

基于多尺度熵-动态对齐融合法结合 AFGRU 的 储能调频指令预测

李志鹏¹, 姜楠², 孙国辉², 谢佳³, 崔磊⁴

(1. 西安热工研究院有限公司, 西安 710048; 2. 华能伊敏煤电有限公司, 内蒙古 呼伦贝尔 021000;
3. 西安石油大学, 西安 710065; 4. 华能日照电厂, 山东 日照 276800)

摘要:为提升电厂调频指令序列的预测精度,提出一种融合多尺度熵-动态对齐融合法(multi scale entropy dynamic alignment fusion, MSED AF)与改进神经网络的组合预测模型。该方法首先将原始序列经 VMD 分解为 6 个子序列(intrinsic mode function, IMF),进而采用创新的多尺度熵-动态对齐融合法(multi scale entropy dynamic alignment fusion, MSED AF)通过结合多尺度熵度量与动态时间规整的复合相似性计算,将规律性相似的子序列两两融合为 3 个综合分量(Fused);随后,设计自适应特征门控单元(adaptive feature gated recurrent unit, AFGRU)网络,其核心特点在于注意力机制和特征增强模块,对 3 个融合子序列并行预测并重构最终结果。基于内蒙古某电厂调频数据的实验表明:MSED AF-VMD-AFGRU 预测的 MAE 较标准 GRU 平均降低 90.14%。该组合模型通过物理规律引导的特征融合与自适应门控机制,显著增强了复杂调频场景的预测精确度,为电网 AGC 控制系统提供了高精度支撑。

关键词:多尺度熵-动态对齐融合;自适应特征门控单元;调频指令;预测;储能

Prediction of Energy Storage Frequency Regulation Commands Based on Multi-scale Entropy Dynamic Alignment Fusion Method Combined with AFGRU

LI Zhipeng¹, JIANG Nan², SUN Guohui², XIE Jia³, CUI Lei⁴

(1. Xi'an Thermal Power Research Institute Co., Ltd., Xi'an 710048, China; 2. Huaneng Yimin Coal and Electricity Co., Ltd., Inner Mongolia Hulunbuir 021000, China; 3. Xi'an University of Petroleum, Xi'an 710065, China; 4. Huaneng Rizhao Power Plant, Shandong Rizhao 276800, China)

Abstract: For improving the prediction accuracy of frequency regulation command sequences in power plants, a combined prediction model integrating multi scale entropy dynamic alignment fusion (MSED AF) and improved neural networks is proposed. This method firstly decomposes the original sequence into 6 subsequences (Intrinsic Mode Function, IMF) through VMD, and then uses the innovative Multi scale entropy dynamic alignment fusion method (MSED AF) to combine multi-scale entropy measurement with dynamic time regularization composite similarity calculation, and fuse the subsequences with similar regularity into 3 comprehensive components (Fused) pairwise. Then, an adaptive feature gated recurrent unit (AFGRU) network is designed, with its core features being attention mechanism and feature enhancement module, to predict and reconstruct the final results in parallel for the three fused subsequences. The experiments based on frequency regulation data from a power plant in Inner Mongolia show that the MAE predicted by MSED AF-VMD-AFGRU is reduced by an average of 90.14% compared to the standard GRU. This combination model significantly enhances the prediction accuracy of complex frequency modulation scenarios through feature fusion guided by physical laws and adaptive gating mechanism, providing high-

收稿日期:2025-07-22; 修回日期:2025-08-11

基金项目:陕西省教育厅专项科研计划(23JK0606);华能集团科技项目(HNKJ24-H30)。

Project Supported by Special Scientific Research Program of the Shaanxi Provincial Department of Education (23JK0606); Science and Technology Project of China Huaneng Group Co., Ltd. (HNKJ24-H30)。

precision support for the AGC control system of power grid.

