



基于深度神经网络的DFIG低电压穿越技术研究

余欣梅, 陈豪君, 王星华

引用本文:

余欣梅, 陈豪君, 王星华. 基于深度神经网络的DFIG低电压穿越技术研究[J]. 南方能源建设, 2021, 8(3): 122–130.

YU Xinmei, CHEN Haojun, WANG Xinghua. Research on Low Voltage Ride Through Technology of DFIG Based on Deep Neural Networks[J]. *Southern Energy Construction*, 2021, 8(3): 122–130.

相似文章推荐 (请使用火狐或IE浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

PSAT应用于风电系统暂态稳定性研究

Research on Transient Stability for Wind Power System Based on PSAT

南方能源建设. 2020, 7(4): 41–47 <https://doi.org/10.16516/j.gedi.issn2095-8676.2020.04.006>

基于BP神经网络灰色回归组合模型的年最大负荷预测

Annual Peak Load Forecasting Based on Combination Model of Back Propagation Neural Network and Grey Regression

南方能源建设. 2017, 4(2): 46–50,57 <https://doi.org/10.16516/j.gedi.issn2095-8676.2017.02.007>

海上风电机组智能故障预警系统研究

Research on Intelligent Fault Warning System of Offshore Wind Turbines

南方能源建设. 2018, 5(2): 133–137 <https://doi.org/10.16516/j.gedi.issn2095-8676.2018.02.019>

基于MI时序处理的GA-BP脱硫制浆系统能耗建模

Energy Consumption Modeling of GA-BP for Desulfurization Pulping System Based on MI Time Series Processing

南方能源建设. 2019, 6(4): 64–68 <https://doi.org/10.16516/j.gedi.issn2095-8676.2019.04.010>

计及限流—储能协调控制的高渗透率微电网故障穿越能力探讨

Study on the Fault Ride-through Capability of High Penetration Micro-grid Considering Coordinated Control of Fault Current Limiter and Energy Storage

南方能源建设. 2015, 2(2): 20–27 <https://doi.org/10.16516/j.gedi.issn2095-8676.2015.02.004>

基于深度神经网络的DFIG低电压穿越技术研究

余欣梅^{1,✉}, 陈豪君², 王星华²

(1. 中国能源建设集团广东省电力设计研究院有限公司, 广州 510663; 2. 广东工业大学自动化学院, 广州 510006)

摘要: [目的] 双馈风机 (DFIG) 的低电压穿越 (LVRT) 性能在一定程度上依赖于控制参数的优化, 而目前对控制参数的优化基本都是离线模式, 原因在于优化算法难以满足实时控制对计算速度的要求。[方法] 基于深度神经网络 (DNN) 原理, 提出基于“离线训练、在线计算”思路的低电压穿越实时优化控制方法。首先针对含DFIG电网在不同运行方式下发生的大量不同故障进行控制参数的离线优化并形成相应的LVRT优化控制策略, 将不同的故障状态进行归类并形成成对的故障模式和参数表, 从而构成深度神经网络的训练样本。[结果] 电网故障瞬间可以将输入参数直接通过训练好的DNN网络迅速实现控制方案和最优参数的优选。[结论] 基于PSCAD和Matlab的联合仿真结果论证了所提思想在优化效果和优化速度方面的优势, 并说明了其实用性。

关键词: 双馈风机; 低电压穿越; 深度神经网络

中图分类号: TM7; TM315

文献标志码: A

文章编号: 2095-8676(2021)03-0122-09

开放科学(资源服务)二维码:



Research on Low Voltage Ride Through Technology of DFIG Based on Deep Neural Networks

YU Xinmei^{1,✉}, CHEN Haojun², WANG Xinghua²

(1. China Energy Engineering Group Guangdong Electric Power Design Institute Co., Ltd., Guangzhou 510663, China;

2. School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: [Introduction] During the power grid fault, the low voltage ride through (LVRT) performance of the doubly-fed induction generator (DFIG) depends on the control parameters. At present, the optimization of control parameters is basically in the offline mode, which lies in the fact that it's hard for algorithm optimization to meet real-time control's requirement of the calculation speed. [Method] Therefore, the real-time optimization control method of LVRT following "offline training, online computation" was presented based on the principles of deep neural networks (DNN). Firstly, the appropriate LVRT strategy for optimization control was proposed for different fault severity levels. The parameters were clustered and optimized according to the respective objectives of each strategy, then the parameter list was formed. [Result] At the moment of power grid fault, the input parameters can be directly input into the trained DNN networks to quickly realize the optimization of control scheme and optimal parameters. [Conclusion] The joint simulation results based on PSCAD and MATLAB demonstrate the advantages of the proposed idea in optimization effect and optimization speed and the practicability is also illustrated.

