

DOI: 10.19783/j.cnki.pspc.240939

基于超参数优化和误差修正的 STAGN 超短期风电功率预测

潘超¹, 王超¹, 孙惠¹, 孟涛^{1,2}

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 吉林 132012;
2. 国网吉林省电力科学研究院有限公司, 吉林 长春 130021)

摘要: 针对风电功率预测模型的数据关联性与误差修正适应性问题, 提出基于超参数优化和误差修正单元切换的超短期风电功率预测方法。首先, 构建时空注意力门控网络预测模型, 利用改进开普勒算法进行超参数优化。然后, 考虑风电场数据与预测误差之间的非线性关联, 构建误差修正自适应单元。同时挖掘风速时序变化特征, 构建深度学习单元。在此基础上, 提出基于风速矩阵梯度的误差修正单元切换策略。最后, 将模型应用于实际风场的功率预测并与其他模型对比分析。结果表明, 所提方法在预测精度上优于其他方法, 且在风速复杂多变的风场仍具有较高预测精度, 验证了所提方法的准确性和适用性。

关键词: 超短期风电功率预测; 改进开普勒算法; 误差修正; 风速矩阵梯度

STAGN ultra-short-term wind power forecasting based on hyperparameter optimization and error correction

PAN Chao¹, WANG Chao¹, SUN Hui¹, MENG Tao^{1,2}

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology (Northeast Electric Power University), Ministry of Education, Jilin 132012, China; 2. State Grid Jilin Electric Power Research Institute Co., Ltd., Changchun 130021, China)

Abstract: To address the issues of data correlation and error correction adaptability in wind power forecasting models, an ultra-short-term wind power prediction method based on hyperparameter optimization and error correction unit switching mechanism is proposed. First, a spatiotemporal attention gated network (STAGN) forecasting model is developed, and hyperparameter optimization is carried out using the improved Kepler optimization algorithm. Second, an error correction adaptive unit is constructed by considering the nonlinear correlation between wind farm data and forecasting errors. Meanwhile, the temporal variation characteristics of wind speed are explored to construct a deep learning unit. On this basis, the error correction unit switching strategy based on the wind speed matrix gradient is proposed. Finally, the model is applied to power forecasting in an actual wind farm and compared with other models. The results show that the proposed method outperforms others in terms of forecasting accuracy and maintains high forecasting accuracy in wind farms with highly variable wind speeds, verifying its accuracy and applicability.

This work is supported by the National Key Research and Development Program of China (No. 2022YFB2404000).

Key words: ultra-short-term wind power prediction; improved Kepler optimization algorithm; error correction; wind speed matrix gradient

0 引言

风能作为清洁可再生的优质能源, 在我国能源系统中得到了广泛运用。然而, 风能的间歇性和不确定性会导致风电功率的强烈波动, 使得风电并网受到

巨大冲击。因此, 准确的风电功率预测对于促进风电优化利用及确保电网稳定运行具有重要意义^[1-3]。

近年来, 组合预测^[4-5]方法成为风电功率预测研究的热点。组合预测包含模型选择、超参数优化、误差修正等环节, 其采用不同的方法, 将模型的输入、输出或模型自身进行优化融合来提升风电功率的预测精度。

基金项目: 国家重点研发计划项目资助(2022YFB2404000)

针对模型选择问题,文献[6]提出了一种结合门控循环单元(gated recurrent unit, GRU)和数据滤波技术的风速预测方法,取得了良好的预测效果;文献[7]结合卷积神经网络(convolutional neural network, CNN)的空间特征提取能力与长短期记忆神经网络 long short term memory, LSTM)的时间特征挖掘能力构建了考虑输入特征时空相关性的风速预测模型;文献[8]提出的双向门控循环单元(bi-directional gated recurrent unit, BiGRU)短期负荷预测模型充分学习负荷的双向时序信息,获得了更为准确的预测结果。文献[9]在 LSTM 网络中加入注意力机制,强化模型对输入特征中重要信息的关注程度,进一步提高了模型的预测精度。概括已有研究可知,不同神经网络模型的组合方法为风电功率预测提供了新的思路。

另外,由于神经网络中超参数选取困难,针对模型自身,可采用群体智能优化算法来对模型超参数进行优化,从而提高模型预测效果。目前主流的智能优化算法包括粒子群算法^[10]、遗传算法^[11]、差分进化算法^[12]、麻雀优化算法(sparrow search algorithm, SSA)^[13]和灰狼优化算法(grey wolf optimization, GWO)^[14]等。为了提升智能优化算法的超参数优化效果,研究者们做了多项改进。文献[15]引入重心反向学习方法改善麻雀优化算法的种群质量,提高了初始种群的适应度;文献[16]通过将粒子群算法与万有引力算法融合,提高了其优化性能;文献[17]通过添加对数权重因子和随机差分变异策略,提升了鲸群算法的整体搜索和局部挖掘能力;文献[18]引入 Tent 混沌映射和随机游走策略改进麻雀优化算法,使其全局搜索性能得到提高。然而,上述方法在提高初始种群质量、平衡局部搜索与全局搜索方面仍存在局限性,限制了它们的超参数优化性能。

为了进一步提升预测准确性,针对模型输出环节,研究者们已对误差修正方法开展研究。文献[19]采用随机森林算法建立误差修正模块,通过误差的概率拟合分布计算置信区间,修正了功率预测值。文献[20]采用优化的广义误差分布模型对预测误差的概率密度进行拟合,从而对误差分布进行精确评估。上述研究提前假设风电功率预测误差遵循某种已定义分布,并对其参数进行确定。但风电自身的随机性和波动性导致其预测误差难以遵循预先定义的统计分布^[21-22]。因此,文献[23]对长短期记忆网络添加注意力机制并修改损失函数,基于误差与风速、功率的相关性拟合多项式对误差进行预测;文献[24]基于风速大小分类误差,针对每类误差建立基于随机森林的误差修正模型,提高了模型的预

测精度。但上述针对误差确定性预测的方法虽更易挖掘误差的隐含信息,但在面对突发的波动时,模型的泛化性便会降低,且单一误差修正模块在面对复杂场景时,往往难以达到理想的修正效果。

针对上述问题,本文构建时空注意力门控网络(spatio-temporal attention gated network, STAGN),提出一种改进开普勒算法(improved Kepler optimization algorithm, IKOA)的超参数优化方法优化 STAGN 超参数,并使用优化后的模型进行风电功率预测。在误差修正模块中嵌入并行的自适应单元和深度学习单元,利用 Toeplitz 风速矩阵梯度切换误差修正单元,利用得到的误差预测值对功率预测结果进一步修正。最后结合实际风场数据,验证了本文方案的准确性和适用性。

1 时空注意力门控网络

STAGN 包含 3 个关键模块:空间卷积模块、时序双向门控模块和注意力增强模块。利用卷积神经网络提取输入数据中的空间特征信息,时序双向门控模块捕捉数据中的时序依赖关系,注意力增强模块对功率时序输出进行加权并计算最终的预测结果,模型整体结构如图 1 所示。

1.1 空间卷积模块

空间卷积模块^[25]利用多卷积层对输入的特征矩阵进行特征提取,得到长度较小的特征图,然后通过池化层把特征向量降为一维数据,最终将提取到的若干特征映射 \mathbf{h}_J^i 输入到时序双向门控模块进行学习,卷积层操作如式(1)所示。

$$\mathbf{h}_J^i = f_c \left(\sum_{l \in N_M} \mathbf{v}_l^{i-1} * \mathbf{W}_{lJ}^i + \mathbf{g}_J^i \right) \quad (1)$$

式中: \mathbf{h}_J^i 表示第 i 层第 J 次卷积映射; f_c 表示激活函数; l 表示输入特征的索引; N_M 表示输入特征的矩阵集合; \mathbf{v}_l^{i-1} 表示第 l 个输入特征在 $i-1$ 层的输出特征; “*” 表示卷积运算; \mathbf{W}_{lJ}^i 表示连接第 l 个输入特征与第 J 个输出特征的第 i 层卷积核矩阵; \mathbf{g}_J^i 表示第 i 层第 J 个输出特征的偏置矩阵。

