

构网型变流器动态模型预测控制

代毅, 郑涛, 杨畅, 汪艳霞

(西安交通大学电气工程学院, 710049, 西安)

摘要: 为解决构网型变流器模型预测控制对滤波器参数高度依赖的问题,提出了一种基于系统动态稀疏回归的模型预测控制策略。该方法通过施加短时低幅值阶梯型扰动信号,激发系统动态响应并获取少量训练数据。基于非线性动力学稀疏辨识算法原理,将状态变量与控制输入组合构建备选函数池,并通过带正则化约束的稀疏回归优化求解系数矩阵,辨识出结构简洁、具有物理意义且具备良好泛化能力的状态空间模型。将该模型离散化后嵌入模型预测控制框架,以输出电压跟踪误差与控制输入能量消耗构建目标函数,结合物理边界约束,通过二次规划在每个控制周期内滚动求解最优控制序列。结果表明:在参数存在较大偏移时,所提策略的建模误差低于 0.7%,能够在 5 ms 内完成负载扰动响应,输出电压稳态误差控制在 $\pm 0.1\%$ 以内,且计算效率显著优于传统方法。所提策略在建模精度、鲁棒性与实时性方面具有综合优势,展现出良好的工程可行性。

关键词: 构网型变流器;模型预测控制;稀疏回归

中图分类号: TM464 **文献标志码:** A

DOI: 10.7652/xjtuxb202603018 **文章编号:** 0253-987X(2026)03-0187-11

Dynamic Model Predictive Control of Grid-Forming Converters

DAI Yi, ZHENG Tao, YANG Chang, WANG Yanxia

(School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the high dependence of model predictive control for grid-forming converters on filter parameters, a predictive control strategy based on dynamic sparse regression is proposed. The proposed method excites the system's dynamic response by applying a short-term, low-amplitude step perturbation signal to acquire a small training dataset. Based on the Sparse Identification of Nonlinear Dynamics algorithm, a candidate function pool is constructed by combining state variables and control inputs. The coefficient matrix is then solved through sparse regression optimization with regularization constraints, thereby identifying a concise and physically meaningful state-space model with strong generalization capability. After being discretized, this model is embedded into the model predictive control framework. By formulating an objective function based on the output voltage tracking error and control input energy consumption, and incorporating physical boundary constraints, the optimal control sequence is iteratively solved over a rolling horizon within each control cycle via quadratic programming. The results show that under significant parameter deviations, the modeling error of the proposed strategy remains below 0.7%, while the load disturbance response is completed within 5 ms, the steady-state error of the output voltage is controlled within $\pm 0.1\%$, and the computational efficiency is significantly

higher than that of traditional methods. The proposed strategy demonstrates comprehensive advantages in modeling accuracy, robustness, and real-time performance, exhibiting strong potential for practical engineering applications.

Keywords: grid-forming converter; model predictive control; sparse regression

随着新能源大规模接入电力系统,微电网逐渐成为提升新能源就地消纳、系统灵活运行的有效途径之一^[1]。作为新能源与电网的连接桥梁,变流器在微电网运行控制中起到了关键作用,而构网型变流器(GFC)因其在微电网并网运行模式,尤其在孤岛运行模式下对系统电压和频率具有强支撑能力,近年来备受关注^[2]。GFC 通常采用基于级联线性控制环的控制策略,控制目标单一,暂态性能较差,并且控制器参数往往依赖设计者的经验。为克服这一局限,综合多控制目标的先进控制方法成为研究热点,其中模型预测控制(MPC)因其快速动态响应能力和多变量约束处理能力,受到广泛关注^[3]。然而,与跟网型变流器(GFL)相比,同样基于 MPC 策略的 GFC 控制效果会更加依赖滤波器参数的准确性。这是因为 GFL 依赖电网电压,其滤波器更多承担谐波抑制任务;而 GFC 需独立构造电压与频率,其滤波器动态直接参与模型预测与约束构造,参数精度对 MPC 的控制性能有直接影响。因此,当滤波器参数因制造工艺或安装条件与标称值存在偏差时,MPC 的性能会显著下降,表现为预测不准和调参复杂度增加,这一点对 MPC 在 GFC 中的应用构成挑战。

针对这一问题,学者提出了无模型预测控制(MFPC),其核心理念是直接利用系统的输入输出数据进行预测和控制,而不依赖于精确的系统物理模型。MFPC 的第一种实现方式为补偿预测误差:假设理想模型与实际系统间有差异,输出预测存在误差,基于扰动估计来修正预测模型的输出,进而提高控制精度^[4-5]。第二种实现方式为直接预测控制变量:利用系统的输入输出数据预测未来的状态变量变化,据此调整控制策略,而不依赖于精确的系统模型参数^[6-7]。然而,系统状态的预测精度受到历史数据和样本更新频率的限制。为了解决这一问题,文献[8]提出一种带外生输入的自回归模型用于电压预测,有效提高了参数鲁棒性。MFPC 虽然在面对系统不确定性时具有较强的鲁棒性,但其依赖于输入输出数据而非精确模型,并且仅在工作点的小邻域内进行预测,因此难以充分捕捉到系统的动态

特性。相比之下,MPC 通过精确的系统模型和优化算法,能够提供更高的控制精度、全局最优解,其在提供控制性能和稳定性方面,尤其是在逆变器控制领域中仍然具有不可替代的重要性。可见,解决 MPC 对精准模型的需求问题是至关重要的,如果能够通过有效的方法提供一个高精度的系统模型,那么 MPC 的优势将得以充分发挥。

