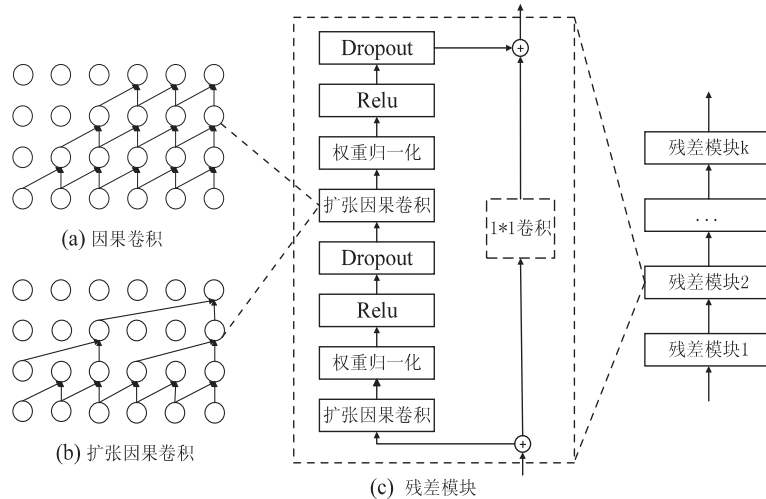


图 1 TCN 结构

1.2.1 因果卷积

图 1(a) 展示了因果卷积的结构。在时刻 t , 因果卷积的输出仅基于前一层的卷积结果和更早的输入元素进行卷积运算。

1.2.2 扩张卷积

扩张因果卷积结构如图 1(b) 所示。相比于普通卷积的卷积核, 扩张卷积通过间隔采样卷积输入, 利用膨胀系数 z 来减少相邻层之间卷积神经元的数量, 从而在保持网络深度不变的情况下扩大视野, 保存更多的历史信息。扩张卷积的计算表示为:

$$F(s) = (x * f)(s) = \sum_{i=0}^{k-1} f(i) \times x_{s-z \times i} \quad (8)$$

其中, x 为输入序列, $*$ 代表卷积操作, k 表示卷积核大小, z 为扩张系数, $f(i)$ 为卷积核中的第 i 个元素, $x_{s-z \times i}$ 则指该卷积对应的乘积元素。

1.2.3 残差连接

残差模块主要是由两个扩张因果卷积层以及非线性映射组成, 具体的结构如图 1(c) 所示, 在每层中利

用 Dropout 正则化来防止深层网络过拟合及权重归一化用以加快训练速度。

1.3 长短时记忆网络

长短期记忆网络通过引入“门控”机制, 能够选择性地记住或遗忘序列数据中的信息。由四个基本单元构成: 输入门、遗忘门、输出门和记忆细胞 (也称为细胞状态)。LSTM 内部结构如图 2 所示。

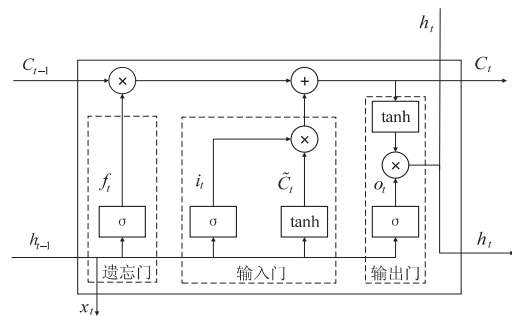


图 2 LSTM 内部结构

遗忘门决定了前一时间步的细胞状态 C_{t-1} 中哪些信息需要被遗忘或保留。输入门决定了当前时间步的

输入 x_t 中需要被更新到细胞状态中的信息。候选细胞状态是根据当前输入和上一时间步的隐藏状态 h_{t-1} 计算出来的,用于更新细胞状态。细胞状态更新是由遗忘门和输入门的输出来决定的。遗忘门控制前一时间步的细胞状态 C_{t-1} 中需要被遗忘的信息;输入门控制候选细胞状态 \tilde{C}_t 中需要被更新到当前细胞状态 C_t 中的信息。具体计算公式如下:

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ \tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ C_t = f_t C_{t-1} + \tilde{C}_t \\ h_t = o_t \tanh(C_t) \end{cases} \quad (9)$$

