

12-21-2022

Low Voltage Ride-through Modeling for Wind Turbines Based on Neural ODEs

Qiping Lai

Department of Electrical Engineering, Tsinghua University, Beijing 100084, China;
lqp22@mails.tsinghua.edu.cn

Tannan Xiao

Department of Electrical Engineering, Tsinghua University, Beijing 100084, China;

Dongsheng Li

Department of Electrical Engineering, Tsinghua University, Beijing 100084, China;

Chen Shen

Department of Electrical Engineering, Tsinghua University, Beijing 100084, China;
shenchen@mail.tsinghua.edu.cn

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Low Voltage Ride-through Modeling for Wind Turbines Based on Neural ODEs

Abstract

Abstract: Considering the difficulty of equivalent modeling of low voltage ride-through(LVRT) characteristics of a wind farm, a *neural ordinary differential equation(ODE)-based wind farm LVRT modeling methodis proposed*. The input of the model is the voltage and wind speed of each wind turbine at the grid connection point of wind farm, and the output is the current at the grid connection point. The model can better characterize the strong nonlinear switching process and describe LVRT characteristics of wind farms under different wind speed scenarios. A simulation example of a wind farm including three doubly-fed induction generators(DFIGs) is established on CloudPSS simulation platform to test the proposed method. The test results verify the generalization ability and effectiveness of Neural ODEs model.

Keywords

DFIGs(doubly-fed induction generators), CloudPSS simulation, LVRT(low voltage ride-through) characteristics, Neural ODEs(ordinary differential equation), data-driven modeling

Recommended Citation

Qiping Lai, Tannan Xiao, Dongsheng Li, Chen Shen. Low Voltage Ride-through Modeling for Wind Turbines Based on Neural ODEs[J]. Journal of System Simulation, 2022, 34(12): 2546-2556.

基于微分神经网络的风电机群低电压穿越特性建模

赖启平, 肖谭南, 李东晟, 沈沉*

(清华大学 电机工程与应用电子技术系, 北京 100084)

摘要: 针对目前缺少分析风电机群低电压穿越特性高效建模方法的问题, 提出了一种基于微分神经网络的风电机群低电压穿越特性建模方法。模型输入为风电场并网点电压与各台风机风速, 输出为并网点电流。该模型能够较好地表征其强非线性切换过程, 刻画风电场不同风速分布场景下风电机群的低电压穿越特性。在CloudPSS云仿真平台上建立了包含3台双馈风力发电机的风电机群仿真算例, 对所提方法进行测试, 测试结果验证了微分神经网络模型的泛化能力与有效性。

关键词: 双馈风力发电机; CloudPSS建模仿真; 低电压穿越特性; 微分神经网络; 数据驱动建模

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2022)12-2546-11

DOI: 10.16182/j.issn1004731x.joss.22-FZ0928

Low Voltage Ride-through Modeling for Wind Turbines Based on Neural ODEs

Lai Qiping, Xiao Tannan, Li Dongsheng, Shen Chen*

(Department of Electrical Engineering, Tsinghua University, Beijing 100084, China)

Abstract: Considering the difficulty of equivalent modeling of low voltage ride-through(LVRT) characteristics of a wind farm, a neural ordinary differential equation(ODE)-based wind farm LVRT modeling method is proposed. The input of the model is the voltage and wind speed of each wind turbine at the grid connection point of wind farm, and the output is the current at the grid connection point. The model can better characterize the strong nonlinear switching process and describe LVRT characteristics of wind farms under different wind speed scenarios. A simulation example of a wind farm including three doubly-fed induction generators(DFIGs) is established on CloudPSS simulation platform to test the proposed method. The test results verify the generalization ability and effectiveness of Neural ODEs model.

Keywords: DFIGs(doubly-fed induction generators); CloudPSS simulation; LVRT(low voltage ride-through) characteristics; Neural ODEs(ordinary differential equation); data-driven modeling

引言

“双碳”目标下, 我国正全力建设以新能源为主导的新型电力系统, 风能是一种安全、清洁的可再生能源, 风电总装机容量逐年升高, 然而目前仍缺少分析风电机群低电压穿越特性的高效建

模方法。此外, 风力发电机群的快速集成并网也对电力系统动态稳定性产生了负面影响^[1]。因此, 研究风电机群的低电压穿越特性建模方法, 对风电场动态建模以及新型电力系统稳定性分析具有重要意义。

在双馈风力发电机群的等值建模和低电压穿

收稿日期: 2022-08-07 修回日期: 2022-09-21

基金项目: 国家自然科学基金集成项目(U2166601); 国家自然科学基金(52107104)

