

基于内蒙古自治区电网影响因素的负荷预测分析

付昱婷¹, 刘震宇²

1. 天津理工大学 电气工程与自动化学院, 天津 300384

2. 内蒙古超高压供电公司, 内蒙古 呼和浩特 010010

DOI: 10.61369/TACS.2026070005

摘 要 : 电力负荷预测是电力系统调度与运行管理的重要基础, 准确的短期负荷预测对于保障风电并网后电网的安全稳定运行具有重要意义。本文选取内蒙古自治区某风电场的真实数据集开展实验, 验证了 PSO 优化的 CNN-LSTM-Attention 模型在内蒙古风电场景下的短期电力负荷预测中具有良好的适用性与优越性, 所提方法可为区域电力系统的风电并网与智能化调度提供有价值的技术参考。

关 键 词 : 电力负荷预测; 神经网络; 粒子群算法; 注意力机制

Load Forecasting Analysis Based on Influencing Factors of the Inner Mongolia Autonomous Region Power Grid

Fu Yuting¹, Liu Zhenyu²

1. School of Electrical Engineering and Automation, Tianjin University of Technology, Tianjin 300384

2. Inner Mongolia Ultra High Voltage Power Supply Company, Hohhot, Inner Mongolia 010010

Abstract : Electric load forecasting is an important foundation for power system dispatching and operation management. Accurate short-term load forecasting is of great significance for ensuring the safe and stable operation of the power grid after wind power is connected. This paper selects a real dataset from a wind farm in Inner Mongolia Autonomous Region to conduct experiments, verifying that the PSO-optimized CNN-LSTM-Attention model has good applicability and superiority in short-term power load forecasting in the scenario of an Inner Mongolia wind farm. The proposed method can provide valuable technical references for wind power integration and intelligent dispatching in regional power systems.

Keywords : power load forecasting; neural networks; particle swarm optimization; attention mechanism.

内蒙古自治区作为国家重要能源和战略资源基地, 其综合能源发展呈现出传统能源转型升级与新能源跨越式增长协同并进的新格局, 正在经历从“单一供能”向“综合赋能”的深度转型。从能源结构来看, 内蒙古自治区已形成以煤炭为基石、新能源为主体的多元化供给体系^[1]。传统能源升级指数达140.96点, 单位 GDP 能耗指标超额完成“十四五”规划目标; 清洁能源转型指数较基期增长69.29%, “风光氢储”全产业链雏形初现; 生态经济协同指数同比增长35.89%, 实现治沙增绿与经济增收双重成效。蒙西电网作为独立的区域性电网, 已成为能源系统智能化升级的理想试验平台, 新能源消纳率显著提升^[2]。因此, 开展高精度、高鲁棒性的电力负荷预测研究, 对保障电网安全稳定运行、优化发电资源配置、提升电力系统经济效益、促进新能源消纳与“双碳”目标落地具有重要的理论价值与实践意义。

一、预测模型设计

(一) PSO 优化算法

PSO 来源于鸟群寻找最佳觅食区域的过程, 是一种基于群体搜索的优化算法。通过群体中个体的信息共享, 整个群体的运动将在问题求解空间中从无序演变为有序, 从而获得最优解。

PSO 的核心是通过迭代寻求最优解。在每次迭代中, 粒子通过跟踪个体最优解和群体最优解两个极值来自我更新。在找到这两个最优解后, 粒子通过以下公式更新其速度和位置。

$$\begin{aligned}v_i &= v_i + c_1 \times \text{rand}() \times (pbest_i - x_i) + c_2 \times \text{rand}() \times (gbest - x_i) \\x_i &= x_i + v_i\end{aligned}\quad (1)$$

式中, $v_i + x_i$ 为记忆项; $c_1 \times \text{rand}() \times (pbest_i - x_i)$ 为自身认知项; $c_2 \times \text{rand}() \times (gbest - x_i)$ 为群体认知项。

(二) 数据集预处理

本研究采用的原始数据为内蒙古自治区某风电场2023年全年实测数据, 该数据由风电场操作员站监控与数据采集系统 SCADA (Supervisory Control And Data Acquisition) 后台实时采集调取。数据时间跨度为2023年1月1日至2023年12月31日, 采样分辨率为天, 共计365个样本。数据集包含4个特征变量, 分别为基础负荷、平均风速、日类型与季节, 本文针对某风电场2023年全年实测数据, 设计并实施了一套完整的数据预处理流程, 主要包括以下三个环节: 首先, 通过数据清洗对原始数据中的缺失

