

基于物理特征门控注意力的长短期记忆网络的风电功率预测

滕菲

哈尔滨电力职业技术学院，黑龙江 哈尔滨 150030

DOI: 10.61369/SSSD.2026090027

摘 要： 风力发电的波动性对电力系统的安全稳定运行构成挑战。但现有预测方法忽略物理规律，导致其在极端场景下的精度较差。因此，本文提出了一种基于物理特征门控注意力的长短期记忆网络预测方法。该方法首先通过相关性分析筛选出风速作为核心物理特征，并利用该物理特征向量融合局部时序模式与全局依赖关系。实验结果表明，所提方法在多种指标上展现出优秀的性能。

关 键 词： 新能源预测；风力出力预测；深度学习；长短期记忆网络；注意力机制

Wind Power Prediction Based on Long Short-Term Memory (LSTM) Network with Physical Feature Gated Attention

Teng Fei

Harbin Electric Power Vocational Technology College, Harbin, Heilongjiang 150030

Abstract： The variability of wind power generation poses challenges to the safe and stable operation of power systems. However, existing prediction methods neglect physical laws, resulting in poor accuracy in extreme scenarios. Therefore, this paper proposes a Long Short-Term Memory (LSTM) prediction method based on physically-informed gated attention. This method first selects wind speed as the core physical feature through correlation analysis and utilizes this physical feature vector to integrate local temporal patterns with global dependencies. Experimental results demonstrate that the proposed method exhibits excellent performance across multiple metrics.

Keywords： new energy forecasting; wind power output forecasting; deep learning; long short-term memory network; attention mechanism

引言

风力发电作为清洁能源的重要组成部分，因其资源丰富、环境友好等优势，在全国能源结构转型中扮演着关键的角色^[1]。然而，风电输出功率呈现出显著的波动性，这给电力系统的安全稳定运行带来了严峻挑战^[2]。因此，实现高精度的风电功率预测具有至关重要的意义。当前，韩健等^[3]提出了基于长短期记忆网络和卷积神经网络的混合预测方法。米云宝等^[4]建基于卷积神经网络与双向门控循环单元组合的预测模型。然而，现有模型的建模过程未能有效融入物理规律^[5]。这导致模型在面对训练数据分布外的场景时，将产生不准确的预测结果^[6,7]。

针对上述问题，本文提出一种新颖的基于物理特征门控注意力的长短期记忆网络方法。所提出的方法基于关键物理特征，自适应地融合局部时序模式与全局依赖关系。

一、方法

传统的注意力机制完全依赖数据驱动，可能产生物理上不合理的预测结果^[8-10]。为此，本文提出了一种新颖的风电功率预测

方法。

原始输入序列 $X=x_1, x_2, \dots, x_T \in R^{T \times d_{input}}$ 首先通过一个两层 LSTM 网络进行编码。LSTM 的输出序列为 $H=h_1, \dots, h_T$ ，其中 h_t 为时间步 t 的隐藏状态。最后一层输出 h_T 被记为 f_{lstm} ，作为局部时

序模式的代表。

为捕获序列中的全局依赖关系，将长短期记忆网络的输出 H 输入到一个多头自注意力层。最终输出同样为一个序列。提取该序列最后一个时间步的特征 f_{att} ，作为全局上下文信息的浓缩表示。

该模块由一个两层的全连接网络组成，被用来将二维物理特征 $v_{physics}$ 映射为一个与特征维度相同的门控权重向量 g ：

$$g = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot v_{physics} + b_1) + b_2) \quad (1)$$

其中 $W_1 \in R^{T \times d_{hidden}/2 \times 2}$ ， $W_2 \in R^{T \times d_{hidden}/2}$ ， $\sigma(\cdot)$ 为 Sigmoid 激活函数，确保 g 的每个元素值域在 (0.1) 之间。本文采用 Pearson 相关系数对各输入特征与目标功率序列之间的线性相关性进行量化评估，定义如下：

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2)$$

其中， x_i 和 y_i 分别为第 i 个样本的特征值和功率值， $\bar{x}$ 和 $\bar{y}$ 分别为对应变量的均值， n 为样本总数。风速与风电功率之间呈现出极高的正相关性。因此，本文选定风速作为核心物理特征，并基于此构造更具代表性的物理特征向量。具体而言，我们构造了两

个特征组合成物理特征向量：

$$v_{physics} = [v_{current}, v_{avg}] \in R^2 \quad (3)$$

其中 $v_{current}$ 表示预测时刻的风速。 v_{avg} 反映过去一小时的风速趋势。接着，本文通过一个两层神经网络将物理特征映射为门控权重：

$$g = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot v_{physics} + b_1) + b_2) \quad (4)$$

