

基于模型和数据驱动的GCI非线性建模及阻抗辨识方法

杨勇,张旭军,刘文飞,牛浩明,赵进国,杨瑞

(国网甘肃省电力公司 电力科学研究院,甘肃 兰州 730070)

摘要: 新能源机组的大规模并网给系统运行的稳定性带来了诸多不良影响,对新能源机组并网逆变器(GCI)进行机理分析和阻抗特性辨识是有效应对上述问题的关键前提之一,因此,提出一种基于模型和数据驱动的GCI非线性建模及阻抗辨识方法。首先,考虑锁相环动态的影响,对新能源机组GCI进行小信号建模,建立GCI阻抗辨识输入和输出变量间的非线性映射关系;其次,利用Matlab/Simulink软件搭建新能源机组并网系统仿真模型,在多种工况下获取极端梯度提升树(XGBoost)训练所需的数据集;然后,利用仿真数据对XGBoost进行训练,并采用粒子群优化(PSO)算法对XGBoost的超参数进行寻优;最后,利用RT-LAB硬件在环测试技术结合小扰动法对GCI的阻抗特性进行扫描,获取模型验证所需的阻抗实际值。经过有效性和优越性对比实验表明了PSO-XGBoost模型相对于其他模型具有更高的GCI阻抗辨识精度。

关键词: 新能源机组;并网逆变器;阻抗辨识;极端梯度提升树;粒子群算法

中图分类号: TM464 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed25996

Model and Data Driven Nonlinear Modeling and Impedance Identification Method for GCI

YANG Yong, ZHANG Xujun, LIU Wenfei, NIU Haoming, ZHAO Jinguo, YANG Rui

(Electric Power Research Institute, State Grid Gansu Electric Power Company, Lanzhou 730070, Gansu, China)

Abstract: The integration of new energy units on a large scale has introduced numerous adverse effects on the stability of system operation. Analysis of mechanisms and identification of impedance characteristics in grid-connected inverter (GCI) for new energy units are key to effectively addressing these issues. Therefore, a model and data-driven nonlinear modeling and impedance identification approach for GCI was presented. Firstly, considering the influence of phase-locked loop dynamics, a small signal modeling was performed on the GCI of new energy units, and a nonlinear functional relationship between the input and output variables of GCI impedance identification was established. Secondly, a simulation model of the new energy units grid connected system by Matlab/Simulink was built, and the dataset required for eXtreme gradient boosting (XGBoost) training under various operating conditions was obtained. Then, simulation data was adopted to train XGBoost, and particle swarm optimization (PSO) was employed to optimize the hyperparameters of XGBoost. Finally, the impedance characteristics of GCI were scanned using RT-LAB hardware-in-the-loop testing technique combined with small disturbance method to obtain the actual impedance values required for model validation. The effectiveness and superiority comparison experiments show that the PSO-XGBoost model has higher GCI impedance identification accuracy compared to other models.

Key words: new energy units; grid-connected inverter (GCI); impedance identification; eXtreme gradient boosting(XGBoost); particle swarm optimization(PSO)

随着“双碳”目标的提出,以风电、光伏为代表的新能源机组呈现大规模并网趋势^[1],其中,并网逆变器(grid-connected inverter, GCI)作为新

源发电系统与电网之间的关键接口元件,发挥着将电能高质量送入电网的重要作用^[2],但其多尺度动态控制过程给电力系统带来的非线性问题

基金项目: 国网甘肃省电力公司电力科学研究院科技项目(52272223004S)

作者简介: 杨勇(1972—),男,硕士,正高级工程师,主要研究方向为电网仿真分析和新能源发电与并网,Email: 1459134111@qq.com

日益突显,为了有效地对高渗透新能源并网系统进行稳定性分析,应对各种非线性因素给系统带来的谐波和振荡等不稳定性问题,对新能源机组 GCI 进行非线性特性建模和阻抗辨识是解决上述问题的关键前提之一^[3-4]。

针对新能源机组 GCI 非线性特性建模问题,国内外学者已经开展了大量的分析研究工作,主要建模方法包括阻抗建模法^[5]和状态空间建模法^[6]两大类,大多数研究通过传递函数推导 GCI 的非线性阻抗数学模型,并考虑多种影响因素对 GCI 的稳定性进行了分析。如文献[7]考虑 GCI 的频率耦合特性建立其精确的阻抗模型,并分析了电压环控制参数对 GCI 稳定性的影响;文献[8]构建考虑等效电流源稳定性的 GCI 单输入单输出阻抗模型,该模型实现了等效电流源与 GCI 参数的解耦,为控制环参数自适应调整控制策略下 GCI 的稳定性分析奠定了模型基础;文献[9]考虑锁相环(phase-locked loop, PLL)的频率特性,构建了不平衡电网下的 GCI 输出阻抗模型,分析了不同 PLL 对 GCI 输出阻抗的影响,并进一步探讨了 GCI 与电网之间的交互稳定性。上述研究对谐波、振荡等一些列不稳定性问题提供了较好的分析解决思路,但所用方法要求 GCI 的结构、参数、控制方式等内部信息是已知的,而在实际工程中,受商业技术保密的限制,这些关键信息往往具有未知性,因此上述这种“白箱”式建模方法不再适用^[10]。

