

DOI: 10.19666/j.rlfd.202511048

基于自适应马尔科夫功率预测的混合储能 辅助火电机组 AGC 随机模型预测控制

王天宇¹, 张江丰¹, 尹昊蕊², 张旭娟², 赵洪宇¹, 王 祺¹, 李 泉¹

(1. 国网浙江省电力有限公司电力科学研究院, 浙江 杭州 310014;
2. 华北电力大学控制与计算机工程学院, 北京 102206)

[摘 要] 【目的】为提升混合储能系统 (hybrid energy storage system, HESS) 辅助火电机组响应自动发电控制 (automatic generation control, AGC) 指令时的调节性能, 提出一种基于随机模型预测控制 (stochastic model predictive control, SMPC) 的火储联合功率分配策略。【方法】首先, 针对包括功率型储能钛酸锂电池与能量型储能磷酸铁锂电池构成的 HESS 系统, 提出基于马尔科夫概率矩阵构建未来时段火电机组响应 AGC 指令的 HESS 功率需求模型, 并引入自适应机制实时动态修正状态转移概率, 以提升 AGC 指令波动下的预测精度; 其次, 提出一种基于概率阈值与分层抽样相结合的场景树生成方法用于将自适应马尔科夫模型输出的概率分布转化为可用于优化的有限场景集合, 描述多场景下功率需求预测的不确定性; 最后, 在上述框架基础上构建随机预测控制器, 实现火电机组和 HESS 的功率最优分配。【结果】仿真实验表明, 所提策略在调节性能上优于不考虑功率预测的传统联合调频策略以及未引入动态修正的由静态转移概率矩阵构建的 SMPC 策略, 其性能指标 K_p 分别提升 14.1% 和 7.5%。【结论】该策略有效提升了火电机组与 HESS 的协同调节性能, 具有较强的应用潜力。未来可以进一步优化模型, 提升其在实际应用中的鲁棒性和适应性, 推动该技术的实际落地。

[关 键 词] 自动发电控制; 混合储能系统; 自适应马尔科夫模型; 场景树; 随机模型预测控制

[引用本文格式] 王天宇, 张江丰, 尹昊蕊, 等. 基于自适应马尔科夫功率预测的混合储能辅助火电机组 AGC 随机模型预测控制[J]. 热力发电, 2026, 55(2): 147-157. WANG Tianyu, ZHANG Jiangfeng, YIN Haorui, et al. Stochastic model predictive control for hybrid energy storage assisted thermal power unit in AGC based on adaptive Markov power prediction[J]. Thermal Power Generation, 2026, 55(2): 147-157.

Stochastic model predictive control for hybrid energy storage assisted thermal power unit in AGC based on adaptive Markov power prediction

WANG Tianyu¹, ZHANG Jiangfeng¹, YIN Haorui², ZHANG Xujuan², ZHAO Hongyu¹,
WANG Qi¹, LI Quan¹

(1. Electric Power Research Institute, State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310014, China;

2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: [Objective] With the growing integration of renewable energy sources into the power grid, frequency fluctuations have become a significant challenge. To address this, hybrid energy storage systems (HESS) are used to assist thermal power units in responding to automatic generation control (automatic generation control, AGC) commands. This paper proposes a novel hybrid power distribution strategy based on stochastic model predictive control (SMPC) to enhance the regulation performance of thermal power units in AGC applications, particularly

收稿日期: 2025-11-13 修回日期: 2025-12-15 接受日期: 2025-12-18 网络首发日期: 2025-12-31

基金项目: 国网浙江省电力有限公司科技项目 (B311DS240011)

Supported by: Science and Technology Project of State Grid Zhejiang Power Co., Ltd. (B311DS240011)

第一作者简介: 王天宇 (1991), 男, 博士, 高级工程师, 主要研究方向为网源协调、新能源调峰调频控制、检测与自动化装置, tywangncepu@163.com。

通信作者简介: 尹昊蕊 (2002), 女, 硕士研究生, 主要研究方向为火储联合系统调频控制, yinhaorui@ncepu.edu.cn。

under fluctuating power demands. The aim is to optimize the power allocation between the thermal power unit and the HESS to improve the accuracy, stability, and efficiency of the regulation process, ensuring a more reliable response to AGC signals. [Methods] The proposed strategy first constructs a power demand model for the HESS system, consisting of lithium titanate batteries for high-power storage and lithium iron phosphate batteries for energy storage, based on a Markov probability matrix, which simulates the response of the thermal power unit to AGC commands. An adaptive mechanism is introduced to dynamically adjust the state transition probabilities in real-time, enhancing the accuracy of power demand predictions during AGC fluctuations. Additionally, a scene tree generation method is proposed, which combines probability thresholds with stratified sampling to transform the probability distribution output by the adaptive Markov model into a finite set of scenarios for optimization. This method is designed to better handle the uncertainty of power demand predictions under multiple future scenarios, addressing the inherent variability of AGC command responses. Finally, the strategy integrates the above components into an SMPC controller, which optimizes power distribution between the thermal power unit and HESS in real-time, considering the stochastic nature of power demands and control parameters. [Results] Simulation experiments demonstrate that the proposed strategy significantly outperforms traditional frequency regulation strategies, which do not incorporate power prediction, and static SMPC strategies that lack dynamic correction of state transition probabilities. The performance index K_p is improved by 14.1% and 7.5%, respectively, showing that the SMPC strategy with adaptive power demand forecasting can achieve more precise and stable regulation performance. Additionally, the model's ability to handle uncertainty in power demand prediction allows for more accurate and timely responses to AGC fluctuations, resulting in better coordination between the thermal power unit and the HESS. [Conclusion] The proposed strategy effectively enhances the collaborative regulation performance between the thermal power unit and HESS, offering strong application potential. Further optimization of the model can improve its robustness and adaptability in practical applications, advancing the implementation of this technology.

