



基于注意力增强 LSTM-GPR 的构网型储能变流器电磁暂态模型参数辨识

伍阳阳¹, 文天舒¹, 张彩强¹, 李晓龙¹, 张伟², 徐恒山²

(¹云南电力试验研究院(集团)有限公司, 云南 昆明 650214; ²华能新能源股份有限公司云南分公司, 云南 昆明 650204; ³三峡大学电气与新能源学院, 湖北 宜昌 443002)

摘要: 针对构网型储能控制器参数无法从厂家直接获取而不能对其控制暂态特性进行精准分析的问题, 提出基于融合自适应注意力机制(Attention Mechanism Augmented, ATA)的长短期记忆网络(long short-term memory, LSTM)与高斯过程回归(Gaussian Process Regression, GPR)的构网型储能内部特性辨识方法。首先, 根据构网型储能控制结构在仿真平台搭建电磁暂态待辨识模型; 然后针对待辨识模型设计 ATA-LSTM-GPR 混合辨识方法, 利用 LSTM 算法结合 ATA 机制准确提取构网型储能的动态时序特征, 采用 GPR 算法对控制参数进行点估计和不确定性量化以实现构网型储能控制参数的精确辨识。最后, 为验证所提方法的正确性和有效性, 基于 RT-LAB 平台搭建构网型储能测试平台并采集动态响应数据集。试验结果表明: 所提 ATA-LSTM-GPR 混合算法能够显著提升构网型储能控制参数的辨识精度, 在复杂的高/低电压穿越工况下, 辨识算法得到的控制参数具有高保真性和适用性。

关键词: 构网型储能变流器; 参数辨识; 电磁暂态模型; 长短期记忆网络; 高斯过程回归; 硬件在环

doi: 10.19799/j.cnki.2095-4239.2026.0417

中图分类号: TM 762

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-11

Parameter Identification of Electromagnetic Transient Model for Grid-Forming Energy Storage Converters Based on Attention-Enhanced LSTM-GPR

WU Yangyang¹, WEN TianshuXu¹, YUAN Huayu¹, ZHANG Caiqiang¹, LI Xiaolong², XU Hengshan²

(¹Yunnan Electric Test & Research Institute Group Co., Ltd., Kunming 650214, China; ²College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: To address the problem that the control parameters of grid-forming energy storage converters cannot be directly obtained from manufacturers, thereby impeding accurate analysis of their control transient characteristics, this paper proposes an identification method for the internal characteristics of grid-forming energy storage converters. The method is based on a long short-term memory (LSTM) network fused with an adaptive attention mechanism (Attention Mechanism Augmented, ATA) and Gaussian process regression (GPR). First, an

收稿日期: 2026-05-16; 修改稿日期: 2026-07-15。

基金项目: 云南省新型电力系统技术创新中心(202405AK340007); 新能源电力系统国家重点实验室开放课题(LAPS24006)

第一作者: 伍阳阳(1988—), 男, 硕士、高级工程师, 主要从事新能源发电与并网分析方面的研究。445800890@qq.com

引用本文: 伍阳阳, 文天舒, 张彩强, 等. 基于注意力增强 LSTM-GPR 的构网型储能变流器电磁暂态模型参数辨识[J]. 储能科学与技术, XXXX, XX(XX): 1-11.

Citation: WU Yangyang, WEN TianshuXu, YUAN Huayu, et al. Parameter Identification of Electromagnetic Transient Model for Grid-Forming Energy Storage Converters Based on Attention-Enhanced LSTM-GPR[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-11.

electromagnetic transient model to be identified is established on a simulation platform according to the control structure of grid-forming energy storage converters. Then, a hybrid ATA-LSTM-GPR identification method is designed for the model to be identified. The LSTM algorithm combined with the ATA mechanism is used to accurately extract the dynamic time-series features of grid-forming energy storage converters, and the GPR algorithm is adopted to perform point estimation and uncertainty quantification of control parameters, so as to realize accurate identification of the control parameters. Finally, to verify the correctness and effectiveness of the proposed method, a grid-forming energy storage test platform is built based on the RT-LAB platform, and a dynamic response dataset is collected. Experimental results show that the proposed hybrid ATA-LSTM-GPR algorithm can significantly improve the identification accuracy of control parameters for grid-forming energy storage converters. Under complex high/low voltage ride-through conditions, the control parameters obtained by the identification algorithm exhibit high fidelity and applicability.

Keywords: Grid-connected energy storage converter; parameter identification; electromagnetic transient model; long short-term memory network; Gaussian process regression; hardware-in-the-loop

构网型储能变流器集成了构网控制的主动支撑能力与储能系统的灵活调节能力,成为增强电网韧性的理想解决方案。不同于依赖锁相环的跟网型变流器,构网型设备模拟同步发电机运行机制,以电压源特性自主构建并维持电网电压和频率^[1-3]。但其卓越主动支撑能力在复杂电网工况下的发挥,高度依赖内部多层次控制参数的精密设计与协同;其动态性能,尤其是电磁暂态过程中的表现,也深刻受制于功率环、电压电流环、虚拟阻抗等内部多层次控制参数,这些参数决定了变流器在极端工况下的短路电流贡献、过电压抑制及暂态稳定性^[4]。然而,制造商出于知识产权保护,常将控制参数封装为“黑箱”,给系统级安全稳定分析与协同控制带来巨大阻碍。因此,通过外部端口测量数据逆向辨识关键控制参数,构建高精度电磁暂态等效模型,成为学术界和工业界的迫切需求^[5]。

