Vol.43 No.3 Mar. 2023

考虑暂态波形特征的风电机组高电压脱网 智能故障溯源方法

王玉荣1,朱奕飞2,汤 奕1

(1. 东南大学 电气工程学院,江苏 南京 210096;2. 国网南通供电公司,江苏 南通 226000)

摘要:大规模风电机组高电压脱网会对电力系统的电能质量和安全稳定运行产生影响。提出了一种风电机 组高电压脱网故障溯源方法,后续可配合保护设备以快速切除故障,减少风电机组高电压脱网对系统产生的 影响。首先基于风电机组高电压脱网时输出波形进行特征分析,构造了风电机组高电压脱网故障特征指标 体系;然后采用Gini指数-最大相关最小冗余法对原始指标体系进行筛选,降低了原始指标体系的冗余度;最 后采用遗传算法-蚁群优化算法-粒子群优化算法对BP神经网络的权重、偏差初值进行优化,从而保证BP神 经网络的溯源准确率。在西北电网中进行了算例分析,验证了所提方法的有效性。与传统机器学习方法相 比,所提方法具有更好的故障溯源性能。

 关键词:高电压脱网;故障溯源;指标体系;Gini指数;最大相关最小冗余法;BP神经网络

 中图分类号:TM614
 文献标志码:A
 DOI:10.16081/j.epae.202208035

0 引言

我国风能资源分布不均,整体上与负荷密集地 区在地理上呈逆向分布^[1],西北地区风电基地通常 采用大规模集中开发模式,通过高压直流输电线路 远距离输送到负荷中心^[2]。虽然风电集中式并网使 风能资源得到大规模开发,但是集群风电的并网点 电压支撑能力减弱^[3],易受到外界扰动的影响,从而 引发风电场大规模脱网。例如,2011年2月24日, 甘肃酒泉风电场内的馈线因电缆头击穿而发生三相 短路故障,部分风电机组因低电压保护而脱网后,继 而引发了300台风电机组因高电压保护动作脱网, 系统频率下跌,共计损失出力837 MW^[4]。

目前,由于抑制风电机组高电压脱网(high voltage trip-off, HVTO)的研究和控制手段尚不完 善,近年来风电机组 HVTO事件时见报道^[5-6]。根据 运行数据分析和文献研究,导致风电机组 HVTO的 主要原因可分为以下3类:①风电场中部分风电机 组因短路故障而低电压脱网后,无功补偿设备不能 自动投切,风电场内无功过剩,母线电压升高,最终 导致临近母线的风电机组因高电压保护动作而脱 网^[7];②在发生直流换相失败故障后,直流系统内的 大量无功涌入交流系统,送端母线电压升高,导致临 近母线的风电机组因高电压保护动作而脱网^[8-10]; ③在发生直流闭锁故障后,无功补偿装置和送端交 流电源发出的无功大量盈余,送端母线电压升高,诱

收稿日期:2021-12-01;修回日期:2022-03-01 在线出版日期:2022-10-10

基金项目:中国南方电网公司科技项目(090000KK52190162) Project supported by the Science and Technology Project of China Southern Power Grid(090000KK52190162) 发附近风电机组因高电压保护动作而脱网^[11]。

在风电机组因高电压保护动作脱网后,电网中 的有功出力存在大量缺额,将导致电网的频率跌落, 对电网的稳定运行产生不利影响^[12]。因此,为防止 电力系统发生进一步的连锁故障,需要对风电机组 HVTO故障溯源展开研究,将快速故障溯源结果作 为保护设备筛选故障数据的依据,确定故障源的位 置并做出准确决策,缩小风电机组HVTO规模。

目前,已有的故障溯源方法可以分为2类,即传 统方法和人工智能方法。在传统方法中,文献[13] 通过克拉克变换推导了参数方程,根据该参数方程 计算了电压波形的椭圆值以区分故障源;文献[14] 采用马氏距离来衡量不同故障源相同特征之间的相 关性,从而识别故障源。因高电压保护动作脱网的 风电机组输出波形种类众多,若逐一计算各波形椭 圆值、特征相关性,则运算过于复杂而无法保证溯源 效率。在人工智能方法中,文献[15]根据波形峰值 总结特征指标,基于神经网络进行故障源识别;文献 [16] 根据电压波形提出特征指标,基于支持向量机 (support vector machine, SVM)进行故障溯源;文献 [17]提出时域与频域相结合的特征指标,基于极限 学习机进行故障源识别。相比于传统故障溯源方 法,人工智能方法无需复杂运算,通过特征指标对分 类器进行训练即可得到良好的溯源性能。

本文对HVTO风电机组的输出有功、输出无功、 机端电压、机端电流、暂态电势的局部波形进行了深 入分析,从波形峰值、斜率、面积、偏度、峭度等方面 构建了能反映不同故障下HVTO风电机组特性的指 标体系。由于原始指标体系存在冗余度,基于Gini 指数-最大相关最小冗余(Gini index and maximum relevance minimum redundancy, Gini-mRMR)法简化 原始指标体系,得到特征指标集。BP神经网络的故 障溯源性能依赖于权重、偏差初值选取^[18],基于遗传 算法-蚁群优化算法-粒子群优化算法(genetic algorithm, ant colony optimization algorithm and particle swarm optimization algorithm, GA-ACO-PSO)对 BP 神经网络的权重、偏差初值进行了优化。最后,采用 经过改良的 BP神经网络对风电机组 HVTO故障进 行了溯源,验证所提方法的有效性。

1 风电机组HVTO故障特征指标体系构造

1.1 各故障场景下的 HVTO 风电机组输出波形分析

因高电压保护动作而脱网的风电机组可量测量 分为电气量和机械量。电气量包括有功功率、无功 功率、机端电压、机端电流,机械量包括转子速度、风 轮转速、桨距角、机械功率。由于暂态过程持续时间 短,机械量变化没有电气量变化明显,本文着重分析 电气量波形特征以构建指标体系,并在分析中加入 暂态电势电气量。暂态过程电气量波动示意图如图 1所示,该波形存在多个波峰和波谷,波形时而陡 峭,时而平缓。





Fig.1 Schematic diagram of electrical variable fluctuation during transient process