Key words: double-fed induction generator; low voltage ride through; deep neural networks

2095-8676 © 2021 Energy China GEDI. Publishing services by Energy Observer Magazine Co., Ltd. on behalf of Energy China GEDI. This is an open access article under the CC BY-NC license (<https://creativecommons.org/licenses/by-nc/4.0/>).

低电压穿越技术是保障电网故障过程中风机和电网安全的重要手段。目前DFIG双馈风机的低电压控制基本分为改进控制策略和增设硬件电路两

类: 文献 [1-2] 采用带补偿项的矢量控制加速定子磁链暂态分量衰减实现低电压穿越, 但受变流器容量限制, 仅适用于轻度故障。文献 [3] 增设撬

收稿日期: 2021-07-26 修回日期: 2021-08-24

基金项目: 国家自然科学基金项目“基于张量技术的多视图特征选择方法研究”(61903091)

棒电阻并推导其整定方法, 适用于严重故障, 但在投入过程中双馈风机会大量吸收无功, 不利于电网电压稳定。文献 [4] 理论分析了多种低电压穿越技术, 讨论了DFIG控制系统的PI参数选择对DFIG机组LVRT效果的影响。

为取得更好的控制性能, 有学者提出用遗传算法 [5-6]、粒子群 [7-8] 等智能算法 [9-10] 对PI控制器参数进行优化。这类优化方法均为电网故障后根据当前故障情况进行参数优化, 但普遍存在两个问题: (1) 在实际情况下, 故障的暂态过程比较快, 故障后优化很可能会错过抑制暂态量的最好时刻; (2) 在有限的时间内在线优化难以同时满足速度和准确度上的要求, 严重制约了其在高实时性领域上的应用, 实际意义不大。

针对以上不足, 本文结合人工智能思想, 提出将深度学习算法应用于双馈风机的LVRT的实时优化控制。首先通过PSCAD-MATLAB联合调用技术对风机故障过程进行大量仿真, 并利用粒子群优化算法对相应的控制参数进行离线优化, 并根据故障程度进行分类, 从而形成不同故障程度的优化控制策略参数表。其次建立DNN故障程度识别模型, 将仿真算例形成训练集, 以故障信息作为训练样本的输入参数对故障程度进行分类训练。训练成功的网络即构成控制策略优选模块, 只需输入所采集的故障信息即可实时选择并确定优化的LVRT控制策略和参数, 从而解决了实际故障时控制的实时性问题。

1 低电压穿越策略以及参数优化

1.1 PSCAD与MATLAB的联合调用

故障点与DFIG并网点的距离直接影响并网点电压的跌落深度。根据电压跌落深度可将故障程度分成三种: 轻度故障 (跌落 10% ~ 30%)、中度故障 (跌落 30% ~ 50%) 和严重故障 (跌落 50% ~ 80%)。不同的严重程度决定了机组应采取的LVRT策略、控制目标和优化参数, 本文利用粒子群优化算法进行不同控制策略的选择和参数优化, 并基于PSCAD-MATLAB联合仿真进行的电磁暂态和优化过程的仿真, 联合仿真模块如图1所示。

图1中, PSCAD中建立含DFIG的仿真网络进行故障仿真, Matlab中利用Multiple Run进行PSO寻

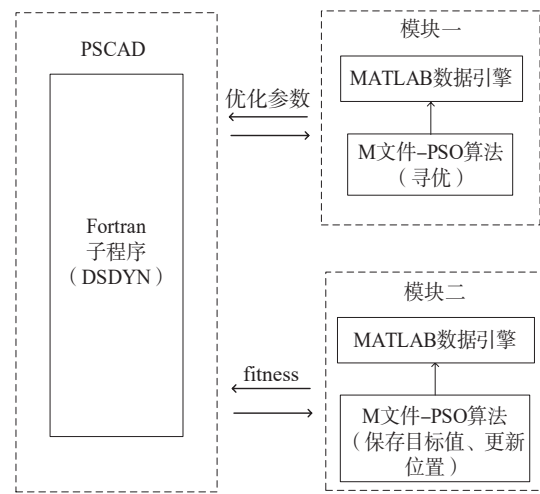


图1 联合模块示意图

Fig. 1 Illustration of combined model

优, 两者通过文件进行优化参数和适应度数据的交互。仿真网络和参数参见文献 [11] 及本文2.2节。

1.2 LVRT策略选择和优化过程

如前文所述, 不同故障程度须选择不同的LVRT策略及相应的优化控制参数。

1) 改进控制策略参数优化

如图2, 转子侧变流器采用了控制外环为功率环, 控制内环为电流环的双闭环控制系统, 当要求电流内环具有较快的电流跟随性能时, 可按典型I型系统设计, 从而得到PI控制器参数的整定公式 [12-13]:

$$\begin{cases} k_p = \omega_c \sigma L_r \\ k_i = \omega_c R_r \end{cases} \quad (1)$$