近年来,基于智能优化算法的参数辨识方法因其处理复杂非线性问题的强大能力而受到广泛关注。其核心思想是将参数辨识问题转化为一个优化问题,通过迭代最小化仿真模型输出与实测响应之间的误差来搜索最优参数。例如,文献^[6]利用遗传算法对下垂控制的虚拟同步机功频环节进行了有效辨识;文献^[7]则采用粒子群算法,在仿真环境下实现了对电压电流环参数的离线辨识。然而,现有研究大多集中于相对简单的跟网型变流器或理想仿真

环境^[8-9]。当研究对象转向控制结构更复杂、动态耦合性更强的构网型变流器时,尤其是在硬件在环实验所获得的、包含真实噪声和动态特性的数据基础上进行辨识,现有方法面临严峻挑战:首先,构网型控制中多个控制环路的参数之间存在强耦合,对智能算法的寻优效率和全局收敛性提出了极高要求^[10];其次,目前的研究验证多依赖于无噪声的纯数字仿真数据,缺乏基于硬件在环(hardware-in-loop, HIL)实验等高保真度数据的支撑,其在实际工程中的可信度存疑。

综上所述,现有研究在面对构网型储能变流器的参数辨识问题时,仍存在以下关键局限:1) 辨识算法的效能瓶颈:构网型控制的多参数强耦合特性导致算法易陷入局部最优,难以在高精度与快收敛之间取得平衡^[11];2) 验证体系的保真度不足:多数研究停留在纯数字仿真层面,其辨识结果在包含真实噪声和控制延迟的HIL环境中的有效性尚待验证;3) 考核工况的严峻性欠缺:现有模型验证通常局限于小扰动或稳态场景,缺乏在高/低电压穿越等极端电磁暂态过程中对模型动态复现能力的系统性评估。

为弥补上述研究缺口,本文针对一款BCS250 0K构网型储能变流器,开展基于硬件在环实验与智能算法的电磁暂态模型控制参数辨识研究。本研究首先利用RT-LAB平台构建高精度HIL实验环境,

获取真实控制器在典型扰动下的动态响应数据集；进而，设计一种适用于强耦合系统的混合智能辨识算法，旨在提升在多参数耦合空间中的寻优效率与精度；最终，通过对比辨识模型与真实控制器在高、低电压穿越等严苛电磁暂态工况下的动态响应，全面验证所提辨识策略的有效性及其所建模型的准确性，为构网型设备的并网分析和高精度建模提供实践依据。

1 构网型储能模型建模

精确的电磁暂态模型是构网型储能系统参数辨识与动态特性分析的前提。为满足后续大量迭代计算的需求，需构建一种既能复现关键暂态过程、又兼顾仿真效率的等效模型。该模型由反映物理特性的功率电路和决定外特性的构网型控制策略两部分组成^[12-13]。建模的目标是在保证足够精度以复现关键电磁暂态过程的前提下，兼顾计算效率，以满足后续大量迭代计算的参数辨识需求。

1.1 功率电路模型

储能变流器的功率电路拓扑结构如图1所示。该系统由直流电压源、直流母线电容、三相逆变桥和LCL滤波器构成。




图1 构网型储能变流器拓扑结构示意图

Fig. 1 Diagram of grid-connected energy storage converter topology

在电磁暂态仿真中，为兼顾精度与效率，通常采用平均模型替代详细开关模型，以刻画变流器在数十微秒至毫秒时间尺度上的动态行为。直流侧由理想电压源串联内阻等效，LCL滤波器在同步旋转d-q坐标系下的动态方程如式(1)所示：

$$\begin{aligned} L_r \frac{di_{fd}}{dt} &= v_{fd} - v_{od} + \omega L_r i_{fq} - R_f i_{fd} \\ L_r \frac{di_{fq}}{dt} &= v_{fq} - v_{oq} - \omega L_r i_{fd} - R_f i_{fq} \\ C_f \frac{dv_{od}}{dt} &= i_{fd} - i_{gd} + \omega C_f v_{oq} \\ C_f \frac{dv_{oq}}{dt} &= i_{fq} - i_{gq} - \omega C_f v_{od} \end{aligned} \quad (1)$$

其中， i_{fd} 、 i_{fq} 和 v_{od} 、 v_{oq} 分别为滤波器电感电流和电容电压的d、q轴分量， v_{fd} 、 v_{fq} 为变流桥臂输出电压， i_{gd} 、 i_{gq} 为网侧电流， ω 为电网角频率； L_r 、 R_f 、 C_f 分别为滤波电感、寄生电阻和滤波电容。

1.2 构网型控制策略建模

构网型控制策略是区别于跟网型变流器的核心，其模型直接决定了系统的外特性。本文采用目前主流的虚拟同步发电机控制架构，其核心在于通过算法使变流器模拟同步发电机的转子运动方程和励磁调节特性^[14-15]。控制框图如图2所示。