1.2 时序双向门控模块

时序双向门控模块^[8]包含两个门控循环单元,分别处理由空间卷积模块提取的特征序列正、反向信息。

$$\begin{cases} \vec{\mathbf{h}}_t = \text{GRU}(\mathbf{x}_t, \vec{\mathbf{h}}_{t-1}) \\ \overleftarrow{\mathbf{h}}_t = \text{GRU}(\mathbf{x}_t, \overleftarrow{\mathbf{h}}_{t-1}) \\ \mathbf{h}_t = w_t^{\rightarrow} \vec{\mathbf{h}}_t + w_t^{\leftarrow} \overleftarrow{\mathbf{h}}_t + \mathbf{b}_t \end{cases} \quad (2)$$

式中: \vec{h}_t 表示 t 时刻正向隐藏层的输出; \overleftarrow{h}_t 表示 t 时刻反向隐藏层的输出; GRU 表示门控循环单元; x_t 表示 t 时刻的输入; h_t 表示 t 时刻时序双向门控的输出; \vec{w}_t 和 \overleftarrow{w}_t 分别表示 t 时刻正、反向隐藏层输出对应的权重; b_t 表示 t 时刻的偏置矩阵。

1.3 注意力增强模块

引入注意力增强模块^[26]提高模型对时序双向门控输出信息的关注程度, 根据 softmax 函数计算门控输出的权重系数, 利用概率分布对功率序列进

行加权求和, 并输出预测结果。

$$\text{score}(h_i, h_t) = h_t^T W h_i \quad (3)$$

$$e_i = \frac{\exp(\text{score}(h_i, h_t))}{\sum_{i=1}^t \exp(\text{score}(h_i, h_t))} \quad (4)$$

$$\lambda_i = e_i h_i \quad (5)$$

式中: $\text{score}(\cdot)$ 表示注意力评分函数; h_i 表示 i 时刻的隐藏层输出; W 表示学习权重矩阵; e_i 表示 i 时刻的注意力权重向量; λ_i 表示 i 时刻的加权系数。

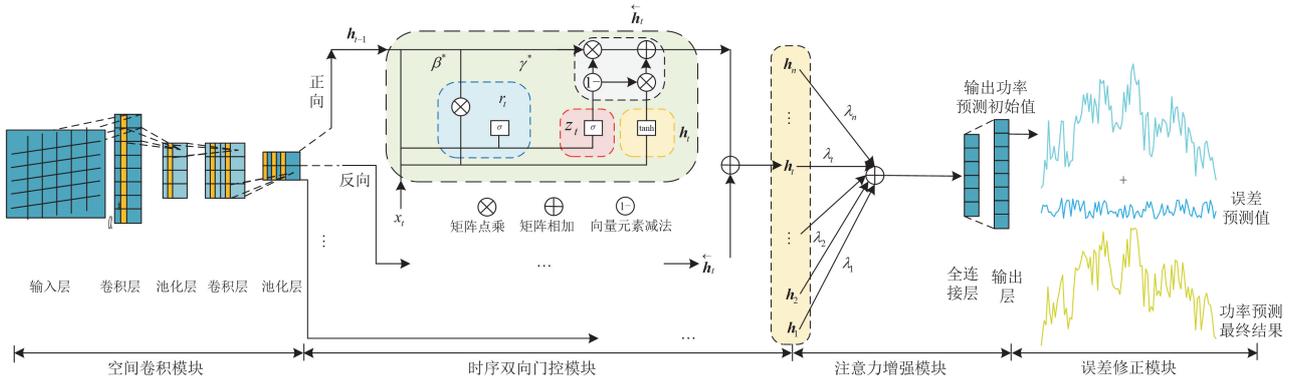


图1 预测模型整体结构

Fig. 1 Overall structure of prediction model

2 基于改进开普勒算法的超参数优化

空间卷积模块卷积核大小 α 、双向门控单元学习率 β 及神经元个数 γ 是 STAGN 模型的关键超参数。较大的卷积核可能会增加模型的计算负担, 而较小的卷积核可能无法捕获足够的时序信息。另外, 合适的双向门控单元学习率使得模型在训练过程中能避免越过最优解或陷入局部解的问题^[27]。同时, 通过优化神经元个数, 可以保持模型的泛化能力, 并避免过拟合。因此, STAGN 超参数优化是提升模型预测精度的重要环节, 若要建立高精度的预测模型, 有必要对上述超参数进行优化。

研究表明, 开普勒算法 (Kepler optimization algorithm, KOA) 具有高效灵活的计算性能, 被广泛应用于神经网络的超参数优化。KOA 以天体运动为启发, 各行星位置作为候选解, 行星在其轨道上向太阳 (最优解) 靠近, 然后远离太阳。具体寻优计算原理参考文献^[28]。本文提出一种改进开普勒算法 (improved Kepler optimization algorithm, IKOA), 通过混沌映射改善星群初始化, 利用高斯变异更新星体位置, 从而优化开发阶段, 以模拟天体运动的形式优化 STAGN 超参数。

2.1 基于 Chebyshev 混沌映射的星群初始化

KOA 初始化易受轨道偏心率 e 和轨道周期 T_0 的随机赋值影响, 导致初始星群的质量存在不确定性, 进而影响算法的寻优效率。此外, 随机初始化也无法有效平衡勘探与开发进程, 从而使初始星群的多样性欠缺, 导致在开发过程中过早收敛或勘探陷入局部最优^[29]。针对上述问题, 采用 Chebyshev 混沌映射改进星群初始化进程。Chebyshev 混沌映射生成的序列在定义区间上具有更好的均匀分布特性, 这有助于在优化过程中保持种群的多样性, 从而提高算法的搜索能力, 具体原理如下所述。

$$x_i^j = \cos(k \arccos(x_{i-1}^j)), \begin{cases} i=1, 2, \dots, n \\ j=1, 2, \dots, d \end{cases} \quad (6)$$

式中: x_i^j 和 x_{i-1}^j 分别表示 j 维度下的第 i 个和第 $i-1$ 个候选解, x_{i-1}^j 设定为 $[-1, 1]$ 内的随机值; k 表示控制参数; n 表示搜索空间中候选解的个数; d 表示待求问题维度。

将混沌映射产生的变量 x_i^j 关联到行星个体, 实现星群初始化。

$$P_{i,\text{up}}^j = P_{i,\text{low}}^j + x_i^j \times (P_{i,\text{up}}^j - P_{i,\text{low}}^j), \begin{cases} i=1, 2, \dots, n \\ j=1, 2, \dots, d \end{cases} \quad (7)$$

式中: $P_{i,\text{up}}^j$ 和 $P_{i,\text{low}}^j$ 分别表示 j 维度下行星 i 位置的

上、下限。

2.2 融合 Gaussian 变异的行星位置更新

另一方面, 为了避免算法陷入局部最优, 引入高斯变异算子 $G_{\text{aussian}}(\sigma)$ 更新星体位置。

$$P_{Gi}(t) = P_i(t)(1 + G_{\text{aussian}}(\sigma)) \quad (8)$$

式中: $P_{Gi}(t)$ 表示经高斯变异后行星 i 的位置; $P_i(t)$ 表示变异前行星 i 的位置。

综合考虑星体最佳位置适应度 $f_{\text{best}}(t)$ 、高斯变异最佳位置适应度 $f_{\text{Gbest}}(t)$ 与平均分布位置适应度 $f_{\text{mean}}(t)$, 提出一种星体位置变异更新规则。

$$P_{Gi,\text{new}}(t) = \begin{cases} P_{\text{Gbest}}(t), & \text{if } f_{\text{Gbest}}(t) = \min\{f_{\text{best}}(t), f_{\text{Gbest}}(t), f_{\text{mean}}(t)\} \\ P_{\text{best}}(t), & \text{if } f_{\text{best}}(t) = \min\{f_{\text{best}}(t), f_{\text{Gbest}}(t), f_{\text{mean}}(t)\} \\ P_i(t), & \text{else} \end{cases} \quad (9)$$

式中: $P_{Gi,\text{new}}(t)$ 表示由更新规则得到的行星 i 的位置; $P_{\text{Gbest}}(t)$ 表示高斯变异对应的星体位置; $P_{\text{best}}(t)$ 表示未变异对应的星体位置; $P_i(t)$ 表示 t 时刻行星 i 的位置。

通过式(9)计算变异更新后的星体位置始终为距离太阳最近的结果。将变异更新规则引入行星位置更新进程。

$$P_i(t+1) = P_{Gi,\text{new}}(t) \times U + (1-U) \times \left\{ \frac{P_{Gi,\text{new}}(t) + S(t) + P_a(t)}{3} + \delta \times \left(\frac{P_{Gi,\text{new}}(t) + S(t) + P_a(t)}{3} - P_b(t) \right) \right\} \quad (10)$$