Keywords: multi scale entropy-dynamic alignment fusion; adaptive feature gating unit; frequency regulation command; prediction; energy storage

0 引言

随着新能源大规模并网,电力系统频率波动问题日益凸显,储能系统凭借快速响应能力成为调频关键支撑^[1-2]。调频指令预测作为储能控制系统的前置环节,其精度直接影响机组调节效能与经济性。据统计,预测误差每降低1%,火储联合调频系统收益可提升2.3%。然而,调频指令序列具有显著的多尺度特性:既包含秒级随机波动(如负荷突变),又蕴含分钟级趋势变化(如新能源出力爬坡),传统预测方法难以兼顾不同时间尺度的动态特征。尤其在新型电力系统转型背景下,高比例可再生能源接入导致调频指令复杂度激增,2023年某省级电网调频指令峰谷差已达额定功率的48%,对预测模型提出更高要求。当前调频指令预测研究主要分为两类:1)信号分解-预测框架:采用变分模态分解(variational mode decomposition, VMD)、经验模态分解(empirical mode decomposition, EMD)等将原始序列分解为子序列分别预测。如Zhang等^[3]利用VMD-GRU模型分解5个子序列(intrinsic mode function, IMF)分量,但固定分解模式导致高频噪声与低频趋势混杂;Liu等提出EEMD-CNN-LSTM组合,仍面临子序列冗余问题(约40%分量信息重叠)^[4-7]。2)深度学习:通过TCN、Transformer等直接建模序列依赖关系。Zhang等设计时空Transformer预测区域调频需求^[8-10],但对阶跃型指令的预测误差仍超3%。

现有的方法存在在以下瓶颈:1)子序列冗余性:VMD等分解产生大量相似模式分量(如IMF₁-IMF₃均表征随机噪声),增加计算负担且引入误差耦合。2)尺度适应性缺失:标准递归网络(如gated recurrent unit, GRU)对高频/低频分量采用相同记忆机制,导致高频分量过平滑、低频分量欠拟合。

本文针对子序列冗余与尺度适应性缺失的挑战^[11-14],建立双引擎方法架构。主要包括:1)多尺度熵-动态对齐融合法(multi scale entropy dynamic alignment fusion, MSSEDAF)重构子序列处理范式,首次实现多尺度熵规律性度量与动态时间对齐的协同;规律性量化:基于多尺度样本熵解析子序列的复杂度分布谱,识别同源波动模式;动态对齐:采用动态时间规整技术校正时序相位偏移,精确匹配非

同步周期特征;能量驱动融合:依据分量能量贡献度自适应加权,将相似性子序列聚合为3个综合分量。2)自适应特征门控单元(adaptive feature gated recurrent unit, AFGRU)再造GRU网络结构,以应对多尺度特征建模瓶颈。主要包括:特征重要性感知:新增门控层自主学习分量预测价值权重,提升关键子序列(如低频趋势)的决策权重;时变记忆更新:根据输入序列瞬时梯度动态调节状态更新强度,实现高频分量快速响应与低频分量长程建模的协同优化。

本文通过MSSEDAF融合机制与AFGRU预测架构的协同,解决调频指令预测建模难题,为储能调频控制提供精准决策支撑。

1 基本原理

传统调频指令预测方法存在显著局限,单一GRU网络如图1所示。




图1 GRU预测模型
Fig. 1 GRU prediction model

因固定记忆机制难以协同建模多尺度特征,导致高频分量过平滑与低频分量滞后响应;经典VMD-GRU如图2所示。

虽通过信号分解缓解此问题,但其固定模态数输出易产生冗余子序列,且独立预测忽略分量间内在规律关联。本文提出三级优化框架如图3所示突破上述瓶颈:首先采用VMD生成6个本征模态函数(IMF);进而通过多尺度熵-动态对齐融合法(MSSEDAF)将相似性子序列凝练为3个综合分量;最后设计自适应特征门控单元(AFGRU)并行预测各分量,再把各分量叠加得到最终的预测结果。




图2 VMD-GRU 预测模型
Fig. 2 VMD-GRU prediction model




图3 MSSEDAF-AFGRU 预测模型
Fig. 3 MSSEDAF-AFGRU prediction model

1.1 变分模态分解方法

原始调频序列具有非规律性、非线性强等特征^[15-18],利用原始调频序列直接训练预测模型无法充分挖掘其内在蕴含的规律。因此,利用VMD将原始调频序列分解为多个规律性的子序列,来降低原始调频序列的波动性和非线性,提升预测准确度。VMD对原始数据序列的分解过程如下:

1)构建约束变分问题。将原始调频序列分解为 K 个模态(本文中 $K=6$),每个模态分解时均对应一个中心频率,目标函数为各个模态分量的估计带宽和最小,约束条件为所有模态分量和是原始序列,约束变分模型式为

$$\min \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$\text{s.t.} \sum_{k=1}^K u_k = f(t)$$