第一作者: 赖启平(2000-), 男, 博士生, 研究方向为风电场等值建模与控制。E-mail: lqp22@mails.tsinghua.edu.cn

通讯作者: 沈沉(1970-), 男, 博士, 教授, 研究方向为电力系统分析与控制。E-mail: shenchen@mail.tsinghua.edu.cn

越特性研究方面, 文献[2]对现有的风电场等值模型、风速-风功率关系模型、稳态潮流计算模型、动态模型和暂态模型进行了分析总结, 指出各类模型中的相关问题和改进方向, 并提出风电场连锁动态过程建模的必要性, 但文中未给出风电场各类模型的具体建立方法。文献[3]利用 PSCAD/EMTDC 电磁暂态仿真软件建立了双馈风力发电机组并网模型, 分析其运行特性和故障暂态过程, 并进一步基于尾流效应等值划分、风机加权平均参数聚合的方法对双馈风电机组进行等值建模, 但当风电机组中所含机组增多时, 参数聚合方法较为繁琐, 等值准确度也会下降。文献[4]建立了风电机组低电压穿越全过程动态模型, 提出集电网络参数解析等值法、四机等值法和解析单机等值法2种风电机组聚合等值方法, 构建了兼顾精度和计算量的风电机组机电暂态等值模型, 但文中未涉及风电机组电磁暂态等值建模方法。文献[5]基于双馈风力发电机精确数学模型, 提出了改进的定子磁链、定子电压定向矢量控制策略, 并在 MATLAB/Simulink 环境下搭建了双馈风电系统仿真模型, 仿真对比改进前后电网电压骤降故障下风力发电机的动态过程, 验证了改进效果, 但未针对风电机组低电压穿越过程进行验证。

微分神经网络(Neural ODEs)是 Chen R. T. Q. 等^[6]提出的一族新型深度神经网络模型, 使用神经网络参数化隐藏状态的导数, 并用黑箱微分方程

求解器计算网络输出, 具有内存优化、自适应计算、连续标准化流等优点, 适用于监督学习、密度估计、时间序列建模等应用场景。文献[7]将神经网络与微分方程结合, 提出了复杂神经网络动力学的框架, 该框架作为一个连续时间的图网络框架, 结合了图网络和神经微分方程的优势, 可以在连续时间预测、离散时间预测甚至半监督分类的任务中, 都取得最优的结果。

本文基于微分神经网络, 以双馈风力发电机组(DFIGs)为例, 针对目前在风电场中不同工况机组低电压穿越特性解析复杂、缺少对风电机组高效建模手段和整体分析方法等问题, 依托 CloudPSS 云端仿真平台, 完成了双馈风力发电机组的动态建模与封装、风电机组并网低电压穿越特性仿真, 以及基于微分神经网络的风电机群低电压穿越特性学习, 得到相应神经网络模型并进行了泛化能力验证。

1 风电机组建模仿真

1.1 双馈风力发电机基础理论

双馈风力发电机以其低成本、灵活高效、解耦控制等优点成为目前风电场的主流机型之一, 故本文以双馈风力发电机为例, 研究数据驱动下的风电机组低电压穿越特性建模。

双馈风力发电系统的结构如图1所示。

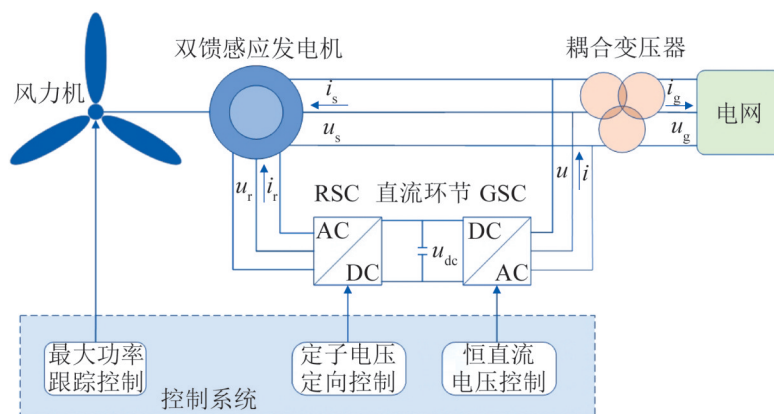


图1 双馈风力发电系统结构图

Fig. 1 Structure diagram of doubly-fed wind power generation system

1.2 双馈风力发电系统数学模型

针对 dq 旋转坐标系下感应发电机的电压方程, 采用定子电压定向矢量控制, 为简化分析, 忽略定子绕组电阻 R_s 和定子磁链瞬态过程 $d\psi_{ds}/dt$, $d\psi_{qs}/dt$, 得到:

$$\begin{cases} u_{dr} = \left(R_r + \sigma L_r \frac{d}{dt} \right) i_{dr} - \omega_{sl} \sigma L_r i_{qr} + \frac{L_m}{L_s} \frac{\omega_{sl}}{\omega_s} u_{ds} \\ u_{qr} = \left(R_r + \sigma L_r \frac{d}{dt} \right) i_{qr} + \omega_{sl} \sigma L_r i_{dr} + \frac{L_m}{L_s} \frac{\omega_{sl}}{\omega_s} u_{qs} \end{cases} \quad (1)$$

式中: σ 为感应发电机的漏磁系数; L_m 为磁化电感; L_{ls} 和 L_{lr} 分别为定子和转子漏感; ω_s 、 ω_r 和 ω_{sl} 分别为感应发电机的同步、转子和转差角速度; $L_s = L_{ls} + L_m$ 、 $L_r = L_{lr} + L_m$ 、 $\omega_{sl} = \omega_s - \omega_r$ 。

网侧变流器控制方程为

$$\begin{cases} u_d = R_g i_{dg} + L_g \frac{di_{dg}}{dt} - \omega_g L_g i_{qg} + u_{dg} \\ u_q = R_g i_{qg} + L_g \frac{di_{qg}}{dt} + \omega_g L_g i_{dg} + u_{qg} \end{cases} \quad (2)$$