为了有效应对上述问题,采用“黑箱”式建模方法可以克服“白箱”式建模方法需要获取 GCI 内部参数的问题,但其计算结果比较随机且通常会缺乏实际的物理意义,而有效地结合两种方法可以不用获取 GCI 的内部参数信息,还能确保结果具有实际物理意义^[11],同时结合人工智能算法拟合输入输出变量间非线性能力强的优势,以“白箱”式建模结果为输出标签,以“黑箱”扫频得到的大数据作为输入特征,通过训练人工智能算法模型,从而获得 GCI 的实际阻抗特性,此外,由于 GCI dq 阻抗更易与实际系统建立联系^[12],因此大多数研究以 GCI dq 阻抗为辨识对象,例如文献[13-14]中分别采用递推最小二乘法和有理函数逼近法,并结合 GCI 端口电压和电流信息,对不同运行工况下的 GCI 进行了 dq 阻抗的在线辨识;而文献[15-16]则分别基于人工神经网络(ANN)、BP 神经网络建立了 GCI dq 阻抗辨识的通用框架。

上述文献分别采用传统拟合方法和神经网络算法对 GCI 阻抗进行辨识,但“黑箱”数据建模往往对先验知识的“白箱”模型缺乏一定的解释,同时传统神经网络辨识方法也存在辨识精度低、泛化性能差的缺点。

基于上述背景,为了加强“黑箱”建模对“白箱”建模物理意义上的解释性,进一步提高 GCI 阻抗辨识的精度,本文提出一种基于模型和数据驱动的新能源机组 GCI 非线性建模及阻抗辨识方法。首先,考虑锁相环的影响,建立新能源机组 GCI 的小信号模型,分析出 GCI 阻抗特性与系统关键参数之间的非线性函数关系;其次,利用 Matlab/Simulink 软件搭建新能源机组并网系统仿真模型,在多种工况下获取极端梯度提升树(eXtreme gradient boosting, XGBoost)训练所需的数据集;然后,利用仿真数据对 XGBoost 进行训练,并使用 PSO 算法对 XGBoost 的超参数进行寻优;最后,利用 RT-LAB 硬件在环测试技术结合小扰动法对 GCI 的阻抗特性进行扫描,获取模型验证所需的阻抗实际值,并对 PSO-XGBoost 模型进行有效性和优越性验证。

1 新能源机组 GCI 非线性建模

当电网发生故障或振荡等不稳定性问题时,新能源机组机端电压会受到新能源机组发出的有功和无功变化量的影响^[17],GCI 作为新能源机组的核心部件,承担着控制整个新能源机组完成故障穿越或抑制振荡等不稳定问题的重要作用,但随着分布式电源的大量并入,电网表现出了弱特性,导致并网系统与电网阻抗之间发生交互作用,这个交互作用会引起并网点电压产生波动,进而使得 PLL 无法准确获取相角信息而对控制环节产生负面影响,严重情况下还会威胁到整个并网系统的稳定性,因此,构建考虑 PLL 动态影响的 GCI 非线性模型具有重要的意义。基于上述背景,本文以 LCL 型 GCI 为例(对于 L 型的 GCI 同样适用),并考虑锁相环动态影响,建立 GCI 的小信号模型,分析出 dq 阻抗与系统关键参数之间的非线性函数关系,图 1 给出了 LCL 型 GCI 的主电路及控制结构示意。图中, U_{dc} 为直流侧电压;电感 L_1 , L_2 和电容 C_f 是构成 LCL 滤波器的三个基本元件; I_1 , I_c , I_2 分别为逆变侧电感电流、滤波电容电流和电网侧电流,其中, I_{2dq} 为 I_2 在 $d-q$ 坐标系下的电流值, I_{2dqref} 为 I_2 在 $d-q$ 坐标系下的参考值; U_g 为

电网电压; U_{PCC} 为公共耦合点 (point of common coupling, PCC) 电压; U_m 为调制电压; Z_g 为电网阻抗; K_{cp} 为电容电流前馈系数; θ_{PLL} 为 PLL 的输出相角; $G_i(s)$ 为电流环 PI 控制器, 有 $G_i(s) = K_p + K_i/s$; ω_0 为 PLL 输出角频率。




图1 LCL型GCI主电路及控制结构

Fig.1 LCL type GCI's main circuit and control structure

根据图1,建立 $d-q$ 坐标系下未考虑 PLL 动态影响的 GCI 的小信号模型如图2所示。




图2 未考虑PLL动态影响的GCI小信号模型

Fig.2 Small signal model of GCI without considering the dynamic impact of PLL

图2中, $G_{de}(s)$ 为采样延迟环节, 计算公式为

$$G_{de}(s) = e^{-1.5T_s s} \quad (1)$$

式中: T_s 为采样时间。

将图2化简,可以得到如图3所示的系统简化的小信号模型。




图3 简化后的GCI小信号模型

Fig.3 Simplified small signal model of GCI

图3中, $G_{C1}(s)$ 和 $G_{C2}(s)$ 具体计算公式为

$$G_{C1}(s) = \frac{1}{s^2 L_1 C_f + s C_f K_{cp} G_{de}(s) + 1} \quad (2)$$

$$G_{C2}(s) = \frac{s^2 L_1 C_f + s C_f K_{cp} G_{de}(s) + 1}{s^3 L_1 L_2 C_f + s^2 L_2 C_f K_{cp} G_{de}(s) + s(L_1 + L_2)} \quad (3)$$