为准确描述暂态过程电气量的波形特性,需要 从以下几个方面进行综合表征:通过波形峰值来衡 量波形变化剧烈程度;通过局部波形斜率最大值来 衡量波形变化速度;通过设定1个基准值以截取该 波形突出部分,计算出这部分的面积来衡量波形突 变程度及持续的时间;通过局部波形的偏度来衡 量波形对称性;通过局部波形的峭度来衡量波形陡 峭程度。根据图1总结得到的波形特征指标如式 (1)—(8)所示。

以F₁表示波形突变程度,其表达式为:

$$F_{1} = \left(y(t)_{\text{max}} - y(t)_{\text{min}} \right) / y_{\text{nom}}$$
(1)

式中: $y(t)_{max}$, $y(t)_{min}$ 分别为波形的最高值、最低值; y_{mm} 为选定的基准值。

以F,表示波形峰值之和,其表达式为:

$$F_2 = \sum_{\alpha=1}^{F_1} y(t)_{\max}^{\alpha}$$
(2)

式中: F_t 为波峰总数; $y(t)_{max}^{\alpha}$ 为波形的第 α 个峰值。

以 F₃表示波形偏离基准值部分的面积,其表达 式为:

$$F_{3} = \sum_{l=1}^{L} \left| y(l\Delta t) - y_{\text{nom}} \right| \Delta t$$
(3)

式中: $y(l\Delta t)$ 为第l个采样点对应值, Δt 为采样间隔; L为采样点总数。

以 F₄表示局部波形的斜率最大值,其表达式为:

$$F_{4} = \max_{1 \le l \le L} \left\{ \left| y\left((l+1)\Delta t \right) - y\left(l\Delta t \right) \right| / \Delta t \right\}$$
(4)

式中:max{·}为最大值函数。

以F₅表示波形的标准差,其表达式为:

$$\begin{cases} \overline{y} = \frac{1}{L} \sum_{l=1}^{L} y(l\Delta t) \\ F_5 = \sqrt{\frac{1}{L} \sum_{l=1}^{L} (y(l\Delta t) - \overline{y})} \end{cases}$$
(5)

以F₆表示波形的偏度,其表达式为:

$$F_{6} = \sum_{l=1}^{L} \left(y \left(l \Delta t \right) - \bar{y} \right)^{3} / \left[(L-1) F_{5}^{3} \right]$$
(6)

以F₇表示波形的峭度,其表达式为:

$$F_{7} = \sum_{l=1}^{L} \left(y \left(l \Delta t \right) - \bar{y} \right)^{4} / \left[(L-1) F_{5}^{4} \right]$$
(7)

以F₈表示波形的平均斜率,其表达式为:

$$\begin{cases} \overline{k}_{i'} = \sum_{l=1}^{L_{i'}} \frac{\left| y\left((l+1)\Delta t \right) - y\left(l\Delta t \right) \right|}{\Delta t} \\ F_8 = \sum_{i'=1}^{m'} \overline{k}_{i'} / m' \end{cases}$$
(8)

式中:m'为图1中基准线与波形围成的封闭区间个数;L_i为第i'个封闭区间内包含的采样点个数。

基于电力系统分析综合程序(power system analysis synthesis program, PSASP)暂态稳定功能, 对风电机组 HVTO 故障场景进行批量仿真,总结分析了多种电气量暂态过程波形的典型特性,并将其应用于所提出的波形特征体系,构造出故障特征指标体系。风电机组 HVTO 故障场景参数设定如下:风电机组类型选定为双馈异步风电机组;直流输电线路两端无功补偿容量均为1000 Mvar;换相失败故障、直流闭锁故障或短路故障发生于 0.2 s,短路故障时间持续 0.2 s。下面分别对 HVTO 风电机组输出的有功、无功、机端电压、机端电流和暂态电势进行分析。

1.2 HVTO风电机组的输出有功典型波形分析

风电机组的有功功率在故障发生后的损失值反 映了不同故障对风电机组造成的出力损失,而有功 功率在故障后的变化反映了不同故障对风电机组产 生的影响特性。

在换相失败、直流闭锁、短路故障下的HVTO风 电机组输出有功功率波形变化分别如图2和附录A 图 A1、A2 所示,图中风电机组有功出力 P 及其初始 值P。均为标幺值。在以上3种故障下HVTO风电机 组输出的有功波形中,以2条水平虚线表示暂态过 程中波形的变化范围, 左、右2条垂直虚线分别表 示故障开始时刻和风电机组脱网时刻。对4条虚线 所截取故障发生后的波形展开局部波形分析,可以 看出:①换相失败故障下HVTO风电机组输出有功 波形先衰减到最低值,后逐渐上升到最高值而切机; ②直流闭锁故障下,HVTO风电机组输出有功波形 多呈现小幅波动后再剧烈升高的波动过程,这是由 于该故障下机端电压波形会出现短时升高,进而会 导致风电机组输出有功呈现明显升高趋势,而后由 于高电压保护动作,风电机组的输出有功因切机时 刻不同呈现有一定差异的波动过程,从故障持续时 间上看,相较于换相失败故障下的HVTO风电机组输 出有功波形,其持续时间更短:③短路故障下HVTO 风电机组输出有功波形多为先衰减到最低值,而后 逐渐上升至最高值而切机。



图 2 换相失败故障下HVTO风电机组输出有功典型波形 Fig.2 Typical waveforms of output active power of HVTO wind turbines under commutation failure fault

根据以上分析,可从波形突变程度、峰值、面积、 局部斜率、标准差、偏度、峭度这7个方面对风电机 组HVTO过程的有功波形进行刻画。

1.3 HVTO风电机组的输出无功典型波形分析

风电机组暂态期间的无功功率与过电压水平呈 正相关关系,无功功率变化能够反映不同故障对风 电机组过电压水平产生的影响大小。

在换相失败、直流闭锁、短路故障下的 HVTO 风电机组输出无功功率波形变化分别如附录 A 图 A3—A5所示。不同故障下的无功功率波形突变、陡 峭程度不同,在故障发生之后的无功功率波形持续 时间存在差异,波形走向也各不相同。在3种故障 下的 HVTO 风电机组输出无功功率典型波形中,对 4条虚线截取的故障发生之后的波形展开局部波形 分析可以发现:①换相失败故障下 HVTO 风电机组 输出无功波形逐渐上升到最高值而切机,其无功平 均增长率范围为[0.005,0.008] p.u./ms;②直流闭 锁故障下HVTO风电机组输出无功波形多为逐渐衰 减到最低值而切机,其无功平均衰减率范围为 [0.002,0.014] p.u./ms,可见,直流闭锁故障与换相 失败故障下的HVTO风电机组输出无功波形变化特 征相反,且衰减变化范围更大;③短路故障下HVTO 风电机组输出无功波形分2种情况,一种是无功逐 渐上升到最高值而切机,另一种是先上升到最高值 再衰减到最低值而切机。