式中: $\sigma = 1 - L_m^2 / (L_s L_r)$; R_r 和 L_s 、 L_r 分别为转子电阻 (Ω) 和定、转子电感 (H); L_m 为励磁电感 (H); $\omega_c = 2\pi f_c$, f_c 为截止频率 (HZ)。一般要保证截止频率在等效开关频率的1/10以内。

故障后闭锁控制外环, 只需考虑内环PI调节器的运行特性。由于d、q轴电流环结构相同, PI参数设置相同, 通过式 (1) 计算和多次仿真调整后得到初始值。

故障点较远时, 硬件设备不动作, 转子侧采取改进的控制策略, 在电流环给定值上添加定子磁链波动的补偿项, 内环d、q的指令值变为 [2]:

$$\begin{cases} i_{rd}^* = i_{rd}^* - (\psi_{sd0} - \psi_{sd}) * L_m / (\sigma L_s L_r) \\ i_{rq}^* = i_{rq}^* - (\psi_{sq0} - \psi_{sq}) * L_m / (\sigma L_s L_r) \end{cases} \quad (2)$$

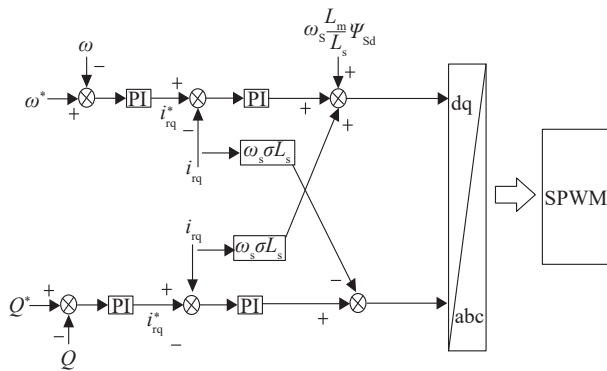


图2 转子侧变流器控制框图
Fig. 2 Schematic diagram

式中： i_{rd}^* 、 i_{rq}^* 和 i_{rd}' 、 i_{rq}' 分别为添加补偿项前后的转子d、q轴电流给定值(A)。 ψ_{sd0} 、 ψ_{sq0} 和 ψ_{sd} 、 ψ_{sq} 分别为定子磁链稳态值和瞬时值的d、q轴分量(Gs)。

改进控制策略中，(1)优化参数为 k_p 、 k_i ；(2)优化目标为暂态直流分量衰减最快，转子电流幅值最低，由此适应度函数定义为：

$$\min f(x) = \int_0^t (|\psi_{sd} - \psi_{sd0}| + |\psi_{sq} - \psi_{sq0}| + |i_{rd} - i_{rd}'| + |i_{rq} - i_{rq}'|) dt \quad (3)$$

通过PSCAD/EMTDC仿真DFIG低电压穿越电磁暂态过程^[14-15]， $t=8\text{ s}$ 时，电网发生三相短路故障，8.2 s故障切除，再利用Matlab中的Multiple Run模块联合仿真粒子群优化过程，优化的种群规模30，迭代终止条件为最大迭代40次及适应度无变化。

在文献[11]中的仿真网络中设置故障参数进行仿真，在电压跌落20%以内时，优化前后转子电流内环PI参数如表1所示。


表1 PI控制器参数对比

Tab. 1 Comparison of PI parameters


参数项	k_p	k_i
初始控制参数值	0.9	0.3
优化后控制参数值	0.742	0.335

比较传统控制、原始参数改进控制和优化参数改进控制三种方案的仿真结果，如图3所示。


对比图3发现，加入转子电流补偿量的改进控制可使暂态分量在半隔周波后快速衰减，机组暂态波动更快稳定。而在参数优化的改进控制中，转子




(a) d轴定子磁链对比



(b) 转子电流对比



(c) 无功功率对比



(d) 电磁转矩对比

图3 电压跌落20%以内LVRT特性对比

Fig. 3 Comparison of LVRT characteristics of 20% voltage sag

电流峰值，定子磁链变化幅度均较未优化前更小，输出无功更多。

2) 撬棒保护参数优化

严重故障下，改进控制策略受DFIG变流器容量约束难以发挥作用，需根据故障情况投入不同的撬棒电阻实现低电压穿越。可变电阻撬棒电路拓扑

结构如图 4 所示。




图 4 撬棒电路的拓扑结构

Fig. 4 Topology of crowbar circuit

撬棒等效阻值的大小通过 R_1 、 R_2 的 IGBT 开关占空比控制, 计算公式为:

$$R_{cb} = \frac{R_1 R_2}{D_1 R_2 + D_2 R_1} \quad (4)$$

式中: D_1 、 D_2 为 IGBT1、IGBT2 导通脉宽占空比; $D_1 + D_2 = 1$, R_{cb} 为等效撬棒电阻 (Ω)。

根据文献 [8] 可得最严重故障下撬棒阻值为:

$$R_{cb,max} = \frac{\sqrt{2} U_{r,max} \omega_s L'_s}{\sqrt{3.2 U_s^2 - 2 U_{r,max}^2}} \quad (5)$$