其中: σ 表示激活函数 Sigmoid,可将输出变换到 $[0, 1]$ 之间; W_i 、 W_o 、 W_f 表示输入门、输出门和遗忘门的权重矩阵; b_i 、 b_o 、 b_f 表示输入门、输出门、遗忘门的偏置因子; x_t 、 h_t 、 C_t 表示 t 时刻的输入层状态、隐藏层状态和控制层状态; \tanh 是曲正切激活函数,将输出变换到 $[-1, 1]$ 之间。

2 IDBO-TCN-LSTM 预测模型

2.1 改进的 DBO 算法

在基本的 DBO 算法中,种群的位置在搜索空间中通过随机初始化,但由于随机生成的解存在局限性,导致蜣螂个体的位置分布不够均匀,降低了种群的多样性(算法的性能)。其次,原始算法存在容易陷入局部最优、全局探索能力较弱、收敛精度较低等问题。因此,针对基础算法存在的局限,提出三种改进策略。具体介绍如下:

2.1.1 混沌反向学习初始化

混沌映射是一种在非线性动态系统中展现出高度敏感性的确定性过程,能够产生看似随机的行为。常见的混沌映射包括 Logistic、Tent 和 Circle 等映射。Logistic 映射通常用于人口增长模型,Tent 映射具有优良的随机性和探索性,Circle 映射常用于周期性系统的建模。该文使用 Tent 混沌映射,其混沌序列的分布如图 3 所示,分布直方图见图 4。Tent 混沌映射的描述如下:

$$x_{k+1} = \begin{cases} x_k/\mu, & 0 < x_k \leq \mu \\ (1-x_k)/(1-\mu), & \mu < x_k \leq 1 \end{cases} \quad (10)$$

其中, k 表示迭代次数, x_k 表示第 k 次迭代结果, $\mu = 0.499$ 。Tent 混沌映射产生初始化种群后,通过精英反向学习策略进一步优化初始种群,从而产生反向学习的种群 X_L 个体。反向学习公式如下:

$$X_L = k(U_b + L_b) - X \quad (11)$$

其中: k 是一个大小为 $1 \times d$ 的随机向量; L_b 和 U_b 分别表示解空间的下界和上界; X 指初始种群。




图 3 Tent 映射序列混沌分布图




图 4 Tent 混沌映射分布直方图

经过精英反向学习对 Tent 产生的种群优化后,将两个种群合在一起计算其适应度,选择最优的 N 个个体作为新的初始种群进入优化算法。

2.1.2 自适应权重和飞行机制

为了使小蜣螂能够向较好的搜索区域收敛,引入权重因子。权值较大时,小偷蜣螂的全局搜索能力较强。随着种群迭代次数的增加,偷窃蜣螂持续向最优位置更新,随着权值减小,其局部搜索能力增强,从而加快了算法的收敛速度。其公式如下:

$$\omega = \frac{e^{2 \times (1 - \frac{t}{T})} - e^{-2 \times (1 - \frac{t}{T})}}{e^{2 \times (1 - \frac{t}{T})} + e^{-2 \times (1 - \frac{t}{T})}} \quad (12)$$

在偷窃阶段引入权重因子可以提高算法的收敛速度,但在面对高维问题时,仍有可能陷入局部最优。Levy 飞行策略是一种随机选择选择技术,利用 Levy 飞行策略可以增强种群的多样性,提高算法的全局优化能力,从而跳出局部最优。改进后的小偷蜣螂的位置更新如下:

$$x_i(t+1) = l_{\text{evy}}(\lambda) \times X^b + S \times g \times (|x_i(t) - X^*| + |x_i(t) - \omega X^b|) \quad (13)$$