值与异常值进行检测与修正,采用随机森林回归方法填补缺失数据,采用孤立森林算法识别并修正异常样本,以保障输入数据的完整性与可靠性;其次,采用最大最小归一化方法对各特征变量进行统一的尺度变换,消除量纲差异对模型训练的不利影响,提升模型的收敛速度与训练稳定性;最后,按照时间顺序对数据集进行划分,并通过滑动窗口方法构造符合深度学习模型输入要求的序列样本,为后续模型的训练与评估提供标准化的数据支撑。

(三) 基于 PSO 优化的 CNN-LSTM-ATTENTION 的短期负荷预测模型

PSO-CNN-LSTM-Attention 的模型结构如图 1 所示。




图 1 PSO-CNN-LSTM-Attention 模型结构图

在电力负荷预测问题中,设原始负荷时间序列为

$$X = \{x_1, x_2, \dots, x_t, \dots, x_N\} \quad (2)$$

其中 x_t 表示时刻 t 的负荷值,样本总数为 N 。在构建监督学习样本时,引入时间步长 T ,采用滑动窗口方式构造训练样本集合:

$$D = \{(X^{(i)}, y^{(i)})\}_{i=1}^m \quad (3)$$

其中 $X^{(i)} = [x_i, x_{i+1}, \dots, x_{i+T-1}]$, $y^{(i)} = x_{i+T}$, $m = N - T$ 为样本数量, $y^{(i)}$ 表示第 i 个样本对应的预测目标,即利用前 T 个时间步数据预测第 $T+1$ 时刻负荷值。

(1) CNN 局部特征提取过程

首先,将输入样本 $X^{(i)}$ 输入一维卷积神经网络 (Convolutional Neural Network, CNN) 进行局部特征提取。设卷积核大小为 k , 卷积核权重为 w , 偏置为 b , 则卷积输出为:

$$z_t = f\left(\sum_{j=1}^{k-1} w_j x_{t-j} + b\right) \quad (4)$$

其中, $f(\cdot)$ 为非线性激活函数, z_t 为卷积后第 t 个时间位置的特征表示

经多组卷积核作用后可得到局部特征矩阵:

$$Z = [z_1, z_2, \dots, z_T] \quad (5)$$

CNN 的作用在于提取负荷序列中的局部波动模式与短期变化特征,增强特征表达能力。

(2) LSTM 时序依赖建模过程

卷积特征序列 Z 作为输入传入长短期记忆网络 (Long Short-Term Memory, LSTM)。LSTM 通过门控机制对历史信息进行选择记忆,其核心计算过程如下:

遗忘门:

$$f_t = \sigma(W_f[h_{t-1}, z_t] + b_f) \quad (6)$$

输入门:

$$i_t = \sigma(W_i[h_{t-1}, z_t] + b_i) \quad (7)$$

候选记忆:

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, z_t] + b_c) \quad (8)$$

记忆更新:

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (9)$$

输出门:

$$o_t = \sigma(W_o[h_{t-1}, z_t] + b_o) \quad (10)$$

隐藏状态:

$$h_t = o_t \tanh(C_t) \quad (11)$$

其中, h_t 为时间步 t 的隐藏状态, C_t 为记忆单元状态, o_t 为 Sigmoid 函数

通过递归更新, LSTM 得到隐藏状态序列:

$$H = [h_1, h_2, \dots, h_T] \quad (12)$$

该过程实现了对负荷序列长期依赖关系和周期性规律的建模。

(3) Attention 关键时间信息加权

为增强模型对关键时间步信息的识别能力,引入注意力机制 (Attention Mechanism) 对隐藏状态序列 H 进行加权。

首先计算时间步的重要性得分:

$$e_t = v^T \tanh(W_a h_t) \quad (13)$$

归一化得到注意力权重:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{j=1}^T \exp(e_j)} \quad (14)$$