图2 虚拟同步机构网控制框图

Fig. 2 Diagram of virtual synchronous mechanism network control

1.2.1 有功-频率控制环

该环路由虚拟转子运动方程实现，模拟了同步机的惯性和一次调频特性：

$$J \frac{d\omega}{dt} = T_m - T_e - D(\omega - \omega_0) \quad (2)$$

其中， J 为虚拟转动惯量， D 为阻尼系数， ω 为额定角频率。机械转矩 T_m 由有功功率参考值， P_{ref} 经过一次调频下垂系数 D_p 调整后得到：

$$T_m = (P_{ref} + D_p(\omega_0 - \omega)) / \omega \quad (3)$$

电磁转矩 T_e 正比于实际输出有功功率 P_{out} 。该环路通过调节角频率 ω 并积分得到虚拟功角 θ ，从而实现对电网频率的主动支撑。

1.2.2 无功-电压控制环

该环路模拟同步发电机的自动电压调节功能：

$$V_{ref} = V_0 + D_q(Q_{ref} - Q_{out}) \quad (4)$$

其中， V_{ref} 为内电势参考幅值， V_0 为额定电幅值电压， D_q 为无功-电压下垂系数， Q_{ref} 和 Q_{out} 分别为无功功率参考值与实际值。

1.2.3 电压电流双闭环控制 虚拟同步机环产生的内电势参考信号 $V_{ref} \angle \theta$ 传递给内层的电压、电流双闭环控制器。电压环（通常为PI控制器）根据电容电压参考值与实际值的偏差，计算出电感电流的

参考值。电流环（也为PI控制器）则快速跟踪电流参考值，并生成最终的调制信号 v_{id} 、 v_{iq} 。dq轴解耦和前馈项被广泛用于提高动态响应性能。

1.3 待辨识参数集

综上所述，本文所建模型的关键在于一组决定系统暂态特性的控制参数。定义待辨识的参数向量为：

$$\mathbf{P} = [J, D_p, D_q, K_{p,v}, K_{i,v}, K_{p,i}, K_{i,i}]^T \quad (5)$$

其中， $K_{p,v}$ 、 $K_{i,v}$ 和 $K_{p,i}$ 、 $K_{i,i}$ 分别为电压环和电流环PI控制器的比例和积分增益。该参数集是后续智能算法逆向辨识的目标。

2 参数辨识方法

构网型储能变流器的控制参数辨识面临三重挑战：1）时序强相关性——暂态响应数据是典型的长时序信号，需模型具备长程记忆能力；2）特征非均匀分布——故障瞬间的动态片段对参数辨识的贡献远高于稳态片段，需模型自动聚焦关键时段；3）参数耦合不确定性——多参数强耦合导致辨识结果存在概率分布特征，需模型量化置信度。为此，本章提出一种融合注意力机制（Attention Mechanism Augmented, ATA）、长短期记忆网络（long short-term memory, LSTM）与高斯过程回归（Gaussian Process Regression, GPR）的混合智能辨识算法：LSTM用于捕捉时序依赖^[16]，注意力机制用于聚焦关键瞬态特征，GPR用于输出概率化辨识结果并量化不确定性。

2.1 基于ATA的LSTM模型

为构建监督学习所需的训练数据集，本文采用参数空间扫描策略：在参数可行域内生成1500组不同的控制参数组合 $\mathbf{P}_i$ ，每组参数下施加典型扰动工况，采集响应波形 $\mathbf{X}_i$ ，构成样本对 $(\mathbf{X}_i, \mathbf{P}_i)$ 。该映射关系训练后，可用于反推参数固定的真实变流器。定义HIL实验获得的暂态响应数据集为 $\mathbf{D}=\{(\mathbf{X}_i, \mathbf{P}_i)\}_{i=1}^N$ ，其中 $\mathbf{X}_i=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T] \in \mathbb{R}^{T \times d}$ 为第 i 个长度为 T 、维度为 d 的时间序列样本（如电压、电流波形）， $\mathbf{P}_i \in \mathbb{R}^m$ 为对应的真实控制参数向量。

LSTM通过门控机制有效缓解了传统循环神经网络的梯度消失问题^[17-18]。对于输入序列 $\mathbf{X}_i$ ，LSTM单元在每一时间步 t 的计算过程如下：

遗忘门决定从上一细胞状态中丢弃哪些信息：

$$f_t = \delta(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

输入门决定哪些新信息将被存储到细胞状态中：

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (7)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (8)$$

更新当前细胞状态：

$$c_t = (f_t \odot c_{t-1} + i_t \odot \tilde{c}_t) \quad (9)$$

输出门决定最终输出的隐藏状态：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (10)$$

$$h_t = o_t \odot \tanh(c_t) \quad (11)$$

其中： σ 为sigmoid函数，表示Hadamard积， W 和 b 为待训练的网络权重和偏置。通过多个LSTM层堆叠，网络能够从端口测量的暂态数据中逐层提取高层次的时序特征。最终，最后一个时间步的隐藏状态 h_T 通过一个全连接层，被映射为特征向量 $\mathbf{z}$ 。

h_T 将LSTM层在所有时间步 $t=1, 2, \dots, T$ 产生的隐藏状态序列 $\{h_1, h_2, \dots, h_T\}$ 作为键值对的集合，此处键和值均设为隐藏状态本身。