综上,3种故障下风电机组HVTO过程的无功波 形在突变程度、峰值、面积、局部斜率、标准差、偏度、 峭度7个方面存在差异,可借以进行特征刻画。

1.4 HVTO风电机组的机端电压典型波形分析

风电机组的机端电压是其出线端子上的实际电 压,暂态期间的机端电压变化能够反映不同故障造 成风电机组过电压的动态特性。

在换相失败、直流闭锁、短路故障下的HVTO风 电机组机端电压波形变化分别如附录A图A6—A8 所示。不同故障下的机端电压波形的波峰和波谷分 布也不相同,而波峰反映了HVTO风电机组的机端 电压突变程度。在3种故障下的HVTO风电机组机 端电压波形中,暂态过程波形分析如下:①换相失败 故障下HVTO风电机组机端电压波形先衰减到最低 值,后又逐渐增大到最高值而切机;②直流闭锁故障 下HVTO风电机组机端电压波形逐渐上升到最高值 而切机;③短路故障下HVTO风电机组机端电压逐 渐衰减到最低值并持续一段时间,然后逐渐上升至 最高值而切机。

3种故障下 HVTO 风电机组机端电压变化特征 分明,不需要使用过多的特征方面描述,故从突变程 度、峰值、面积、平均斜率4个方面进行特征刻画。

1.5 HVTO风电机组的机端电流典型波形分析

在换相失败、直流闭锁、短路故障下的HVTO风 电机组机端电流波形变化分别如附录A图A9—A11 所示。不同故障下的机端电流波形突变、陡峭程度 各不相同,在故障发生后的波形持续时间也各异。

在3种故障下的HVTO风电机组机端电流波形中,暂态过程中波形特征分析如下:①换相失败故障下的HVTO风电机组机端电流波形逐渐增大到最高值而切机,其机端电流平均增长率范围为[0.0008,0.0016] p.u./ms;②直流闭锁故障下的HVTO风电机组机端电流波形多为逐渐衰减到最低值而切机,机端电流平均衰减率范围为[0.0007,0.0032] p.u./ms;③短路故障下的HVTO风电机组机端电流波形分为2种情况,一种为机端电流逐渐衰减后又爬升到最高值而切机,另一种为逐渐上升到最高值再衰减而切机。

由此可知,3种故障下风电机组HVTO过程的机 端电流波形峰值、面积、平均斜率方面存在显著差 异,借助此3个方面能够刻画其波动特征。

1.6 HVTO风电机组的暂态电势典型波形分析

风电机组的暂态电势在故障发生后的波动变化 大且过渡时间短,能够反映不同故障对风电机组的 影响特性。

在换相失败、直流闭锁、短路故障下的HVTO风 电机组暂态电势波形变化分别如附录A图A12— A14所示。不同故障下的暂态电势波形凹陷程度和 变化速度各不相同,达到波峰所需时间也不同。由 3种故障下的HVTO风电机组暂态电势波形可以看 出:①换相失败故障下的HVTO风电机组暂态电势 波形多为先衰减到最低值,后又逐渐上升至最高值 而切机;②直流闭锁故障下的HVTO风电机组暂态 电势波形分为2种情况,一种为暂态电势波形逐渐 下降到最低值而切机,另一种为逐渐增大到最高值 而切机;③短路故障下的HVTO风电机组暂态电势 波形变化分为2种情况,一种为先上升至最高值后 逐渐衰减而切机,另一种为先衰减至最低值再逐渐 上升至最高值而切机。

根据以上波形分析,直流闭锁和短路故障过程中,HVTO风电机组暂态电势波动均有2种典型情况,但其变化过程的剧烈程度不同。故从波形的面积、平均斜率方面刻画特征,从而快速区分3种故障下风电机组HVTO过程的暂态电势波形。

基于以上在不同故障下的HVTO风电机组典型 波形分析,形成了风电机组HVTO故障特征指标体 系,共包含23个指标,总结如表1所示。表中:"√"表 示电气量需通过该波形特征指标刻画,即存在故障 特征指标;"×"表示电气量无需通过该波形特征指标 刻画,即不存在故障特征指标。

表1 风电机组HVTO故障特征指标体系

Table 1 Index system of fault identification for HVTO wind turbines

电气量	F_{1}	F_2	F_3	F_4	F_5	F_{6}	F_7	F_8
有功功率	\checkmark	×						
无功功率	\checkmark	×						
机端电压	\checkmark	\checkmark	\checkmark	×	×	×	×	\checkmark
机端电流	×	\checkmark	\checkmark	×	×	×	×	\checkmark
暂态由垫	×	×	\checkmark	×	×	×	×	\checkmark

2 HVTO故障特征指标体系筛选

基于 N 台 HVTO 风电机组输出数据,根据公式 计算所提 23 个故障特征指标并汇总于指标集 X。以 y_i =1,2,3(1 $\leq i \leq N$)分别对应第 i台 HVTO 风电机组 所发生的故障类别为直流换相失败故障、直流闭锁 故障、短路故障,将导致每台风电机组 HVTO 的故障 类别汇总为故障类别集 $Y=\{y_i\}$ 。最后,将指标集X与故障类别集Y存储到数据集S中, $S=\{X, Y\}$ 。

由于所构建的指标体系数量众多,在反映故障特征上存在不同程度的冗余。若将数据集S用于故障溯源,则会增加BP神经网络的训练时间,并影响故障溯源精度。因此,需要对原始指标体系进行筛选,而Gini指数、mRMR法具有良好的特征指标筛选性能。

2.1 基于Gini指数的故障特征指标重要度计算

1984年布莱曼等人提出了 Gini 指数并将其应 用于决策树算法中。Gini 指数是一种不纯度分裂方 法,对于所建立的 HVTO 风电机组故障特征指标体 系,可用于衡量各指标描述故障特征的重要度。基 于 Gini 指数的故障特征指标筛选过程如下。

