

基于 PSO-LSTM-Attention 的风光互补系统发电功率预测研究

常玲¹, 王博¹, 孟彬², 高钦¹, 李倩¹

(1. 辽宁石油化工大学 信息与控制工程学院, 辽宁 抚顺 113000; 2. 沈阳大学 环境学院, 辽宁 沈阳 110000)

摘要: 为充分利用某油田地区的太阳能和风力资源, 验证该地区施行风光互补发电系统的可行性, 提出了一种融合粒子群算法(Particle Swarm Optimization, PSO)、长短期记忆神经网络(Long Short-Term Memory, LSTM)与注意力机制(Attention Mechanism)的风光互补系统发电功率预测方法。该方法首先利用粒子群算法对模型的隐藏神经元个数和初始学习率进行优化, 获取最优参数并结合 LSTM 捕捉历史序列的相关性。在此基础上, 引入注意力机制, 通过权重分配聚焦关键时间步, 自动识别重要特征维度, 从而提高预测可靠性。结果表明: 本文所提 PSO-LSTM-Attention 模型可以有效捕捉数据的变化趋势, 在风光互补系统发电功率预测中该模型均方根误差 RMSE 值稳定在 0.235, 平均绝对误差 MAE 值为 0.145, 拟合优度 R^2 可达 0.943, 相比于 LSTM 和 LSTM-Attention 模型均有提升。

关键词: 风光互补发电; 粒子群算法; 长短期记忆; 注意力机制; 超参数

中图分类号: TM61 文献标识码: A DOI: 10.16146/j.cnki.rndlgc.2025.12.016

[引用本文格式] 常玲, 王博, 孟彬, 等. 基于 PSO-LSTM-Attention 的风光互补系统发电功率预测研究[J]. 热能动力工程, 2025, 40(12): 171-179. CHANG Ling, WANG Bo, MENG Bin, et al. Study on power generation prediction of wind-solar integrated system based on PSO-LSTM-attention[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(12): 171-179.

Study on Power Generation Prediction of Wind-Solar Integrated System based on PSO-LSTM-Attention

CHANG Ling¹, WANG Bo¹, MENG Bin², GAO Qin¹, LI Qian¹

(1. School of Information and Control Engineering, Liaoning Petrochemical University, Fushun, China, Post Code: 113000; 2. Faculty of the Environment, Shenyang University, Shenyang, China, Post Code: 110000)

Abstract: To fully utilize the solar and wind energy resources in a certain oilfield area and verify the feasibility of implementing a wind-solar complementary power generation system in this area, a power generation prediction method for the wind-solar complementary system was proposed, which combined particle swarm optimization (PSO) and Long Short-Term Memory (LSTM) neural network with attention mechanism (AM). The PSO algorithm was introduced to optimize the number of hidden neurons and the initial learning rate of the model, obtaining the optimal parameters and combining LSTM to capture the correlation of historical sequences. Based on this, the AM was introduced to focus on key time steps through weight distribution and automatically identify important feature dimensions, thereby improving the prediction reliability. The results show that the proposed PSO-LSTM-attention model effectively captures the changing trends of data. In the wind-solar complementary power generation prediction, the root mean

收稿日期: 2025-05-13; 修订日期: 2025-07-18

基金项目: 辽宁省教育厅基本科研项目(JYTS20231450, LJ212510148022); 辽宁石油化工大学科学研究基金(2023XJJL-009)

Fund-supported Project: Basic Research Project of Liaoning Provincial Department of Education (JYTS20231450, LJ212510148022); Scientific Research Foundation of Liaoning Petrochemical University (2023XJJL-009)

作者简介: 常玲(1982-), 女, 辽宁石油化工大学教授。

通信作者: 王博(1999-), 男, 辽宁石油化工大学硕士研究生。

square error (RMSE) value of model is stable at 0.235, the mean absolute error (MAE) value is 0.145, and the goodness of fit R^2 can reach 0.943, which are all improvements compared to that of LSTM and LSTM-attention models.

Key words: complementary wind and solar power generation, particle swarm optimization (PSO), long short-term memory (LSTM), attention mechanism, hyperparameter

引 言

随着全球对可再生能源重视程度的提高,风能和太阳能因具有清洁、可再生的特性,成为新时代能源发展的重要方向。然而,由于风能与太阳能具有间歇性、波动性及难预测性等特点,给新型综合能源系统的健康稳定运行造成了很大困扰^[1-5]。因此,对系统中风力和光伏的发电量准确预测,有助于综合能源系统获取更大的收益以及更稳定的运行。