传统方法仅用 h_T 作为序列特征，但构网型暂态响应中故障瞬间的动态信息更为关键。为此，引入注意力机制对所有隐藏状态进行自适应加权。采用加性注意力计算每个时间步的重要性得分：

$$e_t = \mathbf{v}_a^T \cdot \tanh(\mathbf{W}_a[h_T; h_t] + \mathbf{b}_a) \quad (12)$$

其中， $\mathbf{W}_a$ 和 $\mathbf{b}_a$ 为可学习的权重矩阵和偏置， $\mathbf{v}_a^T$ 是权重向量， $[\cdot]$ 表示向量拼接操作。

随后，对所有时间步的得分 e_t 进行Softmax归一化，生成对应的注意力权重 $\mathbf{a}_t$ ：

$$\mathbf{a}_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)} \quad (13)$$

权重 $\mathbf{a}_t$ 满足 $\sum_{t=1}^T \mathbf{a}_t = 1$ ，其值越大，表示第 t 个时刻的隐藏状态对参数辨识越重要。

最后，使用计算出的注意力权重对值（即隐藏状态序列）进行加权求和，生成一个固定长度的上下文向量 $\mathbf{c}$ ：

$$\mathbf{c} = \sum_{t=1}^T \mathbf{a}_t h_t \quad (14)$$

$\mathbf{c}$ 融合了整个输入序列中关键时序信息的聚合特征，将替代原始的 h_T 作为后续GPR模型的输入。

ATA-LSTM结构如图3所示。图4给出了典型故障工况下的注意力权重分布，可见模型自动聚焦于故障发生瞬间的动态片段。




图3 ATA-LSTM结构图

Fig. 3 Diagram of ATA-LSTM




图4 注意力权重分布示例图

Fig. 4 Example Diagram of Attention Weight Distribution

2.2 高斯过程回归

GPR 是一种非参数贝叶斯模型，其核心优势在于能同时输出预测值与不确定性度量^[19]。将 ATA-LSTM 提取的特征向量 $\mathbf{c}$ 作为 GPR 的输入，待辨识参数 $\mathbf{P}$ 作为输出。假设函数 $f(\mathbf{c})$ 服从高斯过程：

$$f(\mathbf{c}) \sim \mathcal{GP}(m(\mathbf{c}), \kappa(\mathbf{c}, \mathbf{c}')) \quad (15)$$

其中，均值函数通常设为 $m(\mathbf{c})=0$ ；协方差函数 $\kappa(\mathbf{c}, \mathbf{c}')$ 选用平方指数核：

$$\kappa(\mathbf{c}_i, \mathbf{c}_j) = \sigma_f^2 \exp\left(-\frac{1}{2l^2} \|\mathbf{c}_i - \mathbf{c}_j\|^2\right) + \sigma_n^2 \delta_{ij} \quad (16)$$

其中， $2\sigma_f^2$ 为信号方差， l 为长度尺度， σ_n^2 为噪声方差，超参数 $\theta = \{\sigma_f^2, l, \sigma_n^2\}$ 通过最大化边缘似然函数来优化。

对于新测试点输入特征 $\mathbf{c}_*$ ，GPR 给出预测参数 $\mathbf{P}_*$ 的后验分布：

$$p(\mathbf{P}|\mathbf{c}_*) = \mathcal{N}(\mu, \sigma^2) \quad (17)$$

其均值 μ 和方差 $2\sigma^2$ 由以下解析式给出：

$$\mu = \mathbf{k}^T(\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{P} \quad (18)$$

$$\sigma^2 = \kappa(\mathbf{c}_*, \mathbf{c}_*) - \mathbf{k}^T(\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{k} \quad (19)$$

其中， $\mathbf{K}$ 是训练集协方差矩阵， $\mathbf{k}$ 是测试点与训练集各点的协方差向量。均值 μ 即为参数辨识结果，而方差 σ^2 量化了辨识结果的不确定性。该置信区间可为后续鲁棒性控制设计提供重要边界信息：若某参数辨识结果的方差过大，则表明在该工况下参数的可辨识性较差，需重新设计激励信号或补充实验数据。

2.3 算法总体框架

ATA-LSTM-GPR 混合算法的总体框架如图 5 所示，将辨识任务分解为三个阶段：

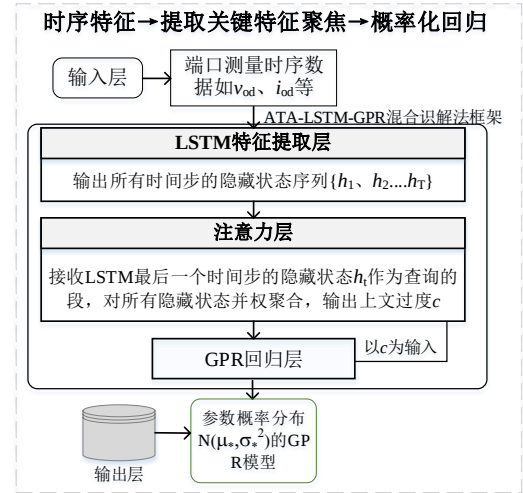


图5 ATA-LSTM-GPR混合辨识算法框架图

Fig. 5 Diagram of ATA-LSTM-GPR Identification Algorithm

数据预处理与特征提取：对 HIL 实验获得的原始时序数据进行标准化处理，划分为训练/验证/测试集。以标准化后的端口测量时序数据 $\mathbf{X}$ 为输入，训练 ATA-LSTM 网络，以最小化预测参数与真实参数的均方误差为目标，最终输出上下文特征向量 $\mathbf{c}$ 。