首先将所建立的故障特征指标体系数据集*S*按 照第t(t=1,2,...,23)个指标划分成q个数据子集, S'_j 表示该指标中第j(j=1,2,...,q)个数据子集,则第t个指标的重要度 V_t 如式(9)所示。

$$V_{t} = \sum_{j=1}^{q} \frac{N_{j}^{t}}{24N} \lambda_{\text{Gini}} \left(S_{j}^{t}\right)$$

$$\tag{9}$$

式中: N_{i}^{t} 为数据子集 S_{i}^{t} 的样本数; $\lambda_{Gini}(S_{i}^{t})$ 为数据子 集 S_{i}^{t} 的Gini指数,其计算过程如式(10)所示。

$$\begin{cases} \operatorname{Gini}(S_{j}^{t}) = 1 - \sum_{y_{i}=1}^{3} (p_{j,y_{i}}^{t})^{2} \\ p_{j,y_{i}}^{t} = \frac{m_{j,y_{i}}^{t}}{N_{j}^{t}} \quad m_{j,y_{i}}^{t} = 0, 1, \cdots, N_{j}^{t} \end{cases}$$
(10)

式中: $m'_{j,y}$ 为数据子集 S'_{j} 中故障类别 y_{i} 下的样本数; $p'_{i,y}$ 为数据子集 S'_{i} 中故障类别 y_{i} 下的样本概率。

在计算出所有指标的重要度之后,由小到大进 行排序,根据设定的特征指标个数,获得相应特征指 标。需要注意的是,Gini指数虽然能够衡量各指标 对于故障溯源的重要性,但是不能评估指标冗余度。 因此,仅通过Gini指数筛选得到的特征指标仍存在 冗余。

2.2 mRMR法

为降低所构建的风电机组 HVTO 故障特征指标 体系,结合 mRMR 法进行滤波式特征选择^[19]。该算 法以互信息(mutual information,MI)来衡量2个指标 间的相似度或指标与故障类别间的相关性。互信息 I(x; y)的表达式为:

$$I(x;y) = \sum_{x} \sum_{y} p(x,y) \lg \frac{p(x,y)}{p(x)p(y)}$$
(11)

式中:x表示任一指标;y表示除x外的任一指标或故 障类别;p(x,y)表示联合分布;p(x)为指标x发生的 概率;p(y)表示指标y或故障类别y发生的概率。 根据式(11),变量x的取值范围越广,I(x; y)越大,即互信息取值易偏向于取值范围广的变量。采 用互信息的对称不确定性(symmetrical uncertainty, SU)来克服互信息量的这一缺陷。变量x,y的SU值 $S_{u}(x,y)$ 的计算式为:

$$\begin{cases} S_{U}(x, y) = \frac{2I(x; y)}{H(x) + H(y)} \\ H(x) = \sum_{x} p(x) \lg p(x) \\ H(y) = \sum_{y} p(y) \lg p(y) \end{cases}$$
(12)

式中:H(x)、H(y)分别为变量x、y的边缘熵。

根据设定的特征指标个数,mRMR法求取相应 特征指标的规则如式(13)所示。

$$\begin{cases} Z = \max \{ D - R \} \\ D = \frac{1}{m} \sum_{x_d \in F} S_{\mathrm{U}}(x_d, Y) \\ R = \frac{1}{m^2} \sum_{x_d, x_f \in F} S_{\mathrm{U}}(x_d, x_f) \end{cases}$$
(13)

式中:D表示特征指标集F与故障类别集Y间的相 关性;R表示特征指标集F的冗余度; $m(1 \le m \le 23)$ 表示特征指标集F中的元素总数; $x_d(d=1, 2, \dots, m)$ 、 $x_f(f=1, 2, \dots, m, f \ne d)$ 分别表示特征指标集F中的 第d、f个特征指标。根据所得Z值,进而确定相应 的特征指标。

需要指出的是,特征指标集F中的样本是通过 枚举法得到的。因此,基于mRMR法筛选特征指标 的计算量随着原始指标个数增加而呈几何倍数增 长。为此,需要提出改进的特征指标筛选方法。

2.3 基于Gini-mRMR法的特征指标筛选方法

考虑到Gini指数无法评估指标冗余度及基于 mRMR法筛选特征指标的计算量缺陷,本节提出了 一种基于Gini-mRMR法的特征指标筛选方法,以发 挥这2种方法对故障特征提炼与筛选的优点,过程 如下。

1)基于Gini指数计算各指标的重要度。

2)根据重要度对指标集*X*中的指标进行排序, 选取前*n*(1≤*n*≤23)个指标作为特征指标并存储 到*X*′中。

3)将特征指标集 F 初始化为空集,即 F 中的特征指标个数 k 初始化为0,记迭代次数 u=1。

4)计算*X*'中各指标与故障类别集*Y*各指标间的 $S_{v}(x, y)$,选择使 $S_{v}(x, y)$ 取最大值的指标作为*F*中的 第1个特征指标并记为 $x_{*}^{"}$,即*F*={ $x_{*}^{"}$ }。

5)将指标 x["]_u 从 X'中去除,记 k=1,用于记录第 u 次迭代中筛选得到的特征指标个数。

6) 根据式(14) 计算 X' 中第 l'(l'=1, 2, …, n-k)

个指标 $x'_{l'}$ 的 $A^{(l)}$ 值,令迭代次数u=u+1。

$$A^{(l')} = S_{\mathrm{U}}(x_{l'}, Y) - \frac{1}{k} S_{\mathrm{U}}(x_{l'}, x_{i'}')$$
(14)

7)将使 $A^{(t')}$ 取最大值的指标 $x'_{t'}$ 存储到F中并记 为 x''_{u} ,即 $F=\{F, x''_{u}\}$ 。

8)将指标x'r从X'中去除,令k=k+1。

9)如果*k*≤*m*,则返回至步骤6),否则特征指标筛选结束。

3 基于 BP 神经网络的 HVTO 故障溯源

3.1 BP神经网络权重更新方法

BP神经网络包括输入层、隐含层、输出层,附录 A图A15为BP神经网络的结构示意图。BP神经网 络的信号向前传播,而误差反向传播。因此,能够在 每次迭代中调整权重、偏差,对非线性问题具有良好 的自学习和自适应能力^[20-22]。虽然BP神经网络能 够通过误差反向传播来更新权重和偏差,但是权重、 偏差初值选取不当,导致收敛速度过慢,使得BP神 经网络训练时间过长。目前,常用的优化算法有遗 传算法(genetic algorithm,GA)、蚁群优化算法(ant colony optimization algorithm,PSO)等。