其中, $l_{\text{evy}}(\lambda)$ 表示随机步长,计算步长的公式如下:

$$s = \frac{u}{|v|^{1/\beta}} \quad (14)$$

式中, u 和 v 服从正态分布, $u \sim N(0, \sigma_u^2)$, $v \sim N(0, \sigma_v^2)$ 。

$$\sigma_u = \left\{ \frac{\Gamma(1 + \beta) \sin\left(\frac{\beta\pi}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \beta \times 2^{\frac{\beta-1}{2}}}\right\}^{\frac{1}{\beta}} \quad (15)$$

$$\sigma_v = 1$$

式中, $\Gamma(x)$ 为 gamma 函数, β 为常数, 取 $\beta = 1.5$ 。

2.1.3 最优位置扰动策略

在传统的 DBO 算法中, 蜣螂个体的快速同化使得种群集中在当前最优位置, 导致算法容易陷入局部最优解, 因此引入变异算子来增加个体的多样性。柯西变异具有较大的搜索范围, 能够探索更多可能的解, 但其较大的步长可能导致偏离最优解, 生成效果较差的后代。高斯变异则在局部搜索中表现出色, 但其跳出局部最优的能力较弱。因此, 该文采用一种柯西混合扰动变异扰动策略, 结合两者的优点, 可以同时保持广泛的探索能力和强大的局部优化能力, 从而提高算法的整体性能。因为变异扰动可能会使算法变得更加复杂, 因此该文将重点关注最佳的变异扰动方案。柯西-高斯变异策略的公式如下:

$$X_r(t) = X_{\text{best}}(t) (1 + \omega_1 O_{\text{Gauss}}(\sigma) + \omega_2 O_{\text{Cauchy}}(\sigma)) \quad (16)$$

式中, $X_r(t)$ 代表在第 t 次时高斯柯西混合扰动后的位置, t_{max} 为最大迭代次数, $\omega_1 = t/t_{\text{max}}$, $\omega_2 = 1 - \omega_1$ 为变异算子的权重系数, $O_{\text{Gauss}}(\sigma)$ 为高斯算子, $O_{\text{Cauchy}}(\sigma)$ 为柯西算子。初期, 由于种群分布不均匀, 因此采用柯西分布函数来改善个体的特征, 从而使其具有更强的多元化特征, 从而达到更好的全局搜寻效果; 随着时间的推移, 当种群分布越来越均匀时, 就会采用高斯分布函数来干预, 从而降低搜寻结果的不确定性, 提升搜寻的准确率。

自适应高斯-柯西混合扰动策略结合了高斯变异的局部搜索能力和柯西变异的广泛探索能力, 通过动态调整扰动幅度来适应不同的搜索阶段。然而, 这种策略并不能确保变异后新位置的适应度一定优于原位置, 可能导致某些不良解的产生。因此, 引入贪婪规则可以在选择新解时优先考虑适应度更高的个体, 减少对低质量解的依赖。贪婪策略的公式如下:

$$X_{\text{best}}(t) = \begin{cases} X_r(t), & f_r < f_{\text{best}} \\ X_{\text{best}}(t), & f_r \geq f_{\text{best}} \end{cases} \quad (17)$$

式中, f_r 为扰动后位置的适应度值, f_{best} 为最优位置的适应度值。通过比较扰动前后适应度值的大小, 选择是否更新最优位置参数。

2.2 IDBO-TCN-LSTM 预测流程

LSTM 模型的性能很大程度上依赖于超参数的选择, 确定合适的超参数是训练一个高效准确模型的关键。

为减少人工设定参数时可能带来的主观性和不稳定性, 引入群体智能优化算法 IDBO 来自动寻优 LSTM 模型的关键参数, 包括学习率、最大迭代次数以及隐藏神经元个数。此外, 该文利用 TCN 进行特征提取, 结合 LSTM 预测光伏发电功率, 能够充分发挥两者的优势, 提升预测准确性。预测流程如图 5 所示。

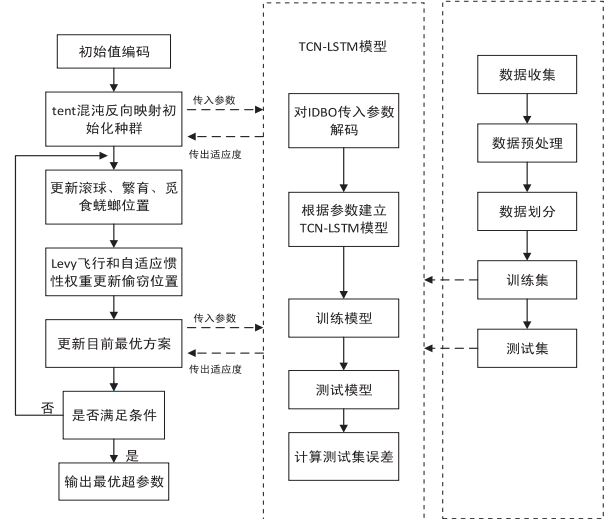


图 5 IDBO-TCN-LSTM 模型流程

IDBO-TCN-LSTM 预测模型具体实现步骤为:

(1) 数据预处理与划分。将环境因素和历史光伏功率等特征作为模型的初始输入并进行归一化处理, 以光伏发电功率作为输出。同时, 将数据分为训练集和测试集。通过数据划分得到供 IDBO-TCN 模型后续使用的训练集和测试集。

(2) IDBO 算法执行。执行 IDBO 算法, 采用 Tent 混沌映射进行蜣螂种群的初始化, 并通过反向学习生成相应的参数。将其传递给 IDBO-TCN-LSTM 部分用于模型的构建。

(3) TCN-LSTM 模型构建。TCN-LSTM 部分对传入的参数解码, 得到学习率、卷积核的层数和卷积核大小、权重系数和偏置项等超参数。根据参数建立 TCN-LSTM 模型, 输入相关数据对 TCN-LSTM 模型进行训练和测试, 计算预测结果的均方根误差, 并将其作为适应度输回到 IDBO 部分进行测试误差的计算。

(4) 超参数优化与迭代。IDBO 部分对 TCN-LSTM 的超参数进行迭代寻优。如果满足条件, 则输出超参数的最优值。反之, 则根据算法的更新规则进行位置更新, 将新的参数传递给模型进行训练, 得到适应度反馈。重复上述循环, 直到满足条件, 得到 TCN-LSTM 模型的最优超参数。

3 实验结果与分析

3.1 实验环境

实验使用 Windows10 操作系统, 处理器为 11th

Gen Intel(R) Core(TM) i5-11400 @ 2.60 GHz 2.59 GHz,并基于 Python 语言,使用 GPU 加速训练,GPU 型号为 NVIDIA GeForce RTX 3080Ti,编程软件为 MATLAB R2022a。

3.2 数据集

该文选用的是 DKASC 数据集中的数据,该数据集包含光伏阵列的历史功率数据以及相关的辐照度、温度、相对湿度等天气数据。原始时间采样间隔为 5 分钟,时间跨度为 2017 年 1 月 1 日至 2017 年 12 月 31 日。考虑到电站本地的环境因素以及光伏功率的有效输出时间段,最终采用的研究时间段为 07:00 至 19:00,每天的数据采样点为 144 个。每组数据都包含特定的环境条件以及相应的光伏发电量的输出信息。

3.3 评价指标

该文使用均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 (R^2) 三种不同的评估指标进行评价,其公式分别为:

$$S_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$

$$S_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n (|y_i - \hat{y}_i|) \quad (19)$$

表 1 消融实验结果

季节	评价指标	IDBO-LSTM	IDBO-TCN	TCN-LSTM	IDBO-TCN-LSTM
春季	RMSE	0.086 2	0.092 8	0.073 5	0.073 4
	MAE	0.041 3	0.055 9	0.037 7	0.038 2
	R^2	0.916 8	0.888 1	0.938 7	0.942 5
夏季	RMSE	0.052 5	0.050 4	0.045 5	0.040 3
	MAE	0.028 9	0.031 1	0.022 3	0.016 3
	R^2	0.978 7	0.978 5	0.981 5	0.987 6
秋季	RMSE	0.041 3	0.048 7	0.033 8	0.034 1
	MAE	0.021 1	0.020 8	0.016 9	0.014 4
	R^2	0.976 8	0.974 1	0.981 8	0.984 5
冬季	RMSE	0.027 1	0.031 7	0.031 2	0.020 8
	MAE	0.015 2	0.014 4	0.014 3	0.014 1
	R^2	0.994 7	0.983 3	0.985 4	0.995 8

3.5 对比实验

为验证 IDBO-TCN-LSTM 光伏功率预测方法的有效性,对比了五种模型 (LSTM、CNN、TCN、CNN-LSTM 以及 TCN-LSTM) 在不同季节对光伏率预测的性能表现。相关结果通过表 2 展示。图 6 展示了各模型在预测光伏功率时与实际功率值之间的关系曲线。为了更直观地呈现模型预测效果的差异,选取了春、夏、秋、冬四季的典型曲线段进行展示。由于展示空间限制,仅展示了曲线的关键部分,以突出模型性能的高峰与低谷。