图3中系统环路增益用 $T_A(s)$ 表示, 计算公式可以表示为

$$T_A(s) = G_i(s) G_{de}(s) G_{C1}(s) G_{C2}(s) \quad (4)$$

由于 GCI 容易和弱电网之间发生交互作用,

易使公共耦合点的电压 U_{PCC} 发生扰动, 由此导致锁相环的输出角 θ_{PLL} 与 PCC 电压的稳态锁相角 θ 之间存在一个相角扰动量 $\Delta\theta$, 此时并网系统中存在两个 $d-q$ 坐标系^[18], 一个是系统本身的 $d-q$ 坐标系, 另一个是 GCI 的 $d-q$ 坐标系, 两者之间的关系如图4所示, 图中上标“s”表示系统本身的 $d-q$ 坐标系, “c”表示 GCI 控制系统的 $d-q$ 坐标系, 两个坐标系之间存在的角度差, 即为 $\Delta\theta$ 。




图4 两个dq坐标系的关系

Fig.4 The relationship between two dq coordinate systems

两个坐标系下状态变量 x^s, x^c 间的关系可以表示为

$$\begin{aligned} x^c &= e^{-j\Delta\theta} x^s \\ &= [\cos(\Delta\theta) - j\sin(\Delta\theta)] x^s \\ &\approx (1 - j\Delta\theta) x^s \end{aligned} \quad (5)$$

引入状态变量的小扰动量后, 上式不等式可以用等式表示为

$$\begin{aligned} &[(x_{d0}^c + \Delta x_d^c) + j(x_{q0}^c + \Delta x_q^c)] \\ &= (1 - j\Delta\theta)[(x_{d0}^s + \Delta x_d^s) + j(x_{q0}^s + \Delta x_q^s)] \end{aligned} \quad (6)$$

式中: 下标“0”表示稳态工作点下的状态变量。

由于两个坐标系中稳态工作点下的状态变量可以相互抵消, 即 $x_{d0}^c = x_{d0}^s, x_{q0}^c = x_{q0}^s$, 且高阶小扰动项 $\Delta\theta x_d^s$ 和 $\Delta\theta x_q^s$ 可被近似忽略, 因此式(6)可以进一步简化为

$$\begin{cases} \Delta x_d^c = \Delta x_d^s + \Delta\theta x_{q0}^s \\ \Delta x_q^c = \Delta x_q^s - \Delta\theta x_{d0}^s \end{cases} \quad (7)$$

可以看出, PLL 动态将在状态变量 Δx_{dq}^s 上引入额外的扰动量 $\Delta\theta \Delta x_{dq0}^s$ 。为了进一步分析考虑 PLL 动态影响下的 GCI 小信号模型, 根据文献[19]可知, PLL 的小信号模型可以表示为

$$\begin{cases} G_{PLL}(s) = \frac{\Delta\theta}{\Delta U_{PCCq}^s} = \frac{F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \\ F_{PLL}(s) = K_{p,PLL} + K_{i,PLL}/s \end{cases} \quad (8)$$

其中

$$s = j\omega = j(2\pi f)$$

式中: ω 为角频率; f 为频率; $K_{p,PLL}, K_{i,PLL}$ 分别为 PLL 的比例常数和积分常数。

将式(8)代入式(7)可以得到:

$$\begin{cases} \Delta x_d^c = \Delta x_d^s + \frac{F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \Delta U_{PCCq}^s x_{q0}^s \\ \Delta x_q^c = \Delta x_q^s - \frac{F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \Delta U_{PCCq}^s x_{d0}^s \end{cases} \quad (9)$$

在 $a-b-c$ 到 $d-q$ 坐标变换的过程中,电网电流 I_{2dq} 和调制电压 U_m 将受到 PLL 动态的影响,因此根据式(9)可以得到考虑 PLL 动态影响的 I_{2dq} 和 U_m 的计算公式:

$$\begin{cases} \Delta I_{2dq}^c = \Delta I_{2dq}^s + G_{PLL}^i(s) \Delta U_{PCCdq}^s \\ \Delta U_{mdq}^c = \Delta U_{mdq}^s + G_{PLL}^u(s) \Delta U_{PCCdq}^s \end{cases} \quad (10)$$

其中

$$G_{PLL}^i(s) = \begin{bmatrix} 0 & \frac{I_{2q0}^s F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \\ 0 & \frac{-I_{2d0}^s F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \end{bmatrix} \quad (11)$$

$$G_{PLL}^u(s) = \begin{bmatrix} 0 & \frac{U_{mq0}^s F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \\ 0 & \frac{-U_{md0}^s F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \end{bmatrix} \quad (12)$$

由于本文中 GCI 采用单位功率因数控制,因此稳态工作点处电网电流的 q 轴分量为零,即 $I_{2q0}^s = 0$ 。所以 $G_{PLL}^i(s)$ 为对角矩阵,式(11)简化为

$$G_{PLL}^i(s) = \begin{bmatrix} 0 & 0 \\ 0 & \frac{-I_{2d0}^s F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \end{bmatrix} \quad (13)$$

此外,在基于电网电压定向的同步旋转坐标系下,电压分量也存在以下简化条件:稳态工作点处的 d 轴耦合电压 $\omega_0 L_1 I_{1d0}^s + \omega_0 L_2 I_{2d0}^s$ 数值较小,可以直接忽略,滤波电感上的 q 轴电压降几乎为零,因此有 $U_{mq0}^s \approx U_{PCCq0}^c$,同时存在 $U_{PCCq0}^s = U_{PCCq0}^c = 0$,所以 U_{mq0}^s 也近似为零。由此 $G_{PLL}^u(s)$ 也为对角矩阵,式(12)简化为

$$G_{PLL}^u(s) = \begin{bmatrix} 0 & 0 \\ 0 & \frac{-U_{md0}^s F_{PLL}(s)}{s + U_{PCCd0}^s F_{PLL}(s)} \end{bmatrix} \quad (14)$$

