

6-5-2020

## Fault Diagnosis Model of Circuit Breaker Based on Sparse Representation and M-ELM

Weihua Niu

*1. Department of Computer, North China Electric Power University, Baoding, 071003, China;;*

Guishu Liang

*2. Department of Electrical Engineering, North China Electric Power University, Baoding, 071003, China;;*

Zhao Peng

*3. State Grid Hebei Electrical Power Company, Shijiazhuang, 050021, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Fault Diagnosis Model of Circuit Breaker Based on Sparse Representation and M-ELM

## Abstract

**Abstract:** In order to improve the deficiencies of the conventional methods used to evaluate the mechanical properties of circuit breaker, *a new circuit breaker diagnosis model based on sparse representation and M-ELM (Memetic-Extreme Learning Machine) is constructed*. Auxiliary mark motion on the pull rod or shaft is recorded by a high speed camera when the circuit breaker is open or close. The motion trajectory is acquired through sparse representation and mechanical parameters, such as open and close velocity, are calculated according to the travel-time curve of the circuit breaker. *With mechanical parameters characteristic values being inputs of M-ELM, fault of circuit breaker can be diagnosed*. Experiment results on the circuit breaker of 12kV show the effectiveness and superiority of the model.

## Keywords

circuit breaker, object tracking, sparse representation, multi-feature fusion, M-ELM

## Recommended Citation

Niu Weihua, Liang Guishu, Zhao Peng. Fault Diagnosis Model of Circuit Breaker Based on Sparse Representation and M-ELM[J]. Journal of System Simulation, 2017, 29(11): 2828-2839.

# 基于稀疏表示和 M-ELM 的断路器故障诊断模型

牛为华<sup>1</sup>, 梁贵书<sup>2</sup>, 赵鹏<sup>3</sup>

(1.华北电力大学计算机系, 保定 071003; 2.华北电力大学电力工程系, 保定 071003; 3.国网河北省电力公司, 石家庄 050021)

**摘要:** 针对传统断路器机械特性评估方法的不足, 构建了基于稀疏表示和 M-ELM(Memetic-Extreme Learning Machine)的断路器故障诊断模型, 该模型首先利用稀疏表示方法跟踪断路器分(合)闸过程中与动触头同步运动的连杆或主轴上辅助标志物运动的轨迹; 然后, 根据该轨迹获取断路器操动机构的行程时间曲线并据此计算断路器的分(合)闸速度等各种机械特性参数; 最后, 将动触头运动机械特性参数作为 M-ELM 的输入进行断路器的故障诊断。通过对 12 kV 真空断路器的测试实验证明了该模型诊断断路器状态的有效性和优越性。

**关键词:** 断路器; 目标跟踪; 稀疏表示; 多特征联合; M-ELM

中图分类号: TM76

文献标识码: A

文章编号: 1004-731X (2017) 11-2828-12

DOI: 10.16182/j.issn1004731x.joss.201711032

## Fault Diagnosis Model of Circuit Breaker Based on Sparse Representation and M-ELM

Niu Weihua<sup>1</sup>, Liang Guishu<sup>2</sup>, Zhao Peng<sup>3</sup>

(1.Department of Computer, North China Electric Power University, Baoding, 071003, China;

2.Department of Electrical Engineering, North China Electric Power University, Baoding, 071003, China;

3.State Grid Hebei Electrical Power Company, Shijiazhuang, 050021, China)

**Abstract:** In order to improve the deficiencies of the conventional methods used to evaluate the mechanical properties of circuit breaker, a new circuit breaker diagnosis model based on sparse representation and M-ELM (Memetic-Extreme Learning Machine) is constructed. Auxiliary mark motion on the pull rod or shaft is recorded by a high speed camera when the circuit breaker is open or close. The motion trajectory is acquired through sparse representation and mechanical parameters, such as open and close velocity, are calculated according to the travel-time curve of the circuit breaker. With mechanical parameters characteristic values being inputs of M-ELM, fault of circuit breaker can be diagnosed. Experiment results on the circuit breaker of 12kV show the effectiveness and superiority of the model.

**Keywords:** circuit breaker; object tracking; sparse representation; multi-feature fusion; M-ELM

## 引言

断路器的运行、维护和检修状况与整个电力系统可靠性密切相关。国际大电网会议对高压断路器

可靠性评估表明, 断路器发生的主要故障中有 64.8%由于操作机械故障, 14%由于绝缘故障, 6%由于 SF6 气体泄漏及其它原因引起的故障<sup>[1]</sup>, 可见操动机构故障是断路器的主要故障原因。目前, 在断路器的故障数据选择上, 主要有振动信号<sup>[2-4]</sup>、分合闸电流<sup>[5]</sup>、合闸弹簧<sup>[6]</sup>以及动触头位移或主轴转角<sup>[7]</sup>等。行程时间特性在断路器操动机构性能的评估中占据着重要地位, 行程时间曲线能够显示出



收稿日期: 2017-01-06 修回日期: 2017-04-18;  
基金项目: 中央高校基本科研业务费专项资金 (2017MS156);

作者简介: 牛为华(1978-), 女, 天津, 博士生, 讲师, 研究方向为图像处理技术在电力系统中的应用; 梁贵书(1961-), 男, 河北, 博士, 教授, 博导, 研究方向为电网络理论及其应用等。

<http://www.china-simulation.com>

• 2828 •

断路器的运行状态。通过监测获取断路器的行程时间特性, 可以获得断路器动触头行程、开距、分(合)闸速度等机械参量<sup>[8-9]</sup>。然而, 由于断路器的动触头在真空灭弧室内, 在线测量时处于高电位对隔离要求很高, 直接测量动触头的运动不方便, 一般是通过间接测量与动触头运动成线性关系的其它机械结构的运动来获得。常用的测量断路器机械特性的传感器有直线位移传感器、光栅传感器、导电塑料电位器和角位移传感器, 这些传感器安装在断路器内部与动触头相连且同步运动的绝缘拉杆或主轴上, 可以测量断路器动作时的直线或角位移特性<sup>[10-13]</sup>。传统的测试方法如采用光栅传感器、导电塑料电位器等角位移传感器是接触式的, 在测量断路器动作特征时需要一次设备停电, 不仅增加了停电时间, 而且一次回路要接线, 需要登高作业, 增加了作业风险。因此, 基于“非接触”技术的高精度断路器机械特性检测方法是解决上述问题的一个有效途径。