3.2 基于改进 BP 神经网络的故障溯源流程

基于上述建立的指标体系及指标筛选方法,本 节结合GA和ACO的全局寻优能力及PSO的局部寻 优能力,提出了一种基于GA-ACO-PSO的BP神经网 络参数优化方法。将GA的优化结果作为ACO的初 始条件,增强ACO初期信息素,提高蚁群初期寻优 速度;针对蚁群后期局部寻优缓慢的问题,采用局部 寻优能力强的PSO进一步寻优,加快寻优结果趋于 最优。流程见附录A图A16。

GA、ACO、PSO中的适应度函数如式(15)所示。

$$f = \frac{1}{M} \sum_{\theta=1}^{M} \left(\hat{\lambda}_{\theta} - \lambda_{\theta} \right)^2 \tag{15}$$

式中: $\hat{\lambda}_{\theta}$ 、 λ_{θ} 分别为经过BP神经网络训练的样本 θ 下 所输出的风电机组HVTO故障类别预测值、期望值; M为用于BP神经网络训练的样本总数。

本文采用5折交叉验证策略划分训练样本和测试样本,将数据集S打乱后平均分为5份,取其中的4份作为训练样本,剩余的1份作为测试样本,共有5种训练样本选法。在确定完训练样本、测试样本之后,先将训练样本输入BP神经网络的权重、偏差初值进行优化,完成BP神经网络的训练。然后,将测试样本输入经过训练的BP神经网络中,获得故障溯源准确率。最后,将5次故障溯源准确率取平均值,作为基于改进BP神经网络的故障溯源准确率。算法流程如图3所示,图中K为交叉验证次数。





4 算例分析

算例基于西北电网的局部区域展开分析。该区域包含1条直流输电线路、15座风电场以及2座火电厂。风电机组采用了低电压穿越策略,风电机组高电压保护的阈值设定为1.15 p.u.,具体接线形式如附录A图A17所示。

为了验证本文所提风电机组 HVTO故障溯源方 法的有效性,本节算例的内容主要分为:①基于故障 场景仿真得到原始指标数据样本,确定 BP神经网络 的输入层、隐含层、输出层神经元个数;②通过 GinimRMR法约简原始特征指标体系,再训练 BP神经网 络,汇总以及分析故障溯源结果;③基于不同特征指 标个数进行故障溯源,对比分析各组故障溯源结果; ④基于传统人工智能方法得到故障溯源结果,与本 文所提方法的故障溯源结果进行对比;⑤调整 BP神 经网络参数优化策略,得到故障溯源结果,与本文所 提方法的结果进行对比。

4.1 样本构造及 BP 神经网络结构选定

在 PSASP 暂态稳定仿真中,本文分别设定换相 失败、直流闭锁、短路故障这3种典型的场景,汇总 了 500组因高电压保护动作而脱网的风电机组有功 功率、无功功率、机端电压、机端电流、暂态电势波形 数据,其中有 150组数据来源于换相失败故障导致 HVTO的风电机组,150组数据来源于直流闭锁故障 导致 HVTO 的风电机组,剩余的 200组数据来源于 短路故障导致HVTO的风电机组。基于1.2—1.6节 所提指标体系,计算得到指标集X,该指标集与其对 应的故障类别集Y合并后,存储为数据集S。针对原 始数据集,基于Gini-mRMR法对原始指标体系进行 简化,筛选后特征指标个数为16。

BP神经网络的输入层神经元个数与经过筛选的特征指标个数 ϕ 相等,BP神经网络的隐含层数为1,隐含层包含的神经元个数为2 ϕ +1,BP神经网络的输出层神经元个数为3。为使故障类别与BP神经网络的输出层神经元个数相对应,将 y_i =1替换为 y_i ={001}以表示换相失败故障,类似地, y_i ={010}表示直流闭锁故障, y_i ={100}表示短路故障。

4.2 基于GA-ACO-PSO的故障溯源结果分析

基于所筛选出的16个特征指标,利用GA-ACO-PSO对BP神经网络权重、偏差初值寻优时个体最优 适应度变化曲线如图4所示。由图可知,当迭代次 数的变化区间为[1,20]时,最优个体适应度下降比 较快,这是因为GA具有较强的全局寻优能力;当迭 代次数的变化区间为[21,80]时,虽然最优个体适应 度下降比较平缓,但是ACO具有维持解在最优区域 的能力;当迭代次数的变化区间为[81,100]时,最优 个体适应度仍能有所下降,体现了PSO的局部寻优 能力。



图4 基于GA-ACO-PSO的个体最优适应度变化曲线 Fig.4 Individual optimal fitness varying curve based on GA-ACO-PSO

设 BP 神经网络的迭代次数为 100, 训练误差为 0.01, 学习率为 0.1。经过 BP 神经网络训练, 使得训 练样本的准确率达到 96%。然后, 将测试样本输入 经过训练的 BP 神经网络中, 得到基于 BP 神经网络的 风电机组 HVTO 故障溯源准确率。经过 1次5 折交 叉验证, 得到如附录 A 表 A1 所示的风电机组 HVTO 故障溯源结果。在本次风电机组 HVTO 故障溯源 中, 150 组换相失败故障溯源结果正确的有 145 组 (错误 5 组); 150 组直流闭锁故障溯源结果正确的有 145 组(错误 9 组); 200 组短路故障溯源结果正确的 有 189 组(错误 11 组)。风电机组 HVTO 故障溯源的 整体准确率达到了 95%, 证明了所提方法能够有效 区分导致风电机组 HVTO 的故障源。

将5折交叉验证重复30次,得到如图5所示的 风电机组HVTO故障溯源准确率变化曲线。由图可 知,30次风电机组HVTO故障溯源准确率平均值为 94.7%,对应的标准差为0.14%;单次故障溯源准确 率与平均值之差最大值为0.3%,单次故障溯源准确 率与平均值之差最低值为0.1%。因此,本文方法在 进行故障溯源时具有较强的鲁棒性。



