

DOI: 10.19783/j.cnki.pspc.240400

基于保护电路运行状态增强识别的双馈风电场等值建模

蒋昊¹, 许立雄¹, 崔晓丹^{2,3}, 吴家龙², 李林秀¹

(1. 四川大学电气工程学院, 四川 成都 610065; 2. 南瑞集团有限公司(国网电力科学研究院有限公司), 江苏 南京 211106; 3. 电网运行风险防御技术与装备全国重点实验室, 江苏 南京 211106)

摘要: 网侧故障期间各风电机组保护电路运行状态是影响双馈风电场并网点暂态响应特性的主要因素。针对双馈风电机组保护电路运行状态难以显式数学表征的问题, 提出了基于保护电路运行状态增强识别的双馈风电场等值建模方法。首先, 根据样本对模型训练过程的影响程度构建了核心样本指数用于提取核心样本, 利用生成对抗网络(generative adversarial network, GAN)对核心样本进行学习生成增强。然后, 采用增强样本集训练深度信念网络(deep belief network, DBN)构建双馈风电机组保护电路运行状态识别模型。最后, 根据识别结果及风速对双馈风电场内机组进行分群, 计算各群等值参数最终建立双馈风电场等值模型。通过对比试验以及指标评价, 验证了样本增强对模型训练的提升效果以及运用所提方法构建的等值模型的准确性。

关键词: 直流卸荷保护; 撬棒保护; 核心样本; 生成对抗网络; 深度信念网络; 两步分群

Equivalent modeling of a DFIG farm based on enhanced recognition of protection circuit operating state

JIANG Hao¹, XU Lixiong¹, CUI Xiaodan^{2,3}, WU Jialong², LI Linxiu¹

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China; 2. Nanrui Group Co., Ltd. (State Grid Electric Power Research Institute Co., Ltd.), Nanjing 211106, China; 3. National Key Laboratory of Risk Prevention Technology and Equipment for Power Grid Operation, Nanjing 211106, China)

Abstract: During a grid side fault, the operating status of each unit protection circuit in DFIG-based wind farms is the main factor affecting the transient response characteristics of point of connection. It is difficult to express the operational status of the protection circuit of DFIG mathematically. Thus an equivalent modeling method of DFIG-based wind farms based on enhanced recognition of the protection circuit operating state is proposed. First, a core sample index is constructed to extract core samples according to the influence of samples on the model training process, and the core samples are trained and enhanced by a generative adversarial network (GAN). Then, the enhanced sample set is used to train a deep belief network (DBN) to construct the operational state recognition model of the DFIG-based wind turbine protection circuit. Finally, according to the recognition results and wind speed, the units in the DFIG-based wind farms are divided into groups, and the equivalent parameters of each group are calculated to establish the equivalent model of DFIG-based wind farms. Through comparative tests and index evaluation, the effectiveness of sample augmentation in improving model training and the accuracy of the equivalent model constructed using the proposed method are verified.

This work is supported by the Management Science and Technology Project of the Headquarters of State Grid Corporation of China (No. 5108-202218280A-2-67-XG).

Key words: chopper protection; crowbar protection; core sample; generative adversarial networks; deep belief networks; two-step clustering

0 引言

目前中国新能源发电装机规模已超越火电, 全

年新增装机超过全球一半^[1], 风电机组的大规模并网给电网特性带来了深刻改变^[2-5]。风电场模型仿真是准确分析大规模高风电占比区域电力系统运行特性的主要手段^[6-7], 但是风电场机组数量大、控制环节多的特点给详细模型的仿真分析带来了巨大的计算负担, 所以研究风场等值建模方法至关重要^[8-12]。

基金项目: 国家电网有限公司总部管理科技项目资助(5108-202218280A-2-67-XG)

双馈风电场等值建模方法按照分群指标选取的不同大致可分为两类：一类是以风速、功率、转差率等机组状态量构建相关性作为分群指标的风电场等值建模方法^[13-19]。文献[13]利用各个风电机组的风速、风向定义风机相关系数，将相关系数作为分群指标进行机群划分。文献[14]通过定义“尾流效应影响因子”来表征风电机组受其他风电机组尾流影响的程度，并以此作为分群指标进行分群。文献[15]将尾迹影响因子和叶片俯仰角的作用作为同一机群的分类指标。文献[16]开发了一种动态加权聚合等效建模方法，其中每个发电机的加权因子根据风速的威布尔分布计算。文献[17]通过匹配输出有功时序的几何模板获取机组相似度，运用属性阈值聚类算法划分机群。文献[18]基于改进 K-means 聚类算法将风速、输出功率及转差率作为分群指标对风电机组进行动态分群。文献[19]将风电机组的状态变量矩阵作为分群指标，利用聚类算法将矩阵中的数据进行分群，将同群的风电机组等值成为一台风力发电机，实现了风电场的动态等值。此类方法能够实现场内机组的稳态特性相似性表征，然而，风力发电的电磁暂态特性给这些方法在高比例新能源并网系统暂态场景仿真分析中的运用带来了挑战。

另一类双馈风电场等值建模方法是选取风电机组的暂态特征信息进行机组运行模式描述并划分机群。按照运行模式判定方法的不同，此类方法又可分为两类：解析判定^[20-22]与运用人工智能、神经网络等智能算法^[23-26]的识别方法。文献[20]通过分析风机低电压穿越下两种保护协同动作特性，解析推导了判定两种保护是否动作的指标，提出了一种双馈型风电场通用等值方法。文献[21]利用短路电流的包络线轨迹特征信息表征双馈感应发电机(doubly-fed induction generator, DFIG)在电网故障期间运行状态的差异，据此划同一运行模式的机群。文献[22]提出了一种考虑风电机组是否进入低电压穿越(low voltage ride through, LVRT)模式的改进两步风电场聚集建模方法。通过一种代表风电场内各风力发电机在同一时刻风速的风速组合模型，并采用二分搜索算法预测电网故障下风电场风力发电机是否进入 LVRT 模式实现分群。由于存在不同保护之间的交互影响、变流器与直流母线之间的交互影响，解析判定故障期间计算难度巨大，所以有研究利用智能算法识别机组运行模式。文献[23]从故障过程中的等效功率角曲线提取等效功率角，即等效瞬态内电压(equivalent transient internal voltage, ETIV)与公共连接点(point of common coupling, PCC)电压之间的夹角可以表征 DFIG 的临界特性。文献[24]将风机出

口有功功率、无功功率、电压和电流的多尺度熵(multi-scale entropy, MSE)作为运行模式特征量，运用多视角模糊 C 均值聚类与迁移学习算法划分机群。文献[25]提出一种计及 Crowbar 状态改进识别的双馈风电场等值建模方法，以 Crowbar 状态识别结果和输入风速为分群指标对场内机组进行机群划分，从而建立风电场等值模型。文献[26]设计了一种深度时空改进自编码器，并与目标聚类层联合训练。利用改进自编码器挖掘风电机组潜在特征，并以无监督的方式对机组进行划分。

丰富的样本数据是运用智能算法进行机组运行模式识别的基础。在实际工程中如何充分利用有限的样本数据，使智能算法识别结果准确反映风电机组的暂态特性成为值得关注的问题。为此，本文以双馈风电机组故障特征信息为识别输入，以保护动作状态为识别输出，提出了基于保护电路运行状态增强识别的双馈风电场等值建模方法。通过构建核心样本指数，提取样本数据中对识别模型训练过程有重要影响的核心样本，搭建了以生成对抗网络(generative adversarial network, GAN)与深度信念网络(deep belief network, DBN)为基础的增强识别模型，实现了核心样本的增强以及双馈风电机组保护动作状态的识别，并利用识别结果划分机群。

1 电网侧对称故障下双馈风电机组保护动作分析

电网发生对称故障时，双馈风电机组机端电压跌落，在转子回路产生暂态冲击电流。为了保护转子侧背靠背变流器的电力电子器件，双馈风电机组广泛采用了撬棒(crowbar)保护措施和直流卸荷(chopper)保护措施。

1.1 保护动作判据分析

双馈风电机组在转子电流超过设定阈值时投入 crowbar 保护；在直流母线电压超过设定阈值时，投入 chopper 保护。由同步速旋转坐标系下的双馈风电机组定转子电压方程和磁链方程(式(1)一式(4))可建立双馈风电机组在保护未动作时的等效电路(图 1)，由等效电路可推导直流母线电压与转子电压之间关系^[27]。转子电压可由转子电流得到，故由转子电流可得到直流母线电压，再与设定的阈值进行比较来确定是否投入 chopper 保护。因此，无论是 crowbar 保护还是 chopper 保护均可由转子电流来判断是否投入。

$$u_s = R_s i_s + j\omega_s \psi_s + \frac{d\psi_s}{dt} \quad (1)$$

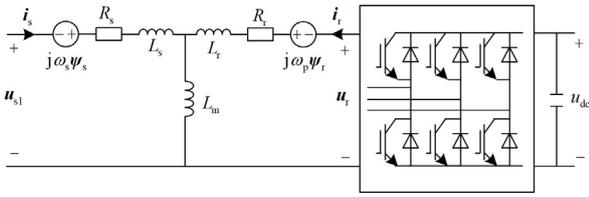


图1 不含保护环节的DFIG等效电路

Fig. 1 Equivalent circuit of DFIG without chopper and crowbar protection

$$\mathbf{u}_r = R_r \mathbf{i}_r + j\omega_p \boldsymbol{\psi}_r + \frac{d\boldsymbol{\psi}_r}{dt} \quad (2)$$

$$\boldsymbol{\psi}_s = L_s \mathbf{i}_s + L_m \mathbf{i}_r \quad (3)$$

$$\boldsymbol{\psi}_r = L_m \mathbf{i}_s + L_r \mathbf{i}_r \quad (4)$$

式中: \mathbf{u}_s 和 \mathbf{u}_r 分别为定子和转子电压矢量; $\boldsymbol{\psi}_s$ 和 $\boldsymbol{\psi}_r$ 分别为定子和转子磁链矢量; \mathbf{i}_s 和 \mathbf{i}_r 分别为定子和转子电流矢量; ω_s 和 ω_p 分别为定子(同步)角速度和转差角速度; R_s 和 R_r 、 L_s 和 L_r 分别为定子和转子的电阻、电感; L_m 为励磁电感。