Key words: automatic generation control; hybrid energy storage system; adaptive Markov model; scenario tree; stochastic model predictive control

随着新能源发电系统接入电网的规模不断扩大, 电网频率波动问题日益突出, 火储联合调频系统凭借其快速响应与稳定支撑的优势, 能够有效平抑频率波动^[1-2]。电池储能单元响应速度快、调频精度高, 具有一定的反向调节能力, 是辅助火电机组进行调频的有效手段^[3]。然而, 单一类型电池难以在功率密度、能量密度和循环寿命上同时满足要求, 需要选取特性互补的储能设备组成混合储能系统 (hybrid energy storage system, HESS), 以满足瞬时功率支撑和长时能量调节需求^[4-6]。对此, 本文采用由钛酸锂电池 (lithium titanium oxide battery, LTO) 与磷酸铁锂电池 (lithium iron phosphate battery, LFP) 构成的双类型锂电池 HESS, 使控制策略能够同时兼顾快速调节能力与能量支撑能力, 为后续设计预测-控制方法提供明确的应用场景。

在火储联合系统中, 设计合理的调频控制策略是提升自动发电控制 (automatic generation control, AGC) 调节性能与优化储能电池利用率的关键^[7]。目前, 火储联合调频系统中常用的调频控制策略包括比例分配^[8]、频谱分解^[9]等, 上述方法主要根据当前时刻 AGC 调频指令和火电机组出力偏差以及各系统响应特性来分配功率, 而未考虑未来的功率需求。在负荷与新能源波动的影响下, 这种基于瞬时状态的分配方式会导致 HESS 充放电指令频繁切

换, 不仅会降低调频精度, 而且会加速电池损耗。因此, 引入未来功率需求的预测信息, 对优化火电机组与 HESS 之间乃至 HESS 内部的功率分配, 进而提升 AGC 调节性能具有重要意义^[10-11]。此外, 朱振山等^[12]提出在 AGC 调节中利用模型预测控制 (model predictive control, MPC) 策略, 基于系统模型对未来状态的预测来优化储能系统出力并调整荷电状态 (state of charge, SOC) 恢复权重, 但其预测模型多依赖确定性输入。实际系统中, 未来的功率需求具有显著的不确定性, 表现为一定的概率分布特征。因此, 构建能够准确刻画未来功率需求的概率分布, 并能与控制策略紧密协同的预测模型, 成为进一步提升火储联合调频性能的关键问题之一。

为得到未来时刻发电功率, 有学者考虑火电机组变负荷机理、功率时序特性等因素构建了预测模型。例如, Zhang 等人^[13]对火电机组实际响应速率进行确定性计算, 将所得功率缺额直接作为 HESS 功率需求预测值, 但火电机组的爬坡能力受限于锅炉特性、煤质、设备状态等因素, 导致所得的功率预测存在较大误差。考虑到功率需求具有时序相关性, 可从历史数据中挖掘其时序特性来构建模型。魏乐等^[14]基于自动机器学习建立了负荷回归预测模型, 在训练数据中引入 AGC 日前计划值以减小

预测误差。还有学者利用深度学习技术从历史数据中提取功率需求特征。姚钦才等^[15]采用基于长短期记忆神经网络的多步预测模型来计算发电功率,王玮等^[16]通过卷积神经网络层增强时间序列得到功率时序关系。卷积神经网络模型复杂且内部逻辑难以解释,难以应用于火储联合控制场景。马尔科夫模型将历史数据划分为不同状态,通过状态转移来推演未来时刻数据可能状态的概率分布。因此,可利用马尔科夫模型描述 HESS 功率需求的时序演化规律^[17-18]。文献[19-22]将马尔科夫模型应用于功率需求预测,发现其表现出良好的性能,但在构建状态转移矩阵时未考虑负荷的不确定性。综合来看,现有功率预测方法可大致分为基于机理的确定性方法、基于机器学习的数据驱动方法、基于深度学习的时序建模方法以及基于马尔科夫状态转移的概率建模方法。前两类方法难以刻画负荷波动的随机性,深度学习方法虽精度较高但缺乏可解释性,而标准马尔科夫模型未能考虑负荷的时变特征,难以反映真实系统的不确定性。

用电负荷与新能源发电的随机波动使得火储联合调频系统响应 AGC 指令过程中的 HESS 功率需求具有不确定性^[23]。标准的马尔科夫模型通过静态状态转移矩阵从历史数据中提取信息,无法反映系统的不确定性。为此,引入最近一段时间观测的状态转移结果对状态转移概率进行滚动更新,生成自适应转移概率矩阵以提升功率需求模型的预测精度。为描述多场景下的功率预测不确定性,利用场景树生成方法得到未来多个决策域内可能出现的系统状态及发生概率,并将自适应模型输出的概率分布转化为离散的场景集合,建立 HESS 功率需求的多场景模型。

在得到未来功率需求信息下,可采用 MPC 实现 HESS 功率分配。但是,HESS 功率需求预测结果呈概率分布形式,传统 MPC 方法采用确定性预测模型进行优化,无法直接处理概率分布的预测信息。为此,提出一种随机模型预测控制(stochastic model predictive control, SMPC)策略,将成本函数数学期望替代传统控制中的确定性成本,并以未来 HESS 功率需求作为扰动嵌入优化问题中,从而将随机优化转化为可求解的确定性形式。

鉴于此,提出一种结合马尔科夫模型 HESS 功率需求和 SMPC 的火储系统调频控制策略。首先,基于马尔科夫模型构建 HESS 功率需求预测模型,同时引入自适应机制实时动态修正状态转移概率;

其次,提出一种场景树生成算法,用以描述多场景下的功率预测不确定性;在此基础上,设计 SMPC 策略,以实现 HESS 功率分配的优化。

1 HESS 功率需求不确定性建模

混合储能辅助火电机组调频系统结构如图 1 所示。调度中心 AGC 指令经过远程测控装置同时发送给火电机组 DCS 和混合储能控制系统。火电机组接收到 AGC 指令后立刻响应,储能控制系统实时获取机组实际功率及 AGC 调节偏差,并根据设计的控制策略调整功率输出,从而辅助火电机组完成调频任务。




图 1 混合储能辅助火电机组调频系统结构

Fig.1 Structural diagram of a hybrid energy storage system assisting thermal power unit in AGC frequency regulation

