

DOI: 10.19783/j.cnki.pspc.221653

基于集成学习的高压直流输电系统故障诊断

李强¹, 陈潜¹, 武霁阳¹, 彭光强¹, 黄雄辉¹, 李子由², 杨博²

(1. 中国南方电网超高压输电公司, 广东 广州 510000; 2. 中国南方电网超高压输电公司大理局, 云南 大理 671000)

摘要: 以某西南电网变电站出现的4种故障的实测数据作为数据集, 针对高压直流输电(high voltage direct-current, HVDC)系统的故障诊断设计一种基于集成学习(ensemble learning, EM)的故障诊断方法, 显著提升了故障诊断的速度、精度和鲁棒性。首先, 对4类故障数据进行数据预处理, 同时对故障数据的特征进行提取并完成训练, 使用故障数据标签对故障数据集进行均分权重。然后, 计算当前弱分类器对带权重数据集的分类误差, 并计算当前分类器在强分类器中的权重。最后, 更新训练样本权值的分布得到强分类器, 根据训练好的模型对不同数据集下的故障类型进行辨识实验。通过与BP神经网络故障诊断模型对比, 所提出的方法在多组测试中可以达到89%以上的诊断准确率, 错误率较低并且鲁棒性强, 有利于HVDC系统的故障识别和快速诊断。

关键词: 高压直流输电系统; 故障诊断; 集成学习; 分类器

Ensemble learning-based HVDC systems fault diagnosis

LI Qiang¹, CHEN Qian¹, WU Jiyang¹, PENG Guangqiang¹, HUANG Xionghui¹, LI Ziyou², YANG Bo²

(1. China Southern Power Grid EHV Transmission Company, Guangzhou 510000, China; 2. China Southern Power Grid EHV Transmission Company Dali Bureau, Dali 671000, China)

Abstract: In this paper, the measured data of four kinds of faults in a substation of the Southwest power grid are used as the data set. A method based on ensemble learning (EM) is designed for the fault diagnosis of a high voltage direct-current (HVDC) system, one which can significantly improve the speed, accuracy, and robustness of fault diagnosis. First, data preprocessing for the four types of fault data is conducted. At the same time, the feature of fault data is extracted and trained. The fault data label is used to average the weight of the fault data set. Then the classification error of the current weak classifier for the weighted data set is calculated, as well as the weight of the current classifier in the strong classifier. Finally, the distribution of the weights of the training samples is updated to obtain a strong classifier. From the trained model, the fault types are identified in the different data sets. Compared with a back propagation neural network fault diagnosis model, the proposed method can achieve more than 89% diagnostic accuracy in multiple tests, with a low error rate and strong robustness. It is conducive to fault identification and rapid diagnosis in an HVDC system in operation.

This work is supported by the National Natural Science Foundation of China (No. 62263014).

Key words: HVDC transmission system; fault diagnosis; ensemble learning; classifier

0 引言

我国正处于经济转型的重要时期, 电网发展面临巨大的挑战, 高压直流(high voltage direct-current, HVDC)输电系统能够保留送受两端电网的相对独立性, 具有无感抗、无同步等交流输电系统不具备的优势, 是建设远距离、大规模、大容量电网互联和

功率交换的重要保障^[1-2]。近10年来可再生能源比例急剧增长, 为解决电能生产和负荷中心的距离增加的问题, HVDC输电已经在很多输电工程中担任主要的送电任务, 目前我国已经建成并投运了7个±800 kV特高压直流输电工程, 有效地促进了“西电东送”工程的实现^[3]。然而, 随着HVDC电压等级不断上升、规模不断扩大, 其发生故障对生产和输送的影响也难以预计, 特别是作为各大电网之间连接的纽带, HVDC的可靠性对整个电力系统的稳定和人身设备的安全保障起着重要作用, 因而对其

基金项目: 国家自然科学基金项目资助(62263014); 南方电网重点科技项目资助(CGYKJXM20210309)

进行高效全面的故障诊断也变得尤为重要^[4-5]。目前,应用在 HVDC 输电系统中的故障诊断方法主要有基于解析模型、基于专家系统^[6]、基于神经网络^[7]、基于支持向量机(support vector machine, SVM)^[8]和基于集成学习(ensemble learning, EM)的故障诊断方法^[9]。基于解析模型的方法需要根据电力系统的输入输出关系建立数学模型,因此在实际工程中容易受限于复杂电力系统;神经网络是一种强学习器,拥有准确率高、鲁棒性强等优势,但是设计复杂,其构建往往需要花费很大的精力,并且要求强大的服务器计算能力;SVM 是一种新颖的小样本学习方法,在计算过程中能够避免“维数灾难”,并且拥有较好的鲁棒性,然而其对大规模的训练样本难以实施,并且在解决电力系统的多分类问题时存在困难。

近年来 HVDC 系统的故障诊断在学术界备受关注,而各类故障诊断的方法也层出不穷。文献[10]利用卷积神经网络(convolutional neural networks, CNN)对 HVDC 输电线路进行区内外故障判别,但卷积网络结构对判别结果的准确性影响较大,对不同结构的电力系统来调整卷积网络结构需要耗费大量时间。针对 HVDC 输电线路故障时的电流突变,文献[11]通过 Teager 能量算子将故障时的正负极电流突变量能量比值组成特征向量,并使用 1D-CNN 对特征向量集进行训练和测试,实现了区内外故障类型和故障极的有效判别。对于故障时暂态量信息的收集和处理,文献[12]对故障时的暂态电流信号进行了变分模态分解(variational mode decomposition, VMD),得到暂态电流信号的本征模态函数(intrinsic mode function, IMF)分量,再利用暂态电流信号的本征模态函数分量计算多尺度模糊熵,最后使用多尺度模糊熵输入至 Softmax 分类器进行 HVDC 输电线路故障辨识。对于 HVDC 输电线路发生故障时有大量的特征量可以收集,文献[13]利用支持向量机对 HVDC 输电线路接地故障时的交直流电压、电流等 13 种故障特征量进行分类来实现故障辨识,文献[14]对直流侧电压信号通过小波包变换提取故障特征后利用鸟群算法优化的 AdaBoost-SVM 对 HVDC 输电线路进行故障辨识。文献[15]针对现有 HVDC 故障诊断方法灵敏度低、辨识精准度低的缺陷,设计出一种基于改进灰狼算法(improved grey wolf optimizer, IGWO)优化时间卷积神经网络(temporal convolutional network, TCN)的 HVDC 传输系统故障诊断方法,解决了在过渡电阻高的情况下 HVDC 输电线路故障诊断和选极问题。然而上述方法均存在模型复杂从而导致鲁棒性弱、建模成本高、诊断速度慢等问题。

上述方法均存在模型复杂从而导致鲁棒性弱、建模成本高、诊断速度慢等问题。

本研究提出基于 EM 的 HVDC 输电系统的故障诊断模型,在 EM 机制中使用多个弱学习器相互配合而达到强学习器的效果,大大缩小了传统单一学习器的灰色地带,并通过与 BP 神经网络故障诊断方法进行对比,测试结果表明所提出的方法具有良好的性能和较高的精准度。

