

耿蒲龙,宋建成,赵钰,等.基于SVM增量学习算法的煤矿高压断路器故障模式识别方法[J].煤炭学报,2017,42(8):2198-2204.

doi:10.13225/j.cnki.jccs.2016.1749

GENG Pulong, SONG Jiancheng, ZHAO Yu, et al. A method of fault pattern recognition for the high voltage circuit breaker based on the incremental learning algorithm for SVM[J]. Journal of China Coal Society, 2017, 42(8): 2198-2204. doi:10.13225/j.cnki.jccs.2016.1749

1749

基于 SVM 增量学习算法的煤矿高压断路器故障模式识别方法

耿蒲龙^{1,2}, 宋建成^{1,2}, 赵钰^{1,2}, 高云广^{1,2}, 郑丽君^{1,2}, 呼守信³

(1. 矿用智能电器技术国家地方联合工程实验室(太原理工大学), 山西太原 030024; 2. 煤矿电气设备与智能控制山西省重点实验室(太原理工大学), 山西太原 030024; 3. 中国煤炭科工集团太原研究院有限公司, 山西太原 030006)

摘要: 高压断路器故障模式的准确识别是矿井电网智能化发展过程中的重要支撑环节。针对高压断路器故障数据不易获取且故障样本较少的问题,提出了一种支持向量机与增量学习算法相结合的故障识别方法,确定了以断路器控制回路电流信号、电压信号以及分合闸振动信号为状态监测量,模拟了弹簧松动、铁芯卡涩、供电异常与线圈老化4种常见故障,提取了故障特征量并建立了故障数据样本与增量学习数据样本,采用支持向量机增量学习算法训练得到了故障识别模型,并利用新增数据样本对其进行了验证。结果表明:支持向量机增量学习算法可准确识别上述4种常见故障,并可以通过对新增样本的不断学习进一步提高识别精度。

关键词: 高压断路器;特征提取;故障模式识别;支持向量机;增量学习算法

中图分类号: TM56 **文献标志码:** A **文章编号:** 0253-9993(2017)08-2198-07

A method of fault pattern recognition for the high voltage circuit breaker based on the incremental learning algorithm for SVM

GENG Pulong^{1,2}, SONG Jiancheng^{1,2}, ZHAO Yu^{1,2}, GAO Yunguang^{1,2}, ZHENG Lijun^{1,2}, HU Shouxin³

(1. National & Provincial Joint Engineering Laboratory of Mining Intelligent Electrical Apparatus Technology(Taiyuan University of Technology), Taiyuan 030024, China; 2. Shanxi Province Key Laboratory of Mining Electrical Equipment and Intelligent Control(Taiyuan University of Technology), Taiyuan 030024, China; 3. Taiyuan Research Institute Co., Ltd., China Coal Technology and Engineering Group, Taiyuan 030006, China)

Abstract: The accurate fault pattern identification for the high voltage circuit breaker (HVCB) plays an important role in the development of mine smart grids. Aiming at the inaccessible obtainment of fault data and the lack of fault samples, a method of fault recognition was proposed based on the incremental learning algorithm for SVM. Firstly, the state monitoring variables were determined by the current signal and voltage signal of control unit and the vibration signal of the switching for HVCB. Secondly, four common faults, including the spring loosening, the core jamming, the coil aging and the abnormal electrical power supply, were simulated. Then the fault features were extracted, and the fault data samples as well as the incremental learning data samples were established. After training fault data samples based on the incremental learning algorithm for SVM, the fault recognition model was acquired and its accuracy was validated through exerting the new fault data samples into the model. Finally, it is shown that the incremental learning algorithm for SVM can be used to recognize the above four common faults for HVCB effectively, and its recognition accuracy can

收稿日期:2016-12-12 修回日期:2017-05-07 责任编辑:许书阁

基金项目:国家自然科学基金资助项目(U1510112,51377113);山西省科技重大专项资助项目(20131101029)

作者简介:耿蒲龙(1982—),男,山西临汾人,讲师,博士研究生。E-mail:gpl_1016@163.com

be improved by continuous learning on new samples.