近年来,非线性动力学稀疏识别(SINDy)^[9-10]技术在电力系统领域逐渐引起关注,在微网系统建模、强迫振荡源定位等方面取得了显著成果^[11-14]。SINDy 技术作为一种数据驱动的建模方法,可以从少量的历史数据中有效识别出系统的动力学方程,特别地,在 GFC 系统中经过稀疏化处理后的回归模型不仅能够保持较高的精度,还能够通过减少冗余变量提升模型的可解释性,避免过拟合问题。

基于 SINDy 技术的算法逻辑,本文提出了一种基于稀疏回归(SR)建模的 GFC 模型预测控制策略——SR-MPC。首先,通过稀疏回归识别出 GFC 系统的动力学模型;然后,基于该模型预测不同控制输入下未来的系统状态,并通过二次规划(QP)方法确定最优控制策略,从而实现对 GFC 的精确调节。本文所提 SR-MPC 策略的主要优势在于以下两点:①泛化能力强。由于 SR 算法能够从少量数据中准确辨识出系统模型,因此 SR-MPC 策略能够适应不同 GFC 系统以及参数漂移,并且有效降低了调参成本。②快速响应能力。稀疏化后的回归模型简洁而高效,并且具有可解释性,能够在计算上快速执行,加之 MPC 的多约束处理能力和较低的计算成本,这些使得 SR-MPC 策略可以快速响应负荷变化,保障 GFC 输出电压的稳定性和系统的控制精度。最后,通过 Matlab/Simulink 软件仿真算例验证了所提控制策略的有效性。

1 构网型变流器的 MPC 控制

1.1 构网型变流器模型

含 LC 型滤波器的 GFC 结构如图 1 所示。图中 U_{dc} 表示直流侧电压, U_i 、 U_o 分别表示对应节点处的电压, I_i 、 I_o 分别表示流经对应线路的电流, I_{id} 、 I_{iq} 分别

表示输入电流 I_i 经过同步旋转坐标变换(Park 变换)后的 d 轴、 q 轴分量, U_{id} 、 U_{iq} 、 U_{od} 、 U_{oq} 、 I_{od} 、 I_{oq} 同理。




图1 GFC模型

Fig. 1 GFC model

建立同步旋转坐标系下 GFC 各节点电压和电流的关系如下

$$L_f \frac{dI_{id}}{dt} = U_{id} - U_{od} + \omega L_f I_{iq} - r I_{id} \quad (1)$$

$$L_f \frac{dI_{iq}}{dt} = U_{iq} - U_{oq} - \omega L_f I_{id} - r I_{iq} \quad (2)$$

$$C_f \frac{dU_{od}}{dt} = I_{id} - I_{od} + \omega C_f U_{iq} \quad (3)$$

$$C_f \frac{dU_{oq}}{dt} = I_{iq} - I_{oq} - \omega C_f U_{id} \quad (4)$$

式中: L_f 和 C_f 分别为 LC 型滤波器的电感和电容; r 为寄生电阻; ω 为角频率。将式(1)~(4)整理为状态空间方程为

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \\ \mathbf{y} = \mathbf{C}\mathbf{x} \end{cases} \quad (5)$$

式中: $\mathbf{x} = [I_{id}, I_{iq}, U_{od}, U_{oq}]^T$; $\mathbf{u} = [U_{id}, U_{iq}, I_{od}, I_{oq}]^T$; $\mathbf{y} = [I_{id}, I_{iq}, U_{od}, U_{oq}]^T$ 。

状态变量 $\mathbf{x}$ 和控制输入 $\mathbf{u}$ 的选取主要考虑模型对于外部拓扑变化的普适性以及在线计算成本的降低, 详见第3节。在孤岛运行模式下, 为实现对负荷功率的自适应跟踪, 控制器需要实时监测输出功率。根据文献[15], 三相瞬时有功功率 P 和无功功率 Q 的计算公式为

$$\begin{cases} P = \frac{3}{2} (U_{od} I_{od} + U_{oq} I_{oq}) \\ Q = \frac{3}{2} (U_{oq} I_{od} - U_{od} I_{oq}) \end{cases} \quad (6)$$

1.2 MPC 控制模型

图2为典型的 MPC 控制原理图。流程为: 首先获取当前的系统状态 $\mathbf{y}(k)$, 并利用系统模型预测未来一段时间内的状态变化 $\mathbf{y}(k+j)$, 然后根据定义的目标函数, MPC 综合约束条件求解优化问题,

得到一个控制输入序列, 并从中选择第一个控制输入 $\mathbf{u}_{opt}$ 应用到被控系统中。每次控制周期结束时, MPC 会根据最新的系统状态重新计算优化问题, 从而实现滚动优化。




图2 MPC控制原理图

Fig. 2 MPC control schematic diagram

在实际应用中, 为使连续时间系统能够在数字控制器中进行计算和控制, 通常将其转化为离散时间模型。本文采用零阶保持(ZOH)法对系统状态方程进行离散化, 最终得到的离散状态方程为

$$\mathbf{x}(k+1) = \tilde{\mathbf{A}}\mathbf{x}(k) + \tilde{\mathbf{B}}\mathbf{u}(k) \quad (7)$$

式中: T 为采样周期; $\tilde{\mathbf{A}} = e^{\mathbf{A}T}$; $\tilde{\mathbf{B}} = \int_0^T e^{\mathbf{A}(T-\tau)} \mathbf{B} d\tau$, τ 为时间。