1 HVDC 系统故障分类

HVDC 输电系统主要由换流站、输电线路和接地极系统等部分组成。其中,换流站是 HVDC 输电系统的核心组成部分之一,结构比较复杂,常常成为故障的高发区域。HVDC 输电系统故障类型较多,例如交流故障、直流故障、逆变器换相失败、换流阀故障和雷击故障等。本研究主要根据某西南电网变电站出现的 4 类故障的实测数据,构建了基于集成学习 AdaBoost 算法的故障诊断模型,对 4 类故障进行分析和诊断。

1.1 交流故障

对变电站而言,故障穿越及故障支撑能力非常重要,如何在交流系统故障时,快速、准确地检测出故障对直流换电站的高效运行意义重大。交流侧故障,主要为换流设备和交流系统故障,在交直流混合系统中,交流系统发生故障时,会打破电力系统的功率、电压和频率等的平衡状态。若交流侧的故障判断未能快速、准确地清除,可能导致交直流换相失败,并且会导致直流侧功率供应不足、换流阀的使用年限缩短、换流变压器励磁失稳及交流侧电气连接减弱引起电压波动等异常情况。

换流站的无功功率平衡依赖于换相的顺利进行,当交流侧故障时,无功功率平衡很可能被打破,造成功率过剩或者不足,不利于系统的故障恢复,进一步影响到 HVDC 系统的后续换相。若故障影响进一步扩大,可能会导致直流侧闭锁,功率输送也会随之中断,大量功率转移到交流侧,将严重危及交流系统正常运行。

对于 HVDC 系统,尤其是多直流馈入系统^[16],快速、准确地检测出交流故障有特别重要的工程意义。一是对系统的故障穿越起到保障作用,尤其是可以减少系统换相失败,提高直流系统的运行可靠性;二是能在故障情况下发挥主动支撑的作用,实现系统有功功率和无功功率的调节和控制^[17]。面对直流输电系统的交流侧故障检测,有许多可行的方法被国内外相关学者陆续提出,并且已经开展了一系列卓有成效的研究^[18]。ABB 公司在直流系统的直

流控制保护技术中采用换相失败预测(commutation failure prevention, CFPREV)^[19], 该保护控制技术以零序电压幅值为单相故障判断量, 通过观测电压值的大小来判断是否发生故障, 以换流母线电压旋转矢量幅值为三相故障判断量, 通过观测矢量幅值的大小来判断是否发生故障^[20-21]; 电压负序分量作为系统发生不对称故障的常见特征, 可以通过检测其是否存在来判断发生的故障是三相对称故障还是其他类型的不对称故障^[22-24]。文献[25]通过增加正余弦分量检测逻辑环节, 在一定程度上提高了CFPREV的启动速度, 弥补CFPREV在交流电压过零时启动慢的缺陷。文献[26]将电流、电压的零序分量和正余弦分量相乘得到功率分量, 提出了功率分量故障检测方法。

1.2 直流故障

换流站内的一次设备和二次设备较多, 一次设备主要有换流器和交直流开关场, 二次设备电压、电流较低, 主要用于控制保护。直流输电系统的稳定运行与其两端连接的交流系统的运行状态密切相关。直流输电系统是一个有机的整体, 任何一个部分故障都可能影响系统的安全稳定运行。

在远距离输电时, 直流输电系统在很多方面优于交流输电系统。因此, 直流输电系统常在远距离输电工程中被考虑, 但是较长的线路也带来很多安全问题, 较远的距离导致发生故障的概率较大。直流输电系统故障中发生对地短路的概率最大, 占直流输电系统线路故障的80%以上, 其中大部分是闪络放电。通常直流输电系统的对地闪络主要是输电线路和地面之间的绝缘被破坏, 常见的原因有雷击造成的空气被击穿、污秽造成的绝缘水平降低以及树枝造成的绝缘距离缩短等。直流输电系统发生故障时, 故障点与换流站间的电气距离影响故障电流的大小, 距离越远故障电流越小, 同时接地电阻越大故障电流越小, 即使是同一个故障点, 不同的故障类型故障电流也不同, 继电保护必须考虑各种情况。直流输电系统线路较长, 常常跨越多个地区, 不同地区之间气候变化较大, 不可避免地要经过多雷地区, 尽管有避雷装置, 但雷击仍然是直流输电系统故障的主要原因。另外, 直流输电系统在运行中也会出现断线和掉线等故障。

一般情况下, HDVC系统采取双极对称的输电方式。直流线路故障包括单极上的接地故障、断线故障和两极间的异常连接导致的短路故障。直流输电系统的永久性故障一般认为将长时间存在, 如断线故障和极间短路故障, 通常为外界机械应力导致。

若保护系统检测到永久性故障, 便会动作闭锁切除故障线路, 防止故障进一步扩大, 危及系统的供电可靠性。

1.3 逆变器换相失败

在直流输电系统中, 换流器是最为重要的元件, 系统故障行为与其可控性以及单项导通的特性有重要的联系。换相失败是逆变器的常见故障之一, 它是指两个阀臂在换相时电流未按预定的阀臂进行切换的故障现象。当换流变压器故障时, 可能会导致换相失败。同时, 交流系统发生短路、断路等三相对称及三相不对称故障时, 同样会导致换相失败。造成换相失败的原因有很多, 主要有逆变侧换流阀短路、交流联接异常、交流电压突变、触发脉冲异常等原因。触发脉冲是引导换相阀进行换相动作的重要信号, 一旦触发脉冲丢失或出现异常, 换相就很难顺利进行。交流联接故障时可能导致交流欠压, 换流器熄弧角减小, 造成前阀不能及时动作阻断而继续导通。换相失败通常也伴随着一些常见的特征, 例如电流中的工频分量大于整定值, 熄弧角小于预设值, 换流变压器出现偏磁, 直流系统中检测到基波成分等等。

1.4 换流阀故障

换流阀位于换流器的主回路中, 换流阀的动作特征, 如触发、导通、关断以及选择都具有独特的运行特点, 同时, 换流阀的故障特征和展现出来的故障形式与系统中的其他一般元件有较大区别。在直流输电系统工程建设中, 所有的工程都有较多的控制保护, 但所有的保护都不采用阀电流作为输入量。因此, 在判断换流器是否发生故障时, 只能选择其他电气量, 通过电气量的特性变化来判断换流器是否发生故障。这样做的原因是为了降低复杂度, 一方面避免测量系统过于复杂, 另一方面可以使保护系统的逻辑更简单。换流阀故障会发生在主回路和控制回路系统上, 发生在主回路上的故障, 主要为短路故障, 短路又分为换流阀短路和换流阀两侧发生短路两种情况, 如直流侧的接地短路和出口短路, 交流侧的相间短路和接地短路。控制系统的故障会引发换流阀的误动或者拒动, 换流阀短路故障是换流阀故障中危害最为严重的一种故障。

2 基于集成学习的 HVDC 故障识别

EM以“群体智慧”作为原理, 将多个单独表现不佳的模型组合之后形成一个强大的模型。对分类任务而言, 将多个弱分类器组合可以形成精度很高的强分类器, 其中增强学习(boosting)是一类以级联方式组合弱分类器的有效方法。

自适应增强(adaptive boosting, AdaBoost)是一种基于监督学习的多学习器增强技术, 由 Yoav Freund 和 Robert Schapire 在 1995 年提出。在每一

