文章编号:1671-4598(2025)05-0069-10

中图分类号:TP18

69

采用改进 HPO-LSTM-Attention 算法的

DOI:10.16526/j. cnki.11-4762/tp.2025.05.009

刘钦晓,孙 德,赵长春,张俊安,赵 孝

太阳散射辐射预测

(重庆理工大学两江人工智能学院,重庆 401135)

摘要:针对现有对于太阳散射辐射的预测方法准确度低等问题,构建了 HPO-LSTM-Attention 组合模型,为了进一步提高模型预测的准确度为 HPO 设计了一种新的自适应动态权重,从而可以平衡算法的全局探索性和局部开发性;经过注意力机制和 HPO 两种算法的优化使得 LSTM 的预测性能有了极大的提升;实验结果表明新提出的 HPO-LSTM-Attention 模型优于 LSTM、BiLSTM 和 HPO-LSTM 模型,在 MAE、MAPE、R² 和 MSE 评价指标下表现更出色,与未改进模型相比其均方差减少了近 40%,证明了 HPO-LSTM-Attention 模型在预测太阳散射辐射方面的有效性。 关键词:太阳辐射散射, HPO; LSTM;注意力机制;优化算法

Solar Radiation Scattering Prediction by Using Improved HPO-LSTM-Attention Algorithm

LIU Qinxiao, SUN De, ZHAO Changchun, ZHANG Junan, ZHAO Fen

(School of Artificial Intelligence Liangjiang Chongqing, Chongqing University of Technology,

Chongqing 401135, China)

Abstract: To address the low accuracy of existing prediction methods in solar scattering radiation, an HPO-LSTM-Attention combination model is constructed. In order to further improve the accuracy of model predictions, a new adaptive dynamic weight for HPO is designed, which can balance the global exploratory and local development of the algorithm. After optimizing the attention mechanism and HPO algorithms, the prediction performance of the LSTM model is greatly improved. Experimental results show that the newly proposed HPO-LSTM-Attention model outperforms the LSTM, BiLSTM and HPO-LSTM models and performs better in the *MAE*, *MAPE*, R^2 and *MSE* evaluation indicators. Compared with the unimproved model, its mean square error is reduced by nearly 40%, which proves that the HPO-LSTM-Attention model has superiority in predicting solar scattered radiation.

的路径等因素。

通常情况下,在晴朗无云的天气中,散射辐射的贡

献相对较小。然而,在多云天气或存在大量烟尘等污染

物的情况下, 散射辐射的比例会增加。散射辐射的强度

通常以其与总辐射强度的比例来表示,而这个比例在不

同地理区域和气象条件下会有很大的变化,通常在总辐

射强度的百分之十几到百分之三十几之间。在大气中,

Keywords: solar radiation scattering; HPO; LSTM; attention mechanism; optimization

0 引言

太阳辐射可分为两种类型,即直射辐射和散射辐射,它们都受到多种因素的制约。直射辐射的大小受太阳位置、接收表面朝向和倾斜角等因素的影响,而散射辐射则取决于大气条件,包括颗粒物、烟雾、水蒸气、 空气分子和其他悬浮物的浓度,以及太阳光线穿越大气

- 作者简介:刘钦晓(1982-),男,博士,副教授。
 - 张俊安(1981-),男,博士,副教授,高级工程师。
- **通讯作者:**孙 德(1997-),男,硕士。

引用格式:刘钦晓,孙 德,赵长春,等.采用改进 HPO-LSTM-Attention 算法的太阳散射辐射预测[J]. 计算机测量与控制, 2025,33(5):69-78.

收稿日期:2024-03-14; 修回日期:2024-04-25。

基金项目:国家制造业重大专项项目(TC220A04A-43)。

太阳辐射会受到大气分子、气溶胶、云层等因素的吸 收、散射和反射的影响,导致辐射减弱。总的来说,大 气主要在太阳光谱两端吸收太阳辐射,而这些区域的能 量相对较低。因此,大气吸收对太阳的直接辐射影响较 小。相比之下,大气对太阳辐射的散射是导致辐射强度 减弱的主要原因之一。表面太阳辐射(SSR)是地球表 面能量预算的关键组成部分,它在不同的空间和时间尺 度上是不同的。对 SSR 如何以及为什么变化的大量了 解对于更好地理解气候变化至关重要,这肯定需要对高 质量的地表辐射散射数据进行长期测量。太阳能在未来 为可持续能源提供至关重要的作用。太阳能的应用十分 丰富,比如光伏新能源、植物光合作用等^[1]。其中,太 阳能发电不会排放二氧化碳或化石燃料燃烧中的其他危 险气体被认为是有吸引力的方向,特别是在电力系统中 占有极高的地位。对于基于太阳能氢能的系统,主要要 求之一是收集和处理精确的太阳辐射数据。然而,由于 昂贵的成本和技术要求,测量太阳辐射的设备并不总是 在许多地区可用。太阳能被认为是未来最重要的能源之 一。然而,受太阳辐射间歇性和天气等其他因素的影 响,太阳能发电的输出会随着时间和季节波动,如果发 电量被定向连接到电网, 它将给电网运行带来许多困 难。因此,为了提高电力系统的稳定性,降低电网运行 和管理成本,准确预测太阳辐射是一项迫切而理想的技 术。目前,已经开发了一系列经典的太阳辐射预测方 法,即数值天气预报、经典统计方法和混合方法。然 而,这些传统的预测方法主要适用于处理线性问题。在 涉及一些非线性因素时,它们的预测准确性会开始下 降, 而机器学习方法的出现为太阳辐射预测打开了新的 大门。