最终得到上下文向量:

$$c = \sum_{t=1}^T \alpha_t h_t \quad (15)$$

其中, α_t 表示第 t 个时间步对预测结果的贡献权重, c 为加权后的综合特征表示。

Attention 机制能够自动强调对预测结果影响较大的历史时刻,提高模型表达能力。

(4) 输出层与预测结果

将上下文向量 c 输入全连接层 (Fully Connected Layer), 得到预测值:

$$\hat{y}^{(i)} = W_o c + b_o \quad (16)$$

其中, $\hat{y}^{(i)}$ 为模型对第 i 个样本的预测结果, W_o, b_o 为输出层参数

从时序建模机理出发, CNN-LSTM-Attention 电力负荷预测模型的预测过程可以理解为对历史负荷信息进行分层抽象、时序整合与重要性重构的递进式处理过程。

最后, PSO 优化算法的引入,能够有效地优化 CNN-LSTM-Attention 模型中的卷积核大小和 LSTM 单元数,从而提高模型的预测精度,减少训练时间,并改善模型的泛化能力。

使用 PSO 优化后,卷积核大小和 LSTM 单元数的选择更加符合数据的特性,模型能够更加精准地提取时空特征和学习长期依赖关系。因此,优化后的模型能够在电力负荷预测中提供更准确的结果。

PSO 优化能够根据数据的特点自适应调整超参数,使得模型避免了过拟合和欠拟合的情况。优化后的模型在训练集和验证集上的误差趋于一致,证明了模型具有更好的泛化能力。PSO 通过优化超参数,使得模型的收敛速度加快,训练时间减少。相比于

未优化的模型，优化后的模型能够在较短的时间内达到更好的预测精度，提高了训练效率。

二、算例分析

（一）与基线模型对比

为全面验证本文所提 PSO-CNN-LSTM-Attention 模型的预测性能，选取 CNN、LSTM、CNN-LSTM、Transformer 以及 CNN-LSTM-Attention 共五种模型作为基准对比模型。各模型预测结果如表 1 所示。

表 1 各模型预测误差对比

模型	MAE	RMSE	R2
PSO-CNN-LSTM-Atteneion	232.064	322.068	0.953
CNN-LSTM-Atteneion	287.828	383.312	0.932
Transformer	301.568	395.006	0.929
CNN-LSTM	319.781	42547.	0.917
LSTM	343.865	454.555	0.905
CNN	367.826	472.721	0.898

从表 1 可以看出，在所有对比模型中，CNN 模型的预测精度最低，表明单纯依赖卷积操作提取局部特征而缺乏时序建模能力的网络结构难以胜任电力负荷这类具有强时序依赖性的预测任务。LSTM 模型在 CNN 基础上有所提升，MAE 降至 343.865， R^2 提升至 0.905，说明引入门控记忆机制后模型对长期时序依赖的捕捉能力有所增强，但仍存在对局部特征提取不足的局限。将 CNN 与 LSTM 进行融合后，CNN-LSTM 模型的预测性能得到进一步改善，MAE 为 319.781，RMSE 为 425.47， R^2 为 0.917，相较于单一 LSTM 模型，MAE 降低了约 7.0%，验证了卷积层在提取输入序列局部特征方面对 LSTM 时序建模的有效补充作用。在 CNN-LSTM 基础上引入注意力机制后，CNN-LSTM-Attention 模型的各项指标均有显著提升，MAE 降至 287.828，RMSE 为 383.312， R^2 提升至 0.932，相较于 CNN-LSTM 模型 MAE 降低了约 10.0%。这一结果表明，注意力机制通过对 LSTM 各时间步隐藏状态赋予差异化权重，使模型能够更加聚焦于与预测目

标强相关的历史时刻，从而有效抑制了冗余时序信息的干扰，提升了模型对关键特征的利用效率。Transformer 模型的 MAE 为 301.568，RMSE 为 395.006， R^2 为 0.929，预测精度介于 CNN-LSTM 与 CNN-LSTM-Attention 之间。尽管 Transformer 依托自注意力机制在长序列建模中具有理论优势，但在本文所使用的小规模时序数据集上，其参数量较大、对数据量需求较高的特点导致其性能未能充分发挥，进一步说明在有限样本条件下，结构精简且针对性强的混合模型具有更强的实用性。




图 2 各预测模型预测曲线对比图

（二）所提模型在不同季节中的对比

为验证所提 PSO-CNN-LSTM-Attention 模型在不同负荷分布条件下的稳定性与适用性，本文分别对春季、夏季、秋季和冬季数据进行独立建模与对比实验。实验结果如表 2 所示。