轮迭代中, AdaBoost 通过调整样本权重和分类器权重的方式实现自适应。图 1 是二分类 AdaBoost 算法的流程图。

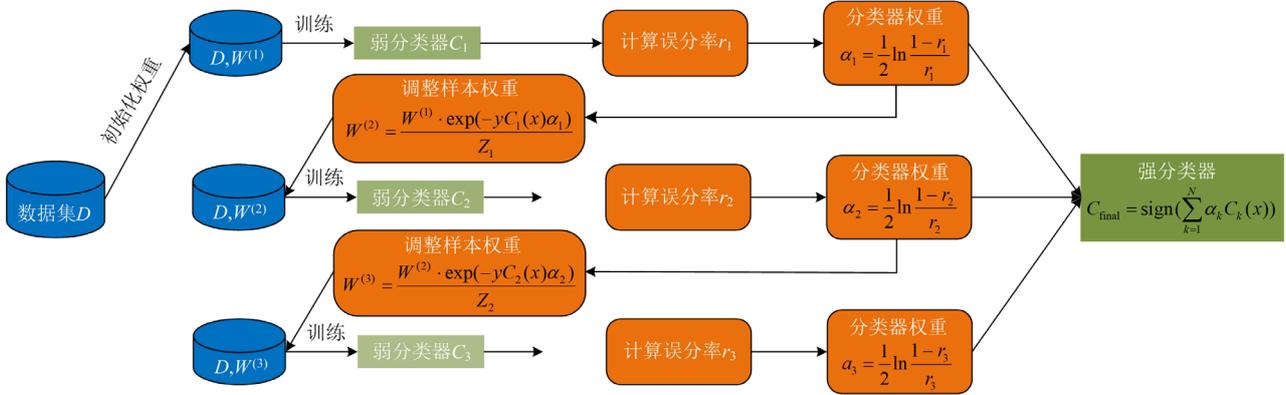


图 1 二分类 AdaBoost 算法流程图

Fig. 1 Flow chart of two category AdaBoost algorithm

令高压直流运行状态数据集 $D = \{d_1, d_2, \dots, d_i, \dots, d_n\}$, 其中 d_i 为某一个故障事件中的录波数据及故障标签, 表示为 $d_i = (x_i, y_i)$ 。数据 $x_i \in \chi \subseteq R^n$, 标签 $y_i \in Y \subseteq \{1, 2, 3, \dots\}$, χ 为数据空间, Y 是标签集合。

二分类 Adaboost 算法流程如下:

1) 根据数据标签对数据集进行均分权重 $W^{(1)}$ 初始化。

$$W^{(1)} = (w_1^{(1)}, w_2^{(1)}, \dots, w_n^{(1)}) = (\frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N}) \quad (1)$$

2) 计算当前弱分类器对带权重数据集的分类误差。

$$r_k = \sum_{i=1}^N w_i^{(k)} I(C_k(x_i) \neq y_i) \quad (2)$$

式中, $I(C_k(x_i) \neq y_i)$ 表示当分类错误时为 1, 否则为 0。

由式(2)可知, 误分率 r_k 是被当前分类器 C_k 误分的样本权值之和。

3) 计算当前分类器在强分类器中的权重 α_k 。

$$\alpha_k = \frac{1}{2} \ln \frac{1-r_k}{r_k} \quad (3)$$

4) 训练集样本权值分布更新。

$$W^{(k+1)} = \frac{W^{(k)} \cdot \exp(-y C_k(x) \alpha_k)}{Z_k} \quad (4)$$

式中, Z_k 为归一化因子, 可以表达为

$$Z_k = \sum_{i=1}^N w_i^{(k)} \quad (5)$$

5) 重复步骤 2)~步骤 4), 直到得到终止条件, 终止条件一般为弱分类器个数或误分率阈值。组合各个弱分类器, 可得到强分类器为

$$C_{\text{final}} = \text{sign}(\sum_{k=1}^N \alpha_k C_k(x)) \quad (6)$$

式中, $\text{sign}()$ 为符号函数。

对本文研究的高压直流输电系统故障诊断而言, 常规二分类算法无法满足其需求。本文对 AdaBoost 算法进行改进, 使其进化为 AdaBoost 多分类算法。最简单的多分类算法就是将数据集中的其中一类数据孤立为一类, 剩余数据定义为另一类, 当有 n 个数据标签时, 共需要 n 个分类器, 并根据 n 个强分类器的投票结果来进行分类决策。但此类方法会造成整个数据空间内有较大灰色地带。为此本文提出另一种思路, 通过对整个数据空间进行组合操作, 每两个样本标签训练一个强分类器。因此当有 n 个数据标签时, 共需要 $n(n-1)/2$ 个分类器。两种方法形成的数据空间和分类面如图 2 所示。由图 2 可知, 方法 2 形成的灰色地带明显小于方法 1。

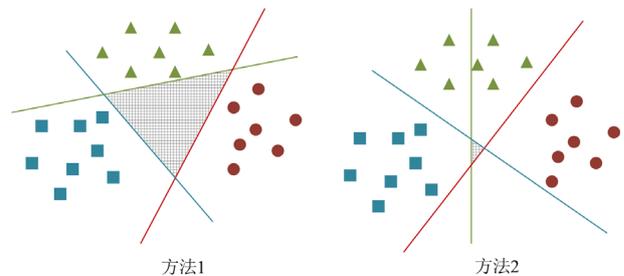


图 2 多分类 AdaBoost 方法对比图

Fig. 2 Comparison of multi-classification AdaBoost methods

3 基于集成学习的多分类 AdaBoost 故障诊断模型

在本节中，以某西南电网一变电站的故障实测数据为基础，具体输电系统的故障点和故障类型电气图如图 3 所示，同时，表 1 总结了各个故障点编号所代表的故障类型。在原数据集中，提取故障前后 15 个周波的录波数据，即录波数据的提取时长为 0.3 s，且在录波数据的提取中，整理出了 15 个具有代表性的信号通道，具体的信号意义描述如表 2 所示。其中，AC 故障、DC 故障、逆变器换相失败故障以及换流阀故障的数据样本中的元素分别为 $N_1=10$, $N_2=14$, $N_3=14$, $N_4=18$ 。在原有数据集的基础上，利用基于集成学习的多分类 AdaBoost 方法进行故障诊断，并验证该方法的有效性，算法执行的过程如图 4 所示。

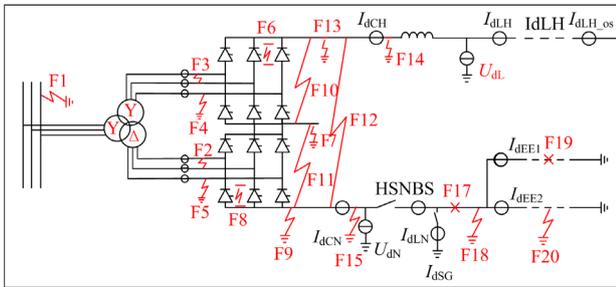


图 3 某西南电网变电站主要故障点

Fig. 3 Main fault points of a substation in southwest power grid of China

表 1 某西南电网变电站故障点故障类型

Table 1 Fault type of fault point in a substation in southwest power grid of China