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

其中, S_{RMSE} 和 S_{MAE} 分别为均方根误差和平均绝对误差, n 为样本总量, y_i 、 \hat{y}_i 表示输出功率的真实值和预测值, \bar{y} 表示所有真实值的平均值。

RMSE 是用来衡量预测值与实际值之间差异的重要指标,较小的 RMSE 值通常表明模型性能更佳。MAE 通过计算预测误差的绝对值平均,提供了一个更直观的误差水平反映。 R^2 量化了模型对数据变异的解释能力,其值范围在 0 到 1 之间,越接近 1 表示模型能够越好地拟合数据。

3.4 消融实验

为了验证模型中不同组件对整体预测性能的影响,进行了消融实验。采用 DKASC 数据集为输入变量,以 MAE、RMSE、 R^2 为评价指标,分别计算 IDBO-LSTM、IDBO-TCN、TCN-LSTM、IDBO-TCN-LSTM 的预测误差。预测结果如表 1 所示,可以看出 IDBO-TCN-LSTM 误差最小,预测精度更高。

对比图 6 中的四张子图 (a)、(b)、(c) 和 (d),可以清晰地观察到 LSTM、CNN 和 TCN 单一模型在预测光伏功率时均呈现出较大的波动效果,特别是在天气变化不稳定的春秋季节。相比之下,将 CNN 和 TCN 与 LSTM 结合成的混合模型在预测性能上明显优于单一模型,预测结果更贴近实际的光伏功率值,且 TCN-LSTM 模型表现更好。这表明 TCN 的特征提取能力优于 CNN,且与 LSTM 的时序数据处理优势互补,使得组合模型能更有效地处理时间序列的复杂变动性。此外,引入 IDBO 优化算法的 TCN-LSTM 组合