式中: u_k 为第 K 个模态函数; ω_k 为 u_k 的中心频率; ∂ 为狄拉克函数; $*$ 为卷积运算符; K 为预设的模态数目,本文取6; $f(t)$ 为调频信号。

2)求解约束变分问题。引入二次惩罚因子 α 和拉格朗日乘子 λ ,消除变分模型的约束条件,拉格朗日函数为

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (2)$$

3)利用交替方向乘子算法更新模态分量 u_k 及中心频率 ω_k ,公式为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \omega \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}$$

式中: $\hat{f}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{\lambda}(\omega)$ 为 $f(t)$ 、 $\hat{u}_i(t)$ 、 $\hat{\lambda}(t)$ 的傅里叶变换; ω 为对应的中心频率; n 迭代次数。

4)持续更新 u_k 及 ω_k ,直至满足要求。

1.2 多尺度熵-动态对齐融合法(MSEDAF)

1.2.1 标准化子序列

原始调频序列经过VMD分解变为了6个子序列 $IMF_1, IMF_2, IMF_3, \dots, IMF_6$,每个长度为 N (即每秒采样一次,共 N 个点)。令 $IMF_i = [x_i^{(1)}, x_i^{(2)}, x_i^{(3)}, \dots, x_i^{(N)}]$, i 代表1到6的任意值。以下步骤均以 IMF_i 代表任意子序列。

首先标准化每个子序列,每个子序列被标准化为零均值和单位方差,公式为

$$\tilde{x}_i^{(t)} = \frac{x_i^{(t)} - \mu_i}{\sigma_i}, \quad t = 1, 2, \dots, N \quad (4)$$

式中: μ_i 是第 i 个子序列的均值; σ_i 是第 i 个子序列的标准差。

标准化后的序列为 $\widehat{IMF}_k = [\tilde{x}_k^{(1)}, \tilde{x}_k^{(2)}, \dots, \tilde{x}_k^{(N)}]$ 。

1.2.2 计算多尺度动态相似性

对于任意两个标准化子序列 $\widehat{IMF}_k$ 和 $\widehat{IMF}_j$,定义它们的“多尺度动态相似性” $S(i, j)$ 。该度量结合了

多尺度熵(MSE)和 DTW 距离,以评估不同时间尺度上的规律性相似性,公式为

$$S(i,j)=\exp\left(-\frac{D_{\text{composite}}(i,j)}{\gamma}\right) \quad (5)$$

式中, $D_{\text{composite}}(i,j)$ 是复合距离,融合了多尺度熵距离和 DTW 距离。

$$D_{\text{composite}}(i,j)=\alpha D_{\text{MSE}}(i,j)+(1-\alpha)D_{\text{DTW}}(i,j) \quad (6)$$

式中: $\alpha=0.6$ 是权重系数, α 通过网格搜索优化确定,在验证集上评估 $\alpha \in [0.1, 0.9]$ 对融合分量规律性(样本熵均值)及预测误差(MAE)的影响,实验表明 $\alpha=0.6$ 时,二者达成最优权衡,见表 1,体现对多尺度熵主导规律性匹配的侧重,同时保留 DTW 对相位偏移的校正能力; $D_{\text{MSE}}(i,j)$ 是多尺度熵距离; $D_{\text{DTW}}(i,j)$ 是动态时间规整距离,公式为

$$D_{\text{MSE}}(i,j)=\sqrt{\sum_{s \in S} (\text{MSE}_s(i)-\text{MSE}_s(j))^2} \quad (7)$$

表 1 权重系数 α 的敏感性分析

Table 1 Sensitivity analysis of weighting coefficient α

α 值	样本熵均值	重构序列绝对平均误差
0.4	0.81	0.17
0.5	0.82	0.12
0.6	0.71	0.09
0.7	0.73	0.10
0.8	0.73	0.11

$\text{MSE}_s(i)/\text{MSE}_s(j)$ 是第 i/j 个子序列在尺度 S 下的样本熵。尺度因子集合为 $S=[1, 2, \dots, 5]$

$$D_{\text{DTW}}(i,j)=\min_{p \in \sum_{(t,s) \in P}} \left| \hat{x}_i^{(t)} - \tilde{x}_j^{(s)} \right| \quad (8)$$