故障点	故障类型	故障点	故障类型
F1	单相接地短路	F1	三相接地短路
F1	相间短路	F3	相间短路
F2	相间短路	F4	单相接地短路
F5	单相接地短路	F6	Y1 桥短路
F6	Y2 桥短路	F6	Y3 桥短路
F6	Y4 桥短路	F6	Y5 桥短路
F6	Y6 桥短路	F8	D1 桥短路
F8	D2 桥短路	F8	D3 桥短路
F8	D4 桥短路	F8	D5 桥短路
F8	D6 桥短路	F9	Y 阀高压侧出口故障
F10	Y 阀短路	F11	D 阀短路
F12	阀短路	F13	Y 阀高压侧出口故障
F14	高压母线故障	F14	高压母线故障
F15	中性母线故障	F16	线路接地故障
F17	中性母线断线	F18	中性母线接地
F19	接地极线路断线	F20	接地极线路接地

表 2 信号名及其意义描述

Table 2 Signal name and meaning description

信号名	信号意义描述	信号名	信号意义描述
UACA(V)	A 相交流电压	IACD_L3(A)	D 桥阀侧 C 相交流电流
UACB(V)	B 相交流电压	UDL(V)	直流线路电压
UACC(V)	C 相交流电压	UDN(V)	中性母线电压
IACY_L1(A)	Y 桥阀侧 A 相交流电流	IDN(A)	中性母线电流
IACY_L2(A)	Y 桥阀侧 B 相交流电流	IDE(A)	接地极母线电流
IACY_L3(A)	Y 桥阀侧 C 相交流电流	IDH(A)	高压母线电流
IACD_L1(A)	D 桥阀侧 A 相交流电流	IDL(A)	直流线路电流
IACD_L2(A)	D 桥阀侧 B 相交流电流	—	—

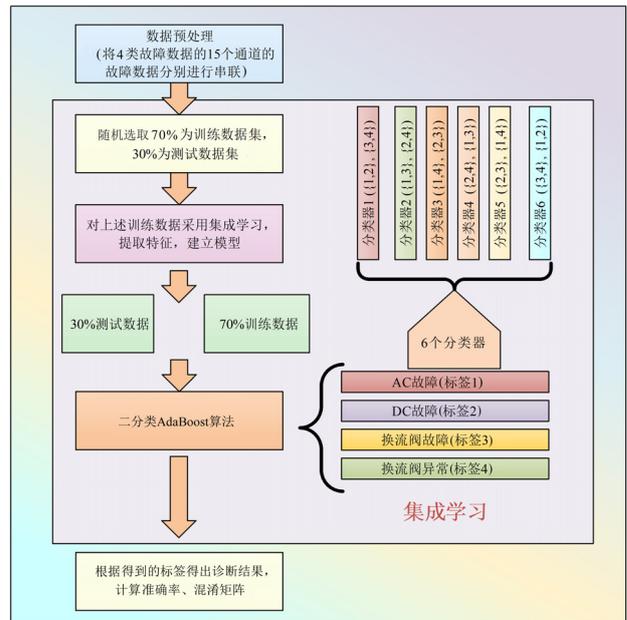


图 4 基于集成学习的 HVDC 故障分类流程图

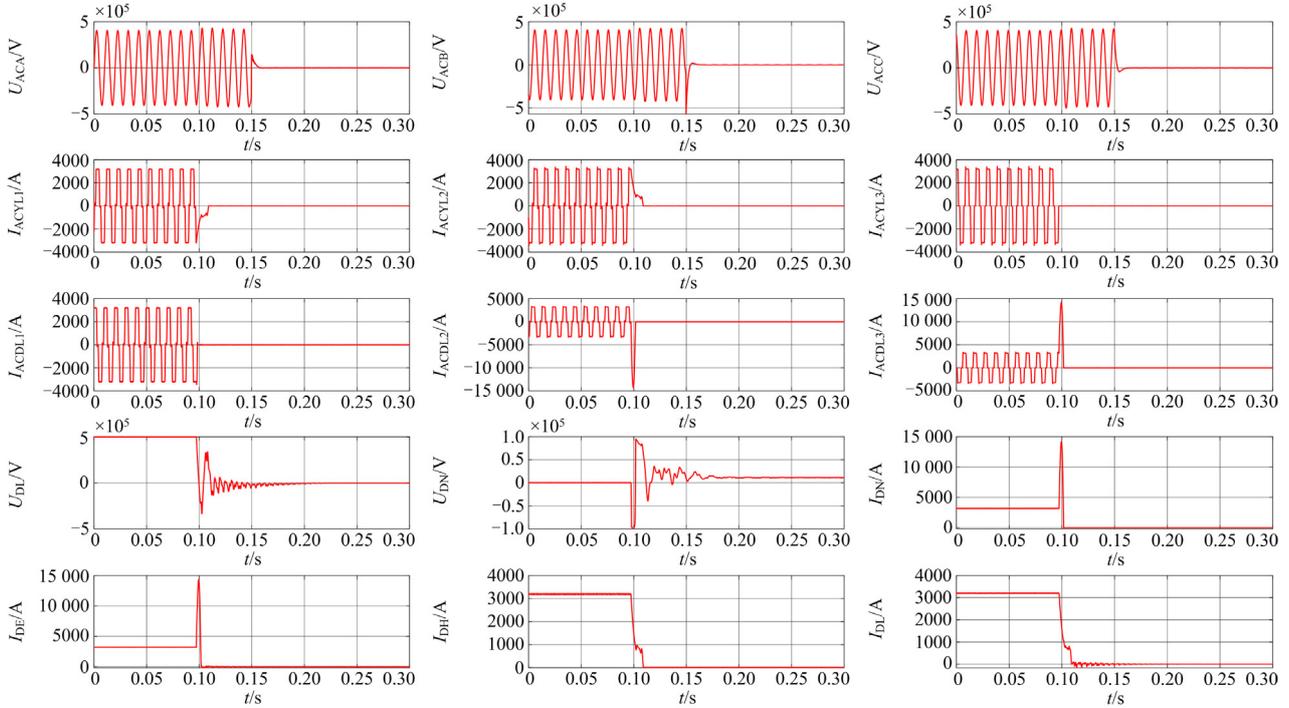
Fig. 4 Flow chart of HVDC fault classification based on integrated learning

具体步骤如下：首先进行数据预处理，将每类故障数据中的每个样本的 15 个通道数据首尾串联，并按样本个数进行堆叠，形成全故障数据集。在全故障数据集中，随机选取 70% 为训练数据，30% 为测试数据。其次利用集成学习对故障数据的特征进行提取，对 70% 的数据进行强化训练，并采用多分类 AdaBoost 确定分类器个数和标签，根据上述多分类 AdaBoost 方法的介绍，样本个数为 4，不难得