根据图 3 和式(10),考虑 PLL 动态影响的 GCI 小信号模型如图 5 所示。图中, $G_i(s)$, $G_{de}(s)$, $G_{cl}(s)$, $G_{c2}(s)$ 分别为对应 $G_i(s)$, $G_{de}(s)$, $G_{cl}(s)$ 和 $G_{c2}(s)$ 的二阶对角矩阵。

根据图 5,得到受 PLL 动态影响的电网电流小信号 $\Delta I_{2dq}^s(s)$ 的计算公式为




图 5 考虑 PLL 动态影响的 GCI 小信号模型

Fig.5 Small signal model of GCI with considering the dynamic impact of PLL

$$\begin{aligned} \Delta I_{2dq}^s(s) = & [E + T_A(s)]^{-1} T_A(s) \Delta I_{2dqref}^s(s) - \\ & [E + T_A(s)]^{-1} G_{C2}(s) \Delta U_{PCCdq}^s(s) - \\ & [E + T_A(s)]^{-1} Y_{PLL}(s) \Delta U_{PCCdq}^s(s) \end{aligned} \quad (15)$$

其中

$$Y_{PLL}(s) = G_{PLL}^i(s) T_A(s) + G_{PLL}^u(s) G_{de}(s) G_{C1}(s) G_{C2}(s) \quad (16)$$

式中: E 为二阶单位矩阵; $T_A(s)$ 为对应环路增益的二阶对角矩阵; $Y_{PLL}(s)$ 为 PLL 的导纳矩阵。

同时,根据诺顿等效,可以得到如图 6 所示新能源机组 GCI 的等效电路图,图中, Z_o 为 GCI 的输出阻抗, I_o 为诺顿等效理想电流源。




图 6 GCI 诺顿等效电路

Fig.6 Norton equivalent circuit of GCI

由图 5 列写该电路在 $d-q$ 坐标系下的 KCL 方程:

$$\Delta I_{2dq}^s(s) = \Delta I_{odq}^s(s) - Z_o^{-1}(s) \Delta U_{PCCdq}^s(s) \quad (17)$$

结合式(15)和式(17),可以得到受 PLL 动态影响的 GCI 的输出阻抗具体表达式:

$$\begin{aligned} Z_o(s) = & [G_{C2}(s) + Y_{PLL}(s)]^{-1} [E + T_A(s)] \\ = & \begin{bmatrix} Z_{dd}(s) & Z_{dq}(s) \\ Z_{qd}(s) & Z_{qq}(s) \end{bmatrix} \end{aligned} \quad (18)$$

其中, $Z_{dd}(s)$, $Z_{dq}(s)$, $Z_{qd}(s)$, $Z_{qq}(s)$ 分别对应 $Z_o(s)$ 在 dd , dq , qd , qq 四个通道上的元素。

根据式(16)可知, $Y_{PLL}(s)$ 和 $d-q$ 坐标系下的并网点电压 U_{PCC} 、并网点电流 I_2 及频率 f 之间存在复杂的非线性映射关系,由此输出阻抗 $Z_o(s)$ 也与这些变量间接存在着复杂的非线性关系,因此,可以将 $Z_o(s)$ 用函数通式表示为

$$Z_o(s) = F(f, U_{PCCd}, U_{PCCq}, I_{2d}, I_{2q}) \quad (19)$$

其中, $F(\cdot)$ 为输入变量 f , U_{PCCd} , U_{PCCq} , I_{2d} , I_{2q} 与输出变量 $Z_o(s)$ 之间的非线性映射函数,给定 5 个输入

变量后可以通过 $F(\cdot)$ 求出输出变量 $Z_o(s)$ 在4个通道上的阻抗元素。

在新能源机组GCI的控制结构与参数均已明确给出的情况下,可以直接采用“白箱”式建模获得非线性映射关系 F 的精确解析表达式。然而,由于商业化新能源机组所固有的技术保密性以及GCI控制结构与参数的未知性,无法直接建立映射关系 F 的解析表达式,针对此问题,可以采用基于数据驱动的人工智能算法模型,通过分析训练数据集中输入和输出数据之间的数据特征,从而可以较为准确地建立非线性映射关系 $F^{[16]}$ 。

2 基于PSO-XGBoost模型的并网逆变器 dq 阻抗辨识

2.1 XGBoost模型

XGBoost^[20]是一种集成学习算法,通过组合多个弱学习器来构建强学习器,每个弱学习器由决策树组成,各棵决策树之间存在先后顺序,后一棵决策树的输出结果会受前一棵决策树的影响,当辨识某个样本时,该样本依次进入每棵决策树并输出辨识值,最后将每棵决策树的辨识值相加得到最终的辨识结果。这一算法在确保高准确率的同时,还展现出了良好的泛化性能,相较于传统神经网络,XGBoost模型能够快速且准确地学习复杂的非线性映射关系的同时,还具有较强的泛化性能。因此,为了提高GCI dq 阻抗辨识的精确性,本文采用XGBoost对GCI多工况下的 dq 阻抗进行辨识。

用于GCI dq 阻抗获取的数据集可以表示为 $D=\{x_i, y_i\} (i=1, 2, \dots, n)$, x_i 为并网点电压 U_{PCC} 、并网点电流 I_2 及频率 f 等特征量, y_i 为GCI dq 阻抗样本标签。每个弱学习器可以用函数 f_k 表示,经过 K 个弱学习器训练后可以得到第 i 个样本对应的GCI dq 阻抗辨识值 $\hat{y}_i$:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad f_k \in \mathbf{F} \quad (20)$$