Key words: high voltage circuit breaker; feature extraction; fault pattern recognition; SVM (support vector machine); incremental learning algorithm

高压断路器是矿井高压配电装置中重要的开关设备,它能否可靠运行将直接影响矿井电网的稳定性和可靠性。因此,研究高压断路器的故障诊断、故障模式识别及寿命评估等方法显得尤为重要^[1-4]。

高压断路器故障种类较多,对于不同类型的故障,其诊断方法也有较大差别。近年来,已有不少智能诊断算法得到了应用,例如遗传算法、BP 神经网络、聚类分析、经验模态分解、粒子群优化、贝叶斯粗糙集和专家系统等^[5-11]。遗传算法具有良好的全局快速搜索能力,易与其他算法相结合,但对新空间的探索能力有限,编程复杂;神经网络算法需要大量的样本作支撑,具有易陷入局部极小和训练时间长等缺点;经验模态分解算法是一种自适应的时频信号分析法,已被广泛用于非线性非平稳过程,但存在模态混叠难题;聚类分析具有方法简明、直观等优点,但容易陷入局部最优;当构建基于知识的系统时,专家系统被认为是最好的选择,但需要丰富的专家经验和知识库做基础。总之,上述方法需要较大数量的样本或经验做基础,而针对矿用高压断路器而言,它内置于高压配电装置的防爆外壳这一特殊工况环境中,且存在故障数据不丰富、典型故障样本不易获取等客观原因,上述方法的适用性及准确性还有待进一步验证。因此,泛化能力强且适合小样本训练的支持向量机算法,以及适用于在新增故障样本中发掘新增故障特征的增量学习等算法在断路器故障诊断方面有着广泛的应用前景。

针对高压断路器控制回路中的弹簧松动、铁心卡涩、供电异常与线圈老化等 4 种常见故障,依据故障机理确定了故障监测参量为控制回路的电流与电压信号以及分合闸振动信号,提取了故障特征量并建立了故障数据样本,得到了基于支持向量机增量学习算法的故障识别模型,实现了对上述 4 种故障的准确识别。

1 支持向量机增量学习算法

1.1 SVM 基本原理

SVM 为建立在统计学习理论基础上的—种数据分类方法,主要适用于小样本情况下得到最优解,以及避免陷入局部最小化与不收敛等情况^[12]。高压断路器故障样本较少,属于小样本情况,支持向量机在处理小样本数据的模式识别具有良好的学习泛化能

力,而且算法本身针对的是二分类问题,适合于进行多种故障类别的判断。

SVM 分类的基本原理是^[13]:寻找满足分类要求的最优分类超平面,使得该平面在保证分类精度的同时,超平面两侧的空白区域最大。

设线性可分训练样本集为

$$T = \{(x_1, y_1), \dots, (x_n, y_n)\}$$

其中, $x_i \in R^n$, $y_i \in \{1, -1\}$ 为类别标号。如果样本集可分,则存在超平面:

$$(w \cdot x) + b = 0 \quad (1)$$

使得训练样本中的正类输入和负类输入分别位于该超平面两侧,其中, w 为超平面法向量; b 为偏置; $(x \cdot y)$ 表示 x 与 y 的内积,即存在着参数对 (w, b) , 使得:

$$y_i = \text{sgn}((w \cdot x_i) + b) \quad (i = 1, 2, \dots, N) \quad (2)$$

本文采用的 SVM 模型为 C-SVC (C-Support Vector Classification)。其原理是引入松弛因子 ξ 及惩罚因子 C , 用于对错分样本惩罚程度的控制, 实现在算法复杂程度和错分样本比例之间的平衡。求最优分类面问题可以转化为下面的二次规划问题:

$$\min_{w, b, \xi} J(w, \xi) = \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad (3)$$

约束条件为

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad (\xi_i \geq 0, i = 1, \dots, N) \quad (4)$$

上述理论针对的是线性可分系统,对于线性不可分的情况,SVM 的思想是通过核函数将输入向量映射到一个高维特征空间中,然后在该特征空间中构造最优分类超平面。

将 x 从输入空间 R^n 映射到特征空间 H , 有

$$x \rightarrow \varphi(x) = (\varphi_1(x), \varphi_2(x), \dots, \varphi_N(x))^T$$

得到的最优分类函数为

$$f(x) = \text{sgn}\left(\sum_{i=1}^N w_i y_i \varphi(x_i) \cdot \varphi(x) + b\right) \quad (5)$$

上述问题中,无论是决策函数还是目标函数,都只是涉及到训练样本之间的内积运算,避免了复杂的高维运算。定义核函数为

$$K(x_i \cdot x_j) = \varphi(x_i) \cdot \varphi(x_j) \quad (6)$$

只要选取适当的内积核函数实现从低维空间到高维空间的映射,就可以实现低维非线性问题的线性

分类。核函数的选取没有统一原则,本文结合实际情况选择径向基函数(Radial Basis Function, RBF)作为核函数,即

$$K(x_i \cdot x_j) = \exp(-\gamma |x_i - x_j|^2), \gamma > 0 \quad (7)$$

1.2 基于 SVM 的增量学习算法

现有的增量学习算法大多采用神经网络和决策树算法实现,这些算法由于缺乏对训练数据有选择地遗忘淘汰机制,容易出现训练数据过量匹配和降低分类精度的问题。而基于 SVM 的增量学习算法的优点主要体现在以下两方面^[14]:首先,无需保存历史数据,大大减小了存储空间;其次,充分利用了历史训练结果,显著减少了后续的训练时间,提高了分类精度。