本文在应用高速、高分辨率相机捕获断路器操作中连接传动部件运动图像序列的基础上, 提出了一种由图像分析和跟踪技术获取传动部件运动轨迹的方法, 并根据断路器的行程时间特性曲线计算了动触头观测行程、分(合)闸时间和速度等机械特征参数, 构建了基于 Memetic 算法的极限学习机

(M-ELM, Memetic Extreme Learning Machine)断路器故障诊断模型, 结合实际样本数据, 验证了本文方法的有效性。

## 1 断路器动触头运动特征提取

### 1.1 多特征联合稀疏表示跟踪方法

为了准确跟踪断路器的快速运动, 本文提出一种基于多特征联合稀疏表示的跟踪方法(MFLS, Multiple Features Structured Local Sparse Representation)。

#### (1) 目标图像区域局部分块

对目标图像区域分块的方法并不唯一, Xu 等<sup>[14]</sup>提出的局部分块方式采用子块大小为  $16 \times 16$  像素, 步长为 8 像素, 故对于  $32 \times 32$  像素的跟踪区域, 共产生了 9 个重叠子块。为了更加准确的跟踪目标, 本文将目标图像区域分为大小不等的 9 块, 即目标块大小为  $30 \times 30$  像素, 其中子块 1 和子块 2 为  $10 \times 20$  像素, 子块 3 和子块 4 为  $20 \times 10$  像素, 子块 5 为  $10 \times 10$  像素, 子块 6、子块 7、子块 8 和子块 9 为  $20 \times 20$  像素, 如图 1 所示。中间重叠的子块 5 中包含更多跟踪目标的信息, 这部分信息多次计算会增强跟踪的鲁棒性。

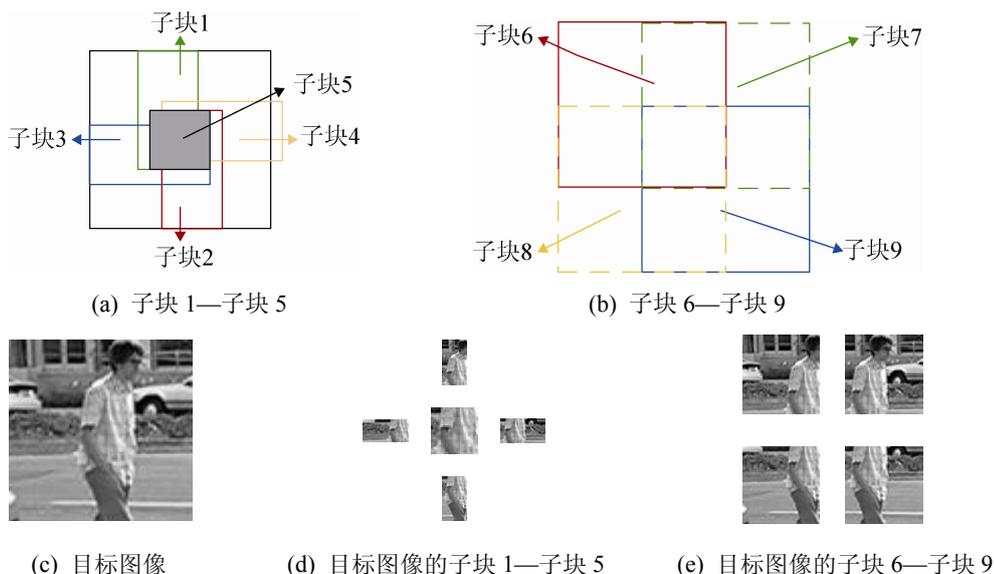


图 1 目标图像区域分块图  
Fig. 1 Target image region patch

<http://www.china-simulation.com>

(2) 目标局部块的特征描述

根据图像区域分块的方法, 将不同位置的块看成不同类别, 则每一个目标图像所包含的块数就相当于类别个数。

假设采用  $K$  个不同的特征, 对于每个特征索引  $k=1,2,\dots,K$ , 模板字典表示为  $X^k=[X_1^k, X_2^k, \dots, X_J^k] \in R^{d_k \times p}$ , 其中  $J$  表示类别数 (单个目标模板所分成的局部块数量),  $X_j^k \in R^{d_k \times p_j}$  表示第  $j$  类局部块的第  $k$  个特征,  $d_k$  是第  $k$  个特征的维数。由于根据局部块的位置划分类别且相同位置的局部块属于同一类, 故本方法中各个类的局部块数目都是相同的, 每一类局部块的数目等于字典模板的个数  $n$ , 即

$$p = \sum_{j=1}^J p_j = n \times J$$

本文选取灰度特征和 HOG 特征,  $K=2$ , 考虑到方法的通用性, 特征数仍用  $K$  表示。

(3) 联合稀疏表示

候选样本(抽样粒子)采用与字典模板相同的特征, 且每块用字典中所有块进行稀疏表示。用  $Y_j^k = [[y_j^k]^{(1)}, [y_j^k]^{(2)}, \dots, [y_j^k]^{(m)}] \in R^{d_k \times m}$  表示第  $j$  类  $m$  个候选样本的第  $k$  个特征量, 则可用字典模板块将其线性表示为

$$Y_j^k = X^k w_j^k + \varepsilon_j^k, k=1,2,\dots,K \quad (1)$$

式(1)中,  $w_j^k \in R^{p \times m}$  是第  $j$  类  $m$  个候选样本在特征  $k$  下的表示系数,  $\varepsilon_j^k \in R^{d_k \times m}$  是残差项,

$w_j = \left[ [w_j^1]^T, [w_j^2]^T, \dots, [w_j^K]^T \right]^T \in R^{(K \times p) \times m}$  为联合所有  $K$  个特征对应于第  $j$  类模板的表示系数。因此, 多特征联合稀疏表示可表示为

$$\min_{w_j} \frac{1}{2} \sum_{k=1}^K \left\| (Y_j^k - X^k w_j^k) \right\|_2^2 + \lambda \left\| w_j^T \right\|_{2,1} \quad (2)$$