由式(1)一式(4)可得转子电压为

$$\mathbf{u}_r = \sigma L_r \frac{d\mathbf{i}_r}{dt} + (R_r + j\omega_p \sigma L_r) \mathbf{i}_r + \mathbf{e} \quad (5)$$

$$\mathbf{e} = \frac{L_m}{L_s} \frac{d\boldsymbol{\psi}_s}{dt} + \frac{L_m}{L_s} j\omega_p \boldsymbol{\psi}_s \quad (6)$$

式中, σ 为漏感系数, $\sigma = 1 - L_m^2 / (L_s L_r)$ 。

双馈风电机组采用定子电压定向的矢量控制方式, 假设电流控制回路闭环带宽足够大, 变流器交流侧电压能无差地跟踪参考值, 有

$$\mathbf{u}_r = k_p (\mathbf{i}_{r_ref} - \mathbf{i}_r) + k_i \int (\mathbf{i}_{r_ref} - \mathbf{i}_r) dt + j\omega_p \sigma L_r \mathbf{i}_r \quad (7)$$

式中: k_p 、 k_i 分别为转子侧变流器电流内环 PI 控制器的比例系数和积分时间常数; \mathbf{i}_{r_ref} 为转子电流参考值。

将式(7)代入式(5), 有

$$\sigma L_r \frac{d^2 \mathbf{i}_r}{dt^2} + (R_r + k_p) \frac{d\mathbf{i}_r}{dt} + k_i \mathbf{i}_r = k_i \mathbf{i}_{r_ref} - \frac{d\mathbf{e}}{dt} \quad (8)$$

假设 $t=0$ 时刻电网侧发生对称故障, 忽略定子相位跳变, $t=0+$ 时刻双馈风电机组机端电压跌落至 \mathbf{u}_{s1} 。

$$\mathbf{u}_{s1} = (1-d)\mathbf{u}_{s0} \quad (9)$$

式中: d 为机端电压跌落系数; \mathbf{u}_{s0} 为故障前双馈风电机组机端电压。

忽略定子电阻, 根据磁链守恒定律, 由式(1)和式(9)可得

$$\boldsymbol{\psi}_s(t) = (1-d) \frac{\mathbf{u}_{s0}}{j\omega_s} + K_d \frac{\mathbf{u}_{s0}}{j\omega_s} e^{-\left(j\omega_s + \frac{1}{\tau_s}\right)t} \quad (10)$$

式中, τ_s 为转子感应电势直流分量衰减系数, 其值与转子侧工况密切相关。当转子开路时, $\tau_s = R_s / L_s$ 。而转子短路时, $\tau_s = R_s / (\sigma L_s)$ 。

将式(10)代入式(6), 有

$$\mathbf{e} = \frac{L_m \mathbf{u}_{s0}}{L_s \omega_s} (1-d) \omega_p + \frac{L_m \mathbf{u}_{s0}}{L_s \omega_s} d \left(\omega_p - \omega_s - \frac{1}{j\tau_s} \right) e^{-\left(j\omega_s + \frac{1}{\tau_s}\right)t} \quad (11)$$

根据国标 GB/T19963.1-2021 风电场接入电力系统技术规定, 双馈风电机组在故障穿越期间采用无功优先控制模式, 无功电流增量响应电压变化, 转子电流参考值可描述为

$$\begin{cases} i_{rd_ref} = \min \left(\frac{2P_{ref} L_s}{3L_m u_{s0}}, \sqrt{I_{r_max}^2 - i_{rq_ref}^2} \right) \\ i_{rq_ref} = \frac{L_s}{L_m} K_q (0.9 - u_{s1}) - \frac{u_{s0}}{\omega_s L_m} \end{cases} \quad (12)$$

式中: i_{rd_ref} 和 i_{rq_ref} 分别为转子电流参考值的 d 、 q 轴分量; u_{s0} 为故障前双馈风电机组机端电压有效值; u_{s1} 为故障后双馈风电机组机端电压有效值; I_{r_max} 为转子侧变流器允许的最大电流; K_q 为动态无功电流比例系数; P_{ref} 为有功功率参考值, 由风速确定^[20]。

$$P_{ref} = \begin{cases} k_1 (v_{wind} - v_{min}), & v_{min} \leq v_{wind} < v_1 \\ k_2 v_{wind}^3, & v_1 \leq v_{wind} < v_{II} \\ k_3 (v_{wind} - v_{rate}) + \lambda_3, & v_{II} \leq v_{wind} < v_{III} \\ P_{rate}, & v_{III} \leq v_{wind} < v_{max} \end{cases} \quad (13)$$

式中: P_{rate} 为双馈风电机组的额定功率; v_{wind} 为风速; v_{min} 、 v_{max} 和 v_{rate} 分别为双馈风电机组的切入风速、切出风速和额定风速; v_1 、 v_{II} 和 v_{III} 分别为双馈风电机组按风速划分的 4 个运行区域的分界风速; k_1 、 k_2 、 k_3 、 λ_3 为常数。

将式(13)代入式(12), 再将式(12)和式(11)代入式(8), 由 $t=0$ -(故障前)时刻双馈风电机组有功功率 P_0 和无功功率 Q_0 计算转子电流初值, 求解式(8)可得电网侧发生对称故障时的转子电流。显然, 转子电流是关于机端电压跌落系数 d 、转差角速度 ω_p 、风速 v_{wind} 、故障前有功功率 P_0 和故障前无功功率 Q_0 的表达式。

$$\mathbf{i}_r = f(d, \omega_p, v_{wind}, P_0, Q_0) \quad (14)$$

对于给定的双馈风电机组, 保护动作阈值已知。

因此，双馈风电机组在电网侧发生对称故障时，crowbar保护和chopper保护是否动作可由机端电压跌落系数 d 、转差角速度 ω_p 、风速 v_{wind} 、故障前有功率 P_0 和故障前无功功率 Q_0 共同判定。

1.2 保护动作状态分析

电网侧发生对称故障，双馈风电机组转子受到的暂态冲击相对较轻时，投入chopper保护用于应对直流母线过电压问题(如图2(a)所示)；双馈风电机组转子受到的暂态冲击较严重时，投入crowbar保护用于应对暂态转子过电流、直流母线过电压问题(如图2(b)所示)。

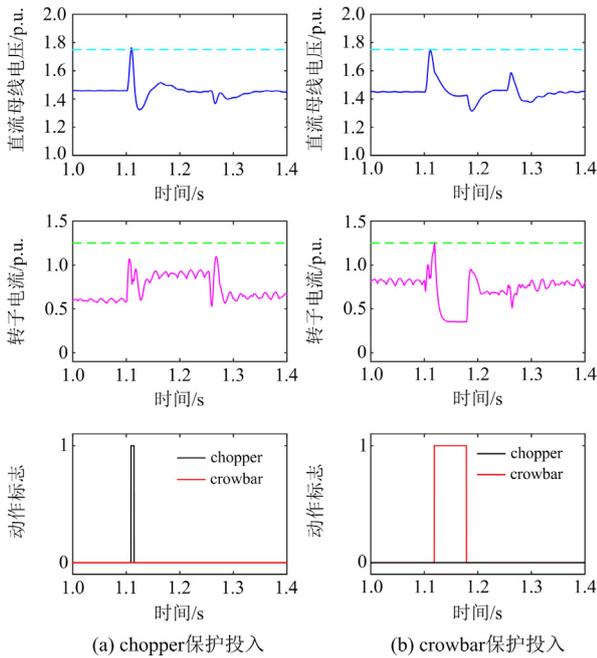


图2 DFIG 保护单独动作

Fig. 2 Chopper and crowbar of DFIG activated separately

chopper保护投入，变流器依然导通工作。直流母线电压一旦恢复chopper保护退出。chopper保护投入虽然可以抑制转子电流，但其投入的时长可能不足以将转子电流抑制在crowbar保护动作阈值以下，crowbar保护依然可能被触发，如图3(a)所示。

crowbar保护投入，变流器被短接。图4为双馈风电机组crowbar保护投入后的等效电路，此时转子电压为

$$u_r = R_{crow} i_r \quad (15)$$

式中， R_{crow} 为撬棒电阻。

对于给定的双馈风电机组，其转子电流越大，撬棒电阻上的压降越大，可能造成变流器续流二极管导通，直流电容器充电，直流电压上升超过chopper保护

的动作阈值，触发chopper保护动作，如图3(b)所示。

综上，电网侧发生对称故障时，双馈风电机组保护动作可能存在4种情形：情形1，chopper保护和crowbar保护均不动作；情形2，仅chopper保护动作；情形3，仅crowbar保护动作；情形4，chopper保护和crowbar保护均动作。