其中

$$\mathbf{F} = \{f_k(x_i) = w_j^{(k)} \quad j = 1, 2, \dots, T\} \quad (21)$$

式中: $\mathbf{F}$ 为决策树的集合空间; j 为叶子节点; T 为每棵决策树中叶子节点的总数; w 为该叶子节点所关联的权重值。

XGBoost的目标函数为

$$O_{bj} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (22)$$

其中

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (23)$$

式中: $l(\cdot)$ 为辨识结果与实际数值间的误差损失函数; $\Omega(\cdot)$ 为正则化函数。

第一项、第二项分别为L1和L2正则化惩罚项, γ , λ 为正则化系数。

为了求得目标函数的最优解,对 $l(\cdot)$ 进行二阶泰勒展开,然后计算偏导数并令偏导为零即可得到:

$$w_{j*} = -\frac{G_j}{H_j + \lambda} \quad (24)$$

式中: w_{j*} 为第 j 个叶子节点的最优权重值; G_j, H_j 分别为所有样本数据在损失函数 $l(\cdot)$ 上的一阶、二阶偏导数。

将 w_{j*} 代入式(22)中可以得到最优目标函数为

$$O_{bj*} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (25)$$

为进一步降低损失函数值,XGBoost在进行节点分裂时,在已有叶子节点上增加新的分裂,从而可以获得更大的增益值。增益公式如下:

$$G = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_R + H_L + \lambda} \right] - \gamma \quad (26)$$

式中: G 为信息增益; G_L, G_R 分别为分裂后左、右叶子的一阶偏导累积和; H_L, H_R 分别为分裂后左、右叶子的二阶偏导累积和。

XGBoost选择信息增益最大的节点进行分裂,以一种更高效的方式来构建决策树,在一定程度上有助于减少模型的过拟合问题。此外,XGBoost通过对特征进行并行处理,还可以有效提高模型训练的效率。

2.2 PSO算法优化的XGBoost模型

在样本确定的情况下,参数的设置会极大地影响模型的精度,通过人为设置的方法很难得到精确度较高的参数,因此可以使用PSO算法进行超参数寻优,避免人工参数设置复杂、辨识不精确等问题。XGBoost模型的弱学习器数目 K 、树的深度 d 、学习率 l 、正则化系数 γ, λ 这5个超参数对其辨识性能有较大的影响,在利用PSO算法对这5个超参数进行寻优时,设置目标函数为辨识值与实际值之间的均方根误差 R_{MSE} ,计算公式为

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (27)$$

利用 PSO 算法对超参数寻优的具体步骤如下:

1) 初始化 PSO 算法的种群数和迭代次数,并设定 XGBoost 模型每个超参数的寻优范围,其中 $K \subseteq [200, 1\ 000]$; $d \subseteq [5, 10]$; $l \subseteq [0.01, 0.3]$; $\gamma \subseteq [0, 10]$; $\lambda \subseteq [0, 10]$ 。

2) 将训练集数据输入 XGBoost 模型,并使用式(27)作为算法的适应度函数,据此计算每个粒子的适应度,适应度值越低,辨识效果越好。

3) 根据适应度更新粒子群的速度和位置。

4) 算法结束判断,若达到最大迭代次数或满足算法精度要求则停止迭代,并输出最优粒子位置,对应着 XGBoost 模型的最优超参数值,否则返回步骤 2) 继续迭代运算。

5) 将最优参数代入 XGBoost 模型进行验证,评估模型的辨识性能。

PSO 算法优化 XGBoost 超参数的流程如图 7 所示。




图7 PSO算法优化XGBoost超参数流程

Fig.7 Optimizing XGBoost's hyperparameters process with PSO algorithm

2.3 并网逆变器 dq 阻抗辨识流程

基于模型和数据驱动的 GCI dq 阻抗辨识的具体流程如图 8 所示,主要分为四个步骤:数据获取、数据处理、模型构建和辨识校验。

步骤 1: 数据获取。为了准确建立 PSO-XGBoost 辨识模型,需要以 GCI dq 阻抗数据作为基础,因此本文在 Matlab/Simulink 中搭建仿真模型,通过设置新能源机组在不同频率下的有功、无功出力情况来改变并网点电压和电流,利用阻抗扫描模块获取 GCI 在多种运行工况下的 dq 阻抗数

据集。

步骤 2: 数据处理。为了提高 PSO-XGBoost 模型的训练效率,首先对获取的数据进行归一化处理,通常将数据缩放到 $(0, 1)$ 范围内,随后按照 8:2 的比例将数据划分为训练集和测试集,供辨识模型训练后将数据反归一化,使其具有实际的物理含义。归一化和反归一化计算公式分别如下式所示:

$$x_{i^*}(k) = \frac{x_i(k) - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (28)$$

$$x_i(k) = x_{i^*}(k)(x_{i,\max} - x_{i,\min}) + x_{i,\min} \quad (29)$$

式中: $x_i(k)$ 为特征 i 的第 k 个样本的原始数据; $x_{i,\max}, x_{i,\min}$ 分别为序列中的最大、最小值; $x_{i^*}(k)$ 为归一化值。

步骤 3: 模型构建。将 $f, U_{\text{PCCd}}, U_{\text{PCCq}}, I_{2d}, I_{2q}$ 作为模型训练的输入变量, GCI dq 阻抗作为输出变量构建阻抗辨识的 XGBoost 模型,并利用 PSO 算法对 XGBoost 的超参数进行寻优。