依据来自澳大利亚5个站点的观测数据, 文献 [2] 里开发了一个调整模型,该模型考虑了纬度因素和散射 率。利用地表太阳总辐射的观测数据, 文献 [3-5] 为 印度亚热带地区构建了若干经验性模型,旨在计算该地 区月平均散射辐射量。文献[6]通过从30多台站的数 据中学习,开发了一种基于深度神经网络 (DNN) 模 型的太阳辐射预测模型。文献[7]将卷积层与多层感 知器 (MLP) 相结合开发了一种名为 ResnetTL 的太阳 辐射预测网络,该网络使用分辨率为16×16的MT-SAT 地球静止卫星图像进行训练。文献 [8] 将多机器 学习方法通过投资组合理论集成到一个新的预测模型 中,他们的测试结果表明,综合方法比单一机器学习方 法具有更高的太阳辐射预测精度。文献[9]通过进行 DNN、循环神经网络和 LSTM 的对比实验发现 RNN 和 LSTM 的性能比 DNN 强。文献「10] 基于 AlexNet 和 GoogLeNet 模型,增加了模型分解转换模块,该模块可 以对一维太阳辐射数据进行转换,并且以二维的数据形

式输入到模型中,增强了模型的预测性能。文献[11] 在他们的研究中引入了一种基于 ESN 的深度学习模型, 被称为 MR-ESN。他们的研究结果表明, MR-ESN 在 太阳辐射预测方面表现明显优于传统的 ESN 模型。文 献[12]研究团队提出了一种混合深度神经网络,将离 散小波分解(WPD)与卷积神经网络(CNN)、长短时 记忆网络(LSTM)以及多层感知机(MLP)相融合, 他们将这个新模型命名为 WPD-CNN-LSTM-MLP,并 对其性能进行了与其他单一神经网络模型的比较,最后 证明了其在太阳能辐射预测建议中的有效性。

文献「13]开发了7个广义经验模型来估计漫射太 阳辐射。他们得出的结论是,这7个特征的相关性是印 度的广义方程,并且能够估计任何印度站点的水平表面 上的月平均日漫反射辐照度。文献「14]提出了一种多 位置模型来估计太阳辐射水平日漫反射分量的预期分 布。他们得出结论,所提出的方法优于文献中提出的其 他模型,适用于特定地理区域。文献[15]分析了阿根 廷3个主要可再生资源(风能、太阳能和生物质)制氢 的潜力,并创建了一个可再生氢的新地理信息系统 (GIS)。他们的结果设想了阿根廷未来氢经济的最佳场 景。文献[16]回顾了太阳辐射模型,用于从全局辐射 预测每小时扩散分数。他们得出的结论是,在未来的工 作中应该利用 Bolande Ridleye Lauret (BRL) 模型的重 新校准和新预测器的开发,以增强更适合研究区域的新 模型的鲁棒性。文献〔17〕建立了一些新的经验模型, 用于预测土耳其典型城市水平表面上的月平均漫射太阳 辐射。结果表明,基于日照持续时间和清晰度指数的三 阶多项式模型可以获得最佳性能。文献 [18] 建立了一 个新的三阶多项式模型来预测水平表面上的全局太阳辐 射。他们得出的结论是,所提出的模型对于预测太阳辐 射以产生制氢电力是非常有效的。文献[19]使用 10 个统计定量指标评估和比较不同的漫射太阳模型。他们 的结果通过泰勒图直观地呈现,这清楚地说明了特定模 型对测量数据的接近程度。文献[20]使用基于清晰度 指数的经验模型预测水平漫反射太阳辐射。他们得出结 论,将这些基于清晰度指数的模型用于任何太阳能系统 应用,特别是太阳能制氢,都十分有效;鉴于清晰度指 数的知识只需要全球太阳辐射数据。文献「21〕讨论了 在 Sahara 区域生成太阳能氢的可能性。他们得出结论, 不同位置的制氢比例最高,因太阳辐射而异。

虽然深度神经网络在许多领域中被广泛应用且表现 出色,但它们也伴随着一些常见的问题,如容易过度拟 合、准确度较低、鲁棒性差以及陷入局部最小值等。本 文提出了 HPO-LSTM-Attention 模型,可用于更精确地 解决太阳辐射散射预测问题。这一模型结合了 LSTM 的时间序列建模能力,注意力机制的数据处理能力,以 及 HPO 算法的全局和局部搜索能力。通过这种结合, 可以克服传统深度神经网络的局限性,提高模型的性能。为未来研究和发展更有效的太阳散射辐射预测方法 提供了有力的基础。