式中: U 表示选择判据; $S(t)$ 表示 t 时刻的太阳位置; $P_a(t)$ 、 $P_b(t)$ 分别表示行星 a、b 的位置; δ 表示自适应因子。

利用 IKOA 优化 STAGN 超参数具体方法如下: 首先, 随机得到初始化 n 个超参数组合即 n 个候选解个数 $x_i(0) = \{x_i^\alpha(0), x_i^\beta(0), x_i^\gamma(0)\}$; 然后根据式(7)计算出 n 个 STAGN 预测模型各自的预测值, 按照式(25)计算各自适应度 $f_i(0)$, 确定当前行星最优位置 $P_i(0) = \{P_i^\alpha(0), P_i^\beta(0), P_i^\gamma(0)\}$, 按照式(10)确定下一代超参数组合 $P_i(1) = \{P_i^\alpha(1), P_i^\beta(1), P_i^\gamma(1)\}$, 重复上述步骤得到 t 代的超参数组合 $P_i(t) = \{P_i^\alpha(t), P_i^\beta(t), P_i^\gamma(t)\}$, 直至迭代次数达到预设值, 即得到最优的超参数组合 $(\alpha^*, \beta^*, \gamma^*)$ 。

利用改进后的算法优化模型超参数的具体流程如图 2 所示。

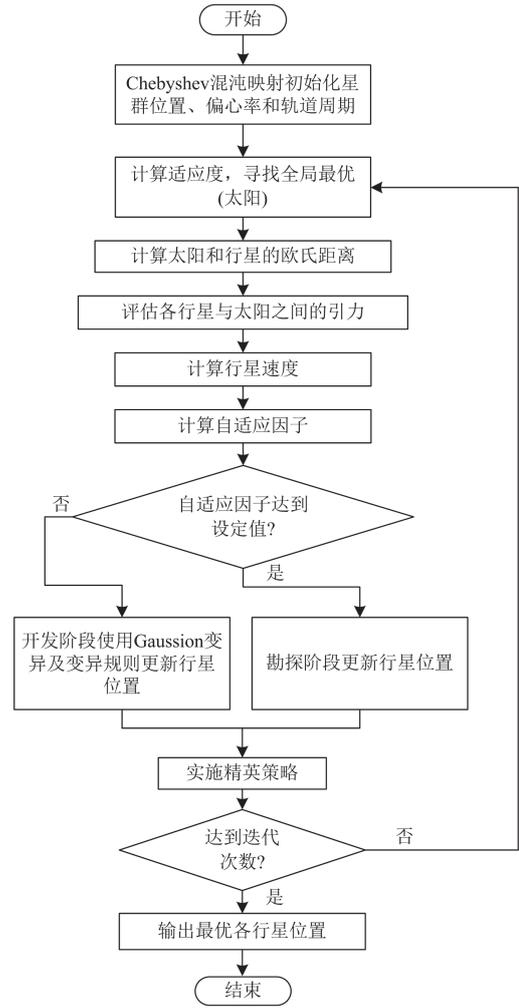


图 2 IKOA 超参数优化过程

Fig. 2 IKOA hyperparameter optimization process

3 基于风速矩阵梯度的误差修正切换策略

为了使功率预测模型精度进一步提高, 对误差进行修正, 误差 e_i 由功率实际值 y_i 与预测值 y'_i 作差得到, 如式(11)所示。

$$e_i = y_i - y'_i \quad (11)$$

3.1 基于显式交叉的自适应单元

考虑风速-功率关联 v^3 、风速切变 s 及功率 p 因素^[30], 建立误差 e 与各类因素的误差修正自适应单元。通过拟合泛函构建预测误差与影响因素的映射关系。

$$e(t) = f_r \{e(t-T), e(t-2T), \dots, e(t-q), v^3(t-T), v^3(t-2T), \dots, v^3(t-l), s(t-T), s(t-2T), \dots, s(t-m), p(t-T), p(t-2T), \dots, p(t-u)\} \quad (12)$$

式中: $e(t)$ 表示 t 时刻的误差预测值; f_r 为神经网络

络映射函数; $v^3(t-T)$ 、 $s(t-T)$ 、 $p(t-T)$ 分别表示风速-功率关联、风速切变、功率在 $t-T$ 时刻的值; q 、 l 、 m 、 u 为时间步长。

归一化消除量纲差异, 如式(13)所示。

$$x_n = \frac{x_i - x_{i\min}}{x_{i\max} - x_{i\min}} \quad (13)$$

式中: x_n 表示归一化后的值; x_i 、 $x_{i\max}$ 、 $x_{i\min}$ 分别表示数据集中的原始值及其最大、最小值。

归一化后的 e_n 与各影响因子关系可表示为

$$e_n = f_r(a_0 + a_1 D_1 + \dots + a_n D_n) \quad (14)$$

式中: a_0, a_1, \dots, a_n 表示自适应权重系数; D_1, D_2, \dots, D_n 表示各影响因素与误差间的非线性关联归一化值。同时考虑不同因素与误差的非线性关联, 进行显式交叉处理。

$$D_{ij} = \prod_{\substack{i,j=1 \\ i \neq j}}^n D_i D_j \quad (15)$$

式中, D_{ij} 表示交叉后的非线性关联值。

修正后的预测误差 e'_i 为

$$e'_i = f_r(a'_0 + a'_1 D_1 + \dots + a'_n D_n + a_{ij} D_{ij}) \quad (16)$$

式中, a'_0, a'_1, \dots, a'_n 和 a_{ij} 表示自适应权重系数。

3.2 考虑物理约束的深度学习单元

构建考虑物理约束的深度学习单元 STAGN-PC, 输入特征与 3.1 节一致, 将误差修正自适应单元损失函数 L_p 作为正则项嵌入深度学习单元的损失函数 L_d 得到总的损失函数 L 。

$$\begin{cases} L = L_d + \eta L_p \\ L_p = \frac{1}{N} \sum_{i=1}^N \sqrt{(e'_i - e_i)^2} \\ L_d = \frac{1}{N} \sum_{i=1}^N \sqrt{(e_i - e_i^*)^2} \end{cases} \quad (17)$$

式中: η 表示控制权重的正则化参数; N 表示样本数; e_i^* 表示深度学习单元的误差预测值。

3.3 基于矩阵梯度的误差修正单元切换策略

采用相邻时刻的风速差值与基准值的比值表征风速波动的方法, 忽略了其他时间步风速间的相关性。本文提出一种基于风速序列构造的 Toeplitz 矩阵(以下简称 T_{oc} 矩阵)梯度来表征风速波动。

根据连续的风速时序 $V = [v_1, v_2, \dots, v_N]$, 构造 T_{oc} 矩阵, 如式(18)所示。

$$T_{oc} = \begin{bmatrix} v_1 & v_2 & v_3 & \dots & v_N \\ v_2 & v_1 & v_2 & \dots & v_{N-1} \\ v_3 & v_2 & v_1 & \dots & v_{N-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ v_N & v_{N-1} & v_{N-2} & \dots & v_1 \end{bmatrix}_{(N \times N)} \quad (18)$$

T_{oc} 以 $v_1 - v_N$ 的序列构成首行与首列, 并沿对角线方向递推填充, 形成以 v_1 为主对角线, v_2 为邻近对角线的矩阵结构。

当风速序列滚动更新时, 下一时间步的 T_{oc} 矩阵为

$$T_{oc} = \begin{bmatrix} v_2 & v_3 & v_4 & \dots & v_{N+1} \\ v_3 & v_2 & v_3 & \dots & v_N \\ v_4 & v_3 & v_2 & \dots & v_{N-1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ v_{N+1} & v_N & v_{N-1} & \dots & v_2 \end{bmatrix}_{(N \times N)} \quad (19)$$

由式(19)可知: 随着新数据的连续引入, 更新后的 T_{oc} 矩阵中, 新的风速值 v_{N+1} 与 v_2, v_3, \dots, v_N 在行和列的矩阵分布都有新的对应关系。原有的 v_1 被移除, 确保了矩阵始终包含最近的数据点, 同时保持矩阵大小不变。这种滑动窗口机制使 T_{oc} 矩阵适于分析动态风速时序数据, 因其能持续更新数据, 并保留历史风速信息。因此, 在 T_{oc} 矩阵滚动更新过程中, 时间窗内的各风速的变化关系同时动态变动。