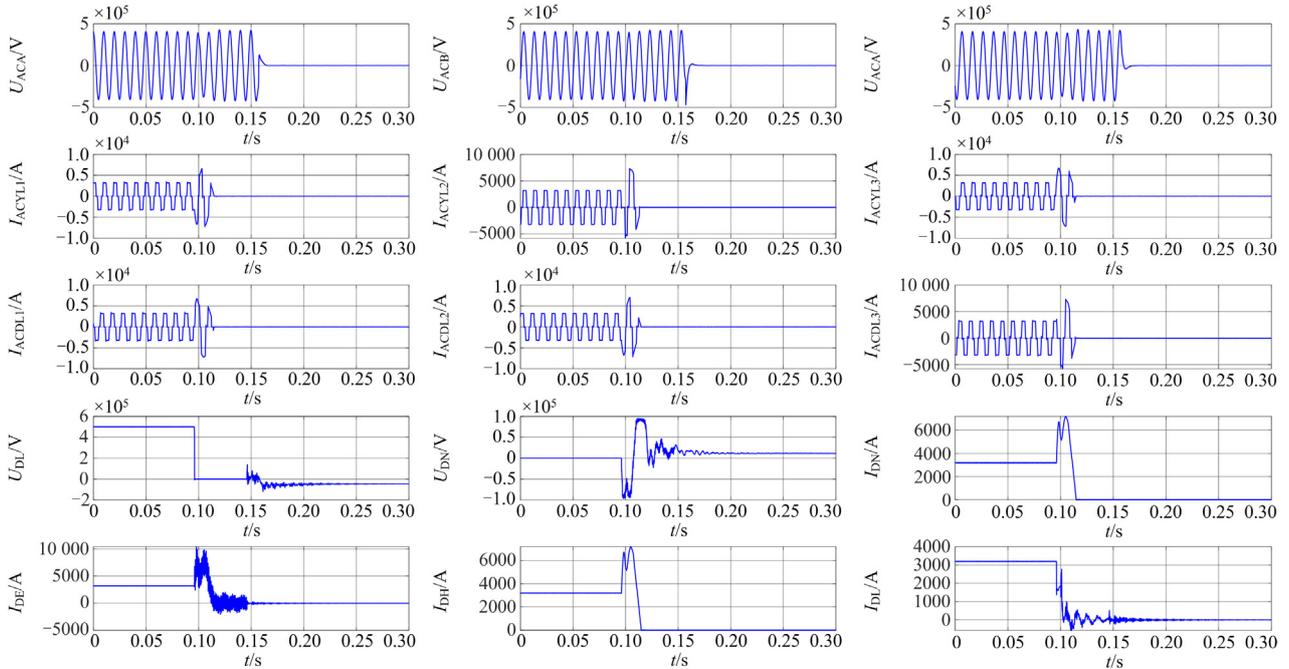
出需要 6 个分类器, 其中, 定义 AC 故障、DC 故障、逆变器换相失败以及换流阀故障的标签分别为 1,2,3,4, 具体的分类方式和解释如表 3 所示, 图 5 是 HVDC 4 类故障对应的 15 个通道数据波形图。

在确定数据分类器个数和数据训练之后, 将剩

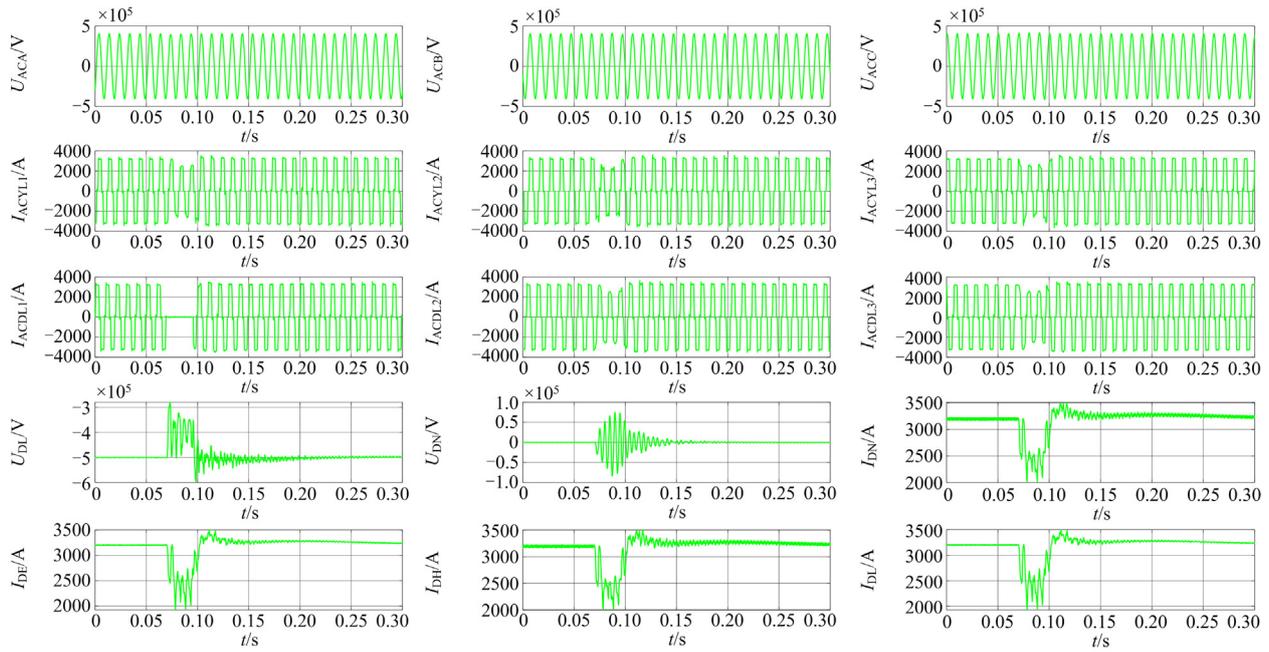
下的 30% 数据作为测试样本, 进行故障诊断和分类, 并根据测试结果与标准故障类别阈值进行对比, 本文通过测试结果与标准故障阈值求欧氏距离来判断故障类别, 最后讨论该方法下对故障数据诊断的准确率。