式中: 下标 g 为电网侧; u_d 和 u_q 为网侧变流器输出电压 d 轴和 q 轴分量。

1.3 模型搭建与仿真

1.3.1 CloudPSS 云端仿真平台简介

CloudPSS 平台是清华四川能源互联网研究院开发的云端高性能仿真平台, 是新一代能源电力系统数字孪生应用的支撑平台, 具有减轻用户硬件负担、仿真运算快速高效、远程调用便捷、多人协作无缝对接等优点^[8-9]。

本文主要使用 CloudPSS 平台的 Simstudio 能源电力系统数字孪生仿真模型工坊, 调用其电磁暂态仿真内核对风电机组低电压穿越过程进行仿真, 并通过 CloudPSS SDK 调整风速、电压等仿真参数, 进行批量仿真和数据导出^[10-11]。

1.3.2 双馈风力发电机详细模型

本文在 CloudPSS 平台搭建了双馈风力发电机详细模型, 该机组模型由风力机模型、异步绕线式感应电机模型、电压源型变流器详细模型、转

子侧变流器控制模型、网侧变流器控制模型、输入输出接口模型等几个部分组成, 再封装为风电机组元件供并网仿真使用。

仿真模型为额定容量 2.5 MVA 的双馈风力发电机组, 经变压器并网, 电网用理想电压源模拟。设置仿真时间 0~25 s, 积分步长 50 μ s, 采样频率 10 kHz, 输入基本风速 8 m/s 进行稳定运行的仿真。

风电机组端电压、端电流、有功/无功出力等均为表征其运行状态的特征量, 当风电机组在恒定风速下工作时, 这些特征量经过短时启动暂态过程后在稳态值附近小幅波动, 实现稳定运行, 验证了该风力发电机组仿真模型的正确性和可靠性。

1.3.3 风电机组等值模型

大型风电机组通常有几十台乃至上百台风电机组接入, 若对每台风电机组均详细建模, 将极大地增加建模工作量和仿真计算量, 故应基于等值建模的思想, 将不同的风力发电机组以型号、工况(如捕获的风速)等为依据划分, 再对同类型风电机组进行等值合并, 最终得到简化的等值模型。

本文仅考虑双馈风力发电机组, 假设其均为同种型号, 将同一排的若干台风电机组等值为一台, 这样便将大型风电机组等值为几台捕获风速不同的风电机组, 便于进行建模仿真。

基于 1.3.2 小节所搭建并封装的风电机组元件模型以及等值建模思想, 搭建如图 2 所示的风电机组等值模型。该等值模型中有 3 台风力发电机组并入电网, 可以等效代表低、中、高 3 种不同风速组合下风电机组的运行情况。

1.4 风电机组低电压穿越特性仿真分析

风电机组的低电压穿越能力, 是指集中并入电网的风电机组在遭遇电网故障或扰动引起的电压跌落时, 在一定的电压跌落范围和时间间隔内, 能够不脱网持续运行, 甚至为电力系统提供无功支持以恢复原电压的能力^[12]。该能力可以大大减少风电场由于电网故障而反复解列又并网的次数, 减小对电网和风力发电设备的冲击。