可以看出, 矩阵 $\tilde{\mathbf{A}}$ 由式(5)中的矩阵 $\mathbf{A}$ 生成, 因此会受 L_f 、 C_f 取值的影响, 进而又会影响到 MPC 的控制精度。考虑 GFC 的输出精度、能量损耗以及系统稳定性要求, 引入系统目标函数 J , 它反映了系统输出跟踪误差和控制输入能量消耗, 表达式为

$$\begin{cases} J(k) = \sum_{\ell=0}^{N_p-1} \|\mathbf{y}(k+\ell+1) - \mathbf{y}_{ref}(k+\ell+1)\|_{\mathbf{L}}^2 + \|\mathbf{u}(k+\ell)\|_{\mathbf{R}}^2 \\ \text{s. t. } \mathbf{x}(k+\ell+1) = \tilde{\mathbf{A}}\mathbf{x}(k+\ell) + \tilde{\mathbf{B}}\mathbf{u}(k+\ell), \\ \ell = 0, 1, \dots, N_p - 1 \\ \mathbf{y}(k+\ell+1) = \mathbf{C}\mathbf{x}(k+\ell+1) \\ \mathbf{u}_{min} \leq \mathbf{u}(k+\ell) \leq \mathbf{u}_{max} \end{cases} \quad (8)$$

式中: $J(k)$ 表示第 k 次执行 MPC 过程的目标函数值; N_p 为预测的迭代次数; $\mathbf{x}(k+\ell+1)$ 表示状态变量基于当前的测量值, 在经过 $\ell+1$ 个时间步长后所对应的预测值, $\mathbf{y}(k+\ell+1)$ 同理; $\|\cdot\|_{\mathbf{L}}$ 表示输出预测值与参考值之间的误差; $\|\cdot\|_{\mathbf{R}}$ 表示控制输入的能量成本, 两者在目标函数中由权重系数矩阵 $\mathbf{L}$ 和 $\mathbf{R}$ 决定, 并且满足 $\mathbf{L}$ 和 $\mathbf{R}$ 为半正定矩阵。物理约束和上下界约束的加入保证了输出不越限,

相较于传统线性级联控制以及 MFPC, MPC 可以在目标函数中方便地加入约束, 如 $\mathbf{u}_{\min} \leq \mathbf{u}(k+\ell) \leq \mathbf{u}_{\max}$ 项限制了控制输入的上下界, 避免产生不符合物理条件的控制输入, 提高控制系统的鲁棒性。根据 GFC 的定压定频控制方式, 可直接给定 $U_{od}^* = U_{ref}$, $U_{oq}^* = 0$, 其中 U_{ref} 为 GFC 输出单相电压的峰值期望值。结合电路拓扑可以得到 GFC 的输出电流参考值为

$$\begin{cases} I_{id}^* = \frac{2P}{3U_{od}^*} \\ I_{iq}^* = \frac{-2Q}{3U_{od}^*} + \omega C_f U_{od}^* \end{cases} \quad (9)$$

1.3 MPC 目标函数最优化

为求解目标函数(8)的最小值 $J_{\min}$, 并且减少运算时间, 使用二次规划(QP)方法进行求解。 N_p 个预测步长下的状态空间表达式为

$$\begin{cases} \mathbf{X}_{aug} = \mathbf{A}_{aug} \mathbf{x}(k) + \mathbf{B}_{aug} \mathbf{U}_{aug} \\ \mathbf{Y}_{aug} = \mathbf{C}_{aug} \mathbf{X}_{aug} \end{cases} \quad (10)$$

其中

$$\begin{cases} \mathbf{A}_{aug} = [\mathbf{A} \quad \mathbf{A}^2 \quad \cdots \quad \mathbf{A}^{N_p}]_{N_x N_p \times N_x N_p}^T \\ \mathbf{B}_{aug} = \begin{bmatrix} \mathbf{B} & 0 & 0 & 0 \\ \mathbf{AB} & \mathbf{B} & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ \mathbf{A}^{N_p-1} \mathbf{B} & \mathbf{A}^{N_p-2} \mathbf{B} & \cdots & \mathbf{B} \end{bmatrix}_{N_x N_p \times N_u N_p} \\ \mathbf{C}_{aug} = [\mathbf{C} \quad \mathbf{C} \quad \cdots \quad \mathbf{C}]_{N_y \times N_x N_p} \\ \mathbf{X}_{aug} = [\mathbf{x}(k) \quad \mathbf{x}(k+1) \quad \cdots \quad \mathbf{x}(k+N_p-1)]^T \end{cases} \quad (11)$$

重新整理式(8)得

$$\begin{aligned} J(k) = & \|\mathbf{C}_{aug}(\mathbf{A}_{aug} \mathbf{x}(k) + \mathbf{B}_{aug} \mathbf{U}_{aug}) - \mathbf{Y}_{aug}^*\|_{\Phi}^2 + \\ & \|\mathbf{U}_{aug}\|_{\Psi}^2 = \|\mathbf{C}_{aug} \mathbf{A}_{aug} \mathbf{x}(k) - \mathbf{Y}_{aug}^*\|_{\Phi}^2 + \\ & 2(\mathbf{C}_{aug} \mathbf{A}_{aug} \mathbf{x}(k) - \mathbf{Y}_{aug}^*)^T \Phi \mathbf{C}_{aug} \mathbf{B}_{aug} \mathbf{U}_{aug} + \\ & \mathbf{U}_{aug}^T \mathbf{B}_{aug}^T \mathbf{C}_{aug}^T \Phi \mathbf{C}_{aug} \mathbf{B}_{aug} \mathbf{U}_{aug} + \mathbf{U}_{aug}^T \Psi \mathbf{U}_{aug} \end{aligned} \quad (12)$$

式中: Φ, Ψ 是 L, R 的增广矩阵, 分别表示输出预测值和参考值的误差权重、控制输入的能量消耗权重; $\mathbf{Y}_{aug}^*$ 表示由 N_p 个输出参考值构成的增广矩阵, 即 $\mathbf{Y}_{aug}^* = [\mathbf{y}_{ref}, \cdots, \mathbf{y}_{ref}]^T$ 。

