

风电并网系统数字孪生及故障态势辨识

陈厚合¹, 杨 政¹, 裴 玮^{2,3}, 叶 华^{2,3}, 刘丰瑞¹

(1. 东北电力大学电气工程学院, 吉林省 吉林市 132012; 2. 中国科学院电工研究所, 北京 100190;
3. 中国科学院大学, 北京 100049)

摘要: 随着新能源渗透率迅速增长, 风电并网系统规模逐渐增大。本文借助数字孪生(DT)技术与深度学习技术实现了风电并网系统的态势精准辨识。本文基于电磁暂态程序(EMTP)所提方法构建以双馈风力发电机(DFIG)构成的风电并网系统虚拟镜像模型, 基于C++多线程并行计算策略进行风电并网系统的超实时镜像计算(MC); 并提出一种面向风电场态势辨识的注意力机制(AM)算法框架。至此, 构建了基于机理驱动与数据驱动融合的风电并网系统数字孪生(DT-WPGIS)。为评价数字孪生智能体的辨识性能, 本文相应地提出了辨识时延常数(RDC)指标。最后, 通过4个算例验证了上述方法在风电并网系统中应用的有效性与可行性。实验结果表明: 该方法将传统的离线仿真加速到了超实时高精度仿真, 将传统的事后故障分析提速到了微秒级的态势精准辨识, 为风电并网系统向数字化与智能化的升级提供了思路。

关键词: 数字孪生; 双馈风力发电机; 超实时镜像计算; 注意力机制; 态势辨识; 辨识时延常数

DOI: 10.12067/ATEEE2112053

文章编号: 1003-3076(2022)11-0043-16

中图分类号: TM343

1 引言

2019年我国提出“双碳”目标^[1], 构建以新能源为主体的新型电力系统已成为电网升级换代的必然趋势^[2]。风能是新能源的典型代表, 我国可再生能源“十四五”规划中风力发电是未来新能源发电发展的重要方向之一。而风力发电对系统稳定性依赖程度高, 缩短风电并网系统态势故障辨识时间即微秒级态势辨识是亟需研究的问题。

考虑故障态运行工况下风电与电力系统的交互影响: 一方面风电机组具有的低惯性、弱致稳性、弱抗扰性和出力随机性对电网带来扰动影响; 另一方面电网故障发生后会与风电机组交互影响引发宽频振荡, 进而威胁电网安全稳定运行^[3,4]。因此, 为解决风电并网系统故障态势快速辨识问题, 本文提出了一种风电机并网超实时高精度数字孪生(Digital Twin, DT)方法, 用以超实时模拟风电并网系统的暂动态变化。数字孪生是建模与仿真技术的综合应用^[5,6], 是一种针对实际物理对象进行实时虚拟镜

像计算, 且与实际物理对象进行实时交互的技术。文献[7]提出了用于分布式光伏发电系统故障诊断的数字孪生方法, 通过比较光伏实际测量值与嵌入式现场可编程逻辑门阵列(Field Programmable Gate Array, FPGA)数字孪生体预期值之间的残差向量, 作为故障诊断的判断条件, 进而分析系统特性, 该方法大大降低了检测时间且提高了故障敏感性, 但该方法不灵活且可移植性差。其中文献[8]通过粒子群优化算法实测数据估计未知电路参数, 而文献[9]认为数字孪生体是一种具有随机变量的实时概率仿真模型, 其将模型求解算法移植于FPGA上进行并行加速计算, 降低了电力电子功率换流器概率仿真时间并实现了换流器的实时故障诊断。文献[10]提出了用于双绕组变压器低压侧推演高压侧态势的数字孪生方法, 其精度与现场实测数据结果一致, 大大降低了高压互感器投入成本且可以识别高压侧的大多数系统故障。文献[5-10]对数字孪生在新能源接入的“双高”新型电力系统中的应用已经开展了相应的探索, 但对于风电机组及其并网系

收稿日期: 2021-12-27

基金项目: 国家自然科学基金项目(52177123, 52077028)

作者简介: 陈厚合(1978-), 男, 江苏籍, 教授, 博士, 研究方向为电力系统安全性与稳定性、电力系统优化运行;
杨 政(1998-), 男, 山西籍, 硕士研究生, 研究方向为新能源并网、电力系统数字孪生。

统的数字孪生还鲜有研究。

近年来,我国也对数字孪生技术应用到电力系统进行了探索。文献[11]描述了数字孪生在电力系统中的应用前景,并采用电力系统潮流计算算例,证明了数字孪生范畴下的数据驱动技术在数据挖掘方面的巨大潜力,并运用此方法在不依赖电力系统拓扑条件下,生成了高精度雅可比矩阵。文献[12]运用内存计算、并行计算、机器学习融合的方法,提高了电网数字孪生计算的速度,并提出新的电网实时在线分析系统软件平台,该软件为下一代秒级响应的在线分析系统提供平台支撑。文献[13,14]探讨了能源互联网中数字孪生定义,为能源互联网数字孪生的应用落地指明了方向。文献[15]分析了传统能源互联系统转型发展中的不足,指出了建设数字化、交互化的综合能源系统的要求,并围绕数字孪生技术在综合能源系统中面临的关键问题进行了详细阐述。文献[16]认为构建新型电力系统就是要推动电网向能源互联网的升级换代,提出了电力物联网体系架构和安全防御机制,研究了“端-边-管-云-智”多层级的关键技术。文献[17]提出了数字孪生技术在综合能源系统方向的应用前景,并对综合能源数字孪生在系统规划、运行、控制等方面的应用进行了展望。文献[18]讨论了数字孪生框架在电力网络分析中的应用,介绍了在线数字孪生实现方法及其突出特点。文献[19]指出鉴于国内交直流电网运行的复杂性与风险,需要新一代的实时在线动态分析系统提供决策支持,并提出了基于数字孪生的解决方案体系架构。文献[20]详细分析了现有文献中数字孪生在电力系统中应用的定义,首次明确了其基本概念,并提出了数字孪生项目成熟度评价的五个维度。文献[21]首次明确提出了数字孪生虚拟电厂定义,并设计了数字孪生虚拟电厂系统框架,该框架是一种以软件形式实现数字孪生的方法。

文献[11-21]所提的数字孪生均在电力系统层面开展电力系统稳态方式的研究,且文献多以综述类为主。另外,建立的数字孪生体精度虽比以往有一定的提高,但快速性没有得到体现且不能满足新型电力系统安全稳定运行的发展需求。目前,国内尚无将数字孪生技术应用于风电并网系统态势辨识的具体案例研究。

针对以上问题,本文提出一种风电及其并网系统的数字孪生微秒级态势辨识方法,主要从高精度、

超实时、可感知等三个方面来验证其有效性。其创新点如下:

(1)本文提出风电并网系统数字孪生(Digital Twin of Wind Power Generator Integrated System, DT-WPGIS),将全电磁暂态建模、计算与辨识的完整过程整合,进而构建数字孪生智能体,超越了传统分析与事件解决在时空上的不一致性。另外,相比传统串行计算,本文将并行计算引入全电磁暂态风电并网系统镜像计算,将计算速度提高到超实时计算。

(2)本文构建的风电机并网系统数字孪生体经过与 Simulink 输出结果对比、C++并行计算时间测试、三相短路故障微秒级定位三个算例测试,验证了数字孪生在风电并网系统故障态势辨识的可行性与有效性。

2 风电并网系统微秒级数字孪生

如图1所示,基于电磁暂态程序(Electro-Magnetic Transient Program, EMT)所提方法,对双馈风力发电机(Double-Fed Induction Generator, DFIG)的物理实体建模,构建基于 EMT 的 DFIG 全电磁暂态模型。




图1 风电并网系统数字孪生构建策略

Fig.1 Digital twin construction strategy for wind power integration system

双馈风力发电机拓扑如图2所示,图2中 V_{sabc} 为定子abc三相电压; V_{rabc} 为转子abc三相电压; L_g 、 R_g 分别为网侧换流器(Grid-Side Converter, GSC)侧滤波器的电感与电阻; ω_r 为转子角速度; T_{e_ref} 为电磁转矩的参考值; i_{dr} 、 i_{qr} 分别为转子dq轴电流; i_{dg} 、 i_{qg} 分别为GSC输出dq轴电流; i_{dr_ref} 、 i_{qr_ref} 分别为转子dq轴参考电流; i_{dg_ref} 、 i_{qg_ref} 分别为网侧dq轴参考电流; v_{dr_ref} 、 v_{qr_ref} 分别为转子dq轴参考电压; v_{dg_ref} 、 v_{qg_ref} 分别为网侧dq轴参考电压; V_{dc} 为两个换流器间的电容两端电压; V_{dc_n} 为电容两端电压基准值。