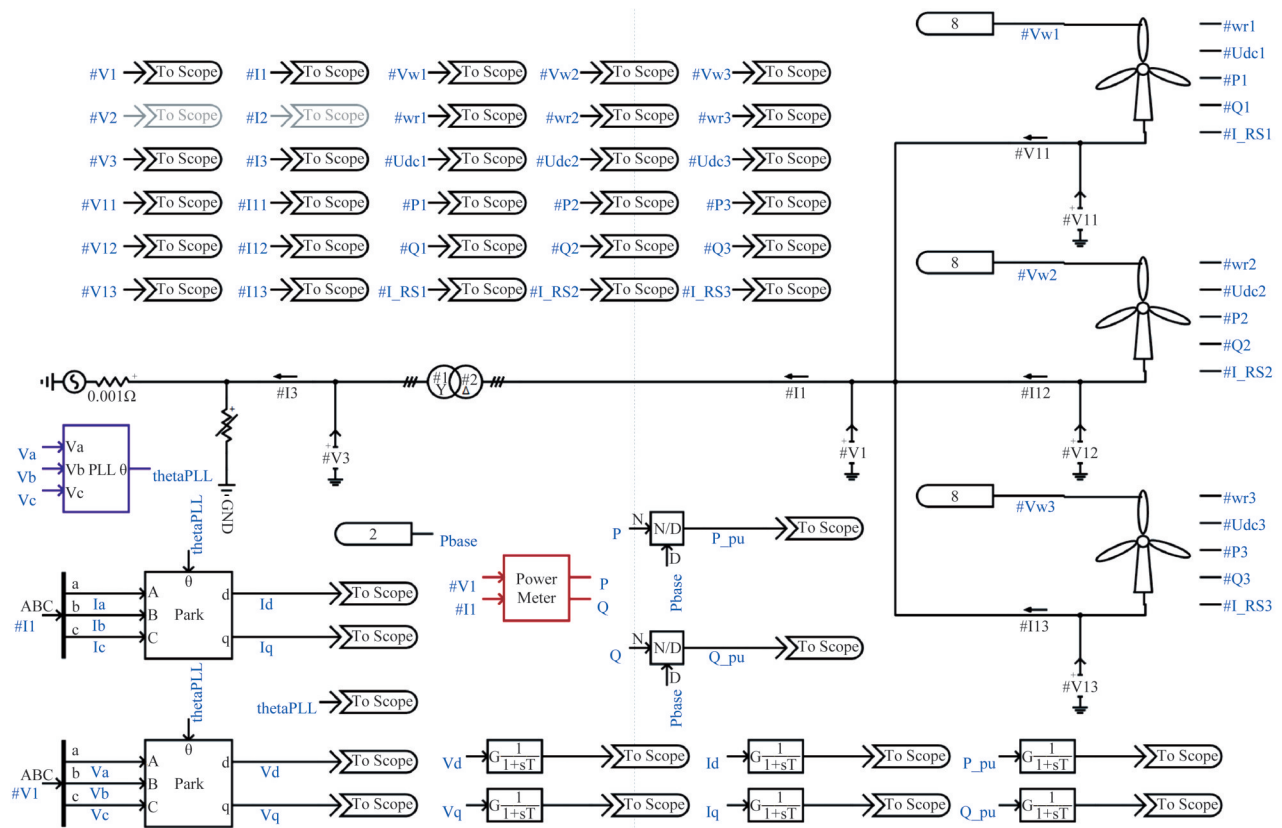


图2 风电机群等值模型
Fig. 2 Equivalent model of wind turbines

采用如图 2 所示的风电机群仿真模型, 设置仿真时间 0~25 s, 积分步长 50 μs, 采样频率 10 kHz, 并在电网侧设置第 20~20.6 s 的三相短路故障, 引起电网电压跌落, 模拟风电机群低电压穿越情况。当 3 台等值风电机组均在中风速 8 m/s 下运行时, 得到的风电机群低电压穿越特性仿真结果如图 3 所示。

由图 3(a)(b)可知, 当电网发生短时低电压故障时, 风电机群端电压迅速衰减至某一故障稳定值, 本仿真条件下约为原电压的 20%, 故障切除后迅速恢复至原电压稳态值, 略有振荡后持续稳定运行; 由于 dq 旋转坐标系的 d 轴与定子电压矢量对齐, 则端电压 q 轴分量始终保持为 0, 仅在故障切入和切除时产生短时尖峰。

由图 3(a)(b)可知, 在低电压故障切入和切除时, 由于锁相环存在时延, 电流控制产生误

差^[13], 风电机群端电流 d 轴/q 轴分量均产生短时过冲; 端电流 d 轴分量在故障期间持续增大, 故障切除后振荡衰减, 再逐渐增长至原稳定运行状态; 端电流 q 轴分量在故障切入时迅速衰减再反向增大, 提供无功支撑, 故障期间维持稳定, 故障切除后逐渐增长至原稳定运行状态。

图 3(c)(d)分别为风电机组、风电机群有功/无功出力低电压穿越全过程。风电机群有功/无功出力为每台风电机组有功/无功出力之和; 当电网电压跌落时, 为支撑电网电压, 风电机群向电网注入无功电流增大, 发出无功功率增大, 而有功电流受到容量限制, 仅能输出少量有功功率; 经历短时暂态后, 有功/无功功率均进入故障稳态, 故障切除后则逐渐恢复至故障前稳态, 并且在切除时会产生有功/无功过冲。




图3 风电机群低电压穿越特性仿真结果

Fig. 3 Simulation results of low voltage ride-through characteristics of wind turbines

2 微分神经网络低穿特性建模

2.1 微分神经网络简介

微分神经网络是神经网络和微分方程、动力系统交叉形成的产物，即用微分方程的视角来理解神经网络，将神经网络转化为一个常微分动力系统，训练与预测归结为常微分方程求解问题，并使用黑箱微分方程求解器来计算网络参数输出。目前有许多有效和流行的深度学习框架类似于微分方程。

本文将微分神经网络应用于学习动态系统、描述复杂的连续动力学过程，即风电机群低电压穿越动力学过程及穿越特性。

2.1.1 常微分方程求解器

微分神经网络中的微分方程求解器是计算网

络输出的重要工具，考虑如下常微分方程初值问题：

$$\begin{cases} \frac{dh(t)}{dt} = g(t, h(t)) \\ h(t_0) = h_0 \end{cases} \quad (3)$$

式中： g 为 h 的导数函数。

将式(3)所示的微分形式方程表示为积分形式：

$$h(t) = h(0) + \int_0^t dt' g(t', h(t')) \quad (4)$$

为便于编程计算，对式(4)所示的积分形式方程进行离散化近似处理，即将时间步离散化，得到：

$$h(N\Delta t) = h(0) + \Delta t \sum_{k=0}^{N-1} g(k\Delta t, h(k\Delta t)) \quad (5)$$

则递归形式为

$$h_N = h_{N-1} + \Delta t g((N-1)\Delta t, h_{N-1}) \quad (6)$$

依据式(3)~(6), 利用 Python 语言编写通用常微分方程求解器 odeint, 输入目标动态过程的导数函数、初值条件和时间步, 便可拟合该动态过程函数。