因为式(12)中的 $\|\mathbf{C}_{aug} \mathbf{A}_{aug} \mathbf{x}(k) - \mathbf{Y}_{aug}^*\|_{\Phi}^2$ 项与控制输入 $\mathbf{U}_{aug}$ 无关, 可认为是目标函数中的常数偏置, 所以最终得到的目标函数可以表示为 QP 形式

$$\min_{\mathbf{U}_{aug}} J = \frac{1}{2} \mathbf{U}_{aug}^T \mathbf{H} \mathbf{U}_{aug} + \mathbf{f}^T \mathbf{U}_{aug} \quad (13)$$

其中

$$\begin{cases} \mathbf{H} = 2(\mathbf{B}_{aug}^T \mathbf{C}_{aug}^T \Phi \mathbf{C}_{aug} \mathbf{B}_{aug} + \Psi) \\ \mathbf{f}^T = 2(\mathbf{C}_{aug} \mathbf{A}_{aug} \mathbf{x}(k) - \mathbf{Y}_{aug}^*)^T \Phi \mathbf{C}_{aug} \mathbf{B}_{aug} \end{cases}$$

2 GFC 模型的稀疏辨识

2.1 数据准备

首先, 对 GFC 系统施加外部激励信号以获取用于模型辨识的训练数据。在该阶段, 主要目标是通过扰动激励充分激发系统的动态响应以获得具有代表性的高质量数据, 而非实现高精度的闭环跟踪控制, 因此即使在数据准备过程中控制器模型参数存在一定偏差, 其对辨识结果的影响也可以忽略。为降低扰动对变流器造成损害, 同时考虑到 GFC 系统动态的特点, 本文使用幅值在 10% 额定值以内的阶梯型扰动作为输入信号^[16-17]。考虑到 d 轴和 q 轴分量的提取对于数据时长的要求, 且为减少对系统扰动的持续时间, 施加的扰动信号持续时间为 3 个工频周期, 即 0.06 s, 并且使用 100 kHz 的采样频率收集 GFC 状态变量数据。此外, 采样得到的数据均通过截止频率为 500 Hz 的低通滤波器滤除采样噪声。

接着, 采用四阶中心有限差分法获得状态变量的导数值 $\dot{\mathbf{x}}$, 以便兼顾微分估计的准确性与计算的简便性, 公式为

$$\dot{\mathbf{x}}(j) \approx \frac{-\mathbf{x}(j+2) + 8\mathbf{x}(j+1) - 8\mathbf{x}(j-1) + \mathbf{x}(j-2)}{12h} \quad (14)$$

式中: h 为步长。

最后, 得到状态变量的导数矩阵为

$$\dot{\mathbf{X}} = \begin{bmatrix} \dot{\mathbf{x}}_1(t_1) & \cdots & \dot{\mathbf{x}}_4(t_1) \\ \dot{\mathbf{x}}_1(t_2) & \cdots & \dot{\mathbf{x}}_4(t_2) \\ \vdots & & \vdots \\ \dot{\mathbf{x}}_1(t_m) & \cdots & \dot{\mathbf{x}}_4(t_m) \end{bmatrix} \quad (15)$$

式中: t_m 为测量过程中的时刻。

2.2 建立备选函数池

在 SINDy 算法中, 由于缺乏对系统模型的先验知识, 往往会穷尽所有状态变量和控制输入的一次、二次甚至更高次数的组合, 如 $x_1^2, x_1 x_2, x_1 u_2, u_1 u_2$ 等, 然后基于如此庞大的备选函数池进行回归运算, 从而获取其中能够充分表达非线性系统动态的函数项。但是, 本文引入系统物理知识, 使用基于 dq 坐标系 GFC 模型进行系统辨识, 不必构造二次及更高次数的备选函数, 这也是本文所提策略能够减少训练数据和提高训练速度的重要原因之一。

由式(5)可知, 状态变量的导数 $\dot{\mathbf{X}}$ 可以表示为备选函数池 $\Theta(\mathbf{X}, \mathbf{U})$ 中各列向量的线性组合

$$\dot{\mathbf{X}} = \Theta(\mathbf{X}, \mathbf{U}) \mathbf{\Xi} \quad (16)$$

式中: $\mathbf{\Xi}$ 为备选函数线性组合系数矩阵。

因此,本文所构造的备选函数池为

$$\Theta = \begin{bmatrix} x_1(t_1) & \cdots & x_4(t_1) & u_1(t_1) & \cdots & u_4(t_1) \\ x_1(t_2) & \cdots & x_4(t_2) & u_1(t_2) & \cdots & u_4(t_2) \\ \vdots & & \vdots & \vdots & & \vdots \\ x_1(t_m) & \cdots & x_4(t_m) & u_1(t_m) & \cdots & u_4(t_m) \end{bmatrix} \quad (17)$$

2.3 稀疏回归算法

由式(16)可知,只要能够获得 $\dot{\mathbf{X}}$ 对应的 Ξ ,就能够为MPC提供GFC系统的预测模型,而这一目标将通过求解一个优化问题达成

$$\xi_i = \arg \min_{\xi_i} \frac{1}{2} \|\dot{\mathbf{X}}_i - \xi_i \Theta^T(\mathbf{X}, \mathbf{U})\|_2^2 + \lambda \|\xi_i\|_1 \quad (18)$$