1.1 HESS 功率需求马尔科夫模型

考虑 HESS 功率需求历史样本的状态集合 s 为:

$$s = [s_1, s_2, \dots, s_m]^T \quad (1)$$

式中: m 为状态个数; s_i 为状态 i 的功率需求值 (HESS 放电为正, 充电为负)。记 k 时刻功率需求为 $P_d(k)$, 将 $k+1$ 时刻需求功率作为随机过程来建立预测模型, 可用马尔科夫状态转移概率矩阵 T 描述状态变化, 该矩阵中元素 t_{ij} 表示为:

$$t_{ij} = P_r[P_d(k+1) = s_j | P_d(k) = s_i], \quad \forall i, j \in \{1, 2, \dots, m\} \quad (2)$$

式中: $P_i[s_j|s_i]$ 为从状态 i 到达状态 j 的概率。

采用最大似然估计法确定转移概率值, 即:

$$\begin{cases} t_{ij} = \frac{\mu_{ij}}{\mu_i} \\ \mu = \sum_{j=1}^m \mu_{ij} \end{cases}, \forall i, j \in \{1, 2, \dots, m\} \quad (3)$$

式中: μ_{ij} 为历史数据中从状态 i 转移到状态 j 的次数; μ_i 为从状态 i 转移出去的总次数。

设给定 k 时刻功率需求的概率分布为 $p(k)$, 则未来 $k+h$ 时刻功率需求的概率分布为:

$$p(k+h) = T^h p(k) \quad (4)$$

未来 $k+h$ 时刻的预测功率期望为:

$$\hat{P}_d(k+h) = s^T p(k+h) \quad (5)$$

式中: $s=[s_1, \dots, s_m]$, s_i 为状态 i 的功率需求值。

1.2 马尔科夫转移概率矩阵自适应算法

为更准确地预测功率需求, 利用式(4)计算概率分布实时调整转移矩阵 T , 构建自适应转移概率矩阵。具体调整过程如下。

1) 计算状态转移概率

假设当前时刻功率需求为 s_i , 计算距当前时刻最近 ΔT 时段内功率需求 s_i 的转移概率 $[\tau_{i1}, \tau_{i2}, \dots, \tau_{im}]$:

$$\tau_{ij} = \frac{\mu_{ij}}{\mu_i}, j=1, 2, \dots, m \quad (6)$$

式中: μ_{ij} 为当前时刻前 ΔT 内从状态 i 转移到状态 j 的次数; μ_i 为该时段内从状态 i 转移出去的总次数。

2) 调整状态转移概率

利用式(7)计算 δ_{ij} :

$$\delta_{ij} = \exp(\lambda \cdot (\tau_{ij} - t_{ij})) \quad (7)$$

式中: τ_{ij} 为 ΔT 时段内功率需求从状态 i 转移到状态 j 的概率; t_{ij} 为待调整转移概率矩阵中从状态 i 转移到状态 j 的概率; λ 为自适应调整系数, 可通过实际预测结果调整, 结合本文选取的机组实际运行数据, 经多组离线交叉验证, 取 λ 为 1.1, 同时兼顾模型对 AGC 波动的快速适应能力与预测稳定性。

基于 δ_{ij} 调整转移概率矩阵:

$$t'_{ij} = \delta_{ij} \cdot t_{ij} \quad (8)$$

式中: t'_{ij} 为基于 δ_{ij} 调整后的转移概率矩阵中从状态 i 转移到状态 j 的概率。

3) 状态转移概率矩阵归一化

转移概率矩阵应满足 $\sum_{j=1}^m t'_{ij} = 1$, 因此对矩阵

元素归一化得到:

$$t''_{ij} = \frac{t'_{ij}}{\sum_{j=1}^m t'_{ij}} \quad (9)$$

利用调整后的自适应转移概率矩阵 $(t''_{ij})_{m \times m}$ 代替式(4)和式(5)中的矩阵 T , 实现功率需求预测。

为定量评估模型的预测性能, 选取均方根误差 δ_{RMSE} 作为评价指标, 计算方法如下:

$$\delta_{RMSE} = \frac{1}{n} \sum_{k=1}^n \sqrt{\frac{1}{h} \sum_{i=1}^h (P_d(k+i) - \hat{P}_d(k+i))^2} \quad (10)$$

式中: $P_d(k+i)$ 为 k 时刻第 i 步的 HESS 功率需求真实值; $\hat{P}_d(k+i)$ 为 k 时刻第 i 步的马尔科夫预测模型预测值; h 为预测步数; n 为样本数。

1.3 场景树的设计生成

为解决预测步长增加所产生的场景匮乏问题, 提出了一种结合动态概率阈值和分层抽样的场景树生成方法来筛选 HESS 功率需求潜在情景。在每个预测时域内, 利用状态转移概率生成场景树, 每个节点代表预测时域内的一种可能功率需求, 并参与后续决策。同时, 引入分层加权抽样, 确保高、中、低概率场景均被覆盖。以 5 步预测为例, 场景树设计过程如图 2 所示, 具体过程如下。




图2 场景树生成过程 (5步预测)

Fig.2 Scenario tree generation process (five-step prediction)

1) 设置动态阈值

为了在近期预测中使用较高阈值, 同时保证预测步长增加时保留更多的场景转移可能性, 设置第 h 步预测时转移概率阈值 β_h 为:

$$\beta_h = \beta_0 \cdot \gamma^{h-1} \quad (11)$$

式中: γ 为衰减因子 ($0 < \gamma < 1$), 结合本文选取的机组实际运行数据, 经多组离线交叉验证将 γ 取为 0.93, 在场景树的规模、对远期不确定性的覆盖能力以及最终控制器的计算负荷与性能中取得最佳

平衡, β_0 为基础概率阈值。

2) 生成候选节点集

对于当前节点 $\mathcal{N}_k$, 选取后继节点生成候选节点集:

$$\mathcal{Z} = \left\{ \mathcal{N}_{s(k,j)} \mid t_{kj} \geq \beta_n, j = 1, 2, \dots, m \right\} \quad (12)$$

3) 分配概率分层与权重

将候选节点集 $\mathcal{Z}$ 按转移概率值分为高、中、低 3 层, 并按概率集中度分配各层抽样数量: 若概率分布集中, 则增加高层抽样比; 否则平衡各层抽样比例。

