



DOI:10.12404/j.issn.1671-1815.2405301

引用格式:刘航,张雷,冯志远,等.混合储能系统能量优化管理策略[J].科学技术与工程,2025,25(17):7187-7196.

Liu Hang, Zhang Lei, Feng Zhiyuan, et al. Energy optimization management strategies for hybrid energy storage systems[J]. Science Technology and Engineering, 2025, 25(17): 7187-7196.

电工技术

## 混合储能系统能量优化管理策略

刘航,张雷\*,冯志远,陈功,石旭阳,胡宇堃

(河南科技大学信息工程学院,洛阳 471000)

**摘要** 为平抑风力发电系统的出力波动,通过调整混合储能系统(hybrid energy storage system, HESS)的控制策略,满足并网波动限制,构建了一种基于风电功率预测的混合储能双层模糊控制策略。首先,利用改进的完全自适应噪声集合经验模态(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)对原始风电数据进行分解;其次,将改进的Adam算法与Transformer模型结合对各分量预测,预测结果叠加作为最终预测结果;最后,基于预测的风电功率波动状态和混合储能荷电状态(state of charge, SOC),对混合储能系统采用双层模糊控制策略进行调节,确保在风电平稳并网前提下,减少混合储能系统的过充、过放情况。结果表明:所提控制策略平抑风电出力达到更低的波动指标,保证可靠并网;并且控制混合储能系统的SOC在合理范围内,使系统整体性能得到提升。

**关键词** 风电功率;Transformer模型;模糊控制;混合储能;荷电状态

**中图分类号** TM614; **文献标志码** A

## Energy Optimization Management Strategies for Hybrid Energy Storage Systems

LIU Hang, ZHANG Lei\*, FENG Zhi-yuan, CHEN Gong, SHI Xu-yang, HU Yu-kun

(College of Information Engineering, Henan University of Science and Technology, Luoyang 471000, China)

**[Abstract]** In order to smooth out the output fluctuation of wind power generation system, a hybrid energy storage dual-layer fuzzy control strategy based on wind power prediction was constructed by adjusting the control strategy of hybrid energy storage system (HESS) to meet the fluctuation limit of grid connection. Firstly, the improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) was used to decompose the original wind power data. Secondly, the improved Adam algorithm and Transformer model were combined to predict each component, and the prediction results are superimposed as the final prediction result. Finally, based on the predicted wind power fluctuation state and state of charge (SOC) of the hybrid energy storage system, the dual-layer fuzzy control strategy was adopted to adjust the hybrid energy storage system to ensure that the overcharge and overdischarge of the hybrid energy storage system are reduced under the premise of smooth grid connection of wind power. The results demonstrate that the proposed control strategy achieves lower fluctuation indices in wind power output, ensuring reliable grid connection. Moreover, it maintains the SOC of the HESS within an optimal range, leading to an overall enhancement in the system's comprehensive performance.

**[Keywords]** wind power generation; Transformer model; fuzzy control; hybrid energy storage system; state of charge

全球能源体系正经历前所未有的转型时期,风能作为最具潜力的可再生能源,展示出了极大的开发利用价值<sup>[1-2]</sup>。然而,风力发电容易受到气温、海拔、地形等多种自然条件影响,发电过程中存在波动性、随机性、间歇性等问题,给电网的稳定输出与高效管理带来严峻考验<sup>[3]</sup>。

在风电功率预测方面,目前中国针对风电预测

的研究方法大致分为三类:物理预测方法<sup>[4]</sup>、统计预测方法<sup>[5]</sup>和组合预测方法<sup>[6]</sup>。物理预测方法基于理论物理学原理和实验数据,通过建立数学模型来预测自然现象和系统行为,精确建模往往复杂度高,需要大量数据和计算资源<sup>[7]</sup>。统计预测方法是一种基于历史数据和统计理论来预测未来风电场输出功率,近年对风电的预测模型通常采用人工智

收稿日期:2024-07-15 修订日期:2025-03-14

基金项目:国家自然科学基金(U2004163)

第一作者:刘航(1999—),男,汉族,河南洛阳人,硕士研究生。研究方向:新能源系统运行与控制。E-mail:lh54292@163.com。

\*通信作者:张雷(1974—),男,汉族,河南洛阳人,博士,副教授。研究方向:计算智能与智能电网。E-mail:leizhang87@163.com。

投稿网址:www.stae.com.cn

能算法进行训练,挖掘数值天气预报(numerical weather prediction, NWP)数据与风电功率之间的相关性,主要包括随机森林<sup>[8]</sup>、长短期记忆神经网络(long short-term memory, LSTM)、支持向量机等,适用于线性关系较强的场景,但对于非线性模式或外部干扰的适应性有限。相比之下,组合预测方法通过整合多个单一预测模型提高预测准确性和稳定性,往往比单个模型更可靠,凭借其强大的特征提取能力和处理复杂非线性关系的优势,在负荷预测中展现出卓越性能。文献[9]提出一种灰狼优化算法、卷积神经网络和双向长短期记忆神经网络的超短期风电组合预测模型。文献[10-11]分别采用经验模态分解和变分模态分解将风电功率分解为子序列,将分解结果与长短期记忆网络组合进行预测,并将子序列重构得到最终预测结果。文献[12-13]分别利用皮尔逊相关系数和变量相关注意力机制与 Transformer 模型结合,构建组合预测模型。相比较而言,组合预测模型更能够有效捕捉风电负荷数据的复杂线性特征,成为提升风电功率预测精确度的关键策略。