式中: ξ_i 表示 Ξ 中的第 i 列;上标 $\hat{\cdot}$ 表示估算值; $\dot{\mathbf{X}}_i$ 表示 $\dot{\mathbf{X}}$ 中的第 i 列; $\|\cdot\|_2^2$ 项保证了由 ξ_i 计算出的状态变量微分值与实际值的误差最小; $\|\cdot\|_1$ 项是稀疏化的关键,其促进了 ξ_i 的稀疏性,避免了过拟合问题的发生,提高了模型的泛化能力; λ 在该优化问题的求解中扮演着重要角色,其被用来平衡辨识结果的稀疏度和准确性。 λ 过大会导致稀疏过度,反之会导致欠拟合,两者都会降低辨识结果的准确性。通常的做法是先粗略扫描一遍 λ ,通过观察误差变化,缩小满足要求的 λ 范围,然后细化参数再次扫描,最终确定 λ 的取值。值得注意的是,看似这个参数选择的过程比较繁琐,但实际上,由于GFC系统模型本身的稀疏度就比较高,即 Ξ 中零项较多,并且系统中一般使用的LC滤波器的参数值还会使得 Ξ 理论上的非零项数值较大,因此 Ξ 中的有效项与无效项差异是比

较大的,降低了 λ 参数调节的难度。在实际应用过程中,经过两次 λ 取值扫描即可基本确定合适的 λ ,调参成本低。本文所提稀疏回归算法的流程如图3所示,其中 D 为索引。




图3 稀疏回归算法流程图

Fig. 3 Flowchart of the sparse regression algorithm

相较于重新精准测量滤波器元件参数,SR一次短时数据注入与回归辨识即可得到可直接用于MPC的等价模型,既免去了调试现场拆机与精密测量成本,又能适应一定程度的参数漂移(在4.4节中详细说明),因此总体工程成本更低。

3 基于SR的MPC设计

图4为本文所提SR-MPC策略的整体框架,其中 $\hat{x}$ 为 x 的估算值, x_{ref} 为 x 的参考值, r_j 为误差项。




图4 SR-MPC控制策略框架

Fig. 4 SR-MPC control strategy framework diagram

首先,采用基于SR过程的数据驱动方法获得GFC系统预测模型。在给定约束和目标函数的基

础上,MPC将计算出未来最优的控制序列,并选择下一时刻的最优控制决策作为GFC的SPWM生成

器的参考值,从而实现对 GFC 输出的精准控制。在系统模型辨识阶段,与传统 GFC 建模方式^[18]不同,SR-MPC 策略将 I_{od} 、 I_{oq} 作为控制输入而非状态变量的优势如下。以 RL 型负载为例,若将 I_{od} 、 I_{oq} 作为状态变量,则系统连续时间模型中的矩阵 $\mathbf{A}$ 将会变为 $\tilde{\mathbf{A}}$

$$\tilde{\mathbf{A}} = \begin{bmatrix} -\frac{r}{L_f} & \omega & -\frac{1}{L_f} & 0 & 0 & 0 \\ -\omega & -\frac{r}{L_f} & 0 & -\frac{1}{L_f} & 0 & 0 \\ \frac{1}{C_f} & 0 & 0 & \omega & -\frac{1}{C_f} & 0 \\ 0 & \frac{1}{C_f} & -\omega & 0 & 0 & -\frac{1}{C_f} \\ 0 & 0 & * & 0 & * & -\omega \\ 0 & 0 & 0 & * & -\omega & * \end{bmatrix} \quad (19)$$

式中: * 项与负载 R_{load} 、 L_{load} 大小有关,所以当负载功率变化时, $\tilde{\mathbf{A}}$ 的回归辨识结果会失效而需要重新辨识,并且若负载类型发生变化,矩阵 $\mathbf{A}$ 的形式可能也会随之变化,从而导致模型泛化能力降低。相比之下,本文选择将 I_{od} 、 I_{oq} 作为控制输入进行系统模型辨识,其辨识结果即式(5)中并不含有负载参数相关项,因此能够有效降低模型训练成本以及提高模型的泛化能力。

在 MPC 阶段,由于孤岛运行模式下的 GFC 为恒压恒频控制,因此 I_{od} 、 I_{oq} 仅由负载功率决定而不能作为 MPC 中取值可变的待优化量,因此本文所提 SR-MPC 策略在每次最优化目标函数的过程中将 I_{od} 、 I_{oq} 设为定值,即认为在未来 N_p 个预测步长时间内 I_{od} 、 I_{oq} 恒为当前时刻的测量值。实际上,GFC 控制输入更新频率一般为 10 kHz 或更高, N_p 在 10 以内,这意味着在负载功率发生突变后的至多 0.1 ms 内,所提控制策略就能够捕捉到这一变化进而产生新的控制序列,维持输出电压的稳定。另外,从式(9)可以看出,传统 MPC 依赖于人为提供的 C_f 参数,其精准性难以保证,同样地,在传统级联控制方式中, I_{od} 、 I_{oq} 也依赖于电压环的 PI 调节器与前馈环节的参数设计,调参成本更高。但是,本文所提 SR-MPC 策略凭借稀疏性的系统回归模型,其结构与式(5)中各矩阵相同,就能够准确获取实际 GFC 系统的 C_f ,因而大大提高了控制精度。

4 算例分析

为验证所提 SR-MPC 控制策略的有效性,在

Matlab/Simulink 软件中搭建了如图 1 所示的孤岛 GFC 模型。通过获取训练数据并进行离线辨识得到的 GFC 系统模型被用于在线 MPC 控制,验证设计及结果分为以下几个部分。

4.1 导数估计的准确性

由式(5)可知,在 SR 过程中需要用到状态变量的导数值,本文使用的采样频率为 100 kHz,每 5 次采样进行一次中间时刻的状态变量微分估计,如式(14)所示。准确的时间导数估计值是保证后续模型辨识效果的关键,因此本文设计了针对状态变量导数检验的仿真实验。为避免获取数据过程中对于 GFC 的损伤,本文使用调制度为 10% 以内的阶梯信号作为激励,扰动系统从而获取训练数据。 $t=0$ 时, d 轴调制幅值为 0.08, q 轴为 0.01; $t=0.04$ s 时, d 轴幅值跃变为 0.02, q 轴幅值 0.05。测量从 $t=0$ 至 $t=0.06$ s 内的系统状态变量和控制输入,系统参数见表 1。