特征转换与 GPR 模型训练：以 $\{(\mathbf{z}_i, \mathbf{P}_i), \dots, (\mathbf{c}_N, \mathbf{P}_N)\}$ 数据集优化 GPR 的核函数超参数 θ 。通过最大化边缘似然函数得到一个能够从特征向量 $\mathbf{c}$ 映射到参数概率分布 $\mathcal{N}(\mu, \sigma^2)$ 的 GPR 模型。

参数辨识与不确定性评估：对于新的实测数据 $\mathbf{X}_{new}$ ，通过预训练的 ATA-LSTM 提取特征 $\mathbf{c}_{new}$ ，输入 GPR 模型，得到后验分布 $p(\mathbf{P}_{new}|\mathbf{c}_{new})$ ，其均值作为最终辨识结果，方差作为置信度评估依据。

3 仿真算例

为验证本文所提 ATA-LSTM-GPR 混合辨识算法的有效性与优越性, 利用 RT-LAB 半实物仿真平台获取的真实动态响应数据集, 在 Matlab/Simulink 中搭建储能变流器的同构辨识模型进行验证。

3.1 仿真平台与参数设置

基于 RT-LAB OP4510 实时仿真系统, 该平台核心包括: 1) 被控对象模型: 在 Simulink 中建立的构网型储能变流器详细电磁暂态平均模型, 运行于 OP4510 实时目标机; 2) 真实控制器: 搭载待辨识的 BCS2500K 变流器实际控制代码的物理控制器。两者通过高速 I/O 板卡实时交互, 确保了测试数据的高保真度。RT-Lab 半实物系统搭建图见图 6, BCS2500K 的主要电气参数见表 1。



图 6 RT-Lab 半实物系统搭建图

Fig.6 RT-Lab HIL system setup diagram

表 1 BCS2500K 构网型储能变流器电气参数

Table 1 Electrical parameters of BCS2500K grid-connected energy storage converter

型号	BCS2500K-B-HUD
MPPT 直流电压范围 (V)	1000-1500
启动电压 (V)	1000
额定输出功率 (kW)	2500
最大输出电流 (A)	2800
网侧额定电压 (V)	690
额定频率 (Hz)	50
功率因数范围	1 超前 ~ 1 滞后

实验共采集 1500 组多扰动工况下的电压、电流时序数据, 其中 1200 组用于训练, 300 组用于测试。待辨识的参数向量为 $\mathbf{P} = [J, D_p, D_q, K_{p,v}, K_{i,v}, K_{p,i}, K_{i,i}]$ 。

原始采集的暂态响应数据 (电压、电流、功率等, 采样率 10 kHz) 按以下步骤处理: 清洗: 剔除因通信丢包导致的异常片段 (阈值法, 超出 3σ 范围); 降噪: 采用滑动平均滤波 (窗口长度 5);

归一化: Z-score 标准化, 使各特征均值为 0、方差为 1; 截取: 统一截取故障前 0.1 s 至故障后 0.5 s 共 0.6 s 窗口, 每个样本 6000 个时间点; 输入格式: 原始时序直接输入 LSTM, 未做额外维度压缩或特征拼接。数据集预处理后, 利用 ATA-LSTM-GPR 算法进行参数辨识, LSTM 的损失函数为 MSE, 优化器为 Adam, 参数设置如表 2 所示。

表 2 ATA-LSTM 算法基本参数

Table 2 Basic parameters of ATA-LSTM algorithm

参数	数值	参数	数值
输入维度	8	学习率调度	$\eta_t = 0.001 \times 0.9^{\lfloor \frac{1}{50} \rfloor}$
输出维度	7	注意力维度	64
隐藏层层数	2	Dropout 率	0.2
隐藏层神经元数	128	优化器	Adam
初始学习率	0.015	损失函数	MSE

3.2 对比算法与评价指标

为全面评估所提算法性能, 选取两类代表性先进算法作为对比基准: 1) LSTM-IPSO 混合算法^[20]: 融合 LSTM 时序特征提取能力与改进粒子群优化 (IPSO) 的全局寻优能力, 代表了“深度学习+群体智能”的主流技术路线; 2) GMM-PSO 概率化校正算法: 基于高斯混合模型 (GMM) 与 PSO 的概率生成模型方法。其中 LSTM 部分采用与本文相同的网络结构, 但直接通过全连接层输出参数点估计, 以凸显引入 GPR 进行概率建模的增益。