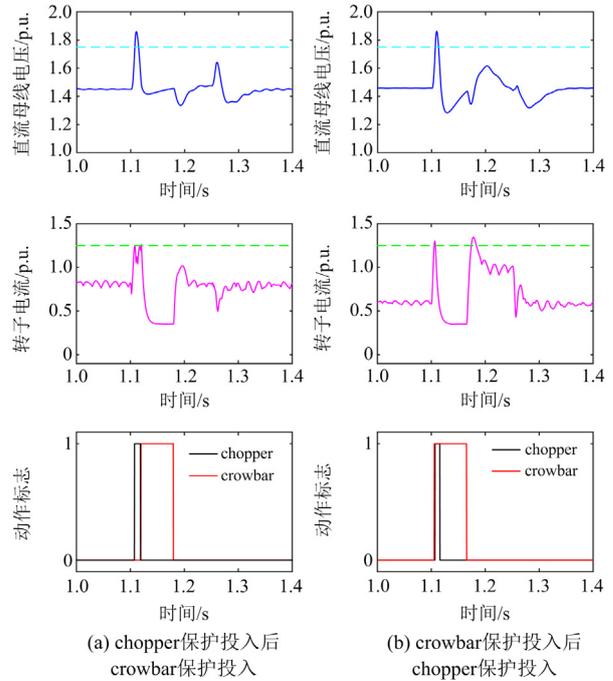


图3 DFIG 的chopper保护与crowbar保护均投入
Fig. 3 Both chopper and crowbar of DFIG activated

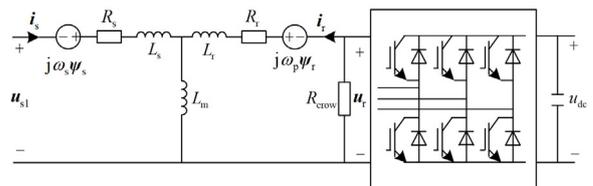


图4 crowbar保护投入后的DFIG等效电路

Fig. 4 Equivalent circuit of DFIG with crowbar activated

2 基于GAN-DBN的双馈风电机组保护动作识别

为了解决风电场参数获取不充分，解析计算复杂的难题，有研究引入了智能算法进行状态识别，但仍然存在对样本充分性依赖程度高的问题。在样本数据量少、覆盖场景不均衡时，对于各运行模式边界区域的识别准确度较低。所以有必要解决少样本情况下风机保护环节是否动作的识别问题。

高质量的样本是实现场内风机保护动作状态识别的保障，然而其获取、标注、评估均需要大量的

时间与专家知识。在此背景下, 基于核心样本学习的样本增强方法成为充分发挥有限样本作用的重要途径。

2.1 训练样本生成及核心样本提取

由第1节分析可知, 双馈风电机组 chopper 保护和 crowbar 保护可由机端电压跌落系数 d 、转差角速度 ω_p 、风速 v_{wind} 、故障前有功功率 P_0 和故障前无功功率 Q_0 共同判定。风速变化的时间尺度通常为几秒到几十秒^[28], 而故障时间通常在几十毫秒, 因此故障期间可认为风速不变。双馈风电机组发电机转子通过齿轮箱与风力机相连, 利用风力机变桨控制、发电机转子有功功率控制等调整转速, 匹配风速实现最佳风能利用^[27]。故障期间风速不变, 转子角速度围绕该风速对应的最佳转速波动。故选取机端电压跌落、故障前转子角速度 $\omega_r = \omega_s - \omega_p \cdot \omega_N$ 、风速、故障前有功功率和故障前无功功率作为特征量输入, chopper 保护与 crowbar 保护是否动作作为输出, 并构成样本。

通过仿真获取双馈风电机组在不同机端电压跌落、不同风速下的保护动作情况, 记录机端电压跌落深度、风速、故障前转子角速度、故障前有功功率、故障前无功功率, 以及对应的 chopper 保护和 crowbar 保护动作情况, 形成训练样本集。采用 min-max 方法对样本进行归一化处理以消除不同特征量之间量纲不同造成的影响。

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

式中: x_i 、 \bar{x}_i 分别为归一化前后的特征量; x_{\max} 、 x_{\min} 分别为归一化前特征量的最大值、最小值。

在将样本用于模型训练时, 模型参数的调节过程反映了模型的学习过程。绝大多数智能算法和神经网络模型都使用损失函数来度量模型的性能, 如图5所示。损失函数是模型在训练过程中优化的目标, 它衡量模型的预测输出与真实标签之间的差异或错误程度, 并据此进行模型参数的更新。因此样本集中, 对损失函数贡献较大的样本对模型训练影响较大^[29], 提取对损失函数贡献较大的样本作为核心样本。

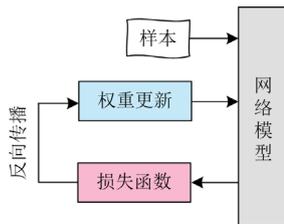


图5 模型调参示意图

Fig. 5 Diagram of model parameter tuning

模型训练过程中, 损失函数变化值表示为

$$\begin{aligned} \frac{d}{dt}l(p(w_i, x), y) &= \frac{d}{dw_i}l(p(w_i, x), y) \cdot (w_{i+1} - w_i) = \\ &= \frac{d}{dw_i}l(p(w_i, x), y) \cdot \eta \sum_{(x,y) \in X} g_i(x, y) \end{aligned} \quad (17)$$

式中: $l(p(w_i, x), y)$ 为损失函数; $p(w_i, x)$ 为分类输出环节的概率分布; w_i 为第 i 次迭代的权重; η 为常数项; $g_i(x, y)$ 为损失函数对权重的梯度; $X = (x, y)$ 为样本集。

若去除样本点 (x_j, y_j) , 其对损失函数变化的贡献值为

$$\begin{aligned} \left\| \frac{dl}{dt} - \frac{dl'}{dt} \right\| &= \left\| \eta \frac{dl}{dw_i} \sum_{(x,y) \in X} g_i(x, y) - \eta \frac{dl'}{dw_i} \sum_{(x,y) \in X-j} g_i(x, y) \right\| \leq \\ &= \eta \left\| \frac{dl}{dw_i} \right\| \cdot \|g_i(x_j, y_j)\| = k \|g_i(x_j, y_j)\| \end{aligned} \quad (18)$$

式中: $X-j$ 为去除样本点 (x_j, y_j) 后的样本集;

$\frac{dl'}{dw_i} \sum_{(x,y) \in X-j} g_i(x, y)$ 样本集 $X-j$ 的损失函数变化值; k 为常数项。

由式(18)可知, 去除样本点 (x_j, y_j) 对模型的影响可由 $\|g_i(x_j, y_j)\|$ 表示。当损失函数采用交叉熵时由式(19)近似计算, 将其定义为核心样本指数^[29] I_{csi} 。

$$I_{\text{csi}} = \|p(w_i, x) - y\| \quad (19)$$

该指标描述了每个样本对模型训练过程中参数更新的影响, 反映了样本对模型训练的重要性。

2.2 基于 GAN 的核心样本增强

GAN 网络能够生成逼真样本得益于生成器和判断器的动态博弈。生成器能够生成与真实数据接近的样本数据, 使判断器难以区分; 而判断器的作用与之对抗, 其目的在于区分真实数据与生成的数据。经过生成器与判断器反复对抗迭代 GAN 最终得到逼真的样本, 实现对原始核心样本的增强。用于核心样本学习的 GAN 训练过程如图6所示。

其对抗迭代过程的目标函数为

$$\min_G \max_D V(D, G) = E_{p_{\text{data}}(x)}[\log D(x)] + E_{p_{G(z)}}[\log(1 - D(G(z)))] \quad (20)$$

式中: $\min_G \max_D V(D, G)$ 为判断器与生成器的目标函数; $E_{p_{\text{data}}(x)}[\log D(x)]$ 表示判断器将真实数据判定为真的对数概率期望; $E_{p_{G(z)}}[\log(1 - D(G(z)))]$ 表示判断器将来自生成器的生成数据判定为真的负对数概

率期望。

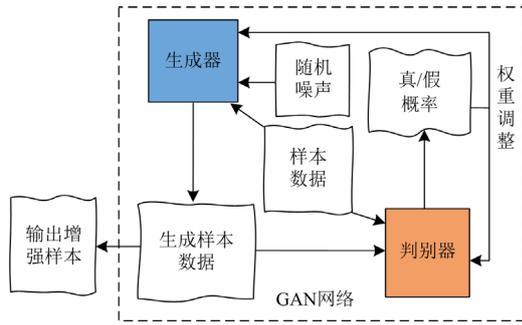


图 6 基于核心样本学习生成的 GAN 结构图
 Fig. 6 Structure diagram of GAN generated from core samples learning

2.3 基于 DBN 的双馈风电机组保护动作识别

运用本节所提样本增强方法，可解决数据获取不充分、数据存在缺陷等在实际风电场等值工作中较为常见的难题，在此基础上提出基于 DBN 网络的动作状态识别方法。DBN 作为一种深度学习模型，能够有效地处理大量数据和复杂的特征关系，从而更好地捕捉到系统的内在模式和规律。对于双馈风场这样的复杂系统，DBN 可以更好地发现隐藏在数据之间的关联关系，从而提高分类的准确性。DBN 网络架构如图 7 所示。