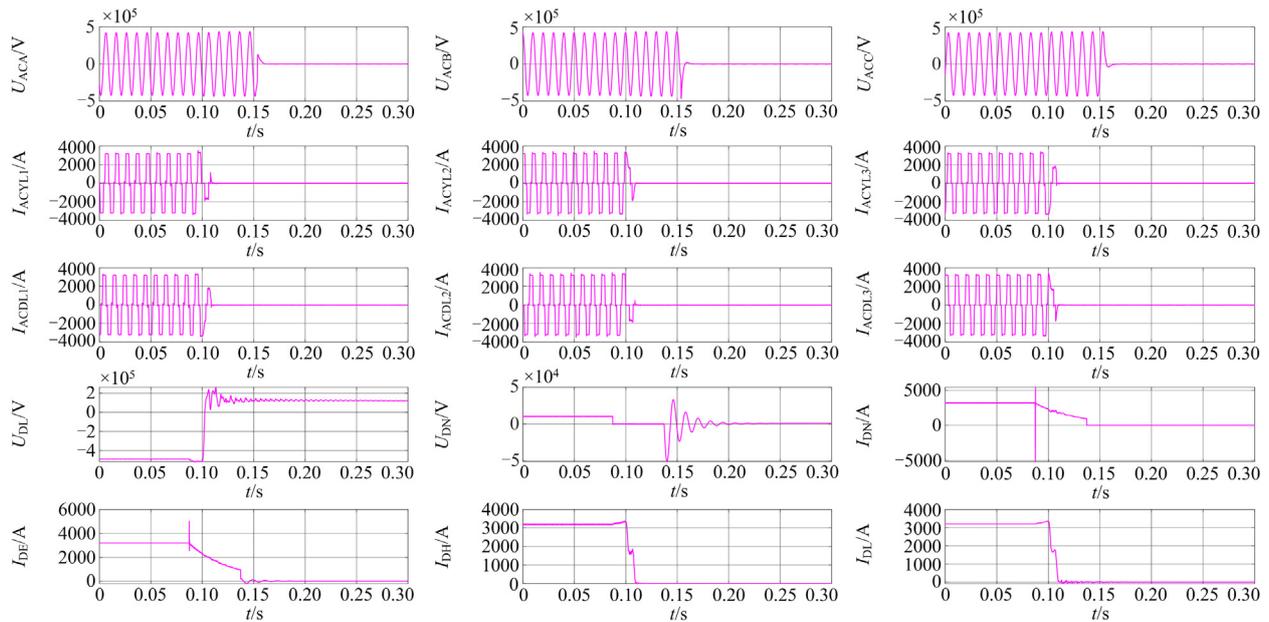
(a) AC故障数据



(b) DC故障数据



(c) 逆变器换相失败故障数据



(d) 换流阀故障数据

图 5 HVDC 4 类故障的诊断波形图

Fig. 5 Diagnosis waveform of HVDC four types of faults

表 3 HVDC 系统故障分类方式及意义

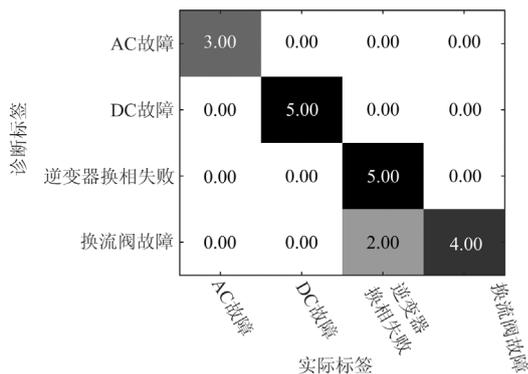
Table 3 HVDC system fault classification mode and significance

分类器	分类方式	具体意义
分类器 1	{1, 2}, {3, 4}	测试数据属于 AC 或 DC 故障, 输出为 1, 否则输出为-1
分类器 2	{1, 3}, {2, 4}	测试数据属于 AC 或换流阀故障, 输出为 1, 否则输出为-1
分类器 3	{1, 4}, {2, 3}	测试数据属于 AC 或逆变器换相失败, 输出为 1, 否则输出为-1
分类器 4	{2, 3}, {1, 4}	测试数据属于 DC 或换流阀故障, 输出为 1, 否则输出为-1
分类器 5	{2, 4}, {1, 3}	测试数据属于 DC 或逆变器换相失败, 输出为 1, 否则输出为-1
分类器 6	{3, 4}, {1, 2}	测试数据属于换流阀故障或逆变器换相失败, 输出为 1, 否则输出为-1

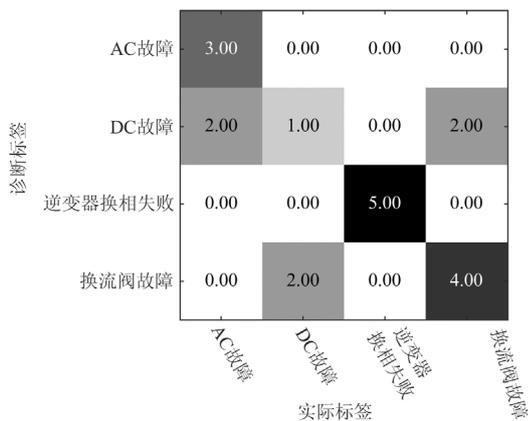
4 算例分析

输入测试样本, 分 3 组对模型进行测试, 第 1 组测试集 Y_1 为上述全部数据集剩下的 30% 测试数据 ($n_1 = 3, n_2 = 5, n_3 = 5, n_4 = 6$), 第 2 组测试集 Y_2 为训练数据集 ($n_1 = 7, n_2 = 9, n_3 = 9, n_4 = 12$), 第 3 组测试集 Y_3 为全部数据集 ($n_1 = 10, n_2 = 14, n_3 = 14, n_4 = 18$)。为了验证 EM 在故障诊断应用上的先进性和有效性, 采用 BP 神经网络算法作为对比, 其中神经网络的神经元个数为 50, 在相同的测试集下比较两种方法的故障诊断准确率。

为了直观地观察 3 次测试的故障诊断准确率, 采用混淆矩阵来进行分析, 两种方法在训练好各自的故障诊断模型后, Y_1 测试集的故障诊断结果如图 6 所示。不难看出, 两种方法在换流阀故障上都会出现误诊, 但 BP 神经网络方法出现的误诊个数明显高于 EM 诊断结果, EM 的整体故障诊断的准确率还是处于一个较高的水平。其次, 当用训练数据



(a) EM模型测试结果

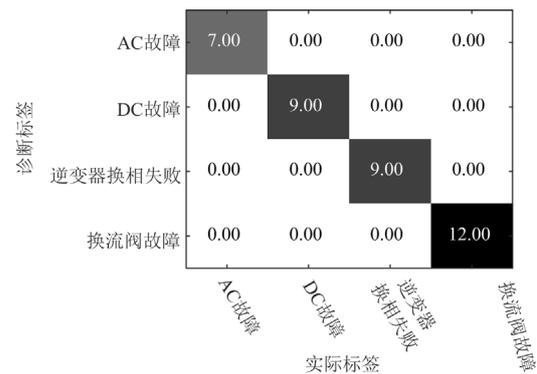


(b) BP神经网络模型测试结果

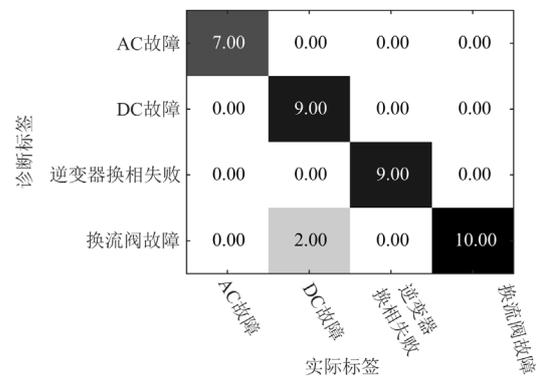
图 6 测试集为 Y_1 实验结果混淆矩阵图Fig. 6 Confusion matrix of experimental results for test set Y_1

集 Y_2 当作测试集再去测试模型的准确率时, 测试结果如图 7 所示。由图 7 可知, EM 模型整个故障诊断的准确率高达 100%, 4 类故障都能够被有效地识别出来, BP 神经网络方法还是出现两个错误诊断, 说明了 EM 能够有效地提取和辨识故障数据的特征。最后在数据集 Y_3 下对两种故障诊断模型进行测试, 结果如图 8 所示。基于 BP 神经网络方法出现 8 个数据诊断错误, 而 EM 模型对 AC 故障和 DC 故障确实有着较高的准确率, 两个数据出现误诊主要在逆变器换相失败和换流阀故障这两类。

最后根据混淆矩阵得出两个诊断模型 3 组故障诊断实验的准确率, 如表 4 所示。不难发现, 在全数据集下的 EM 模型故障诊断的准确率高达 92.31%, 而 BP 神经网络的故障诊断准确率只有 85.71%, 充分证明了 EM 模型在高压直流输电系统故障诊断中的先进性。所有仿真实验都是在配置为 2.90 GHz Intel(R) Core(TM) i5-9400 CPU, 32.0 GB RAM, 64 位 Windows 10 的计算机上 Python-PyCharm Community Edition 2022 环境下运行的。