式(2)中,  $\left\| w_j^T \right\|_{2,1} = \sum_{i=1}^m \left\| [w_j^T]_i \right\|_2$ ,  $[w_j^T]_i$  是  $w_j$  转置后的第  $i$  行。

在局部块中, 不同特征描述的维数不同, 为了使特征之间的维数统一, 需要先对字典模板  $X^k$  和候选样本  $Y_j^k$  进行核化处理, 具体过程为

$$\begin{aligned} X^k \in R^{d_k \times p} &\xrightarrow{\text{核化处理}} [X^k]^T X^k \xrightarrow{\text{核化后}} X^k \in R^{p \times p} \\ Y_j^k \in R^{d_k \times p} &\xrightarrow{\text{核化处理}} [X^k]^T Y_j^k \xrightarrow{\text{核化后}} Y_j^k \in R^{p \times m} \end{aligned}$$

经核化处理后, 对候选样本的每个特征有  $X^k \in R^{p \times p}$ ,  $Y_j^k \in R^{p \times m}$ , 不同特征经过核化后的维数只与局部块的数量有关。因此, 全部特征在维数上达到了统一, 特征之间可方便快速的进行融合。

对于所有特征, 利用一个非线性函数  $\phi^k$  将构建的字典模板和候选样本从原始特征空间映射到另一个高维空间中, 对于给定的核函数  $g^k$ , 有  $\phi^k(x_i)^T \phi^k(x_j) = g^k(x_i, x_j)$ , 在高维空间中, 将式(2)写为

$$\min_{w_j} \frac{1}{2} \sum_{k=1}^K \left\| (\phi^k(Y_j^k) - \phi^k(X^k) w_j^k) \right\|_2^2 + \lambda \left\| w_j^T \right\|_{2,1} \quad (3)$$

设  $G^k = \phi^k(X^k)^T \phi^k(X^k)$  是对应第  $k$  个特征的字典模板核矩阵,  $H_j^k = \phi^k(X^k)^T \phi^k(Y_j^k)$  是对应第  $k$  个特征的第  $j$  个候选样本的核向量。利用核矩阵将  $G^k$  和  $H_j^k$  作为提取的新特征, 则式(3)可写为

$$\min_{w_j} \frac{1}{2} \sum_{k=1}^K \left\| (H_j^k - G^k w_j^k) \right\|_2^2 + \lambda \left\| w_j^T \right\|_{2,1} \quad (4)$$

利用核化加速近邻梯度法求解式(4)得到相应的稀疏系数。

(4) 跟踪方法

MFLS 方法在粒子滤波框架下实现目标的跟踪, 主要步骤如下:

1) 模板初始化: 在第一帧中, 手动得到跟踪目标的位置, 然后利用高斯分布生成  $m$  个粒子, 根据 KNN 算法得到前 10 帧的跟踪目标, 形成目标模板空间;

2) 目标区域分块: 对字典模板和候选样本进行重叠分块, 提取出每块的像素灰度值和 HOG 两个特征, 然后进行核化处理;

3) 联合稀疏表示: 利用字典模板中的所有块对候选样本中每一块分别进行多特征联合稀疏表示, 用核化加速近邻梯度法求解稀疏系数;

4) 目标状态估计: 求解各抽样粒子的重构误差, 根据重构误差最小原则得到当前帧的跟踪结果;

5) 模板更新: 根据海明距离自适应更新字典模板;

6) 如果已到最后一帧, 则跟踪结束, 否则转至 2)。

通过以上步骤可获得当前帧的目标状态和更新的字典模板。

### (5) 跟踪方法分析

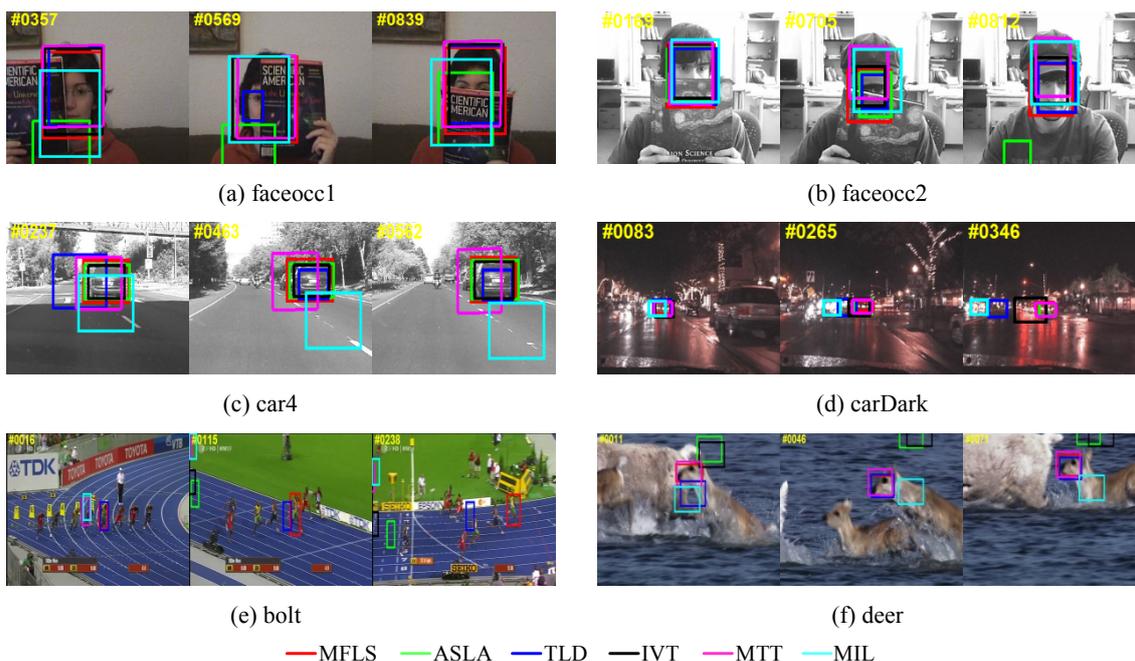


图 2 部分跟踪结果  
Fig. 2 Partial tracking results

由图 2 可以看出, 当目标图像序列出现图 2(a) 和图 2(b) 的局部遮挡情况时, ALSA 方法在图 2(a) 的 569 帧和图 2(b) 的 812 帧时出现跟踪失败; 当目标图像序列出现图 2(c) 的光照变化时, MIL 方法在 463 帧出现跟踪失败; 当目标图像序列出现图 2(d) 的背景杂波时, TLD 方法和 MIL 方法在 265 帧后都出现了跟踪失败; 当目标图像序列出现图 2(e) 的目标形态变化时, 其它几种方法在 115 帧后均出现了跟踪失败; 当目标图像序列出现图 2(f) 的快速运动时, ALSA 方法、IVT 方法和 MIL 方法均在 46 帧后出现跟踪失败。由此可见, 本文方法在目标图像序列发生各种变化时, 仍然能够准确的跟踪目标。