4) 分层加权随机抽样

对每层转移概率归一化后, 进行随机抽样, 并与 0~1 范围内的随机数比较, 选中满足条件的节点。

5) 计算节点概率

对于选中的后继节点 $\mathcal{N}_{s(k,j)}$, 计算节点选中概率:

$$\zeta_j = \zeta_k \cdot t_{kj} \quad (13)$$

式中: ζ_k 为场景树中当前节点 $\mathcal{N}_k$ 的选中概率, 根节点选中概率为 1; ζ_j 为处于状态 j 的后继节点的选中概率。

6) 递归生成与终止条件

对于新生成的节点, 重复步骤(2)—(5), 直到所选节点概率小于阈值, 记录从根节点到叶节点的完整路径, 形成场景序列。

2 基于随机模型预测控制的 HESS 功率分配策略

2.1 HESS 辅助 AGC 调节模型

考虑实际工程案例, HESS 由高功率特性钛酸锂电池 (LTO) 与高能量特性磷酸铁锂电池 (LFP) 组成, 辅助火电机组实现 AGC 调节过程。HESS 在 k 时刻的功率需求 $P_d(k)$ 为:

$$P_d(k) = P_{LFP}(k) + P_{LTO}(k) + P_{dif}(k) \quad (14)$$

式中: $P_{LFP}(k)$ 和 $P_{LTO}(k)$ 分别为磷酸铁锂电池 (LFP) 和钛酸锂电池 (LTO) 在 k 时刻的功率, MW; $P_{dif}(k)$ 为 HESS 补偿后的功率差, MW。

磷酸铁锂电池 (LFP) 和钛酸锂电池 (LTO) 在 $k+1$ 时刻的 SOC 值可以通过下式确定:

$$S_{SOC,LFP}(k+1) = S_{SOC,LFP}(k) - P_{LFP}(k) \cdot \frac{\Delta t}{E_{LFP}} \quad (15)$$

$$S_{SOC,LTO}(k+1) = S_{SOC,LTO}(k) - P_{LTO}(k) \cdot \frac{\Delta t}{E_{LTO}} \quad (16)$$

式中: Δt 为采样时间; $S_{SOC,LFP}$ 和 $S_{SOC,LTO}$ 分别为磷酸铁锂电池和钛酸锂电池的 SOC; E_{LFP} 和 E_{LTO} 分别为磷酸铁锂电池和钛酸锂电池的储能容量; P_{LFP} 和

P_{LTO} 分别为磷酸铁锂电池和钛酸锂电池的功率。

以混合储能系统的 SOC 值构建状态向量 $\mathbf{x}(k)$ 和输出向量 $\mathbf{y}(k)$, 即:

$$\mathbf{x}(k) = [S_{SOC,LFP}(k), S_{SOC,LTO}(k)]^T \quad (17)$$

$$\mathbf{y}(k) = [S_{SOC,LFP}(k), S_{SOC,LTO}(k)]^T \quad (18)$$

构建输入向量 $\mathbf{u}(k)$ 如下:

$$\mathbf{u}(k) = [P_{LFP}(k), P_{dif}(k)]^T \quad (19)$$

以功率需求 $w(k)$ 作为扰动参数:

$$w(k) = P_d(k) \quad (20)$$

基于上式可得到状态空间模型:

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}\mathbf{x}(k) + \mathbf{B}_1\mathbf{u}(k) + \mathbf{B}_2w(k) \\ \mathbf{y}(k) = \mathbf{C}\mathbf{x}(k) \end{cases} \quad (21)$$

其中:

$$\begin{aligned} \mathbf{A} = \mathbf{C} &= \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \\ \mathbf{B}_1 &= \begin{bmatrix} -\frac{\Delta t}{E_{LFP}} & 0 \\ \frac{\Delta t}{E_{LTO}} & \frac{\Delta t}{E_{LTO}} \end{bmatrix} \\ \mathbf{B}_2 &= \begin{bmatrix} 0 \\ \frac{\Delta t}{E_{LTO}} \end{bmatrix} \end{aligned} \quad (22)$$

2.2 随机模型预测控制策略

HESS 功率需求 $w(k)$ 为随机变量, 基于马尔科夫模型和多场景树实现该变量的预测, 构建随机模型预测控制 (SMPC) 策略得到 HESS 最优输出。SMPC 的控制目标设置为, 在功率偏差 P_{dif} 的基础上, 使 HESS 的 SOC 保持在期望值附近, 同时减小磷酸铁锂电池 (LFP) 充放电功率波动。因此, 得到目标函数如下:

$$\min_{\mathbf{u}} \sum_{\mathcal{N}_i \in \mathcal{N} \setminus \{\mathcal{N}_0\}} \zeta_i (\mathbf{y}_i - \mathbf{y}_{ref}(k))^T \mathbf{Q} (\mathbf{y}_i - \mathbf{y}_{ref}(k)) + \sum_{\mathcal{N}_i \in \mathcal{N} \setminus \mathcal{S}} \zeta_i \mathbf{u}_i^T \mathbf{R} \mathbf{u}_i \quad (23)$$

其中:

$$\mathbf{Q} = \begin{bmatrix} Q_{LFP,SOC} & 0 \\ 0 & Q_{LTO,SOC} \end{bmatrix}, \mathbf{R} = \begin{bmatrix} R_{LFP,p} & 0 \\ 0 & R_{dif,p} \end{bmatrix} \quad (24)$$

$$[\mathbf{y}_{ref}(k)]_1 = S_{SOC,LFP}(k), [\mathbf{y}_{ref}(k)]_2 = S_{SOC,LTO}(k)$$

式中: ζ_i 为场景树中节点 (除去根节点 $\mathcal{N}_0$) 的概率; $\mathbf{y}_i$ 为节点输出; $\mathbf{u}_i$ 为场景树中节点 (除去尾节点集 $\mathcal{S}$) 的输入; $\mathbf{Q}$ 和 $\mathbf{R}$ 为目标函数的权重系数矩阵。

参数 $Q_{LFP,SOC}$ 、 $Q_{LTO,SOC}$ 、 $R_{LFP,p}$ 、 $R_{dif,p}$ 均大于 0, 其中: $Q_{LFP,SOC}$ 较大时表征磷酸铁锂电池 (LFP) SOC

变化更小,从而延长电池寿命; $R_{LFP,p}$ 较大时可减小磷酸铁锂电池(LFP)充放电功率波动; $R_{dif,p}$ 较大时可使 HESS 输出尽可能接近功率需求 P_d 。