式中: $L'_s = L_s + \frac{L_r L_m}{L_r + L_m}$; U_s 为故障前定子电流相电压 (V); $U_{r,max}$ 为转子电压的最大值 (V); ω_s 为同步转速 (转/s); $R_{cb,max}$ 为最大等效撬棒电阻 (Ω)。

撬棒保护参数优化的对象为 D_1 , 其实质是优化 Crowbar 电阻大小, 优化的目标是转子电流最小, 无功输出最大, 同时满足直流母线电压 U_{dc} 小于阈值 U_{dc}^* , 则适应度函数定义为:

$$f(x) = \int_0^t (|U_{dc} - U_{dc}^*| + |i_{rd} - i_{rd}^*| + |i_{rq} - i_{rq}^*|) dt \quad (6)$$

式中: 要求 $f(x)$ 适应值最小, 保留一定的裕度, 取 $U_{dc}^* = 1330$ 。

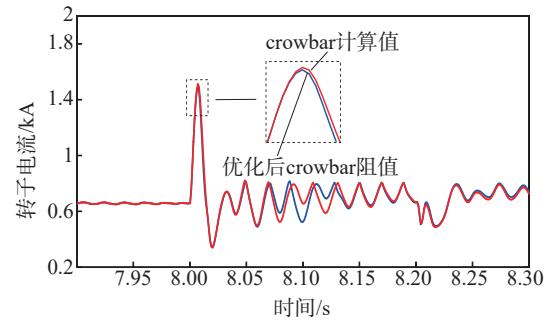
传统撬棒电阻整定值由式 (4) 得到, 优化后的结果参见表 2。

严重故障下电压跌落 70%, 当故障电流大于 0.8 kA 时撬棒电路接入, 固定撬棒电阻和可变电阻两种方案的仿真结果如图 5 所示。


表 2 优化前后撬棒阻值对比

Tab. 2 Comparison of Crowbar crowbar resistance


参数项	参数值
固定 Crowbar 电阻整定值/ Ω	2
优化后 Crowbar 电阻值/ Ω	1.625
对应 D_1 占空比	0.923




(a) 转子电流波形



(b) 直流母线电压波形



(c) 电磁转矩波形



(d) 输出无功功率波形

图 5 电压跌落 70% 场景的 LVRT 特性对比

Fig. 5 Comparison of LVRT characteristics

对比分析可知, 传统撬棒固定整定值较大, 对转子过电流的抑制能力更好, 但容易出现直流母线电压骤升的问题, 如图 5 (b) 中显示母线电压升至 1 430 V, 超出 U_{dc}^* 约 100 V。

两种方案的电磁转矩和无功消耗差异不大, 但

固定电阻方案波动大,对机组安全更为不利。

3) 联合控制参数优化

中度故障下,单独采用改进控制策略效果不明显,无法降低转子电流峰值;纯撬棒保护能有效抑制过电流和过电压,但撬棒电路投入越久,机组从电网中吸收的无功会更多。

利用撬棒保护和改进控制结合的控制策略,能够有效解决两种方案单独投入时存在的弊端:在转子侧过电流严重时投入撬棒电路,旁路转子侧变流器,当电流恢复到改进控制的可控范围内切出撬棒电路,采用变流器改进控制策略,直到故障结束。

本文通过设置电流阈值来制定两者的切换规则,规则如下式所示:

$$\begin{cases} \vec{i}_r \leq 1.2I_{rN} & \text{改进控制} \\ \vec{i}_r > 1.2I_{rN} & \text{可变撬棒保护} \end{cases} \quad (7)$$

式中: \vec{i}_r 为转子电流 (A); I_{rN} 为转子电流额定值 (A)。

同样,对电压跌落 50% 时的电流内环 PI 控制器和 IGBT 开关占空比进行优化,得到参数如表 3 所示。

表 3 最优控制参数
Tab. 3 Optimal control parameters

参数	k_p	k_i	R_{CB}/Ω
优化值	0.861	0.237	1.344

图 6 为在电压跌落 50% 的情况下三种方案的 LVRT 特性对比,其中联合控制的电流阈值设为 0.8 kA,切换规则按式 (7) 执行。

联合控制策略灵活运用两种方案,有效减少了撬棒电阻投入时间和次数,同时在抑制电流电压能力上与纯撬棒相近,因此适用中度的电压跌落情况。

根据上述优化结果形成参数表,用于 DNN 网络识别故障后匹配策略和参数,具体参数如表 4 所示。

每种故障程度都有对应的 LVRT 策略,当程度较轻时,只采取改进控制策略,参数给的是转子控制系统内环的 PI 值;而中度故障下,采用联合控制策略,则参数涉及 PI 值和撬棒阻值;严重故障下单独投入撬棒电路,因此只给出撬棒阻值。