其中 σ 为 Sigmoid 激活函数，确保门控权重 $g \in (0.1)$ ，并指导特征进行自适应融合调节。最后，长短期记忆网络特征与注意力特征通过门控权重进行自适应融合：

$$f_{fused} = g \odot f_{attention} + (1 - g) \odot f_{lstm} \quad (5)$$

当风速变化剧烈时，门控权重倾向于增强注意力特征的贡献；当风速平稳时，则更多依赖长短期记忆网络的局部时序特征。融合后的特征 f_{fused} 经过一个两层全连接网络后，映射为最终的标量预测值 $\hat{y}$ 。

$$\hat{y} = W_{out2} \cdot \text{ReLU}(W_{out1} \cdot f_{fused} + b_{out1}) + b_{out2} \quad (6)$$

二、实验

本文采用某风电场 2021–2022 年的历史数据进行验证。




图 1 对比实验结果

图 1 展示了三种模型在测试集上的功率预测结果。本文提出的方法在大部分评估指标上取得了最优性能。从曲线趋势上看，MLP 模型的预测曲线最为平滑，但对功率的快速波动响应迟钝，尤其在功率骤升或骤降时刻出现明显滞后，这表明纯前馈网络难以有效建模时序依赖关系。其次，LSTM 在某些极端天气条件下，预测值出现较大偏差。最后，本文提出的方法展现出最佳的

预测性能。其在功率剧烈变化时仍能保持较高的预测精度。

表 1 三种模型的预测性能对比

	MAE	RMSE	MAPE	
MLP	4057.02	6643.33	25.99	0.9554
LSTM	2996.22	5531.84	17.89	0.9691
Proposed	2992.69	6427.95	18.82	0.9583

三、结论

本文针对风电功率预测中纯数据驱动模型缺乏物理一致性的问题，提出了一种基于物理特征门控注意力的长短期记忆网络方法。

该方法通过筛选风速作为核心特征，设计物理驱动的门控融合模块，动态调节局部时序特征与注意力全局特征的权重。实验结果表明，本文为构建高可靠性的风电预测系统提供了有效方案。

参考文献

[1] 张懿夫, 张海峰, 崔运海, 等. 考虑多源数据融合的风力发电机组功率预测模型 [J]. 自动化与仪器仪表, 2026, (02): 166–170. DOI: 10.14016/j.cnki.1001-9227.2026.02.166.

[2] 夏卫平, 邓艾东, 薛原, 等. 基于 VMD 和多时间尺度分类预测的风电单机短期功率预测研究 [J]. 太阳能学报, 2025, 46(12): 554–563. DOI: 10.19912/j.0254-0096.tynxb.2024-1466.

[3] 韩健. 基于 LSTM-CNN 混合预测的风电功率预测技术研究 [J]. 石油石化节能与计量, 2025, 15(12): 14–18.

[4] 米云宝. 时序数据挖掘下风力发电机组输出功率预测方法 [J]. 技术与市场, 2026, 33(03): 101–104.

[5] 李传栋, 张明慧, 张逸, 等. 考虑风力波动相关性的风电场超短期出力预测 [J]. 太阳能学报, 2025, 46(11): 754–763. DOI: 10.19912/j.0254-0096.tynxb.2024-1299.

[6] 马昕远, 伊海港. 基于 CNN-LSTM-Attention 的风力发电功率预测与可解释性分析 [J]. 长江信息通信, 2025, 38(11): 17–21. DOI: 10.20153/j.issn.2096-9759.2025.11.005.

[7] G.Wang, L.Jia and Q.Xiao. A Hybrid Approach Based on Unequal Span Segmentation-Clustering for Short-Term Wind Power Forecasting [J]. IEEE Transactions on Power Systems, 2024, vol.39, no.1, pp.203–216.

[8] Y.Wang, Q.Hu, D.Srinivasan and Z.Wang. Wind Power Curve Modeling and Wind Power Forecasting With Inconsistent Data [J]. IEEE Transactions on Sustainable Energy, 2019, vol.10, no.1, pp.16–25.

[9] J.Sathyaraj and V.Sankardoss. Enhancing Short-Term Wind Speed Prediction Based on Deep Learning With Ensemble Learning Model for Small Wind Turbine Applications [J]. IEEE Access, 2025, vol.13, pp.82759–82782.

[10] S.Wang, J.Li, Z.Hou, Q.Meng and M.Li. Composite Model-free Adaptive Predictive Control for Wind Power Generation Based on Full Wind Speed [J]. CSEE Journal of Power and Energy Systems, 2022, vol.8, no.6, pp.1659–1669.