国内外众多学者针对发电量预测开展研究。王登海等人^[6]和王晨阳等人^[7]通过结合卷积神经网络和长短期记忆混合(Convolutional Neural Networks-Long Short-Term Memory, CNN-LSTM)模型进行光伏发电量预测,前者利用模型捕捉时空特征,以应对天气突变对发电量预测精度造成的影响,后者使用基于遗传算法的预测模型进行优化,两者均在一定程度上提高了所提模型的预测精度。方鹏等人^[8]创新性地融合模糊聚类算法(FCMA)与 LSTM 神经网络,构建了面向中长期辐射照度的混合预测框架,该研究通过 FCMA 算法提取辐照度时序特征,结合随机森林进行特征优化,并利用 LSTM 捕捉长周期时序关联特性,最终建立分布式光伏电站出力预测模型。实验表明,其预测精度较单模型有较大提升,有效攻克了传统预测中长周期时序依赖的技术瓶颈。代倩等人^[9]结合自组织特征映射(Self-Organizing Feature Map, SOM)天气聚类与 BP 神经网络,解决太阳辐照度数据不足问题,使预测误差降低 40%。潘东等人^[10]通过量子 LSTM 联合双重注意力机制降低参数冗余,提高了光伏发电预测精度。王俊杰等人^[11]通过多特征融合,并结合 XGBoost-LightGBM-ConvLSTM (XGB-LG-CL)模型,减少梯度问题,预测率达到了 88.4%。

相对于光伏发电,近年来针对风力发电功率预

测算法方面的研究呈现多样化。唱友义等人^[12]针对风电的季节性波动和短时平稳变化特征,开发了月度发电数据集的扩展方法,结合中期气象预报信息精度前高后低的特点,构建了融合 kdtree 单元匹配机制、数据增强策略和时间序列分析的三维预测模型,并通过熵权法实现多算法的组合优化。冯乐^[13]从风光互补的时空关联特征切入,系统探讨了风光功率时空交互关系、联合预测模型架构、参数优化策略及预调度协同机制,创新性地设计了基于异构图神经网络的联合预测框架,为风光协同发电系统的智能调度提供理论依据。李俊^[14]构建了风机功率特性曲线模型,并进行了多环境参数下的实测对比,发现了风速湍流强度、大气密度和温度梯度等环境参数对风力发电效率的影响规律。张宇^[15]创新性地将数值气象预报(Numerical Weather Prediction, NWP)的多分辨率数据整合技术引入风电预测,采用插值分析与聚类算法相结合的方式建立多维时序特征提取模型,并引入注意力机制改进的 Seq2Seq 深度学习架构进行模型验证,实证结果显示,该多元聚类算法较大提升了预测精度。

目前,对单一能源的发电量预测方法已经相对成熟,但对风光互补发电系统发电功率预测方法的研究相对较少。基于上述分析,本文主要贡献如下:提出利用粒子群优化算法对 LSTM 的超参数进行优化;通过引入注意力机制,实现权重分配聚焦关键时间步,弥补了单一 LSTM 模型平等对待所有历史时间导致预测精度低的缺点;通过引入 4 项评价指标直观展示了 PSO-LSTM-Attention 模型的预测性能;风光互补发电系统通过整合区域风能与太阳能资源,可降低单一能源对电力系统的影响,使风力、光伏的预测误差被抵消。尤其在多元气象条件协同作用下,该机制可优化 PSO-LSTM-Attention 预测模型的泛化能力,从而提高预测精度。

1 预测模型设计

预测模型以 LSTM 算法为核心,利用 PSO 对其初始学习率等超参数进行寻优,并引入 Attention 机制以增强特征提取,从而共同提高模型的预测精度。

1.1 长短期记忆神经网络

作为一种特殊的循环神经网络,LSTM 能在一定程度上弥补 RNN 的不足:解决 RNN 误差在时间步上的反向传播,对长时间序列更为敏感,支持多变量输入输出;其独特的层控机制可筛选无关信息,极大增强模型的稳定性^[16],LSTM 结构如图 1 所示。图中, X 表示输入向量, Y 表示输出向量, h 表示隐含层状态值, C 表示细胞层状态值, $t-1, t$ 和 $t+1$ 分别表示 $t-1, t$ 和 $t+1$ 时刻。




图 1 LSTM 结构图

Fig. 1 LSTM structure diagram

LSTM 的核心在于其内部具有 4 个交互层,分别为输入层、遗忘层、细胞层、输出层。4 个交互层之间以一种特殊的方式进行交互并形成逻辑闭环:遗忘层与输入层共同调控记忆更新,细胞状态执行整合,输出门控制信息释放,使得 LSTM 可以存储和访问长序列中的信息^[17-18]。

然而,LSTM 独特的层控机制也导致其训练和预测速度慢于循环神经网络。此外,LSTM 对初始学习率、隐藏层大小、初始化等超参数高度敏感,超参数的选取极大地影响模型对时间序列的预测精度,因此采用合适的超参数优化算法,可使 LSTM 的准确性和计算速度得到改善。

1.2 PSO 算法

粒子群优化算法是一种基于鸟群觅食行为的启发式搜索算法,其通过群体协作在解空间寻找全局最优解^[19-22]。

迭代前,粒子的生成具有随机性并配置参数。其中每个粒子记录自身历史最优位置(即个体极值),用于指导后续搜索方向。迭代阶段,每个粒子为了完成自身速度和位置的更新,而去追踪个体极值点和全局极值点。用 n 维向量表示粒子 i 的信息,位置为 $L_i = (l_{i,1}, l_{i,2}, \dots, l_{i,n})$,速度为 $V_i = (v_{i,1}, v_{i,2}, \dots, v_{i,n})$,方程表示为:

$$v_{i,n}^{k+1} = \omega \cdot v_{i,n}^k + c_1 \cdot \text{rand}_1^k(p_{i,n}^k - l_{i,n}^k) + c_2 \cdot \text{rand}_1^k(g_{i,n}^k - l_{i,n}^k) \quad (1)$$

$$l_{i,n}^{k+1} = l_{i,n}^k + v_{i,n}^{k+1} \quad (2)$$

式中: $v_{i,n}^k$ —在第 n 维度中迭代时,第 i 个粒子在第 k 次的速度; ω —惯性权重; c_1, c_2 —学习因子,旨在改变粒子变化的步长; rand — $[1, 2]$ 范围内的随机数,实现粒子搜索和寻优行为的动态平衡; $p_{i,n}^k$ 和 $g_{i,n}^k$ —在第 n 维度中,第 i 个粒子在第 k 次迭代中的粒子最佳位置和群体最佳位置; $l_{i,n}^k$ —第 n 维度中,第 i 个粒子在第 k 次迭代中的位置。

粒子根据个体极值和全局极值来改变自身的搜索速度和方向^[23-26]。通过对给定超参数空间的搜索,不仅减少人工试错,显著降低超参数的调整时间,还可以避免出现局部最优,找到最优的超参数组合。整个过程中,粒子的优劣需引入特定函数来进行抉择,例如适应度函数,从而更好地改变粒子的速度和位置等参数。

LSTM 在短时间序列、少变量等简单场景中可能具有良好的先进性,但在长序列、多变量等复杂现实环境中可能表现不佳。

1.3 注意力机制

注意力(Attention)机制灵感来源于人类视觉的信息处理机制,视觉系统在整体环境中找到焦点区域给予更多关注^[27-30],同时抑制无用信息的获取。Attention 机制能弥补 LSTM 在长时间序列中的不足,通过动态分配权重,捕捉影响模型预测精度的关键信息,避免 LSTM 因时间序列过长而引起预测性能下降。

注意力机制与 LSTM 结合的工作流程分为两步:特征匹配阶段,通过计算 Attention 机制相似度函数使输出权重标准化,从而得到变量及权重;特征增强阶段,依据注意力权重对变量进行加权相加,得到新的

输出向量,以此突出关键特征,抑制噪声干扰。注意力机制与 LSTM 结合原理如图 2 所示。图中 $a_t(t=1,2,3,\cdots)$ 表示输入与输出状态之间的权重比,反映其对当前输出的影响; h_t 为某个特定时间步前一刻的隐藏状态; c 为加权后输出的新向量。




图 2 LSTM 与 Attention 机制结合原理图

Fig.2 Schematic diagram of LSTM combined with attention mechanism

序列片段的权重占比取决于相似度的计算,二者呈正相关。注意力机制会自动忽略差异性较大的序列,从而降低对模型的不良影响,实现降低计算成本,提高学习效率和准确性^[30]。注意力机制公式为:

$$a_t = \frac{\exp[s(h_t, \bar{h}_s)]}{\sum_{i=1}^n \exp[s(h_i, \bar{h}_s)]} \tag{3}$$

$$s(h_t, h_s) = h_t^T h_s \tag{4}$$

$$c = \sum_{i=1}^n a_i h_i \tag{5}$$

式中: $s(\cdot)$ —两输入变量之间的相似度计算; h_s —源端隐藏状态; \bar{h}_s —某个特定时间步的隐藏状态; h_t^T — h_t 的转置矩阵; h_i —隐向量,包含整个输入序列的信息,但重点关注第 j 变量周围的部分; a_i —对应隐向量的权重。

1.4 PSO-LSTM-Attention 神经网络发电功率预测模型

LSTM 可以很好地解决神经网络中长期依赖问题,但在训练过程中仍要面临如何选择网络结构和最优参数的问题,而依赖经验或使用网格搜索法对训练效果影响较大。PSO 优化算法能模拟群体智能搜索,通过粒子位置更新策略,在指定的参数空间寻

求全局最优解,以寻找最优参数并提高算法的收敛速度。在多变量时间序列中,不同特征对预测结果的影响程度不同,引入注意力机制可实现权重再分配,进而增强序列非平稳性特征的提取能力,使模型能够更精确地捕捉影响发电量预测的敏感信息,从而提高预测性能。

本文 PSO-LSTM-Attention 模型通过分阶段耦合设计提高模型精度:首先采用 PSO 算法优化 LSTM 的超参数,以均方误差损失函数(MSE)为适应度函数,提升模型泛化能力;随后,采用 Attention 机制增强特征提取,通过给予关键变量更大权重,使模型能更准确地捕捉影响发电量预测精度的数据特征。PSD-LSTM-Attention 模型结构如图 3 所示。



图 3 PSO-LSTM-Attention 模型结构图

Fig.3 Structural diagram of PSO-LSTM-attention model

PSO-LSTM-Attention 预测模型在提升精度方面具有优化和部署优势。参数的自动优化极大缩短了寻优时间,减少了冗余计算。此外,模型采用的阶段性融合架构首次将 PSO 算法的全局优化、LSTM 的时序建模以及注意力机制的特征选取进行集成,在一定程度上解决了复杂时序中“优化 - 建模 - 聚焦”的耦合问题,具有一定的先进性。