表 1 GFC 系统参数设置

Table 1 GFC system parameter setting

参数	数值
采样频率/kHz	100
低通滤波器自然频率/Hz	500
直流侧电压/V	800
滤波电感/mH	1.35
滤波电感寄生电阻/ Ω	0.1
滤波电容/ μF	50

图 5 以 $\dot{I}_{id}$ 为例展示了状态变量导数的验证结果。可以看出,数值计算获得的状态导数曲线与实际参考值高度吻合,验证了所选导数估计方法的有效性。




图 5 I_{id} 导数估计值与实际值对比

Fig. 5 Estimated vs. actual values of derivative I_{id}

4.2 稀疏回归模型的准确性与泛化能力

为验证模型辨识结果的有效性和准确性,本文在 $t=0, 0.04$ s, 0.08 s, 0.10 s 时,同时在 d 轴施加幅值为 0.08, 0.02, 0.04, 0.07 和 q 轴为 0.01,

0.05, 0.08, 0.03 的 SPWM 的参考值,然后获取从 $t=0$ 至 $t=0.12$ s 内的测量数据。其中, $t=0$ 至 $t=0.06$ s 的数据用于训练以获得系统辨识模型,而 $t=0.06$ s 至 $t=0.12$ s 的数据用来验证 SR 的结果。由于验证阶段所采用的激励信号不同于训练阶段的输

入,因此可以有效评估所辨识系统模型在未见数据下的泛化能力和预测精度,图 6 展示了 I_{id} 与 U_{oq} 的验证结果。可以看出,SR 模型准确反映了 GFC 系统的动态响应,能够有效预测系统在不同激励下的状态变量变化。




图 6 I_{id} 与 U_{oq} 的预测值与测量值对比

Fig. 6 Comparison of predicted and measured values for I_{id} and U_{oq}

为进一步验证所提 SR 算法在应对 GFC 参数变化方面的泛化能力及其对参数整定工作的简化效果,本文设置了 5 种 GFC 参数场景,如表 2 所示。使用同样的激励,同样的稀疏度参数 $\lambda = 400, 400, 5 \times 10^3, 5 \times 10^3$ 进行系统辨识,实验结果如图 7 所示。

从图 7 可知,在 GFC 参数发生不同类型且较大比例偏移的情况下,使用相同的稀疏度参数 λ 进行模型辨识的平均相对误差均在 0.7% 以内。由此验证了所提 SR 策略对于不同 GFC 参数偏移场景的适应性,且相较于直接精准测量滤波器参数的做法,所提方法显著降低了现场调试与复现成本,工程成本更低。

表 2 变 GFC 参数的场景设置

Table 2 Scene setting for variable GFC parameters

场景编号	寄生电阻 r/Ω	滤波电感 L_f/mH	滤波电容 $C_f/\mu\text{F}$	参数变化率/%		
				r	L_f	C_f
1	0.10	1.35	50	0	0	0
2	0.05	1.00	60	-50	-26	20
3	0.15	1.50	45	50	11	-10
4	0.20	2.50	70	100	85	40
5	0.04	0.70	30	-60	-48	-40




图 7 不同 GFC 参数场景下的辨识结果

Fig. 7 Recognition results for scenarios with different GFC parameters

4.3 动态性能与计算效率

在孤岛运行方式下,GFC 需要在负载功率发生

变化时保持微网电压稳定,并且能够快速提供功率支撑以满足动态需求。为验证所提 SR-MPC 策略在该场景下的性能,本节设计了变功率因数负载的测试工况,如图 8 所示。




图 8 负载功率变化情况

Fig. 8 Load power variation

图 9 和图 10 展示了输出电压与电流的动态响应结果,下角 rms 表示有效值, U_{oa} 、 U_{ob} 、 U_{oc} 分别为 a、b、c 相输出电压, I_{oa} 、 I_{ob} 、 I_{oc} 分别为 a、b、c 相输出电流。可以看出,所提 SR-MPC 控制策略能够在半个周波时间内响应负荷变化并且提供稳定的电压支撑,状态过渡平滑,具备优秀的动态性能。

为验证稀疏回归模型以及基于该模型的二次规划最优化方法对于 MPC 计算效率的有效提升,本文设置了 SR-MPC 与基于最小二乘回归模型的 MPC (LS-MPC)、枚举式 MPC (EMPC) 的对比实验。其中,LS-MPC 与 SR-MPC 均使用二次规划最优化方法,但 LS-MPC 采用非稀疏性的模型进行预测;EMPC 与

SR-MPC 均使用稀疏模型,但 EMPC 采用枚举式最优化方法。场景设置如下:在图 8 所示工况下,其他条件相同,分别记录 3 种策略的在线 MPC 单次执行时长,统计 T_{mean} 、 $T_{95\%}$ 和 $T_{99\%}$ (单次执行耗时平均值、处于 95%、99% 位置的值),结果如表 3 所示。可以看出,在不同预测步长条件下,SR-MPC 策略的计算耗时平均值及 95%、99% 分位值均显著低于 LS-MPC,验证了稀疏化模型在降低计算负担方面的优势。同时,对比 SR-MPC 与 EMPC 的结果可以发现,QP 最优化方法能够有效应对预测步长增加所带来的计算量增大问题,表明所提策略具备良好的工程应用潜力。