步骤 4: 辨识校验。基于 RT-LAB 软件搭建半实物仿真平台,采用小扰动法测试不同工况下 GCI 的 dq 阻抗,从而形成模型辨识校验的验证数据集,采用小扰动法得到的 GCI 阻抗可以表示为

$$\mathbf{Z}_o(s) = \begin{bmatrix} U_{d1} & U_{d2} \\ U_{q1} & U_{q2} \end{bmatrix} \begin{bmatrix} I_{d1} & I_{d2} \\ I_{q1} & I_{q2} \end{bmatrix}^{-1} \quad (30)$$

式中: 下标 1 和 2 表示测试时两次扰动注入。




图8 基于模型和数据驱动的 GCI dq 阻抗辨识

Fig.8 Model-data driven identification of GCI dq impedance

实验过程中注入的小信号干扰源为电压信号,扰动电压源以串联的方式接入,考虑 PLL 动态影响,将单一频率的信号作为每次扰动的注入量,并确保扰动信号的幅度适中,否则会对系统稳态测试结果造成干扰,或扰动信号不明显导致

的阻抗测量精度偏低,综合考虑,本文叠加的电压小信号幅值选取为并网点电压的3%。

3 算例分析

3.1 数据获取及模型训练

为了获取训练 PSO-XGBoost 模型所需的样本数据,本文以双馈风机并网系统为例,利用 Matlab/Simulink 软件搭建其典型结构及控制仿真模型,并通过阻抗扫描模块获取其 GCI dq 阻抗数据,随后将获取的数据进行归一化处理以便更好地服务于模型进行阻抗辨识。其中设置双馈风机有功出力步长为 10%,出力变化范围为[0, 100%],无功出力包括最大容性无功出力、无功为 0、最大感性无功出力这三种工况,结合不同的有功和无功出力情况,可得到总的工况为 33 组,在每种工况下对并网点处的 d, q 轴电压和电流数据进行采集并记录,测量出 1 Hz 至 1 000 Hz 范围内的 dq 阻抗。

利用上述样本数据对 PSO-XGBoost 模型进行训练和测试,按照 8:2 划分训练集和测试集,并设置 PSO 算法的种群数和迭代次数分别为 30 和 100,惯性因子为 0.8,第一、第二学习因子分别为 1.8 和 2。经过 PSO 算法优化得到的最优超参数如表 1 所示,PSO 算法优化迭代曲线如图 9 所示。

表 1 XGBoost 模型超参数优化结果

Tab.1 Optimal parameters of XGBoost

参数名称	参数初始值	参数寻优范围	最佳参数值
弱学习器数目 K	500	$200 \leq K \leq 1\,000$	390
树的深度 d	9	$5 \leq d \leq 10$	6
学习率 r	0.1	$0.01 \leq r \leq 0.3$	0.05
正则化系数 γ	10	$0 \leq \gamma \leq 10$	1
正则化系数 λ	8	$0 \leq \lambda \leq 10$	1




图 9 PSO 算法迭代曲线

Fig.9 Iteration curve of PSO algorithm

从图 9 中可以看出,当迭代次数达到 45 代左右时,适应度降至最低点,随着迭代次数的增加,

迭代曲线并未出现明显的变化,这说明算法已经达到了全局最优,输出的粒子位置即为 XGBoost 最优超参数,同时也说明了 PSO 算法参数设置的合理性,通过 PSO 算法对 XGBoost 超参数进行寻优,可以使其获得更好的辨识效果。

3.2 有效性验证

为了验证 PSO-XGBoost 模型的有效性,利用硬件在环测试技术通过 RT-LAB 软件构建双馈风机并网系统的半实物仿真平台,图 10 给出了该平台的示意图,随后基于小扰动法扫描获取 GCI dq 阻抗,以获取模型有效性验证所需的实际阻抗值。利用训练好的 PSO-XGBoost 模型拟合出 33 种测试工况下 GCI dq 阻抗,并计算出 33 种工况下实测值与辨识值之间的误差情况,计算结果如图 11 所示,随后画出阻抗对应的 Bode 图,由于工况数较多,本文只选取了一组工况下的阻抗获取结果进行展示,该工况对应有功出力为 100%,无功为最大容性无功出力,实测值与辨识值对比情况如图 12 所示,图中幅值误差为 0.301 dB,相角误差为 2.559°。



图 10 硬件在环仿真平台

Fig.10 Hardware-in-the-loop simulation platform




图 11 33 种工况下的阻抗辨识误差

Fig.11 Impedance identification error under 33 operating conditions

由图 11 可知,在 33 种测试工况下,利用本文所提方法获得的 GCI 阻抗值与通过小扰动法实际测量得到的阻抗值基本一致,且幅值误差不超过 0.35 dB,相角误差不超过 3°,但这些工况对应的

两种误差值差异波动较明显,原因在于各种工况下对应的 Bode 图曲线波动情况有所不同,复杂工况下对应的辨识误差固然比较大,即使存在较大的误差波动,但这些误差普遍较小,从而验证了所提方法辨识的准确性和有效性,也表明通过 Matlab/Simulink 仿真软件得到的多种工况下模型训练所需的样本数据是可靠的,并且所提方法能够为 GCI 在多种运行工况下的阻抗特性辨识提供较为精确的结果。通过图 12 可以直观看出,该组工况下的辨识值和实测值曲线拟合情况较好,两者之间紧密贴合,仅在低频阶段中高频阶段的时候出现了一定的辨识偏差,但整体误差较小,说明了通过 PSO-XGBoost 对 GCI dq 阻抗进行辨识,可以得到与实测阻抗特性最接近的值,从而验证了所提方法的有效性。