PSO-LSTM-Attention 模型的具体预测流程如图 4 所示。具体步骤为:

- (1) 采用 PSO 算法对需要优化的参数进行编码;
- (2) 定义用于评估粒子性能的适应度函数;
- (3) 初始化种群个体位置和速度;
- (4) PSO 算法搜索全局最优解和个体最优解;
- (5) 检查是否达到最大迭代次数。如果否,则继续搜索。如果是,则进入下一步;
- (6) 输出通过 PSO 算法找到的最优参数;
- (7) 创建含注意力机制的长短期记忆神经网络 LSTM-Attention 模型;

- (8) 获取最优隐藏神经元个数和初始学习率;
(9) 建立 PSO-LSTM-Attention 预测模型并使用数据集训练;
(10) 输出模型的迭代和发电量预测曲线;
(11) 评估模型预测结果的性能。

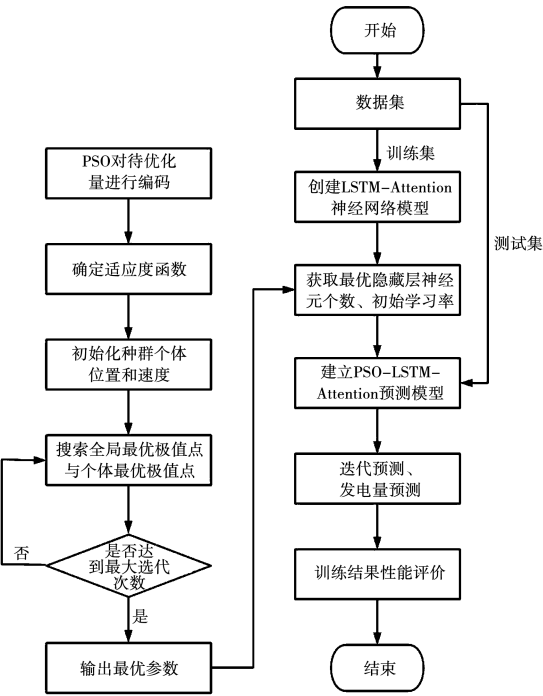


图 4 PSO-LSTM-Attention 模型发电功率预测流程
Fig.4 PSO-LSTM-attention model generation power prediction process

2 实验分析

实验采用 MSE 损失函数度量了样本点在特征空间中到回归曲面的垂直距离,通过最小化这些距离的平方和,模型可寻找到一个最优超平面,使得所有样本点与该平面的偏差最小,从而确保模型对数据分布的良好拟合。MSE 的值越小,表示预测模型描述的样本数据的精确度越高。

为了验证模型的预测性能,选取平均绝对误差 (MAE)、均方误差 (MSE)、均方根误差 (RMSE) 和决定系数 (R^2) 作为评价指标,计算公式如下。

$$MAE = \frac{1}{m} \sum_{i=1}^m (|y_i - f(x_i)|)$$

(6)

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - f(x_i))^2$$

(7)

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - f(x_i))^2}$$

(8)

$$R^2 = 1 - \frac{MSE(y_i, f(x_i))}{\frac{1}{m} \sum_{i=1}^m (y_i - y_i)^2}$$

(9)

式中: y_i —当时的标准化实际观察值; x_i —输入变量;
 y_i —平均值; m —样本容量。

本文采用 Python 程序搭建 PSO-LSTM-Attention 模型,并以河北省唐山市某油田地区真实历史数据为实验数据。在实验参数的选取上,参数过多可能会导致实验结果误差变大,而参数过少则会导致提供的信息不足,难以提取数据特征。为此,本文选取了风速、瞬时风向、温度、太阳辐射强度和发电功率五维输入参数对典型日 24 h 的发电量进行了预测。

2.1 实验参数设置

为验证 PSO-LSTM-Attention 模型对风光互补发电系统发电功率的预测性能,对 24 h 内的 100 份发电量数据进行训练和分析。在保持数据集相同、参数设置一致的前提下,将 LSTM、LSTM-Attention 和 PSO-LSTM-Attention 3 种模型的预测效果进行对比分析。搭建的 LSTM-Attention 模型经 PSO 算法优化后获取最佳超参数,最终获得的最优学习率为 0.012,最优的隐藏层神经元个数为 20。表 1 为 PSO-LSTM-Attention 模型参数。

表 1 PSO-LSTM-Attention 模型参数
Tab.1 PSO-LSTM-attention model parameters

参 数	数 值
粒子群规模	10
PSO 迭代次数	100
惯性权重	0.9
个体学习因子	1.5
LSTM 最大训练回合数	100
输入维度	5
输出维度	1
学习率范围	(0.0001,0.1)
隐藏层范围	(10,100)