视频图像序列跟踪的效果可以从定性和定量

本文利用 Benchmark<sup>[15]</sup>对公开的 6 个标准图像序列进行了跟踪实验, 比较了 5 个跟踪方法, 其中 MIL<sup>[16]</sup>和 TLD<sup>[17]</sup>是判别式跟踪方法, IVT<sup>[18]</sup>、MTT<sup>[19]</sup>和 ASLA 是生成式跟踪方法。令粒子数  $m = 600$ , 正则化参数  $\lambda = 0.01$ , 字典模板每 5 帧更新一次, 跟踪结果如图 2 所示。

两方面进行评价。定性评价依靠目标跟踪的效果进行评价, 如图 2 所示。对于定量评价, 本文利用成功率均值实现跟踪方法性能的评价。设目标的真实矩形区域与目标的跟踪结果矩形区域分别是  $r_a$  和  $r_t$ , 则重叠得分定义为:  $score = area(r_t \cap r_a) / area(r_t \cup r_a)$ , 其中  $\cap$  和  $\cup$  分别表示区域的交集和并集。若跟踪方法在某一帧图像上的重叠得分  $score$  大于设定的重叠阈值  $t_0$  时, 则判定为该跟踪方法在这一帧图像上是跟踪成功的。因此, 可以将跟踪方法在一个图像序列上的跟踪成功率定义为成功跟踪的图像帧数与序列图像总帧数的比值。给定一系列重叠阈值即可得到跟踪成功率均值。

表 1 给出了本文方法与 5 个不同跟踪方法在 6

个图像序列上的跟踪成功率均值。

表 1 跟踪成功率均值  
Tab. 1 Average success rate

Video	IVT	MTT	ASLA	MIL	TLD	MFLS
faceocc1	0.83	0.83	0.31	0.57	0.52	0.89
faceocc2	0.79	0.74	0.71	0.73	0.56	0.80
carDark	0.51	0.59	0.77	0.22	0.32	0.81
car4	0.74	0.54	0.87	0.29	0.58	0.92
bolt	0.02	0.03	0.15	0.51	0.17	0.73
deer	0.21	0.58	0.59	0.20	0.39	0.72

由表 1 可看出，本文方法的成功率均值高于其它 5 个跟踪方法。图 2 和表 1 的实验结果表明，基于多特征联合稀疏表示的跟踪方法可以准确跟踪运动目标，而且较其它几种跟踪方法成功率均值更高。

### 1.2 断路器动触头运动轨迹跟踪

实验采用 ZN65-12 断路器为测试对象，对其分(合)闸及分-合-分过程进行了测试。在基于粒子滤波框架下实现目标的跟踪方法中，设定种群规模为 600，即粒子数为 600；图像序列相邻两帧采用常速随机运动模型，故惯性权重系数为单位矩阵  $I$ ，增量按照正态分布(0,1)生成，速度边界为(-3,3)；粒子适应度为目标与信息块的匹配度，按照重构误差取最小为最相似的匹配目标；跟踪过程中粒子的参数包括目标块的起始点坐标  $(x,y)$  和两个方向运动速度  $(v_x,v_y)$ 。图 3 是 600 个初始样本中前 10 个样本的示意图，由于坐标值较大，为了能更好的显示，将  $x$  轴和  $y$  轴的坐标值缩小 100 倍。

断路器分(合)闸操动过程中，绝缘拉杆及主轴均与动触头联动，实验中分别体现为直线及旋转运动，部分图像分别如图 4(a)和图 4(b)所示。通过 MFLS 方法对拉杆及主轴的运动进行跟踪后，可获取断路器动触头的行程时间曲线。对于绝缘拉杆运动可直接跟踪其运动轨迹，对于旋转运动则需跟踪图 4(b)中两目标点从而获得其运动轨迹。

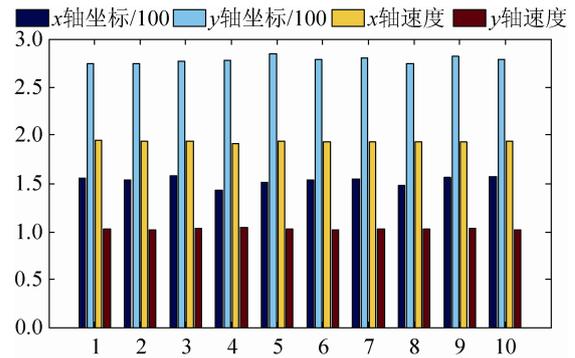
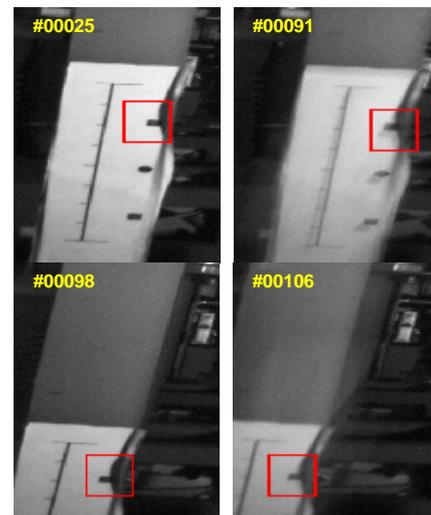
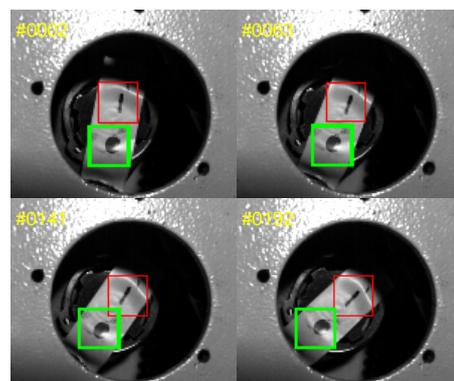