式中, P 是所有可能的 DTW 路径集合。路径 P 是序列索引对 (t, s) 的列表,满足边界和单调性约束。

$$\gamma = \frac{1}{15} \sum_{1 \leq i < j \leq 6} D_{\text{composite}}(i,j) \quad (9)$$

1.2.3 配对选择

计算所有可能对 (i, j) (其中 $i < j$) 的相似性得分 $S(i, j)$, 选择相似性最大的对进行融合,公式为

$$(i^*, j^*) = \arg \max_{i,j} S(i,j) \quad (10)$$

1.2.4 融合子序列

融合采用自适应能量加权,确保高能量子序列(代表更强信号成分)在融合中占主导,公式为

$$\text{Fused}_0 = w_i x_{i^*} + w_j x_{j^*}, \quad t=1, 2, \dots, N \quad (11)$$

其中权重基于能量比例,公式为

$$w_i = \frac{E_i}{E_i + E_j}, \quad w_j = \frac{E_j}{E_i + E_j} \quad (12)$$

式中: $E_i = \sum_{t=1}^N (x_{i^*}^{(t)})^2$ 是第 i^* 个子序列的能量;

$E_j = \sum_{t=1}^N (x_{j^*}^{(t)})^2$ 是第 j^* 个子序列的能量。

融合后,新序列 Fused_1 替换原始 IMF_{i^*} 和 IMF_{j^*} 。

1.2.5 剩余综合分量的生成

接下来从剩余的 4 个序列中重复式(5)–(11)生成 Fused_2 , 然后再把剩余的 2 个序列依据式(11)–(12)进行融合生产 Fused_3 。

此时 6 个子序列 $\text{IMF}_1, \text{IMF}_2, \text{IMF}_3, \dots, \text{IMF}_6$ 经过式(4)–(11)就变为了 3 个综合分量 $\text{Fused}_1, \text{Fused}_2, \text{Fused}_3$, 接下来就要把这 3 个综合分量放入 AFGRU 中进行预测, AFGRU 是 GRU 的改进网络, 本文接下来先介绍 GRU 网络。

1.3 门控循环单元(GRU)

门控循环单元(GRU)通过门控机制有效捕捉时序依赖关系,其计算流程如下^[19–20]:

1)重置门(reset gate)决定历史状态的遗忘程度

$$r_t = \sigma[W_r(h_{t-1}, x_t)] \quad (13)$$

式中: r_t 为 t 时刻重置门的输出向量; σ 是 sigmoid 激活函数; W_r 重置门的可训练权重矩阵; h_{t-1} 是 $t-1$ 时刻的隐藏状态向量; x_t 是 t 时刻的输入特征向量。

2)更新门(update gate)调节新旧状态融合比例

$$z_t = \sigma[W_z(h_{t-1}, x_t)] \quad (14)$$

式中: z_t 是 t 时刻更新门的输出向量; W_z 是更新门的可训练权重矩阵。

3)候选隐藏状态生成

$$\tilde{h}_t = \tanh[W(h_t \odot h_{t-1}, x_t)] \quad (15)$$

式中: $\tilde{h}_t$ 是 t 时刻的候选隐藏状态向量; $\tanh$ 是双曲正切激活函数; W 候选状态的可训练权重矩阵; $\odot$ 逐元素乘法(Hadamard 积); $r_t \odot h_{t-1}$ 重置门控制的历史状态过滤。

4)最终隐藏状态更新

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (16)$$

历史状态继承分量,当前状态更新分量。GRU 的网络结构如图 4 所示。

现有 GRU 网络因固定门控机制难以适应调频指令的多尺度特性^[21–25]: 高频分量预测易受随机噪声干扰,低频趋势响应存在滞后现象。为此,提出自适应特征门控单元(AFGRU),通过特征重要性加权与时变记忆更新机制,实现多尺度特征的协同优化预测。




图4 GRU网络结构
Fig. 4 GRU network structure

1.4 自适应特征门控单元

在标准重置门中引入输入特征的瞬时梯度,增强对突变特征的感知能力。

$$r_t = \sigma[W_r(h_{t-1}, x_t) + V_r \Gamma_t + b_r] \quad (17)$$

式中: $\Gamma_t = \frac{|x_t - x_{t-1}|}{\Delta t}$ 是时域梯度因子; Δt 为采样间隔,本文中 $\Delta t = 1$ s; V_r 为梯度权重矩阵; b_r 为偏置项; σ 是 Sigmoid 激活函数,确保输出在 $[0, 1]$ 范围内。