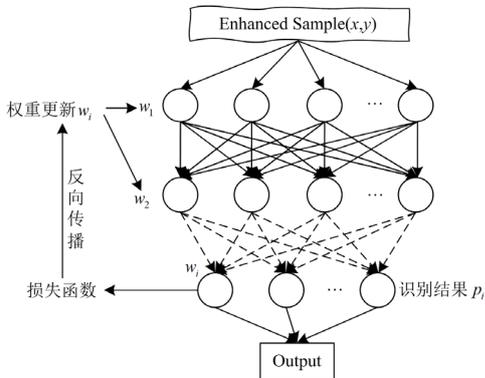


图 7 DBN 网络架构示意图
 Fig. 7 Schematic diagram of the DBN network architecture

DBN 神经网络包括输入层、多个隐含层和输出层。每个隐含层都被初始化为一个受限玻尔兹曼机 (restricted boltzmann machine, RBM)，每个 RBM 包括可见层与隐藏层，除了第一层 RBM 的可见层连接到训练集，其他各 RBM 的可见层均连接到上一层 RBM 的隐藏层，使用对比散度算法在各层 RBM 上进行训练，最大化训练数据的似然概率。

重复上述过程直到所有层的 RBM 都被训练完毕，每个 RBM 的隐含层可以被视为提取的特征。这些特征可以用作样本集的高级表示；使用 softmax

函数完成输出层中最终的模式分类任务，使用 Backpropagation 算法将输出层连接到最顶层 RBM 的隐含层，损失函数采用最小化交叉熵函数，以损失函数的梯度下降优化算法迭代权重，直至损失函数收敛或达到预设的停止条件。

基于 GAN-DBN 的双馈风电机组保护动作识别流程如图 8 所示。

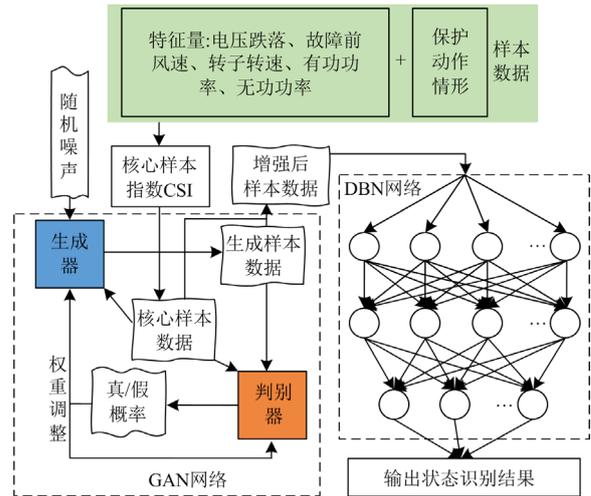


图 8 基于 GAN-DBN 的双馈风电机组保护动作增强识别
 Fig. 8 Enhanced recognition of DFIG protection action based on GAN-DBN

3 计及保护动作差异的双馈风电场等值建模

3.1 基于风速与保护动作识别的机群划分

双馈风电机组按照风速可划分为不同运行区域，风速低于额定风速时采用最大功率跟踪变速运行，风速高于额定风速时采用恒速运行^[28]。转速影响故障结束时暂态阶段的功率特性^[20]，因此，首先按照风速将双馈风电场内的机群划分为 2 个群：最大功率跟踪变速运行的风电机组和恒速运行的风电机组。

双馈风电机组保护动作情况影响故障发生后暂态阶段的功率特性^[20]，因此根据风速区间分群之后再对各群根据保护是否动作分群。双馈风电机组保护动作情况采用基于 GAN-DBN 的双馈风电机组保护动作识别方法。故障情况下，由于集电网络的存在，双馈风电场并网点电压跌落与场内各风电机组的机端电压跌落存在差异，需要进行电压折算获得各风电机组的故障稳态电压，再用故障前电压减去故障稳态电压求得各风电机组的电压跌落。

场内节点 k 的有功功率 P_k 、无功功率 Q_k 与电压 V_k 的关系表示为

$$P_k + jQ_k = V_k \sum_{l=1}^m Y_{kl}^* V_{kl}^* \quad (21)$$

式中: Y_{kl}^* 为与节点 k 直接相联的第 l 个节点处导纳的共轭; V_{kl}^* 为与节点 k 直接相联的第 l 个节点处电压的共轭; m 为与节点 k 直接相联的节点数。

风电机组输出有功功率 P 和无功功率 Q 为

$$\begin{cases} P = u_w i_{\text{ref}} L_m / L_s \\ Q = u_w [u_w / (\omega_s L_s) - i_{\text{ref}} L_m / L_s] \end{cases} \quad (22)$$

式中, u_w 为故障期间端口电压幅值(为简化计算可采用故障期间双馈风电场并网点电压)。故障穿越期间双馈风电机组采用式(12)描述的控制策略。

将双馈风电场集电网络参数、各风电机组参数代入式(12)、式(21)和式(22), 联立可求解得到各风电机组故障稳态期间的机端电压。

$$V_k = \frac{\sum_{l=1}^m Y_{kl}^* V_{kl}^*}{P_k + jQ_k} \quad (23)$$

用故障前电压减去故障稳态电压即可得到风电机组机端电压跌落深度, 再与风电机组的风速、故障前转子角速度、故障前有功功率和故障前无功功率输入训练好的 GAN-DBN 双馈风电机组保护动作识别模型, 获得风电机组的保护动作情况; 将保护动作相同的风电机组归为一群。

计及保护动作差异的双馈风电场等值建模流程如图 9 所示。

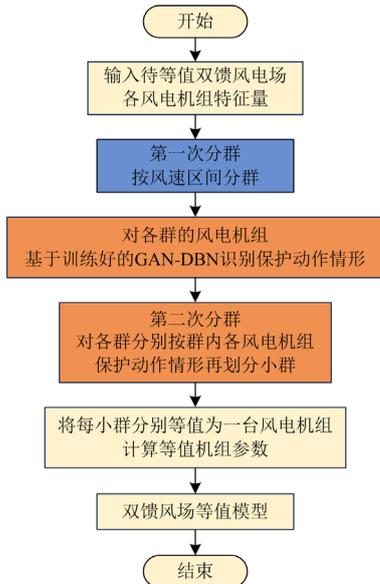


图 9 计及保护动作识别的双馈风电场等值建模方法

Fig. 9 DFIG wind farm equivalent modeling method considering protection action recognition

3.2 等值模型参数计算

根据等值前后风电场内部功率损耗不变原则, 采用容量加权法将同一机群等值为一台机, 等值模型参数计算方法为

$$\begin{cases} l_g = \frac{S_g}{\sum_{g=1}^n S_g}, x_{\text{eq}} = \sum_{g=1}^n l_g x_g, r_{\text{eq}} = \sum_{g=1}^n l_g r_g \\ S_{\text{eq}} = \sum_{g=1}^n S_g, H_{\text{eq}} = \sum_{g=1}^n H_g \\ K_{\text{eq}} = \sum_{g=1}^n K_g, D_{\text{eq}} = \sum_{g=1}^n D_g \\ v_{\text{eq}} = (\sum_{g=1}^n v_g^3 / n)^{1/3}, Z_{\text{eq}} = \sum_{g=1}^n (P_g^2 Z_g) / (\sum_{g=1}^n P_g)^2 \end{cases} \quad (24)$$

式中: l_g 为第 g 台风机容量在同群风机容量的占比; n 为同群风电机组数量; x_{eq} 为等值后风机的等效电抗, 其值等于同群风机电抗的容量加权, 权重为 l_g ; r_{eq} 为等值后风机的等效电阻; S_{eq} 为等值后风机的等效容量; H_{eq} 为等值后风机的等效惯性系数; K_{eq} 为等值后风机的等效刚性系数; D_{eq} 为等值后风机的等效阻尼系数; v_{eq} 为等值后风机的等效风速; Z_{eq} 为等值后集电系统的等效阻抗。

4 等值模型评价

双馈风电场等值建模是在不失精度的条件下对详细模型的简化。对等值模型的评价, 以详细模型仿真得到的风电场并网点功率曲线为基准, 分析量化等值模型仿真得到的风电场并网点功率曲线与基准之间的偏差程度。与详细模型相比, 等值模型的并网点功率曲线不仅存在数值大小上的偏差, 也有曲线局部变化趋势上的偏差。为此, 采用数值误差指标与趋势误差指标量化等值模型与详细模型之间的偏差程度。

此外, 电网侧发生对称故障时, 双馈风电场并网点功率响应具有阶段特征, 可划分为故障发生暂态阶段、故障稳态阶段和故障结束恢复阶段。不同阶段等值模型偏差的来源不同, 保护的行动情况影响故障发生暂态阶段, 故障期间的控制策略影响故障稳态阶段, 风电机组运行区域与故障恢复策略影响故障恢复阶段。为此, 对等值模型分故障阶段进行评价, 再对各阶段加权获得最终评价结果。

1) 数值误差指标

数值误差反映每个仿真时刻点等值模型输出与详细模型之间的偏差, 采用平均绝对误差 E_m 来具体衡量。

$$E_m = \frac{\sum_{t=1}^{n_{data}} |x_t - x_t^{dt}|}{n_{data} \times x_N} \times 100\% \quad (25)$$