基于 SVM 的增量学习问题可描述如下:

(1)前提条件:存在历史数据集 A 、增量样本 B ,并假定这两个数据集满足条件 $A \cap B = \Phi$, ψ_1 和 SV_a 分别为数据集 A 上的初始 SVM 分类器以及对应的支持向量集。

(2)学习目标:寻找基于样本集合 $A \cup B$ 上 SVM 分类器 ψ 和对应的支持向量集 SV 。

基于 SVM 的增量学习算法的基本思想如图 1 所示,具体步骤如下:

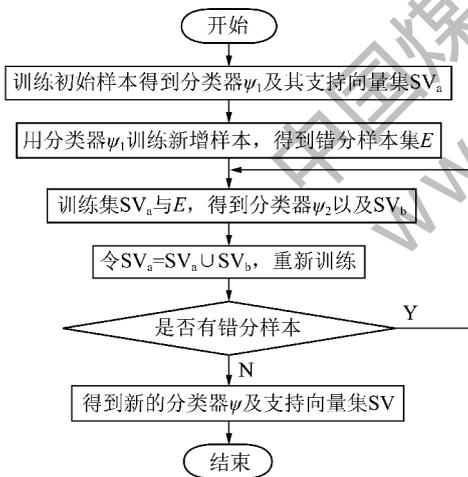


图 1 增量学习流程

Fig. 1 Chart of the incremental learning

(1)训练初始样本,得到分类器 ψ_1 和支持向量集 SV_a 。

(2)利用分类器 ψ_1 训练新增样本得到错分样本集 E 。

(3)训练 SV_a 与 E 得到新的分类器 ψ_2 和支持向量集 SV_b 。

(4)取 SV_a 与 SV_b 的并集作为新的训练集,对错分样本重新训练,直到没有错分样本为止。

(5)得到最终分类器 ψ 与支持向量集 SV 。

2 故障特征提取

本文以矿用高压配电装置中常用的 ZNY1-10(6)/630-12.5 型永磁操作机构高压真空断路器为研究对象,其永磁机构控制回路通过电压互感器从主回路获取电能,并通过开关电源将交流电转换为直流电(155 VDC)为电容储能。特征提取作为故障模式识别的重要环节,提取的特征量要求能够全面、准确地反映断路器实际故障,并且各特征量之间尽量避免信息冗余^[15-16]。断路器控制回路电流信号与电压信号以及断路器振动信号特征量的提取方法如下所述。

2.1 控制回路信号特征提取

当控制回路线圈中通有瞬间大电流时,动铁芯在电磁力作用下动作,使断路器合闸或分闸。线圈电流与电压信号中包含着丰富的状态信息,能够反映出电磁铁本身及其所控制的连杆机构和触头在分合闸过程中的工作状态。它们属于时域信号,信号曲线上的拐点时刻与断路器从一个状态向下一状态的过渡时刻相对应,这一过渡阶段从曲线上可以明显反映出断路器运行状态,相应的特征提取方法在多篇文献中都得到论证^[14,17]。本文选取线圈电流与电压信号曲线拐点处的坐标作为特征量,具体的特征提取步骤如下:

(1)滤波。为了尽量减小滤波算法在时域上的延迟,避免滤波窗口过大,遗漏重要的幅值信号,选取了拓扑结构为三阶 Bessel 的 IIR 滤波器。

(2)求极值点坐标。对滤波之后的信号求取极值,获取各极值点的坐标值,即为所求特征量。

(3)特征量归一化。为了消除指标之间的量纲影响,方便后续数据处理,对所求得特征量映射到 $[0, 1]$ 之间,转换函数如下:

$$X^* = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (8)$$

本文选用 CSM030SY 霍尔电流传感器与 VSM200D 霍尔电压传感器分别测量线圈电流与电压信号,采样频率为 17 kHz。采集到的线圈电流与电压波形如图 2,3 所示,同时在图中标注出了需要提取的各个特征量。 T_1 为线圈电流产生的电磁力可以驱动铁芯运动的时刻, T_2 为动铁芯运动停止时刻, T_3 为连杆接触到行程开关的时刻,它们分别与特征电流 I_1, I_2, I_3 相对应; T_4 为辅助开关触点断开时刻; I_4 为断路器的维持电流; T_5 为储能电容向控制回路放电的开始时刻, T_6 为放电结束时刻,分别与特征电压 U_1, U_2 对应。