在控制策略方面,控制混合储能系统(hybrid energy storage system, HESS)可以有效解决风电输出功率波动对电网造成的冲击。文献[14]提出一种风电储能控制系统,该系统预测风力发电量的变化,根据于相空间重构-随机森林预测的功率波动,用模糊策略自动调整储能的充放电,保证电力系统稳定高效运行,但是单一储能系统由于存储容量有限,难以补偿风电出力的大幅波动。文献[15-17]以储能荷电状态(state of charge, SOC)为指标,分别运用小波包变换、经验模态分解(empirical mode decomposition, EMD)和变分模态分解(variational mode decomposition, VMD)的方法对风电功率进行预处理,对充放电功率在线预测,实现储能输出的动态自适应调整,并对部分充放电功率进行修正,平衡储能的充、放电效能、延长使用寿命。文献[18]构建模型预测控制(model predictive control, MPC),利用滚动优化的方法,对混合储能 SOC 进行控制,优化储能 SOC 的运行空间,提升混合储能分配的合理性,调节系统寿命与输出功率稳定性。文献[19]则利用分层 MPC,进行数学建模,构建混合逻辑动态框架,考虑 HESS 的各种逻辑状态和持续输出状态。文献[20-21]对风电功率进行分解,采用基于时序模糊控制策略对混合储能系统充放电进行优化,修正混合储能系统的初始出力,实现混合储能的协同运行。

综上所述,现提出一种基于风电功率预测的混

合储能双层模糊控制策略,通过对预测风电功率波动量与当前混合储能 SOC 进行综合考虑,动态调整混合储能系统的功率分配策略,有效平抑风电功率和延长混合储能系统的寿命。首先,对风电功率进行完全自适应噪声集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN),获得初级分配的混合储能功率指令;其次,采用 Transformer 模型,配合 Adam 优化器进行训练,深入探索节点负荷数据的时空关联特性,对分解的风电功率分别进行预测,集成预测结果;然后,基于风电预测数据求解混合储能未来时刻的功率波动估计值,实时判断混合储能出力状态;最后,利用模糊控制策略,控制当前时刻风电并网功率和混合储能系统出力。通过仿真验证,所提方法在满足并网标准下,实现对风电功率最大限度的平抑,利用预测数据,实现超前调节混合储能功率,有效减少混合储能系统的出力和充放电深度,提升风电并网的稳定性和混合储能系统的可靠性。

## 1 风力发电系统模型

### 1.1 风力发电系统结构与功率分配

在风电混合储能系统中,通过控制混合储能功率控制器,对风电功率进行平抑,同时调节混合储能系统充放电功率,使其工作在安全范围,系统整体结构图,如图 1 所示。

利用混合储能功率控制器,获得风电原始数据、风电并网数据、风电功率预测数据及混合储能 SOC,并对混合储能系统出力进行分配和实时控制。根据图 1 的能量守恒定律可得

$$\begin{cases} P_g(t) = P_w(t) - P_{hess}(t) \\ P_{hess}(t) = P_{ba}(t) + P_{sc}(t) \end{cases} \quad (1)$$

式(1)中: $P_g(t)$ 、 $P_w(t)$ 、 $P_{hess}(t)$ 、 $P_{sc}(t)$ 、 $P_{ba}(t)$ 分别为并网功率、风电功率、混合储能功率、超级电容功率和蓄电池功率。

风电功率具有较强的波动性,采用混合储能系统可以平抑并网功率波动,使风电场的并网功率满足并网要求,中国的并网标准如表 1 所示。

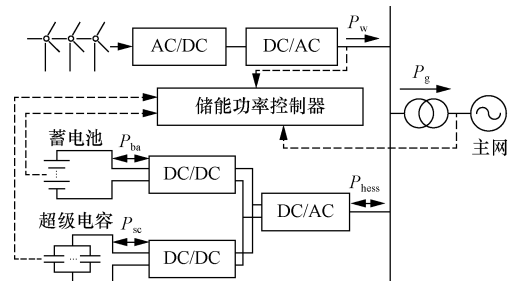


图 1 风力发电系统

Fig. 1 Wind storage power generation system

表1 风电场输出功率的波动限值

Table 1 Fluctuation limits of output power for wind farm

装机容量/MW	10 min 最大波动量/MW	1 min 最大波动量/MW
<30	10	3
30 ~ 150	装机容量/3	装机容量/10
>150	50	15

以表1中1 min有功功率波动作为判断标准进行分析,以每分钟的风力发电各参数的均值得出每分钟的风电功率。

## 1.2 风电功率信号的ICEEMDAN分解

ICEEMDAN 是基于经验模态分解 (empirical mode decomposition, EMD) 的一种变体,有效解决 EMD 衍生方法中常见的问题,如模态交叉污染、运算效率低、残余噪声干扰和伪模态,可以提升信号分解的准确性和处理速度,因此,采用 ICEEMDAN 对原始风电数据进行分解,具体分解步骤如下。

**步骤1** 建立原始风电功率分解  $P_w^{(i)}(t)$  为

$$P_w^{(i)}(t) = P_w(t) + \alpha_i E_i[\omega^{(i)}(t)] \quad (2)$$

式(2)中:  $P_w(t)$  为风电原始功率;  $\alpha_i$  为信噪比;  $E_i[\omega^{(i)}(t)]$  为分解产生的第  $i$  个分量,  $\omega^{(i)}(t)$  为第  $i$  个白噪声。