式中： x_t 为等值模型仿真功率曲线第 t 个仿真时刻点数值； x_t^{dt} 表示详细模型仿真功率曲线第 t 个仿真时刻点数值； x_N 表示额定功率； n_{data} 为目标阶段的仿真时刻点数。

2) 趋势误差指标

趋势误差反映等值模型输出与详细模型在每个仿真时刻点趋势走向的偏差。等值模型与详细模型采用相同的仿真步长，第 i 个仿真时刻点的趋势走向可由功率曲线在该点的一阶差分表示，故采用平均绝对趋势误差(mean absolute trend error, MATE) 衡量等值模型与详细模型在趋势上的偏差。

$$E_T = \frac{\sum_{t=1}^{n_{data}-1} |(x_{t+1} - x_t) - (x_{t+1}^{dt} - x_t^{dt})|}{(n_{data} - 1) \times x_N} \times 100\% \quad (26)$$

式中： E_T 为趋势偏差； x_{t+1} 为等值模型仿真功率曲线第 $t+1$ 个仿真时刻点数值。

5 算例仿真

算例分析采用的双馈风电场结构如图 10 所示。图 10 中标号为机组编号，风电场系统相关参数参考文献 [25,30]，如表 1 所示，双馈风电机组模型详见文献[30]。

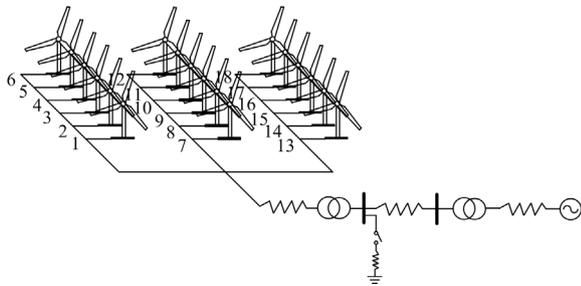


图 10 双馈风电场结构示意图

Fig. 10 Schematic diagram of DFIG farm

表 1 风电场系统参数

Table 1 System parameters of the wind farm

参数	数值	参数	数值	
发电机	额定功率/MW	2	$R_s/p.u.$	0.006 07
参数	额定容量/MW	2.5	$L_s/p.u.$	0.11
	额定电压/kV	0.69	$L_r/p.u.$	0.1
	$R_r/p.u.$	0.0054	$L_m/p.u.$	0.5
保护动作	chopper/p.u.	1.1	crowbar/p.u.	1.25
集电网络	集电线路	0.062 +	升压变	15
参数	阻抗/(Ω/km)	$j0.1302$	变压器 XT/%	

5.1 核心样本增强的效果分析

将原始样本数据集的 I_{csi} 归化至 0~1 区间内进行统一分析，归化后核心样本指数 I_{csi}^* 为

$$I_{csi}^* = \frac{I_{csi} - \min(I_{csi})}{\max(I_{csi}) - \min(I_{csi})} \quad (27)$$

从表 2 的统计结果可知，在原始样本集中，高 I_{csi}^* 指数的样本数据占比较少，其中 0.9~1 区间内的样本个数仅有 0.69%，而 0~0.5 区间内的样本个数高达 95.40%，可见高核心样本指数样本点在样本数据中的作用十分关键， I_{csi} 指标能够为原始样本的充分获取以及样本增强指明方向。

表 3 给出了样本中双馈风电机组保护不同动作情形的数据量占比及其 I_{csi}^* 。样本中情形 2 数据量占比最多，情形 3 数据量占比最少；高 I_{csi}^* 样本主要出现在情形 3、4，情形 1、2 的整体 I_{csi}^* 较低。情形 3 的样本量很少，其大部分样本点在特征空间中靠近各个情形的分布边界，使得样本中情形 3 的数据量容易获取不足，从而影响到模型训练效果。所以，在仿真收集样本集时，如果能够以高 I_{csi}^* 为目标，既能在不需要过多数据量的区域节省仿真时间，又能注重对分界面分布复杂区域样本点的收集，从而提高样本集的获取效率与各情形分解特性表征能力。

表 2 样本核心指数 (I_{csi}^*)

Table 2 Sample core index (I_{csi}^*)

I_{csi}^* 区间	样本个数	占比/%
0~0.1	3856	85.67
0.1~0.2	203	4.51
0.2~0.3	83	1.84
0.3~0.4	75	1.67
0.4~0.5	77	1.71
0.5~0.6	56	1.24
0.6~0.7	46	1.02
0.7~0.8	47	1.04
0.8~0.9	27	0.60
0.9~1.0	31	0.69

表 3 样本状态分布

Table 3 Distribution of the sample states

	情形 1	情形 2	情形 3	情形 4
数据量占比/%	23.47	44.17	0.63	31.72
I_{csi}^* 范围	0~0.217	0.145~0.481	0.344~0.647	0.463~1

为检验所提基于核心样本的 GAN 样本增强方法对保护动作识别的助力效果。本文以核心样本指数分布一致为原则，将原始样本集划分为训练集与验证集，训练集与验证集数据量各占 80%与 20%，

对比了训练集的核心样本指数分布不同以及不同样本增强量模型训练效果, 结果如表 4 所示。

表 4 中增强范围为增强样本中被选中加入训练集的样本 I_{csi}^* 分布。增强量为被选中加入训练集的样本量占增强前训练集数量的比重。弱核心训练集为原始训练集中 $0.5 < I_{csi}^* < 1.0$ 样本点的集合; 极弱核心训练集为原始训练集中 $0.5 < I_{csi}^* < 1.0$ 样本点的集合; 少样本量训练集 1 和少样本量训练集 2 的核心样本指数分布与原始训练集基本一致, 数据量为 2809, 约占原始训练集数据量的 78%; 少样本量训练集 2 的数据量与少样本量训练集 1 一致, 高 I_{csi}^* 占比更高, 如表 5 所示。

由表 4 可知, 原始训练集的增强通过提高训练集中高 I_{csi}^* 样本的占比提升了模型识别准确率 A 。随着训练集的增强量由 5% 增加到 10%, 模型识别准确率不断提高, 误判率 F 与漏判率 M 不断降低, 说明基于核心样本的增强能够帮助识别模型找到适合风电场保护动作状态的分类超平面, 从而提升识别准确率。若使用将原始样本集中高 I_{csi}^* 样本剔除所构建的弱核心样本集进行模型训练, 相对使用原始样本集准确率有所下降, 相对使用原始样本集误判率、

表 4 样本增强量对训练效果的影响评价

Table 4 Influence evaluation of sample augmentation on training effect

训练集		效果验证		
		$A/\%$	$F/\%$	$M/\%$
原始训练集		97.998	97.998%	0.556%
增强范围:	增强量: 5%	98.220	0.445	1.335
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	98.443	0.334	1.224
弱核心训练集		96.218	96.218	2.225
增强范围:	增强量: 5%	96.663	1.891	1.446
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	96.997	1.669	1.335
极弱核心训练集		90.100	90.100	5.562
增强范围:	增强量: 5%	90.656	5.117	4.227
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	91.212	4.783	4.004
少样本量训练集 1		95.328	95.328	3.337
增强范围:	增强量: 5%	96.440	2.336	1.224
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	96.663	2.225	1.112
增强范围:	增强量: 5%	95.773	2.447	1.780
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	95.996	2.336	1.669
少样本量训练集 2		96.774	96.774	1.669
增强范围:	增强量: 5%	97.330	1.335	1.335
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	97.775	1.112	1.112
增强范围:	增强量: 5%	97.108	1.446	1.446
$0.5 < I_{csi}^* < 1.0$	增强量: 10%	97.442	1.224	1.335

表 5 少样本量训练集 1-2 I_{csi}^* 分布

Table 5 Small sample size training set 1-2 I_{csi}^* distribution

I_{csi}^* 区间	少样本量训练集 1		少样本量训练集 2	
	样本个数	占比/%	样本个数	占比/%
0~0.1	2406	83.45	2292	81.59
0.1~0.2	126	4.37	162	5.77
0.2~0.3	51	1.77	66	2.35
0.3~0.4	47	1.63	60	2.14
0.4~0.5	48	1.66	62	2.21
0.5~0.6	35	1.21	45	1.60
0.6~0.7	29	1.01	37	1.32
0.7~0.8	30	1.04	38	1.35
0.8~0.9	17	0.59	22	0.78
0.9~1.0	20	0.69	25	0.89

漏判率有所上升, 对比少样本量训练集与弱核心训练集的整体训练效果, 前者漏判率相对较低, 后者误判率较低。

极弱核心训练集的整体核心样本指数低, 进行增强可略微提高模型准确率, 但过低的准确度使得其几乎不可用于模型的训练。对比极弱核心训练集与原始样本集可以发现, 在仿真得到极弱核心训练集时, 如果能够针对高 I_{csi}^* 区域进行仿真补充, 可极大地改善样本集的训练效果; 对数据量仅占原始训练集约 78% 的少样本量训练集 1 进行 5% 与 10% 增强后, 训练效果得到改善, 其识别准确度逐渐赶超数据量占比约为原始训练集 95% 的弱核心样本集的识别准确度。少样本量训练集 2 相对少样本量训练集 1 高 I_{csi}^* 样本点占比更高, 其增强识别效果整体更好。