图 6 风机 LVRT 在电压跌落 50% 时的特性
Fig. 6 LVRT characteristics with 50% voltage sag

2 故障程度识别模型

2.1 DNN 结构与原理

DNN 本质上是一个包含多个隐含层的前馈神

表 4 策略参数表
Tab. 4 Parameter table

序号	故障程度	LVRT策略	优化参数
0	轻度故障	改进控制	$k_p=0.742; k_i=0.335$
1	中度故障	联合控制	$k_p=0.861; k_i=0.237; R_{cb}=1.344(\Omega)$
2	严重故障	撬棒保护	$R_{cb}=1.625(\Omega)$

神经网络, 是近年来发展迅速的深度学习网络的一种, 具有很好的非线性映射关系和学习能力, 适宜处理更大的函数集合^[16-18], 结构如图 7 所示:




图 7 DNN 网络结构图
Fig. 7 Structure of DNN

x_1, x_2, \dots, x_n 为模型输入, 是由故障信息中提取的定、转子电流所组成的向量, 输入层采用线性恒等函数作为激活函数, 隐含层层数为 n , 最终传递给网络的输出向量 y_1, y_2, \dots, x_n 。 (w_i, b_i) 分别为第 i 个隐含层的权重与偏置。假定第 $i-1$ 隐含层的输入向量为:

$$a^{(i-1)} = (a_1^{(i-1)}, a_2^{(i-1)}, \dots, a_i^{(i-1)}, \dots, a_m^{(i-1)})^T \quad (8)$$

则第 i 层神经元的输出向量 $a^{(i)}$ 可表示为:

$$a^{(i)} = f\left(\sum_{j=1}^a w_{i-1} a_j^{(i-1)} + b_{i-1}\right) \quad (9)$$

式中: a 为第 i 层神经元数目; w_{i-1}, b_{i-1} 为第 $i-1$ 层的权重矩阵和阈值变量, $f(x)$ 采用 ReLU 函数。

在分类问题中, 常用 softmax 分类方法, 将多分类的输出值转化为相对概率, 如式 (10) 所示:

$$S_i = \frac{e^{V_i}}{\sum_i^c e^{V_i}} \quad (10)$$

式中: i 为类别索引; C 为总类别数; V_i 是分类器前级输出单元输出; S_i 为当前元素与所有元素的指数和的比值。

输入通过 softmax 函数计算完后, 再计算它们的交叉熵, 表示的是目标实际输出概率与期望输出概率的差距, 表达式为:

$$H(W) = \sum_{t=1}^N \sum_{y=1}^S \tilde{p}(y|X_t) \log p(y|X_t) \quad (11)$$

式中: N 为训练样本的数目; $\tilde{p}(y|X_t)$ 为期望概率, 值为 0 或 1; $p(y|X_t)$ 为 DNN 网络的实际输出概率。

最后, 由式 (9) 可求得整个网络输出为:

$$y = f^{n+1}\left(\sum_{i=1}^{\beta} w_{n+1} f^n + b_{n+1}\right) \quad (12)$$

其中: 最后一层隐含层神经元数量为 β ; f^n 为计算的最后一层隐含层输出; w_{n+1}, b_{n+1} 为输出层权值和偏置。

2.2 训练样本集与测试样本集数据生成

在 PSCAD/EMTDC 上建立双馈风机-无穷大系统, 图 8 为仿真系统原理图。




图 8 仿真系统图

Fig. 8 Diagram of simulation system

模型参数: DFIG 容量为 2 MW; T1 表示风机经 0.69 kV/33 kV 和 35 kV/110 kV 两个变压器并入无穷大电网; 线路长度 L 取 50 km; n 为不同的故障点序号。

为方便研究, 本文只考虑了三相短路故障的情况, 仿真不同故障点和过渡电阻下 DFIG 的故障暂态过程, 选取故障发生后一个周波的三相定、转子电流采样数据 (每周波的采样点数为 24), 构成 DNN 的训练集和测试集, 仿真参数如表 5~表 6 所示。

表 5 训练样本仿真参数设置

Tab. 5 Simulation parameters for training set

类型	参数取值	数量
故障位置/km	0, 10, 15, 20, 25, 30, 35, 40, 45, 50	10
过渡电阻	0, 5, 10, 15, 20, 25, 30, 35, 40	9
故障程度	轻度(0), 中度(1), 严重(2)	3