目标函数的约束条件如下。

1) SOC 约束

场景树节点输出 y_i 满足 HESS 的 SOC 约束:

$$\begin{cases} S_{SOC,LFP,min} < [y_i(k)]_1 < S_{SOC,LFP,max} \\ S_{SOC,LTO,min} < [y_i(k)]_2 < S_{SOC,LTO,max} \end{cases}, \quad (25) \\ \forall \mathcal{N}_i \in \mathcal{N} \setminus \{\mathcal{N}_0\}$$

式中: $S_{SOC,LFP,min}$ 、 $S_{SOC,LFP,max}$ 、 $S_{SOC,LTO,min}$ 、 $S_{SOC,LTO,max}$ 分别为磷酸铁锂电池(LFP)和钛酸锂电池(LTO)

的最小和最大 SOC 值。

2) 功率约束

场景树节点满足 HESS 的功率约束:

$$\begin{cases} P_{LFP,min} < [u_i(k)]_1 < P_{LFP,max} \\ P_{LTO,min} < [u_i(k)]_2 < P_{LTO,max} \end{cases}, \quad \forall \mathcal{N}_i \in \mathcal{N} \setminus \mathcal{S} \quad (26)$$

式中: $P_{LFP,min}$ 、 $P_{LFP,max}$ 和 $P_{LTO,min}$ 、 $P_{LTO,max}$ 分别为磷酸铁锂电池和钛酸锂电池的最小和最大功率。

上述优化问题可以转化为标准的二次规划问题,以求得输入向量 u ,并将与根节点 $\mathcal{N}_0$ 对应的向量 u_0 作为 HESS 的输出。所提出的随机模型预测控制策略的框架如图 3 所示。




图 3 基于自适应马尔科夫预测的混合储能-火电联合调频随机模型预测控制框架

Fig.3 Framework of the stochastic model predictive control for HESS-thermal power joint frequency regulation based on adaptive Markov prediction

3 仿真结果与分析

实际工程案例中,某 330 MW 火电机组配置磷酸铁锂电池(LFP)和钛酸锂电池(LTO)双类型锂电池混合储能系统,电池功率容量均为 6 MW,能量容量分别为 3 MW h、0.05 MW h。控制器采样时间为 3 s,数据采样时间为 1 s。机组 AGC 调节性能指标 K_p 可根据《华北区域并网发电厂辅助服务管理实施细则》和《华北区域发电厂并网运行管理实施细则》由调节速率 K_1 、调节精度 K_2 和响应速率 K_3 计算得到。

3.1 功率预测结果分析

基于机组响应 AGC 指令的历史数据,HESS 功率需求在-14~14 MW 范围内。离散区间的大小决定状态数量:若区间过大,则状态数量不足,难以刻画 AGC 信号的细粒度功率波动;若区间过小,则状态数量急剧增加,导致部分状态出现样本不足的问题,使转移概率矩阵变得稀疏、预测结果不稳定。因此,选择 1/3 MW 作为离散区间建立马尔科夫预测模型,采用一天内的响应数据来获取转移概率矩阵,离散后的数据状态个数 $m=40$,能够在预测精细

度、转移矩阵稳定性以及计算复杂度之间取得最优平衡。当 AGC 指令增加或减少时, HESS 功率需求的变化趋势不同, 因此分别建立转移概率矩阵来得到功率需求预测模型, 结果如图 4 所示。




图 4 HESS 功率需求转移概率矩阵
Fig.4 Transition probability matrices for HESS power demand

由式(6)可知, 在构建自适应转移概率矩阵时, 选择不同时间段 ΔT 会对马尔科夫模型预测精度产生一定影响。因此, 选择不同 ΔT 进行 5 步预测, 采用 δ_{RMSE} 评估模型的预测精度, 以确定最优的自适应时间 ΔT 。结果如表 1 所示。

表 1 不同自适应时间下的预测误差
Tab.1 Prediction errors with different adaptive times

自适应时间/h	$\delta_{\text{RMSE}}/\text{MW}$	准确率提升率/%
none	3.398 8	—
0.5	2.382 8	29.06
1.0	2.374 4	29.30
1.5	2.373 4	29.34
2.0	2.379 4	29.16
2.5	2.389 7	28.85
3.0	2.415 7	28.08
3.5	2.431 4	27.61

由表 1 可见, 随着自适应时间的增加, 模型预测误差 δ_{RMSE} 先减小后增大。若 ΔT 过长, 则马尔科夫矩阵反映的是负荷的平均波动; 反之, 则该矩阵受负荷随机波动的影响更大。当自适应时间为 1.5 h 时, 预测精度提升率最高, 表明所提出的自适应马尔科夫模型能够提供可靠的功率需求信息。


3.2 随机模型预测控制结果及分析

3.2.1 整体控制效果分析

采用随机模型预测控制策略对火储联合系统进行控制, 参数设置如表 2 所示。火储系统联合调频效果以及 HESS 功率分配和对应的 SOC 状态如图 5 所示。由图 5a)可见, SMPC 策略能够较好地跟踪 AGC 指令变化, AGC 指令在 01:10—01:18 持续上升和 01:18—01:27 持续下降时, 在火电机组增加和减小功率调节输出的同时, SMPC 策略可以控制 HESS 出力及时提供补偿以减少功率偏差。

表 2 随机模型预测控制策略参数设置
Tab.2 Parameters settings in the SMPC strategy

SMPC 参数	定义	取值
λ	自适应调整系数	1.1
γ	衰减因子	0.93
$Q_{\text{LFP},\text{SOC}}$	目标函数权重系数	0.1
$Q_{\text{LTO},\text{SOC}}$	目标函数权重系数	10
$R_{\text{LFP},p}$	目标函数权重系数	0.1
$R_{\text{dif},p}$	目标函数权重系数	10
$S_{\text{SOC,LFP,min}}$	LFP 电池最小 SOC 约束	0.2
$S_{\text{SOC,LFP,max}}$	LFP 电池最大 SOC 约束	0.8
$S_{\text{SOC,LTO,min}}$	LTO 电池最小 SOC 约束	0.05
$S_{\text{SOC,LTO,max}}$	LTO 电池最大 SOC 约束	0.95
P_{LFP}/MW	LFP 功率容量	6
E_{LFP}/MW	LFP 能量容量	3
P_{LTO}/MW	LTO 功率容量	6
E_{LTO}/MW	LTO 能量容量	0.05
N_p	预测时域	5
$\Delta t/\text{s}$	采样周期	3