**步骤2** 计算  $P_w^{(i)}(t)$  的局部均值  $M[P_w^{(i)}(t)]$ , 得到第1个残差分量。

$$r_1(t) = M[P_w^{(i)}(t)] \quad (3)$$

**步骤3** 计算第  $n$  个模态分量  $I_n(t)$  的值,当  $n = 1$  时,则模态分量  $I_1(t)$  的值。

$$I_1(t) = P_w(t) - r_1(t) \quad (4)$$

**步骤4** 计算下一模态分量的值。

$$I_2(t) = r_1(t) - r_2(t) \quad (5)$$

式(5)中:残差分量  $r_2(t) = M\{r_1(t) + \alpha_1 E_2[\omega^{(i)}(t)]\}$ 。

**步骤5** 以此类推得到残差分量  $r_n(t)$  和模态分量  $I_n$ 。

$$r_n(t) = M\{r_{n-1}(t) + \alpha_{n-1} E_n[\omega^{(i)}(t)]\} \quad (6)$$

$$I_n(t) = r_{n-1}(t) - r_n(t) \quad (7)$$

**步骤6** 重复步骤1~步骤5,直到获得原始风电功率的全部本征模态函数 (intrinsic mode function, IMF) 分量,如图2所示。

风力发电混合储能系统的功率分配如下:首先,对原始的风电功率进行 ICEEMDAN 分解,得到  $k$  个子序列,然后,根据并网允许范围,将分解得到的残差依次与不同频率的每个子序列的功率累加进行判断,直到第  $k - (i - 1)$  个子序列不满足并网标准,此时  $k - i$  为最佳混合储能介入阶数,将风电原始功率和并网功率做差,获得混合储能功率  $P_{\text{hess}}(t)$ 。




图2 ICEEMDAN 分解得到的 IMF 和残差

Fig. 2 IMF and remnant decomposed by ICEEMDAN

选取的混合储能系统由超级电容和蓄电池混组成。将混合储能功率分解为低频和高频两部分,超级电容负责高频部分的充放电功率,蓄电池负责低频部分的充放电功率,表达式如下。

$$\begin{cases} P_{\text{sc}}(t) = \sum_{k=1}^j \text{IMF}_k(t) \\ P_{\text{ba}}(t) = \sum_{k=j+1}^i \text{IMF}_k(t) \end{cases}, \quad j \in (1, 2, \dots, i) \quad (8)$$

式(8)中:  $P_{\text{sc}}(t)$  为超级电容对应高频部分充放电功率;  $P_{\text{ba}}(t)$  为蓄电池对应低频部分充放电功率。

## 1.3 混合储能系统功率指令

对于风电并网功率波动,以 HESS 作为研究对象,整体系统协调控制策略如下。

(1) 功率波动绝对值均值。

$$\Delta P_g(t) = |P_g(t+1) - P_g(t)| \quad (9)$$

式(9)中:  $\Delta P_g(t)$  为  $t$  时刻并网功率波动绝对值。

(2) 混合储能充放电总能量。

$$E_{\text{hess}} = T \sum_{t=1}^{n-1} |P_{\text{hess}}(t)| \quad (10)$$

式(10)中:  $E_{\text{hess}}$  为混合储能典型日吸收和释放的总能量;  $T$  为典型日时长。

(3)混合储能进入死区时间。

$$\begin{cases} T_d = \Delta t \sum_{t=1}^n [f(x_1) \cup f(x_2)] \\ x_1 = \frac{\text{SOC}_{\min}}{\text{SOC}(t)} \\ x_2 = \frac{\text{SOC}(t)}{\text{SOC}_{\max}} \\ f(x) = \begin{cases} 1, & x \geq 1 \\ 0, & x < 1 \end{cases} \end{cases} \quad (11)$$

式(11)中:  $T_d$  为死区整体时间;  $\text{SOC}_{\max}$  和  $\text{SOC}_{\min}$  分别为混合储能 SOC 的上下限。

由上述公式可知,若混合储能系统的控制策略能够有效降低风电功率接入电网时的波动,且能有效缩短混合储能充放电的死区时间,则表明该系统混合储能控制策略具有优越性。

## 2 风电功率预测模型设计

### 2.1 Transformer 模型

Transformer 是一种基于自注意力机制的深度学习模型,改变了循环神经网络和长短期记忆网络处理序列数据的传统方法,利用自注意力机制实现了并行计算,提升了训练速度和模型规模的可扩展性,有效捕捉长距离依赖,通过位置编码处理序列顺序,结构灵活可扩展,已成为处理时序数据的强大工具。使用分解后的风电功率数据作为输入,采用绝对位置编码为输入数据中的每个位置赋予独特的向量,表达式如下。

$$\begin{cases} \text{PE}(t, 2i) = \sin\left(\frac{t}{1000^{\frac{2i}{d}}}\right) \\ \text{PE}(t, 2i + 1) = \cos\left(\frac{t}{1000^{\frac{2i}{d}}}\right) \end{cases} \quad (12)$$

式(12)中: PE 为位置编码;  $t$  为时间序列位置;  $i$  为特征维度;  $d$  为风电功率序列长度。

Transformer 的编码器由多个相同的层堆叠而成,每层包含两个关键子层:多头自注意力机制和前馈神经网络。多头机制捕捉 NWP 和风电功率特征参数的信息,通过不同的权重矩阵映射到不同的头,完成注意力计算后,各个头的结果再被合并(通常是拼接或平均)并经过一个最终的线性变换,生成最终的输出结果,表达式如下。

$$\begin{cases} \text{Multihead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \\ \text{head}_2, \dots, \text{head}_i) \mathbf{W}_o \\ \text{head}_i = \text{Attention}(\mathbf{Q} \mathbf{W}_q, \mathbf{K} \mathbf{W}_k, \mathbf{V} \mathbf{W}_v) \end{cases} \quad (13)$$

式(13)中:  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  分别为查询、键、值矩阵;  $\mathbf{W}_q, \mathbf{W}_k, \mathbf{W}_v$  为对应权重;  $\mathbf{W}_o$  为多头注意力的输出变换矩阵。

自注意力机制允许模型在处理输入序列时,根据序列内部各元素间的相关性来动态调整关注点,表达式为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_1}}\right)\mathbf{V} \quad (14)$$

式(14)中: softmax 表示归一化;  $d_1$  为键相量维度。

前馈层通常由两个连续的全连接层(也称为线性变换)组成,中间夹着一个非线性激活函数,表达式为

$$\text{FFN}(\mathbf{x}) = \text{ReLU}(\mathbf{x}\mathbf{W}_1 + b_1)\mathbf{W}_2 + b_2 \quad (15)$$