表 6 测试样本仿真参数设置表

Tab. 6 Simulation parameters for testing set

类型	参数取值	数量
故障位置/km	5, 12, 18, 24, 32, 38, 49	7
过渡电阻	0, 5, 10, 15, 20, 25, 30, 35, 40	9
故障程度	轻度(0), 中度(1), 严重(2)	3

表中,故障位置指故障点离风机并网点的距离,从0~50 km中选取了10个故障点,体现了故障点的远、中、近,与故障程度相对应;同理,考虑存在过渡电阻的情况,一共设置了9个阻值。故障程度根据电压跌落设置轻度、中度和严重故障三种,DNN的标签即为相应故障类型下的优化控制

参数。

2.3 仿真结果

DNN的分类效果受网络参数的影响很大,仿真中设置了不同的DNN网络结构、参数以及迭代次数,并利用测试集校验训练结果,如表7所示。

表7 不同网络参数下DNN故障识别仿真结果

Tab. 7 Results of simulation

序号	网络结构(层数、神经元数量)	最大迭代次数	训练率	平均训练误差	测试准确率/%	训练时间/s
1	500—400—300—100	5 000	0.000 1	0.005 6	95	898
2	500—400—300	5 000	0.000 1	0.009 0	92.5	839
3	500—400—300—100	5 000	0.001	0.003 9	95	974
4	200—100—100—50	5 000	0.000 1	0.007 5	92.5	501
5	200—100—100—50	2 500	0.000 1	0.036 1	90	253

由表7分析可知,DNN的隐含层层数、各层神经元个数、迭代次数等均会影响训练的精度、时间。参数序号1、2的对比表明,隐含层的层数越多,越能够有效识别特征来对事物进行区分,获得更好的分类效果;序号1、3的对比表明学习率过大,难以避免出现训练震荡的问题,使得达到相同测试准确率的时间更长;对比序号1、4,隐含层层数相同,迭代次数相同,神经元数量能够提升准确率,但是太高容易出现过拟合现象;序号4、5网

络结构相同,迭代次数越多准确率越高。此外,测试过程中,所有训练好的模型在输入参数后0.2~0.4 ms的时间内,均能够获取相应的优化控制参数,能够满足实时控制的需要。