2.2 发电量预测分析

通过对数据集进行训练,得到 3 种不同模型对

风光互补发电系统发电功率的预测情况,结果如图 5 所示。

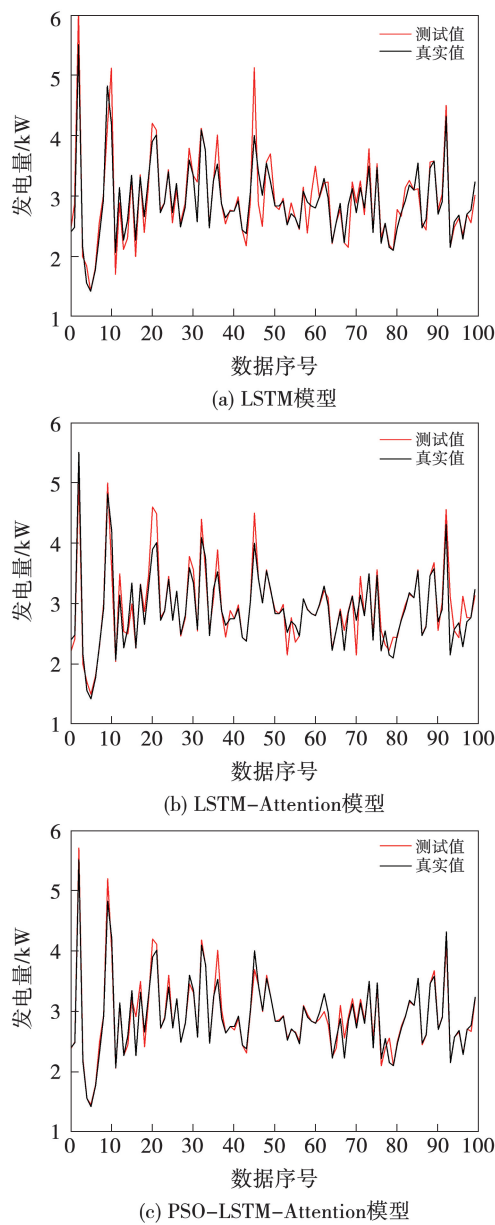


图 5 3 种模型风光互补发电系统发电功率的预测结果
Fig. 5 Prediction results of power generation capacity
of wind-solar hybrid power generation
systems among three models

由图 5(a)可知,单一的 LSTM 模型预测表现相对较差,在关键时间步上存在较大预测误差。为减少此类型误差,引入注意力机制通过权重分配聚焦关键时间步。由图 5(b)可知,引入注意力机制的 LSTM 模型在拟合程度上有了较大提升,表明模型能够更准更快地抓取数据的特征信息。由图 5(c)可

知,通过粒子群算法对部分超参数进行寻优,再融合注意力机制识别重要特征维度,拟合效果相较单一 LSTM 模型和 LSTM-Attention 模型有了极大改善。

3 种模型的损失函数迭代情况如图 6 所示。从图 6 可以看出,3 种模型的损失函数均能在 50 次迭代次数内下降并达到稳定,说明模型是理性且稳定的。另外,从走势情况上可以看出,PSO-LSTM-Attention 模型损失函数的下降速度更快,一定程度上说明经过寻优以及添加注意力机制后,模型可以更快更准地抓取数据特征的有效信息。

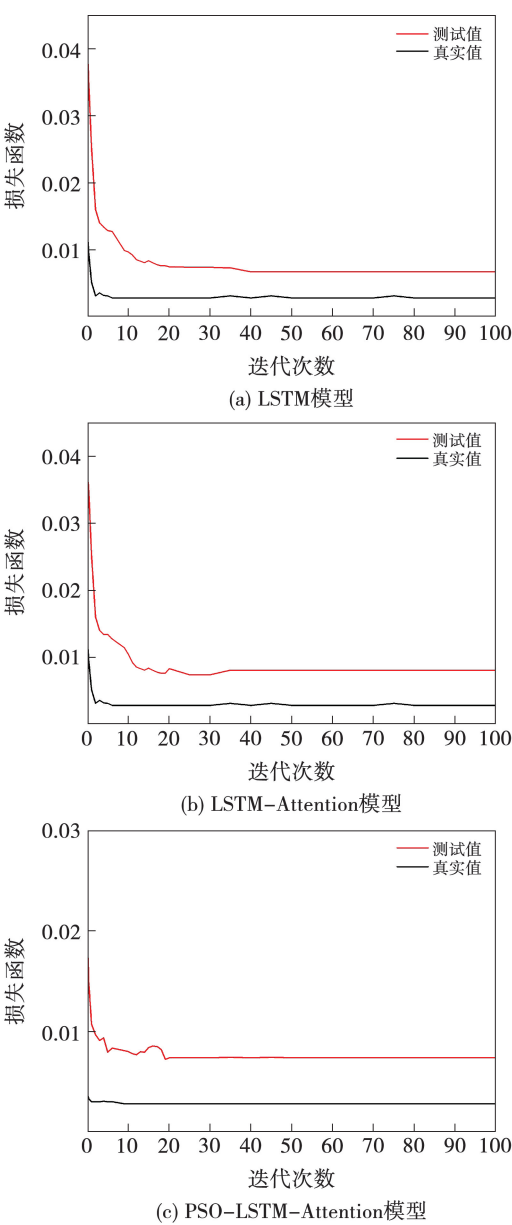


图 6 3 种模型损失函数迭代对比
Fig. 6 Iterative comparison of loss functions
among three models