2.1.2 反向传播算法

在微分神经网络中, 传统神经网络的残差连接被替换成了常微分方程, 通过黑箱微分方程求解器求解该常微分方程, 并将输出状态代入损失函数, 再计算相应的损失函数梯度^[6]:

$$L(h(t_1)) = L\left(h(t_0) + \int_{t_0}^{t_1} f(h(t), t, \theta) dt\right) = L(\text{ODESolve}(h(t_0), f, t_0, t_1, \theta)) \quad (7)$$

式中: f 为微分神经网络层导数函数; θ 为网络参数, 例如网络层的权重和偏置。

本文将常微分方程求解器视为一个黑箱, 使用伴随方法计算梯度, 为了优化损失函数 $L(h(t_1))$, 使损失值最小化, 需要计算关于网络参数 θ 的梯度 $\partial L/\partial \theta$ 。首先确定损失函数如何依赖于每一时刻的隐藏状态 $h(t)$, 即伴随状态 $a(t) = \partial L/\partial h(t)$, 使用伴随方法可以推导出其动力学方程^[6]。

伴随方法可以理解为连续的链式法则, 通过链式法则可以计算损失函数关于输入状态的梯度:

$$\frac{\partial L}{\partial h(t)} = \frac{\partial L}{\partial h(t+\varepsilon)} \frac{\partial h(t+\varepsilon)}{\partial h(t)} \quad (8)$$

式中: $L = L(h(t+\varepsilon))$ 。

由式(8)和伴随状态定义可得:

$$a(t) = a(t+\varepsilon) \frac{\partial h(t+\varepsilon)}{\partial h(t)} \quad (9)$$

微分神经网络隐藏层连续函数积分为

$$h(t+\varepsilon) = h(t) + \int_t^{t+\varepsilon} f(h(t'), t', \theta) dt' \quad (10)$$

则可以得到描述伴随状态动力学的微分方程:

$$\frac{da(t)}{dt} = \lim_{\varepsilon \rightarrow 0^+} \frac{a(t+\varepsilon) - a(t)}{\varepsilon} = -a(t) \frac{\partial f(h(t), t, \theta)}{\partial h(t)} \quad (11)$$

伴随状态的最终值 $a(t_{\text{end}})$ 是末尾隐藏层的损失函数梯度, 一般为已知量, 依据伴随状态动力学方程式(11), 使用常微分方程求解器进行反向传

播计算, 得到伴随状态初值:

$$a(t_0) = a(t_{\text{end}}) - \int_{t_{\text{end}}}^{t_0} dt' a(t') \frac{\partial f(h(t'), t')}{\partial h(t')} \quad (12)$$

则关于参数 θ 的梯度 $\partial L/\partial \theta$ 为

$$\frac{\partial L}{\partial \theta}(t_0) = \underbrace{a_{\theta}(t=t_{\text{end}})}_{=0} - \int_{t_{\text{end}}}^{t_0} dt' a(t') \frac{\partial f(h(t'), t')}{\partial \theta} \quad (13)$$

使用梯度下降法对损失函数关于网络参数 θ 的梯度进行优化训练, 使损失值最小化, 达到较好的学习效果^[14-17]。

2.2 风电机组低电压穿越特性建模

随着风力发电等可再生能源发电不断接入电网, 使得电网架构日益复杂化, 给电力系统的安全稳定运行带来了新的技术挑战。建模仿真研究新型电力系统运行特性及其稳定性的基本手段, 准确可靠的仿真依赖于精确的动态部件建模, 而新型电力系统的建模仿真面临着模型确定和模型校准的挑战, 主要体现在3个方面:

(1) 一些电力系统动态部件的物理特性仍在研究中, 没有完善的理论支撑来构建合适的模型;

(2) 出于技术机密等方面的考虑, 电力设备制造商可能不会和用户共享设备的内部构造、运行理论、仿真模型等信息;

(3) 理论推导模型不能很好地匹配实测数据, 并且缺乏将理论分析模型和数据驱动模型集成在一起的方法。

针对这些富有挑战性的问题, 可以利用实时测量或仿真结果大数据, 采用基于微分神经网络的数据驱动建模方法, 建立电力系统动态部件模型, 接入仿真分析, 用于预测电力系统的动态变化^[15]。

双馈风力发电机群低电压穿越特性微分神经网络模型中的微分方程可以描述为

$$\frac{dh(t)}{dt} = f(h(t), z, t) \quad (14)$$

式中: $h \in \mathbf{R}^D$ 为系统的状态变量; $z \in \mathbf{R}^N$ 为系统的输入变量; $f: \mathbf{R}^{D+N} \rightarrow \mathbf{R}^D$ 为由系统决定的导数函数。结合式(1)、式(2)可得:

$$\begin{cases} \frac{di_{dr}}{dt} = f_1(i_{dr}, i_{qr}, u_{dr}, u_{ds}, t) \\ \frac{di_{qr}}{dt} = f_2(i_{dr}, i_{qr}, u_{qr}, u_{qs}, t) \end{cases} \quad (15)$$

$$\begin{cases} \frac{di_{dg}}{dt} = f_3(i_{dg}, i_{qg}, u_{dg}, u_d, t) \\ \frac{di_{qg}}{dt} = f_4(i_{dg}, i_{qg}, u_{qg}, u_q, t) \end{cases} \quad (16)$$