量化上述变化关系, 引入矩阵梯度的概念: 以滚动更新 T 步的 $T_{oc}(T)$ 为例, 将 $N \times N$ 的矩阵划分为 $1 \times N$ 的列向量形式, $T_{oc}(T) = [V_1, V_2, \dots, V_N]$, 横向梯度 G_h 表达式为

$$G_h = [V_1 - V_2, \frac{(V_1 - V_2) + (V_3 - V_2)}{2}, \dots, V_N - V_{N-1}] \quad (20)$$

由式(20)可知: G_h 首列由 T_{oc} 矩阵前两列作后向差分获得, G_h 末列由 T_{oc} 矩阵最后两列作前向差分获得, G_h 其余各列为 T_{oc} 中对应列与相邻两列作差分运算求和后的均值。

行向量形式 $T_{oc}(T) = [V_1^T, V_2^T, \dots, V_N^T]^T$, 以此类推, 纵向梯度 G_v 表达式为

$$G_v = [V_1^T - V_2^T, \frac{(V_1^T - V_2^T) + (V_3^T - V_2^T)}{2}, \dots, V_N^T - V_{N-1}^T]^T \quad (21)$$

矩阵梯度 G 表示为

$$G = \sum_{i=1}^N \sum_{j=1}^N (|G_h(i, j)| + |G_v(i, j)|) \quad (22)$$

式中, $G_h(i, j)$ 和 $G_v(i, j)$ 分别表示横向梯度和纵向

梯度第 i 行第 j 列的元素值。

以相邻时刻的矩阵梯度差值的归一化值 ΔG 作为风速波动程度的量化指标

$$\Delta G = \frac{G(t) - G(t-1)}{G_N} \quad (23)$$

式中: $G(t)$ 表示 t 时刻的梯度值; G_N 表示矩阵梯度的基准值。

在 ΔG 较大时, 自适应单元处理复杂非线性数据的局限性会影响预测精度, 而深度学习单元能更好地适应误差时序变化, 提供更精确的预测。因此, 当 ΔG 大于设定阈值时, 采用误差修正切换(error switching correction, ESC)策略切换到深度学习单元对误差序列进行预测。

误差修正模块通过上述两个修正单元进行修正, 并根据 T_{oc} 矩阵梯度设定的阈值切换运行, 最终将修正单元得到的误差预测值与风电功率初始预测值相加得到最终的预测结果。基于 IKOA-STAGN-ESC 的风电功率超短期预测模型结构如图 1 所示, 整体流程如图 3 所示。

4 算例分析

以东北地区某风电场为研究对象, 该风场装机容量为 22.5 MW, 选取该风场 2023 年数据, 采样率为 15 min, 将数据集划分为四季度子集, 各子集前 80% 作为训练集, 后 20% 作为测试集, 时间窗口设置为 16。使用平均绝对百分比误差 ε_1 和均方根误差 ε_2 作为评价指标。

$$\varepsilon_1 = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y_i - y'_i}{y_i} \right| \quad (24)$$

$$\varepsilon_2 = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (25)$$

4.1 STAGN 预测效果分析

为了验证空间卷积模块及时序双向门控模块的特征提取能力和预测性能, 以及注意力增强模块对预测精度的提升作用, 本研究通过对比实验, 采用 CNN-BiGRU(模型 4)、CNN-LSTM(模型 5)、BiGRU(模型 6)与本文模型(STAGN)进行功率预测, 结果如图 4 所示, 不同模型评价结果如表 1 所示, 各模型结构参数见附录 A。

由表 1 可知, 相较于模型 4、模型 5、模型 6, 本文模型 ε_1 分别降低 51.22%、57.58%、60.34%, ε_2 分别降低 53.71%、58.85%、61.90%。结果表明, 模型 4 利用空间卷积模块与时序双向门控模块提取输入特征的时空相关性, 预测误差水平低于模型 5 和模型 6。本文模型在模型 4 的基础上引入了注意力

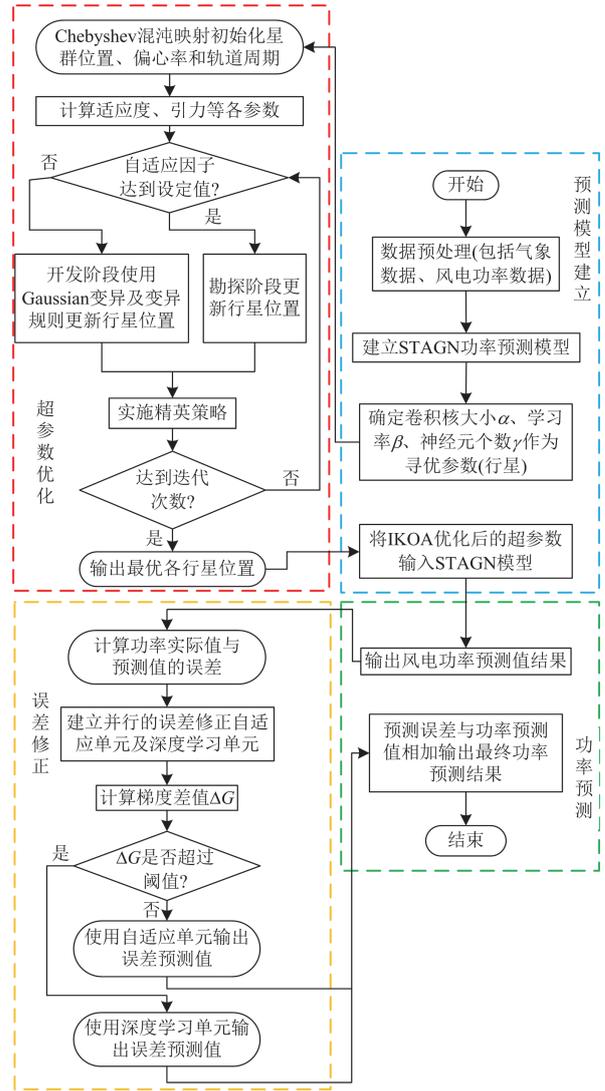


图 3 模型预测流程

Fig. 3 Model prediction process

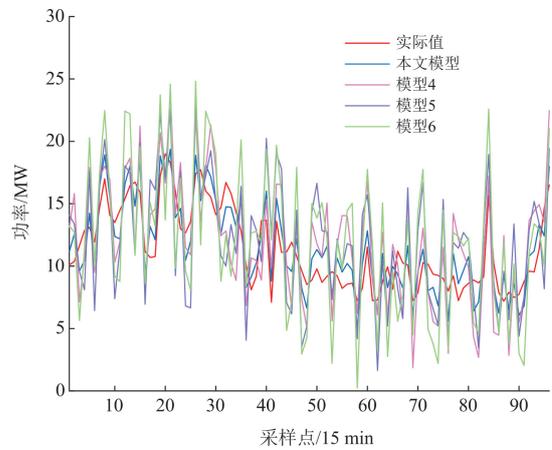


图 4 各模型预测结果对比

Fig. 4 Prediction results comparison of different models

表 1 本文模型与模型 4—模型 6 的评价指标对比

Table 1 Evaluation indicators comparison of this paper's model and model 4—model 6

模型	评价指标	
	$\varepsilon_1/\%$	ε_2/MW
本文模型	16.728 8	1.809 9
模型 4	34.293 3	3.910 2
模型 5	39.438 9	4.398 5
模型 6	42.182 5	4.749 8

模块增强对关键信息的关注程度, 进一步提高了模型预测的准确性。

4.2 IKOA 超参数优化

结合文献[31-33]并通过大量仿真, IKOA 种群数设置为 10, 超参数维度 $d=3$, 最大迭代次数设置为 100。超参数优化结果如表 2 所示。

表 2 超参数优化结果

Table 2 Hyperparameter optimization results

参数	搜索空间	数值
空间卷积模块卷积核大小 α	[5,10]	5
双向门控单元学习率 β	[0.001,0.01]	1.684×10^{-4}
双向门控单元神经元个数 γ	[50,60]	58

由于 STAGN 网络的预测精度很大程度上依赖模型内部超参数的设定, 为了验证 IKOA 的超参数优化性能, 采用 KOA 算法及麻雀搜索算法(SSA)、灰狼优化算法(GWO)进行超参数优化, 并与 IKOA 对比, 迭代收敛过程对应的适应度曲线如图 5 所示。结果表明, IKOA 在收敛速度与搜索能力方面均具有明显优势。