对比原始训练集与不同核心样本增强量训练集的训练效果可知, 高 I_{csi}^* 样本是保证训练效果的“关键少数”, 对模型准确度起到不可或缺的作用; 针对高 I_{csi}^* 样本的增强能够一定程度上弥补样本不充分给模型训练效果带来的影响。

5.2 双馈风电场等值结果分析

采用本文所提方法在表 6 所示 4 种场景下对图 10 所示双馈风电场进行等值, 并在 PSCAD/EMTDC 搭建等值模型。

表 6 给出了 4 种场景下并网点电压跌落深度、双馈风电场内各风电机组风速。场景 1 电压跌落深度较浅, 场内各风电机组保护环节均不动作。随着电压跌落程度加深, 场内各风电机组保护差异化投入。当电压跌落 0.42 p.u. 时, 场内存在保护动作不动作以及仅 chopper 动作的风电机组; 当电压跌落 0.56 p.u. 时, 场内存在仅 crowbar 动作以及保护均动作的风电机组; 当电压跌落 0.67 p.u. 时, 场内风电机组的保护均动作。本文所提基于 GAN-DBN 的保

护动作识别结果如图 11 所示,与详细模型的仿真结果一致,表明了所提保护动作识别方法的有效性。

将本文所提等值方法(下文采用 cc 标识)与根据风速区间分群的等值方法(下文采用 wind 标识)以及

表 6 等值验证场景

场景编号	井网点电压跌落 $\Delta u/p.u.$	持续时间/s	机组 1~18 风速分布/(m/s)
1	0.16	0.15	6.50、7.23、9.22、9.78、11.87、11.32、6.11、7.98、11.53、8.87、8.30、11.26、5.79、6.39、6.36、7.24、8.20、8.07
2	0.42	0.15	4.30、4.69、8.52、9.06、9.77、10.22、10.12、9.88、7.23、7.94、11.50、12.46、10.80、11.19、9.23、10.31、11.32、11.67
3	0.56	0.15	4.23、4.75、6.12、8.05、8.05、8.53、4.36、6.45、7.65、7.65、9.85、11.5、5.61、7.25、9.75、9.75、11.23、12.23
4	0.67	0.15	4.50、4.76、8.74、9.13、9.87、10.32、10.11、8.98、7.53、7.87、11.30、12.26、10.79、11.39、9.43、10.44、11.30、11.07

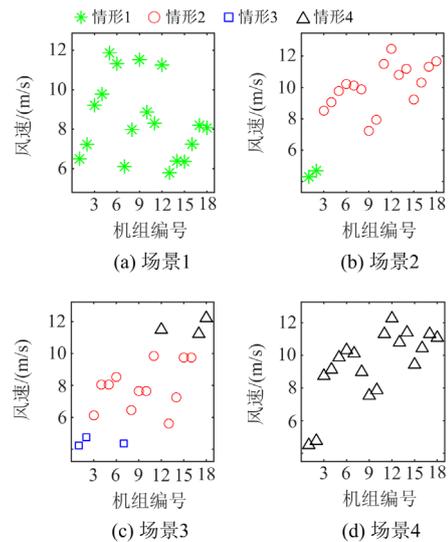


图 11 4 种场景下识别结果

Fig. 11 Recognition results in four scenarios

根据 crowbar 是否动作分群的等值方法(下文采用 crow 标识)进行比较。4 种场景下 3 种方法的分群结果如表 7 所示, 3 种等值模型和详细模型的功率曲线如图 12 所示。

表 7 各场景各分群方法分群结果

Table 7 Clustering results of each clustering method in each scenario

场景	分群方法	分群数	各群机组编号
场景 1	本文方法	2	群 1: 1,2,3,4,7,8,10,11,13,14,15,16,17,18 群 2: 5,6,9,12
	根据风速区间分群	2	群 1: 1,2,3,4,7,8,10,11,13,14,15,16,17,18 群 2: 5,6,9,12
	根据 crowbar 是否动作分群	1	群 1: 1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18
场景 2	本文方法	3	群 1: 1,2 群 2: 3,4,5,6,7,8,9,10,13,15,16 群 3: 11,12,14,17,18
	根据风速区间分群	2	群 1: 1,2,3,4,5,6,7,8,9,10,13,15,16 群 2: 11,12,14,17,18
	根据 crowbar 是否动作分群	1	群 1: 1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18
场景 3	本文方法	4	群 1: 1,2 群 2: 3,4,5,6,7,8,9,10,11,12 群 3: 13,14,15 群 4: 16,17,18
	根据风速区间分群	2	群 1: 1,2,3,4,5,6,7,8,9,10,11,12,13,14,15 群 2: 16,17,18
	根据 crowbar 是否动作分群	2	群 1: 1,2,3,4,5,6,7,8,9,10,11,12 群 2: 13,14,15,16,17,18
场景 4	本文方法	2	群 1: 1,2,3,4,5,6,7,8,9,10,13,15,16 群 2: 11,12,14,17,18
	根据风速区间分群	2	群 1: 1,2,3,4,5,6,7,8,9,10,13,15,16 群 2: 11,12,14,17,18
	根据 crowbar 是否动作分群	1	群 1: 1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18

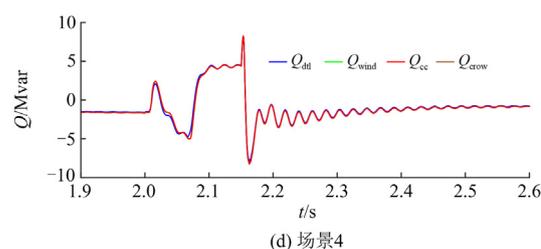
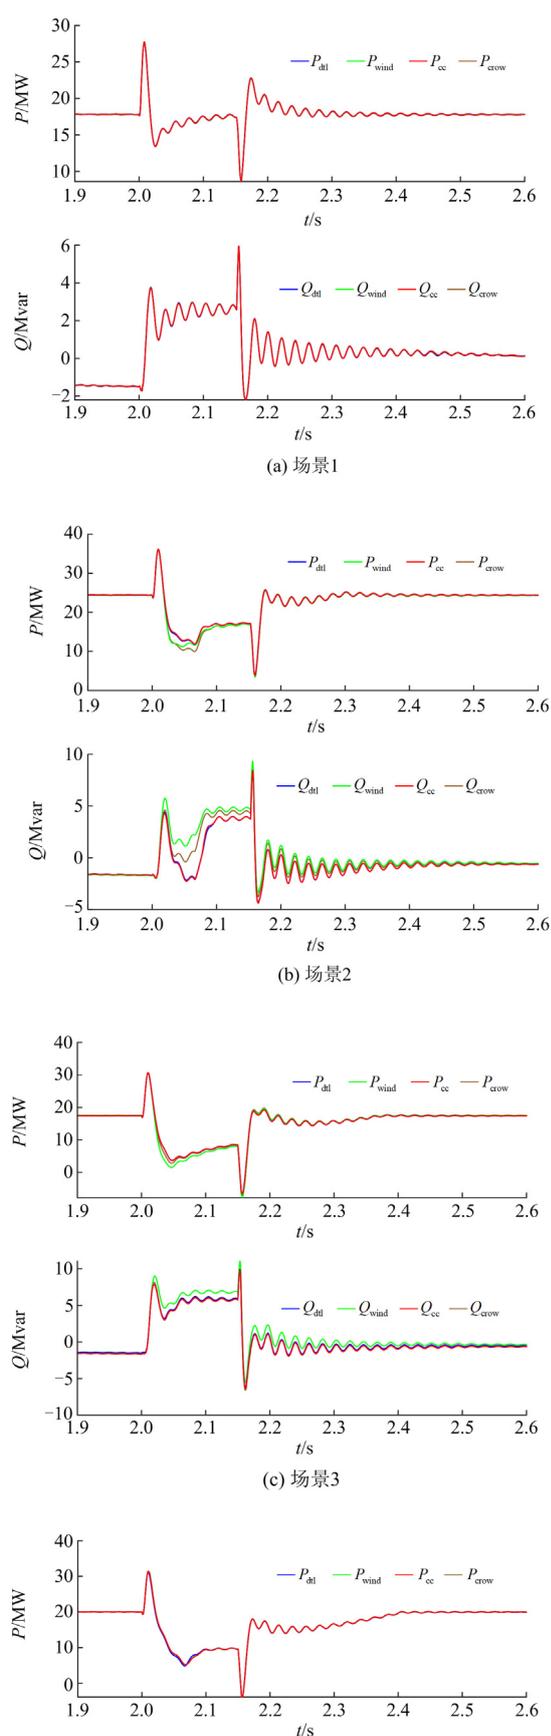