2.1 风电并网数字孪生体构建

风电并网数字孪生体所对应的系统网络采

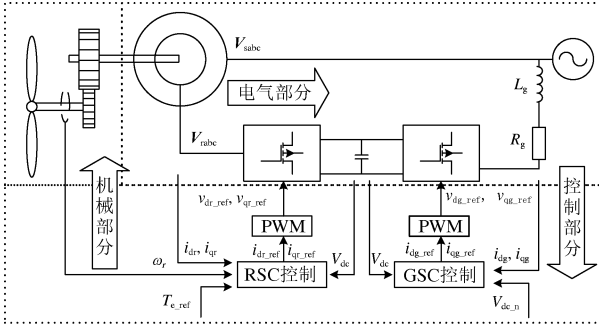


图2 双馈风力发电机结构

Fig.2 DFIG structure

用节点电压方程来描述且假设系统节点导纳矩阵已知,其对应的系统风电机设备采用状态方程来描述且假设状态矩阵已知,其构建步骤一般为以下四步:

(1)采用初始已知节点电压瞬时值与初相角的方式启动 DFIG,基于 EMTF 方法求解本时步内 DFIG 的所有状态变量。

(2)将第一步所得定子侧与 GSC 侧的电流解作为下一时步注入到电网的电流,并以电流源元件形式等效。

(3)将前一步所得的电流源元件与系统接口,基于 EMTF 方法可求解本时步内全电网的状态变量,因此可得到 DFIG 端口处的瞬时电压。

(4)将 DFIG 端口处瞬时电压输入锁相环 (Phase Locked Loop, PLL) 中计算,再将瞬时电压与 PLL 计算得出的角度回代到步骤 (1) 进行反复迭代。

2.1.1 异步发电机电气暂态模型

式(1)、式(2)用以模拟异步发电机的电气物理动态过程与 GSC 侧滤波器的电气物理动态过程。

$$\dot{\mathbf{X}}_e = \mathbf{A}_e \mathbf{X}_e + \mathbf{B}_e \mathbf{U}_e \quad (1)$$

$$T_e = \frac{3P}{2}(i_{qs}\lambda_{ds} - i_{ds}\lambda_{qs}) \quad (2)$$

式中, $\mathbf{X}_e = [i_{dg} \quad i_{qg} \quad \lambda_{ds} \quad \lambda_{qs} \quad \lambda_{dr} \quad \lambda_{qr}]^T$; $\mathbf{U}_e = [v_{dg} - v_{di} \quad v_{qg} - v_{qi} \quad v_{ds} \quad v_{qs} \quad v_{dr} \quad v_{qr}]^T$; \cdot 为微分算子; v_{ds} 、 v_{dg} 分别为定子与网侧折算到 d 轴上的电压; v_{qs} 、 v_{qg} 分别为定子与网侧折算到 q 轴上的电压; v_{dr} 、 v_{qr} 分别为转子 dq 轴上的电压; i_{ds} 、 i_{qs} 分别为定子 dq 轴上的电流; λ_{ds} 、 λ_{qs} 、 λ_{dr} 、 λ_{qr} 分别异步机定子、转子 dq 轴上的磁链; P 为极对数; T_e 为电磁转矩; v_{di} 、 v_{qi} 分别为 GSC 输出的 dq 轴上的电压; 矩阵 \mathbf{B}_e 为单位矩阵; 矩阵 \mathbf{A}_e 如下:

$$\mathbf{A}_e = \begin{bmatrix} -\frac{R_g}{L_g} & \omega & 0 & 0 & 0 & 0 \\ -\omega & -\frac{R_g}{L_g} & 0 & 0 & 0 & 0 \\ 0 & 0 & -\frac{R_s L_r}{L_s L_r - L_m^2} & \omega & \frac{R_s L_m}{L_s L_r - L_m^2} & 0 \\ 0 & 0 & -\omega & -\frac{R_s L_r}{L_s L_r - L_m^2} & 0 & \frac{R_s L_m}{L_s L_r - L_m^2} \\ 0 & 0 & \frac{R_r L_m}{L_s L_r - L_m^2} & 0 & -\frac{R_r L_s}{L_s L_r - L_m^2} & \omega - \omega_r \\ 0 & 0 & 0 & \frac{R_r L_m}{L_s L_r - L_m^2} & \omega_r - \omega & -\frac{R_r L_s}{L_s L_r - L_m^2} \end{bmatrix}$$

式中, ω 为电网角速度; R_s 、 R_r 分别为定子与转子电阻; L_r 为转子自感。

2.1.2 异步发电机机械动态模型

$$\dot{\mathbf{X}}_m = \mathbf{A}_m \mathbf{X}_m + \mathbf{B}_m \mathbf{U}_m \quad (3)$$

式中, $\mathbf{X}_m = [\omega_t \quad \omega_r \quad T_g]^T$; $\mathbf{U}_m = [T_m \quad T_e]^T$; ω_t 为传动链角速度; T_g 为齿轮扭矩; T_m 为机械转矩; 矩阵 \mathbf{A}_m 与 \mathbf{B}_m 如下:

$$\mathbf{A}_m = \begin{bmatrix} -\frac{D_t + D_{tg}}{2H_t} & \frac{D_{tg}}{2H_t} & -\frac{1}{2H_t} \\ \frac{D_{tg}}{2H_g} & -\frac{D_g + D_{tg}}{2H_g} & \frac{1}{2H_g} \\ K_{tg}\omega & -K_{tg}\omega & 0 \end{bmatrix} \quad \mathbf{B}_m = \begin{bmatrix} \frac{1}{2H_t} & 0 \\ 0 & -\frac{1}{2H_g} \\ 0 & 0 \end{bmatrix}$$

式中, H_t 和 H_g 分别为风力机与电机的惯性时间常数; D_t 和 D_g 分别为涡轮机与电机的阻尼常数; D_{tg} 为二质量块间的制动阻尼; K_{tg} 为轴刚度。

式(3)以二质量块模型模拟 DFIG 的机械传动部分。式(4)为转子运动方程。

$$\dot{\mathbf{X}}_r = \mathbf{A}_r \mathbf{X}_r + \mathbf{B}_r \mathbf{U}_m \quad (4)$$

式中, $\mathbf{X}_r = [\theta \quad \omega_m]^T$; ω_m 为转子机械速度, $\omega_m = \omega_r / P$; θ 为 PLL 输出的定子 dq 坐标系相对于电网 abc 坐标系上一时刻的角度。矩阵 \mathbf{A}_r 与 \mathbf{B}_r 如下:

$$\mathbf{A}_r = \begin{bmatrix} 0 & 1 \\ 0 & -\frac{F}{2H} \end{bmatrix} \quad \mathbf{B}_r = \begin{bmatrix} 0 & 0 \\ -\frac{1}{2H} & \frac{1}{2H} \end{bmatrix}$$

式中, F 为转子阻尼; H 为转子惯性。

DFIG 全电磁暂态模型的控制部分包括桨距角控制、传动链控制、转子侧换流器 (Rotor-Side Converter, RSC) 控制、GSC 控制、PLL 控制, 如图 3 所示, 其中 $\hat{\theta}$ 为 PLL 输出的定子 dq 坐标系相对于电网 abc 坐标系的本时刻角度; ω_s 为 PLL 输出的定子角速度; ω_0 为角速度的基准值; $1/s$ 为积分算子, PI 为

比例积分模块; v_{w-s} 为输入到 DFIG 中的风速; K 与 K_{pitch} 为传动链控制的增益; f_{pitch} 为当前风速与桨距角和输出的机械功率间的函数; S_b 为系统容量的基准值; H 为转子惯性; θ_{pitch} 为桨距角; P_{pu} 为 DFIG 输出有功的标么值; ω_{r-ref} 为转子角速度基准值; f_{abc} 为 dq 旋转坐标系向 abc 静止坐标系的变换; f_p 为 dq 旋转

坐标系向极坐标系的变换; f_p^{-1} 为 dq 旋转坐标系向极坐标系的逆变换; f_{pi} 为 PI 控制算法模块; λ_s 为异步机定子磁链; L_m 为励磁电感; L_s 为定子自感; v_{ar-c} 、 v_{br-c} 、 v_{cr-c} 为输入到转子换流器的 abc 三相电压控制值; v_{ag-c} 、 v_{bg-c} 、 v_{cg-c} 为输入到网侧换流器的 abc 三相电压控制值。其数学模型见 2.1.3 节、2.1.4 节。