1 模型结构

1.1 LSTM 网络层

LSTM 最初的设计目的是应对所谓的梯度消失和 梯度爆炸问题,因此当涉及到处理长时间序列时, LSTM 表现出了卓越的性能。LSTM 引入了门控机制, 包括遗忘门、输入门和输出门。这些门控制着信息的保 留、输入和输出。通常情况下,LSTM 在需要处理长期 依赖性的任务中表现更出色。LSTM 的网络结构如图 1 所示。在 LSTM 的训练过程中,关键的操作是由这些 门控制,以确保梯度能够合理地传播,这一结构和机制 使 LSTM 成为一种强大的工具,其运行机理用数学模 型解释如公式 (1) ~ (5):

$$f_{t} = \varepsilon(g_{f}[h_{t-1}, x_{t}] + b_{f})$$
(1)

$$i_t = \varepsilon(g_i [h_{t-1}, x_t] + b_i) \tag{2}$$

$$o_t = \varepsilon(g_{\varepsilon}[h_{t-1}, x_t] + b_f) \tag{3}$$

$$c_{t} = f_{t}c_{t-1} + i_{t} \tanh(g_{0}[h_{t-1}, x_{t}] + b_{c})$$
(4)

$$h_t = o_t \tanh(c_t) \tag{5}$$

激活函数用符号 ε、tanh 表示,遗忘门的输出为 f, 输入门的输出为 it,输出门的输出为 α,当前时刻 t 的 神经单元状态为 ct,t 时间步下的 LSTM 记忆单元的输 出为 ht。此外,gf 代表遗忘门的权重,gi、gc 代表输入 门的权重,go 代表从单元到输出门的权重,xt 表示当前 t 时刻的输入,bf 表示隐藏层遗忘门的偏差值,bi 表示隐 藏层输入门的参数,bc 表示隐藏层记忆单元的偏差值。



图 1 LSTM 网络结构

长短期记忆网络改进了隐藏层的结构,将神经元改 为存储单元,可以记忆长期记忆,在存储单元中加入门 控单元(遗忘门、输入门和输出门),遗忘门控制输入 数据质量,输入门控制存储单元细胞状态,不会无差别 输入和存储所有信息,输出门决定了隐藏层的最终输出 数据,从而解决了循环神经网络梯度消失问题,被广泛 应用于长期时间序列预测问题中。

1.2 注意力机制层

注意力机制可以强化模型对于主要数据特征的处理,通过权重分配让模型减少对无关信息的注意力。注意力机制的权重计算过程如公式(6)~(9)所示:

$$e_t = \tanh(wh_t + b) \tag{6}$$

$$a_t = \operatorname{softmax}(e_t) \tag{7}$$

$$Y = \sum_{t=1}^{n} a_t h_t \tag{8}$$

其中: ht 是注意力机制的输入, et 和 ht 是注意力机制的权重, w 和 b 是权重的训练值和偏置系数, at 是经过权重归一化后的权重值,最后经过注意力机制计算后输出 Y。

引入注意力机制旨在实现在 LSTM 中更高效地分 配资源,使模型能够更智能地关注关键信息。通常的操 作流程包括以下步骤:首先,确认输入序列信息;然 后,通过计算注意力分布权重,模型能够确定序列中不 同部分的重要性;最后,使用权重信息将各部分的信息 进行加权平均,从而实现更智能的信息提取和预测。

图 2 展示了基于注意力机制的 LSTM 模型的工作 原理。通过模型处理一个预测序列的元素,计算每个元 素的"键"(key)的概率分布,并将这个分布应用于相 应元素的"值"(value)上,其中"键"和"值"是序 列中的元素。这样每个"键"获得了一个与之对应的权 重系数,通过对值进行加权求和,然后将其输入到 LSTM 网络中,用于时间序列预测。引入注意力机制使 得模型更精细地提取时间序列中的关键特征,实现了高 效信息优化和神经网络训练,从而显著提高了模型的性 能水平。



图 2 加入注意力机制的 LSTM 模型

1.3 HPO优化算法层

1.3.1 HPO优化算法原理

猎人猎物优化算法(HPO)^[22]是一种基于生物学启 发的优化算法,其中猎人代表搜索代理,猎物代表 目标。

HPO 算法利用了生物学中的猎杀行为的思想,通 过猎人和猎物之间的相互作用,以及根据平均位置的调 整,来实现全局和局部搜索的平衡。这种算法的性能和 适用性可能因应用领域和具体问题而异,HPO 算法的 更新机制如式(9)所示:

$$x_{i,j}(t+1) =$$

$$\begin{cases}
x_{i,j}(t) + 0.5[(2CZH_{\text{pos}(j)} - x_{i,j}(t)) - (2(1-C)Z\mu(j) - x_{i,j}(t))], R_5 < B \\
G_{\text{beg}(i)} + CZ\cos(2\pi R_1) \times (G_{\text{beg}(i)} - (t)), R
\end{cases}$$
(9)

其中: R₅ 是一个范围区间 [0,1] 的随机数; B 是 一个协调参数,设置为 0.1。当 R₅ 的值小于 B 时,代 理搜索点被认为是猎人的位置,开展猎人搜素机制。反 之,则认为代理搜索点是猎物的位置,开展猎物位置更 新机制。