式(15)中: ReLU 为非线性激活函数;  $\mathbf{x}$  为特征表示向量;  $\mathbf{W}_1, \mathbf{W}_2$  分别为升、降维的权重矩阵;  $b_1, b_2$  分别为升、降维的偏置项。

### 2.2 改进 Adam 优化器

传统 Adam 算法使用固定的超参数  $\beta_1$  和  $\beta_2$  来分别估计梯度的指数移动平均和梯度平方的指数移动平均。通过改进两个参数随着迭代次数动态变化,旨在提高算法的收敛速度和稳定性。动态调整使得早期迭代时能快速响应梯度变化,在后期迭代时逐渐稳定,以避免估计偏差和波动。

$$\begin{cases} \beta_{1,i} = \mu\beta_{1,i-1} \\ \beta_{2,i} = 1 - \frac{1}{i} \end{cases} \quad (16)$$

式(16)中:  $\mu$  为衰减系数;  $i$  为下降速度。

在迭代初期可以快速学习到有用的梯度信息,而随着迭代深入,逐渐增加历史梯度的影响力,平衡了学习的稳定性和快速性。

$$\begin{cases} \mathbf{m}_i = \beta_{1,i}\mathbf{m}_{i-1} + (1 - \beta_{1,i})\mathbf{g}_i \\ \mathbf{v}_i = \beta_{2,i}\mathbf{v}_{i-1} + (1 - \beta_{2,i})\mathbf{g}_i^2 \end{cases} \quad (17)$$

式(17)中:  $\mathbf{m}_i$  为一阶矩阵;  $\mathbf{v}_i$  为二阶矩阵;  $\mathbf{g}_i$  为当前迭代步的梯度。

模型参数在每一步迭代中与最优参数之间的累积损失差,是衡量算法收敛性能的重要指标。

$$R_n = \sum_{i=1}^n [L_i(\boldsymbol{\theta}_i) - L^*(\boldsymbol{\theta}^*)] \quad (18)$$

式(18)中:  $L_i$  为第  $i$  次迭代损失函数值;  $L^*$  为最优损失值;  $\boldsymbol{\theta}_i$  为预测模型的参数向量;  $\boldsymbol{\theta}^*$  为最优预测模型的参数向量。

改进的 Adam 算法存在残差上界,表明了算法的收敛性质。

$$R_n \leq \left[ \frac{D^2}{2\alpha(1 - \beta_{1,0})} + \frac{2\xi}{(1 - \beta_{1,0})^3} \right] \sum_{j=1}^d \|\mathbf{g}_{1:n,j}\|_2 + \frac{\beta_1 D^2 G}{(1 - \beta_1)^2 (1 - \mu)^2} \quad (19)$$

式(19)中:  $D$  为参数空间直径;  $\alpha$  为初始学习率;  $\xi$  为算法稳定性和收敛性相关的常数;  $\mathbf{g}_{1:n,j}$  为第  $j$  个参数维度上的梯度序列的累积范数。

随着迭代次数的增加,优化残差的增长受到各项参数限制,特别是与迭代次数相关的项和参数空间特性紧密相关,优化残差增长的速度会逐渐减慢,体现了算法的稳定收敛行为。

### 2.3 改进 Adam 优化与 Transformer 模型结合

基于改进 Adam 优化的 Transformer 预测模型,首先对原始风电功率数据进行分解,得到各  $k$  子序列,然后每个子序列作为输入进行预测,最终将每一个子序列预测结果进行累加,得到风力发电功率预测值。如图 3 所示,基于改进 Adam 优化的 Transformer 预测模型的具体流程。

**步骤 1** 使用 ICEEMDAN 对风电原始功率  $P_w(t)$  进行分解,获得  $k$  个 IMF 分量。

**步骤 2** 设置 Transformer 算法的 2 个编码器和 1 个解码器、头数、隐藏层大小等超参数。

**步骤 3** 利用改进 Adam 优化器,调整超参数,如学习率、 $\beta_{1,j}$ 、 $\beta_{2,j}$  等。

**步骤 4** 将构造好的数据集划分为训练集和验证集,开始训练模型。

**步骤 5** 利用训练好的 Transformer 模型对每个子序列进行未来时段的预测,最终将所有子序列的预测值进行叠加,得到整体风力发电功率预测值。

**步骤 6** 计算实际风电功率数据与模型预测风电功率数据的均方根误差 (root mean squared error,

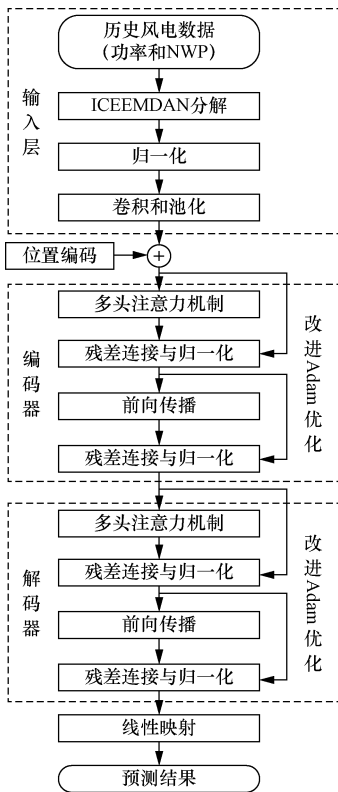


图 3 风电功率预测模型

Fig. 3 Wind power prediction mode

RMSE) 是否超出阈值,超出则返回至步骤 2,重新训练模型,直到低于设定的误差阈值为止,输出预测模型结构。

### 3 混合储能控制策略

混合储能系统 SOC 是管理能量、分配功率及维持系统稳定的关键指标。SOC 的范围是  $[0, 1]$ , 当  $SOC = 0$  时,表示储能系统完全处于放电状态,当  $SOC = 1$  时,表示储能系统完全处于充电状态。因此,SOC 的区间不宜设置过大,长时间在警戒区作业会减短储能系统寿命,应确保混合储能系统在 SOC 正常工作区工作,如图 4 所示。