图 9 负载功率变化下的 GFC 输出电压

Fig. 9 GFC output voltage under load power variation




图 10 负载功率变化下的 GFC 输出电流

Fig. 10 GFC output current under load power variation

表 3 3 种 MPC 策略的计算耗时对比

Table 3 Comparison of computational time for three MPC strategies

控制策略	计算耗时/ μs								
	$N_p=3$			$N_p=6$			$N_p=9$		
	T_{mean}	$T_{95\%}$	$T_{99\%}$	T_{mean}	$T_{95\%}$	$T_{99\%}$	T_{mean}	$T_{95\%}$	$T_{99\%}$
LS-MPC	13.3	9.9	13.7	70.7	68.9	82.2	120.1	120.3	143.3
EMPC	13.3	9.7	14.2	51.2	45.9	67.8	77.8	73.9	96.7
SR-MPC	11.7	2.9	4.4	12.4	6.0	8.8	17.9	11.5	16.8

4.4 控制性能与工程可行性

为进一步评估所提 SR-MPC 策略在参数不确定下的综合控制性能与鲁棒性,本文在仿真中设置 $L_f=1.34$ mH, $C_f=49.6$ μ F,此时两者分别偏离其标称值(如表 1 所示)0.7%与 0.8%。在相同的变负载场景(图 11)下,双环 PI^[19-20]、FCS-MPC^[21]、MFPC^[22]与 SR-MPC 策略的输出表现见图 12~图 14。




图 11 变负载场景

Fig. 11 Varying load scenarios




图 12 4 种策略的 GFC 输出电压对比

Fig. 12 Comparison of GFC output voltage of four strategies

由图 12 可见,由于参数偏差的存在,FCS-MPC 策略输出电压出现了明显的非对称失真,说明该测试工况对于控制器性能提出了较高要求,这也从侧面验证了采用 MPC 控制的 GFC 对于滤波器参数精准度的高度依赖性;双环 PI 控制在负载突变后出现较为明显的电压波动,并且稳态恢复时间相对较

长;相比之下,MFPC 对于负载变化的响应速度有所提升,但暂态性能较差,尤其是在启动阶段存在明显的超调与振荡;SR-MPC 在相同工况下呈现更短的暂态调节时间与更小的稳态误差,输出电压的稳态误差控制在 $\pm 0.1\%$ 以内,验证了其对于轻度参数漂移的鲁棒性以及较低的再整定成本。在 GFC 启动并稳定后,对 $t=0.2\text{ s}$ 至 $t=1.0\text{ s}$ 内的电压波形进行了谐波分析,数据显示 MFPC 控制下的输出电压总谐波失真为 1.74% ,而 SR-MPC 的为 0.20% ,进一步体现了所提策略优秀的控制性能。




图 13 4 种策略的 GFC 输出有功功率对比

Fig. 13 Comparison of GFC output active power of four strategies




图 14 4 种策略的 GFC 输出无功功率对比

Fig. 14 Comparison of GFC output reactive power of four strategies

从图 13 和图 14 可以发现,双环 PI 控制下的 GFC 输出功率在负载变化后出现较为明显的振荡过程,并且存在稳态误差;同样地,MFPC 控制也出现了功率振荡以及稳态误差,而且较前者更为明显;相比之下,SR-MPC 输出功率跟踪平滑,稳态波动低且误差被控制在 $\pm 1\%$ 以内,说明在参数偏差场景中依然能够提供准确稳定的功率响应。

综合对比图 12~图 14 中 SR-MPC 与 MFPC 的仿真结果可以发现,前者控制下的 GFC 输出电压谐波含量更少、稳态误差更小,说明当模型精度足够时,MPC 在约束处理、跟踪精度方面相较于 MFPC 表现更优,而本文的 SR 策略降低了获得高精度模型的成本,使该优势具有工程可行性。

以本文控制器结构与测试工况为例,即短时域($N_p < 10$)、输入盒约束与稀疏模型,使用主频为 200 MHz 及以上 DSP 并采用快速梯度法求解 QP 方程,可以将在线优化最坏时间控制在 $50 \mu\text{s}$ 以内,能够满足控制更新周期为 20 kHz 的 GFC 实时性需求^[23]。至此,从性能表现到实现可行性,验证了 SR-MPC 在参数不确定性的工程场景中同时具备稳健的控制效果与可控的计算开销。

5 结 论

(1)本文提出了一种基于系统动态稀疏回归的构网型变流器模型预测控制策略(SR-MPC),有效解决了传统双环控制与 MPC 控制中调参难度大、对精确物理参数依赖性强的问题。在 5 组幅度的参数偏移场景中,采用相同的稀疏度参数 λ 所得模型的平均相对误差均在 0.7% 以内,验证了所提 SR 策略在具备良好的建模精度的同时能够降低调参成本。

(2)所提稀疏回归模型具有良好的可解释性,在提高 MPC 计算效率与泛化能力方面优势显著;基于回归模型的 MPC 兼具优秀的控制性能与工程可实现性。仿真结果表明,在负载大小及功率因数发生变化时,SR-MPC 策略能够在 5 ms 内完成对负载扰动的动态响应,输出相电压有效值的稳态误差控制在 $\pm 0.1\%$ 以内。与传统双环 PI 控制、FCS-MPC 及 MFPC 相比,SR-MPC 策略在参数漂移工况下展现出更强的鲁棒性和动态性能。

(3)本文所提 SR-MPC 策略与目前广泛使用的虚拟同步发电机(VSG)控制策略具有天然的兼容性,VSG 可作为外环为 SR-MPC 内环提供更精准的电压与频率参考,从而形成功能更加完善的 GFC 双环控制方案。

未来的研究将考虑将 SR-MPC 策略与 VSG 相结合,以进一步提升构网型变流器在大规模新能源并网中的动态性能和鲁棒性。

参考文献:

[1] 郭方洪,冯秀荣,杨谟,等.基于数据模型双驱动的新能源微电网分布鲁棒优化调度[J].电力系统自动

化,2024,48(20):36-47.