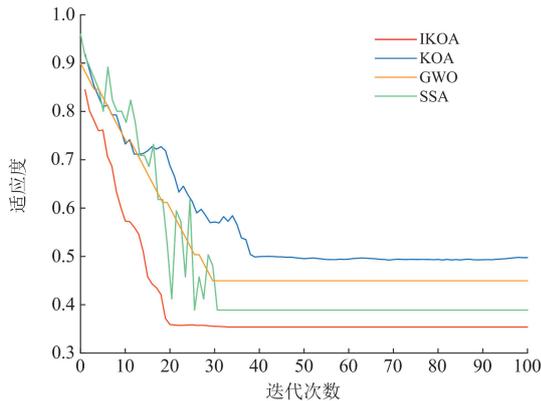


图 5 适应度曲线

Fig. 5 Fitness curve

当进行风电功率预测时, 预测模型输入前 4 h 的气象及风电功率数据, 滚动输出未来 4 h 的风电功率, 并通过滑动时间窗得到 24 h 的预测结果。将 IKOA-STAGN(本文模型)与 SSA-STAGN(模型 1)、

GWO-STAGN(模型 2)及 KOA-STAGN(模型 3)对比, 不同模型的预测结果如图 6 所示, 评价指标如表 3 所示。结果表明, IKOA 能够有效改善模型的预测精度和运算效率。

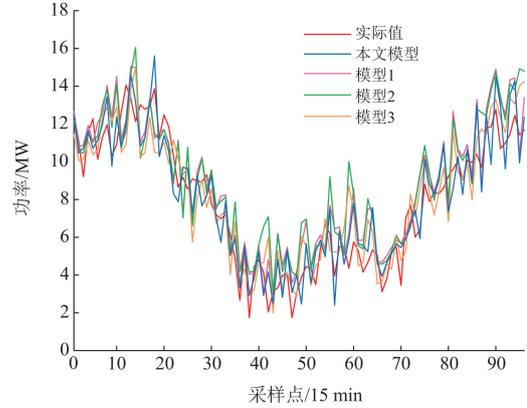


图 6 不同模型预测结果对比

Fig. 6 Prediction results comparison of different models

表 3 本文模型与模型 1—模型 3 的评价指标对比

Table 3 Evaluation indicators comparison of this paper's model and model 1—model 3

预测模型	评价指标		
	$\varepsilon_1/\%$	ε_2/MW	训练时间/s
本文模型	16.328 1	2.021 6	25
模型 1	18.151 7	4.414 7	40
模型 2	20.628 1	4.865 7	42
模型 3	27.872 3	4.874 7	62

注: 微型型号为 13th Gen Intel(R) Core(TM) i5-13500H CPU, 16 GB 内存。

4.3 误差修正效果分析

采用本文 IKOA-STAGN 模型对 2023 年 6 月份功率进行预测, 得到的各梯度差值下的误差分布如图 7 所示。

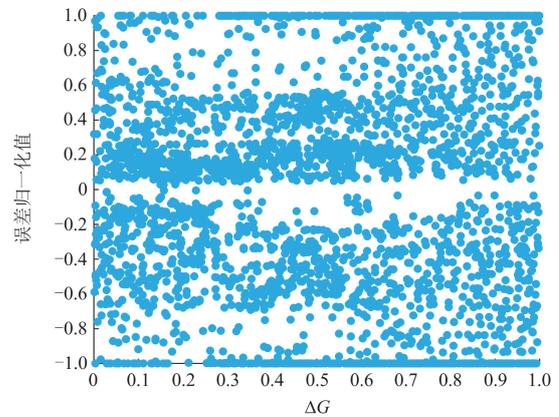


图 7 各梯度差值下误差分布

Fig. 7 Error distribution for each gradient difference

由图 7 可知,当 ΔG 较小时误差分布相对集中,功率预测模型准确性相对较高,当 ΔG 大于 0.6 时,误差分布变得较为均匀,表明风电功率预测的准确性较低,功率输出波动较大,预测误差增大。当 ΔG 过大时,误差修正自适应单元无法捕捉误差的剧烈变化,误差预测性能变差。对 ΔG 进行分析和设定,阈值设置 10%为取值步长,当 ΔG 小于设定阈值 K 时,使用自适应单元进行修正,反之,则切换到深度学习单元修正。

量化评价模型性能,分析设定不同阈值 K 下测试集功率预测的评价指标均方根误差(root mean square error, RMSE)如图 8 所示。

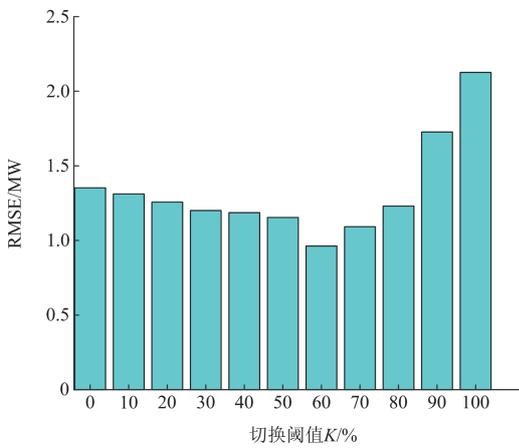


图 8 不同阈值下策略的评价指标
Fig. 8 Evaluation indicators of the strategy under different thresholds

当 $K = 0$ 时,表示仅使用深度学习单元进行误差修正;当 $K = 100\%$ 时,表示仅使用自适应单元进行误差修正;当 $K = 60\%$ 时 RMSE 最低,因此使用 $K = 60\%$ 作为误差修正单元的切换阈值。

自适应误差修正单元综合考虑多种影响因素与误差的非线性关联,但当短期内风速变化过大时难以适应风速的变化规律,导致误差修正效果过差;深度学习单元深度虽能挖掘风速时序变化规律,但单一的神经网络模型数据依赖性强,可解释性差。为了验证本文策略的误差修正效果,选用其他两种修正策略与本文策略进行对比分析,本文策略表示考虑误差修正切换策略的预测模型 IKOA-STAGN-ESC,策略 1 表示仅使用自适应单元误差修正的预测模型;策略 2 表示仅使用深度学习单元误差修正的预测模型,选取夏、冬季节典型时段(4 h),计算上述 3 种策略的功率实际值与预测值的差值,如图 9 所示。

该风场夏季风速波动平缓,不同策略的预测误差较为接近;冬季风速变化剧烈,各策略的预测误

差相差较大。为了便于分析误差修正单元切换策略的有效性,定义本文策略预测误差均小于其他两种策略的情况为有效修正。夏季样本误差有效修正占比 87.5%,冬季样本误差有效修正占比 68.75%。统计各季度测试集(样本数 11 520),有效修正占比分别为 82.36%、81.56%、81.01%、85.28%,虽然在个别采样点存在无效修正的情况,但本文策略的总体准确性显著高于其他策略,从而验证了误差修正切换策略的有效性。

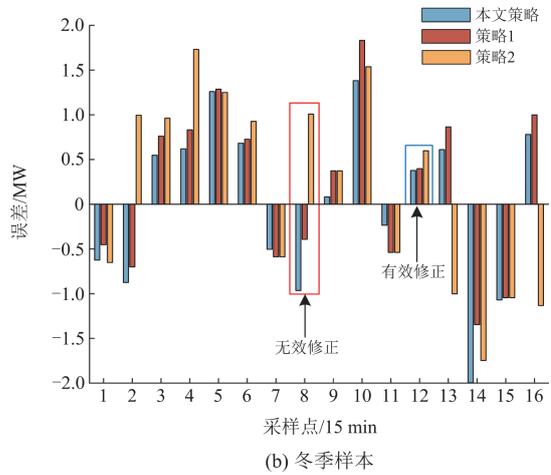
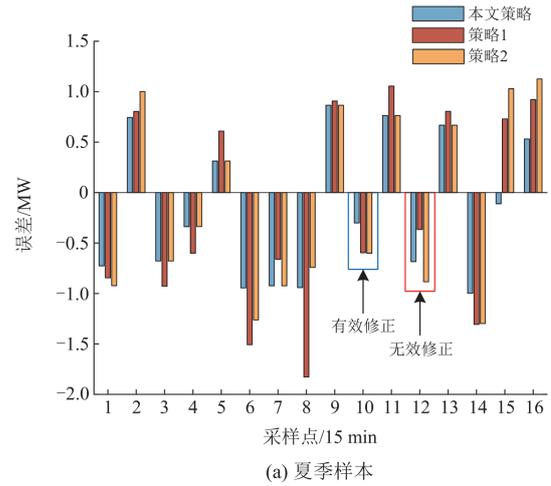