采用均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 以及平均置信区间宽度 (MCIW, 95% 置信水平) 作为评价指标:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{P}_i - P_i)^2} \quad (20)$$

$$\text{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{\hat{P}_i - P_i}{P_i} \right| \quad (21)$$

$$\text{MCIW} = \frac{1}{N} \sum_{i=1}^N 1.96 \times \sigma. \quad (22)$$

总体指标是在所有测试样本、所有待辨识参数维度上统一计算的: 设测试样本数为 N , 参数维度为 7, 预测值矩阵 $\hat{\mathbf{P}} \in \mathbb{R}^{N \times m}$, 真实值矩阵 $\mathbf{P} \in \mathbb{R}^{N \times m}$ 。则总体 RMSE 为

$$\sqrt{\frac{1}{Nm} \sum_{i=1}^N \sum_{j=1}^m (\hat{P}_{ij} - P_{ij})^2}, \quad \text{总体 MAPE 为}$$

$$\frac{100\%}{Nm} \sum_{i=1}^N \sum_{j=1}^m \left| \frac{\hat{P}_{ij} - P_{ij}}{P_{ij}} \right|. \quad \text{MCIW 则对各参数独立}$$

计算后取平均。

两种对比方法均采用“特征提取+参数映射”的混合架构，与本文ATA-LSTM-GPR的思路一致。区别在于：本文使用GPR直接学习特征到参数的映射，而LSTM-IPSO和GMM-PSO使用PSO间接寻优。对比旨在验证GPR相较于PSO在效率与不确定性量化上的优势。

3.3 结果与分析

3.3.1 辨识精度对比分析

各算法在测试集上对关键控制参数的辨识精度对比如表3所示。

表3 不同算法辨识精度对比

Table 3 Comparison of Accuracy Among Different Algorithms


算法	RMSE	MAPE (%)	MCIW (%)
LSTM-IPSO	0.145	4.82	-
GMM-PSO	0.089	2.95	-
ATA-LSTM-GPR (本文)	0.062	2.01	3.4

由表3可以看出，本文所提ATA-LSTM-GPR算法的RMSE和MAPE均为最低，这一显著提升归因于GPR模块在LSTM提取的特征基础上进行非线性概率回归，有效修正了LSTM初步预测的残差，同时通过核函数自适应地捕捉了参数间的耦合关系。


辨识精度需最终体现为模型动态响应的复现能力。为直观验证所提方法的有效性和实用性，本节选取不同g高、低电压穿越工况下的实测数据集，与ATA-LSTM-GPR种算法辨识所得参数模型的仿真输出进行动态响应曲线对比。图7为电压跌落到0.2p.u.时测试结果，图8为电压抬升到1.3p.u.时测试结果。

由图7、图8可见，在整个LVRT/HVRT过程中，基于ATA-LSTM-GPR辨识参数构建的模型仿真曲线与实测数据高度一致。这充分验证了本文方法在极端电磁暂态工况下的高保真复现能力，证明了本文所提方法能够精确捕捉构网型变流器多环路、强耦合的控制系统特性，所获得的电磁暂态模型具有很高的工程实用价值，可用于高可信度的系统级仿真分析。


本文参考相关标准中建模精度评价方法，要求储能电站整站等值模型与详细模型下并网点电压、电流、无功电流、有功功率和无功功率的仿真计算




a. 80%电压跌落下 u_{dc} 响应波形




b. 80%电压跌落下 i_{dc} 响应波形



c. 80%电压跌落下 i_d 响应波形



d. 80%电压跌落下 P 响应波形



e. 80%电压跌落下 Q 响应波形

图7 80%电压跌落响应波形

Fig.7 Waveform of response for 80% voltage drop

偏差应满足表4所规定的允许最大偏差值。分别计算电压跌落程度80%和提升135%下辨识结果的平均偏差。

如图9所示，得到80%和130%电压扰动下






a. 130% 电压抬升下 u_{dc} 响应波形b. 130% 电压抬升下 i_p 响应波形c. 130% 电压抬升下 i_q 响应波形d. 130% 电压抬升下 P 响应波形e. 130% 电压抬升下 Q 响应波形

图8 130%电压抬升的响应波形

Fig.8 Response Waveform of 130% Voltage Elevation

ATA-LSTM-GPR 模型输出结果的平均偏差。


可知, 本文所提算法在计算精度和收敛速度等方面具有优越性, 并适用于构网型储能变流器的电磁暂态模型参数辨识。

表4 单机验证的精度要求

Table 4 Accuracy Requirements for Single-machine Verification


电气参数	F_{1max}	F_{2max}	F_{3max}	F_{Gmax}
电压偏差, $\Delta U_s/U_n$	0.02	0.05	0.05	0.05
电流, $\Delta I/I_n$	0.10	0.20	0.15	0.15
无功电流, $\Delta I_q/I_n$	0.10	0.20	0.15	0.15
有功功率, $\Delta P/P_n$	0.10	0.20	0.15	0.15
无功功率, $\Delta Q/P_n$	0.10	0.20	0.15	0.15

F_{1max} : 稳态区间平均偏差允许值; F_{2max} : 暂态区间平均偏差允许值;
 F_{3max} : 稳态区间最大偏差允许值; F_{Gmax} : 所有区间加权平均总偏差允许值。

图9 不同电压扰动程度误差
Fig.9 Error for different LVRT

3.3.2 不确定性量化分析

ATA-LSTM-GPR 混合模型的核心优势在于其概率化输出。图10展示了测试集中虚拟惯量参数 J 的辨识结果散点图及其 95% 置信区间。

图10 参数 J 的辨识结果与置信区间Fig. 10 Identification Results and Confidence Interval for Parameter J