图 5 SMPC 策略仿真结果
Fig.5 Simulation results of the SMPC strategy

由图 5b)可见,在整个调频过程中,钛酸锂电池 (LTO) 主要承担快速功率响应,其输出频繁变化但幅值较小;而磷酸铁锂电池 (LFP) 负责长期能量支撑,其功率变化较平稳,在 AGC 指令持续上升阶段可提供较大的放电功率。

由图 5c)可见,磷酸铁锂电池 SOC 整体保持在中高水平,约 0.6~0.8,呈较稳定趋势;钛酸锂电池 (LTO) SOC 在 0.3~0.6 波动,并在约 01:15—01:20 期间出现较明显下降,表明其在该阶段承担了主要的短时调节任务。

总体而言,采用 SMPC 策略能够快速精确响应 AGC 调节指令,实现对双类型锂电池能量的合理分配,使能量型电池 (磷酸铁锂电池) 的 SOC 维持在中值附近,而功率型电池 (钛酸锂电池) 快速响应高频扰动,从而兼顾系统调频性能与电池寿命。

3.2.2 不同权重系数下控制效果对比

目标函数权重系数不仅会改变两类储能单元的出力分配特性,还会影响响应速率与调节精度。为比较权重系数对调频效果的影响,设置不同的参数集合进行仿真。具体情况如下。

- 1) 参数集 I 按照表 2 设置各个权重系数, $Q_{LTO,SOC} = 10$, $Q_{LFP,SOC} = R_{LFP,p} = 0.1$, $R_{dif,p} = 10$ 。
- 2) 参数集 II 4 个权重系数的值相同,即 $Q_{LTO,SOC} = Q_{LFP,SOC} = R_{LFP,p} = R_{dif,p} = 0.1$ 。
- 3) 参数集 III 增大 $Q_{LFP,SOC}$ 减小 $Q_{LTO,SOC}$,即 $Q_{LTO,SOC} = 0.1$, $Q_{LFP,SOC} = R_{LFP,p} = 10$, $R_{dif,p} = 10$ 。
- 4) 参数集 IV 增大 $R_{dif,p}$,即 $Q_{LTO,SOC} = 10$, $Q_{LFP,SOC} = R_{LFP,p} = 0.1$, $R_{dif,p} = 100$ 。

表 3 给出了各参数集下调节性能对比结果。

表 3 各参数集调节性能指标
Tab.3 Regulation performance metrics of various parameters sets

参数集	K_1	K_2	K_3	K_p
I	1.38	1.82	1.77	4.45
II	0.82	1.88	1.94	2.99
III	1.03	1.88	1.94	3.76
IV	1.39	1.69	1.77	4.16

参数集 I 中,磷酸铁锂电池 (LFP) 具有更高的 SOC 权重,钛酸锂电池 (LTO) 主要承担快速补偿任务,系统对 AGC 指令响应较快,磷酸铁锂电池 (LFP) 则通过较强的能量约束维持 SOC 稳定,实现能量平衡与快速协调;该配置下系统总体调节性能最优,响应速度与稳态精度兼顾。

参数集 II 中,权重系数相同,HESS 中两类储能地位相对均衡,调节任务分配更平均;钛酸锂电池 (LTO) 快速出力优势受限,而磷酸铁锂电池 (LFP) 响应较慢,导致系统在 AGC 初期的动态响应减弱,表现为 K_1 减小,在循环后期磷酸铁锂电池 (LFP) 逐步承担更多调节任务,系统稳态偏差减小,因而 K_3 增大。

参数集 III 中,磷酸铁锂电池 (LFP) 权重增大、钛酸锂电池 (LTO) 权重减小,因此优先使用钛酸锂电池 (LTO) 进行补偿,导致钛酸锂电池 (LTO) 能量快速消耗。

由表 3 可见, K_1 和 K_3 较高,说明初期和末期响应良好,但 K_2 略降,表明过度偏重磷酸铁锂电池 (LFP) 会削弱系统整体协同性。参数集 IV 提高了功率偏差的约束权重,强化了两储能系统间的协同一致性,其调节性能次于参数集 I,但优于参数集 II 和 III。

3.2.3 转移概率矩阵自适应算法有效性分析

为验证转移概率矩阵对控制效果的影响,将基于自适应转移概率矩阵的 SMPC 策略记为 Model I,即本文提出的调频控制策略,将基于未考虑自适应算法 (即静态转移概率矩阵) 构建的控制策略记为 Model II,二者控制效果对比如表 4 和图 6 所示。

表 4 引入自适应算法前、后调节性能指标
Tab.4 Regulation performance metrics before and after the introduction of adaptive algorithms

控制策略	K_1	K_2	K_3	K_p	$\sigma(S_{SOC,LFP})$	$\sigma(S_{SOC,LTO})$
Model I	1.38	1.82	1.77	4.45	0.070	0.09
Model II	1.30	1.76	1.81	4.14	0.001	0.26




图 6 引入自适应算法前、后仿真结果对比

Fig.6 Comparison of simulation results before and after the introduction of the adaptive algorithm

可以看出,引入自适应算法后,系统的综合性能指标 K_p 由 4.14 提升至 4.45,提升了 7.5%。具体来看,Model I 在调节精度 K_1 和调节速度 K_2 指标上均实现了提升,原因在于自适应转移概率矩阵能够通过更新机制动态捕捉 HESS 需求功率的瞬时变化,从而提供更接近实际的预测场景树,有效降低预测误差带来的控制滞后;对于响应速率 K_3 ,虽然其数值相较 Model II 有下降,但这是由于自适应预测提高了场景树精度,使控制器规划出更加平滑且符合机组动态特性的功率调整过程,从而避免了 Model II 中因预测偏差而产生快速跃变,使跨越死区所需的归一化时间略有延长,导致 K_3 出现轻微回落,这一变化反映出响应行为由追求极短瞬时跨越转向兼顾稳定性与电池寿命的合理调整。对比电池 SOC 变化趋势也可以看出,Model I 的 $S_{SOC,LTO}$ 波动性显著降低,其标准差 $\sigma(S_{SOC,LTO})$ 从 0.26 降至 0.09。可以看出,精确的功率需求预测使 SMPC 能够更平滑地规划钛酸锂电池 (LTO) 的充放电行为,有效避免因非必要深度充放电带来的不稳定性,保证电池的安全运行和长效可用性。