图 12 4 种场景下故障过程暂态功率特性

Fig. 12 Transient power characteristics of the fault process in four scenarios

故障较为轻微时,场内各风机由变流控制器应对电压跌落,不同分群方法的等值效果差异不大,如图 12(a)所示。场景 2 下 $\Delta u = 0.42$ p.u., 双馈风电机组故障穿越过程保护投入,此时场内存在 2 种风速区间以及 2 种保护动作情形。由图 12(b)可知,在场景 2 下,根据风速区间分群的等值方法的故障功率特性误差最大,其次是仅考虑 **crowbar** 动作情况的等值方法,本文方法误差最小。说明保护环节未动作与仅 **chopper** 动作风电机组之间的故障功率特性存在明显差异。场景 2 下各等值方法的故障有功特性误差主要在故障发生时刻暂态阶段,故障无功特性在故障的各个阶段均有明显误差。场景 3 下 $\Delta u = 0.56$ p.u., 场内存在 2 种风速区间以及 3 种保护动作情形。由如图 12(c)可知,此时根据风速区间分群的等值方法相比于详细模型误差最大,考虑 **crowbar** 动作情况的等值方法与本文方法的故障过程暂态功率特性相比于详细模型差异较小。说明仅 **crowbar** 动作风电机组与保护均动作风电机组之间的故障过程暂态功率特性差异较小。场景 3 下各等值方法的故障有功特性差异主要在故障发生时刻暂态阶段,故障无功特性在故障发生暂态阶段、故障稳态阶段、故障恢复阶段均有明显差异。场景 4 下 $\Delta u = 0.67$ p.u., 场内存在 2 种风速区间以及 1 种保护动作情形。由如图 12(d)可知,此时根据风速区间分群的等值方法的故障有功特性与详细模型差异不大,而故障无功特性与详细模型差异均较大。说明在故障较为严重时,单机等值的方法无法准确反映风电场的故障无功特性。

5.3 等值模型评价

本文所提等值方法与根据风速分群等值方法以及根据 **crowbar** 是否动作分群等值方法的分阶段误差如图 13 所示,阶段 I 是故障发生时刻暂态阶段,阶段 S 是故障稳态阶段,阶段 R 是故障恢复阶段。场景 1 下本文所提等值方法与根据风速分群等值方法的分群结果一样,误差一样,图 13(a)中两者曲线重叠;场景 1 下双馈风电场内风电机组保护均未动

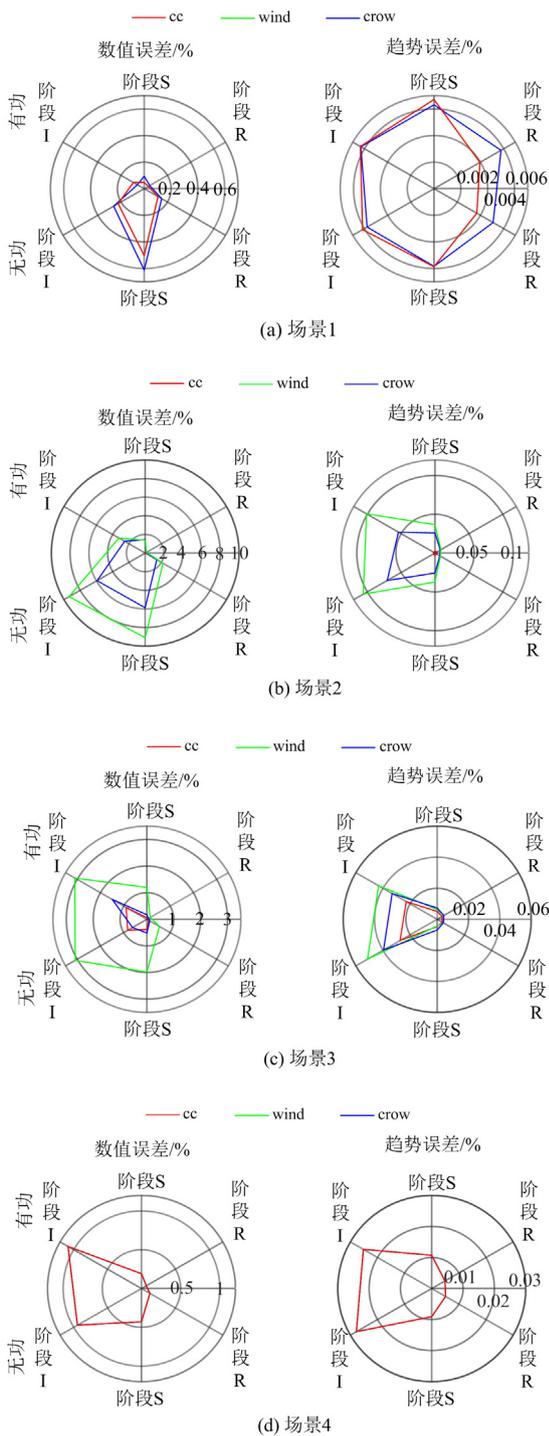


图 13 4 种场景下故障过程暂态功率特性误差分析

Fig. 13 Error analysis of transient power characteristics of the fault process in four scenarios

作, 3 种等值方法功率曲线与详细模型几乎一致, 误差均不超过 0.5%。场景 2 下本文所提等值方法功率曲线与详细模型几乎一致, 误差明显小于其他两种等值方法, 在图 13(b)所示刻度下显示为圆心(0

刻度处)小点。由图 13(c)可知, 场景 3 下本文所提等值方法误差与根据风速分群等值方法相近, 明显小于根据 crowbar 是否动作分群等值方法的误差。场景 4 下本文所提等值方法与根据风速分群等值方法的分群结果一样, 误差一样, 在图 13(d)中两者曲线重叠; 场景 4 下双馈风电场内风电机组 chopper 保护和 crowbar 保护均动作, 3 种等值方法的功率曲线与详细模型几乎一致。

考虑各分阶段误差来源各异, 采用平均加权方式综合分阶段误差, 结果如表 8 所示。场景 1 和场景 4 双馈风电场内各风电机组保护动作情况一样, 3 种等值方法误差几乎一样, 均不超过 0.5%; 场景 3 中本文所提等值方法误差为 0.25%, 略大于根据风速分群等值方法。本文所提等值方法考虑了仅 chopper 保护动作的情况, 所以在场景 2 中的误差明显小于另外两种等值方法。本文所提等值方法在不同场景下均有较好的等值精度。

表 8 综合误差计算

Table 8 Comprehensive error calculation

等值方法	%				综合误差	
	有功特性误差		无功特性误差			
	数值误差	趋势误差	数值误差	趋势误差		
场景 1	cc	0.06	0.01	0.28	0.01	0.09
	wind	0.06	0.01	0.28	0.01	0.09
	crow	0.07	0.01	0.34	0.01	0.11
场景 2	cc	0.03	0.00	0.04	0.00	0.02
	wind	1.36	0.03	4.41	0.03	1.46
	crow	1.60	0.05	6.88	0.05	2.14
场景 3	cc	0.38	0.02	0.58	0.02	0.25
	wind	0.34	0.01	0.43	0.01	0.20
	crow	1.48	0.02	1.87	0.02	0.85
场景 4	cc	0.46	0.01	0.45	0.01	0.23
	wind	0.45	0.01	0.50	0.01	0.24
	crow	0.45	0.01	0.50	0.01	0.24

6 结论

本文提出了一种基于保护电路运行状态增强识别的双馈风场等值建模方法。实验验证了所提方法的有效性。结论如下:

1) 样本数据中核心样本指数较高的很少, 大多数样本点对模型训练过程影响较小。本文提出的 I_{csi} 指标可用于指导风电场样本收集, 避免少数关键样本缺少给样本集带来的缺陷; 同时针对核心样本的增强能够有效提高样本表征风机故障特性的能力, 提高模型训练的效果和模型的识别结果准确度。

2) 直流母线充电过程受风速、电压跌落程度以

及撬棒阻值的影响。在直流母线过电压达到 chopper 触发阈值之前, crowbar 动作会影响直流母线的过电压,若过电压被抑制到 chopper 触发阈值之下,则 chopper 不再触发,此时风机处于 1.2 节所述情形 3。当风力较强时,直流母线充电时间短, crowbar 来不及将过电压拉至 chopper 触发阈值之下,此时 chopper 与 crowbar 均动作,风机处于 1.2 节所述情形 2。

3) 通过等值模型的量化评价体系的验证可知,本文方法在故障起始阶段、故障稳态阶段、故障恢复阶段的数值误差指标与趋势误差指标均最小。相较于根据风速分群以及根据 crowbar 是否动作,本文所提的等值建模方法分群性能更优。