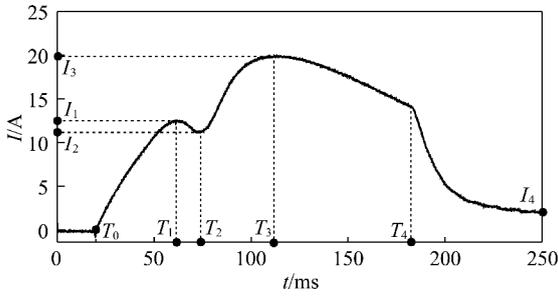


图2 线圈电流波形及相应特征量

Fig. 2 Waveform and features of coil current

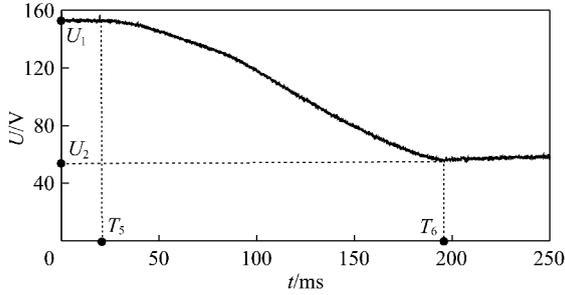


图3 线圈电压波形及相应特征量

Fig. 3 Waveform and features of coil voltage

2.2 振动信号特征提取

高压断路器振动信号是一种典型的冲击型非平稳信号,包含着丰富的状态信息与特征信息。振动信号特征提取方法主要有时域范围内的短时能量法与包络谱分析等,频域范围内的傅里叶分析与模态分析等,以及时频域相结合的希尔伯特变换与小波变换法等。本文选取目前应用效果较好的小波包分析法,该方法通过多层次划分频带进一步细分高频部分,使频带与信号频谱相匹配,提高了信号特征分辨率^[15,18-20]。具体特征提取步骤如下:

(1) 小波降噪

本文选用 LC0159T 加速度传感器采集断路器动触头振动信号,采样频率 20 kHz。所采集的原始信号进行小波降噪的主要步骤为:① 对信号进行小波分解;② 利用分层阈值对信号进行软阈值降噪处理;③ 信号重构。

通过配置参数,得出以下结论:当小波基函数选取 db4、阈值选取 3 时,降噪效果比较理想。降噪前后的信号波形如图 4 所示。

(2) 小波包分解

采样频率为 20 kHz,根据采样定理,奈奎斯特频率是 10 kHz,对降噪处理后的信号进行小波包 3 层分解,得到 8 段频率下的信号,每个频率段的频率区间宽度为 10 kHz/8=1.25 kHz,见表 1。

(3) 特征值提取

当断路器运行状态异常或出现故障时,表现为振

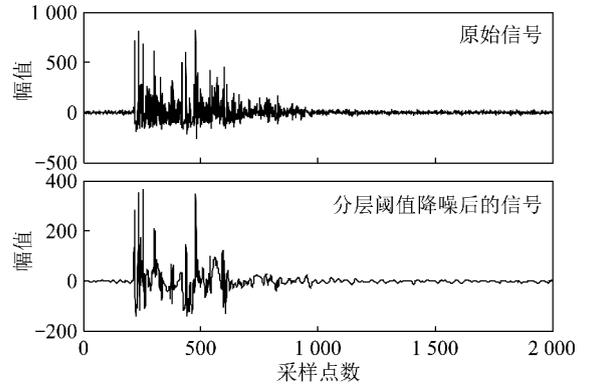


图4 降噪前后信号波形

Fig. 4 Signal waveform before and after noise reduction

表1 频率子带的划分

Table 1 Division of frequency subbands

频带序号	频率/kHz	频带序号	频率/kHz
1	0 ~ 1.25	5	5.00 ~ 6.25
2	1.25 ~ 2.50	6	6.25 ~ 7.50
3	2.50 ~ 3.75	7	7.50 ~ 8.75
4	3.75 ~ 5.00	8	8.75 ~ 10.00

动信号各频率成分的能量发生了相应变化。因此,可以用某一种或几种频率成分能量值的改变来表征断路器所对应的异常或故障状态。

设断路器振动信号长度为 N ,对信号进行 j 层小波包分解,得到分解序列 $X_{jk}(k=0 \sim 2^j-1)$ 。对分解系数进行单支重构后得到信号 S_{jk} ,设 E_{jk} 为重构信号在第 j 层第 k 个节点上的功率,则有 $E_{jk} = |S_{jk}|^2$ 。令 $\varepsilon_{jk} = E_{jk}/E$,则 $\sum \varepsilon_{jk} = 1$ 。定义小波包能量熵为

$$H_{jk} = - \sum_{i=1}^N \varepsilon_{jk}(i) \log |\varepsilon_{jk}(i)| \quad (9)$$