图 3 粒子参数  
Fig. 3 Particle parameters



(a) 绝缘拉杆上辅助标志物的直线运动



(b) 主轴上辅助标志物的旋转运动

图 4 断路器动作过程中辅助标志物运动过程跟踪  
Fig. 4 Tracking of auxiliary marker during circuit breaker operation

对于图 4(a)中的直线运动序列图像，在跟踪过程中，跟踪的目标模板、字典及稀疏系数分别如图 5(a)，5(b)和 5(c)所示。

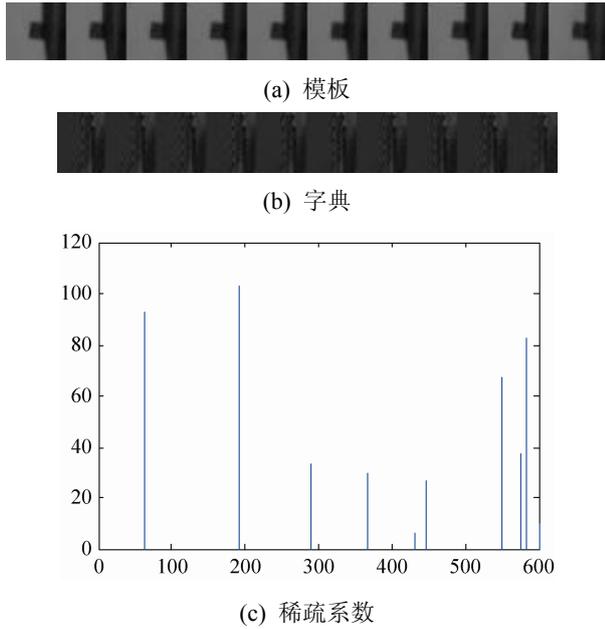


图 5 跟踪过程中的部分参数  
Fig. 5 Partial parameters in tracking

图 5(a)为模板空间, 初始时取前 10 帧的跟踪目标, 形成目标模板空间, 随着目标的运动过程实时更新模板空间。图 5(b)中每列表示字典中的一个基向量, 由于每次更新时有 600 个粒子, 共有 600 个基向量。图 5(c)为一个目标的稀疏系数, 在目标选择时, 将各待选粒子与其所对应的稀疏系数相乘, 相乘结果与模板之间的残差最小者即为跟踪结果。

图 4(b)中的旋转运动中需要合成计算出行程时间曲线。设在动作前, 两辅助标志物质心之间的连线为  $l_1$ , 动作后, 两辅助标志物质心间的连线为  $l_2$ , 则  $l_1$  到  $l_2$  的夹角  $\theta$  即为断路器动触头的角位移

(即  $l_1$  沿逆时针方向旋转到第一次与  $l_2$  重合时所转的角度)。其中,  $\theta \in [0, \pi)$ , 计算公式为

$$\operatorname{tg} \theta = \frac{k_2 - k_1}{1 + k_2 \times k_1} \quad (5)$$

其中:  $k_1$ 、 $k_2$  为直线  $l_1$ 、 $l_2$  的斜率。式(5)计算角位移的前提是  $l_1$  和  $l_2$  的斜率都存在。若都不存在, 则  $l_1$  和  $l_2$  平行, 角位移  $\theta$  为 0; 当有且只有一个斜率不存在时, 有四种情况:

- 1)  $l_2$  的斜率不存在, 且  $l_1$  与横轴的夹角  $\alpha_1 < \pi/2$ :  $\theta = \pi/2 - \alpha_1$ ;
- 2)  $l_2$  的斜率不存在, 且  $l_1$  与横轴的夹角  $\alpha_1 > \pi/2$ :  $\theta = \pi/2 + (\pi - \alpha_1)$ ;
- 3)  $l_1$  的斜率不存在, 且  $l_2$  与横轴的夹角  $\alpha_2 < \pi/2$ :  $\theta = \alpha_2 + \pi/2$ ;
- 4)  $l_1$  的斜率不存在, 且  $l_2$  与横轴的夹角  $\alpha_2 > \pi/2$ :  $\theta = \alpha_2 - \pi/2$ 。

采用多特征联合的结构化局部稀疏表示跟踪方法对拉杆上辅助标志物直线运动进行跟踪, 得到质心在 X 轴、Y 轴及图像平面上运动轨迹如图 6 所示。对主轴上两个辅助标志物的旋转运动进行跟踪, 得到其质心在 X 轴、Y 轴方向的运动轨迹分别如图 7(a)和 7(b)所示, 将其在图像平面上进行运动合成, 结果如图 7(c)所示。由拉杆及转轴上辅助标志物的运动轨迹和相机的内外参数及相机帧率可得断路器动作时的行程时间曲线。实验中 ZN65-12 断路器分(合)闸时的行程时间曲线如图 8 所示。