2 种控制策略下 AGC 调节过程和电池 SOC 变化趋势如图所示。由图 6a)可以看出,Model I 的总出力曲线相对 Model II 能够更迅速地跟踪 AGC 指令,尤其在指令斜率变化较大的区域,Model II 曲线往往出现明显的偏差和迟滞。图 b)中能量型磷酸铁锂电池 (LFP) 的 SOC 波动性小幅增加,为 AGC 大幅变化及时提供了能量支持,使调频过程更加平稳。图 c)中功率型钛酸锂电池 (LTO) 的 SOC 波动性在 Model I 下明显降低,这更直观地体现出钛酸锂电池 (LTO) 在 Model I 中主要承担高频短时功率响应,而非中低频能量支撑,使其 SOC 能够稳定维持在中值附近并保留充足裕度以应对突发指令,保障了系统的持续高性能输出。

3.2.4 传统火储联合调频控制策略效果对比

为验证调频控制时引入功率预测的有效性,采用未考虑功率预测的传统调频控制策略进行对比,并将传统调频控制策略记为 Model III,对比结果如表 5 和图 7 所示。

表 5 Model I 与 Model III 调节性能指标对比
Tab.5 Comparison of regulation performance metrics between Model I and Model III

控制策略	K_1	K_2	K_3	K_p
Model I	1.38	1.82	1.77	4.45
Model II	1.46	1.59	1.68	3.90




图 7 Model I 与 Model III 调节结果对比
Fig.7 Comparison of regulation results between Model I and Model III

可以看出,由于火电机组在 AGC 指令快速变化时响应存在明显滞后,在未考虑 HESS 功率需求预测时,Model III 难以及时协调储能系统之间的能量分配,导致整体调节性能受限。相比之下,Model I 在控制周期内引入对未来功率需求的预测信息,能够提前规划钛酸锂电池 (LTO) 与磷酸铁锂电池 (LFP) 的出力,即由钛酸锂电池 (LTO) 承担快速功率波动、磷酸铁锂电池 (LFP) 承担长时能量支撑,从而在动态响应速度与能量平衡之间实现协

调。由表 7 可知, Model I 的综合调频性能指标较 Model III 提升约 14.1%, 表明考虑 HESS 功率需求预测能够显著增强火储联合调频系统的调频能力。

4 结 论

1) 构建了自适应马尔科夫模型与随机模型预测控制框架。通过引入转移概率矩阵自适应算法准确刻画了功率需求的不确定性, 结合场景树生成算法, 为 SMPC 提供高质量的概率场景输入。

2) 提出的随机模型预测控制策略显著提升了系统的调频性能。仿真结果表明, 与不考虑功率预测的传统联合调频以及未引入动态修正的由静态转移概率矩阵构建的随机模型预测控制策略相比, 本文策略的 AGC 调频综合性能指标 K_p 分别提升了 14.1% 和 7.5%, 验证了其在调频性能上的优越性。

3) 实现了调频性能与电池寿命的协同优化。所提策略在提升调频精度的同时, 有效降低了高功率型钛酸锂电池 (LTO) 的 SOC 波动幅度, 兼顾了系统调节性能与储能设备的使用寿命。