其中, H_{jk} 为信号的第 j 层第 k 个小波包能量熵。则对信号进行 3 层小波包分解之后,得到 8 个频带上的能量熵,对各个能量熵归一化处理如下:

令

$$H = \left[\sum_{k=0}^7 |H_{3k}|^2 \right]^{1/2} \quad (10)$$

则有

$$T = \left[\frac{H_{30}}{H}, \frac{H_{31}}{H}, \frac{H_{32}}{H}, \frac{H_{33}}{H}, \frac{H_{34}}{H}, \frac{H_{35}}{H}, \frac{H_{36}}{H}, \frac{H_{37}}{H} \right] \quad (11)$$

归一化之后的能量熵可作为断路器状态特征量,对所采集的振动信号进行归一化处理,结果如图 5 所示。

3 实验分析

3.1 故障模拟及数据样本建立

为了获取故障数据,在借鉴前人经验的基础上,

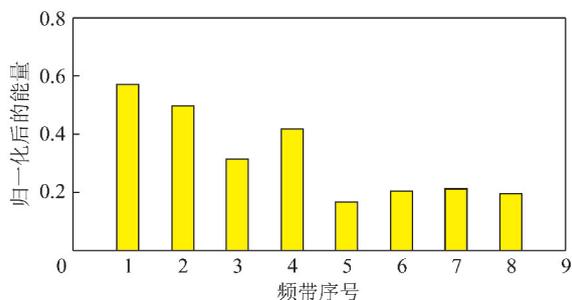


图 5 振动信号归一化能量谱

Fig. 5 Energy spectrum of the vibration signal

通过控制螺丝的松动程度、在传动拐臂转轴上施加不同的作用力、利用交流调压器改变输入电压、主控制回路中串接相应阻值的电阻等办法,对高压断路器控制回路中弹簧松动、铁心卡涩、供电异常与线圈老化等 4 种常见故障进行了模拟,具体步骤在文献[17]中有详细阐述,在此不再详述。故障模拟及数据采集试验现场如图 6 所示。

按照前述故障特征提取方法,对上述 4 种故障各提取了 50 组数据,同时提取了 5 组正常情况下的特



图 6 故障模拟及数据采集试验现场

Fig. 6 Test field of fault simulation and data acquisition

征量作为参照数据。将特征量归一化后并分组,对每种故障数据随机均匀抽取 20 组作为模型训练数据,组别记为 0;再随机均匀选 10 组作为增量学习数据,组别记为 1;另外 20 组作为模型验证数据,组别记为 2。得到特征量数据样本见表 2。表中, $I_1 \sim I_4, T_1 \sim T_6, U_1, U_2$ 分别为控制回路各特征量的归一化计算结果; $H_1 \sim H_8$ 分别为振动信号 8 个频带上能量熵的归一化计算结果。