1.3.2 正余弦搜索策略

基于正余弦的猎人猎物算法(SCHPO)^[23]是 HPO 算 法的一种变体。这个算法的灵感来自于 SCA 算法,特别 是在处理决策变量时的更新策略方面。我们使用了正余 弦模型的震荡特性,来影响猎物的行动方式。这一新策 略有助于保持猎物位置的多样性,从而提升了整个种群 内个体的搜索能力,同时减少了陷入局部最优解的风险。

SCHPO 算法的核心目标是提高多样性,帮助种群 更全面地搜索解空间,减少局部最优解的影响。这一改 进的算法可应用于各种优化问题,以提高优化的效率和 结果的质量。我们相信这一策略将在不同领域的优化问 题中发挥重要作用:

$$x_{i,j}(t+1) = \begin{cases} G_{\text{best}} + r_2 CZ \cos(2\pi R_4) \times \\ \mid G_{\text{best}} - (t) \mid , r_1 < 0.5 \\ G_{\text{best}} + r_2 CZ \sin(2\pi R_4) \times \\ \mid G_{\text{best}} - x_{i,j}(t) \mid , r_1 > 0.5 \end{cases}$$
(10)

1.3.3 基于自适应动态权重的改进

猎人猎物算法中的群体行为是单次迭代中个体更新 位置的主要方式之一,更新步长越大,算法的全局探索 能力越强;步长越小,算法的局部开发能力越强。从式 (10)可以看出,其步长大小主要受随机数 r₂的影响, 因此算法在更新权重行为阶段具有一定的盲目性。基于 正余弦猎人猎物算法引入一种在 [0,1]范围内非线性 递减的自适应权重来代替 r₂,平衡算法的全局探索性和 局部开发性,表达式如(11)所示:

$$m = \sqrt{\cos\left(\frac{\pi t}{T}\right) \cdot e^{a(t-T)}}$$
(11)

其中: *t* 表示当前迭代次数; *T* 表示最大迭代次数; *a* 为调节因子, 控制权重的上升速度。更新后如公式 (12) 所示:

$$x_{i,j}(t+1) = \begin{cases} G_{\text{best}} + mCZ\cos(2\pi R_4) \times \\ \mid G_{\text{best}} - (t) \mid , r_1 < 0.5 \\ G_{\text{best}} + mCZ\sin(2\pi R_4) \times \\ \mid G_{\text{best}} - x_{i,j}(t) \mid , r_1 > 0.5 \end{cases}$$
(12)

HPO-LSTM-Attention 模型构建与模型输入特 征选取

2.1 HPO-LSTM-Attention 模型构建

针对太阳辐射散射问题构建了一种名为 HPO-LSTM-Attention 的组合模型,该模型旨在优化 LSTM 神经网络的训练参数,以克服局部最优解问题。在 HPO-LSTM-Attention模型中,依赖于传统的 LSTM 结 构,还运用 HPO 算法来实时调整 LSTM 模型的参数, 以更好地适应不同的数据情境。HPO-LSTM-Attention 算法框架如图 3 所示。



图 3 LSTM-HPO-Attention 模型结构

HPO-LSTM-Attention 模型的结构框架包括3个主 要模块。HPO模块详细描述了猎人猎物优化算法的工 作流程,它致力于找到适应度函数的最大或最小值,以 不断改进模型的性能。LSTM-Attention模块提供了关 于长短时记忆神经网络和注意力机制的详细算法,这有 助于模型更细致地处理时间序列数据。数据模块则包含 了丰富的特征参数,以及历史太阳辐射散射数值,这为 模型提供了充足的输入信息。HPO-LSTM-Attention模 型进行太阳辐射散射预测的步骤如下:

1) 初始化 HPO-LSTM-Attention 模型参数。

2)初始化 HPO 算法的种群,其中包括 LSTM-Attention 神经网络的超参数,如迭代次数、学习率和隐 藏层节点数等,这些参数将在优化过程中不断调整。

3)进行 HPO-LSTM-Attention 模型的训练与测试, 其中初始化值作为历史最优值分配给 LSTM-Attention 模型。在模型的训练过程中,我们采用了均方根误差作 为适应度函数,用来度量实际输出值与期望输出值之间 的差异。这个适应度函数在每次测试和计算训练损失值 时都发挥了重要的作用。通过不断地优化模型,我们力 求降低这一均方根误差,以达到更准确的预测结果。这 个过程促使模型逐渐适应并学习数据的特征,从而提高 了模型的性能和可靠性。

4)通过精细地调整 HPO 参数并不断优化种群的 最佳解,得以确定 HPO-LSTM-Attention 模型的最佳预 测值。这一过程涉及寻找 HPO 优化模型的最小训练损 失值,从而最佳预测值。