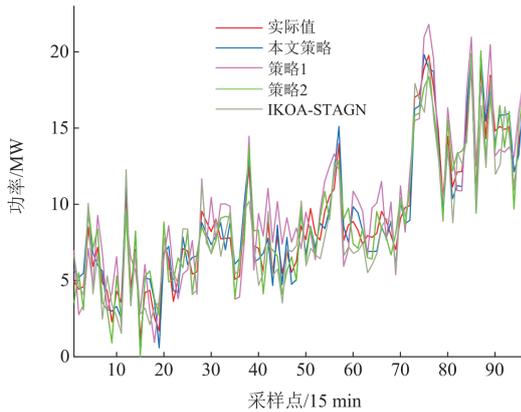
图 9 各策略误差对比

Fig. 9 Comparison of errors in each strategy

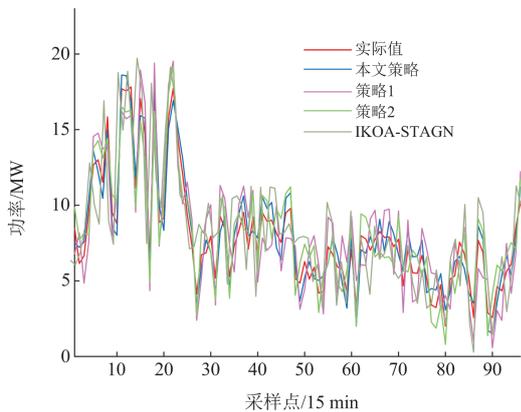
为了验证误差修正效果,对比分析 IKOA-STAGN 及不同误差修正策略,选取各季度典型日(5月15日、8月5日、10月11日、2月28日)进行风电功率预测,结果如图 10 所示,不同策略评价指标如表 4 所示。

结果表明,各策略相比未考虑误差修正的 IKOA-STAGN,预测精度均实现了一定程度的提

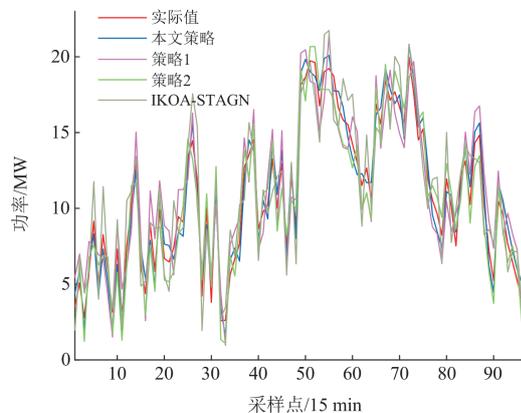
高。策略 1 采用自适应误差修正, 考虑多种影响因素与误差的非线性关联, 当短期风速波动过大或风速波动较为频繁时, 自适应单元难以及时获取风速时序波动相关特征, 导致预测误差偏高, 在季节更替时稳定性较差, 修正效果较差。策略 2 利用深度学习挖掘风速时序变化规律, 能够更加贴近实际风速变化, 尽管相较于策略 1 修正效果明显提高, 但该策略针对单一的误差深度学习单元数据依赖性较



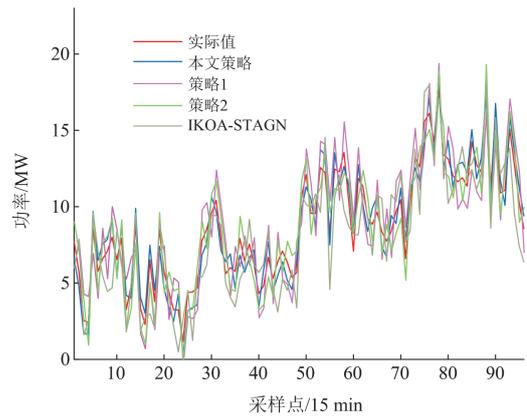
(a) 春季典型日预测结果



(b) 夏季典型日预测结果



(c) 秋季典型日预测结果



(d) 冬季典型日预测结果

图 10 东北风电场各季度典型日预测结果对比

Fig. 10 Comparison of typical daily prediction results for each quarter in northeast wind farm

表 4 东北风电场不同策略评价指标

Table 4 Evaluation indicators of different strategies in northeast wind farm

日期	策略	评价指标	
		$\varepsilon_1/\%$	ε_2/MW
5月15日	IKOA-STAGN	27.632 1	1.923 5
	策略 1	27.096 0	1.761 1
	策略 2	18.180 0	1.262 1
	本文策略	13.955 1	0.959 6
8月5日	IKOA-STAGN	25.701 3	1.975 8
	策略 1	25.443 9	1.887 7
	策略 2	20.521 7	1.354 3
	本文策略	14.937 1	0.965 4
10月11日	IKOA-STAGN	18.147 9	1.997 2
	策略 1	28.972 2	1.918 6
	策略 2	15.385 5	1.279 6
	本文策略	11.269 7	0.932 1
2月28日	IKOA-STAGN	22.206 0	1.810 6
	策略 1	26.184 9	1.797 1
	策略 2	18.640 7	1.266 9
	本文策略	13.648 1	0.949 1

强, 导致模型解释性较弱。本文策略利用梯度阈值灵活切换两种误差修正单元, 典型日评价指标均优于策略 1 和策略 2, 表明所提误差修正单元切换策略提高了预测模型的适应性, 具有更高的精度和稳定性。

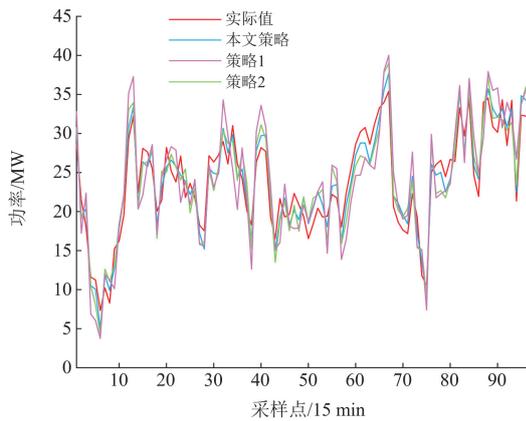
以云南某风电场(装机容量 40 MW)为例对本文策略进行泛化验证, 选取该风电场 2023 年实测数据, 数据处理与前文一致。各季度典型日(3 月 26 日、6 月 28 日、9 月 11 日、11 月 28 日)预测结果如图 11 所示, 不同策略评价指标如表 5 所示。结果表明, 本文策略预测精度高于其他策略。高原山地

风电场的地形风速多变，对模型的精细化和适应性要求更高。通过本文策略得到的预测结果仍具有较高的准确性，从而验证其泛化能力。

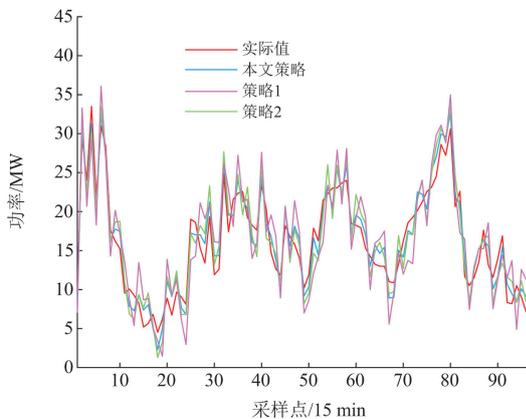
表 5 云南风电场不同策略评价指标

Table 5 Evaluation indicators of different strategies in Yunnan wind farm

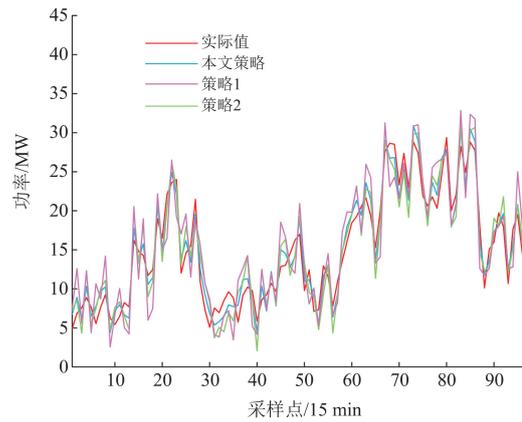
日期	策略	评价指标	
		$\varepsilon_1/\%$	ε_2/MW
3月26日	策略1	11.864 7	2.671 7
	策略2	16.463 0	3.869 1
	本文策略	8.289 2	1.839 4
6月28日	策略1	17.976 4	2.613 3
	策略2	25.576 1	3.755 0
	本文策略	13.193 4	1.827 4
9月11日	策略1	20.988 7	2.620 6
	策略2	27.460 9	3.600 3
	本文策略	13.937 0	1.691 8
11月28日	策略1	11.009 6	2.766 8
	策略2	17.737 1	4.665 2
	本文策略	6.566 9	1.620 3