对标准重置门的改进作用是当调频指令突变时 Γ_t 增大, r_t 趋近于 0 强制遗忘历史状态,避免低频分量惯性影响。

接下来改进 GRU 的更新机制,使其自动适应不同时间序列变化特征:

$$\begin{aligned} z_t &= \sigma[W_z(\tilde{x}_t; h_{t-1}) + \alpha_t] \\ r_t &= \sigma[W_r(\tilde{x}_t; h_{t-1}) + \alpha_t] \\ \tilde{h}_t &= \tanh[W_h(r_t \odot h_{t-1}; \alpha_t)] \\ h_t &= (1 - \alpha_t) \odot h_{t-1} + \alpha_t \odot \tilde{h}_t \end{aligned} \quad (18)$$

式中新增加的自适应因子公式为:

$$\alpha_t = \lambda z_t + (1 - \lambda) \times \arg(|x_t - x_{t-1}|)$$

式中, $\lambda = 0.5$, 为可学习参数。

改进的意义在于当输入变化剧烈时(综合分量规律性弱),增大 α_t 加速更新。当输入变化平缓时(综合分量规律性强),减小 α_t 保持长期记忆。

2 预测流程

1) 将原始调频序列 $[x_1, x_2, x_3, \dots, x_N]$ 使用 VMD 分解为 6 组子序列 $IMF_1, IMF_2, IMF_3, \dots, IMF_6$ 。

2) 对这 6 组子序列使用式(4)-(11)融合为 3 个综合分量 $Fused_1, Fused_2, Fused_3$ 。

3) 对 GRU 网络的重置门中引入输入特性的瞬时速度,对 GRU 的更新机制引入自适应因子。

4) 把 3 个综合分量 $Fused_1, Fused_2, Fused_3$ 放入改进后的 GRU—AFGRU 中进行预测,得到预测结果。整个流程如图 5 所示。




图5 MSSEDAF-AFGRU的预测流程图
Fig. 5 Prediction flowchart of MSSEDAF-AFGRU

3 调频指令预测预测试验

为了验证基于 MSSEDAF-VMD-AFGRU 组合预测模型的调频指令预测能力,本文对内蒙古某电厂调频指令数据进行试验研究。案例 1 选取 2025 年 1 月 10 日每隔 2 s 获取一次调频指令数据,共计 751 个数据。调频序列分为训练集和测试集。因此,选择 671 个数据样本来训练预测模型;接下来的 80 个数据用于测试所提出模型的性能,如图 6 所示。案例 2 选取 2025 年 1 月 11 日 4:00 开始每隔 2 s 获取一次调频指令数据,共计 287 个数据。调频序列分为训练集和测试集。因此,选择 228 个数据样本来训练预测模型;接下来的 59 个数据用于测试所提出模型的性能,如图 7 所示。




图6 案例一原始调频序列
Fig. 6 Case 1-original FM sequence




图7 案例2原始调频序列
Fig. 7 Case 2-original FM sequence

本文选用均方根误差(root mean square error, RMSE)、绝对平均误差(mean absolute error, MAE)、相对百分误差绝对平均值(mean absolute relative percentage error, MAPE)作为评价指标。当这些指标越小时,表示预测模型的预测误差越小,其性能越佳。

评价指标数学表达式为

$$\text{RMSE} = \left(\frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2 \right)^{\frac{1}{2}} \quad (19)$$

$$\text{MAE} = \frac{1}{N} \sum_{n=1}^N |y_n - \hat{y}_n| \quad (20)$$

$$\text{MAPE} = \frac{1}{N} \sum_{n=1}^N \left| \frac{y_n - \hat{y}_n}{y_n} \right| \times 100\% \quad (21)$$

为了验证所提出模型的性能,通过试验来进一步评估所提出的组合模型。包含在组合模型中的单个模型(即 GRU,AFGRU)称为基准模型,用来与组合模型进行比较。表 2 显示了不同模型的预测误差系数。