采用改进的 Transformer 预测模型,对下一时刻的风电功率进行预测,得到预测值  $\hat{P}(t + 1)$ ,基于预测数据,可以得到混合储能系统应平抑功率的波动估计值,表达式为

$$\Delta \hat{P}(t) = \frac{\hat{P}(t + 1) - P_g(t - 1)}{2t} \quad (20)$$

式(20)中:  $P_g(t - 1)$  为上一时刻并网功率;  $t$  为单位时间。

在此基础上,采用双重模糊控制策略,对混合储能充电过程进行控制,模糊控制器 1 做出初步控制决策,模糊控制器 2 对输出做出修正,使超级电容器和蓄电池的 SOC 保持在合理范围内,确保储能元件在正常工作区工作,控制策略如图 5 所示。

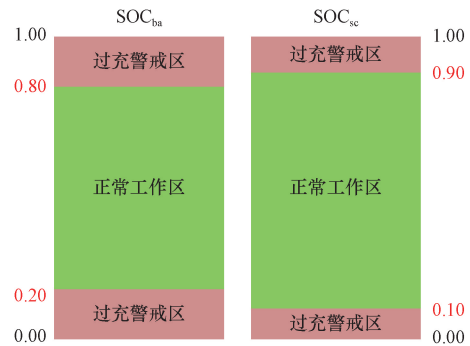


图 4 不同储能介质的 SOC 限值范围

Fig. 4 The SOC limit ranges for various energy storage media




图 5 混合储能充放电控制策略

Fig. 5 Hybrid energy storage charge and discharge control strategy

通过双层模糊控制可以优化混合储能的 SOC, 并对分配的混合储能功率进行二次修正。模糊控制器 1 控制得到超级电容器充放电功率  $P_{sc1}(t)$ ; 模糊控制器 2 控制得到蓄电池充放电功率  $P_{bal}(t)$ 。下文选用控制超级电容的模糊控制器 1 进行举例。

以  $t$  时刻的超级电容器的  $SOC_{sc}(t)$  作为模糊控制器输入 1,  $SOC_{sc}(t)$  表示  $t$  时刻超级电容电荷的百分比, 即已存储电能与最大存储电能之比。通常输入范围是  $[0, 1]$ , 将输入范围划分成不同的模糊子集, 以 0.1 为间隔设置模糊域为  $\{0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1\}$ , 模糊子集为  $\{NB, NS, ZO, PS, PB\}$ , 表示  $t$  时刻超级电容 SOC  $\{$ 非常低、较低、适中、较高、非常高 $\}$ 。模糊控制规则表如表 2 所示。

表 2 模糊控制规则表  
Table 2 Fuzzy control rules

$SOC_{sc}(t)$	$\Delta\hat{P}(t)$						
	NB	NM	NS	PS	PM	PB	NB
NB	NB	NM	NS	PB	PB	PM	NB
NS	NM	NS	NS	PB	PM	PS	NS
ZO	NS	PS	PM	PM	PS	NS	ZO
PS	PS	PM	PB	NS	NS	NM	PS
PB	PM	PB	PS	NS	NM	NB	PB

设置输入范围为  $[-1, 1]$ , 结合变化量以 0.1 为间隔设置模糊域为  $\{-1, -0.9, -0.8, -0.7, -0.6, -0.5, -0.4, -0.3, -0.2, -0.1, 0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1\}$ , 其模糊子集设置为  $\{NB, NM, NS, PS, PM, PB\}$  表示超级电容器的荷电偏差为  $\{$ 负高、负中、负小、正小、正中、正高 $\}$ 。

模糊控制对于不确定性和非精确性的复杂系统有较好的控制效果和鲁棒性, 根据图 6 采用模糊控制的隶属度函数对混合储能 SOC 和预测出力波动值进行模糊化处理, 转换为模糊集, 利用表 2 中的模糊规则, 进行模糊推理, 得到模糊控制量和最佳调节系数  $K_1$ , 完成风电功率波动调节, 模糊控制策略的输出曲面如图 7 所示。

得到超级电容对应平抑的功率  $P_{sc1}(t)$  和蓄电池对应平抑的功率  $P_{bal}(t)$ , 计算公式为

$$\begin{cases} P_{sc1}(t) = K_1 P_{sc}(t) \\ P_{bal}(t) = K_2 [P_{ba}(t) + (1 - K_1) P_{sc}(t)] \end{cases} \quad (21)$$

模糊规则的设计遵循以下原则: 当超级电容的  $SOC_{sc}(t)$  较大, 估计波动量指令下一时刻需要充电时, 或者超级电容  $SOC_{sc}(t)$  较小, 估计波动量指令下一时刻需要放电, 则分配一部分功率给蓄电池承担, 减少超级电容负担, 使两部分储能系统荷电状态始终维持在正常工作区。