图 12 幅值和相角曲线辨识情况

Fig.12 Identification of amplitude and phase angle curves

3.3 优越性对比

为了验证所提方法的优越性,选取 XGBoost、人工神经网络(ANN)、极限学习机(extreme learning machine, ELM)、长短期记忆神经网络(long short-term memory, LSTM)与所提方法进行对比,采用辨识值与实测值之间的均方根误差 R_{MSE} 、平均绝对百分比误差 M_{APE} 进行对比说明,各个对比模型的参数参考已有文献设定,同时为了避免偶然性误差,每个模型独立进行 10 次辨识,并取平均值作为最终的辨识结果。同样地,为了方便展示,采用与 3.2 节相同的工况进行对比分析,得到

各个模型的阻抗 Bode 图幅值和相角曲线辨识情况如图 13 所示,辨识误差指标结果如表 2 所示。




图 13 多模型幅值和相角辨识曲线对比

Fig.13 Comparison of amplitude and phase identification curves for multiple models

表 2 多模型辨识结果误差对比

Tab.2 Comparison of error in identification results of multiple models

模型	R_{MSE}		M_{APE}	
	幅值	相角	幅值	相角
ANN	1.869	13.021	0.349	0.421
ELM	1.774	14.586	0.316	0.454
LSTM	1.366	5.158	0.153	0.204
XGBoost	1.574	7.532	0.177	0.226
PSO-XGBoost	0.301	2.559	0.032	0.065

通过图 13 可以直观看出,各个模型均能较好地学习到幅频曲线的变化趋势,原因在于阻抗 Bode 图对应的幅值和相角曲线波动变化幅度较小,但 ELM, ANN 辨识得到的幅值和相角曲线偏离实际曲线比较明显, LSTM 和 XGBoost 拟合性能更好,但不优于 PSO-XGBoost,综合对比,所提 PSO-XGBoost 模型能更好地学习到输入变量和输出阻抗变量间的非线性关系。

由表 2 可知, PSO-XGBoost 模型得到的幅值、相角的 R_{MSE} 和 M_{APE} 指标均保持最小,说明了所提方法可以有效地提高并网 GCI 阻抗辨识的精度,通过对比 PSO-XGBoost 和 XGBoost, 幅值的 R_{MSE} 降低了 1.273 dB, 相角的 R_{MSE} 降低了 4.973°, 幅值的 M_{APE} 和相角的 M_{APE} 分别降低了 14.5% 和 16.1%,

说明了利用PSO对XGBoost的超参数寻优,利用寻优后的XGBoost模型进行GCI阻抗辨识,其辨识效果更好。

为了确保GCI在多种运行工况下对GCI dq 阻抗的精确辨识,从而保障并网系统稳定性分析结论的正确性,通过对比4种不同模型的参数辨识误差指标,结果表明了所提PSO-XGBoost模型在阻抗辨识精度方面具有显著优势,有效验证了所提模型的优越性。

4 结论

本文提出一种基于模型和数据驱动的新能源机组GCI非线性建模和阻抗辨识方法。通过算例分析和实验验证,得到了以下结论:

1)建立新能源机组GCI非线性数学模型,可以较为准确地反映出影响GCI阻抗辨识的系统关键参数,并将其作为模型训练的输入特征,可以通过人工智能算法模型较好地构建出影响参数和GCI阻抗之间的复杂非线性关系;

2)相比XGBoost,PSO-XGBoost模型的幅值和相角的 R_{MSE} , M_{APE} 两个误差指标均有所降低,说明通过PSO对XGBoost的超参数进行寻优,可以有效提高模型对GCI阻抗辨识的精度,验证了所提方法的有效性;

3)相比于ANN,LSTM,ELM三个对比辨识模型,XGBoost模型具有更高的辨识精度,通过PSO对超参数进行优化后可以得到更好的辨识效果,验证了所提方法的优越性。