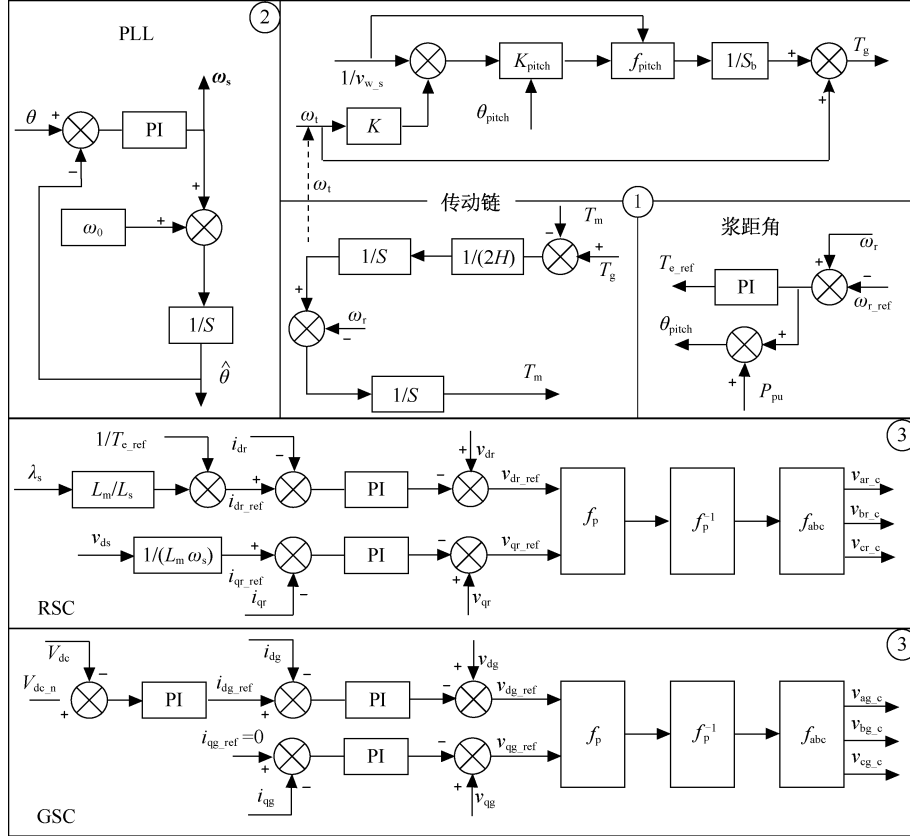


图3 DFIG 各部分控制逻辑

Fig.3 DFIG control logic for each part

2.1.3 异步发电机控制动态模型

由图3的第①部分控制可知,转子侧 d 轴电流受到电磁转矩的控制,电磁转矩又与风电机电输出的功率有关,其数学表达式为:

$$T_{e-ref} = \begin{cases} \omega_{r-ref} & P_{pu} > 0.75 \\ \omega_r + 0.67P_{pu}^2 - 1.42P_{pu} - 0.51 & P_{pu} \leq 0.75 \end{cases} \quad (5)$$

$$\begin{cases} i_{dr-ref} = \frac{T_{e-ref}}{\lambda_s \frac{L_m}{L_s}} \\ i_{qr-ref} = -\frac{v_{ds}}{\omega_s L_m} \end{cases} \quad (6)$$

$$i_{dg-ref} = f_{PI}(V_{dc-n} - V_{dc}) \quad (7)$$

$$\begin{bmatrix} v_{ar-c} \\ v_{br-c} \\ v_{cr-c} \end{bmatrix} = f_{abc} \left\{ f_p^{-1} \left[\text{diag} \begin{bmatrix} 1 & 1/V_{dc} \end{bmatrix} \cdot f_p \left(f_{PI} \begin{bmatrix} i_{dr-ref} - i_{dr} \\ i_{qr-ref} - i_{qr} \end{bmatrix} - \begin{bmatrix} v_{dr} \\ v_{qr} \end{bmatrix} \right) \right] \right\} \quad (8)$$

$$\begin{bmatrix} v_{ag_c} \\ v_{bg_c} \\ v_{cg_c} \end{bmatrix} = f_{abc} \left\{ f_p^{-1} \left[\text{diag} [1 \quad 1/V_{dc}] \cdot f_p \left(f_{PI} \begin{bmatrix} i_{dg_ref} - i_{dg} \\ i_{qg_ref} - i_{qg} \end{bmatrix} - \begin{bmatrix} v_{dg} \\ v_{qg} \end{bmatrix} \right) \right] \right\} \quad (9)$$

设置网侧 q 轴参考电流 $i_{qg_ref} = 0$ 。式(5)~式(9)为换流器的电气控制物理公式,式(5)依据输出有功功率的标幺值 P_{pu} 来计算电磁功率的期望值。

$$\begin{cases} u_{ab} = \frac{u_{ab_c} V_{dc}}{2} \\ u_{bc} = \frac{u_{bc_c} V_{dc}}{2} \end{cases} \quad (10)$$

式中, u_{ab} 、 u_{bc} 分别为换流器输出的 ab 相线电压与 bc 相线电压; u_{ab_c} 、 u_{bc_c} 为输入到换流器的 ab 相线电压控制值与 bc 相线电压控制值。

$$\frac{P_g - P_r}{V_{dc}} = C \frac{dV_{dc}}{dt} \quad (11)$$

式中, P_g 为 GSC 侧输出功率; P_r 为 RSC 侧流入功率; C 为换流器间电容值。式(11)依据功率守恒原则且忽略换流器的能量损耗来计算换流器间电容两端电压 V_{dc} 。

式(6)~式(11)模拟换流器的控制物理过程。式(10)以换流器的平均值模型来模拟换流器电气量输出的物理过程。

2.1.4 异步发电机并网 PLL 锁相环

由于锁相环需要采集 DFIG 端口处三相电压瞬时值进行计算,因此采用三相分别建模。PLL 控制如图 3 第②部分所示。

$$\theta = \frac{f_{\alpha\beta}([v_a \quad v_b \quad v_c])}{\|f_{\alpha\beta}([v_a \quad v_b \quad v_c])\|} \cdot \begin{bmatrix} \cos \hat{\theta} \\ -\sin \hat{\theta} \end{bmatrix} \quad (12)$$

$$\hat{\theta} = \int [f_{PI}(\theta) + \omega_0] dt \quad (13)$$

式中, v_a 、 v_b 、 v_c 为输入到 PLL 中的 abc 三相电压; $f_{\alpha\beta}$ 为 abc 静止坐标系向 $\alpha\beta$ 静止坐标系的变换。式(12)与式(13)模拟 DFIG 端口处的频率和 DFIG 相对于电网 abc 静止坐标系角度。

2.2 风电并网多线程并行超实时数字镜像

2.2.1 风电并网系统建模

风电并网系统异常场景下的模拟分析方法主要包括:时域仿真法、特征值法、复转矩系数分析法、阻抗分析法等^[23]。由于新能源发电系统含有大量电力电子设备,响应速度快,因此要求时域仿真法必须采用足够小的仿真步长。然而,时域仿真模型复杂,

会面临复杂的计算过程,这使得时域仿真法在使用传统串行计算架构时会花费很长的时间^[24]。因此,时域仿真利用传统串行计算架构不能满足数字孪生的实时计算甚至超实时计算的要求。而特征值法、复转矩系数分析法、阻抗分析法虽然计算速度快却不能直观地观察问题与记录数据,不能为数字孪生可感知部分的故障辨识模型提供详细的数据支撑。本文为既满足数字孪生的计算快速性要求亦满足数字孪生可感知部分充足的数据量要求,提出了基于 C++多线程超实时镜像计算技术。此技术将传统串行时域计算转为多线程并行时域计算,加快了计算速度,亦保留了时域仿真全仿真周期数据直观显示的优点,因此本文采用此技术对并网系统异常场景进行超实时全电磁暂态模拟推演。

由第 2.1 节所构建的动态模型可知,DFIG 与传统发电机模型不同,它消除了所有的磁通动态过程以反映电力电子换流器,以此来快速响应来自电气控制的更高级别的命令。因此,DFIG 并网后相当于受控时变电流源^[25]。

本文将风电接入系统并网节点作为无穷大电压源,因此,风电汇集系统的系统级建模只含有受控电流源、电压源、等值阻抗模型等,并采用三相组式变压器并以“T 型”等值电路建模。因此线路只含有基本的电感与电容的动态微分模型,即可采用 EMTP 离散化方法以及基本电压方程 $YU=I$ 求解。

2.2.2 多线程并行超实时镜像计算

如图 1 所示,对第 2.1 节建立的 DFIG 并网系统高保真数字镜像进行求解时,需考虑 CPU 串行计算能力,单台 DFIG 的计算效率难以突破, n 台 DFIG 采用矩阵求解相当于串行计算,时间能耗约为原先的 n 倍。同时,系统 abc 三相串行执行也为单相时间能耗的 3 倍。因此,传统方法不能满足数字孪生超实时推演的内在要求。

为实现风电场并网系统的高精度超实时镜像计算,本文调用 C++的 OpenMP 接口对镜像计算进行并行加速。并行计算策略如下:

并行策略一:由图 3 第③部分可见,在求解 RSC 控制与 GSC 控制时均需要本时步内 V_{dc} 的值。考虑数值稳定且不出现代数环,因此对式(11)采用后退欧拉法离散化处理,因此,求解本时步内 V_{dc} 的值需