图9为序号1、2、3的训练图,其中括平均训练误差和测试准确率。

综合分析结果,在测试样本中故障位置、过渡电阻等参数均不同的情况下,DNN仍然能准确判断故障程度,这是因为DNN具有很强的泛化能力

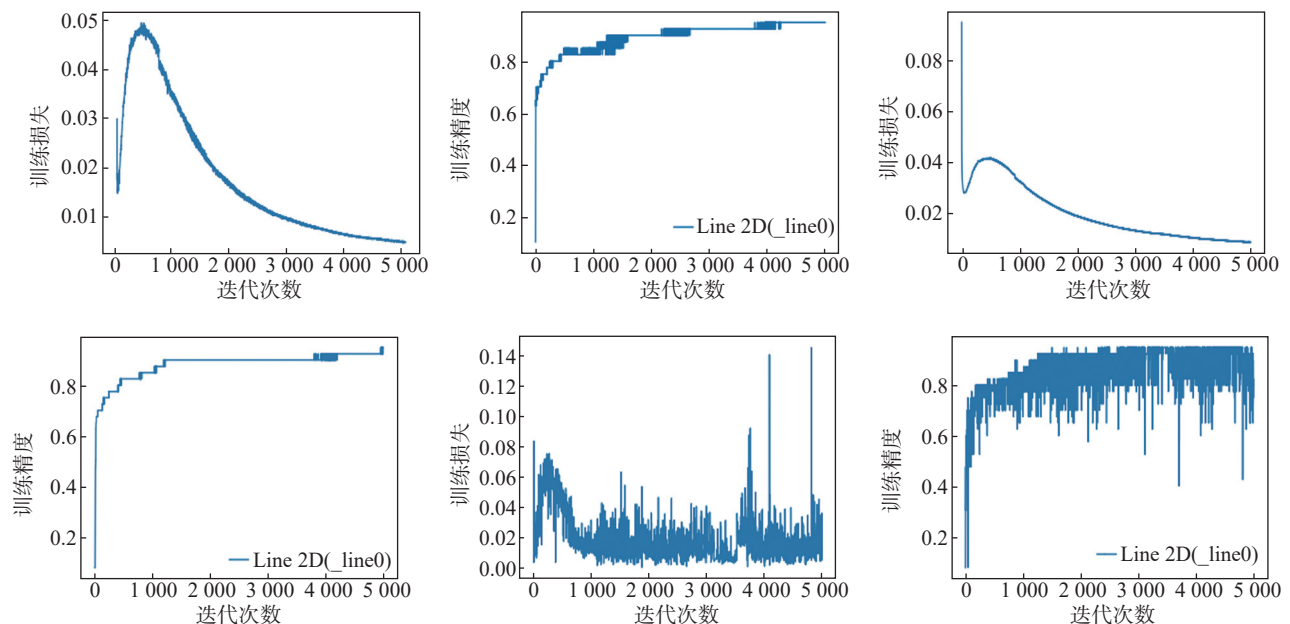


图9 训练结果图

Fig. 9 Graphic of training result

与学习能力,当样本数足够时,对网络的输入向量进行反复多重的训练可以实现更好的效果,使得该网络用于故障程度识别具有极高的准确率。

3 结 论

由于无法提前预知电网故障,优化控制在实时性上无法满足LVRT的控制要求,本文提出将控制参数离线优化,提前考虑所有的故障情况,并制定成一个策略参数表。通过建立DNN网络来进行故障识别,在面对各种故障状态下均可直接从表中选取控制策略和参数。本文基于深度神经网络的低电压穿越方案在一定程度上克服了传统参数优化无法满足实时控制要求的问题,有效改善了DFIG机组的低电压穿越效果。

参考文献:

- [1] 张学广,徐殿国,潘伟明,等. 基于电网电压定向的双馈风力发电机灭磁控制策略[J]. 电力系统自动化,2010,34(7):95-99.
ZHANG X G, XU D G, PAN W M, et al. A flux damping control strategy of doubly-fed induction generator based on the grid voltage vector oriented [J]. Automation of Electric Power Systems, 2010, 34(7): 95-99.
- [2] 杨晨星,杨旭,童朝南. 双馈异步风力发电机低电压穿越的软撬棒控制[J]. 中国电机工程学报,2018,38(8):2487-2495+2558.
YANG C X, YANG X, TONG C N. An LVRT control strategy based on soft crowbar control for doubly fed induction wind power generations [J]. Proceedings of the CSEE, 2018, 38(8): 2487-2495+2558.
- [3] 朱晓东,石磊,陈宁,等. 考虑Crowbar阻值和退出时间的双馈风电机组低电压穿越[J]. 电力系统自动化,2010,34(18):84-89.
ZHU X D, SHI L, CHEN N, et al. An analysis on low voltage ride through of wind turbine driven doubly fed induction generator with different resistances and quitting time of crowbar [J]. Automation of Electric Power Systems, 2010, 34(18): 84-89.
- [4] 郑涛,魏旭辉,李娟,等. PI控制参数对双馈风电机组短路电流特性的影响分析[J]. 电力自动化设备,2016,36(7):15-21.
ZHENG T, WEI X H, LI J, et al. Influence of PI control parameters on short circuit current characteristics of DFIG [J]. Electric Power Automation Equipment, 2016, 36(7): 15-21.
- [5] 谷昱君,聂暘,王东,等. 基于改进免疫遗传算法的双馈风机控制系统PI参数优化[J]. 陕西电力,2016,44(11):25-30.
GU Y J, NIE Y, WANG D, et al. PI parameters optimization of DFIG control system based on improved immune genetic algorithm [J]. Shanxi Electric Power, 2016, 44(11): 25-30.
- [6] 黄琳妮. 基于群飞蛾扑火算法的风力发电系统PI控制参数优化整定[D]. 广州:华南理工大学,2018.
HUANG L N. Optimization of PI control parameters of wind energy system based on swarm moths flame algorithm [D]. Guangzhou: South China University of Technology, 2018.
- [7] 李达,薛卿,孔德健,等. 基于PSO-BP算法的高压输电线路故障分类[J]. 电气自动化,2018,40(6):46-48.
LI D, XUE Q, KONG D J, et al. Fault classification of high voltage transmission line based on PSO-BP algorithm [J]. Electrical Automation, 2018, 40(6): 46-48.
- [8] 马浩森,高勇,杨媛,等. 双馈风力发电低电压穿越撬棒阻值模糊优化[J]. 中国电机工程学报,2012,32(34):17-23+4.
MA H M, GAO Y, YANG Y, et al. Fuzzy optimization of crowbar resistances for low-voltage ride through of doubly-fed induction generators [J]. Proceedings of the CSEE, 2012, 32(34): 17-23+4.
- [9] 王国权. 双馈风力发电系统低电压穿越优化研究[D]. 郑州:华北水利水电大学,2017.
WANG G Q. Study on optimization of low voltage ride through for doubly fed wind power generation system [D]. Zhengzhou: North China University of Water Resources and Electric Power, 2017.
- [10] 贺益康,周鹏. 变速恒频双馈异步风力发电系统低电压穿越技术综述[J]. 电工技术学报,2009,24(9):140-146.
HE Y K, ZHOU P. Overview of the low voltage ride-through technology for variable speed constant frequency doubly fed wind power generation systems [J]. Transactions of China Electrotechnical Society, 2009, 24(9): 140-146.
- [11] 陈豪君. 基于人工智能的双馈风机低电压穿越控制策略研究[D]. 广州:广东工业大学,2020.
CHEN H J. Research on control strategy for low-voltage ride through of double-fed fan based on artificial intelligence [D]. Guangzhou: Guangdong University of Technology, 2020.
- [12] MORREN J, HAAN S W H D. Short-circuit current of wind turbines with doubly fed induction generator [J]. IEEE Transactions on Energy Conversion, 2007, 22(1): 174-180.
- [13] 孔祥平,张哲,尹项根,等. 计及励磁调节特性影响的双馈风力发电机组故障电流特性[J]. 电工技术学报,2014,29(4):256-265.
KONG X P, ZHANG Z, YIN X G, et al. Fault current characteristics of DFIG considering excitation and regulation characteristics [J]. Transactions of China Electrotechnical Society, 2014, 29(4): 256-265.
- [14] 杨健维,麦瑞坤,何正友. PSCAD/EMTDC与Matlab接口研究[J]. 电力自动化设备,2007(11):83-87.
YANG J W, MAI R K, HE Z Y. Interface between PSCAD/EMTDC and Matlab [J]. Electric Power Automation Equipment, 2007(11): 83-87.