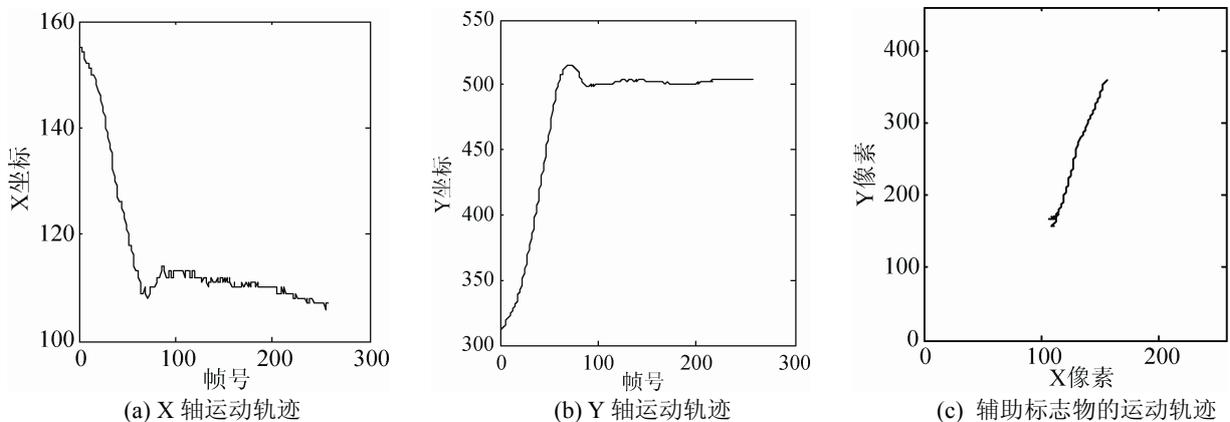


图 6 断路器动作过程中绝缘拉杆上辅助标志物的运动轨迹  
Fig. 6 Motion trajectory of auxiliary marker on pull rod

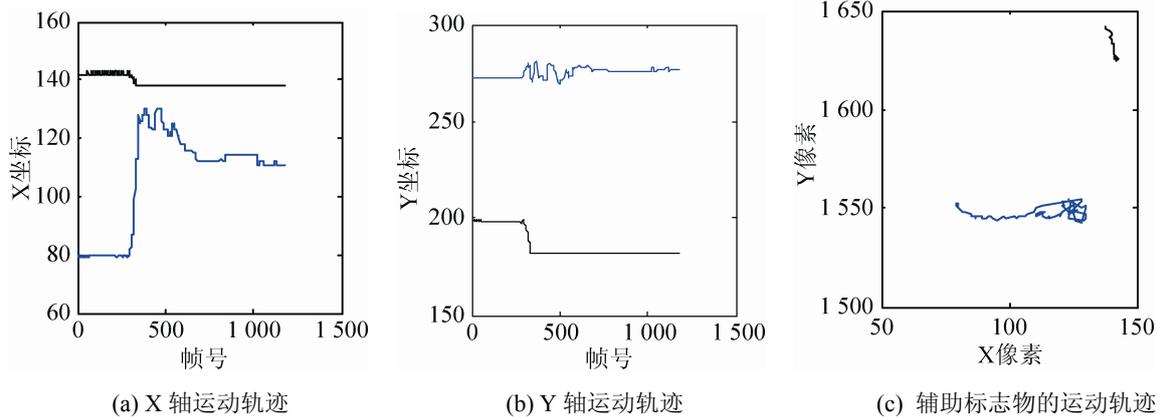


图7 断路器动作过程中主轴上两个辅助标志物的运动轨迹

Fig. 7 Motion trajectory of two auxiliary marker on shaft

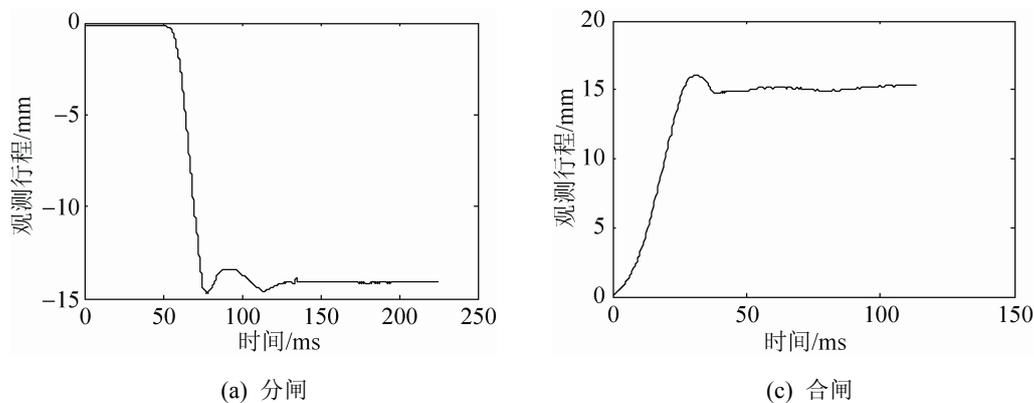


图8 断路器动作的行程时间曲线

Fig. 8 Travel-time curve of circuit breaker

从图8可以看出,采用非接触图像测量方法获取的断路器行程时间曲线,能够描绘出断路器动作时动触头的运动轨迹。

### 1.3 断路器动触头运动特征提取

在断路器进行合闸操作的时候,动触头开始迅速移动并接触静触头,这时断路器导通并接入负载。但是,由于动触头的运动过程存在一定惯性,还将继续运动并到达最高点,然后再返回接近到平衡点,形成了一个振荡到逐步稳定的过程。因此,断路器的运动行程曲线中会存在一个超调过程。图9给出了基于断路器行程时间曲线来定义和计算断路器机械特性参数的方法。

为了验证本文方法的性能,分别采用本文方法和光栅测试仪对ZN65-12断路器进行分(合)闸测试,对比结果如表2所示。由表2可见,计算断路

器的分(合)闸速度等机械特性参数与目前使用的断路器机械特性测试仪一致,且符合断路器出厂报告指标要求,说明该断路器机械特性目前满足技术要求指标,是正常运行的断路器。经过多次实验验证,基于计算机视觉的非接触测量技术是有效和可行的,能够满足断路器操动结构机械特性检测的要求,且现场测试速度更快。

断路器故障诊断时,时间特性反映了动触头运动的整个过程,对于断路器动触头运动过程和断路器机械故障诊断尤为重要。本文测试了断路器动作过程中的正常状态、机构卡涩和基座松动3种状态,其中提取各种状态的3组动作特征如表3所示。

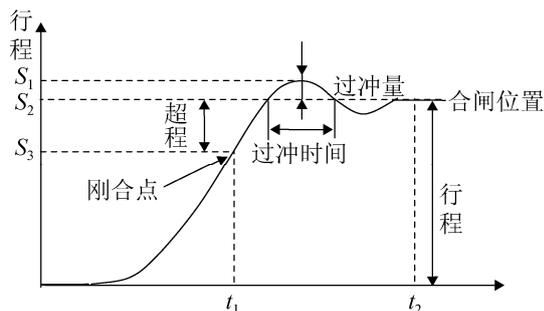


图 9 断路器行程时间曲线  
Fig. 9 Diagram of travel-time curve

表 2 断路器操动机构机械特性参数测量结果  
Tab. 2 Measurement result of mechanical characteristic for circuit breaker operating system