要本时步的 P_g 与 P_r , 由于所有方程均为一阶线性微分方程, 因此求解 P_g 与 P_r 只需采用上一时步 V_{dc} 的值即可满足求解精度。虽然 GSC 与 RSC 通过 V_{dc} 连接, 但采用离散化方式求解时 V_{dc} 采用上一时步的值, 相当于 GSC 与 RSC 控制被解耦。由于本时步内数据无关联, 因此 RSC 与 GSC 控制部分的求解可以采用多线程并行计算。

并行策略二: 每台 DFIG 的参数不相同, 如定转子电阻、磁极对数、扭轴惯量与阻尼等, 但计算流程相同(如图4所示), 因此采用多线程并行计算。

并行策略三: 求解网侧系统时, 系统 abc 三相激励瞬时值不同, 因此造成了各个节点的 abc 电压与电流的瞬时值不同, 但计算流程相同(如图4所示), 因此采用多线程并行计算。

并行策略四: 求解 DFIG 时采用的是上一时刻 DFIG 并网电压从而求解本时刻注入电网电流 J 。

求解本时刻电网节点电压需要已知本时刻每个节点注入电网的电流, 而本时刻每个节点注入电网电流是由时变电流源 i_s 、电感注入节点电流 i_L 、电容注入节点电流 i_C 共同完成的, 因此在求解本时刻电网电压时, 可以将电网部分与 DFIG 部分并行求解, 先计算完成的部分进入线程等待状态, 等待另一部分计算完成后, 可以通过电压方程求出电网节点电压进行下一次计算。

基于以上三个并行点的多线程并行计算策略, 可将数字孪生体镜像计算程序拆分为三个并行计算块, 然后调用 OpenMP 接口进行并行计算。此方法可以将风电场并网系统全电磁暂态镜像计算加速到超实时, 即拥有多倍加速比, 如图4所示。

3 风电并网系统数字孪生的辨识

本文对实际 DFIG 并网系统采用节点电压方程与状态方程描述, 其中节点导纳矩阵与状态方程系

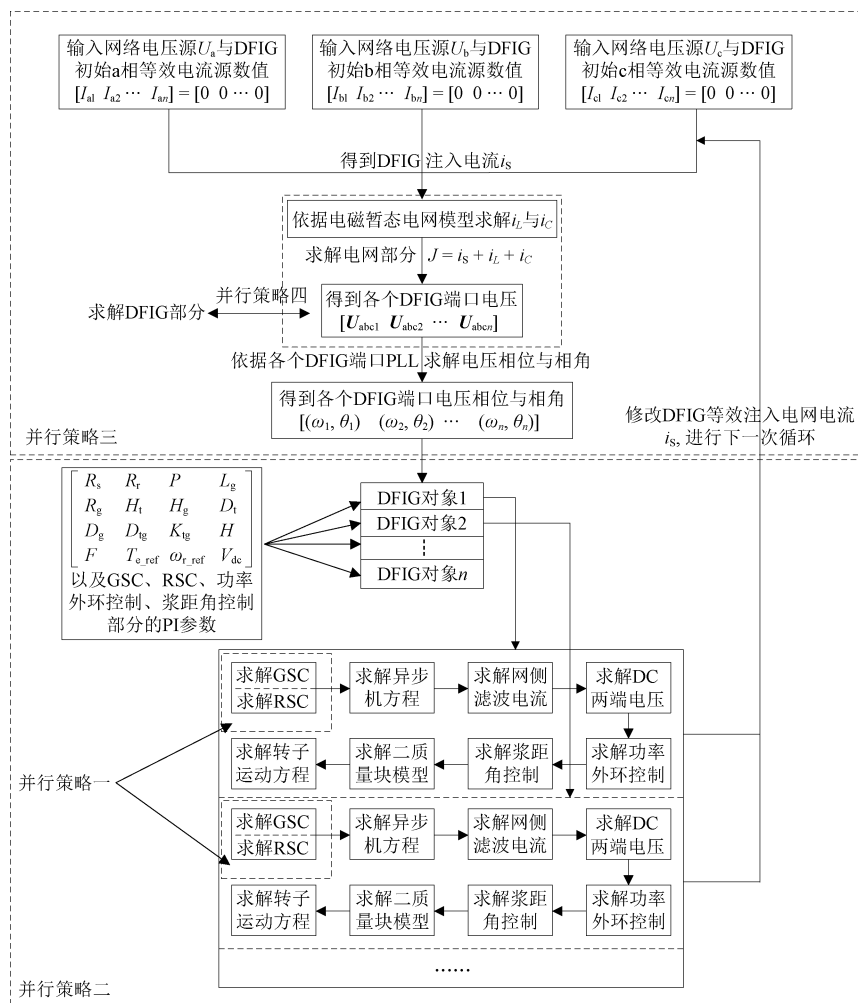


图4 C++并行计算流程

Fig.4 C++ parallel computing process

数是经常性变化的,而电流、电压、状态变量与激励可以被电源管理单元(Power Management Unit, PMU)装置测量得到。因此有文献提出针对实测数据反求节点导纳矩阵进行故障辨识,如文献[26]提出针对实测数据基于 Kron 降阶后的节点导纳矩阵对系统态势进行辨识,由于 Kron 降阶后的节点导纳矩阵不能反应中间节点(消去节点)的导纳情况,因此对于中间节点发生短路故障不能有效辨识。而本文采用的数字孪生技术并不依赖于节点导纳矩阵的变化进行识别。数字孪生体是一个理想模型,只需要提供求解初值即可运行,当输出数据与实际物理体采集数据保持在误差允许的范围内即认为数字孪生体构建正确,因此可以反应实际物理体的运行工况。当实际物理体出现故障,则实际物理体采集数据与理想数字孪生体输出数据会出现偏移。

因此针对上述现象,本文提出一种基于注意力机制算法的风电并网系统数字孪生态势辨识方法,利用第2节建立的风电并网系统的超实时高精度数字理想镜像输出的理想数据加以训练,从而达到故障态势辨识的目的。

3.1 基于注意力机制设计的辨识算法框架

为模型输入 N 种不同故障场景的 DFIG 功率数据样本,每个样本是通过第二部分数字孪生体输出的维数为 M 、长度为 L 的多元时序(Multivariate Time Series, MTS),样本集定义 k 个类别标签。对于每个样本 i ,目标是训练出一个函数,使 $F_{\theta}(MTS_{M \times L}^{(i)}) = k^{(i)}$,其中 θ 为通过训练得到的参数。

对每个故障场景下的样本,从 M 维时序中提取特征,生成低维表征。对每个类别 k ,综合考量标签为 k 的各个样本,生成一个原型表征(Prototype Representation, PR),则在预测时只需计算新样本的低维表征和原型表征的距离即可求出新样本属于第 k 类的概率。具体搭建的算法框架如图5所示, $P(C|X)$ 为样本 X 属于类别 C 的概率。

3.1.1 多元时序特征挖掘

首先,依据文献[27],针对故障定位问题提出随机维度全排列(Random Dimension Permutation, RDP),旨在挖掘不同维数据间的相关关系。随机返回某个序列的若干重排列,比如输入<123456>,要求随机采样3次,则从6!中选择3个序列返回,假设得到<134652>、<436125>、<425163>,而输入数据为前 φ 个维度,假如 φ 为2,则实际输入的就是<13>、<43>、<42>。随机采样的次数是自定义的超

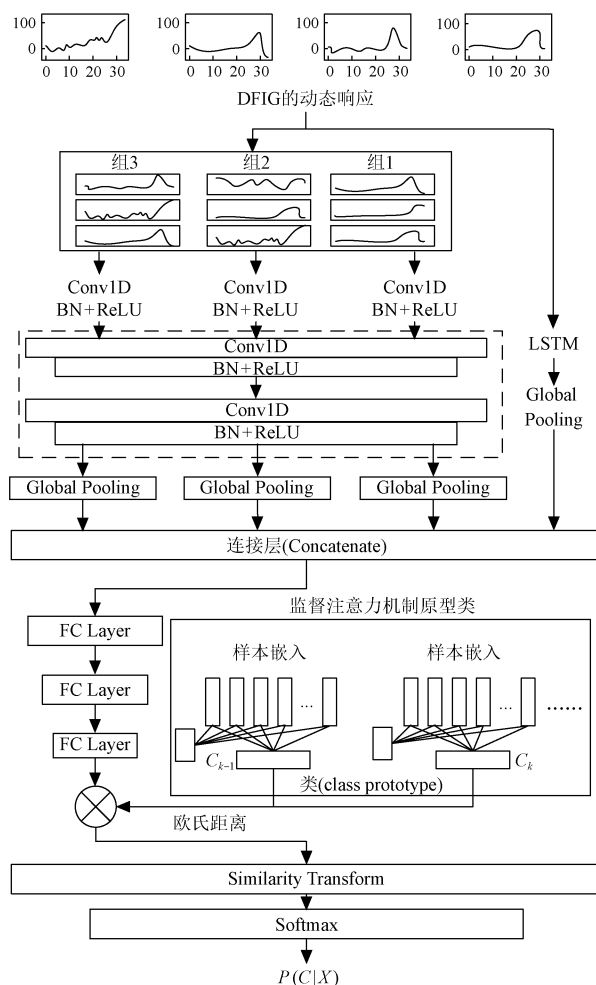


图5 注意力机制算法流程

Fig.5 Attention mechanism algorithm

参数 g , g 越大则覆盖的组合可能性越多,提取的特征越全面,但是训练时间和预测时间也会过长,因此选择合适的 g 可以平衡效率与准确性;超参数 φ 则控制相关性特征提取的细腻程度,假如 φ 为2则会考虑两纬度之间的关系,由于提取到的特征维度是固定的,因此 φ 越小则提取的特征越局部化、 φ 越大则提取的特征就越全局化(相同维度下要容纳更多元时序的特征)。为了考量 φ 的大小,定义 $\varphi = \lceil M\alpha/g \rceil$,即超参数变为放缩因子 α ,经大量实验总结 α 通常在区间[1.5,3]内。