2.3 模型评价对比

对 3 种模型进行训练,并通过 MAE、MSE、RMSE 和 R^2 评估指标来衡量模型的预测性能,结果如表 2 所示。这 4 项指标共同反映了模型在发电量预测方面的准确性和可靠性。由表 2 可知,PSO-LSTM-Attention 模型的 MAE 值和 MSE 值最小,表明本文模型在发电功率预测精度和拟合程度方面有较好的表现。另外, RMSE 可以反映平均误差,本文提出 PSO-LSTM-Attention 模型的 RMSE 值为 0.235,相比于 LSTM 和 LSTM-Attention 模型均有所降低,说明本文模型误差较小。拟合优度 R^2 同样可以直观展示预测结果拟合实际值的程度, PSO-LSTM-Attention 模型中 R^2 约为 0.943,为 3 种模型中的最大值。但 3 种模型的 R^2 值均达到 0.75 以上,表明这些模型都可以在一定程度上对发电功率进行预测,而 PSO-LSTM-Attention 模型表现更好,预测能力和准确性更高。

表 2 模型评价指标对照表

模 型	MAE	MSE	RMSE	R^2
LSTM	0.435	0.423	0.650	0.756
LSTM-Attention	0.286	0.189	0.435	0.867
PSO-LSTM-Attention	0.145	0.055	0.235	0.943

为进一步验证本文模型的先进性,选取 5 种模型与 PSO-LSTM-Attention 模型的评估指标进行对比,结果如表 3 所示。由表 3 可知,本文所提 PSO-LSTM-Attention 模型的精度整体优于其他模型,直观地表明本文所提模型的先进性。

表 3 不同改进模型评价指标对照表

Tab.3 Comparison table of evaluation indicators for different improvement models				
模 型	MAE	MSE	RMSE	R^2
CNN-LSTM ^[6]	—	0.523	0.723	0.921
GA-CNN-LSTM ^[7]	0.212	0.585	0.612	—
DA-QLSTM ^[10]	—	0.120	0.347	0.918
XGBoost-LightGBM-ConvLSTM ^[11]	—	—	0.131	0.884
改进 PSO-LSTM ^[31]	0.260	—	0.172	0.979
PSO-LSTM-Attention	0.145	0.055	0.235	0.943

注:表中“—”表示无数据。

3 结 论

本文对比研究了 LSTM、LSTM-Attention 和 PSO-LSTM-Attention 3 种模型在发电功率预测方面的性能,所得结论如下:

- (1) PSO-LSTM-Attention 模型利用粒子群算法对部分超参数进行寻优,加速了算法的收敛过程,实现了超参数的最佳配置。
- (2) 通过融合注意力机制实现了权重分配聚焦关键时间步,弥补了单一 LSTM 模型对所有历史时间平等对待而导致预测精度低的缺点。
- (3) 粒子群算法和注意力机制的双重作用,一方面优化了模型超参数,另一方面精确捕捉了影响结果的关键特征,从而提高了预测准确性。
- (4) 实验所得预测结果表明,基于 PSO-LSTM-Attention 预测模型的 MSE 值为 0.055,MAE 值为 0.145, RMSE 值为 0.235,决定系数 R^2 提高到 0.943,各项评价指标均优于 LSTM、LSTM-Attention 模型,预测效果更好。

参考文献:

[1] 程临燕,冯艳虹,徐 林. 基于风光互补出力特性的可消纳容量研究[J]. 中国电力,2019,52(7):63-68.
CHENG Linyan, FENG Yanhong, XU Lin. Consumptive capacity research based on wind-solar hybrid characteristics [J]. Electric Power,2019,52(7):63-68.

[2] 步天龙,寇汉鹏,张大沛,等. 考虑风光发展趋势与碳排放评估的多能源系统优化运行模型[J]. 可再生能源,2025,43(2):260-267.
BU Tianlong, KOU Hanpeng, ZHANG Dapai, et al. Optimization operation model of multi-energy system considering wind power and PV development trend and carbon emission assessment [J]. Renewable Energy Resources,2025,43(2):260-267.

[3] 刘 风,马铁驹. 风光电力消纳机制与方案研究现状及前沿展望[J]. 中国管理科学,2025,33(1):247-258.
LIU Feng, MA Tieju. Review and frontier prospect of the researches on the mechanisms and strategies of wind and solar power consumption [J]. Chinese Journal of Management Science, 2025, 33(1):247-258.

[4] 樊晓伟,王瑞妙,朱小军,等. 考虑风光荷时序波动特性的配电网投资策略多目标优化[J]. 可再生能源,2023,41(2):268-76. DOI:10.13941/j.cnki.21-1469/tk.2023.02.006.