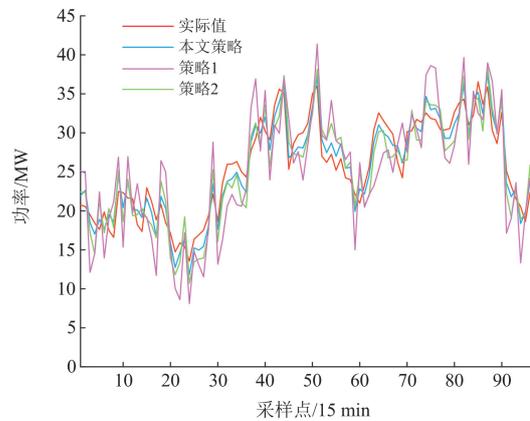
(a) 春季典型日预测结果



(b) 夏季典型日预测结果



(c) 秋季典型日预测结果



(d) 冬季典型日预测结果

图 11 云南风电场各季度典型日预测结果对比

Fig. 11 Comparison of typical daily prediction results for each quarter in Yunnan wind farm

5 结论

本文提出一种基于 IKOA 超参数优化的 STAGN 风电功率预测模型，并对预测结果进行误差修正，得出以下结论。

1) 利用空间卷积模块与时序双向门控模块提取输入特征的时空相关性，引入注意力模块增强模型对关键信息的关注程度，提高了预测的准确性。改进的开普勒算法引入混沌映射，改善了初始化种群质量；利用高斯变异及新的适应度规则，增强了算法全局寻优能力，从而有效改善模型的预测精度和运算效率。

2) 自适应误差修正单元综合考虑多种影响因素与误差的非线性关联，深度学习单元可以挖掘风速时序变化规律，基于风速矩阵梯度的误差修正切换策略提升了误差修正模块的适应性和稳定性，进一步提高了功率预测精度。

3) 所提模型可应用于实际风电场的规划运行, 通过误差修正策略进一步降低预测结果与计划出力曲线之间的偏差, 提高风电场预测精度, 避免经济损失, 提升风电参与新型电力市场调度的可控性与可靠性。另一方面, 研究发现预测模型在 Toeplitz 矩阵的步长设置可进一步改善预测效果, 因此可以探索根据模型性能或数据特征动态调整的自适应步长策略, 进而提高精细化模型对时间序列特征的提取能力, 并提升计算效率。

附录 A

表 A1 模型结构参数

Table A1 Model construction parameters

模型	结构参数
模型 4	采用 3 层卷积, 卷积核数量分别为 24、48、100, 池化层为平均池化, CNN 全连接层数为单层, 全连接层单元数为 200, 单隐藏层, 隐藏单元数为 58, 全连接层数为 1, 全连接层单元数为 150
模型 5	采用 3 层卷积, 卷积核数量分别为 24、48、100, 池化层为平均池化, CNN 全连接层数为单层, 全连接层单元数为 200; LSTM 单隐藏层, 隐藏单元数为 58, LSTM 全连接层数为 1, 全连接层单元数为 150
模型 6	单隐藏层, 隐藏单元数为 58, BiGRU 全连接层数为 1, 全连接层单元数为 150
本文模型	采用 3 层卷积, 卷积核数量分别为 24、48、100, 池化层为平均池化, CNN 全连接层数为单层, 全连接层单元数为 200, GRU 单隐藏层, 隐藏单元数为 58, BiGRU 全连接层数为 1, 全连接层单元数为 150; 注意力头数为 1, dropout 率为 0.2

参考文献

- [1] 杨茂, 张书天, 王勃. 基于因果正则化极限学习机的风电功率短期预测方法[J]. 电力系统保护与控制, 2024, 52(11): 127-136.
YANG Mao, ZHANG Shutian, WANG Bo. Short-term wind power forecasting method based on a causal regularized extreme learning machine[J]. Power System Protection and Control, 2024, 52(11): 127-136.
- [2] 王小明, 徐斌, 尹元亚, 等. 基于空间相关性与 Stacking 集成学习的风电功率预测方法[J]. 电力工程技术, 2024, 43(5): 224-232.
WANG Xiaoming, XU Bin, YIN Yuanya, et al. Wind power prediction method based on spatial correlation and Stacking ensemble learning[J]. Electric Power Engineering Technology, 2024, 43(5): 224-232.
- [3] 胡宇晗, 朱利鹏, 李佳勇, 等. 融合深度误差反馈学习和注意力机制的短期风电功率预测[J]. 电力系统保护与控制, 2024, 52(4): 100-108.
HU Yuhan, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. Power System Protection and Control, 2024, 52(4): 100-108.
- [4] 蔡昌春, 范靖浩, 李源佳, 等. 基于 TPA-MBLSTM 模型的超短期风电功率预测[J]. 电力科学与技术学报, 2024, 39(1): 47-56.
CAI Changchun, FAN Jinghao, LI Yuanjia, et al. Ultra-short-term wind power prediction based on TPA-MBLSTM model[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 47-56.
- [5] 杨国华, 祁鑫, 贾睿, 等. 基于 CEEMD-SE 的 CNN&LSTM-GRU 短期风电功率预测[J]. 中国电力, 2024, 57(2): 55-61.
YANG Guohua, QI Xin, JIA Rui, et al. Short-term wind power forecast based on CNN & LSTM-GRU model integrated with CEEMD-SE algorithm[J]. Electric Power, 2024, 57(2): 55-61.
- [6] PENG Z, PENG S, FU L, et al. A novel deep learning ensemble model with data denoising for short-term wind speed forecasting[J]. Energy Conversion and Management, 2020, 207(11): 519-524.
- [7] CHEN Y, ZHANG S, ZHANG W, et al. Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting[J]. Energy Conversion and Management, 2019, 18(5): 783-799.
- [8] 邹智, 吴铁洲, 张晓星, 等. 基于贝叶斯优化 CNN-BiGRU 混合神经网络的短期负荷预测[J]. 高电压技术, 2022, 48(10): 3935-3945.
ZOU Zhi, WU Tiezhou, ZHANG Xiaoxing, et al. Short-term load forecast based on Bayesian optimized CNN-BiGRU hybrid neural networks[J]. High Voltage Engineering, 2022, 48(10): 3935-3945.
- [9] 杨晶显, 张帅, 刘继春, 等. 基于 VMD 和双重注意力机制 LSTM 的短期光伏功率预测[J]. 电力系统自动化, 2021, 45(3): 174-182.
YANG Jingxian, ZHANG Shuai, LIU Jichun, et al. Short-term photovoltaic power prediction based on variational mode decomposition and long short-term memory with dual-stage attention mechanism[J]. Automation of Electric Power Systems, 2021, 45(3): 174-182.
- [10] 郭雪丽, 华大鹏, 包鹏宇, 等. 一种基于改进 VMD-PSO-CNN-LSTM 的短期电价预测方法[J]. 电力科学与技术学报, 2024, 39(2): 35-43.
GUO Xueli, HUA Dapeng, BAO Pengyu, et al. A short-term electricity price forecasting method based on improved VMD-PSO-CNN-LSTM[J]. Journal of Electric Power Science and Technology, 2024, 39(2): 35-43.
- [11] 郑睿程, 顾洁, 金之俭, 等. 数据驱动与预测误差驱动