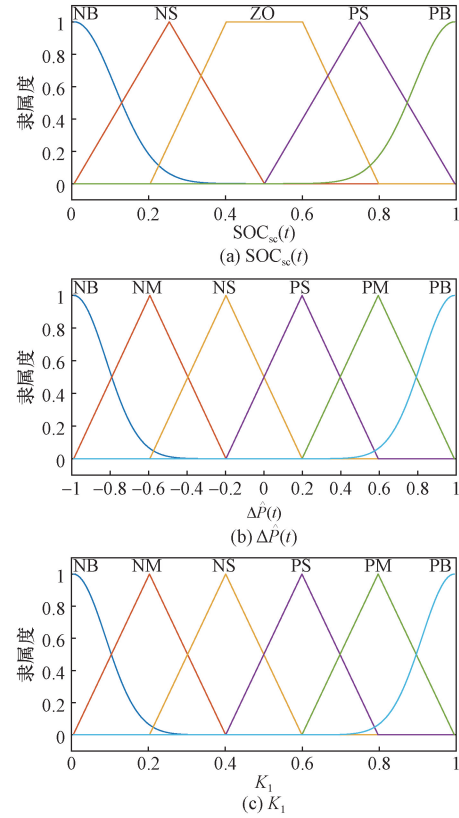


图 6 模糊控制器 1 隶属度函数  
Fig. 6 Fuzzy controller's first membership function




图 7 模糊控制输出曲面  
Fig. 7 Output surface of fuzzy control system

## 4 算例分析

### 4.1 以新疆哈密地区风电场为例

以新疆哈密地区总装机容量为 70 MW 风电场实际数据为例, 采用 5 d 的气象数据和功率作为实验数据, 风电功率为每 1 min 采样一次, 如图 8 所示。采用前 4 d 的数据作为训练集, 最后 1 d 的数据作为测试集, 验证模型性能。仿真系统中混合储能系统各储能介质容量配置根据文献[22]所给出的方法确定。蓄电池额定功率 2 MW、容量 5 MW·h, SOC 初始值设置为 0.5, 限值范围为  $[0.2, 0.8]$ ; 超级电容额定功率 2 MW、容量 1.2 MW·h, SOC 初始值设置为 0.7, 限值范围为  $[0.1, 0.9]$ 。




图8 原始风电功率数据

Fig. 8 Original wind power generation data

4.2 仿真结果

在预测方面,为了验证改进 Adam 算法与 Transformer 模型结合预测效果,另外构建 LSTM 模型和 Transformer 模型梯度下降都采用 Adam 优化器进行对比,利用训练集数据对 3 个模型分别进行训练,以第 5 天的实时风电功率为测试进行预测,不同模型预测结果如图 9 所示。

风电功率的预测精度将直接影响风电平抑的控制策略,选择平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)以及平均绝对百分比误差(mean absolute percentage error, MAPE)为评价指标对预测精度进行评价,其公式如下。

$$\begin{cases} MAE = \frac{1}{N} \sum_{t=1}^N |\hat{P}_w(t) - P_w(t)| \\ RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [\hat{P}_w(t) - P_w(t)]^2} \\ MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{P_w(t) - \hat{P}_w(t)}{P_w(t)} \right| \times 100\% \end{cases} \quad (22)$$

式(22)中:  $N$  为总训练样本;  $\hat{P}_w(t)$  为预测功率;  $P_w(t)$  为实际功率。

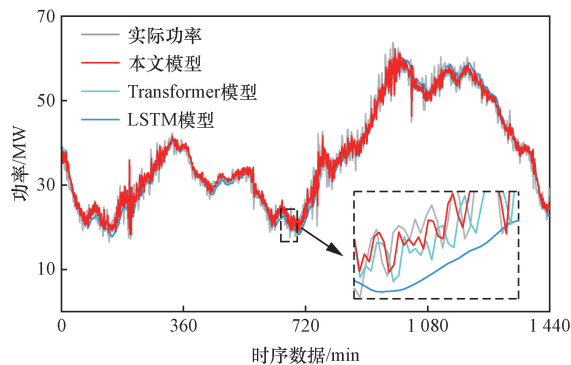


图9 各模型预测结果对比

Fig. 9 Comparison of model prediction outcomes

从表 3 中可以看出,本文算法相较于 LSTM 模型和 Transformer 模型,性能指标 MAE、RMSE、MAPE 分别减少了 79%、76%、80% 与 35%、45%、45%,通过选用合适的组合预测模型,能显著提高风力发电预测精度,为平抑风电功率的控制策略提供了数据支撑。

如图 10 所示,为了进一步直观展示本文模型的精确性,对预测结果与实际功率的误差进行可视化分析。误差拟合曲线近似呈正态分布,说明本文预测模型误差波动小,预测功率更接近实际功率。


分析可知,混合储能系统充放电存在时间延迟,提前利用风电功率预测对波动进行预估,为混合储能提前调度提供数据支撑。基于预测数据,对混合储能系统进行有预见性的充、放电调度,实现对风力发电功率波动的即时补偿与平滑化处理,平抑后的风电功率,如图 11 所示。

图 12(a)和图 12(b)所示分别为超级电容和蓄

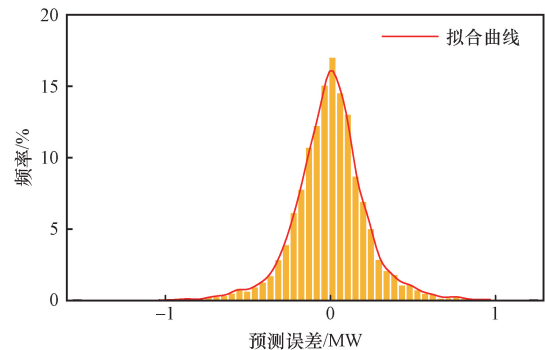
表 3 不同预测方法的误差评价指标

Table 3 Different error evaluation metrics for predictive methods

方法	MAE	RMSE	MAPE/%
LSTM	4.351 3	5.882 8	5.531 9
Transformer	1.846 1	2.590 4	2.081 0
本文算法	1.203 1	1.415 9	1.130 8



(a) 预测误差曲线



(b) 误差分布

图 10 预测功率误差

Fig. 10 Wind power prediction error

电池在储能功率响应上,传统方法与本文方法的功率响应对比曲线。可以发现运用本文控制策略后,超级电容充放电频次更快,提前做出响应补偿产生高频功率,充分利用快速响应和频繁充放电的特性,并辅助承担了部分原蓄电池的功率调节,有效拓宽功率补偿的范围;蓄电池分配的功率则更为平滑,充放电切换频率明显降低。