因此，系统的状态变量有 i_{dr} 、 i_{qr} 、 u_{dr} 、 u_{qr} 、 u_{ds} 、 u_{qs} 、 i_{dg} 、 i_{qg} 、 u_{dg} 、 u_{qg} 、 u_d 、 u_q ，当双馈风力发电系统稳定运行时，各状态变量导数均为 0，故引入输入变量风速 v_w ，当 v_w 变化时能够使得状态变量发生变化，并进入暂态过程。

考虑搭建并网等效模型的需要，选取系统状态变量中的并网点电流和电压作为微分神经网络的外部变量，即输入和输出，而定转子电压、电流等状态变量则隐藏在模型内部的网络连接关系中。则该微分神经网络模型中待学习的微分方程为

$$\begin{cases} \frac{dI_d}{dt} = f_5(I_d, I_q, V_d, V_q, v_w, t) \\ \frac{dI_q}{dt} = f_6(I_d, I_q, V_d, V_q, v_w, t) \end{cases} \quad (17)$$

式中： I_d, I_q 为风电场并网点输出电流 d 轴、q 轴分量； V_d, V_q 为风电场并网点电压 d 轴、q 轴分量； v_w 为 3 台风机的风速工况。

选取 V_d, V_q, v_w 作为模型输入， I_d, I_q 作为模型输出，搭建如图 4 所示的微分神经网络连接结构，内含 2 个隐藏层，每个隐藏层均含 64 个神经元，输入层、隐藏层、输出层之间全连接，网络参数 θ ，激活函数均采用 ELU 函数。

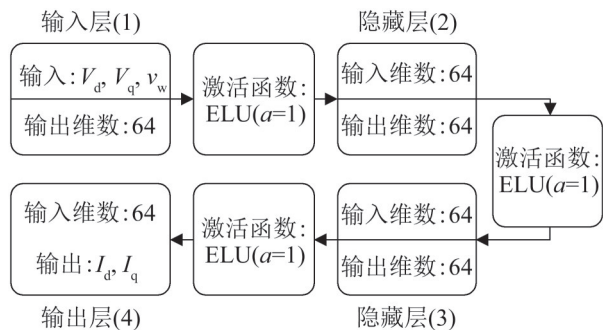


图 4 微分神经网络层连接结构图
Fig. 4 Structure diagram of neural ODEs

微分神经网络的核心思想是将微分方程求解器作为学习可微计算图的一部分，如图 5 所示。




图 5 神经网络常微分方程简略计算图
Fig. 5 Simplified calculation diagram of neural ODEs

该计算图亦可表示微分神经网络的单层连接：

$$Output = ELU \left(I_{\theta} \left(\mathbf{h}(0) + \int_0^T \mathbf{g}_{\theta}(t, \mathbf{h}(t)) dt \right) \right) \quad (18)$$

微分神经网络中的参数主要包括学习率、网络层数、隐藏层神经元个数、训练轮数、批大小、损失函数、神经元激活函数、训练样本数等，在确定了训练样本、损失函数、激活函数、优化器的选取，以及神经网络结构后，对批大小、学习率、训练轮数进行调试和选择。

首先，选取一个较大的训练轮数(如 $epoch = 800$)，以保证训练结束时的误差值已稳定在某一较低值附近，满足准确度要求，并且初步设置学习率为 Adam 优化器的常用值 0.001；其次，分别设置批大小为 1、2、4、5、8、10、20 等值进行训练，记录不同批大小下的平均误差和训练时长进行对比选择；接下来，仔细调整学习率，权衡准确率和训练时长进行选择；最后，依据每轮平均误差随轮数变化的曲线，选择满足平均误差要求的较小训练轮数，以减少训练时长。本文微分神经网络训练参数设置如表 1 所示。

表 1 微分神经网络训练参数
Table 1 Training parameters of neural ODEs

参数名称	参数选取	参数名称	参数选取
训练集样本数	200	批大小	4
学习率	0.05	训练轮数	400
网络层数	4	优化器	Adam
隐藏层神经元数	64	激活函数	ELU

参考 Github 上名为 torchdiffeq 的开源神经网络常微分方程模块包以及 Py_PSNODE 工具，利用 Python 语言编写微分神经网络。编写完成后，

将CloudPSS平台导出的风电机群低电压穿越特性批量仿真数据输入网络进行训练, 便可以得到基于微分神经网络的风电机群低电压穿越特性模型。

3 微分神经网络低穿特性模型测试

3.1 算例生成

通过CloudPSS SDK调用其电磁暂态仿真计算内核进行批量仿真, 仿真中风电场正常并网运行时并网点电压波动范围 $\pm 6\%$, 短路故障时电压跌落80%。截取并导出不同电压、风速工况下风电机群发生低电压穿越时端电压、端电流、有功/无功出力的样本数据集, 并保存为npz格式, 输入微分神经网络进行训练, 学习其低电压穿越特性。

针对不同电压、风速工况下的风电机群低电压穿越特性进行批量仿真, 得到了含300个样本的数据集, 数据集的构成如表2~3所示。

表2 110 kV标称电压批量仿真数据集
Table 2 Batch simulation data set (110 kV nominal voltage)