表2 3种模型的预测误差系数
Table 2 Prediction error coefficients of three models

案例	评测指标	GRU	AFGRU	MSedAF-VMD-AFGRU
案例1	RMSE	1.25	0.52	0.04
	MAE	0.84	0.61	0.07
	MAPE	15.87	7.96	0.49
案例2	RMSE	0.92	0.51	0.03
	MAE	0.79	0.52	0.09
	MAPE	17.21	8.34	0.62

从表 2 可以明显的看出误差系数随着模型结构的提升而降低,即所建立模型误差系数最小,单一的 GRU 模型误差系数最大。表 2 所示,当与其他所有的基准模型对比时,MSedAF-VMD-AFGRU 具有最小的误差系数。说明了所建立的模型具有

最佳的预测结果。例如,可以从表 2 得出以上结论,其中案例 1 预测的 RMSE 分别减少了 96.80%、92.31%,MAE 分别减少了 91.67%、88.52%,MAPE 分别减少了 96.91%、93.84%。案例 2 预测的 RMSE 分别减少了 96.74%、94.12%,MAE 分别减少了 88.61%、82.69%,MAPE 分别减少了 96.40%、92.57%。这说明相比 GRU 网络和 AFGRU 网络,MSedAF 融合后的综合分量更能体现原始序列的内在规律,从而提高了预测精度。AFGRU 与单个 GRU 模型相比,AFGRU 具有令人满意的预测性能,如表 2 中案例 1 的 MAPE 值减少 49.84%,案例 2 的 MAPE 值减少了 51.54%,这说明了 AFGRU 通过特征重要性加权和时变记忆更新机制,有效解决了传统 GRU 在复杂时间序列预测中的不足,显著提高了预测精度。

图 8-9 显示了不同模型的预测结果,MAPE、MAE 和 RMSE 是应用于所有模型的评测指标。从图 8-9 中可以明显的看出预测本文所建立的模型与原始数据的拟合程度最好。




图8 案例1 3组模型预测结果对比
Fig. 8 Comparison of prediction results of three models in case 1




图9 案例2 3组模型预测结果对比
Fig. 9 Comparison of prediction results of three models in case 2

为验证模型工程适用性,在配备英特尔 i7-13700H 处理器及 NVIDIA RTX 4050 的硬件环境下,测试 MSedAF-AFGRU 全流程计算耗时与其他现有模型的训练耗时对比,如表 3 所示。

表3 模型计算效率对比

Table 3 Comparison of model computation efficiency

模型	训练时间/min	单步预测 耗时/ms	是否满足 2 s实时
标准GRU	9.5	105	是
VMD-GRU	22	530	是
Transformer	41	1 800	否
MSEDAF-AFGRU	18	310	是

结果显示,MSEDAF-AFGRU模型以310 ms单步预测耗时显著优于对比模型,满足实时控制需求。其训练耗时18 min(可接受离线成本),并在电厂边缘设备实现72 h零延迟部署,为储能调频提供高精度低延迟决策支撑。

4 结语

本文针对储能调频指令序列多尺度特性显著、传统预测方法难以兼顾高频随机波动与低频趋势变化的难题提出了一种基于多尺度熵-动态对齐融合法(MSEDAF)-自适应特征门控单元(AFGRU)的组合预测模型。基于内蒙古电厂调频数据的实验结果总结如下:1)所建立的MSEDAF-AFGRU模型与基准模型(GRU、AFGRU)相比具有最优性能表明该模型能精准捕捉调频指令的多尺度动态特征。2)MSEDAF融合机制有效解决了子序列冗余问题,通过多尺度熵规律性度量与动态时间规整的协同,将6个VMD子序列凝练为3个综合分量,消除信息重叠,显著提升特征表达效率。3)AFGRU网络创新通过双重改进优化预测能力:重置门引入瞬时梯度因子,增强对突变指令的响应;更新门嵌入自适应因子,动态调节记忆强度。4)计算效率高完美匹配工程应用。

总之,MSEDAF-AFGRU模型通过物理规律引导的特征融合耦合自适应门控机制优化为储能调频控制系统提供了高精度决策支撑,可推广至高比例新能源电网的稳定性优化场景。

参考文献

[1] 黄策,燕云飞,沈迎,等. 超容储能辅助火电机组调频的电气问题研究[J]. 电气技术,2022,23(8):103-108.
HUANG Ce, YAN Yunfei, SHEN Ying, et al. Research on electrical issues of frequency regulation of thermal power units assisted by super capacity energy storage [J]. Electrical Technology, 2022, 23 (8):103-108.