表 2 归一化后特征量汇总

Table 2 Feature summary of the normalized characteristic quantity

特征量	正常(0)	正常(0)	...	弹簧松 动(1)	弹簧松 动(1)	...	铁心卡 涩(2)	铁心卡 涩(2)	...	供电异 常(3)	供电异 常(3)	...	线圈老 化(4)	线圈老 化(4)
I_1	0.790 4	0.749 3		0.671 3	0.738 6		0.768 9	0.767 3		0.727 6	0.733 5		0.662 0	0.689 9
I_2	0.514 4	0.584 3		0.514 8	0.599 9		0.648 7	0.625 6		0.588 1	0.583 5		0.791 1	0.718 5
I_3	0.534 1	0.590 1		0.636 3	0.678 7		0.589 7	0.549 5		0.411 7	0.495 2		0.447 6	0.515 5
I_4	0.850 7	0.760 6		0.696 7	0.582 8		0.879 0	0.788 9		0.729 6	0.615 4		0.700 5	0.865 4
T_1	0.612 6	0.598 9		0.479 5	0.601 3		0.498 1	0.500 9		0.527 7	0.627 8		0.574 7	0.545 2
T_2	0.738 6	0.733 5		0.666 4	0.683 5		0.660 9	0.729 8		0.646 7	0.626 1		0.690 8	0.682 3
T_3	0.592 0	0.581 4		0.580 1	0.501 7		0.462 7	0.484 3		0.428 3	0.520 9		0.544 9	0.409 4
T_4	0.552 3	0.529 9		0.614 7	0.562 4		0.489 6	0.492 5		0.403 2	0.449 5		0.423 1	0.405 5
U_1	0.146 5	0.189 1		0.035 2	0.281 9		0.195 2	0.299 1		0.042 7	0.038 6		0.135 8	0.145 2
U_2	0.123 9	0.190 4		0.273 9	0.270 3		0.256 5	0.240 3		0.185 3	0.208 5		0.241 7	0.206 1
T_5	0.047 9	0.082 1		0.014 2	0.016 6		0.073 7	0.052 1		0.105 7	0.062 1		0.031 2	0.128 7
T_6	0.037 8	0.063 4		0.034 4	0.084 4		0.085 6	0.013 4		0.060 4	0.058 9		0.177 6	0.198 6
H_1	0.058 7	0.061 9		0.050 2	0.062 0		0.041 9	0.032 9		0.070 3	0.016 2		0.056 4	0.013 5
H_2	0.582 2	0.540 7		0.564 8	0.618 1		0.639 8	0.645 6		0.569 9	0.559 2		0.609 5	0.639 3
H_3	0.044 7	0.047 3		0.021 0	0.022 5		0.018 7	0.005 8		0.043 9	0.093 7		0.009 7	0.063 6
H_4	0.104 6	0.148 4		0.163 5	0.127 9		0.132 9	0.172 7		0.165 8	0.172 0		0.192 1	0.138 9
H_5	0.036 3	0.033 8		0.030 3	0.031 1		0.033 5	0.031 4		0.035 4	0.034 9		0.031 3	0.030 1
H_6	0.037 7	0.041 5		0.032 1	0.044 5		0.042 8	0.042 4		0.036 1	0.034 9		0.037 8	0.039 2
H_7	0.036 3	0.034 7		0.040 4	0.042 3		0.030 9	0.024 3		0.033 4	0.049 6		0.030 3	0.037 1
H_8	0.099 5	0.091 7		0.097 7	0.051 6		0.059 5	0.044 9		0.045 2	0.039 5		0.032 9	0.038 3
序号	1	2		6	7		56	57		106	107		156	157
组别	1	0		2	1		0	1		1	2		1	1

3.2 故障识别模型的建立

采用核函数为 RBF 的 C-SVC 模型对故障模式进行识别时,首先需要对模型参数错误惩罚因子 C 和 Gamma 参数 g 进行最优化选择,寻找最佳的 (C, g) 参数对,使分类器的分类效果最优。具体寻优过程为:选择 C, g 的参数范围,将范围构成的二维空间内所有的 (C, g) 构成参数对,并将训练数据(组别 0)作为原始数据,求得此组参数对下分类模型的平均分类准确率,选取准确率最高的 (C, g) 参数对即为最优参数对。本文选取的 C, g 参数范围为均为 $(2^{-5}, 2^5)$,寻优效果如图 7 所示。

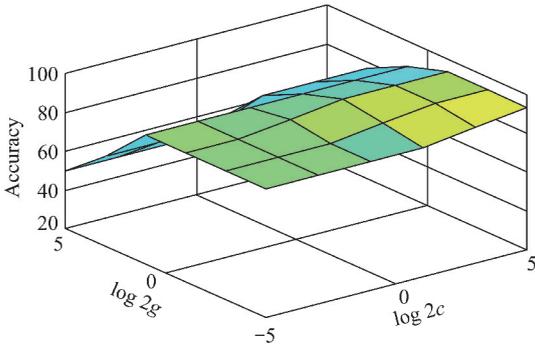


图 7 参数寻优效果

Fig. 7 Effect figure of parameter optimization

选取 $C = 8, g = 0.03125$ 可使识别准确率达到 90% 以上,训练出的识别模型见表 3。

表 3 原始数据训练模型参数

Table 3 Table of original data training model parameter

参数	值	含义
model. Label	[0;1;2;3;4]	相应故障类别的标签
model. nSV	[5;5;3;3;6]	各类数据中支持向量个数
model. sv_coef	<22x5 double>	决策函数中的系数
model. SVs	<22x20 double>	支持向量
model. rho	<4x1 double>	常数项的相反数(-b)

利用增量学习数据(组别 1),按照上文步骤重新对原始数据模型进行训练,得到增量学习训练模型见表 4。训练出的分类模型本质上是一个决策函数。由式(6),(8)可推出最优分类决策模型如下:

$$f(x) = \text{sgn}\left(\sum_{i=1}^N w_i \exp(-\gamma |x_i - x|^2) + b\right) \quad (12)$$

式中, w_i 为支持向量的系数,与表 3,4 中的参数 model. sv_coef 相对应; γ 即参数 g ; x_i 表示支持向量,与表中 model. SVs 相对应; x 表示输入待预测向量; b 代表偏置,是参数 model. rho 的负数。