GUO Fanghong, FENG Xiurong, YANG Hao, et al. Dual-data-model-driven distributionally robust optimal scheduling of renewable energy microgrid [J]. Automation of Electric Power Systems, 2024, 48(20): 36-47.

[2] 许诒翊,刘威,刘树,等.电力系统变流器构网控制技术的现状与发展趋势[J].电网技术,2022,46(9):3586-3594.

XU Jieyi, LIU Wei, LIU Shu, et al. Current state and development trends of power system converter grid-forming control technology [J]. Power System Technology, 2022, 46(9): 3586-3594.

[3] DRAGIĆEVIĆ T, VAZQUEZ S, WHEELER P. Advanced control methods for power converters in DG systems and microgrids [J]. IEEE Transactions on Industrial Electronics, 2021, 68(7): 5847-5862.

[4] LI Hongfeng, SHAO Jianyu, LIU Zhengyu. Incremental model predictive current control for PMSM with online compensation for parameter mismatch [J]. IEEE Transactions on Energy Conversion, 2023, 38(2): 1050-1059.

[5] SIAMI M, KHABURI D A, ABBASZADEH A, et al. Robustness improvement of predictive current control using prediction error correction for permanent-magnet synchronous machines [J]. IEEE Transactions on Industrial Electronics, 2016, 63(6): 3458-3466.

[6] ZHANG Yongchang, LIU Xiang, LI Bingyu, et al. Robust predictive current control of PWM rectifier under unbalanced and distorted network [J]. IET Power Electronics, 2021, 14(4): 797-806.

[7] LAMMOUCHI Z, LABIOD C, SRAIRI K, et al. Enhanced model-free predictive control for voltage source inverters using an adaptive observer [J]. Revue Roumaine des Sciences Techniques-Série Électrotechnique Et Énergétique, 2024, 69(3): 321-326.

[8] HUANG Min, ZHANG Huiying, WANG Kangan, et al. Model-free predictive control based on RLS algorithm for grid-forming inverters with virtual synchronous generator [J]. IEEE Access, 2025, 13: 57921-57931.

[9] BRUNTON S L, PROCTOR J L, KUTZ J N. Sparse identification of nonlinear dynamics with control (SINDy) [J]. IFAC-PapersOnLine, 2016, 49(18): 710-715.

[10] FASEL U, KUTZ J N, BRUNTON B W, et al. Ensemble-SINDy: robust sparse model discovery in the low-data, high-noise limit, with active learning and control [J]. Proceedings of the Royal Society: A Mathematical, Physical and Engineering Sciences, 2022, 478(2260): 20210904.

- [11] NANDAKUMAR A, LI Yan, ZHENG Honghao, et al. Data-driven modeling of microgrid transient dynamics through modularized sparse identification [J]. IEEE Transactions on Sustainable Energy, 2024, 15(1): 109-122.
- [12] CAI Yaojie, WANG Xiaozhe, JOÓ S G, et al. An online data-driven method to locate forced oscillation sources from power plants based on sparse identification of nonlinear dynamics (SINDy) [J]. IEEE Transactions on Power Systems, 2023, 38(3): 2085-2099.
- [13] SHADAEI M, KHAZAEI J, MOAZENI F. Data-driven nonlinear model predictive control for power sharing of inverter-based resources [J]. IEEE Transactions on Energy Conversion, 2024, 39(3): 2018-2031.
- [14] SAEED KANDEZY R, JIANG J, WU Di. On SINDy approach to measure-based detection of nonlinear energy flows in power grids with high penetration inverter-based renewables [J]. Energies, 2024, 17(3): 711.
- [15] YAZDANI A, IRAVANI R. Two-level, three-phase voltage-sourced converter [M]//YAZDANI A, IRAVANI R. Voltage-Sourced Converters in Power Systems: Modeling, Control, and Applications. Piscataway, NJ, USA: Wiley-IEEE Press, 2010: 115-126.
- [16] LIU Tao, WANG Qingguo, HUANG H P. A tutorial review on process identification from step or relay feedback test [J]. Journal of Process Control, 2013, 23(10): 1597-1623.
- [17] KATAYAMA T, KAWAUCHI H, PICCI G. Subspace identification of closed loop systems by the orthogonal decomposition method [J]. Automatica, 2005, 41(5): 863-872.
- [18] MITTAL R, MIAO Zhixin. Analytical model of a grid-forming inverter [C]//2022 IEEE Power & Energy Society General Meeting (PESGM). Piscataway, NJ, USA: IEEE, 2022: 1-5.
- [19] MITRA A, CHOWDHURI S. Analysis of single phase PWM rectifier for different applications [J]. Journal of the Institution of Engineers (India): Series B, 2017, 98(2): 161-169.
- [20] 李双, 施建强. 基于新型双环控制的 LC 型逆变器研究 [J]. 上海交通大学学报, 2022, 56(9): 1139-1147.
- LI Shuang, SHI Jianqiang. An LC inverter based on novel dual-loop control [J]. Journal of Shanghai Jiao Tong University, 2022, 56(9): 1139-1147.
- [21] MOHAMED I S, ZAID S A, ABU-ELYAZEED M F, et al. Implementation of model predictive control for three-phase inverter with output LC filter on eZdsp F28335 Kit using HIL simulation [J]. International Journal of Modelling Identification and Control, 2016, 25(4): 301-312.
- [22] ZHAO Tao, ZHANG Mingzhou, WANG Chunlin, et al. Model-free predictive current control of three-level grid-connected inverters with LCL filters based on Kalman filter [J]. IEEE Access, 2023, 11: 21631-21640.
- [23] RICHTER S, JONES C N, MORARI M. Computational complexity certification for real-time MPC with input constraints based on the fast gradient method [J]. IEEE Transactions on Automatic Control, 2012, 57(6): 1391-1403.

(编辑 亢列梅)