2.2 数据分析与模型输入特征选取

数据集包含了浙江地区的光伏站地表太阳散射辐射 5 个关键维度的数据,其中包括太阳直射辐射、太阳散 射辐射、大气气压、温度、湿度。囊括了 2013 年至 2016 年的数据。数据的空间分辨率为 0.5°×0.5°,因 此所获得的太阳散射辐射数据在空间层面上的大小为 5 ×4,数据的时间分辨率为 1 小时。数据的 90%用于模 型训练的训练数据,其余 10%用作测试数据,用于评 估模型的预测性能。这部分数据被用于测试模型的预测 效果。为了方便处理,在训练之前需要对数据进行归一 化处理,训练完毕后再进行反归一化输出预测数据。通 过绘制九种核函数密度图可以更方便观察数据的分布情 况,如图 4 所示。



图 4 散射辐射数据核函数密度图

为了筛选有用的特征对已有数据集进行了特征相关 性分析。通过绘制热力图来确认各维度特征之间的皮尔 逊系数,正相关性系数表示两个特征呈正相关,而负相 关性系数则表示它们呈负相关。相关性系数接近正1表 明正相关性强,而接近负1则表明负相关性强。根据图 5 所示,直射太阳辐射和气温这两个维度的数据与太阳 辐射散射特征之间存在明显的高度相关性。因此将太阳 辐射直射、温度以及太阳辐射散射这3个参数作为深度 学习模型的输入,以更准确地考虑相关性特征,从而提 高模型的性能和预测精度。

2.3 模型训练参数

在 GPU 平台上部署基于 pytorch 1.8.0 深度学习平

						1.0
辐射散射	辐射散射	0.88	0.83	-0.058	-0. 37	- 0.8
						- 0.6
直射	0.88	直射	0.67	-0. 034	-0.32	- 0.4
气温	0.83	0.67	气温	-0.35	-0. 51	
						-0.2
气压	-0.058	-0.034	-0.35	气压	0.14	0. 4
						0.6
湿度	-0. 37	-0. 32	-0. 51	0.14	湿度	0. 8
l] 🗖 –1. 0
	辐射散射	直射	气温	气压	湿度	
图 5 特征相关性热力图						

台,建立由一个全连接输入层,一个最大池化层,3个 LSTM 层和3个 DropOut 层构成的隐藏层,一个输出层 构成的深度网络,网络涉及超参数5类,输入全连接层 的节点数、各 LSTM 层单元节点数、L1\L2 正则化参 数、Dropout 自动丢弃指数、梯度优化器 adam 的初始 参数、学习率为经过 HPO 优化算法后的最优参数值。 各超参数设置情况如表1所示。

表1 神经网络超参数设置情况

参数类型	节点数	激活函数	L1	L2	Dropout	优化器	
输入层	7	RELU		_	_	-	
Max Pooling	—	RELU		-	0.3	-	
LSTM1	32	Sigmoid	0.001	0.002	0.3	adam	
LSTM2	64	Sigmoid	0.001	0.001	0.5	adam	
LSTM3	64	Sigmoid	0.001	0.002	0.6	adam	
adam	lr=0.002,beta_1=0.9,beta_2=0.8, epsilon=1e						
	-08, schedule decay=0.004						

3 实验验证与分析

3.1 试验结果对比分析

为更好体现 HPO-LSTM-Attention 模型优化改进后 的效果,将本章构建的 HPO-LSTM-Attention 深度学习 模型与 LSTM 模型、BiLSTM 模型和 LSTM-HPO 模型 进行对比,所有模型均在相同数据集下进行实验验证。 因各个模型性能不尽相同所以本章将4种模型的在同一 实验条件下进行,为了便于比较将预测步长都设置为 100。实验结果如图 6 所示,改进后的 HPO-LSTM-Attention 模型优于其他模型。

3.2 评价指标

为了评估 HPO-LSTM-Attention 模型对太阳辐射散 射的预测能力,使用以下几个评价指标进行评估,其 中,N是测试样本数,和分别是时间*t*的预测值和真 值,Z是时间序列的平均值。MSE、MAE、MAPE 和 的值越小,意味着预测偏差越小,预测性能越好。通过



实验对比结果,如图7所示为改进后的HPO-LSTM-Attention模型的预测误差均小于其他的对比模型。



图 7 多模型 loss 对比

1) MAE-平均绝对误差:

$$MAE = \frac{1}{N} \sum_{t=1}^{N} |\hat{z}(t) - Z(t)|$$
(13)

2) MAPE-平均绝对百分比误差:

$$MAPE = \frac{1}{N} \sum_{t=1}^{N} \left| \frac{\hat{z}(t) - Z(t)}{Z(t)} \right| \cdot 100\%$$
(14)

3) MSE-均方根误差:

$$MSE = \frac{1}{N} \sum_{i=1}^{N} (\hat{Y}_i - Y_i)^2$$
(15)

4) R² 决定系数:

$$R^2 = 1 - rac{\sum\limits_{i=1}^{n}{(Y_i - \hat{Y}_i)^2}}{\sum\limits_{i=1}^{n}{(Y_i - ar{Y}_i)^2}}$$