图 3 四种季节类型预测结果

表 2 预测结果评价指标对比

季节	指标	PSO-CNN-LSTM-Atteneion	CNN-LSTM-Atteneion	Transformer	CNN-LSTM	LSTM	CNN
春季	MAE	383.229	389.594	401.476	438.577	469.773	469.773
	RMSE	551.921	578.667	583.413	614.829	636.179	636.179
	R2	0.841	0.826	0.823	0.803	0.789	0.789
夏季	MAE	238.988	273.688	312.458	268.549	362.339	309.348
	RMSE	381.99	398.29	431.621	413.142	466.808	486.788
	R2	0.904	0.896	0.877	0.88	0.857	0.844
秋季	MAE	253.362	292.269	291.261	350.623	354.932	397.188
	RMSE	350.795	399.268	408.194	437.138	442.661	500.414
	R2	0.933	0.914	0.91	0.897	0.895	0.865
冬季	MAE	202.243	204.689	220.381	234.453	237.94	256.418
	RMSE	275.955	282.598	302.584	309.96	322.78	330.349
	R2	0.864	0.857	0.836	0.828	0.813	0.805

春季方面,各模型整体预测精度相较于其他季节有所下降,这与春季负荷受气温回升、节假日集中及用电行为不稳定等多重因素叠加影响、规律性相对较弱有关。CNN 模型预测误差最大,MAE 为 475.098, R^2 仅为 0.781; PSO-CNN-LSTM-Attention 模型 MAE 为 383.229, RMSE 为 551.921, R^2 为 0.841,在所有对比模型中仍取得最优结果。与性能次优的 CNN-LSTM-Attention 模型相比,MAE 降低了约 1.6%;与基准 CNN 模型相比,MAE 降低了约 19.3%,表明本文模型在规律性较弱的季节数据上依然保持了相对稳定的预测优势。

夏季方面,各模型整体预测精度有所提升,这与夏季空调等制冷设备大规模投入使用使负荷呈现出较强周期性规律有关,模型更易捕捉数据分布特征。PSO-CNN-LSTM-Attention 模型 MAE 为 238.988, RMSE 为 381.990, R^2 为 0.904,在六个模型中表现最优。与 CNN-LSTM-Attention 模型相比,MAE 降低了约 12.7%;与基准 CNN 模型相比,MAE 降低了约 22.7%,进一步说明 PSO 优化策略在负荷规律性较强的季节中能够更充分地发挥超参数寻优的效能。

秋季方面,各模型预测精度在四个季节中整体表现较好,秋季气温适宜、负荷波动相对平稳,时序规律性较强,有利于深度学习模型的特征学习。PSO-CNN-LSTM-Attention 模型 MAE 为 253.362, RMSE 为 350.795, R^2 达到 0.933,为四个季节中 R^2 最高值。与 CNN-LSTM-Attention 模型相比,MAE 降低了约 13.3%;与基准 CNN 模型相比,MAE 降低了约 36.2%,充分验证了本文模型在负荷平稳场景下的优越预测性能。

冬季方面,受采暖负荷集中释放影响,负荷整体水平较高

但各模型的 MAE 绝对值相对较小,说明冬季负荷虽峰值较高但其日内变化趋势较为规律,模型更易拟合。PSO-CNN-LSTM-Attention 模型 MAE 为 202.243, RMSE 为 275.955, R^2 为 0.864,在六个对比模型中仍取得最优结果。与 CNN-LSTM-Attention 模型相比,MAE 降低了约 1.2%;与基准 CNN 模型相比,MAE 降低了约 21.1%。值得注意的是,冬季各模型之间的性能差距相对其他季节有所收窄,说明在高规律性负荷场景下模型结构本身的边际贡献趋于饱和,而 PSO 优化的参数配置仍能维持相对领先优势。

综合四个季节的实验结果可以发现,PSO-CNN-LSTM-Attention 模型在春、夏、秋、冬四个季节均取得了最低的 MAE 与 RMSE 以及最高的 R^2 ,充分证明了本文模型具有良好的跨季节泛化能力,并非仅对特定季节的负荷特性过拟合。