[2] 殷悦,孙钢虎,兀鹏越,等. 混合储能调频工程经济性提升策略研究及应用[J]. 热力发电, 2024, 53(10):81-89.
YIN Yue, SUN Ganghu, WUPengyue, et al. Research and application of economic enhancement strategies for hybrid

energy storage frequency regulation engineering [J]. Thermal Power Generation, 2024, 53 (10):81-89.

[3] 张江广,桂成中,段志,等. 基于VMD-GRU-DTW组合模型的在役桥梁健康状态预测预警技术[J]. 防灾科技学院学报,2025,27(1):31-40.
ZHANG Jiangguang, GUI chengzhong, DUAN Zhi; et al. Prediction and early warning technology for the health status of in-service bridges based on VMD-GRU-DTW combination model [J]. Journal of Disaster Prevention Science and Technology College, 2025, 27 (1):31-40.

[4] 刘航源,陈伟涛,李远耀,等. 基于EEMD-CNN-LSTM的新型综合模型在滑坡位移预测中的应用[J]. 地质力学学报,2024,30(4):633-646.
LIU Hangyuan, CHEN Weitao, LI Yuanyao, et al. Application of a new comprehensive model based on EEMD-CNN-LSTM in landslide displacement prediction [J]. Journal of Geomechanics, 2024, 30 (4):633-646.

[5] 徐冬梅,廖安栋,王文川. 基于VMD-EEMD-CNN-LSTM混合模型的月径流预测[J]. 水利规划与设计,2023(7):57-63.
XU Dongmei, LIAO Andong, WANG Wenchuan, et al. Monthly runoff prediction based on VMD-EEMD-CNN-LSTM hybrid model [J]. Water Resources Planning and Design, 2023 (7):57-63.

[6] 王凤,尚若冰. 基于EEMD-CNN-LSTM的短期风电功率预测方法:CN115510739a [P]. 2022-12-23.

[7] 方明宽,宁静,陈春俊. 高速列车横向蛇行失稳的EEMD-CNN-LSTM预测方法[J]. 中国测试,2021,47(7):79-83.
FANG Mingkuan, NING Jing; CHEN Chunjun. EEMD-CNN-LSTM prediction method for lateral instability of high-speed trains [J]. China Test, 2021, 47 (7):79-83.

[8] 夏天,杨超,宋进良,等. 基于动态事件触发复合输出一致性的直流微网电池储能系统分布式控制策略[J]. 电力电容器与无功补偿, 2025,46(2):44-52.
XIA Tian, YANG Chao, SONG Jinliang, et al. Distributed control strategy for battery energy storage system in DC microgrid based on dynamic event-triggered composite output consistency[J]. Power Capacitor & Reactive Power Compensation, 2025, 46(2):44-52.

[9] 奚增辉,王卫斌,陆嘉铭. 运用电力大数据构建企业污染指数及监测分析[J]. 西安工程大学学报2024,38(6):83-89.
XI Zenghui, WANG Weibin, LU Jiaming, Constructing enterprise pollution index and monitoring analysis using electricity big data[J]. Journal of Xi'an Polytechnic University,2024,38(6):83-89.

[10] 孟伟,俞斌,白隆,等. 基于STGCN-Transformer的短期电力净负荷预测[J]. 中国测试,2025,51(6):160-169.
MENG Wei, YU Bin, BAI Long, et al. Wait short term electricity net load forecasting based on STGCN transform-