HPO-LSTM-Attention 深度学习模型与 LSTM 模

型、BiLSTM 模型和 LSTM-HPO 模型的 MAE、 R^2 、 MSE和 MAPE 评价指标表 2 所示, HPO-LSTM-Attention的 MAE 值为 2.935,小于其他模型。从 MSE 来看,HPO-LSTM-Attention 深度学习模型与 LSTM 模 型、BiLSTM 模型和 LSTM-HPO 模型的 MSE 值相差 不明显,但是 HPO-LSTM-Attention 模型仍然是最低, 说明 HPO-LSTM-Attention 模型在一定程度上优于其他 模型。HPO-LSTM-Attention 的 MAPE 和 R^2 值均优于 其他 3 种深度学习模型,说明 HPO-LSTM-Attention 深 度学习模型预测结果的认可度高于 LSTM 模型、BiL-STM 模型和 HPO-LSTM 模型。

表 2 各模型评价指标对比

模型	MAE	MAPE/%	MSE	R^2
LSTM	5.642	1.66	0.264	0.84
HPO-LSTM	3.409	1.43	0.236	0.89
BiLSTM	3.212	1.52	0.221	0.88
HPO-LSTM-Attention	2.935	0.82	0.138	0.92

3.3 模型预测性能分析

3.3.1 短期预测性能分析

研究输入与输出之间最佳的数据结构配置是预测模型的一个核心问题。这一问题本质上牵涉到了必要的历史数据长度确定,旨在精确预测未来一段特定时间内的太阳散射辐射水平。为了评估 HPO-LSTM-Attention 的性能,对模型进行不同长度序列的输入进行训练,数据规模选择 8 小时、12 小时、16 小时和 24 小时。分析结果显示,对于 1 小时提前的预测,仅需使用 8 小时的历史数据,模型便能展现出高度的预测精确性。随着历史数据量的增加,损失函数、均方误差、二值化均方误差、准确度、精确度以及召回率的变化不大,表明增加更多历史数据对于提升预测性能并没有显著效果。因此,使用 HPO-LSTM-Attention 模型进行太阳散射辐射的 1 小时前预测,仅需 8 小时的历史数据即可实现高预测精度。

为了更进一步地对模型的预测效果进行测试,对一 天内任意3个时刻进行提前1小时的太阳散射辐射预 测,预测过程中使用8小时历史数据作为输入,真实值 和预测值的数据对比如图9所示。从图中的结果我们可 以看出,3个不同时刻的预测值与真实值数据的对比几 乎一致,差距非常小。说明使用 HPO-LSTM-Attention 的预测结果几乎和真值完全一致,这说明了本章所建立 的预测模型具备良好的有效性。

除此之外,对任意 3 天不同时刻进行提前 1 小时的 太阳散射辐射预测并且绘制这 3 次预测值和真实值的相 关性散点图,从而可以更直观地进行观察。如图 10 所 示,所有的数据点基本均稳定的分布在 y=x 附近,这



图 8 提前 1 小时预测评价参数

说明,本章建立的预测模型对于太阳散射辐射预测具非 常高的准确性。 3.3.2 长期预测性能分析

长期预测性能分析实验将输入历史数据增加到 36 小时。结果如图 11 所示,当输入数据量不超过 16 小时 时,增加历史数据量能够显著降低损失函数、均方差和 二值化均方差,同时提升准确率、精度和召回率,表明 在输入数据量小于 16 小时的情形下,扩大历史数据规 模可有效增强预测性能。然而,一旦输入数据量超过 16 小时,进一步增加历史数据量对损失函数的影响微 乎其微,均方差和二值化均方差趋于上升,准确率、精 度和召回率出现下降,这表明历史数据量超过 16 小时 时,进一步扩大输入规模对提升预测效果的边际效应递 减,甚至可能适得其反,并导致预测成本上升。因此, 针对 8 小时提前预测,采用 16 小时的历史数据作为输 入参数乃至关重要的最佳策略。

已经通过采用评估指标对神经网络模型的预测能 力进行了量化分析,为了深入理解模型的实际预测性 能,本研究随机选择了一组基于16小时历史数据输入 的预测结果,并将接下来6小时每小时的预测值与其 对应真实值进行了对比分析,具体表现如图12所示。 分析结果表明,随着预测时间的推移,预测值与实际



图 9 HPO-LSTM-Attention 模型同一天任意 3 个时刻真 1 实值与预测值对比结果(a)(b)(c)均为提前一小时预测



图 10 HPO-LSTM-Attention 模型任意任意 3 天不同时刻真实值与预测值对比结果(a)(b)(c)均为提前一小时预测





图 11 提前 6 小时预测评价参数

值之间的差距逐渐扩大。特别是在预测的前2到3小时内,预测值与真实值之间的偏差较小,几乎可以说 是高度吻合。

然而,超过3小时后,预测值与真实值之间的偏差 开始显著增加。这一现象说明,利用16小时的历史数 据输入,本研究采用的HPO-LSTM-Attention模型在短 期太阳散射辐射预测方面表现出色,尤其是在最初的2到3小时内,预测精度极高。但随着预测时间延长至3小时之后,虽然预测值的总体趋势仍与真实值保持一致,但预测精度有所下降,从而标志着3小时 为该模型短期预测能力的关键分界点。