图 5 基于 30 次 5 折交叉验证的风电机组 HVTO 故障溯源准确率

Fig.5 HVTO fault source identification accuracy of wind turbines based on 5-fold cross validation for 30 times

4.3 特征指标筛选对故障溯源精度的验证

为考察特征指标筛选方法的有效性,当选取不同个数的特征指标时,基于所提风电机组HVTO故障溯源方法,重复进行30次5折交叉验证,计算了不同特征指标下的风电机组HVTO故障溯源准确率平均值,如图6所示。由图可见:当特征指标个数为16时,基于本文方法进行故障溯源的准确率平均值最高;但是,继续增大特征指标个数或缩小特征指标个数时,故障溯源准确率均呈下降趋势。



图 6 基于不同特征指标个数的风电机组 HVTO 故障溯源准确率

Fig.6 HVTO fault source identification accuracy of wind turbines based on changing number of feature indices

经过筛选得到的16个特征指标如表2所示。由 表可知,经过Gini-mRMR法筛选的特征指标保留了 电气量与故障类别之间的强相关特性,同时减少了 指标间的冗余程度;另外,保留下来的16个特征指 标较好地综合反映了3种故障下波形的局部差异。

表2 基于Gini-mRMR法的特征指标筛选结果

Table 2 Screening result of feature indices by Gini-mRMR method

电气量	F_2	F_3	F_4	F_{6}
有功功率	\checkmark	\checkmark	\checkmark	\checkmark
无功功率	\checkmark	\checkmark	\checkmark	\checkmark
机端电压	\checkmark	\checkmark	\checkmark	×
机端电流	\checkmark	×	\checkmark	×
暂态电势	\checkmark	\checkmark	\checkmark	×

4.4 传统机器学习算法与所提算法精度对比分析

选定特征指标个数为16,基于SVM、决策树、GA-BP神经网络、ACO-BP神经网络、PSO-BP神经网络、PSO-BP神经网络进行风电机组HVTO故障溯源,重复进行30次5 折交叉验证,将溯源结果与本文所提基于GA-ACO-PSO-BP神经网络的故障溯源结果进行对比,分析 如下。

基于 SVM、决策树 2种机器学习方法的 30次故 障溯源准确结果如附录 A表 A2所示。基于 GA-ACO-PSO-BP 神经网络的故障溯源准确率最大值为 95%, 最小值为 94.6%,平均值为 94.7%,相比于 SVM、决 策树,其故障溯源性能更稳定,溯源精度更高,验证 了本文方法的有效性。

基于GA-BP神经网络、ACO-BP神经网络、PSO-BP神经网络30次故障溯源准确结果如附录A表A3 所示。分别从准确率最大值、准确率最小值、准确率 平均值这3个方面进行排序,基于GA-BP神经网络 的风电机组HVTO故障性能优于其余2种方法。

由以上分析可知,从准确率最大值、准确率最小 值、准确率平均值3个方面来看,基于GA-ACO-PSO-BP神经网络的故障溯源性能优于基于GA-BP、ACO-BP、PSO-BP神经网络。

5 结论

本文提出了一种考虑暂态波形特征的风电机组 HVTO智能故障溯源方法。通过对风电机组输出波 形分析,构建了风电机组HVTO故障特征指标体系。 基于Gini-mRMR法对原始指标体系进行筛选,采用 经过GA-ACO-PSO优化的BP神经网络进行风电机 组HVTO故障溯源,在西北电网中进行了算例分析。 得到如下结论:①基于选取不同个数的特征指标进 行故障溯源,验证了本文所提Gini-mRMR法既能有 效降低原始特征指标体系的冗余度,又保留了与故 障类别相关性强的特征指标;②采用GA-ACO-PSO 对BP神经网络的权重、偏差初值进行了优化,使得 BP神经网络得到了充分的训练,提高了故障溯源精 确度;③重复30次5折交叉验证了所提故障溯源方 法的鲁棒性,表明本文所提故障溯源算法具有良好 的溯源精度。

在已有 HVTO 风电机组数据样本的基础上,所 提算法对于每起故障的识别时间为毫秒级,能够从 数据分析上感知系统发生风电机组 HVTO 的态势和 故障源。后续研究将进一步对引发风电机组 HVTO 的故障过程进行预判和态势分析,对新能源高比例 接入电力系统的连锁故障溯源进行更深入的分析。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

[1]赵宏博,姚良忠,王伟胜,等. 大规模风电高压脱网分析及协调

预防控制策略[J]. 电力系统自动化,2015,39(23):43-48,65. ZHAO Hongbo,YAO Liangzhong,WANG Weisheng, et al. Outage analysis of large scale wind power under high voltage condition and coordinated prevention and control strategy[J]. Automation of Electric Power Systems,2015,39(23):43-48,65.

[2] 王熙纯,刘纯,林伟芳,等.风机故障穿越特性对大规模风电直 流外送系统暂态过电压的影响及参数优化[J].电网技术,2021, 45(12):4612-4621.

WANG Xichun, LIU Chun, LIN Weifang, et al. Influence of wind turbine fault ride-through characteristics on transient overvoltage of large-scale wind power DC transmission systems and parameter optimization[J]. Power System Technology, 2021,45(12):4612-4621.

[3] 庄希瑞.风电脱网对区域电力系统稳定性影响的研究[D].广州:华南理工大学,2016.
 ZHUANG Xirui. Studies on the stability of regional power

system with trip-off accidents of wind power[D]. Guangzhou: South China University of Technology, 2016.

- [4] 贺静波,庄伟,许涛,等. 暂态过电压引起风电机组连锁脱网风 险分析及对策[J]. 电网技术,2016,40(6):1839-1844.
 HE Jingbo,ZHUANG Wei,XU Tao,et al. Study on cascading tripping risk of wind turbines caused by transient overvoltage and its countermeasures[J]. Power System Technology, 2016, 40(6):1839-1844.
- [5] 詹锦,陈波,熊永新,等.利用调相机提升送端双馈风机高电压 穿越能力的协调控制[J].电力系统保护与控制,2020,48 (18):59-68.
 ZHAN Jin,CHEN Bo,XIONG Yongxin, et al. Coordinated control for improving the HVPT complifience of a DEEC wind form

trol for improving the HVRT capability of a DFIG wind farm using a synchronous condenser [J]. Power System Protection and Control, 2020, 48(18):59-68.