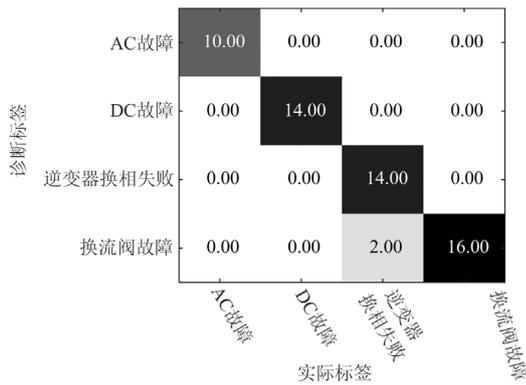


(a) EM模型测试结果

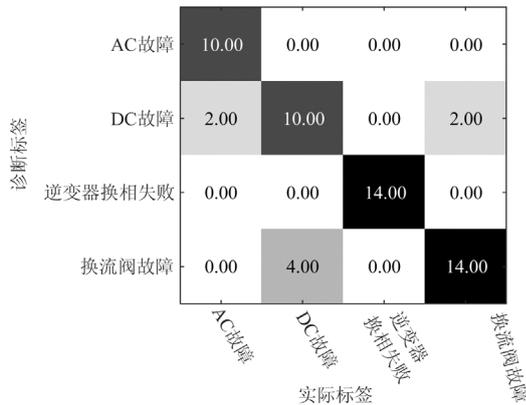


(b) BP神经网络模型测试结果

图 7 测试集为 Y_2 实验结果混淆矩阵图Fig. 7 Confusion matrix of experimental results for test set Y_2



(a) EM模型测试结果



(b) BP神经网络模型测试结果

图 8 测试集为 Y_3 实验结果混淆矩阵图

Fig. 8 Confusion matrix of experimental results for test set Y_3

表 4 3 组实验结果精度统计

Table 4 Precision statistics of three groups of experimental results

测试 样本	样本 个数 N	正例		反例		准确率/%		分类错误率/%	
		样本数		样本数					
		EM	BP	EM	BP	EM	BP	EM	BP
Y_1	19	17	13	2	6	89.47	68.42	10.53	31.58
Y_2	37	37	35	0	2	100.00	94.59	0.00	5.41
Y_3	56	54	48	2	8	92.31	85.71	7.69	14.29

5 结论

本文提出了一种新型高压直流输电系统故障诊断模型——基于集成学习多分类 AdaBoost 的故障诊断模型。该模型可以有效地提取各类故障的特征，在测试时能够准确识别出输电系统中的各类故障，其主要贡献点可总结如下：

1) 首先分析了交流故障、直流故障、逆变器换相失败和换流阀故障 4 类高压直流输电系统中常见故障，收集整理了这 4 类故障在 15 个周波内(0.3 s)具有代表性特征意义的 15 个通道数据，并作为样

本原始数据集。

2) 提出了基于集成学习的高压直流输电系统故障诊断策略。集成学习能够准确地提取每类故障的特征，并改进了集成学习中的分类机制，与传统的二分类器相比，改进的多分类器极大地减少了灰色地带，同时，采用 BP 神经网络方法进行对比，分析了两种方法在 HVDC 故障诊断结果上的差异。

3) 基于集成学习多分类 AdaBoost 的高压直流输电系统故障诊断 3 个仿真算例表明：EM 能够高效地提取数据集的特征并对大量数据集进行训练。通过 3 个混淆矩阵展示了 EM 和 BP 神经网络两种模型的诊断结果，EM 的整个模型的故障诊断准确率高达 92.31%，显著高于 BP 神经网络故障诊断模型的准确率。

故障诊断是保证电力系统安全可靠运行的重要保障，不管是输电线路还是变电站等重要设备，故障发生时都会伴随着大量的故障数据，如何根据故障时的大量数据预测出未来电力系统发生故障的概率从而降低故障带来的损失是研究的重点。未来故障诊断的研究应该注重故障数据的高效处理，同时推动故障诊断技术与人工智能的结合，尽可能地提高故障诊断技术的效率和准确率。

参考文献

[1] 陈厚合, 茅文玲, 张儒峰, 等. 基于碳排放流理论的电力系统源-荷协调低碳优化调度[J]. 电力系统保护与控制, 2021, 49(10): 1-11.
CHEN Houhe, MAO Wenling, ZHANG Rufeng, et al. Low-carbon optimal scheduling of a power system source-load considering coordination based on carbon emission flow theory[J]. Power System Protection and Control, 2021, 49(10): 1-11.

[2] 关志军. ± 800 kV 工程特高压直流输电铁塔真型试验研究[J]. 山西电力, 2022(4): 19-22.
GUAN Zhijun. Full-scale test research on ± 800 kV UHVDC transmission tower[J]. Shanxi Electric Power, 2022(4): 19-22.

[3] 宋益, 张怿宁, 尹立群, 等. 高压直流输电线路故障行波传播特性研究[J]. 东北电力技术, 2022, 43(7): 8-11, 15.
SONG Yi, ZHANG Yining, YIN Liqun, et al. Research on fault traveling wave propagation characteristics of HVDC transmission line[J]. Northeast Electric Power Technology, 2022, 43(7): 8-11, 15.

[4] 雷朝煜, 郝良收, 戴甲水, 等. 高压直流输电线路故障定位研究综述[J]. 电力系统保护与控制, 2022, 50(11): 178-187.
LEI Chaoyu, HAO Liangshou, DAI Jiashui, et al. A review