- FAN Xiaowei, WANG Ruimiao, ZHU Xiaojun, et al. Multi-objective optimization of distribution network investment strategy considering the time series fluctuation of wind power generation, photovoltaic power generation and power load [J]. Renewable Energy, 2023, 41(2): 268 – 276. DOI: 10.13941/j.cnki.21-1469/tk.2023.02.006.
- [5] 翁 詠. 风光互补发电系统能量预测及储能调度研究[D]. 扬州: 扬州大学, 2021.
- WENG He. Research on energy forecasting and energy storage dispatching of wind-solar hybrid power generation system[D]. Yangzhou: Yangzhou University, 2021.
- [6] 王登海, 安玥馨, 廖晨博, 等. 基于 CNN-LSTM 混合神经网络的光伏发电量预测方法研究[J]. 西安石油大学学报(自然科学版), 2024, 39(1): 129 – 134.
- WANG Denghai, AN Yuexin, LIAO Chenbo, et al. Research on photovoltaic power generation prediction method based on CNN-LSTM hybrid neural network[J]. Journal of Xi'an Shiyou University (Natural Science Edition), 2024, 39(1): 129 – 134.
- [7] 王晨阳, 段倩倩, 周 凯, 等. 基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测[J]. 物理学报, 2020, 69(10): 51 – 57.
- WANG Chenyang, DUAN Qianqian, ZHOU Kai, et al. A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm[J]. Acta Physica Sinica, 2020, 69(10): 51 – 57.
- [8] 方 鹏, 高亚栋, 潘国兵, 等. 基于 LSTM 神经网络的中长期光伏电站发电量预测方法研究[J]. 可再生能源, 2022, 40(1): 48 – 54.
- FANG Peng, GAO Yadong, PAN Guobing, et al. Research on forecasting method of mid- and long-term photovoltaic power generation based on LSTM neural network[J]. Renewable Energy Resources, 2022, 40(1): 48 – 54.
- [9] 代 倩, 段善旭, 蔡 涛, 等. 基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究[J]. 中国电机工程学报, 2011, 31(34): 28 – 35.
- DAI Qian, DUAN Shanxu, CAI Tao, et al. Short-term PV generation system forecasting model without irradiation based on weather type clustering[J]. Proceedings of the CSEE, 2011, 31(34): 28 – 35.
- [10] 潘 东, 杨 欣, 施天成, 等. 基于量子长短期记忆网络的光伏功率预测模型[J]. 电力建设, 2025, 46(1): 122 – 133.
- PAN Dong, YANG Xin, SHI Tiancheng, et al. Photovoltaic-power prediction model based on quantum long short-term memory network[J]. Electric Power Construction, 2025, 46(1): 122 – 133.
- [11] 王俊杰, 毕 利, 张 凯, 等. 基于多特征融合和 XGBoost-LightGBM-ConvLSTM 的短期光伏发电量预测[J]. 太阳能学报, 2023, 44(7): 168 – 174.
- WANG Junjie, BI Li, ZHANG Kai, et al. Short-term photovoltaic power generation prediction based on multi-feature fusion and XGBoost-LightGBM-ConvLSTM[J]. Journal of Solar Energy, 2023, 44(7): 168 – 174.
- [12] 唱友义, 孙赫阳, 顾泰宇, 等. 采用历史数据扩充方法的风力发电量月度预测[J]. 电网技术, 2021, 45(3): 1059 – 1068.
- CHANG Youyi, SUN Heyang, GU Taiyu, et al. Monthly forecast of wind power generation using historical data expansion method[J]. Power System Technology, 2021, 45(3): 1059 – 1068.
- [13] 冯 乐. 非线性随机模型预测控制及其在风力发电系统中的应用研究[D]. 北京: 华北电力大学, 2022.
- FENG Le. Research on nonlinear stochastic model predictive control and its application in wind power generation system[D]. Beijing: North China Electric Power University, 2022.
- [14] 李 俊. 风力发电机组发电性能影响因素分析[J]. 机械制造, 2024, 62(5): 32 – 34, 43.
- LI Jun. Influencing factor analysis of power generation performance of wind turbine unit[J]. Machinery, 2024, 62(5): 32 – 34, 43.
- [15] 张 宇. 复杂数据环境下的风力发电厂功率预测研究[D]. 上海: 上海交通大学, 2021.
- ZHANG Yu. Research on power forecast of wind power plant under complex data environment[D]. Shanghai: Shanghai Jiao Tong University, 2021.
- [16] 朱琳琳, 钟志峰, 严 海, 等. 一种新的光伏发电预测模型设计[J]. 太阳能学报, 2016, 37(1): 63 – 68.
- ZHU Linlin, ZHONG Zhifeng, YAN Hai, et al. A new design of photovoltaic power generation forecasting model[J]. Acta Energiae Solaris Sinica, 2016, 37(1): 63 – 68.
- [17] 徐恒山, 莫汝乔, 薛 飞, 等. 基于时间戳特征提取和 CatBoost-LSTM 模型的光伏短期发电功率预测[J]. 太阳能学报, 2024, 45(5): 565 – 575.
- XU Hengshan, MO Ruqiao, XUE Fei, et al. Short-term photovoltaic power prediction based on timestamp feature extraction and CatBoost-LSTM model[J]. Acta Energiae Solaris Sinica, 2024, 45(5): 565 – 575.
- [18] BENRABIA I, SOFFKER D. Modeling and evaluation of forecasting models for energy production in wind and photovoltaic systems[J]. Energies, 2025, 18(3): 625.
- [19] 杨美春. 基于改进粒子群算法的电力系统经济调度研究[J]. 中国新技术新产品, 2025(3): 124 – 126.
- YANG Meichun. Research on economic scheduling of power system based on improved particle swarm algorithm[J]. New Technology & New Products of China, 2025(3): 124 – 126.
- [20] 李浩光, 于云华, 逢 燕, 等. 粒子群算法的近红外光谱定性分析预处理及特征提取参数优化方法研究[J]. 光谱学与光

谱分析,2021,41(9):2742–2747.