3.3.3 鲁棒性分析

鲁棒性是衡量太阳散射辐射预测方法性能的一 个核心指标。通过在输入数据中添加1%至50%的不 同程度噪声来测试所构建的 HPO-LSTM-Attention 模型的鲁棒性,这些噪声遵从正态分布,以此来更 真实地模拟实际测量过程中可能出现的误差。通过 比较加入最高50%噪声水平之前和之后的太阳散射 辐射分布情况,我们观察到噪声的引入对太阳散射 辐射的分布产生了显著的影响,该影响在图13中得 到了直观的呈现。

通过实验,观察到随着噪声水平的升高,尤其 是当噪声比例达到 50%时,模型的预测准确性显著 下降,相比于无噪声环境下的表现,精度损失严重。 为了提高模型在太阳辐射时间序列预测任务中的可

靠性和准确性,未来将致力于开发具有更强鲁棒性的预 测模型,以更好地应对测量误差带来的挑战。

4 结束语

本研究旨在提高太阳辐射散射的预测准确度,通过 结合注意力机制和猎人猎物优化技术,使用长短时记忆



图 12 HPO-LSTM-Attention 模型提前 6 小时真实值与预测值对比结果



图 13 噪声分布对比

噪声	Loss	MSE	Accuracy	Precision	Recall
0	2. 418×10^{-1}	6.28 $\times 10^{-2}$	9. 424×10^{-1}	9. 212×10^{-1}	9.004 $\times 10^{-1}$
1 %	2.418 $\times 10^{-1}$	6.28 $\times 10^{-2}$	9.392 $\times 10^{-1}$	9.204 $ imes 10^{-1}$	8.902 $\times 10^{-1}$
5 %	2.418 $\times 10^{-1}$	6.28 $\times 10^{-2}$	9.348 $\times 10^{-1}$	9. 187×10^{-1}	8.793 $ imes$ 10 ⁻¹
10%	2.418 $\times 10^{-1}$	6.28 $\times 10^{-2}$	9. 302×10^{-1}	9.129 $\times 10^{-1}$	8.772 $\times 10^{-1}$
20 %	2.432×10^{-1}	6.55 $\times 10^{-2}$	9. 183×10^{-1}	9.014 $ imes 10^{-1}$	8.703 $ imes$ 10 ⁻¹
30 %	2.432 $\times 10^{-1}$	6.72 $\times 10^{-2}$	8.942 $\times 10^{-1}$	8.833 $ imes 10^{-1}$	8.622 $ imes$ 10 ⁻¹
50 %	2.46 $\times 10^{-1}$	6.8 $\times 10^{-2}$	8.554 $\times 10^{-1}$	8.453 $\times 10^{-1}$	8.405 $\times 10^{-1}$

表 3 不同噪声等级对太阳散射辐射预测性能的影响

神经网络(LSTM)模型。实验结果表明,HPO-LSTM-Attention模型在全局模型学习和预测精度方面明显优 于其他单一模型,但其鲁棒性较差,未来的研究可能会 构建一种鲁棒性较强的预测模型。

1)通过加入注意力机制使得 LSTM 模型可以更高效地分配资源,使模型能够更智能地关注关键信息,并 且在太阳辐射散射预测中展现出良好的性能。

2)提出非线性动态权重动态调整 HPO 参数并不 断优化种群的最佳解,我们得以确定 HPO-LSTM-Attention 模型的最佳预测值。这一过程涉及寻找 HPO 优 化模型的最小训练损失值,为我们提供了参数的最佳预 测值。这种精细的参数优化过程极大地提高了模型的性 能和预测准确性,为解决问题提供了坚实的基础。

3) HPO-LSTM-Attention 模型能够有效地学习全局 模型,与其他单一模型相比,在多个评价指标(MAE、 MAPE、R^e和 MSE)下表现更出色,相比没有改进的 模型其预测能力提升了接近 8%。

参考文献:

 [1] DORVLO A S S, JERVASE J A, Al-LAWATI A. Solar radiation estimation using artificial neural networks [J]. Applied Energy, 2002, 71 (4): 307 - 319.

- [2] SPENCER J W. A comparison of methods for estimating hourly diffuse solar radiation from global solar radiation
 [J]. Solar Energy, 1982, 29 (1): 19 - 32.
- [3] JAMIL B, AKHTAR N. Estimation of diffuse solar radiation in humid-subtropical climatic region of India: Comparison of diffuse fraction and diffusion coefficient models [J]. Energy, 2017, 131: 149-164.
- [4] JAMIL B, AKHTAR N. Comparative analysis of diffuse solar radiation models based on sky-clearness index and sunshine period for humid-subtropical climatic region of India: A case study [J]. Renewable and Sustainable Energy Reviews, 2017, 78: 329 - 355.
- [5] JAMIL B, AKHTAR N. Comparison of empirical models to estimate monthly mean diffuse solar radiation from measured data: Case study for humid-subtropical climatic region of India [J]. Renewable & Sustainable Energy Reviews, 2017, 77: 1326 - 1342.
- [6] KABA KM, SAR1 GU L M, AVC M, KAND1 RMAZ HM. Estimation of daily global solar radiation using deep learning model [J]. Energy 2018; 162: 126-35.
- [7] JIANG H, LU N, QIN J, et al. A deep learning algorithm to estimate hourly global solar radiation from geostationary satellite data [J]. Renew Sustain Energy Rev 2019; 114: 109327.