其次,设计分层的特征提取结构对全局特征和局部特征进行提取(现有的一些神经网络结构虽然可以处理多维时序,但是当维度过高、数据过于复杂时,单一网络无法很好地提取到多层次特征)。

第一步提取全局特征:将 $M \times L$ 的多元时序输入到长短期记忆网络(Long Short-Term Memory,

LSTM)^[28],得到 LSTM 编码的 $M \times d_{\text{LSTM}}$ 的数据,其中 d_{LSTM} 为 LSTM 的隐藏层个数,再将 LSTM 的输出输入到全局池化层,得到 $1 \times d_{\text{LSTM}}$ 的嵌入向量。

第二步提取局部特征:①RDP 后得到 g 组 $\varphi \times L$ 的时序,每组分别输入 1 个 1 维卷积神经网络(Convolutional Neural Networks, CNN)中(每个 CNN 层链接 1 个 BatchNorm 层和 1 个 ReLU 激活函数),输出 g 个 $d_{\text{f1}} \times d_{\text{c1}}$ 的向量,提取每个时序的特征和组内的相关性特征。其中 d_{f1} 表示第 1 层的卷积核数,根据卷积核大小与 L 计算出 d_{c1} ;②依次输入到同一个 2 层 1 维 CNN 中(权值共享),输出 g 个 $d_{\text{f3}} \times d_{\text{c3}}$ 的向量,接着进行全局池化得到 g 个 $d_{\text{f3}} \times 1$ 的向量,拼接后得到一个 $d_{\text{f3}}g \times 1$ 的向量,以此提取组间特征。

第三步进行特征融合:将 $1 \times d_{\text{LSTM}}$ 的全局特征和 $d_{\text{f3}}g \times 1$ 的局部特征纵向拼接,得到 $(d_{\text{LSTM}} + d_{\text{f3}}g) \times 1$ 的向量,输入连续的两层全连接层,得到一个 d 维表征,其中 d 为第二个全连接层的神经元数。

3.1.2 基于注意力机制的原型学习

将上述得到的 d 维表征按照其对应的标签分组, N 个样本被组织为 $H_N = \{H_1, H_2, \dots, H_K\}$, 其中 H_k 包含 S_k 个 d 维表征,这 S_k 个样本的分类标签均为 k ,则原型表征为 $c_k = \Sigma(A_i^{(k)} h_i^{(k)})$, $1 \leq i \leq S_k$, 其中 $A_i^{(k)}$ 为通过学习得到的标签为 k 的样本中,第 i 个样本的权重, $h_i^{(k)}$ 为标签为 k 的样本中第 i 个样本的 d 维表征。参数 A 为通过注意力机制计算得到的,具体来说 $A^{(k)} = \text{softmax}[\mathbf{W}_k^T \tanh(\mathbf{V}_k \mathbf{H}_k^T)]$, 其中 \mathbf{W}_k 为 $u \times 1$ 维的参数, \mathbf{V}_k 为 $u \times d$ 维的参数, u 为注意力层的隐藏层节点数(超参数)。

3.1.3 样本 i 属于第 k 类的概率

样本 i 的表征为 h_i , 它和第 k 类的原型表征的距离为 $dis_{i,k} = D(h_i^{(k)}, c_k)$, 则 i 属于第 k 类的概率为: $P_\theta(y=k|h_i) = \exp(-dis_{i,k}) / [\Sigma_k \exp(-dis_{i,k})]$, D 为距离函数。进一步可以直接将样本 x 属于类别 k 的概率表示为 $P_\theta(y=k|x) = \exp\{-D[F_\theta(x), c_k]\} / \{\Sigma_k \exp\{-D[F_\theta(x), c_k]\}\}$ 。损失函数基于最大似然估计,尽可能减小样本 x 不属于其真实标签 y 的概率,即 $J(\Theta) = -\lg[P_\theta(y|x)]$ 。

采用数据样本对模型进行训练后,模型即拥有了故障辨识能力,而模型辨识能力的强弱,是根据所需要的测试数据样本来确定的。在同样辨识精度前提下,所需样本量越少模型辨识能力越强,本文将在准确辨识前提下所需最小样本数定义为 N_{AI} 。

3.2 孪生体辨识步长时延常数

本文采用 C++ 多线程并行计算与基于注意力机制辨识模型,针对故障态势辨识问题在辨识速度方面得到了显著提升。

步长仿真加速比 S_p 定义:在每实际物理离散时间(如 $50 \mu\text{s}$)内, C++ 数字孪生模型计算次数与 Simulink 计算次数的比值。

$$S_p = \frac{N_{\text{DT}}}{N_{\text{Simulink}}} \quad (14)$$

式中, N_{Simulink} 为每离散化步长对等实际物理时间内 Simulink 仿真次数; N_{DT} 为每离散化步长对等实际物理时间内数字孪生体完成高精度超实时镜像计算次数。

步长实际加速比 S_{real} 定义:在每实际物理离散时间(如 $50 \mu\text{s}$)内, C++ 数字孪生体模型计算次数 N_{DT} 与每时步内实际物理物体计算次数 N_{realtime} (由于微分动态方程数值解算法理论是通过离散化方式求解的,因此会存在 N_{realtime} 值)的比值。

$$S_{\text{real}} = \frac{N_{\text{DT}}}{N_{\text{realtime}}} \quad (15)$$

由于每步长的高精度超实时预测是基于初始值计算的,当初始值为正常值时,预测值即为超实时正常状态值。如果在此时刻到下一次采样时间内出现故障,那么要感知到这个故障的发生,则会在下一次采样才能采集到这个故障数据,这会带来一段延迟时间,本文将这个感知时间 T_i 定义为:孪生体辨识步长时延常数。这个常数对于采用离散化方法求解连续系统是可以经过算力加速减小的,但却是不可突破的。

$$T_i = \left(1 + \frac{N_{\text{AI}}}{N_{\text{DT}}}\right) \Delta t \quad (16)$$

由式(16)可知,随着算力的提升,在离散化算法未能突破的前提下, T_i 的最小值为 $2\Delta t$, 这个值是不可突破的。即: $T_i \geq 2\Delta t$ 。式中, Δt 为离散化连续系统后的时间间隔,其值越小则精度越高。辨识时延常数现象如图 6 所示。




图6 数字孪生辨识时延常数

Fig.6 Recognition delay constant of digital twin

4 算例分析

为验证本文所提风电并网系统数字孪生生态势微秒级精准辨识方法的有效性,分别开展模型计算精度验证、模型计算速度验证与模型辨识精度验证三个实验。本节算例 PC 机配置为:2.60 GHz 六核 Intel(R) Core(TM) i7-10750H 处理器、16.0 GB 2 667 MHz DDR4 内存、Microsoft Windows 11 操作系统, Matlab 版本为 2017b。

基于本文第 2 节所提 C++多线程并行计算的高精度超实时数字孪生体及其感知方法,构建由 16 台额定功率为 1.5 MW 的 DFIG 构成的风电并网系统数字孪生。DFIG 机端额定电压 575 V,由一机一变的单元接线方式就地升压至 25 kV,并输送到外部电网,每台 DFIG 的海拔、集电线长度、拓扑结构与故障位置示例如图 7 所示。每台 DFIG 原始参数见表 1,其中 S_T 为每台 DFIG 的额定容量; K_{p1} 、 K_{i1} 为 RSC 换流器的 PI 参数; K_{p2} 、 K_{i2} 为 GSC 换流器的 PI 参数。系统集电线路参数见表 2。




图 7 16 机风电场拓扑(折线为故障位置示例)

Fig.7 16-machine wind farm (broken line refers to fault locations)