三、总结

本文围绕内蒙古自治区电力负荷预测这一核心问题,系统开展了从理论分析到模型优化的研究,为区域能源系统的智能化调度提供技术支持。构建了 PSO-CNN-LSTM-Attention 混合电力负荷预测优化模型。PSO 算法通过模拟群体智能对模型超参数进行全局寻优,有效提升了模型的拟合能力与泛化性能。综上所述,本文从数据预处理、模型组合到参数优化,证明了 PSO 优化的 CNN-LSTM-Attention 电力负荷预测模型在短期电力负荷预测中的适用性与优越性,为内蒙古自治区风电并网与调度负荷预测提供了有价值的技术参考。

参考文献

- [1] 武强. 协调规模与效能,推进煤炭与新能源协同发展 [N]. 中国能源报, 2025-07-02.
- [2] 陈柏任, 陈沁铭, 邵敏伦, 等. 实测用电数据驱动的需求侧响应电力用户二次聚类及双层 BiLSTM 预测方法 [J/OL]. 南方电网技术, 1-11[2026-01-12].<https://link.cnki.net/urlid/44.1643.tk.20260104.1333.006>.
- [3] 包育德, 邱润韬, 许博智. 基于 ADKDE-LSTM 的变电站短期负荷功率区间预测研究 [J]. 电器与能效管理技术, 2025, (11): 42-50.DOI: 10.16628/j.cnki.2095-8188.2025.11.006.
- [4] 戚励楠, 姚正平, 王青磊. 基于 SSA-VMD 和 QPSO-LSTM 的短期电力负荷预测方法 [J]. 自动化应用, 2025, 66(22): 57-61.DOI: 10.19769/j.zdhy.2025.22.015.
- [5] 王海天, 谭爱国, 彭赛, 等. 基于 LGWO-XGBoost-LightGBM-GRU 的短期电力负荷预测算法 [J]. 湖北民族大学学报 (自然科学版), 2025, 43(01): 73-79.DOI: 10.13501/j.cnki.42-1908/n.2024.12.019.
- [6] 宋冠君, 王磊, 张鹏超, 等. 基于双通道特征提取 VMD-CNN-BiLSTM 的短期负荷预测 [J/OL]. 电力系统及其自动化学报, 1-14[2026-01-12].<https://doi.org/10.19635/j.cnki.csu-epsa.001751>.
- [7] 冯崇峰, 孟春旅, 冯积家. 基于混合深度学习的电力负荷预测模型 [J]. 电力需求侧管理, 2024, 26(06): 94-100.
- [8] 李志霄, 武文丽, 武衡, 等. 基于时滞注意力机制的短期电力负荷预测 [J/OL]. 计算机技术与发展, 1-9[2026-01-12].<https://doi.org/10.20165/j.cnki.ISSN1673-629X.2025.0308>.
- [9] 饶弘宇, 陈馨, 陈胜, 等. 基于改进鲸鱼算法的 Bi-LSTM 电力负荷预测 [J]. 计算机与现代化, 2025, (07): 77-82+89+126.
- [10] 王生, 张和茂, 王晓荣. 基于 CNN-LSTM-AM 模型的短期电力负荷预测研究 [J]. 电工电气, 2025, (05): 57-61.
- [11] 孙帆. 含冷热电联供的用户级综合能源系统多能协同优化调度研究 [D]. 华北电力大学, 2021.DOI: 10.27139/d.cnki.ghbdu.2021.000118.
- [12] 任明远, 马国瀚, 唐聪, 等. 基于 CNN-Attention-BiLSTM 的碳化硅企业负荷预测与可调节潜力分析 [J]. 电力需求侧管理, 2025, 27(03): 38-43.
- [13] 王生, 张和茂, 王晓荣. 基于 CNN-LSTM-AM 模型的短期电力负荷预测研究 [J]. 电工电气, 2025, (05): 57-61.
- [14] 王婷. 基于 LSTM 深度网络的电力负荷预测 [D]. 山西大学, 2020.DOI: 10.27284/d.cnki.gsxiu.2020.000860.
- [15] 王剑锋, 郑剑, 王旭东, 等. 基于改进深度信念网络的短期电力负荷预测方法 [J]. 电力系统及其自动化学报, 2021, 33(10): 125-130.DOI: 10.19635/j.cnki.csu-epsa.000781.