比较原始数据训练模型与增量学习训练模型,发现通过进一步增量学习训练,使得模型中的支持向量个数增加,同时对于每一类故障中的支持向量个数也增加,相应的故障类别没有变化。

表 4 增量学习训练模型参数

Table 4 Table of incremental learning training model parameter

参数	值	含义
model. Label	[0;1;2;3;4]	相应故障类别的标签
model. nSV	[9;10;13;6;7]	各类数据中支持向量个数
model. sv_coef	<45x5 double>	决策函数中的系数
model. SVs	<45x20 double>	支持向量
model. rho	<4x1 double>	常数项的相反数(-b)

3.3 模型测试

为了验证增量学习算法的效果,需要对训练模型进一步测试。具体过程为:将模型验证数据(组别 2)分别代入原始数据训练模型与增量学习训练模型,求得各个模型的识别准确率,以此来评价分类器的性能。上文在建立数据样本时已随机均匀选出了 20 组测试数据,将该数据分别代入上述模型中,发现原始数据训练出的模型对于正常情况(标号 0)与供电异常故障(标号 3)各有 1 次没有准确识别,而增量学习模型对各个故障全部识别准确,具体情况见表 5。

表 5 模型准确率对比

Table 5 Comparison of the model accuracy

类别	正确样本数	错误类别	准确率/%
初始数据训练模型	18	0,3	90
增量学习数据训练模型	20	—	100

4 结 论

(1) 选取永磁机构高压断路器控制回路中的电流信号与电压信号以及断路器振动信号,作为故障模式识别的监测信号,可以整体反映出断路器的上述 4 种常见故障。

(2) 本文采用的基于时域特征的控制回路信号特征提取方法,与基于小波包分析的振动信号特征提取方法,2 者结合可以有效反映出故障特征,由提取到的数据建立的特征数据样本满足了模型训练的要求。

(3) 基于支持向量机的增量学习故障分类算法可以对小样本的高压断路器故障进行有效识别,同时,当有新增样本时,该算法可以通过学习训练进一步提高识别精度。

参考文献(References):