如图 13 所示,将本文控制策略与无模糊控制策略进行对比。在无模糊控制的情况下,蓄电池 SOC 波动范围更显著,具体范围为 0.27 ~ 0.91,超出了正常工作区域(0.2 ~ 0.8),将导致蓄电池面临过充的风险,加速了蓄电池的老化,缩短系统使用寿命;在加入模糊控制之后,蓄电池的 SOC 被显著优化,范围缩小至 0.37 ~ 0.78,完全符合设计的安全操作范围。




图 11 平抑风电并网功率

Fig. 11 Smoothing wind power integration into the grid





图 12 混合储能元件功率分配情况

Fig. 12 Power distribution of energy storage components

如图 14 所示,超级电容 SOC 允许范围为 0.1 ~ 0.9,在有模糊控制的情况下,范围被控制在 0.31 ~ 0.72,但是无模糊控制范围为 0.09 ~ 0.74,超出安全范围,表明本文控制策略高效地平衡了储能资源的充放电过程,确保 SOC 既不降至过低导致能量不足,也不超过上限引起安全风险。

在无模糊控制时,可以看到蓄电池 2 次超越安全界限,并长期处在过充的警戒区域;超级电容器 4 次超越设定的安全界限,频繁在过放电的警戒区域内运作。相反,本文所提出的策略,无论是蓄电池还是超级电容器,都没有发生过充过放的情况,确保了两种储能设备始终运行在合理的 SOC 区间范围,保障了设备的稳定运行。

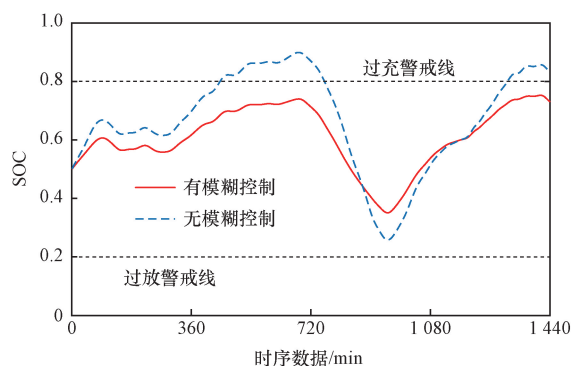


图 13 蓄电池 SOC 对比图

Fig. 13 Battery SOC comparison diagram




图 14 超级电容 SOC 对比图

Fig. 14 Supercapacitor SOC comparison diagram

## 5 结论

为平抑风电并网功率的波动性并提升混合储能系统的整体性能,创新性提出了一种结合预测与模糊控制技术的风电功率平滑化策略,通过验证得到了以下几个结论。

(1)对 Adam 算法进行改进,使超参数  $\beta_1$  和  $\beta_2$  随着迭代次数动态变化,提高了算法的收敛速度和稳定性。

(2)构建基于 ICEEMDAN 分解的改进 Adam 算法与 Transformer 模型结合的预测模型,预测结果的平均绝对误差 MAE 为 1.203 1、均方根误差 RMSE 相关系数为 1.415 9,表明预测值与实际值间有极强的正相关性,证明了本文模型的有效性,为模糊控制策略提供数据支撑。

(3)将风电功率预测值和混合储能系统 SOC 结合,定制了模糊控制器的输入、输出、规则和隶属度函数。控制混合储能 SOC 动态维持在中间 ZO 区域,避免深度充放电,在有效地平抑风电波动同时,缩短了混合储能系统的死区时间。