- [6] WANG Yurong, ZHU Yifei, WANG Qi, et al. Complex fault source identification method for high-voltage trip-offs of wind farms based on SU-MRMR and PSO-SVM[J]. IEEE Access, 2020,8:130379-130391.
- [7] 杜维柱,罗亚洲,李蕴红,等.风电汇集系统无功盈余导致暂态 过电压问题的研究综述[J].中国电机工程学报,2022,42(9): 3224-3239.

DU Weizhu, LUO Yazhou, LI Yunhong, et al. Reviews of transient overvoltage problem cause by extra reactive power in large scale wind power systems[J]. Proceedings of the CSEE, 2022,42(9):3224-3239.

[8] 赵学明.换相失败对含风电场的交直流混联系统过电压影响的研究[D].天津:天津大学,2018.
 ZHAO Xueming. Study on the influence of commutation fai-

lure on the overvoltage of AC / DC hybrid power system with wind $farms[\,D\,].$ Tianjin:Tianjin University,2018.

 [9] 崔晓丹,吴家龙,雷鸣,等.新能源高占比电力系统的连锁故障 诱因及事故链搜索技术探讨[J].电力自动化设备,2021,41
 (7):135-143.
 CUI Xiaodan, WU Jialong, LEI Ming, et al. Discussion on in-

ducement and fault chain search technology of cascading failure in power system with high penetration of renewable energy [J]. Electric Power Automation Equipment,2021,41(7):135-143.

[10] 陈厚合,鲁华威,王长江,等.抑制直流送端系统暂态过电压的 直流和风电控制参数协调优化[J].电力自动化设备,2020,40 (10):46-55.

CHEN Houhe, LU Huawei, WANG Changjiang, et al. Coordinated optimization of HVDC and wind power control parameters for mitigating transient overvoltage on HVDC sendingside system[J]. Electric Power Automation Equipment, 2020, 40(10):46-55.

[11]朱丽萍,刘文颖,邵冲,等. 基于调相机与SVC协调的抑制高压

直流送端风机脱网的控制策略[J]. 电力自动化设备,2021,41 (6):107-115.

ZHU Liping,LIU Wenying,SHAO Chong, et al. Control strategy of suppressing wind turbine tripping based on coordination between synchronous condenser and SVC in sending-end network of HVDC[J]. Electric Power Automation Equipment, 2021,41(6):107-115.

- [12] 屠竞哲,张健,刘明松,等.考虑风机动态特性的大扰动暂态过 电压机理分析[J].电力系统自动化,2020,44(11):197-205.
 TU Jingzhe, ZHANG Jian, LIU Mingsong, et al. Mechanism analysis of transient overvoltage with large disturbance considering dynamic characteristics of wind generator[J]. Automation of Electric Power Systems, 2020, 44(11): 197-205.
- [13] CAMARILLO-PEÑARANDA J R, RAMOS G. Characterization of voltage sags due to faults in radial systems using threephase voltage ellipse parameters [J]. IEEE Transactions on Industry Applications, 2018, 54(3): 2032-2040.
- [14] 肖先勇,崔灿,汪洋,等. 电压暂降分类特征可比性、相关性及 马氏距离分类法[J]. 中国电机工程学报,2015,35(6):1299-1305.

XIAO Xianyong, CUI Can, WANG Yang, et al. Comparability and relevance of voltage sag classifying features and classification methods based on Mahalanobis distance [J]. Proceedings of the CSEE, 2015, 35(6):1299-1305.

[15] 尹柏强,何怡刚,朱彦卿.一种广义S变换及模糊SOM网络的 电能质量多扰动检测和识别方法[J].中国电机工程学报, 2015,35(4):866-872.

YIN Baiqiang, HE Yigang, ZHU Yanqing. Detection and classification of power quality multi-disturbances based on generalized S-transform and fuzzy SOM neural network [J]. Proceedings of the CSEE, 2015, 35(4):866-872.

- [16] 赵莹,赵川,叶华,等.应用主成分分析约简电压暂降扰动源识别特征的方法[J].电力系统保护与控制,2015,43(13):105-110.
 ZHAO Ying, ZHAO Chuan, YE Hua, et al. Method to reduce identification feature of different voltage sag disturbance source based on principal component analysis[J]. Power System Protection and Control,2015,43(13):105-110.
- [17] 汪颖,王欢,张妹. 基于优化极限学习机的电压暂降源识别方法[J]. 电力系统自动化,2020,44(9):135-143.
 WANG Ying, WANG Huan, ZHANG Shu. Recognition method of voltage sag source based on optimized extreme learning machine[J]. Automation of Electric Power Systems, 2020, 44 (9):135-143.
- [18] WANG Shaoshuai, ZHU Huangqiu, WU Mengyao, et al. Active disturbance rejection decoupling control for three-degree-offreedom six-pole active magnetic bearing based on BP neural network[J]. IEEE Transactions on Applied Superconductivity, 2020, 30(4):1-5.
- [19] HU Qin, SI Xiaosheng, QIN Aisong, et al. Machinery fault diagnosis scheme using redefined dimensionless indicators and mRMR feature selection[J]. IEEE Access, 2020, 8:40313-40326.
- [20] 赵文清,严海,周震东,等.基于残差 BP 神经网络的变压器故 障诊断[J].电力自动化设备,2020,40(2):143-148.
 ZHAO Wenqing,YAN Hai,ZHOU Zhendong, et al. Fault diagnosis of transformer based on residual BP neural network[J]. Electric Power Automation Equipment,2020,40(2):143-148.
- [21] 陆双,彭曙蓉,杨云皓,等.基于平均影响值-启发式前向搜索 的异常光伏用户识别方法[J].电力自动化设备,2022,42(2): 106-111.

LU Shuang, PENG Shurong, YANG Yunhao, et al. Identification method of abnormal photovoltaic users based on mean impact value and heuristic forward searching [J]. Electric Power Automation Equipment, 2022, 42(2):106-111.

[22] 徐敏锐,李云,卢树峰,等. 基于D-S证据组合规则的双模型融合局部放电模式识别方法[J]. 电力自动化设备,2021,41(11): 153-159.