模型在预测精度上进一步得到提高,缩小了预测输出

与实际功率值之间的差距,预测精度得到了显著提升。

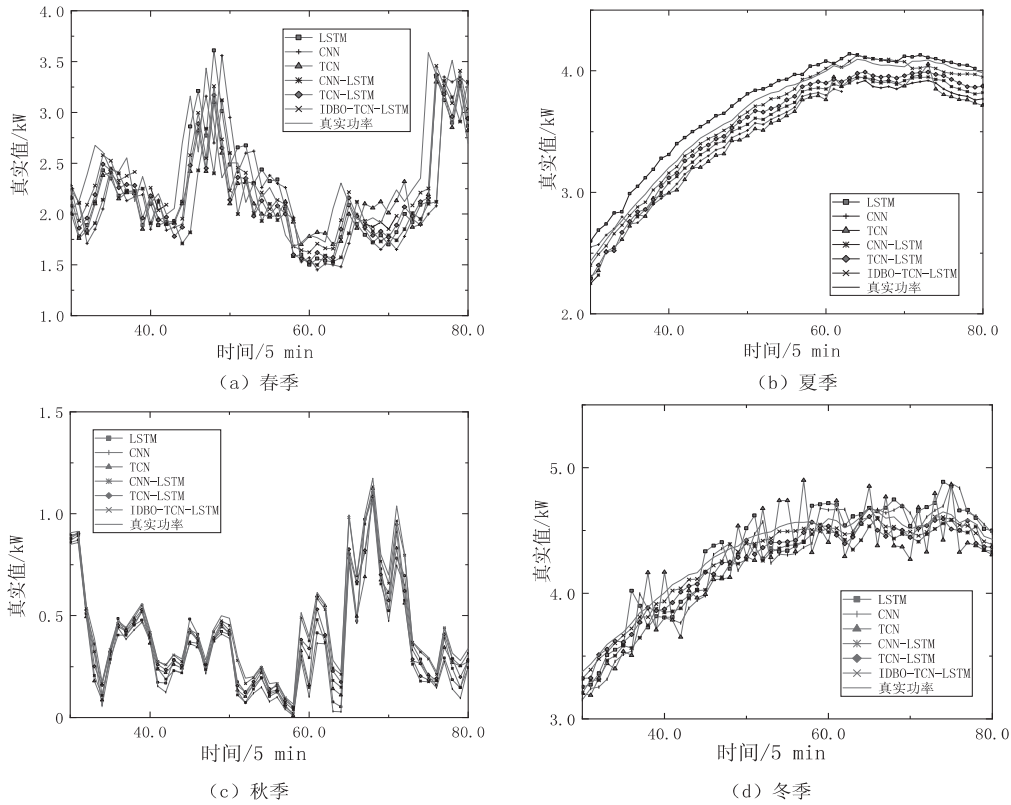


图6 不同季节下的模型预测结果

表2 光伏发电预测结果比较

季节	评价指标	LSTM	CNN	TCN	CNN-LSTM	TCN-LSTM	IDBO-TCN-LSTM
春季	RMSE	0.086 5	0.092 9	0.093 2	0.078 4	0.073 7	0.073 1
	MAE	0.041 6	0.056 1	0.056 2	0.041 1	0.038 1	0.037 7
	R^2	0.916 7	0.887 6	0.887 9	0.928 7	0.938 7	0.943 1
夏季	RMSE	0.052 8	0.051 6	0.050 7	0.047 3	0.045 2	0.039 3
	MAE	0.029 1	0.032 1	0.031 3	0.028 5	0.022 8	0.016 1
	R^2	0.978 6	0.978 5	0.978 3	0.979 9	0.981 3	0.987 9
秋季	RMSE	0.041 6	0.048 7	0.049 1	0.039 6	0.034 6	0.034 3
	MAE	0.021 4	0.020 5	0.021 1	0.019 2	0.017 1	0.014 8
	R^2	0.976 7	0.974 1	0.973 9	0.978 6	0.981 6	0.984 4
冬季	RMSE	0.027 3	0.034 7	0.031 9	0.031 7	0.031 4	0.020 6
	MAE	0.015 6	0.014 6	0.014 5	0.014 4	0.014 1	0.013 8
	R^2	0.994 4	0.982 6	0.983 1	0.985 1	0.985 5	0.996 1

由表2可知, IDBO-TCN-LSTM 模型在所有指标上表现最优,较单一的 LSTM、CNN 和 TCN 模型以及 CNN-LSTM、TCN-LSTM 组合模型表现更好。与 TCN-LSTM 相比, IDBO-TCN-LSTM 在春、夏、冬季的均方根误差分别降低了 0.06 百分点、0.59 百分点和 1.08 百分点,决定系数从 0.985 5 提高到了 0.996 1,表现最为突出。这表明在引入 IDBO 算法后,优化了 LSTM 参数的选择过程,从而显著提升模型的学习和泛化能力。从季节上来看,春季的预测效果在各个模

型上普遍较差,误差更大。这是由于春季月份的天气变化不稳定和频繁的气候转换,使得预测序列产生较大的波动,导致模型的预测精度普遍降低。然而,该文提出的模型在应对这种波动方面的表现仍然优于其他模型,显示出更强的适应性和鲁棒性。结果表明, IDBO-TCN-LSTM 模型在各季节均表现出较低的 RMSE 和 MAE 值,以及较高的 R^2 值,证明了该算法在预测精度上的显著提升。验证了 IDBO 技术的实用性和有效性,进一步突显了其在光伏功率预测领域的优

越性。

4 结束语

针对光伏发电短期功率预测因随机性和波动性导致预测精度较差的问题,提出一种 IDBO-TCN-LSTM 组合预测模型。

(1)考虑到光伏数据以及环境因素之间的时间关联性,采用 LSTM 网络作为预测模型基础。

(2)为了提高预测精度,选择使用时间卷积网络(TCN)来提取光伏数据和环境因素的空间特征。TCN 通过结合因果卷积和扩张卷积,能够有效捕捉时间序列数据中的长期依赖性,同时保留了数据的顺序特性。

(3)引入蜣螂优化算法优化 LSTM,并对蜣螂算法进行改进。通过混沌反向初始化种群、莱维飞行和动态权重因子、高斯-柯西变异平衡 DBO 全局和局部寻优能力,加快收敛速度。

通过对比分析实验证明, IDBO-TCN-LSTM 模型的预测精度更高,显著提升了光伏发电功率预测的准确性和稳健性。

参考文献:

- [1] AHMED R, SREERAM V, MISHRA Y, et al. A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization [J]. *Renewable and Sustainable Energy Reviews*, 2020, 124: 109792.
- [2] 赖昌伟, 黎静华, 陈博, 等. 光伏发电出力预测技术研究综述[J]. *电工技术学报*, 2019, 34(6): 1201-1217.
- [3] 钟安德, 吴自玉, 谢宗效, 等. 基于混合算法改进 BP 神经网络的光伏发电功率预测研究[J]. *云南民族大学学报: 自然科学版*, 2025, 34(1): 100-106.
- [4] 高寒旭, 袁祖晴, 张淑婷, 等. 基于 LSTM 模型的短期光伏功率预测[J]. *太阳能学报*, 2024, 45(6): 376-381.
- [5] 戴长春, 郑晓亮, 杨铖, 等. 基于改进 DBO-BiLSTM-GRU 的光伏发电功率预测方法研究[J]. *自动化应用*, 2024, 65(19): 89-93.
- [6] 白隆, 俞斌, 高峰, 等. 基于 ICEEMDAN 和 TCN-AM-BiGRU 的短期光伏功率预测[J]. *电子测量技术*, 2024, 47(9): 61-69.
- [7] 姜建国, 金方承, 毕洪波. 多策略改进蜣螂优化算法及其在光伏发电功率预测中的应用[J]. *电力需求侧管理*, 2024, 26(6): 101-106.
- [8] 薛阳, 燕宇铖, 贾巍, 等. 基于改进灰狼算法优化长短记忆网络的光伏功率预测[J]. *太阳能学报*, 2023, 44(7): 207-213.
- [9] 赵倩, 郭锋, 王婷, 等. 融合多策略改进红尾鹰优化算法及其应用[J]. *计算机技术与发展*, 2025, 35(1): 140-147.
- [10] XIA Y, WANG J, ZHANG Z, et al. Short-term PV power forecasting based on time series expansion and high-order fuzzy cognitive maps [J]. *Applied Soft Computing*, 2023, 135: 110037.
- [11] 宋绍剑, 姜屹远, 刘斌. 一种 TCN 的改进模型及其在短期光伏功率区间预测的应用[J]. *计算机应用研究*, 2023, 40(10): 3064-3069.
- [12] CHEN H, CHANG X. Photovoltaic power prediction of LSTM model based on pearson feature selection[C]//2021 international conference on energy engineering and power systems (EEPS2021). Hangzhou: EEPS, 2021.
- [13] 时培明, 郭轩宇, 杜清灿, 等. 基于 TCN-BiLSTM-Attention-ESN 的光伏功率预测[J]. *太阳能学报*, 2024, 45(9): 304-316.
- [14] 汪繁荣, 梅涛, 卢璐. 基于相似日聚类和 VMD-LT-WDBO-BiLSTM 的短期光伏功率预测[J]. *智慧电力*, 2024, 52(10): 56-63.
- [15] LI G, XIE S, WANG B, et al. Photovoltaic power forecasting with a hybrid deep learning approach [J]. *IEEE Access*, 2020, 8: 175871-175880.
- [16] ZHANG C, PENG T, NAZIR M S. A novel integrated photovoltaic power forecasting model based on variational mode decomposition and CNN-BiGRU considering meteorological variables [J]. *Electric Power Systems Research*, 2022, 213: 108796.
- [17] 龙小慧, 秦际赞, 张青雷, 等. 基于相似日聚类及模态分解的短期光伏发电功率组合预测研究[J]. *电网技术*, 2024, 48(7): 2948-2957.
- [18] 王东风, 刘婧, 黄宇, 等. 结合太阳辐射量计算与 CNN-LSTM 组合的光伏功率预测方法研究[J]. *太阳能学报*, 2024, 45(2): 443-450.
- [19] 陈君, 郭立颖, 赵小会, 等. 基于 MPBiLSTM 的短期光伏发电功率预测[J]. *计算机技术与发展*, 2024, 34(10): 186-191.
- [20] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J]. *arXiv*: 1803.01271, 2018.
- [21] XUE J, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization [J]. *The Journal of Supercomputing*, 2023, 79(7): 7305-7336.