表 1 单台双馈风力发电机组原始参数

Tab.1 Original parameters of single doubly-fed wind turbine

参数	数值	参数	数值	参数	数值
H_g/s	0.685	$S_b/(MV \cdot A)$	1.5	K_{p1}/K_{i1}	3/0.6
H_l/s	4.32	$F(pu)$	0.63	K_{p2}/K_{i2}	8/20
$D_{ig}(pu)$	1.5	$H(pu)$	0.55	$R_s(pu)$	0.018
$K_{ig}(pu)$	1.11	$S_T/(MV \cdot A)$	1.75	$L_s(pu)$	3.08
$R_r(pu)$	0.016	$L_r(pu)$	3.06	$L_m(pu)$	2.9

表 2 集电线参数

Tab.2 Collector wire parameter

参数	电阻/ (Ω/km)	电感/ (H/km)	电容/ (F/km)
数值	0.012 73	0.933 7e-3	12.74e-9

所采用风电并网系统参数为:系统频率 $f=50$ Hz,初始角速度标么值 $\omega_{pu}=1.2$,离散化时间

间隔(步长) $\Delta t=50e-6$ s,DFIG 的极对数 $P=3$ 。

设风向为 0° ,到此风场前的风速为 13 m/s,根据风速尾流效应,由本算例的风电场接线图计算每台 DFIG 的初始风速见表 3。

表 3 每台双馈风力发电机组的初始风速

Tab.3 Initial wind speed of each doubly-fed wind turbine

风机编号	风速/(m/s)	风机编号	风速/(m/s)
1	13.000 0	9	13.000 0
2	12.314 9	10	12.282 4
3	11.814 4	11	11.906 9
4	10.775 7	12	11.139 7
5	13.000 0	13	13.000 0
6	12.288 9	14	12.385 1
7	12.015 9	15	11.779 3
8	11.423 1	16	11.735 5


4.1 风电场并网系统数字孪生精度验证

Simulink 搭建的仿真模型原理图如图 3 所示。基于 2.1 节搭建的包含 2 台并列运行风电机并网系统数字孪生与 Simulink 仿真对比结果如图 8 所示,16 台风电机并网系统数字孪生功率输出结果与 Simulink 仿真对比结果如图 9 所示。本文设置仿真时间为 $10 \sim 20$ s^[29],而步长为 $50 \mu s$,因此每次模拟运行都可以获得大量数据。并网前 3 s 为并网系统的启动过程,因此输出结果会出现数值跃变以及误差较大的情况。


由于本文模拟计算步长为 $50 \mu s$,而每次模拟时间为 $10 \sim 20$ s,因此每次可以得到 $20 \sim 40$ 万组数据。由图 8、图 9 可以看出数字孪生体输出结果与 Simulink 的仿真结果误差很小,图 10 给出了数字孪生体输出结果的相对误差,在 3 s 后,相对误差均低于 1%。结果表明此数字孪生体完全达到了本文数字孪生定义的高精度镜像。本节算例表明本文构建的基于 C++的风电场并网系统数字镜像能够为数字孪生镜像并行计算研究提供模型基础以及为注意力机制辨识模型提供数据支撑。

4.2 风电场并网系统数字孪生镜像计算速度验证


将 4.1 节构建的 DFIG 并网系统的数字孪生体采用 2.2 节所提并行策略求解可以得到表 4 的数据。表 4 实验结果表明:含 4 台 DFIG 的风电场并网系统在单一时间步长 $50 \mu s$ 内,能够镜像计算 42 次,含 16 台 DFIG 的风电场并网系统在 $50 \mu s$ 内能够镜像计算 8 次。然而,Simulink 仿真计算单机系统每 $50 \mu s$ 步长需要计算时长 0.25 ms,4 机系统每步需要 1 ms,16 机系统则需要 4 ms。




(a) DC-link电压结果对比



(b) 转子转速结果对比




(c) DFIG输出功率结果对比




(d) DFIG输出电流结果对比

图8 单机数字孪生与 Simulink 仿真结果对比


Fig.8 Digital twin of single-DFIG compared with Simulink results




(a) 1~4号机组输出功率结果对比



(b) 5~8号机组输出功率结果对比



(c) 9~12号机组输出功率结果对比



(d) 13~16号机组输出功率结果对比

图9 风电场数字孪生与 Simulink 仿真结果对比

Fig.9 Digital twin of wind-farm compared with Simulink results

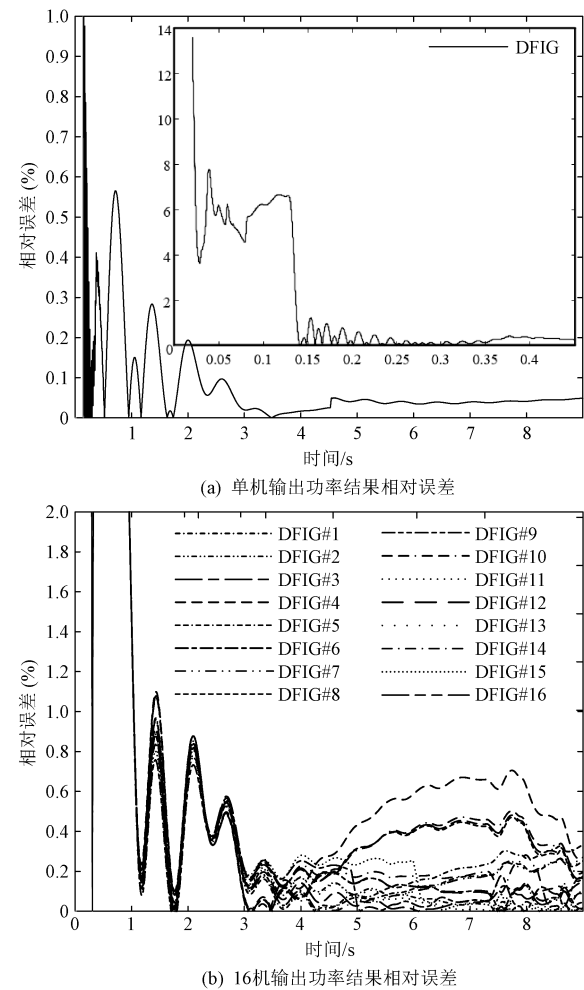


图 10 数字孪生模拟结果与 Simulink 仿真结果误差分析
Fig.10 Error analysis of digital twin simulation results and simulation results

表 4 含不同数量风电机组风电场并网系统镜像计算时间
Tab.4 Mirror calculation time of grid-connected system of wind farm with different numbers of wind generators

风机数量	监测时间/ μs	计算次数
1	50.019	136
4	50.901	42
16	51.128	8

由式(14)与式(15)可计算镜像计算加速比见表 5。

表 5 镜像计算加速比
Tab.5 Speed-up ratio of mirror calculation

风机数量	S_p	S_{real}
1	680	136
4	840	42
16	640	8

由表 5 可知,本文构建的基于 C++ 的风电场并网系统数字镜像在与 Simulink 仿真结果对比低于

1%误差前提下,计算速度比 Simulink 提高了百倍,且在多机并行时仍然能够保持超实时的镜像计算,从而充分验证所提方法的有效性。

由于模拟步长为 $50\ \mu\text{s}$,模拟时间为 $20\ \text{s}$,即每次可以模拟 40 万组数据。因此数字孪生体运行一次即可拥有足够的数据量为本文所提模型用以训练。因此,将 4.1 节与 4.2 节共同构建的高精度超实时风电场并网系统数字孪生体的模拟数据缓存到数据库中,将数据库中风电场每台 DFIG 输出的功率动态响应数据用以第 3 节所提基于注意力机制辨识模型训练。

4.3 风电场并网系统数字孪生辨识性能验证

由于电网三相短路故障对风电并网系统运行暂态稳定性破坏最严重。本算例假设 32 种三相短路故障场景,包括 16 台 DFIG 端口三相短路故障、各个风机间的集电线路发生三相短路故障等,故障场景位置与对应编号见表 6,且设置 $N_{\text{AI}} = 20$ 。进一步采用本文所提模型对采集的动态响应数据进行训练,提取每种故障情况下的响应特性,对随机设置 32 种故障下的风电场动态响应作为测试集,对模型效果进行检验,经测试得出其故障定位的准确率为 100%。

表 6 风电机并网系统故障设置
Tab.6 Wind power grid system fault setting

故障编号	故障位置	故障编号	故障位置
1/17	W1/W1~W5	9/25	W9/W9~W13
2/18	W2/W2~W6	10/26	W10/W10~W14
3/19	W3/W3~W7	11/27	W11/W11~W15
4/20	W4/W4~W8	12/28	W12/W12~W16
5/21	W5/W5~W9	13/29	W13/W13~PCC
6/22	W6/W6~W10	14/30	W14/W14~PCC
7/23	W7/W7~W11	15/31	W15/W15~PCC
8/24	W8/W8~W12	16/32	W16/W16~PCC