机械特性参数	单位	技术要求	光栅测试仪	本文方法
合闸时间	ms	50 ± 10	54.2	51.3
合闸速度	m/s	0.6 ± 0.2	0.53	0.48
分闸时间	ms	45 ± 10	49.7	47.7
分闸速度	m/s	1.3 ± 0.2	1.22	1.34

表 3 断路器各种状态下的特征提取  
Tab. 3 Feature extraction of circuit breaker in various states

断路器状态	动作时间/ms	触头开距/mm	观测行程/mm	过冲量/mm	超行程/mm	合闸速度/(m/s)
正常合闸	48.175	10.62	15.23	1.55	4.61	0.48
	49.561	11.22	15.68	1.23	4.46	0.47
	51.316	11.28	16.19	1.07	4.91	0.48
机构卡涩	29.386	5.56	9.68	0.82	4.12	0.34
	26.754	6.60	11.98	0.61	5.38	0.45
	43.421	6.37	11.98	0.79	5.61	0.35
基座松动	50	8.53	15.47	0.9	6.94	0.30
	51.754	8.56	16	0.88	7.44	0.31
	54.386	9.06	17	1.09	7.94	0.31

## 2 基于 M-ELM 的断路器故障诊断模型

### 2.1 极限学习机

极限学习机(ELM)是一种特殊的前馈神经网络,其输入层权值、隐含层权值和隐含层偏差均是随机产生的,输出层权值是通过计算获得的,在训练过程中不需要调整网络参数,只需设置隐含层神经元个数,即可获得唯一的全局最优解,克服了传统神经网络存在的训练时间长、过拟合等问题<sup>[20-22]</sup>。

对于给定的  $n$  个样本  $(x_i, t_i)$ ,  $i=1,2,\dots,n$ , 隐藏节点的个数为  $N$ , 激活函数为  $g(x)$ , 则  $\beta_i$ ,  $w_i$  和  $b_i$  满足

$$\sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = t_j \quad j=1,\dots,N \quad (6)$$

式(6)中,  $w_i = (w_{i1}, w_{i2}, \dots, w_{im})^T$  是第  $i$  个隐层节点的输入权重;  $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})^T$  是第  $i$  个隐层节点到输出节点的权重;  $b_i$  是第  $i$  个隐层节点的阈值。

式(6)可用矩阵表示为

$$H\beta = T \quad (7)$$

其中:

$$H(w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_n) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & & \vdots \\ g(w_1 \cdot x_n + b_1) & \dots & g(w_N \cdot x_n + b_N) \end{bmatrix}$$

$$\beta = [\beta_1^T, \dots, \beta_N^T]^T_{N \times m}, \quad T = [t_1^T, \dots, t_n^T]^T_{n \times m}$$

矩阵  $H$  被称为神经网络的输出矩阵,其第  $i$  列是受输入  $x_1, \dots, x_n$  影响的第  $i$  个隐层节点的输出。

极限学习机的模型训练开始后,输入权重  $w_i$  和隐层阈值  $b_i$  是随机产生的,不需要额外调整,而且隐层输出矩阵  $H$  可以一直保持不变的。从式(7)可知问题等价于求线性系统  $H\beta = T$  的最小二乘解  $\hat{\beta}$ 。但是,当矩阵  $H$  不是方阵时,不存在  $w_i, b_i, \beta(i=1, \dots, N)$  使  $H\beta = T$ 。

因此,系统的最小二乘解可以表示为

$$\hat{\beta} = H^{-1}T \quad (8)$$

式(8)中,  $H^{-1}$  是矩阵  $H$  的广义逆矩阵。

## 2.2 基于文化基因算法的 ELM 模型参数优化

在实际应用中, ELM 的输入层权值、隐含层权值和隐含层偏差均是随机产生的,但这些网络参数在分类中至关重要,因此,对于优化 ELM 方法中的参数非常重要。文化基因算法(Memetic Algorithms)是一种带有启发式的搜索算法,由全局最优优化算法和局部搜索策略两部分组成。全局最优优化算法可以寻找区域内最优解但寻找邻域内的最优解略差,而文化基因算法对于特定问题可以以很高的收敛速度寻求最优解。利用文化基因算法产生最优参数的过程为:

1) 随机生成断路器诊断模型的初始群体  $\Psi = \{\varphi_1, \dots, \varphi_{N_p}\}$ , 其中包括  $N_p$  个初始样本, 而每个样本有  $\phi_i$  个特征量,  $\varphi_i = \{\varphi_{i1}, \dots, \varphi_{ij}, \dots, \varphi_{iL}\}$ 。

2) 针对已经产生的  $N_p$  个初始个体, 按照交叉变异的原则任选两个个体进行杂交, 由此产生出下一代群体中的两个新个体为

$$\begin{aligned} \varphi_1' &= \alpha_1 \varphi_1 + (1 - \alpha_1) \varphi_2 \\ \varphi_2' &= \alpha_2 \varphi_2 + (1 - \alpha_2) \varphi_1 \end{aligned} \quad (9)$$

其中:  $\varphi_1$  和  $\varphi_2$  是从种群中选定的两个个体;  $\varphi_1'$  和  $\varphi_2'$  是进行交叉运算后新产生的两个子代个体;  $\alpha_1$  和  $\alpha_2$  是定义在  $[0, 0.5]$  上的随机数。

3) 计算群体中每个样本的适应度, 第  $i$  个样本  $\varphi_i$  在第  $t$  代的适应度为其分类准确率, 即

$$\begin{aligned} f(\varphi_i^t) &= \frac{1}{N_t} \sum_{i=1}^{N_t} \delta(c(\varphi_i^t), y_i^t) \\ \delta(c(\varphi_i^t), y_i^t) &= \begin{cases} 1 & c(\varphi_i^t) = y_i^t \\ 0 & \text{其它} \end{cases} \end{aligned} \quad (10)$$