参考文献

- [1] 国家能源局 2023 年四季度新闻发布会文字实录[EB/OL]. http://www.nea.gov.cn/2023-10/31/c_1310748132.htm.
- [2] 周雪松,张波,马幼捷. 基于滤波函数的风电并网逆变器改进线性自抗扰控制[J]. 电测与仪表, 2022, 59(10): 137-144.
ZHOU Xuesong, ZHANG Bo, MA Youjie. Improved linear active disturbance rejection control of wind power grid-connected inverter based on filter function[J]. Electrical Measurement & Instrumentation, 2022, 59(10): 137-144.
- [3] 周霞,刘懿诗,戴剑丰,等. 考虑风-储-直参与调频的电力系统频率特征定量分析[J]. 电力系统保护与控制, 2023, 51(6): 30-44.
ZHOU Xia, LIU Yishi, DAI Jianfeng, et al. Quantitative analysis of power system frequency characteristics considering wind power-energy storage-flexible HVDC transmission participation in frequency modulation[J]. Power System Protection and Control, 2023, 51(6): 30-44.
- [4] 袁庆伟,吴扣林,谢晔源,等. 不平衡电网下风电并网逆变器直接正负序功率控制[J]. 供用电, 2023, 40(1): 88-96, 104.
YUAN Qingwei, WU Koulin, XIE Yeyuan, et al. Direct positive and negative sequence power control of wind power grid-connected inverter under unbalanced grid condition[J]. Distribution & Utilization, 2023, 40(1): 88-96, 104.
- [5] 陈康,王泽,郭永吉. 基于 grcForest 模型的风电并网系统暂态电压稳定评估[J]. 智慧电力, 2023, 51(1): 31-37.
CHEN Kang, WANG Ze, GUO Yongji. Transient voltage stability assessment of wind power grid-connected system based on grcForest model[J]. Smart Power, 2023, 51(1): 31-37.
- [6] WANG Peng, ZHANG Zhengyuan, HUANG Qi, et al. Improved wind farm aggregated modeling method for large-scale power system stability studies[J]. IEEE Transactions on Power Systems, 2018, 33(6): 6332-6342.
- [7] 陈磊,郑燊聪,蒋禹齐,等. 基于改进混沌布谷鸟算法的风电场多机等值参数辨识方法[J]. 电力系统保护与控制, 2023, 51(20): 99-106.
CHEN Lei, ZHENG Shencong, JIANG Yuqi, et al. Identifying multi-machine equivalent parameters of wind farms based on an improved chaotic cuckoo search algorithm[J]. Power System Protection and Control, 2023, 51(20): 99-106.
- [8] 何君毅,周瑀涵,王康,等. 主导模态保持的风电场站自适应等值方法[J]. 电力系统自动化, 2021, 45(11): 28-36.
HE Junyi, ZHOU Yuhuan, WANG Kang, et al. Self-adaptive equivalence method for wind farm with maintained dominant mode[J]. Automation of Electric Power Systems, 2021, 45(11): 28-36.
- [9] MOHAMED E, KWOK L L, OLIMPO A, et al. Impacts of high penetration of DFIG wind turbines on rotor angle stability of power systems[J]. IEEE Transactions on Sustainable Energy, 2015, 6(3): 759-766.
- [10] DU Wenjuan, CHEN Xiao, WANG Haifeng, et al. Impact of dynamic interactions introduced by DFIGs on power system electromechanical oscillation modes[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4954-4967.
- [11] 苏晨博,刘崇茹,李志显,等. 基于阻抗法的大规模风电场等值方法研究[J]. 电测与仪表, 2022, 59(6): 90-97.
SU Chenbo, LIU Chongru, LI Zhixian, et al. Research on equivalent method of large-scale wind farm based on impedance method[J]. Electrical Measurement & Instrumentation, 2022, 59(6): 90-97.
- [12] 韩伟,李峰,王轩,等. 考虑尾流效应和集电系统元件故障的风电场可靠性建模[J]. 电测与仪表, 2023, 60(4): 126-132.
HAN Wei, LI Feng, WANG Xuan, et al. Reliability modeling of wind farm considering wake effects and fault of collector system components[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 126-132.
- [13] 曹娜,于群. 风速波动情况下并网风电场内风电机组分组方法[J]. 电力系统自动化, 2012, 36(2): 42-46.
CAO Na, YU Qun. A grouping method for wind turbines in a grid-connected wind farm during wind speed fluctuation[J]. Automation of Electric Power Systems, 2012, 36(2): 42-46.
- [14] 徐玉琴,张林浩,王娜,等. 计及尾流效应的双馈机组风电场等值建模研究[J]. 电力系统保护与控制, 2014, 42(1): 70-76.
XU Yuqin, ZHANG Linhao, WANG Na, et al. Study on equivalent model of wind farms with DFIG considering wake effects[J]. Power System Protection and Control, 2014, 42(1): 70-76.
- [15] TIAN Jie, ZHOU Dao, SU Chi, et al. Reactive power dispatch method in wind farms to improve the lifetime of power converter considering wake effect[J]. IEEE

- Transactions on Sustainable Energy, 2017, 8(2): 477-487.
- [16] ZHOU Y, ZHAO L, MATSUO L B M, et al. A dynamic weighted aggregation equivalent modeling approach for the DFIG wind farm considering the Weibull distribution[C] // Commercial Power System Technology Conference (I&CPS), May 2019, Calgary, AB, Canada: 1-7.
- [17] 张星, 李龙源, 胡晓波, 等. 基于风电机组输出时间序列数据分群的风电场动态等值[J]. 电网技术, 2015, 39(10): 2787-2793.
- ZHANG Xing, LI Longyuan, HU Xiaobo, et al. Wind farm dynamic equivalence based on clustering by output time series data of wind turbine generators[J]. Power System Technology, 2015, 39(10): 2787-2793.
- [18] 吴红斌, 何叶, 赵波, 等. 基于改进 K-means 聚类算法的风电场动态等值[J]. 太阳能学报, 2018, 39(11): 3232-3238.
- WU Hongbin, HE Ye, ZHAO Bo, et al. Research on dynamic equivalent of wind farm based on improved K-means clustering algorithm[J]. Acta Energetica Sinica, 2018, 39(11): 3232-3238.
- [19] 陈树勇, 王聪, 申洪, 等. 基于聚类算法的风电场动态等值[J]. 中国电机工程学报, 2012, 32(4): 11-19, 24.
- CHEN Shuyong, WANG Cong, SHEN Hong, et al. Dynamic equivalence for wind farms based on clustering algorithm[J]. Proceedings of the CSEE, 2012, 32(4): 11-19, 24.
- [20] 郑子萱, 宋东徽, 谢琦, 等. 考虑撬棒与直流卸荷协同保护动作特性的双馈风电场通用等值建模方法[J/OL]. 中国电机工程学报: 1-12[2024-01-04]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20230710.1920.019.html>.
- ZHENG Zixuan, SONG Donghui, XIE Qi, et al. A general equivalent modeling method for DFIG wind farms considering the coordinated action characteristics of crowbar and chopper protection[J/OL]. Proceedings of the CSEE: 1-12[2024-01-04]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20230710.1920.019.html>.
- [21] 欧阳金鑫, 刁艳波, 郑迪, 等. 基于电流轨迹相似度的双馈风电机组电磁暂态同调分群方法[J]. 中国电机工程学报, 2017, 37(10): 2896-2904.
- OUYANG Jinxin, DIAO Yanbo, ZHENG Di, et al. A clustering method of coherent generators during electromagnetic transient process based on similar degrees of current trajectories for doubly fed wind farms[J]. Proceedings of the CSEE, 2017, 37(10): 2896-2904.
- [22] JIN Yuqing, WU Daming, JU Ping, et al. Modeling of wind speeds inside a wind farm with application to wind farm aggregate modeling considering LVRT characteristic[J]. IEEE Transactions on Energy Conversion, 2019, 35(1): 508-519.
- [23] ZHU Lin, ZHANG Jian, ZHONG Danting, et al. A study of dynamic equivalence using the similarity degree of the equivalent power angle in doubly fed induction generator wind farms[J]. IEEE Access, 2020, 8: 88584-88593.
- [24] 韩佶, 苗世洪, 李力行, 等. 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[J]. 中国电机工程学报, 2020, 40(15): 4866-4881.
- HAN Ji, MIAO Shihong, LI Lixing, et al. Wind turbines clustering in wind farm based on multi-view transfer learning and synthetic optimization of parameters in equivalent wind farm[J]. Proceedings of the CSEE, 2020, 40(15): 4866-4881.
- [25] 吴志鹏, 曹铭凯, 李银红, 等. 计及 Crowbar 状态改进识别的双馈风电场等值建模方法[J]. 中国电机工程学报, 2022, 42(2): 603-614.
- WU Zhipeng, CAO Mingkai, LI Yinhong, et al. An equivalent modeling method of DFIG-based wind farm considering improved identification of crowbar status[J]. Proceedings of the CSEE, 2022, 42(2): 603-614.
- [26] HU Xiaorui, SHANG Zengyi, YI Zhengbo, et al. Wind turbine clustering and equivalent parameter identification in multitime scales based on the deep migration of multiview features[J]. IEEE Access, 2022, 10: 89568-89580.
- [27] GONZALO A, JESÚS L, MIGUEL A R, et al. 双馈感应电机在风力发电中的建模与控制[M]. 胡家兵, 迟永宁, 汤海雁, 等译. 北京: 机械工业出版社, 2014.
- [28] 蔡旭, 李征. 风电机组与风电场的动态建模[M]. 北京: 科学出版社, 2016.
- [29] PAUL M, GANGULI S, DZIUGAITE G, et al. Deep learning on a data diet: finding important examples early in training[J]. Advances in Neural Information Processing Systems, 2021, 34: 20596-20607.
- [30] ARASH Y G, DHARSHANA M, YOUSEF P, et al. Modeling of type-3 wind farm and investigation of fault contribution in power system[C] // 2016 IEEE Power and Energy Society General Meeting (PESGM), 2016, Boston, MA, USA: 1-5.

收稿日期: 2024-04-05; 修回日期: 2024-06-24

作者简介:

蒋昊(1998—), 男, 硕士研究生, 研究方向为风电场等值建模; E-mail: scuqh@qq.com

许立雄(1982—), 男, 通信作者, 博士, 硕士生导师, 研究方向为电力系统稳定与控制; E-mail: xulixiong@163.com

崔晓丹(1981—), 男, 博士, 研究员级高级工程师, 研究方向为电力系统安全稳定分析及控制技术。E-mail: cuixiaodan@sgepri.sgcc.com.cn

(编辑 许威)