- [1] KEZUNOVIC M, NAIL C, REN Z, et al. Automated circuit breaker monitoring and analysis [A]. Proc IEEE Power Eng Soc Trans Distrib Conf [C]. IEEE, 2002; 559-564.
- [2] NI J, ZHANG C, YANG S X. An adaptive approach based on KPCA and SVM for real-time fault diagnosis of HVCBs [J]. Power Delivery, IEEE Transactions on, 2011, 26(3): 1960-1971.
- [3] WANG Jinhua. Development and prospect on fully mechanized mining in Chinese coal mines [J]. International Journal of Coal Science & Technology, 2014, 1(3): 153-260.
- [4] 李斌, 郭凤仪, 王智勇, 等. 双稳态永磁机构优化设计及智能控制器 [J]. 电工技术学报, 2013, 28(10): 83-89.
LI Bin, GUO Fengyi, WANG Zhiyong, et al. Bi-State PMA optimization design and intelligent controller [J]. Transactions of China Electrotechnical Society, 2013, 28(10): 83-89.
- [5] 孙一航, 武建文, 廉世军, 等. 结合经验模态分解能量总量法的断路器振动信号特征向量提取 [J]. 电工技术学报, 2014, 29(3): 228-236.
SUN Yihang, WU Jianwen, LIAN Shijun, et al. Extraction of vibration signal feature vector of circuit breaker based on empirical mode decomposition amount of energy [J]. Transactions of China Electrotechnical Society, 2014, 29(3): 228-236.
- [6] 梅飞, 梅军, 郑建勇, 等. 粒子群优化的 KFCM 及 SVM 诊断模型在断路器故障诊断中的应用 [J]. 中国电机工程学报, 2013, 33(36): 134-141.
MEI Fei, MEI Jun, ZHENG Jianyong, et al. Application of particle swarm fused KFCM and classification model of SVM for fault diagnosis of circuit breaker [J]. Proceedings of the CSEE, 2013, 33(36): 134-141.
- [7] 赵金宪, 涂展, 谢阳. 粒子群改进算法在配电网故障定位中的应用 [J]. 黑龙江科技大学学报, 2014, 24(3): 277-281.
ZHAO Jinxian, TU Zhan, XIE Yang. Application of improved binary particle swarm optimization for fault location in distribution network with distributed generation [J]. Journal of Heilongjiang University of Science & Technology, 2014, 24(3): 277-281.
- [8] 黄建, 胡晓光, 巩玉楠, 等. 高压断路器机械故障诊断专家系统设计 [J]. 电机与控制学报, 2011, 15(10): 43-49.
HUANG Jian, HU Xiaoguang, GONG Yunan, et al. Machinery fault diagnosis expert system for high voltage circuit breaker [J]. Electric Machines and Control, 2011, 15(10): 43-49.
- [9] 齐贺, 赵智忠, 李振华, 等. 基于多传感器振动信号融合的真空中断路器故障诊断 [J]. 高压电器, 2013, 49(2): 43-48.
QI He, ZHAO Zhizhong, LI Zhenhua, et al. Fault diagnosis of vacuum circuit breaker based on multi-sensor for vibration signals of fusion [J]. High Voltage Apparatus, 2013, 49(2): 43-48.
- [10] ZHANG K, QIAN K, CHAI Y, et al. Research on fault diagnosis of tennessee eastman process based on KPCA and SVM [A]. 7th International Symposium on Computational Intelligence and Design [C]. ISCID, 2014: 490-495.
- [11] 王振浩, 杜凌艳, 李国庆, 等. 动态时间规整算法诊断高压断路器故障 [J]. 高电压技术, 2006, 32(10): 36-38.
WANG Zhenhao, DU Lingyan, LI Guoqing, et al. Fault diagnosis of high voltage circuit breakers based on dynamic time warping algorithm [J]. High Voltage Engineering, 2006, 32(10): 36-38.
- [12] HUANG J, HU X, YANG F. Support vector machine with genetic algorithm for machinery fault diagnosis of high voltage circuit breaker [J]. Measurement, 2011, 44(6): 1018-1027.
- [13] 丁世飞, 齐丙娟, 谭红艳. 支持向量机理论与算法研究综述 [J]. 电子科技大学学报, 2011, 40(1): 2-10.
DING Shifei, QI Bingjuan, TAN Hongyan. An overview on theory and algorithm of support vector machines [J]. Journal of University of Electronic Science and Technology of China, 2011, 40(1): 2-10.
- [14] 袁金丽, 李奎, 郭志涛, 等. 基于 SVM 与合分闸线圈电流参数的高压断路器机械故障诊断 [J]. 高压电器, 2011, 47(3): 26-30.
YUAN Jinli, LI Kui, GUO Zhitao, et al. Mechanical failure diagnosis of high voltage circuit breaker based on SVM and opening/closing coil current parameters [J]. High Voltage Apparatus, 2011, 47(3): 26-30.
- [15] 夏彦, 许春雨, 宋建成, 等. 基于 LabVIEW 的高压配电装置振动信号特征提取和模式识别方法 [J]. 煤矿安全, 2015, 46(8): 103-106.
XIA Yan, XU Chunyu, SONG Jiancheng, et al. feature extraction and pattern recognition method of vibration signals in high voltage distribution equipment based on LabVIEW [J]. Safety in Coal Mines, 2015, 46(8): 103-106.
- [16] LU D, QIAO W. Adaptive feature extraction and SVM classification for real-time fault diagnosis of drivetrain gearboxes [A]. 2013 IEEE Energy Conversion Congress and Exposition [C]. ECCE, 2013: 3934-3940.
- [17] 赵钰, 耿蒲龙, 许春雨, 等. 基于控制回路的断路器永磁机构故障特征提取方法 [J]. 高压电器, 2017, 53(2): 39-46.
ZHAO Yu, GENG Pulong, XU Chunyu, et al. Fault feature extraction method of the circuit breaker with permanent magnetic mechanism based on control loop [J]. High Voltage Apparatus, 2017, 53(2): 39-46.
- [18] SOUALHI A, MEDJAHAR K, ZERHOUNI N. Bearing health monitoring based on Hilbert-Huang Transform, Support Vector Machine, and regression [J]. IEEE Transactions on Instrumentation & Measurement, 2015, 64(1): 52-62.
- [19] 徐晶, 刘德坤, 刘彦慧, 等. 基于小波包能量谱及 SVM 算法的轴承故障检测 [J]. 黑龙江科技大学学报, 2015, 25(1): 110-114.
XU Jing, LIU Dekun, LIU Yanhui, et al. Bearing fault detection method based on wavelet packet energy spectrum and SVM algorithm [J]. Journal of Heilongjiang University of Science & Technology, 2015, 25(1): 110-114.
- [20] 孙来军, 胡晓光, 纪延超. 基于支持向量机的高压断路器机械状态分类 [J]. 电工技术学报, 2006, 21(8): 53-58.
SUN Laijun, HU Xiaoguang, JI Yanchao. Mechanical fault classification of high voltage circuit breaker based on support vector machine [J]. Transactions of China Electrotechnical Society, 2006, 21(8): 53-58.