XU Minrui, LI Yun, LU Shufeng, et al. Recognition method of partial discharge pattern based on double models fusion with D-S evidence combination rule[J]. Electric Power Automation Equipment, 2021, 41(11):153-159.

作者简介:

王玉荣(1981-),女,副教授,博士,主要研究方向为电



力系统电压稳定、最优化理论、时间序列分 析(**E-mail**:wangyurong@seu.edu.cn); 朱奕飞(1995—),男,硕士研究生,主 要研究方向为含新能源电力系统电压稳定 分析(**E-mail**:zhuyifei@seu.edu.cn); 汤 奕(1977—),男,教授,博士研究 生导师,主要研究方向为电力系统稳定分 析与控制、新能源并网、电网信息物理融合

系统(E-mail:tangyi@seu.edu.cn)。 (编辑 王欣竹)

Intelligent fault source identification method for high-voltage trip-off of wind turbines considering transient waveform characteristics

WANG Yurong¹, ZHU Yifei², TANG Yi¹

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

2. State Grid Nantong Power Supply Company, Nantong 226000, China)

Abstract: The large-scale high-voltage trip-off(HVTO) of wind turbines has an impact on the power quality and the safe stability operation of the power system. A fault source identification method for HVTO of wind turbines is proposed, which can be used as a support to fastly remove the fault by protection devices to reduce the impact on the power system brought by HVTO of wind turbines. Firstly, a fault characteristic index system is constructed to reflect the fault source characteristic based on the characteristic analysis of output waveform on HVTO of wind turbines. Secondly, the original index system is sorted out by Gini coefficient and maximum relevance and minimum redundancy (Gini-mRMR) method. Finally, the weights and initial deviation values of back propagation(BP) neural network are optimized by genetic algorithm, ant colony optimization algorithm, and particle swarm optimization algorithm (GA-ACO-PSO) to guarantee the accuracy of fault source identification. A case study is conducted in the Northwest Power Grid, which verifies the validity of the proposed method. Compared with the traditional machine learning method, the proposed method has better performance of fault source identification.

Key words: high-voltage trip-off; fault source identification; index system; Gini coefficient; mRMR method; BP neural network

(上接第85页 continued from page 85)

Equivalent modeling of PV station groups considering dynamic interaction between PV and power grid

PAN Xueping¹, WANG Weikang¹, HUANG Hua², LIANG Wei¹, CHEN Haidong¹, YONG Chengli¹

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. School of Electrical Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: Equivalent modeling of photovoltaic (PV) station groups is the basis for studying the dynamic characteristics of new energy power system. An equivalent modeling strategy for PV station groups that comprehensively considers the PV power source dynamic behavior and the dynamic interaction between PV power source and power system is proposed. Based on the differential algebraic equations of power system, the dynamic interaction between PV power source and power system is discussed, and it is emphasized that the terminal voltage of PV station is the key factor of the interaction between PV power source and power system. The dynamics of PV power source under different voltage dip degrees are simulated, which shows that the converter control strategy is the main factor that affects the PV dynamic behavior. Based on this, the dynamic grouping method and modeling procedure of PV station groups considering the interaction between PV power source and power system are proposed. Finally, a simulation example shows that compared with the existing dynamic grouping method based only on the PV dynamic behavior, further considering the interaction between PV power source and power system can significantly improve the equivalence modeling accuracy of PV station groups.

Key words: PV station groups; dynamic equivalence; voltage dip; voltage fluctuation











Fig.A2 Typical waveforms of output active power of HVTO wind turbines under short circuit fault



图 A3 换相失败故障下 HVTO 风电机组输出无功典型曲线

Fig.A3 Typical reactive power waveforms of HVTO wind turbines under commutation failure fault





图 A4 直流闭锁故障下 HVTO 风电机组输出无功典型曲线

Fig.A4 Typical reactive power waveforms of HVTO wind turbines under DC block fault





Fig.A5 Typical reactive power waveforms of HVTO wind turbines under short circuit fault



图 A6 换相失败故障下 HVTO 风电机组机端电压典型曲线

Fig.A6 Typical terminal voltage waveforms of HVTO wind turbines under commutation failure fault



图 A7 直流闭锁故障下 HVTO 风电机组机端电压典型曲线 Fig.A7 Typical terminal voltage waveforms of HVTO wind turbines under DC block fault





Fig.A8 Typical terminal voltage waveforms of HVTO wind turbines under short circuit fault



图 A9 换相失败故障下 HVTO 风电机组机端电流典型曲线

Fig.A9 Typical terminal current waveforms of HVT wind turbines under commutation failure fault









Fig.A11 Typical terminal current waveforms of HVTO wind turbines under short circuit fault





Fig.A12 Typical transient voltage waveforms of HVTO wind turbines under commutation failure fault



图 A13 直流闭锁故障下 HVTO 风电机组暂态电势典型曲线

Fig.A13 Typical transient voltage waveforms of HVTO wind turbines under DC block fault





Fig.A14 Typical transient voltage waveforms of HVTO wind turbines under short circuit fault



Fig.A15 Schematic diagram of back propagation neural network structure



图 A16 基于 GA-ACO-PSO 的参数优化流程图 Fig.A16 Parameter optimization flow chart based on GA-ACO-PSO method





Fig.A17 Wind turbine distribution schematic diagram in local area of Northwest China Power Network

表 A1 基于所提方法的风电机组 HVTO 故障溯源结果

Table A1 HVTO fault source identification result of wind turbines based on proposed method

故障	换相失败	直流闭锁	短路故障
换相失败	145	2	3
直流闭锁	3	141	6
短路	7	4	189

表 A2 基于 SVM、决策树的风电机组 HVTO 故障溯源结果

Table A2 HVTO fault source identification result of wind turbines based on SVM and decision tree method

溯源方法	准确率最大值	准确率最小值	准确率平均值
SVM	84.6%	81.2%	82.9%
决策树	82.8%	80.0%	81.6%

溯源方法	最大值	最小值	平均值
GA-BP 神经网络	90.2%	88.6%	89.5%
ACO-BP 神经网络	89.6%	87.2%	88.6%
PSO-BP 神经网络	89.8%	87.0%	88.7%

表 A3 GA-BP、ACO-BP 和 PSO-BP 下风电机组 HVTO 故障溯源准确率对比 Table A3 HVTO fault source identification result of wind turbines based on GA-BP, ACO-BP, PSO-BP