- [8] LIMA MAFB, CARVALHO PCM, FERN ANDEZ-RAMIREZ LM, et al. Improving solar forecasting using deep learning and Portfolio theory integration [J]. Energy 2020; 195: 117016.
- [9] CORREA-JULLIAN C, CARDENIL JM, DROGUETT EL, et al. Assessment of Deep Learning techniques for Prognosis of solar thermal systems [J]. Renew Energy 2020; 145: 2178 - 2191.
- [10] ACIKGOZ H. A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting [J]. Appl Energy 2022; 305: 117912.
- [11] LI Q, WU Z, LING R, et al. Multi-reservoir echo state computing for solar irradiance prediction: a fast yet efficient deep learning approach [J]. Appl Soft Comput 2020; 95: 106481.
- [12] HUANG X, LI Q, TAI Y, et al. Hybrid deep neural model for hourly solar irradiance forecasting [J]. Renew Energy 2021; 171: 1041-1060.
- [13] KARAKOTI I, DAS P K, SINGH S K. Predicting monthly mean daily diffuse radiation for India [J]. Applied Energy, 2012, 91 (1): 412-425.
- [14] BORTOLINI M, GAMBERI M, GRAZIANI A, et al. Multi-location model for the estimation of the horizontal daily diffuse fraction of solar radiation in Europe [J]. Energy Conversion and Management, 2013, 67: 208 - 216.
- [15] SIGAL A, LEIVA E P M, RODRÍGUEZ C R. Assessment of the potential for hydrogen production from renewable resources in Argentina [J]. International journal of hydrogen energy, 2014, 39 (16): 8204 - 8214.

- [16] MAGARREIRO C, BRITO M C, SOARES P M M. Assessment of diffuse radiation models for cloudy atmospheric conditions in the Azores region [J]. Solar Energy, 2014, 108: 538 - 547.
- [17] TAPAKIS R, MICHAELIDES S, CHARALAMBIDES A
 G. Computations of diffuse fraction of global irradiance: Part 1-Analytical modelling [J]. Solar Energy, 2016, 139: 711 - 722.
- [18] BAKIRCI K. Models for the estimation of diffuse solar radiation for typical cities in Turkey [J]. Energy, 2015, 82: 827 - 838.
- [19] YANIKTEPE B, GENC Y A. Establishing new model for predicting the global solar radiation on horizontal surface
 [J]. International Journal of Hydrogen Energy, 2015, 40 (44): 15278 - 15283.
- [20] DESPOTOVIC M, NEDIC V, DESPOTOVIC D, et al. Evaluation of empirical models for predicting monthly mean horizontal diffuse solar radiation [J]. Renewable and Sustainable Energy Reviews, 2016, 56: 246 - 260.
- [21] MOHAMED B, ALI B, AHMED B, et al. Study of hydrogen production by solar energy as tool of storing and utilization renewable energy for the desert areas [J]. international journal of hydrogen energy, 2016, 41 (45): 20788 - 20806.
- [22] NARUEI I, KEYNIA F, SABBAGH MOLAHOSSEINIA. Hunter-prey optimization: algorithm and applications[J]. SoftComputing, 2022, 26: 1279-1314.
- [23] 常耀华, 韦根原. 基于领导者竞争策略的改进猎人猎物 优化算法 [J]. 计算机应用研究, 2024, 41 (1): 142 -149.

(上接第 68 页)

- [12] DAI J, QI H, XIONG Y, et al. Deformable Convolutional Networks [J]. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017: 764 - 773.
- [13] NIU Z, ZHONG G, YU H. A review on the attention mechanism of deep learning [J]. Neurocomputing, 2021, 452: 48-62.
- [14] HU J, SHEN L, SUN G. Squeeze-and-Excitation Networks [J]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132-7141.
- [15] 李宗祐,等. 基于深度学习的金属材料表面缺陷检测综 述[J]. 材料工程,2023,42 (6):101-110
- [16] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C] //Proceedings of the Europe-

an conference on computer vision (ECCV). 2018: 3-19.

- [17] YU J, CHENG X, LI Q. Surface defect detection of steel strips based on anchor-free network with channel attention and bidirectional feature fusion [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 71: 1-10.
- [18] SUTSKEVER I, MARTENS J, DAHL G, et al. On the importance of initialization and momentum in deep learning [C] //International conference on machine learning. PM-LR, 2013: 1139 - 1147.
- [19] IHOR KONOVALENKO, SERGEY G. Basov. 基于 Res-Net 的钢材表面缺陷分类 [J]. 材料加工与检测, 2024, 42 (3): 96-102.
- [20] HASSABALLAH M, KENK M A, WUTTIG R,等. 钢 材表面缺陷检测的深度学习模型 [J]. 计算机应用与软 件, 2024, 42 (3): 125-132.