风速工况	样本编号	样本数量
对称	000	0~5
	111	6~13
	222	14~19
不对称	000	20~27
	001	28~35
	002	36~43
	011	44~51
	012	52~59
	022	60~67
	111	68~75
	112	76~83
	122	84~91
	222	92~99

表2~3中, 0表示5.5~7 m/s的低风速, 1表示7~9 m/s的中风速, 2表示9~10.5 m/s的高风速, 风速取值随机, 对称风速工况指3台风电机组输入风速均相同, 不对称风速工况指3台风电机组输入风速各不相同。在300个样本数据中随机抽取200个作为训练集, 用于微分神经网络训练, 100个作为测试集, 用于模型的泛化能力测试。

表3 103.4~116.6 kV随机电压批量仿真数据集
Table 3 Batch simulation data set (103.4~116.6 kV)

风速工况	样本编号	样本数量
对称	000	100~112
	111	113~126
	222	127~139
不对称	000	140~155
	001	156~171
	002	172~187
	011	188~203
	012	204~219
	022	220~235
	111	236~251
	112	252~267
	122	268~283
	222	284~299

3.2 算例测试

在同一故障类型和故障条件下, 由于风电机群端电压适配于电网电压, 不同风速工况下端电压在低电压穿越期间的故障变化曲线基本相同, 故选取风电机群端电流的故障变化曲线进行学习, 并将三相电流经派克变换转换为d轴/q轴分量输出, 便于微分神经网络学习。

利用训练集完成微分神经网络训练后, 选取测试集中的几个典型工况来展示微分神经网络对风电机群低电压穿越时端电流d轴/q轴分量故障变化曲线的动态学习测试效果, 而风电机群的有功/无功出力情况可由端电压、端电流信息计算得到。

(1) 示例工况1: 当电网电压为110 kV标称电压, 风电机群处于5.95 m/s的对称风速工况下时, 端电流d轴/q轴分量故障变化曲线及微分神经网络动态学习测试曲线如图6所示。

(2) 示例工况2: 当电网电压为110 kV标称电压, 3台风电机组分别输入6.39、9.87、10.08 m/s的不对称风速时, 测试曲线如图7所示。

(3) 示例工况3: 当电网电压为109.16 kV, 风电机群处于8.71 m/s的对称风速时, 测试曲线如图8所示。




图6 示例工况1微分神经网络低穿特性模型测试
Fig. 6 Neural ODEs based LVRT model test under working condition 1




图7 示例工况2微分神经网络低穿特性模型测试
Fig. 7 Neural ODEs based LVRT model test under working condition 2




图8 示例工况3微分神经网络低穿特性模型测试
Fig. 8 Neural ODEs based LVRT model test under working condition 3

(4) 示例工况4: 当电网电压为115.56 kV, 3台风电机组分别输入6、7.75、9.81 m/s的不对称风速时, 测试曲线如图9所示。




图9 示例工况4微分神经网络低穿特性模型测试
Fig. 9 Neural ODEs based LVRT model test under working condition 4

图6~9展示了针对本文微分神经网络泛化能力的示例测试结果, 至第400个循环时二者已基本吻合。上述4个示例测试的最终误差列于表4中。

表4 4个示例测试的最终误差
Table 4 Final error of 4 sample tests

测试工况	最终误差
示例工况1	0.000 265 704
示例工况2	0.000 185 900
示例工况3	0.000 405 468
示例工况4	0.000 229 250

测试集的平均误差和方差如表5所示。

表5 测试集的平均误差和方差
Table 5 Mean error and variance of test sets

循环数	平均误差	方差
100	0.000 265	0.000 162
200	0.000 234	0.000 211
300	0.000 139	0.000 229
400	0.000 115	0.000 218

从以上测试结果可以看出, 本文微分神经网络模型可以对电网侧发生三相短路故障造成电压跌落时, 风电机群端电流故障变化曲线取得较好的学习效果, 测试曲线吻合度高, 测试集平均误差小, 验证了该微分神经网络模型的泛化能力和有效性。

目前, 针对风电场低电压穿越特性建模的主流算法为参数聚合、解析计算等基于风电场内部详细模型机理的等值建模方法^[2-5], 而本文风电机群微分神经网络模型的建立仅需要风电场端口电压、电流量测和风速工况等数据, 适用于风电场内部模型信息缺失的场景。对该微分神经网络模型输入风电机群低电压穿越过程中并网点电压和风速工况信息, 经模型内部微分神经网络运算便可以得到端电流输出。

4 结论

针对目前风电机群低电压穿越特性解析复杂、缺少高效建模手段和整体分析方法等问题, 本文提出了一种基于微分神经网络的风电机群低电压穿越特性建模方法, 在CloudPSS云仿真平台对其低穿过程进行建模仿真, 得到端电压、端电流、有功/无功出力等状态变量数据, 以数据驱动建模, 通过学习训练得到风电机群低穿特性微分神经网络模型, 能够较好地表征低电压穿越时端电压、端电流等状态变量的强非线性切换过程。

未来将进一步研究如何提高微分神经网络的训练速度和效率, 应用于电力系统动态部件建模, 并将得到的模型接入电磁暂态仿真应用, 服务于新型电力系统仿真分析。

参考文献:

- [1] Masa A, Kkm B, Sb A, et al. Modified Rotor-Side Converter Control Design for Improving the LVRT Capability of A DFIG-Based WECS-Science Direct[J]. *Electric Power Systems Research(S0378-7796)*, 2020, 186: 106403.
- [2] 葛江北, 周明, 李庚银. 大型风电场建模综述[J]. *电力系统保护与控制*, 2013, 41(17): 146-153.
Ge Jiangbei, Zhou Ming, Li Gengyin. Review on Large-Scale Wind Farm Modeling[J]. *Power System Protection and Control*, 2013, 41(17): 146-153.
- [3] 崔峰. 双馈风力发电机及风电场建模仿真研究[D]. 北京: 华北电力大学, 2015.
Cui Feng. Research on Modeling and Simulation of Double-fed Induction Generator and Wind Farm[D]. Beijing: North China Electric Power University, 2015.
- [4] 晁璞璞. 双馈型风电场的机电暂态等值建模方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
Chao Pupu. Research on Electromechanical Transient Equivalent Modeling of DFIG-Based Wind Farms[D]. Harbin: Harbin Institute of Technology, 2018.
- [5] 胡家兵, 孙丹, 贺益康, 等. 电网电压骤降故障下双馈风力发电机建模与控制[J]. *电力系统自动化*, 2006, 30(8): 21-26.
Hu Jiabing, Sun Dan, He Yikang, et al. Modeling and Control of DFIG Wind Energy Generation System under Grid Voltage Dip[J]. *Automation of Electric Power Systems*, 2006, 30(8): 21-26.
- [6] Chen R T Q, Rubanova Y, Bettencourt J, et al. Neural Ordinary Differential Equations[J]. *Advances in Neural Information Processing Systems(S1049-5258)*, 2018, 31: 6571-6583.
- [7] Zang C, Wang F. Neural Dynamics on Complex Networks[C]//KDD'20: The 26th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: ACM, 2020: 892-902.
- [8] 沈沉, 陈颖, 黄少伟, 等. 新型电力系统仿真应用软件设计理念与发展路径[J]. *电力系统自动化*, 2022, 46(10): 75-86.
Shen Chen, Chen Ying, Huang Shaowei, et al. Design Idea and Development Path of Simulation Application Software for New Power System[J]. *Automation of Electric Power Systems*, 2022, 46(10): 75-86.
- [9] 陈颖, 高仕林, 宋炎侃, 等. 面向新型电力系统的高性能电磁暂态云仿真技术[J]. *中国电机工程学报*, 2022, 42(8): 2854-2864.
Chen Ying, Gao Shilin, Song Yankan, et al. High-performance Electromagnetic Transient Simulation for New-type Power System Based on Cloud Computing[J]. *Proceedings of the CSEE*, 2022, 42(8): 2854-2864.
- [10] 董毅峰, 王彦良, 韩佶, 等. 电力系统高效电磁暂态仿真技术综述[J]. *中国电机工程学报*, 2018, 38(8): 2213-2231, 2532.
Dong Yifeng, Wang Yanliang, Han Ji, et al. Review of High Efficiency Digital Electromagnetic Transient Simulation Technology in Power System[J]. *Proceedings of the CSEE*, 2018, 38(8): 2213-2231, 2532.
- [11] 宋炎侃, 陈颖, 黄少伟, 等. 大规模电力系统电磁暂态并行仿真算法和实现[J]. *电力建设*, 2015, 36(12): 9-15.
Song Yankan, Chen Ying, Huang Shaowei, et al. Electromagnetic Transient Parallel Simulation Algorithm and Implementation for Large-scale Power System[J]. *Electric Power Construction*, 2015, 36(12): 9-15.
- [12] 中国国家标准化管理委员会. 风力发电机组 故障电压穿越能力测试规程: GB/T 36995-2018[S]. 北京: 中国标准出版社, 2018: 1-20.
Standardization Administration of the People's Republic of China. Wind Turbines-Test Procedure of voltage Fault Ride Through Capability: GB/T 36995-2018[S]. Beijing: Standards Press of China, 2018: 1-20.
- [13] 孙大卫, 吴林林, 刘辉, 等. 弱电网直驱风机低电压穿越特性及其对机端暂态电压的影响[J]. *中国电机工程学报*, 2021, 41(14): 4777-4786.
Sun Dawei, Wu Linlin, Liu Hui, et al. Effect of the Low Voltage Ride Through Characteristics on PMSG Terminal Transient Voltage in Weakly-synchronized Grid[J]. *Proceedings of the CSEE*, 2021, 41(14): 4777-4786.
- [14] Kidger P. On Neural Differential Equations[D]. Oxford: University of Oxford, 2021.
- [15] Xiao T, Chen Y, Huang S, et al. Feasibility Study of Neural ODE and DAE Modules for Power System Dynamic Component Modeling[J/OL]. *IEEE Transactions on Power Systems(S0885-8950)* [2022-08-03]. DOI: 10.1109/TPWRS. 2022.3194570. <https://ieeexplore.ieee.org/document/9844253>.
- [16] Zhou Y, Zhang P. Neuro-Reachability of Networked Microgrids[J]. *IEEE Transactions on Power Systems (S0885-8950)*, 2022, 37(1): 142-152.
- [17] Pontryagin L S. The Mathematical Theory of Optimal Processes[M]. New York, USA: John Wiley & Sons, Inc, 1962.