考虑实际工程中存在的测量误差,引入 $10 \sim 20\ \text{dB}$ 的信噪比。实验结果表明,信噪比大于 $20\ \text{dB}$ 时可以达到精准识别,而 $10\ \text{dB}$ 时准确率仍大于 87%,保持较高精度。在实际工程中,几乎不存在信噪比为 $10\ \text{dB}$ 的极端情况,可证明本文算法的抗扰性较好,辨识结果如图 11 所示。

由文献 [30],分别在本算例中使用 CNN、LSTM、堆栈自编码器(Stacked Auto-Encoder, SAE)、变分自动编码器(Variational Auto-Encoder, VAE),与本文算法做出抗扰性比较,设置 N_{AI} 为 20,各算法辨识对比结果见表 7。




图 11 不同噪声下的辨识正确率

Fig.11 Perceptual accuracy under different noise

表 7 16 机辨识精度对比

Tab.7 Perception accuracy comparison of 16-DFIG

算法	40 dB	30 dB	20 dB
CNN 误差 (%)	93.75	90.63	71.88
LSTM 误差 (%)	87.5	84.38	62.50
SAE 误差 (%)	100	90.63	78.13
VAE 误差 (%)	100	93.75	90.63
本文算法误差 (%)	100	100	100

由表 7 可知,当信噪比为 40 dB 时,本文算法和 SAE、VAE 的感知精度均为 100%,而 CNN、LSTM 均出现了感知错误。随着信噪比的降低,CNN、LSTM 和 SAE 的感知精度显著下降,抗扰性极差,而 VAE 的抗扰性表现较好,但 VAE 也出现了感知错误,只有本文算法在信噪比为 20 dB 时仍然保持 100%的感知精度,满足实际工程需求。

下面计算定位时间:

$$T_i = \left(1 + \frac{N_{AI}}{N_{DT}}\right) \Delta t = \left(1 + \frac{20}{18}\right) \times 50 \mu s = 0.106 \text{ ms}$$

辨识时间在 0.093 ~ 0.106 ms (由于物理时间 50 μs 内,数字孪生计算次数在 18~23 次)。由于本文为 51 节点系统,因此采用文献[26]理论算法需要 26 个步长来计算 Kron 降阶后的节点导纳矩阵从而辨识系统故障,对于其不能辨识到的故障,本文在不损失辨识精度的前提下仅需要时延 5 个步长后即可辨识到故障位置。本节算例表明本文构建的基于注意力机制的故障辨识模型实现了微秒级的风电并网系统故障快速辨识。

4.4 数字孪生技术在 32 机风电并网系统故障态势辨识中的应用

某 32 机风电场如图 12 所示。风电场由 32 台风机组组成,每台风电机通过 0.69/35 kV 箱式变压器

连接到集电网络,并通过 35/220 kV 变压器接入外部系统^[31]。数据集采用与 4.3 节相同的故障设置方式,即设置在端口与集电线路之间,线路长度参数见表 8。32 机模型精度验证如图 13 所示。图 14 给出了数字孪生体输出结果的相对误差。

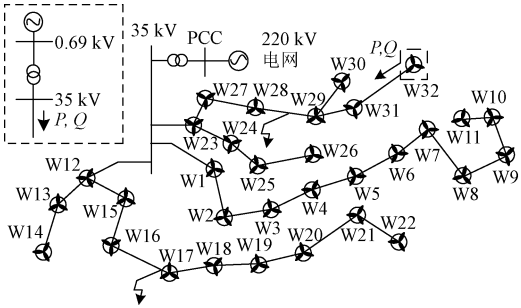



图 12 32 机风电场拓扑 (折线为故障位置示例)

Fig.12 32-machine wind farm (broken line refers to fault locations)


表 8 风电场线路长度参数

Tab.8 Parameter of wind-farm line length


线路位置	长度/m	线路位置	长度/m
PCC~W1	401	W27~W28	422
W1~W2	426	W28~W29	369
W2~W3	381	W29~W30	302
W3~W4	372	W29~W31	199
W4~W5	244	W31~W32	397
W5~W6	201	PCC~W12	482
W6~W7	381	W12~W13	321
W7~W8	366	W13~W14	322
W8~W9	320	W12~W15	323
W9~W10	277	W15~W16	324
W10~W11	197	W16~W17	325
PCC~W23	281	W17~W18	261
W23~W24	402	W18~W19	331
W24~W25	325	W19~W20	285
W25~W26	408	W20~W21	245
W23~W27	189	W21~W22	269




(a) 1~4号机组输出功率




(b) 5~8号机组输出功率




(f) 21~24号机组输出功率




(c) 9~12号机组输出功率




(g) 25~28号机组输出功率



(d) 13~16号机组输出功率



(h) 29~32号机组输出功率




(e) 17~20号机组输出功率

图 13 风电场数字孪生与 Simulink 仿真结果对比


Fig.13 Digital twin of wind-farm compared with Simulink results

采用 2.2 节所提并行策略求解可得 32 机风电并网系统仿真加速比 $S_p = 212$ 与实际加速比 $S_{real} = 2$ 。

本算例假设 64 种三相短路故障场景, 且设置 N_{AI} 为 20。采用本文所提模型对采集的动态响应数据进行训练, 提取每种故障情况下的响应特性, 对随机设置 30 种故障下的风电场动态响应作为测试集,



(a) 1~16号机组输出功率相对误差



(b) 17~32号机组输出功率相对误差

图14 数字孪生模拟结果与 Simulink 仿真结果误差分析

Fig.14 Error analysis of digital twin simulation results and Simulink simulation results

辨识结果见表9。

表9 32机辨识精度对比

Tab.9 Perception accuracy comparison of 32-DFIG

算法	40 dB	30 dB	20 dB
CNN 误差(%)	89.06	81.25	76.56
LSTM 误差(%)	81.25	79.69	68.75
SAE 误差(%)	92.19	87.5	78.13
VAE 误差(%)	98.44	93.75	85.94
本文算法误差(%)	100	98.44	96.88

下面计算定位时间:

$$T_i = \left(1 + \frac{N_{AI}}{N_{DT}}\right) \Delta t = \left(1 + \frac{20}{2}\right) \times 50 \mu s = 0.55 \text{ ms}$$

辨识时间在 0.383 ~ 0.55 ms (由于物理时间 50 μs 内, 数字孪生计算次数在 2~3 次)。

5 结论

本文提出了将数字孪生技术融入到风电并网系

统故障态势辨识的方法, 首先根据机理驱动的物理模型构建了风电并网系统数字孪生体; 其次采用传统机理驱动与数据驱动融合方案为数字孪生体加入了态势辨识功能; 最后将风电并网系统数字孪生体与 Simulink 仿真结果进行高精度、超实时、可感知三方面的验证。本文与现有故障态势辨识研究做出对比分析, 得到了实验结果。结果表明:

(1) 数字孪生技术是机理驱动与数据驱动深度融合。相比传统的离线仿真及事后态势辨识方法, 本文所提的高精度超实时数字孪生体具有明显优势, 证明数字孪生技术能够有效快速辨识风电并网系统故障位置辨识问题。

(2) 本文通过三个算例分别验证了数字孪生体的计算精度, 计算速度与故障辨识性能。在数字孪生系统正确启动后, 其计算精度误差小于 1%。计算速度在精度不丢失情况下仍然保持超实时镜像计算。考虑极端工况, 16 机风电并网孪生体的感官仍然保持 87% 以上的辨识精度。本文还验证了所提方法在含 32 台风机的风电并网系统中应用的有效性, 结果仍保持较高的辨识精度。

此项研究在超实时仿真的基础上完成了微秒级风电并网系统故障态势精准辨识, 为支撑风电并网系统的动态实时态势辨识提供了思路。

参考文献 (References):

- [1] 韩肖清, 李廷钧, 张东霞, 等 (Han Xiaoqing, Li Tingjun, Zhang Dongxia, et al.). 双碳目标下的新型电力系统规划新问题及关键技术 (New issues and key technologies of new power system planning under double carbon goals) [J]. 高电压技术 (High Voltage Engineering), 2021, 47 (9): 3036-3046.
- [2] 盛戈崂, 钱勇, 罗林根, 等 (Sheng Gehao, Qian Yong, Luo Lin'gen, et al.). 面向新型电力系统的电力设备运行维护关键技术及其应用展望 (Key technologies and application prospects for operation and maintenance of power equipment in new type power system) [J]. 高电压技术 (High Voltage Engineering), 2021, 47 (9): 3072-3084.
- [3] 孙瑶, 韩民晓, 黄永宁, 等 (Sun Yao, Han Minxiao, Huang Yongning, et al.). 考虑换流器外环特性的双馈风电场并网稳定性分析 (General impedance model with out-loop for DFIG wind farm stability analysis) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2021, 40 (2): 15-24.
- [4] 杨蕾, 周宗仁, 郭成, 等 (Yang Lei, Zhou Zongren,