- of fault location methods in HVDC transmission lines[J]. *Power System Protection and Control*, 2022, 50(11): 178-187.
- [5] 刘琿, 赵丽萍, 李建萍, 等. 考虑开关状态集调整的含光伏并网配电网动态故障恢复方法[J]. *电力系统保护与控制*, 2021, 49(1): 24-31.
- LIU Shen, ZHAO Liping, LI Jianping, et al. Dynamic fault recovery method of a photovoltaic distribution network considering switch state set adjustment[J]. *Power System Protection and Control*, 2021, 49(1): 24-31.
- [6] 张彪, 王渝红, 李兴源, 等. 高压直流输电设备状态评价专家系统研究[J]. *计算机工程与设计*, 2014, 35(2): 690-694.
- ZHANG Biao, WANG Yuhong, LI Xingyuan, et al. Research on expert system of condition evaluation for HVDC transmission equipments[J]. *Computer Engineering and Design*, 2014, 35(2): 690-694.
- [7] 齐建平, 杨春静, 赵海成. 基于神经网络的高压直流输电线路故障测距[J]. *电力科学与工程*, 2014, 30(3): 45-49.
- QI Jianping, YANG Chunjing, ZHAO Haicheng. Fault-location method for HVDC transmission lines based on ANN[J]. *Electric Power Science and Engineering*, 2014, 30(3): 45-49.
- [8] 李福祥, 王雪, 张驰, 等. 基于边界点的支持向量机分类算法[J]. *陕西理工大学学报(自然科学版)*, 2022, 38(3): 30-38.
- LI Fuxiang, WANG Xue, ZHANG Chi, et al. Support vector machine classification algorithm based on boundary points[J]. *Journal of Shaanxi University of Technology (Natural Science Edition)*, 2022, 38(3): 30-38.
- [9] 陈雷, 吴浩, 李栋, 等. 基于集成学习的HVDC输电线路雷击故障识别方法[J]. *电力系统及其自动化学报*, 2022, 34(5): 102-110.
- CHEN Lei, WU Hao, LI Dong, et al. Identification method for HVDC transmission line lightning strike fault based on Adaboost.M2[J]. *Proceedings of the CSU-EPSCA*, 2022, 34(5): 102-110.
- [10] 魏东, 龚庆武, 来文青, 等. 基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J]. *中国电机工程学报*, 2016, 36(增刊 1): 21-28.
- WEI Dong, GONG Qingwu, LAI Wenqing, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolutional neural network[J]. *Proceedings of the CSEE*, 2016, 36(S1): 21-28.
- [11] 王桥梅, 吴浩, 杨杰, 等. 基于 Teager 能量算子和 1D-CNN 的 HVDC 输电线路故障识别方法[J]. *智慧电力*, 2021, 49(5): 93-100.
- WANG Qiaomei, WU Hao, YANG Jie, et al. Fault identification method of HVDC transmission line based on teager energy operator and 1D-CNN[J]. *Smart Power*, 2021, 49(5): 93-100.
- [12] 王桥梅, 吴浩, 胡潇涛, 等. 基于 VMD 多尺度模糊熵的 HVDC 输电线路故障识别方法[J]. *电力系统及其自动化学报*, 2021, 33(5): 134-144.
- WANG Qiaomei, WU Hao, HU Xiaotao, et al. Fault recognition method for HVDC transmission line based on VMD multi-scale fuzzy entropy[J]. *Proceedings of the CSU-EPSCA*, 2021, 33(5): 134-144.
- [13] 胡伟, 沈煜, 刘浴霜, 等. 改进支持向量机的 MMC-HVDC 系统故障识别[J]. *智慧电力*, 2019, 47(7): 91-97.
- HU Wei, SHEN Yu, LIU Yushuang, et al. MMC-HVDC system fault identification based on modified support vector machines[J]. *Smart Power*, 2019, 47(7): 91-97.
- [14] 郑小霞, 彭鹏. 优选小波包和 AdaBoost-SVM 的柔性直流输电变流器故障诊断[J]. *电力系统及其自动化学报*, 2019, 31(3): 42-49.
- ZHENG Xiaoxia, PENG Peng. Fault diagnosis of flexible HVDC converter based on preferred wavelet packet and AdaBoost-SVM[J]. *Proceedings of the CSU-EPSCA*, 2019, 31(3): 42-49.
- [15] 刘辉, 李永康, 张淼, 等. 基于 GWO-TCN 网络的 HVDC 输电线路故障诊断[J]. *电子测量技术*, 2021, 44(22): 168-174.
- LIU Hui, LI Yongkang, ZHANG Miao, et al. Fault diagnosis of HVDC transmission lines based on GWO-TCN networks[J]. *Electronic Measurement Technology*, 2021, 44(22): 168-174.
- [16] 张东辉. 多直流集中馈入受端广东电网发展的思考[J]. *广东电力*, 2015, 28(8): 33-37, 100.
- ZHANG Donghui. Reflect on development of centralized feed-in of multi direct current into receiving-end Guangdong Power Grid[J]. *Guangdong Electric Power*, 2015, 28(8): 33-37, 100.
- [17] 汪娟娟, 黄梦华, 傅闯. 交流故障下高压直流运行特性及恢复策略研究[J]. *中国电机工程学报*, 2019, 39(2): 514-523, 648.
- WANG Juanjuan, HUANG Menghua, FU Chuang. Research on HVDC operation characteristics and recovery strategy under AC fault[J]. *Proceedings of the CSEE*, 2019, 39(2): 514-523, 648.
- [18] 林圣, 刘健, 刘磊, 等. 基于控制保护的高压直流输电系统换相失败抑制方法综述[J]. *中国电机工程学报*, 2020, 40(19): 6045-6059.
- LIN Sheng, LIU Jian, LIU Lei, et al. A review of commutation failure suppression methods for HVDC

systems based on control protection measures[J]. Proceedings of the CSEE, 2020, 40(19): 6045-6059.

[19] 李程昊, 刘畅, 张振安, 等. 计及换相失败预测控制和故障合闸角的 HVDC 换相失败分析[J]. 电力系统自动化, 2018, 42(3): 56-63, 76.
LI Chenghao, LIU Chang, ZHANG Zhen'an, et al. Analysis of commutation failure in HVDC power transmission system considering prediction control of commutation failure and initial fault angle[J]. Automation of Electric Power Systems, 2018, 42(3): 56-63, 76.

[20] 王海军, 黄义隆, 周全. 高压直流输电换相失败响应策略与预测控制技术路线分析[J]. 电力系统保护与控制, 2014, 42(21): 124-131.
WANG Haijun, HUANG Yilong, ZHOU Quan. Analysis of HVDC commutation failure response strategy and predictive control technology route[J]. Power System Protection and Control, 2014, 42(21): 124-131.

[21] 邵瑶, 汤涌. 多馈入交直流混合电力系统研究综述[J]. 电网技术, 2009, 33(17): 24-30.
SHAO Yao, TANG Yong. Research survey on multi-infeed AC/DC hybrid power systems[J]. Power System Technology, 2009, 33(17): 24-30.

[22] MIRSAEIDI S, DONG X. An enhanced strategy to inhibit commutation failure in line-commutated converters[J]. IEEE Transactions on Industrial Electronics, 2020, 67(1): 340-349.

[23] 刘战磊, 曾祥君, 喻锴, 等. 基于不平衡过电压动态抑制的谐振接地配电网单相接地故障保护新方法[J]. 电力系统保护与控制, 2021, 49(8): 41-49.
LIU Zhanlei, ZENG Xiangjun, YU Kun, et al. A new method of single-phase grounding fault protection for a resonant grounding distribution network based on unbalanced overvoltage dynamic suppression[J]. Power System Protection and Control, 2021, 49(8): 41-49.

[24] 王开科, 熊小伏, 肖扬, 等. 基于负序电流的主动配电网单相断线故障保护方法[J]. 电力系统保护与控制, 2021, 49(6): 10-18.
WANG Kaike, XIONG Xiaofu, XIAO Yang, et al. Single-phase break fault protection method for an active distribution network based on negative sequence current[J]. Power System Protection and Control, 2021, 49(6): 10-18.

[25] 陈树勇, 李新年, 余军, 等. 基于正余弦分量检测的高压直流换相失败预防方法[J]. 中国电机工程学报, 2005, 25(14): 1-6.
CHEN Shuyong, LI Xinnian, YU Jun, et al. A method based on the sin-cos components detection mitigates commutation failure in HVDC[J]. Proceedings of the CSEE, 2005, 25(14): 1-6.

[26] GUO C, LIU Y, ZHAO C, et al. Power component fault detection method and improved current order limiter control for commutation failure mitigation in HVDC[J]. IEEE Transactions on Power Delivery, 2015, 30(3): 1585-1593.

收稿日期: 2022-10-18; 修回日期: 2022-11-06

作者简介:

李强(1990—), 男, 本科, 高级工程师, 研究方向为直流输电控制与保护、数字化智能化技术; E-mail: liqiang.outlook@qq.com

陈潜(1979—), 男, 通信作者, 硕士, 高级工程师, 研究方向为直流输电控制与保护技术; E-mail: 14408384@qq.com

武霖阳(1987—), 男, 博士, 高级工程师, 研究方向为直流输电控制与保护技术。E-mail: wujy0451@163.com

(编辑 魏小丽)