LI Haoguang, YU Yunhua, PANG Yan, et al. Research of parameter optimization of preprocessing and feature extraction for NIRS qualitative analysis based on PSD method[J]. Spectroscopy and Spectral Analysis, 2021, 41(9): 2742–2747.

[21] 戴朝辉,陈 昊,刘莘轶,等. 基于 K-medoids-GBDT-PSO-LSTM 组合模型的短期光伏功率预测[J]. 太阳能学报, 2025, 46(1): 654–661.

DAI Zhaohui, CHEN Hao, LIU Xinyi, et al. Short-term photovoltaic power prediction based on K-medoids-GBDT-PSO-LSTM combined model[J]. Acta Energaie Solaris Sinica, 2025, 46(1): 654–661.

[22] 苏 凯,赵鑫蕊,朱洪泽,等. 基于 PSO-SVR 的海缆刚度预测模型研究[J]. 太阳能学报, 2024, 45(8): 458–465.

SU Kai, ZHAO Xinrui, ZHU Hongze, et al. Study on prediction model of submarine cable stiffness based on PSO-SVR algorithm[J]. Acta Energaie Solaris Sinica, 2024, 45(8): 458–465.

[23] 方 娜,万 畅,余俊杰. 基于改进 PSO 的水火电短期发电优化调度[J]. 现代电子技术, 2020, 43(6): 119–123, 128.

FANG Na, WAN Chang, YU Junjie. Short-term hydrothermal power generation optimal scheduling based on improved PSO[J]. Modern Electronics Technique, 2020, 43(6): 119–123, 128.

[24] 叶豪杰,李文娜. 基于 PSO 的管式加热炉热效率动态矩阵控制[J]. 辽宁石油化工大学学报, 2023, 43(3): 81–85.

YE Haojie, LI Wenna. Dynamic matrix control of thermal efficiency of tubular furnace based on PSO algorithm[J]. Journal of Liaoning Petrochemical University, 2023, 43(3): 81–85.

[25] 胡 滢,臧大进,张 勇,等. 基于知识融合 PSO 的风光互补发电系统优化[J]. 控制工程, 2019, 26(5): 799–805.

HU Ying, ZANG Dajin, ZHANG Yong, et al. Wind-light generation system optimization based on knowledge fusion PSO algorithm[J]. Control Engineering of China, 2019, 26(5): 799–805.

[26] 秦涛涛,季思源,雷 琳,等. 基于 PSO-RNN 算法的多级感应线圈炮非参数建模与出口速度预测[J]. 兵工学报, 2025, 46(7): 87–97.

QIN Taotao, JI Siyuan, LEI Lin, et al. Non-parametric modeling and muzzle velocity prediction of multi-stage induction coilgun based on PSO-RNN algorithm[J]. Acta Armamentarii, 2025, 46(7): 87–97.

[27] 胡 强,高雅婷,尹宾礼,等. MDA-MIM:一种融合多尺度特征与双重注意力机制的雷达回波图预测模型[J]. 通信学报, 2025, 46(3): 248–257.

HU Qiang, GAO Yating, YIN Binli, et al. MDA-MIM: A radar echo map prediction model integrating multi-scale feature fusion and dual attention mechanism[J]. Journal of Communications, 2025, 46(3): 248–257.

[28] 夏起磊,罗 林,张 垚. 基于注意力增强型编解码网络的化工过程故障诊断[J]. 辽宁石油化工大学学报, 2024, 44(2): 63–70.

XIA Qilei, LUO Lin, ZHANG Yao. Fault diagnosis of chemical processes based on attention-enhanced encoder-decoder network[J]. Journal of Liaoning Petrochemical University, 2024, 44(2): 63–70.

[29] 毕贵红,孔凡文,黄 泽,等. 基于 Inception 和注意力机制的双分支日前电价预测[J]. 电力系统自动化, 2025, 49(5): 128–144.

BI Guihong, KONG Fanwen, HUANG Ze, et al. Double-branch day-ahead electricity price forecasting based on inception and attention mechanism[J]. Automation of Electric Power Systems, 2025, 49(5): 128–144.

[30] 王家乐,张 耀,林 帆,等. 基于自注意力特征提取的光伏功率组合概率预测[J]. 太阳能学报, 2024, 45(12): 123–131.

WANG Jiale, ZHANG Yao, LIN Fan, et al. Combining probabilistic prediction of PV power based on self-attentive feature extraction mechanism[J]. Acta Energaie Solaris Sinica, 2024, 45(12): 123–131.

[31] 孟令哲,周 翔,曾新华,等. 基于特征构造和改进 PSO 算法的分布式光伏功率预测[J]. 电源技术, 2024, 48(2): 325–330.

MENG Lingzhe, ZHOU Xiang, ZENG Xinhua, et al. Distributed photovoltaic power prediction based on feature construction and improved PSO algorithm[J]. Chinese Journal of Power Sources, 2024, 48(2): 325–330.

(刘 颖 编辑)