- [15] 卫志农, 缪新民, 王华伟, 等. 基于PSCAD-MATLAB联合调用的高压直流控制系统参数优化[J]. 高电压技术, 2014, 40(8):2449-2455.
WEI Z N, MIAO X M, WANG H W, et al. Parameter optimization for HVDC control system based on PSCAD-MATLAB combined invocation [J]. High Voltage Engineering, 2014, 40(8):2449-2455.
- [16] QIAN Y, FAN Y, HU W, et al. On the training aspects of deep neural network(DNN) for parametric TTS synthesis [C]//IEEE. ICASSP 2014-2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Florence, Italy, May 4-9, 2014. Florence: IEEE, 2014: 3829-3833.
- [17] WU Z Z, SWIETOJANSKI P, VEAUX C, et al. A study of speaker adaptation for DNN-based speech synthesis [C]//International Speech Communication Association. Proceedings of Interspeech 2015, Dresden, Germany, Sep. 6-9, 2015. Dresden: International Speech Communication Association, 2015: 879-883.
- [18] 余达. 基于深度学习的风力发电系统故障在线诊断研究[D]. 广州: 华南理工大学, 2018.
YU D. Online fault diagnosis of wind Power systems using deep learning Algorithms [D]. Guangzhou: South China Uni-

versity of Technology, 2018.

作者简介:



余欣梅

余欣梅 (通信作者)

1978-, 女, 浙江衢州人, 高级工程师、注册咨询师, 工学博士, 主要从事能源与电力规划咨询研究的工作 (e-mail) yuxinmei@gedi.com.cn。

陈豪君

1995-, 男, 广东佛山人, 工学硕士, 从事新能源接入及运行控制等研究 (e-mail) 2621344218@qq.com。

王星华

1972-, 男, 江苏扬州人, 副教授, 工学硕士, 从事电力系统高级应用软件开发, 大数据分析、含分布式发电的配电网规划优化研究 (e-mail) 1805211@qq.com。

(责任编辑 李辉)

《南方能源建设》被世界著名检索系统 JST 收录

2021年7月,《南方能源建设》被世界六大著名检索系统之一——日本科学技术振兴机构(JST)数据库(原日本科学技术社数据库)正式收录。日本科学技术振兴机构隶属于日本政府文部科学省的科学技术管理组织,是实施日本“科技立国”战略的核心力量,也是日本最重要的科技信息机构。JST数据库是在日本《科学技术文献速报》的基础上发展起来的网络版,由日本科学技术振兴机构于2007年首次出版。

《南方能源建设》作为唯一聚焦能源建设领域的专业技术期刊,创刊当年即被国内三大权威数据库“中国知网”“万方数据”“维普资讯”收录,先后获评广东省特色科技期刊、中国电力报刊协会优秀期刊。2020年入选中国科学评价研究中心RCCSE准核心学术期刊。近年来,《南方能源建设》不断加大能源战略与规划、清洁能源发电、清洁高效发电、先进输电和智能电网、氢能和储能综合利用、能源经济与市场、水环境与生态治理等研究成果的推广,办刊质量和学术影响力不断提高。此次期刊被JST收录,不仅展示了《南方能源建设》在能源科学技术领域的重要影响力和高学术水平,也将进一步促进我国能源科学技术的国际交流。

《南方能源建设》的进步与发展离不开广大专家、作者和读者的关注与支持!希望在大家的共同努力下,我刊能够更好地为大家服务,更好地发挥交流平台的作用,承担起宣传我国科研工作者学术成果的责任和使命!

(《南方能源建设》编辑部)