从图10可见, 绝大多数真实值均落在置信区间内, 证明了不确定性评估的有效性。进通过式(23-24)计算发现, 辨识误差较大的样本点其对应的置信区间宽度也明显更大, 表明该算法具备“自

诊断”能力——当辨识结果不可靠时，模型会通过更大的方差发出警示，这是传统点估计方法所不具备的。

$$\mu_* = \mathbf{k}^T (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{P} \quad (23)$$

$$\sigma_*^2 = \kappa(\mathbf{z}_*, \mathbf{z}_*) - \mathbf{k}_*^T (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{k}_* \quad (24)$$

其中， $\mathbf{K}$ 为训练样本协方差矩阵， $\mathbf{k}_*$ 为测试点与所有训练点的协方差向量。

为直观比较不同算法对各控制参数的辨识效果，图 11 给出了三种算法在测试集上对 7 个参数 $J, D_p, D_q, K_{p,v}, K_{i,v}, K_{p,i}, K_{i,i}$ 的 MAPE 分布箱线图。可以看出，本文所提 ATA-LSTM-GPR 方法在各参数上的误差中位数和离群点均显著优于对比方法，尤其对耦合性强的 PI 参数提升更为明显。




图 11 控制参数 MAPE 分布箱线图

Fig.11 Box plot of control parameter MAPE distribution

3.3.3 泛化能力测试


为测试模型的泛化能力，使用一组训练集中未出现的严重电网故障工况，三相电压跌至 0.75 p.u. 时的 HIL 实验数据对已训练模型进行测试，如图 12 所示。

结果如图 12 所示。在剧烈的电压暂降和恢复过程中，基于 ATA-LSTM-GPR 辨识参数构建的模型输出与真实控制器高度吻合，误差如图 13 所示。


可知本文方法所辨识的参数具有优异的泛化能力，能够精确复现实际设备在关键电磁暂态过程中的行为。

4 总 结


针对构网型储能控制参数不易获取导致动态性能无法准确评估和改进的问题，提出基于 ATA-LSTM-GPR 的构网型储能内部特性辨识方法，通过试验得到以下结论：




a. 35% 电压跌落下 u_{dc} 响应波形




b. 35% 电压跌落下 i_p 响应波形



c. 35% 电压跌落下 i_q 响应波形



d. 35% 电压跌落下 P 响应波形



e. 35% 电压跌落下 Q 响应波形

图 12 35% 电压跌落的响应波形

Fig.12 Waveform of response for 35% voltage drop

（1）基于 RT-LAB 半实物仿真平台测试构网型储能控制器动态特性，可为构网型储能控制器的精




图 13 35%电压跌落程度误差
Fig.13 Error for 35% LVRT

确建模提供精确数据集:

(2) 将 LSTM 与 GPR 结合有利于提高构网型储能控制参数的辨识精度, 基于 ATA 机制的 LSTM 能精准捕捉构网型变流器在多扰动下的关键瞬态特征, 可提高构网型储能非线性控制参数的适应性, GPR 可为构网型储能不确定控制参数的辨识过程提供可量化的点估计处理以提高控制参数的辨识效率和精度;

(3) 由于可提高辨识算法的泛化能力, 相比于 GMM-PSO 和 LSTMLSTM-IPSO 算法, ATA-LSTM-GPR 算法可获得更精确的构网型储能控制参数, 且在深度电压穿越工况下这一优势更加突出。该方法能从参数变化的训练数据中学习映射, 并泛化至参数固定的真实设备。