【参 考 文 献】

- [1] 余晋宇, 周荔丹, 于天佑, 等. 基于分布式模型预测控制的电-氢混合储能系统控制策略[J]. 电力系统自动化, 2025, 49(3): 114-124.
YU Jinyu, ZHOU Lidan, YU Tianyou, et al. Control strategy for electricity-hydrogen hybrid energy storage system based on distributed model predictive control[J]. Automation of Electric Power Systems, 2025, 49(3): 114-124.
- [2] 居文平, 王一帆, 赵勇, 等. 新型电力系统长时储能技术综述[J]. 热力发电, 2024, 53(9): 1-9.
JU Wenping, WANG Yifan, ZHAO Yong, et al. Overview of long-term energy storage technologies in new power systems[J]. Thermal Power Generation, 2024, 53(9): 1-9.
- [3] 李菁华, 兀鹏越, 黄富强, 等. 超级电容混合储能辅助火电机组 AGC 调频容量配置方案研究与应用[J]. 热力发电, 2025, 54(7): 101-110.
LI Jinghua, WU Pengyue, HUANG Fuqiang, et al. Research and application of AGC frequency regulation capacity allocation scheme for supercapacitor hybrid energy storage assisted thermal power unit[J]. Thermal Power Generation, 2025, 54(7): 101-110.
- [4] 杨鼎全, 魏平. 基于小波变换的混合储能二次调频容量优化配置方法研究[J]. 电网与清洁能源, 2025, 41(10): 24-35.
YANG Dingquan, WEI Ping. A study on the optimal capacity configuration method for secondary frequency regulation of hybrid energy storage based on wavelet transform[J]. Power System and Clean Energy, 2025, 41(10): 24-35.
- [5] 唐卫华, 陈长青, 史清芳, 等. 基于数据分解的“飞轮+锂电”混合储能系统辅助风电调频容量配置研究[J]. 电网与清洁能源, 2025, 41(9): 132-140.
TANG Weihua, CHEN Changqing, SHI Qingfang, et al. Research on frequency modulation capacity allocation of wind power assisted by “flywheel + lithium” hybrid energy storage system based on data decomposition[J]. Power System and Clean Energy, 2025, 41(9): 132-140.
- [6] LV Y, SUN H, WANG T, et al. A frequency modulation capability enhancement strategy of thermal power units by the integration of a hybrid energy storage system[J]. Applied Thermal Engineering, 2025, 278: 127441.
- [7] 刘佳钰, 梁晓斌, 黄锡芳, 等. 多类型储能参与电力系统频率调节的协同控制策略[J]. 中国电力, 2026, 59(1): 124-132.
LIU Jiayu, LIANG Xiaobin, HUANG Xifang, et al. Coordinated control strategy for multi-type energy storage participating in power system frequency regulation[J]. Electric Power, 2026, 59(1): 124-132.
- [8] 崔杨, 修志坚, 薄利明, 等. 考虑火-储深度调峰容量二次分配的含风电电力系统分层优化调度[J]. 电网技术, 2022, 46(7): 2520-2531.
CUI Yang, XIU Zhijian, BO Liming, et al. Hierarchical optimal scheduling of power systems with wind generation considering secondary allocation of thermal-storage deep peaking capacity[J]. Power System Technology, 2022, 46(7): 2520-2531.
- [9] 陈鹏, 王玮, 杨建青, 等. 基于多尺度分解的风火储协同调频控制策略[J]. 太阳能学报, 2024, 45(3): 428-435.
CHEN Peng, WANG Wei, YANG Jianqing, et al. Cooperative frequency regulation control strategy of wind-thermal-storage system based on multi-scale decomposition[J]. Acta Energiae Solaris Sinica, 2024, 45(3): 428-435.
- [10] 邢峰, 褚文超, 苏智东, 等. 基于 AGC 预测指令的火电机组控制策略[J]. 现代电力, 2023, 40(5): 742-750.
XING Feng, CHU Wenchao, SU Zhidong, et al. A control strategy of thermal power unit based on AGC prediction command[J]. Modern Electric Power, 2023, 40(5): 742-750.
- [11] AJAMI O M T, TAN R H G, NADARAJAH M, et al. Multi-objective optimization of HESS control for optimal frequency regulation in a power system with renewable penetration[J]. E-Prime-Advances in Electrical Engineering, Electronics and Energy, 2024, 10: 100805.
- [12] 朱振山, 翁凯亮, 欧阳海涛. 基于动态参与因子和自适应模型预测控制的电池储能二次调频控制策略[J]. 电工技术学报, 2026, 41(1): 343-358.
ZHU Zhenshan, WENG Kailiang, OUYANG Haitao. Secondary frequency modulation control strategy for battery energy storage based on dynamic participation factor and adaptive model predictive control[J]. Transactions of China Electrotechnical Society, 2026, 41(1): 343-358.
- [13] ZHANG F, HU Z, MENG K, et al. Hess sizing methodology for an existing thermal generator for the promotion of AGC response ability[J]. IEEE Transactions on Sustainable Energy, 2020, 11(2): 608-617.
- [14] 魏乐, 苏少忻, 房方, 等. 基于负荷预测的飞轮-火电系统自动发电控制响应性能优化[J]. 热力发电, 2023, 52(5): 92-99.
WEI Le, SU Shaoxin, FANG Fang, et al. Optimization of automatic generation control response performance of flywheel-thermal power system based on load forecasting[J]. Thermal Power Generation, 2023, 52(5): 92-99.
- [15] 姚钦才, 向文国, 陈时熠, 等. 基于 ICEEMDAN-KPCA-ICPA-LSTM 的光伏发电功率预测[J]. 动力工

- 程学报, 2025, 45(3): 374-382.
- YAO Qincai, XIANG Wenguo, CHEN Shiyi, et al. Photovoltaic power forecasting based on ICEEMDAN-KPCA-ICPA-LSTM[J]. Journal of Chinese Society of Power Engineering, 2025, 45(3): 374-382.
- [16] 付炳喆, 王玮, 任国瑞, 等. 考虑增强特征选择的深度卷积时序网络短期风功率预测[J]. 动力工程学报, 2024, 44(10): 1565-1573.
- FU Bingzhe, WANG Wei, REN Guorui, et al. Consider enhancing feature selection in deep convolutional temporal networks for short-term wind power forecasting[J]. Journal of Chinese Society of Power Engineering, 2024, 44(10): 1565-1573.
- [17] 朱晨曦, 张焰, 严正, 等. 采用改进马尔科夫链蒙特卡洛法的风电功率序列建模[J]. 电工技术学报, 2020, 35(3): 577-589.
- ZHU Chenxi, ZHANG Yan, YAN Zheng, et al. A wind power time series modeling method based on the improved Markov chain Monte Carlo method[J]. Transactions of China Electrotechnical Society, 2020, 35(3): 577-589.
- [18] 张帅, 杨晶显, 刘继春, 等. 基于多尺度时序建模与估计的电力负荷数据恢复[J]. 电工技术学报, 2020, 35(13): 2736-2746.
- ZHANG Shuai, YANG Jingxian, LIU Jichun, et al. Power load recovery based on multi-scale time-series modeling and estimation[J]. Transactions of China Electrotechnical Society, 2020, 35(13): 2736-2746.
- [19] HONG Y, CHANG W, CHANG Y, et al. Optimal sizing of renewable energy generations in a community microgrid using Markov model[J]. Energy, 2017, 135: 68-74.
- [20] XIE S, HE H, PENG J. An energy management strategy based on stochastic model predictive control for plug-in hybrid electric buses[J]. Applied Energy, 2017, 196: 279-288.
- [21] GOLCHOUBIAN P, AZAD N L, PONNAMBALAM K. Stochastic nonlinear model predictive control of battery-supercapacitor hybrid energy storage systems in electric vehicles[C]. 2017 American Control Conference (ACC). Seattle, WA, USA, 2017.
- [22] 何俊强, 师长立, 韦统振. 基于马尔科夫链的自适应储能需求功率预测模型[J]. 电工技术学报, 2021, 36(增刊 2): 563-571.
- HE Junqiang, SHI Changli, WEI Tongzhen. Adaptive power demand prediction model of energy storage based on Markov chain[J]. Transactions of China Electrotechnical Society, 2021, 36(Suppl.2): 563-571.
- [23] 殷展翔, 陆锋, 潘庭龙, 等. 基于 FCS-MPC 的分布式 HESS 功率协调控制[J]. 太阳能学报, 2024, 45(1): 442-449.
- YIN Zhanxiang, LU Feng, PAN Tinglong, et al. Distributed hybrid energy storage system power coordination control based on FCS-MPC[J]. Acta Energiae Solaris Sinica, 2024, 45(1): 442-449.

(责任编辑 李园)