参考文献

- [1] 舒印彪,赵勇,赵良,等. “双碳”目标下我国能源电力低碳转型路径[J]. 中国电机工程学报,2023,43(5):1663-1672.
SHU Yinbiao, ZHAO Yong, ZHAO Liang, et al. Study on low carbon energy transition path toward carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2023, 43(5): 1663-1672.
- [2] 许津铭,凌子涵,程成,等. 并网逆变器非线性特性建模及稳定性研究综述[J]. 高电压技术,2024,50(1):370-385.
XU Jinming, LING Zihan, CHENG Cheng, et al. Overview on nonlinear modeling and stability analysis of grid-tied inverters[J]. High Voltage Engineering, 2024, 50(1): 370-385.
- [3] 张自强,高建勇,时翔,等. 考虑锁相环多单相光伏逆变器并联稳定性分析[J]. 电气传动,2021,51(10):23-29,44.
ZHANG Ziqiang, GAO Jianyong, SHI Xiang, et al. Stability analysis of multi-paralleled grid-connected single-phase inverters considering phase-locked loop influence[J]. Electric Drive, 2021, 51(10): 23-29, 44.
- [4] WANG R, SUN Q Y, MA D Z, et al. Line impedance cooperative stability region identification method for grid-tied inverters under weak grids[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 2856-2866.
- [5] 吴旭,王伟,肖华锋,等. 并网逆变器整体序阻抗建模方法及其稳定性分析[J]. 中国电机工程学报,2024,44(9):3645-3656.
WU Xu, WANG Wei, XIAO Huafeng, et al. Overall sequence impedance model of grid-connected inverter and its stability analysis[J]. Proceedings of the CSEE, 2024, 44(9): 3645-3656.
- [6] 张国荣,高凯,解润生,等. 考虑交直流谐波耦合的并网逆变器建模与分析[J]. 电测与仪表,2024,61(6):72-79.
ZHANG Guorong, GAO Kai, XIE Runsheng, et al. Modeling and analysis of grid-connected inverter considering AC and DC harmonic coupling[J]. Electrical Measurement & Instrumentation, 2024, 61(6): 72-79.
- [7] XU J M, ZHONG J F, KANG J H, et al. Stability analysis and robust parameter design of DC-voltage loop for three-phase grid-connected PV inverter under weak grid condition[J]. IEEE Transactions on Industrial Electronics, 2024, 71(4): 3776-3787.
- [8] 高家元,黄帅,姜飞,等. 弱电网下基于比例权重的控制环参数自适应调整并网逆变器稳定性提升方法[J]. 电工技术学报,2024,39(24):7846-7859.
GAO Jiayuan, HUANG Shuai, JIANG Fei, et al. Stability improvement method of grid-connected inverter based on proportional weight control loop parameters adaptive adjustment under weak grid[J]. Transactions of China Electrotechnical Society, 2024, 39(24): 7846-7859.
- [9] 解宝,李萍宇,苏建徽,等. 不平衡电网下并网逆变器阻抗建模及稳定性分析[J]. 高电压技术,2023,49(12):5196-5206.
XIE Bao, LI Pingyu, SU Jianhui, et al. Impedance modeling and stability analysis of grid-connected inverter under unbalanced grid[J]. High Voltage Engineering, 2023, 49(12): 5196-5206.
- [10] 吴滨源,李建文,李永刚,等. 基于知识和数据联合驱动的并网逆变器多工况阻抗获取方法[J]. 电力系统自动化,2022,46(6):83-91.
WU Binyuan, LI Jianwen, LI Yonggang, et al. Combined data-knowledge-driven impedance acquisition method for grid-connected inverter under multiple operation conditions[J]. Automation of Electric Power Systems, 2022, 46(6): 83-91.
- [11] 刘淇玉,李永刚,王月,等. 多并网逆变器系统灰箱阻抗辨识与阻抗聚合分析方法[J]. 电力自动化设备,2022,42(11):92-98,105.
LIU Qiyu, LI Yonggang, WANG Yue, et al. Grey-box impedance identification and impedance aggregation analysis method for multiple grid-connected inverter system[J]. Electric Power Automation Equipment, 2022, 42(11): 92-98, 105.
- [12] WEN B, BOROYEVICH D, BURGOS R, et al. Analysis of $D-Q$

- small-signal impedance of grid-tied inverters[J]. IEEE Transactions on Power Electronics, 2016, 31(1): 675–687.
- [13] 吴滨源, 李建文, 李永刚, 等. 并网逆变器 dq 阻抗灰箱辨识方法与应用[J]. 中国电机工程学报, 2022, 42(4): 1534–1546.
WU Binyuan, LI Jianwen, LI Yonggang, et al. Gray-box identification method of grid-connected inverters dq impedance and its applications[J]. Proceedings of the CSEE, 2022, 42(4): 1534–1546.
- [14] 吴滨源, 李建文, 李永刚, 等. 用于谐波劣化分析的并网逆变器阻抗灰箱拟合方法[J]. 电工技术学报, 2022, 37(4): 942–953.
WU Binyuan, LI Jianwen, LI Yonggang, et al. A gray-box fitting method of grid-connected inverters impedance for the analysis of harmonic degradation[J]. Transactions of China Electrotechnical Society, 2022, 37(4): 942–953.
- [15] ZHANG M F, WANG X F, YANG D S, et al. Artificial neural network based identification of multi-operating-point impedance model[J]. IEEE Transactions on Power Electronics, 2021, 36(2): 1231–1235.
- [16] 饶仪明, 吕敬, 王众, 等. 基于数据-模型融合驱动的新能源场站宽频阻抗在线辨识及稳定性评估[J]. 中国电机工程学报, 2024, 44(7): 2670–2685.
RAO Yiming, LÜ Jing, WANG Zhong, et al. Wideband impedance online identification and stability assessment of renewable power plants based on physics-informed data-driven method[J]. Proceedings of the CSEE, 2024, 44(7): 2670–2685.
- [17] 周莹坤, 谢恒, 孙华东, 等. 新能源机组低电压穿越控制参数对机端工频过电压的影响[J]. 电网技术, 2022, 46(5): 1907–1916.
ZHOU Yingkun, XIE Heng, SUN Huadong, et al. Influence of renewable energy low voltage ride-through control parameters on overvoltage[J]. Power System Technology, 2022, 46(5): 1907–1916.
- [18] WEN B, BOROEVICH D S, BURGOS R, et al. Analysis of $D-Q$ small-signal impedance of grid-tied inverters[J]. IEEE Transactions on Power Electronics, 2015, 31(1): 675–687.
- [19] ZHOU S Y, ZOU X D, ZHU D H, et al. An improved design of current controller for LCL-type grid-connected converter to reduce negative effect of PLL in weak grid[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2018, 6(2): 648–663.
- [20] CHEN T Q, GUESTIN C. XGBoost: a scalable tree boosting system[J]. ArXiv, 2016: 1603. 02754.

收稿日期: 2024-06-16

修改稿日期: 2024-08-05