### 参 考 文 献

- [1] 陶思钰, 江福庆. 集群化发展模式下风电场预测、规划及控制关键技术综述[J]. 电力工程技术, 2024, 43(1): 86-99.  
Tao Siyu, Jiang Fuqing. Review of the key technologies of wind farm cluster prediction, planning and control[J]. Electric Power Engineering Technology, 2024, 43(1): 86-99.
- [2] 刘晓艳. 计及初始荷电状态的含混合储能微电网双层调度研究[J]. 太阳能学报, 2024, 45(2): 416-420.  
Liu Xiaoyan. Two-layer dispatch of microgrid with hybrid energy storage considering initial state of charge[J]. Acta Energeticae Solaris Sinica, 2024, 45(2): 416-420.
- [3] 黄利祥, 张新燕, 梁帅, 等. 平抑风光功率波动的混合储能功率分配策略[J]. 科学技术与工程, 2023, 23(25): 10825-10834.  
Huang Lixiang, Zhang Xinyan, Liang Shuai, et al. Hybrid energy storage power distribution strategy for smoothing wind-photovoltaic power fluctuation[J]. Science Technology and Engineering, 2023, 23(25): 10825-10834.
- [4] Zhang Y, Li Y T, Zhang G Y, et al. Short-term wind power forecasting approach based on Seq2Seq model using NWP data[J]. Energy, 2020, 213: 118371.
- [5] 屈尹鹏, 徐箭, 姜尚光, 等. 基于频繁模式挖掘的风电爬坡事件统计特性建模及预测[J]. 电力系统自动化, 2021, 45(1): 36-43.  
Qu Yinpeng, Xu Jian, Jiang Shangguang, et al. Frequent pattern mining based modeling and forecasting for statistical characteristics of wind power ramp events[J]. Acta Energeticae Solaris Sinica, 2021, 45(1): 36-43.
- [6] 孙荣富, 张涛, 和青, 等. 风电功率预测关键技术及应用综述[J]. 高电压技术, 2021, 47(4): 1129-1143.  
Sun Rongfu, Zhang Tao, He Qing, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021, 47(4): 1129-1143.
- [7] 王勃, 刘晓琳. 计及多误差场景集划分的超短期 NWP 风速修正方法[J]. 南方电网技术, 2023, 17(2): 118-127.  
Wang Bo, Liu Xiaolin. Ultra-short-term NWP wind speed correction method based on multiple error scenarios division[J]. Southern Power System Technology, 2023, 17(2): 118-127.
- [8] 刘兴, 王艳, 纪志成. 基于随机森林的风电功率短期预测方法[J]. 系统仿真学报, 2021, 33(11): 2606-2614.  
Liu Xing, Wang Yan, Ji Zhicheng. Short-term wind power prediction method based on random forest[J]. Journal of System Simulation, 2021, 33(11): 2606-2614.
- [9] 程杰, 陈鼎, 李春, 等. 基于 GWO-CNN-BiLSTM 的超短期风电预测[J]. 科学技术与工程, 2023, 23(35): 15091-15099.  
Cheng Jie, Chen Ding, Li Chun, et al. Ultra-short-term wind power prediction based on GWO-CNN-BiLSTM[J]. Science Technology and Engineering, 2023, 23(35): 15091-15099.
- [10] 张云钦, 程起泽, 蒋文杰, 等. 基于 EMD-PCA-LSTM 的光伏功率预测模型[J]. 太阳能学报, 2021, 42(9): 62-69.  
Zhang Yunqin, Cheng Qize, Jiang Wenjie, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM[J]. Acta Energeticae Solaris Sinica, 2021, 42(9): 62-69.
- [11] 王俊, 李霞, 周昔东, 等. 基于 VMD 和 LSTM 的超短期风速预测[J]. 电力系统保护与控制, 2020, 48(11): 45-52.  
Wang Jun, Li Xia, Zhou Xidong, et al. Ultra-short-term wind speed prediction based on VMD-LSTM[J]. Power System Protection and Control, 2020, 48(11): 45-52.
- [12] 张亚丽, 王聪, 张宏立, 等. 基于非平稳 Transformer 的超短期风电功率多步预测[J]. 智慧电力, 2024, 52(1): 108-115.  
Zhang Yali, Wang Cong, Zhang Hongli, et al. Multi-step prediction of ultra-short-term wind power based on non-stationary Transformer[J]. Smart Power, 2024, 52(1): 108-115.
- [13] 王旭光, 张可, 李潇, 等. 基于变量相关注意力机制的短期风速预测[J]. 太阳能学报, 2023, 44(8): 467-476.  
Wang Xuguang, Zhang Ke, Li Xiao, et al. Short-term wind speed forecasting based on variable correlation attention mechanism[J]. Acta Energeticae Solaris Sinica, 2023, 44(8): 467-476.
- [14] 刘颖明, 王维, 王晓东, 等. 结合风功率预测及储能能量状态的模糊控制策略平滑风电出力[J]. 电网技术, 2019, 43(7): 2535-2543.  
Liu Yingming, Wang Wei, Wang Xiaodong, et al. A fuzzy control strategy combined with wind power prediction and energy storage SOE for smoothing wind power output power system technology[J]. Power System Technology, 2019, 43(7): 2535-2543.
- [15] 贺誉京, 陈洁, 张久明. 小波包分析与 BP 神经网络预测相结合的在线能量管理策略[J]. 电网与清洁能源, 2023, 39(9): 9-18.  
He Yujing, Chen Jie, Zhang Jiuming, et al. The online energy management strategy combining wavelet packet analysis and BP neural network prediction[J]. Power System and Clean Energy, 2023, 39(9): 9-18.
- [16] 贾东卫, 任永峰, 李莉美, 等. 基于集合经验模态分解的微电网混合储能优化配置[J]. 太阳能学报, 2023, 44(2): 239-246.  
Jia Dongwei, Ren Yongfeng, Li Limei, et al. Research on optimization of hybrid energy storage capacity using ensemble empirical mode decomposition and fuzzy control[J]. Acta Energeticae Solaris Sinica, 2023, 44(2): 239-246.
- [17] Zhang L, Zhang T W, Zhang, K, et al. Research on power fluctuation strategy of hybrid energy storage to suppress wind-photovoltaic

- hybrid power system[J]. *Energy Reports*, 2023, 10: 3166-3173.
- [18] 林莉, 林雨露, 谭惠丹, 等. 计及SOC自恢复的混合储能平抑风电功率波动控制[J]. *电工技术学报*, 2024, 39(3): 658-671.
- Lin Li, Lin Yulu, Tan Huidan, et al. Hybrid energy storage control with SOC self-recovery to smooth out wind power fluctuations [J]. *Transactions of China Electrotechnical Society*, 2024, 39(3): 658-671.
- [19] Muhammad B A, Valerio M, Davide L, et al. Hierarchical model predictive control for islanded and grid-connected microgrids with wind generation and hydrogen energy storage systems[J]. *International Journal of Hydrogen Energy*, 2022, 45: 103751.
- [20] 赵欣雨, 张云晓, 万乐, 等. 平抑百兆瓦级风电场功率波动的混合储能充放电协同控制策略[J]. *智慧电力*, 2023, 51(11): 23-29, 68.
- Zhao Xinyu, Zhang Yunxiao, Wan Le, et al. Charge-discharge cooperative control strategy for hybrid energy storage system for suppressing power fluctuation of hundred megawatt level wind farm [J]. *Smart Power*, 2023, 51(11): 23-29, 68.
- [21] Chen S Y, Liu D, Yang Q F, et al. A dual-layer cooperative control strategy of battery energy storage units for smoothing wind power fluctuations[J]. *International Journal of Electrical Power & Energy Systems*, 2021, 127: 106681.
- [22] 李学斌, 刘建伟. 采用二阶滤波的混合储能系统实时功率分配方法[J]. *电网技术*, 2019, 43(5): 1650-1657.
- Li Xuebin, Liu Jianwei. Real-time power distribution method adopting second-order filtering for hybrid energy storage system [J]. *Power System Technology*, 2019, 43(5): 1650-1657.