参考文献

- [1] Sun P, Tian Z, Huang M, et al. Additional Kinetic Energy Injection and Piecewise Damping Based Postfault Antiwindup and Transient Stability Enhanced Control for Grid-Forming Inverter[J]. IEEE Transactions on Power Electronics, 2024(7 Pt.1):39.
- [2] 马悦鑫,王鹏,赵浩然,等. 基于分段仿射阻抗模型的电压源变流器小扰动稳定域在线构造[J]. 中国电机工程学报, 2024, 44(14): 5667-5680.
MA Y X, WANG P, ZHAO H R, et al. Online construction of small-signal stability region for voltage source converter based on piecewise affine impedance model[J]. Proceedings of the CSEE, 2024, 44(14): 5667-5680.
- [3] 胡朝华,杜新伟,苟竞,等. 提升新型电力系统宽频振荡稳定性的构网型储能设备优化配置方法[J]. 储能科学与技术, 2025, 14(12): 4583-4593.
HU C H, DU X W, GOU J, et al. Optimal configuration method of grid-forming energy storage devices for improving broadband oscillation stability of new power systems[J]. Energy Storage Science and Technology, 2025, 14(12): 4583-4593.
- [4] 颜湘武,张书瑞,蔡光,等. 构网型双馈风电机组稳定性分析[J]. 太阳能学报, 2025, 46(10): 561-569.
- [5] YAN X W, ZHANG S R, CAI G, et al. Stability analysis of grid-forming doubly-fed wind turbines[J]. Acta Energaie Solaris Sinica, 2025, 46(10): 561-569.
- [6] Ai C, Li Y, Zhao Z, et al. An Extension of Grid-Forming: A Frequency-Following Voltage-Forming Inverter[J]. IEEE Transactions on Power Electronics, 2024(10 Pt.1):39.
- [6] 张梦琪,李永刚,孙庚,等. 基于 DBN-ELM 的构网型并网逆变器控制参数自适应调整方法[J]. 电力自动化设备, 2024, 44(04): 111-118.
ZHANG M Q, LI Y G, SUN G, et al. Adaptive adjustment method of control parameters for grid-forming grid-connected inverter based on DBN-ELM[J]. Electric Power Automation Equipment, 2024, 44(4): 111-118.
- [7] 秦继翔,贾科,孔繁哲,等. 基于寻优算法的永磁风机并网逆变器故障穿越控制参数分步辨识[J]. 中国电机工程学报, 2021, 41(S1): 59-69.
- [7] QIN J S, JIA K, KONG F Z, et al. Step-by-step identification of fault ride-through control parameters for permanent magnet wind turbine grid-connected inverter based on optimization algorithm [J]. Proceedings of the CSEE, 2021, 41(S1): 59-69.
- [8] 王渝红,王雪珂,文玉玲,等. 基于 MCC-PCKF 的跟网型变流器时变虚拟惯量与状态估计[J]. 电力系统自动化, 2025, 49(13): 103-112.
WANG Y H, WANG X K, WEN Y L, et al. Time-varying virtual inertia and state estimation of grid-following converter based on MCC-PCKF[J]. Automation of Electric Power Systems, 2025, 49(13): 103-112.
- [9] M. Chen, D. Zhou, and F. Blaabjerg, "Enhanced Virtual Synchronous Generator with Adaptive Inertia and Damping Support," IEEE Transactions on Industrial Electronics, vol. 70, no. 6, pp. 5845-5856, Jun. 2023.
- [10] Mahmood Z I, Cui H, She B, et al. Evaluating the Equivalent Inertia of Grid-Following and Grid-Forming Inverter-Based Resources[J]. IEEE Transactions on Energy Conversion, 2024: 1-12.
- [11] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Computation, vol. 9, no. 8, pp. 1735-1780, 1997.
- [12] 李毅丰,裴玮,熊佳旺,等. 构网型变流器的功率-相角直接控制策略[J]. 中国电机工程学报, 2025, 45(S1): 71-82.
LI Y F, PEI W, XIONG J W, et al. Direct power-angle control strategy for grid-forming converters[J]. Proceedings of the CSEE, 2025, 45(S1): 71-82.
- [13] 宾子君,孔祥平,黄云辉,等. 接入交流电网的构网型储能变流器阻抗建模及稳定性分析[J]. 储能科学与技术, 2025, 14(9): 3434-3443.
BIN Z J, KONG X P, HUANG Y H, et al. Impedance modeling and stability analysis of grid-forming energy storage converters connected to AC grid[J]. Energy Storage Science and Technology, 2025, 14(9): 3434-3443.
- [14] 李明烜,王跃,徐宁一,等. 基于带通阻尼功率反馈的虚拟同步发电机控制策略[J]. 电工技术学报, 2018, 33(10): 2176-2185.
LI M X, WANG Y, XU N Y, et al. Control strategy of virtual synchronous generator based on band-pass damping power feedback[J]. Transactions of China Electrotechnical Society, 2018, 33(10): 2176-2185.

- [15] Quan X , Li D , Zou Z , et al. Complex Variable Design for Power Control of Grid-Forming Inverter[J]. IEEE Transactions on Sustainable Energy, 2025:1-4.
- [16] Sun L , Ding G , Geng S .A New Neural Network Model Based on Attention Mechanism that Embeds LSTM into RNN for Nonlinear Time-Lag System Identification[J]. Lecture Notes in Electrical Engineering, 2024:610-618.
- [17] Yang R , Peng S , Yao G .Multimodal feature enhanced Bi-LSTM model for harmonic power load identification in distribution networks[J].Journal of Power Electronics, 2025, 25(6):1116-1126.
- [18] 施永,黄宁,谢缔,等.基于自注意力机制和CNN融合的燃料电池故障诊断技术[J].太阳能学报,2025,46(05):53-61.
- SHI Y, HUANG N, XIE D, et al. Fault diagnosis technology for fuel cells based on fusion of self-attention mechanism and CNN[J]. Acta Energiae Solaris Sinica, 2025, 46(5): 53-61.
- [19] 褚昱麟,陈红坤,王嘉琦,等.基于多元高斯过程回归和空间聚类的复信号谐波源建模[J].电工技术学报,2025,40(23):7621-7634.
- CHU Y L, CHEN H K, WANG J Q, et al. Modeling of complex signal harmonic sources based on multivariate Gaussian process regression and spatial clustering[J]. Transactions of China Electrotechnical Society, 2025, 40(23): 7621-7634.
- [20] 徐恒山,李颜汝,李文昊,等.融合寻优算法的双馈风力机控制参数分步辨识方法[J].太阳能学报,2024,45(04):247-256.
- XU H S, LI Y R, LI W H, et al. Step-by-step identification method of control parameters for doubly-fed wind turbine integrating optimization algorithm[J]. Acta Energiae Solaris Sinica, 2024, 45 (4): 247-256.