- Guo Cheng, et al.). SVG 协同风电场的电网电压稳定控制策略研究 (Study on voltage stability control strategy of power grid with SVG coordinated wind farm) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2020, 39 (10): 55-64.
- [5] 陶飞, 张萌, 程江峰, 等 (Tao Fei, Zhang Meng, Cheng Jiangfeng, et al.). 数字孪生车间——一种未来车间运行新模式 (Digital twin workshop: A new paradigm for future workshop) [J]. 计算机集成制造系统 (Computer Integrated Manufacturing Systems), 2017, 23 (1): 1-9.
- [6] Tao F, Zhang H, Liu A, et al. Digital twin in industry: State-of-the-art [J]. IEEE Transactions on Industrial Informatics, 2019, 15 (4): 2405-2415.
- [7] Jain P, Poon J, Singh J P, et al. A digital twin approach for fault diagnosis in distributed photovoltaic system [J]. IEEE Transactions on Power Electronics, 2019, 35 (1): 940-956.
- [8] Peng Y Z, Zhao S, Wang H. A digital twin based estimation method for health indicators of DC-DC converters [J]. IEEE Transactions on Power Electronics, 2021, 36 (2): 2105-2118.
- [9] Milton M, Castulo A, Ginn H L, et al. Controller-embeddable probabilistic real-time digital twins for power electronic converter diagnostics [J]. IEEE Transactions on Power Electronics, 2020, 35 (9): 9850-9864.
- [10] Moutis P, Alizadeh-Mousavi O. Digital twin of distribution power transformer for real-time monitoring of medium voltage from low voltage measurements [J]. IEEE Transactions on Power Delivery, 2021, 36 (4): 1952-1963.
- [11] 贺兴, 艾芊, 朱天怡, 等 (He Xing, Ai Qian, Zhu Tianyi, et al.). 数字孪生在电力系统应用中的机遇和挑战 (Opportunities and challenges of the digital twin in power system applications) [J]. 电网技术 (Power System Technology), 2020, 44 (6): 2009-2019.
- [12] 周二专, 冯东豪, 严剑峰, 等 (Zhou Mike, Feng Donghao, Yan Jianfeng, et al.). 秒级响应电网在线分析软件平台 (A software platform for second-order responsiveness power grid online analysis) [J]. 电网技术 (Power System Technology), 2020, 44 (9): 3474-3480.
- [13] 唐文虎, 陈星宇, 钱瞳, 等 (Tang Wenhui, Chen Xingyu, Qian Tong, et al.). 面向智慧能源系统的数字孪生技术及其应用 (Technologies and applications of digital twin for developing smart energy systems) [J]. 中国工程科学 (Strategic Study of CAE), 2020, 22 (4): 74-85.
- [14] 李德仁 (Li Deren). 数字孪生城市 智慧城市建设的
新高度 [J]. 中国勘察设计 (China Engineering Consulting), 2020, (10): 13-14.
- [15] 蒲天骄, 陈盛, 赵琦, 等 (Pu Tianjiao, Chen Sheng, Zhao Qi, et al.). 能源互联网数字孪生系统框架设计及应用展望 (Framework design and application prospect for digital twins system of energy internet) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2021, 41 (6): 2012-2029.
- [16] 赵鹏, 蒲天骄, 王新迎, 等 (Zhao Peng, Pu Tianjiao, Wang Xinying, et al.). 面向能源互联网数字孪生的电力物联网关键技术及展望 (Key technologies and perspectives of power internet of things facing with digital twins of the energy internet) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2021, 42 (2): 447-458.
- [17] 王成山, 董博, 于浩, 等 (Wang Chengshan, Dong Bo, Yu Hao, et al.). 智慧城市综合能源系统数字孪生技术及应用 (Digital twin technology and its application in the integrated energy system of smart city) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2021, 41 (5): 1597-1608.
- [18] Zhou M, Yan J F, Zhou X X. Real-time online analysis of power grid [J]. Journal of Power and Energy Systems, 2020, 6 (1): 236-238.
- [19] Zhou M, Yan J F, Feng D H. Digital twin framework and its application to power grid online analysis [J]. Journal of Power and Energy Systems, 2019, 5 (3): 391-398.
- [20] 沈沉, 曹仟妮, 贾孟硕, 等 (Shen Chen, Cao Qianni, Jia Mengshuo, et al.). 电力系统数字孪生的概念、特点及应用展望 (Concepts, characteristics and prospects of application of digital twin in power system) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2021, 41 (2): 487-499.
- [21] 严兴煜, 高赐威, 陈涛, 等 (Yan Xingyu, Gao Ciwei, Chen Tao, et al.). 数字孪生虚拟电厂系统框架设计及其实践展望 (Framework design and application prospect for digital twin virtual power plant system) [J/OL]. 中国电机工程学报 (Proceedings of the CSEE), 2021, DOI: 10.13334/j.0258-8013.pcsee.212378.
- [22] Dommel H W. EMTP theory book [M]. Vancouver: Microtran Power Systems Analysis Corporation, 1992.
- [23] 马宁宁, 谢小荣, 贺静波, 等 (Ma Ningning, Xie Xiaorong, He Jingbo, et al.). 高比例新能源和电力电子设备电力系统的宽频振荡研究综述 (Review of wide-band oscillation in renewable and power electronics highly integrated power systems) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2020, 40 (15): 4720-4732.
- [24] 徐韵扬 (Xu Yunyang). 振荡频率耦合下风电机组的

- 阻抗建模与并网稳定性分析 (Impedance modeling and grid-connected stability analysis of wind turbine under oscillating frequency coupling) [D]. 杭州: 浙江大学 (Hangzhou: Zhejiang University), 2021.
- [25] Clark K, Miller N, Sanchez-Gasca J. Modeling of GE wind turbine-generators for grid studies (Version 4.5) [R]. New York: General Electric International, Inc., 2010.
- [26] Huang L B, Xin H H, Li Z Y, et al. Identification of generalized short-circuit ratio for on-line stability monitoring of wind farms [J]. IEEE Transactions on Power Systems, 2020, 35 (4): 3282-3285.
- [27] Zhang X C, Gao Y F, Lin J, et al. TapNet: Multivariate time series classification with attentional prototypical network [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (4): 6845-6852.
- [28] Liu F R, Ren M Y, Zhai J D, et al. Bitcoin transaction strategy construction based on deep reinforcement learning [A]. 2021 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering [C]. Nanchang, China, 2021. 180-183.
- [29] Cao S Q, Lin N, Dinavahi V. Mitigation of subsynchronous interaction in hybrid AC/DC grid with renewable energy using faster-than-real-time dynamic simulation [J]. IEEE Transactions on Power Systems, 2020, 36 (1): 670-679.
- [30] 和敬涵, 罗国敏, 程梦晓, 等 (He Jinghan, Luo Guomin, Cheng Mengxiao, et al.). 新一代人工智能在电力系统故障分析及定位中的研究综述 (A research review on application of artificial intelligence in power system fault analysis and location) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2020, 40 (17): 5506-5516.
- [31] 韩佳, 苗世洪, 李力行, 等 (Han Ji, Miao Shihong, Li Lixing, et al.). 基于多视角迁移学习的风场内机群划分及等值风场参数综合优化 (Wind turbines clustering in wind farm based on multi-view transfer learning and synthetic optimization of parameters in equivalent wind farm) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2020, 40 (15): 4866-4881.

Digital twin and fault situation identification of wind power integration system

CHEN Hou-he¹, YANG Zheng¹, PEI Wei^{2,3}, YE Hua^{2,3}, LIU Feng-rui¹

(1.School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 2.Institute of Electrical Engineering, Chinese Academy of Sciences, Beijing 100190, China; 3.University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: With the rapid growth of the penetration rate of new energy, the scale of wind power integration system gradually increases. In this paper, digital twin (DT) technology and deep learning technology are used to realize the precise situation identification of wind power integration system. In this paper, based on the method proposed by the electro-magnetic transient program (EMTP), a virtual image model of wind power integration system composed of double-fed induction generator (DFIG) is constructed. Mirror computing (MC) for wind power grid-connected system is carried out based on C++ multi-thread parallel computing strategy, and an algorithm framework of attention mechanism (AM) for wind farm situation identification is proposed. At this point, the digital twin of wind power generator integrated system (DT-WPGIS) based on the fusion of mechanism drive and data drive is constructed. In order to evaluate the recognition performance of digital twin agent, a recognition delay constant (RDC) is proposed. Finally, the effectiveness and feasibility of the proposed method in wind power integration system are verified by four numerical examples. The experimental results show that this method accelerates the traditional off-line simulation to faster than real time and high-precision simulation, and accelerates the traditional post-fault analysis to micro-second precise situation identification, which provides a new idea for the digital and intelligent upgrade of wind power integration system.

Key words: digital twin; double-fed induction generator; mirror computing of faster than real time; attention mechanism; situation awareness; recognition delay constant