- 融合的短期负荷预测输入变量选择方法研究[J]. 中国电机工程学报, 2020, 40(2): 487-500.
- ZHENG Ruicheng, GU Jie, JIN Zhijian, et al. Research on short-term load forecasting variable selection based on fusion of data driven method and forecast error driven method[J]. Proceedings of the CSEE, 2020, 40(2): 487-500.
- [12] 张涛, 朱瑞金, 扎西顿珠. 基于改进骨干差分进化算法优化 LSSVM 的短期光伏发电功率预测[J]. 热力发电, 2021, 50(5): 102-107.
- ZHANG Tao, ZHU Ruijin, ZHAXI Dunzhu. Short-term photovoltaic power generation forecasting based on improved backbone differential evolution algorithm optimizing LSSVM[J]. Thermal Power Generation, 2021, 50(5): 102-107.
- [13] 姚芳, 汤俊豪, 陈盛华, 等. 基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法[J]. 电力系统保护与控制, 2023, 51(16): 158-167.
- YAO Fang, TANG Junhao, CHEN Shenghua, et al. Charging load prediction method for electric vehicles based on an ISSA-CNN-GRU model[J]. Power System Protection and Control, 2023, 51(16): 158-167.
- [14] 王凌云, 王舟盼, 安晓, 等. 基于改进灰狼算法优化自适应相似日选取的小水电短期预测[J]. 科学技术与工程, 2021, 21(5): 1832-1839.
- WANG Lingyun, WANG Zhoupan, AN Xiao, et al. Short-term prediction of small hydropower based on adaptive similar day selection optimized by improved grey wolf algorithms[J]. Science Technology and Engineering, 2021, 21(5): 1832-1839.
- [15] 欧旭鹏, 任涛, 王玉鹏, 等. 基于改进麻雀搜索算法优化深度学习网络超参数的短期风电功率预测[J]. 智慧电力, 2023, 51(3): 31-38, 52.
- OU Xupeng, REN Tao, WANG Yupeng, et al. Short-term wind power prediction by optimizing deep learning network hyper-parameters based on ISSA[J]. Smart Power, 2023, 51(3): 31-38, 52.
- [16] 鲁迪, 王星华, 贺小平. 基于混合粒子群算法和多位鲁棒极限学习机的短期风速预测方法[J]. 电力系统保护与控制, 2019, 47(5): 115-122.
- LU Di, WANG Xinghua, HE Xiaoping. A short-term wind speed prediction method based on hybrid particle swarm algorithm and multicentered robust limit learning machine[J]. Power System Protection and Control, 2019, 47(5): 115-122.
- [17] 李崎勇, 张伟斌, 赵新哲, 等. 改进鲸鱼算法优化支持向量回归的光伏最大功率点跟踪[J]. 电工技术学报, 2021, 36(9): 1771-1781.
- LI Jiyong, ZHANG Weibin, ZHAO Xinzhe, et al. Improved whale algorithm optimized support vector regression for photovoltaic maximum power point tracking[J]. Transactions of China Electrotechnical Society, 2021, 36(9): 1771-1781.
- [18] 王维高, 魏云冰, 滕旭东. 基于 VMD-SSA-LSSVM 的短期风电预测[J]. 太阳能学报, 2023, 44(3): 204-211.
- WANG Weigao, WEI Yunbing, TENG Xudong. Short-term wind power forecasting based on VMD-SSA-LSSVM[J]. Acta Energetica Solaris Sinica, 2023, 44(3): 204-211.
- [19] 李大中, 李颖宇. 基于深度学习与误差修正的超短期风电功率预测[J]. 太阳能学报, 2021, 42(12): 200-205.
- LI Dazhong, LI Yingyu. Ultra-short-term wind power prediction based on deep learning and error correction[J]. Acta Energetica Solaris Sinica, 2021, 42(12): 200-205.
- [20] 叶林, 任成, 赵永宁, 等. 超短期风电功率预测误差数值特性分层分析方法[J]. 中国电机工程学报, 2016, 36(3): 692-700.
- YE Lin, REN Cheng, ZHAO Yongning, et al. Stratification analysis approach of numerical characteristics for ultra-short-term wind power forecasting error[J]. Proceedings of the CSEE, 2016, 36(3): 692-700.
- [21] 苏向敬, 宇海波, 符杨, 等. 基于 DALSTM 和联合分位数损失的海上风电功率概率预测[J]. 中国电力, 2023, 56(11): 10-19.
- SU Xiangjing, YU Haibo, FU Yang, et al. Probabilistic forecasting of offshore wind power based on dual-stage attentional LSTM and joint quantile loss function[J]. Electric Power, 2023, 56(11): 10-19.
- [22] LI C, TANG G, XUE X, et al. Short-term wind speed interval prediction based on ensemble GRU model[J]. IEEE Transactions Sustainable Energy, 2020, 11: 1370-1380.
- [23] 赵铁成, 谢丽蓉, 叶家豪. 基于误差修正的 NNA-ILSTM 短期风电功率预测[J]. 智慧电力, 2022, 50(1): 29-36.
- ZHAO Tiecheng, XIE Lirong, YE Jiahao. NNA-ILSTM short term wind power prediction based on error correction[J]. Smart Power, 2022, 50(1): 29-36.
- [24] 丁婷婷, 杨明, 于一潇, 等. 基于误差修正的短期风电功率集成预测方法[J]. 高电压技术, 2022, 48(2): 488-496.
- DING Tingting, YANG Ming, YU Yixiao, et al. Short-term wind power integration prediction method based on error correction[J]. High Voltage Engineering, 2022, 48(2): 488-496.
- [25] 王晨, 寇鹏, 王若谷, 等. 利用多空间尺度下时空相关性的点云分布多风机风速预测[J]. 电力系统自动化, 2021, 45(22): 65-73.
- WANG Chen, KOU Peng, WANG Ruogu, et al. Wind speed forecasting for multiple wind turbines with point

- cloud distribution using spatio-temporal correlation on multiple spatial scale[J]. *Automation of Electric Power Systems*, 2021, 45(22): 65-73.
- [26] 胡宇晗, 朱利鹏, 李佳勇, 等. 融合深度误差反馈学习和注意力机制的短期风电功率预测[J]. *电力系统保护与控制*, 2024, 52(4): 100-108.
- HU Yuhan, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. *Power System Protection and Control*, 2024, 52(4): 100-108.
- [27] 潘超, 李润宇, 蔡国伟, 等. 考虑风速属性约简聚类的组合预测模型[J]. *电网技术*, 2022, 46(4): 1355-1362.
- PAN Chao, LI Runyu, CAI Guowei, et al. Combined forecasting model considering wind speed attribute reduction and clustering[J]. *Power System Technology*, 2022, 46(4): 1355-1362.
- [28] ABDEL-BASSET M. Kepler optimization algorithm: a new metaheuristic algorithm inspired by Kepler's laws of planetary motion[J]. *Knowledge-based Systems*, 2023, 268.
- [29] HU Gang, GONG Changsheng, LI Xiuxiu, et al. CGKOA: an enhanced Kepler optimization algorithm for multi-domain optimization problems[J]. *Computer Methods in Applied Mechanics and Engineering*, 2024, 425.
- [30] 叶林, 杨丹萍, 赵永宁. 风电场风能资源评估的测量—关联—预测方法综述[J]. *电力系统自动化*, 2016, 40(3): 140-151.
- YE Lin, YANG Danping, ZHAO Yongning. Overview of wind resource measure-correlate-predict methods for wind farms[J]. *Automation of Electric Power Systems*, 2016, 40(3): 140-151.
- [31] 张文字, 张茜, 杨媛, 等. 基于改进 GWO-CV 优化的 K-调和均值聚类算法[J]. *统计与决策*, 2020, 36(16): 9-13.
- ZHANG Wenyu, ZHANG Xi, YANG Yuan, et al. K-harmonic mean clustering algorithm based on improved GWO-CV optimization[J]. *Statistics & Decision*, 2020, 36(16): 9-13.
- [32] 王典, 潘超, 鹿丽, 等. 计及风-光时序相关特性的源-储并网阶段式规划策略[J]. *东北电力大学学报*, 2020, 40(4): 1-10.
- WANG Dian, PAN Chao, LU Li, et al. Source-storage staged planning strategy considering wind-photovoltaic timing related characteristics[J]. *Journal of Northeast Electric Power University*, 2020, 40(4): 1-10.
- [33] ZHANG Hao, SUN Hanlei, KANG Le, et al. Prediction of health level of multiform lithium sulfur batteries based on incremental capacity analysis and an improved LSTM[J]. *Protection and Control of Modern Power Systems*, 2024, 9(2): 21-31.

收稿日期: 2024-07-22; 修回日期: 2024-08-25

作者简介:

潘超(1981—), 男, 博士, 教授, 研究方向为电力系统稳定与电磁兼容; E-mail: 31563018@qq.com

王超(1999—), 男, 通信作者, 硕士研究生, 研究方向为新能源发电并网。E-mail: 2387618195@qq.com

(编辑 张颖)