- er[J]. China Test, 2025, 51(6):160-169
- [11]张启龙, 陈湘萍. 考虑风电消纳多向量流系统的遗传优化方法[J]. 电测与仪表, 2023, 60(3):115-121.
Zhang Qilong, Chen Xiangping. Genetic optimization method for multi-vector flow system considering wind power consumption[J]. Electrical Measurement & Instrumentation, 2023, 60(3):115-121.
- [12]董明, 李晓枫, 杨章, 等. 基于数据驱动的分布式光伏发电功率预测方法研究进展[J]. 电网与清洁能源, 2024, 40(1):8-17.
DONG Ming, LI Xiaofeng, YANG Zhang, et al. Research progress on data-driven prediction methods for distributed photovoltaic power generation [J]. Power System and Clean Energy, 2024, 40(1):8-17.
- [13]邓韦斯, 卢斯煜, 刘显茁, 等. 基于相空间重构和BiLSTM的风电功率短期预测[J]. 广东电力, 2023, 36(7):22-30.
DENG Weisi, LU Siyu, LIU Xianzhuo, et al. Short term wind power prediction based on phase space reconstruction and BiLSTM [J]. Guangdong Electric Power, 2023, 36(7):22-30
- [14]苏华英, 林晨, 张俨, 等. 基于改进AP聚类和双重注意力机制的区域级新能源超短期出力预测方法[J]. 广东电力, 2025, 38(3):8-17.
SU Huaying, LIN Chen, ZHANG Yan, et al. Regional level ultra short term output prediction method for new energy based on improved AP clustering and dual attention mechanism [J]. Guangdong Electric Power, 2025, 38(3):8-17
- [15]LIU B, ZHAO J B, HUANG Q, et al. Nonlinear virtual inertia control of WTGs for enhancing primary frequency response and suppressing drivetrain torsional oscillations[J]. IEEE Transactions on Power Systems, 2021, 36(5):4125-4136.
- [16]PU D G, YUE Z, TIM G, et al. Resilient secondary voltage control of islanded microgrids: an eskbf-based distributed fast terminal sliding mode control approach[J]. IEEE Transactions on Power Systems, 2020, 35(3):2319-2331.
- [17]DANNY O, SERGIO M. A simplified electro-mechanical model of a DFIG-based wind turbine for primary frequency control studies[J]. IEEE Latin America Transactions, 2016, 14(8):3600-3608.
- [18]LEE J, JANG G, MULJADI E, et al. Stable short-term frequency support using adaptive gains for a DFIG-based wind power plant[J]. IEEE Transactions on Energy Conversion, 2016, 31(3):1068-1080.
- [19]李志鹏, 张宇翼, 马益文, 等. 一种基于VMD分解与交换法的储能调频指令预测方法及系统: CN120222418a [P]. 2025-06-27.
- [20]李志鹏, 王小辉, 康祯, 等. 一种储能调频指令预测方法及系统: CN120165407a [P]. 2025-06-17.
- [21]朱海南, 李丰硕, 孙华忠, 等. 基于改进 AlexNet-GRU 深度学习网络的配电网短期负荷预测方法[J]. 电力电容器与无功补偿, 2023, 44(4):48-54.
ZHU Hainan, LI Fengshuo, SUN Huazhong, et al. Short-term load forecasting method for distribution network based on improved AlexNet-GRU deep learning network [J]. Electric Power Capacitors and Reactive Power Compensation, 2023, 44(4):48-54.
- [22]许道林, 谢兵, 伍毅, 等. 基于多层双向递归神经网络的短期电力负荷预测[J]. 电力电容器与无功补偿, 2022, 43(2):96-104.
XU Daolin, XIE Bing, WU Yi, et al. Short-term power load forecasting based on multi-layer bidirectional recurrent neural network [J]. Electric Power Capacitors and Reactive Power Compensation, 2022, 43(2):96-104.
- [23]吴昌兵, 李志鹏, 兀鹏越, 等. 一种超级电容耦合锂电池的储能调频控制方法及系统: CN120200277a [P]. 2025-06-24.
- [24]杨沛豪, 兀鹏越, 王小辉, 等. 一种储能架构优化方法及系统: CN120105647a [P]. 2025-06-06.
- [25]李志鹏, 张宇翼, 马益文, 等. 基于运算改进型VMD的超级电容储能调频并网方法及系统: CN119834330b [P]. 2025-06-24.

作者简介:

李志鹏(1993—), 男, 工程师, 通信作者, 长期从事储能技术研发工作。

姜楠(1990—), 男, 工程师, 主要从事火电智慧化、新型储能、自动控制方面的研究工作。E-mail: nh66@qq.com。

孙国辉(1988—), 男, 高级工程师, 从事电厂热工自动化以及智慧化工作。E-mail: 645764152@qq.com。

谢佳(1990—), 女, 实验师, 主要从事单螺杆压缩机的内部工作过程研究、工作性能优化工作。E-mail: 230102@xsyu.edu.cn。

崔磊(1992—), 男, 主要从事电气工程及其自动化工作。E-mail: 1058224886@qq.com。