其中:  $y_i^t$  为第  $i$  个样本的实际类别;  $c(\varphi_i^t)$  为第  $i$  个样本的分类结果;  $N_t$  为群体第  $t$  代样本个数。

4) 在新产生的群体当中, 按照给定的变异概率选取若干个体进行变异操作

$$v_i = \varphi_i + \gamma_i \cdot (\varphi_{best}^p - \varphi_i) + \gamma_i \cdot (\varphi_{r1} - \hat{\varphi}) \quad (11)$$

其中:  $\varphi_i$ ,  $\varphi_{r1}$ ,  $\varphi_{best}^p$  为从当前  $100p\%$  的个体中选取的样本;  $p$  为  $(0, 1)$  之间的随机数;  $\hat{\varphi}$  为从当前群体和  $100p\%$  群体中联合选出的任意个体;  $\gamma_i$  为第  $i$  代的变异参数。

5) 应用模拟退火算法实现对当前这代群体中所有个体样本的局部搜索策略。

## 2.3 故障诊断步骤

利用上述原理设计的基于 M-ELM 的断路器故障诊断方法步骤如下:

1) 采集动触头运动图像序列并获取动触头运动轨迹;

2) 根据动触头运动轨迹计算出相关特征向量, 如动作时间、触头开距, 观测行程、过冲量、合闸速度等;

3) 根据文化基因算法获得最优输入层权重矩阵  $W$ , 最优隐含层连接权重矩阵  $\beta$  和最优偏移量  $b$ ;

4) 将 2) 获得的断路器 6 个特征量作为极限学习机的输入, 确定隐层神经元的个数  $N$ , 并根据输入层连接权重矩阵  $W$ , 隐含层连接权重矩阵  $\beta$  和偏移量  $b$  计算输出层权值  $\hat{\beta}$ , 利用训练好的极限学习机进行断路器机械故障分类诊断。

## 2.4 模型参数选择

为了验证本文方法的有效性, 采用 60 组断路器动作时获取的运动特征向量, 每个输入向量的特征个数为 6, 神经元个数为 4, 输出层节点个数为 3,  $N_p$  个初始样本, 变异概率最大值  $\gamma$ , 交叉概率  $\alpha_1$  和  $\alpha_2$  取  $[0, 0.5]$  之间的随机数。设定准确率超过 0.8 停止寻优。根据初始样本、迭代次数和变异概率的不同取值, 其分类准确率如表 4 所示。

由表 4 可以看出, 当初始群体个数  $N_p=30$ , 变异概率为  $[0.25, 0.35]$  之间的随机数时分类准确率最高。

应用文化基因算法进行训练的收敛曲线如图 10 所示。由图 10 可知, 当训练到第 9 代时, 适应度已经收敛, 因此在实际应用时迭代次数取 10 即能满足要求。

表 4 不同参数的分类准确率  
Tab.4 Classification accuracy of different parameters

$N_n$	$\gamma$	迭代次数	准确率
20	0.20	20	0.516 7
30	0.20	20	0.816 7
40	0.20	20	0.816 7
30	0.20	20	0.550 0
30	0.30	20	0.816 7
30	0.50	20	0.616 7
30	0.30	5	0.516 7
30	0.30	10	0.816 7
30	0.30	20	0.816 7

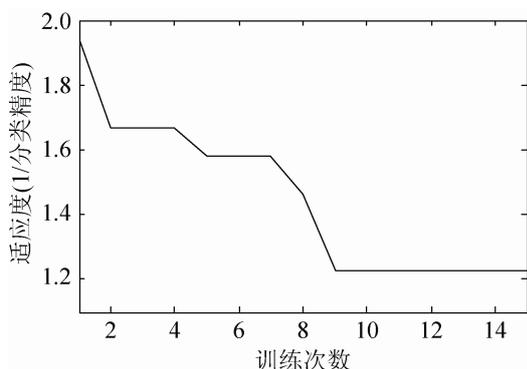


图 10 文化基因算法的收敛曲线  
Fig. 10 Convergence curve of memetic algorithm

通过文化基因算法进行 ELM 初始参数的优化时, 令  $N_p=30$ , 变异概率为 0.3, 交叉概率为 0.5, 迭代次数为 10, 分别计算出的最优输入层权重矩阵  $W$ , 最优隐含层连接权重矩阵  $\beta$  和最优偏移量  $b$  分别为:

$$W = \begin{bmatrix} 0.3056 & 0.6516 & 0.6500 & 0.5858 & 0.4887 & 0.2910 \\ 0.3966 & 0.2318 & 0.3055 & 0.5942 & 0.7066 & 0.5874 \\ 0.4630 & 0.5907 & 0.5130 & 0.4157 & 0.6886 & 0.4432 \\ 0.7489 & 0.7849 & 0.5572 & 0.6685 & 0.5961 & 0.4357 \end{bmatrix}$$

$$\beta = \begin{bmatrix} 0.4486 & 0.5234 & 0.4404 & 0.4018 \\ 0.4326 & 0.3250 & 0.7448 & 0.5529 \\ 0.4818 & 0.3688 & 0.5971 & 0.3363 \end{bmatrix}$$

$$b = [0.5540 \quad 0.5857 \quad 0.3906]$$

这里, 由于文化基因算法的初始群体是随机生成的, 经过计算后产生的最优参数略有不同。

### 3 实例分析

在实际测试中, 采用 ZN65-12 作为研究的断

路器进行分合闸操作, 利用高速相机采集断路器正常、机构卡涩和基座松动三种状态的信号, 时间信号使用采集卡自带的时钟信号。分别采集每种状态数据各 20 组, 然后将利用 MFLS 方法选取的特征向量作为输入样本输入到构建的 M-ELM 训练模型, 将样本数据按比例分为训练集和测试集送入极限学习机进行状态识别分类。本文设定的单隐层神经网络有 6 个特征向量作为输入。

每种状态选择数据的 2/3 作为训练数据, 另外的 1/3 作为测试数据。三种类别的标签 1, 2, 3 分别表示正常状态、机构卡涩和基座松动。实验中, 1~7 表示正常状态, 8~14 表示机构卡涩, 15~21 表示基座松动, 实验测试结果如图 11 所示。

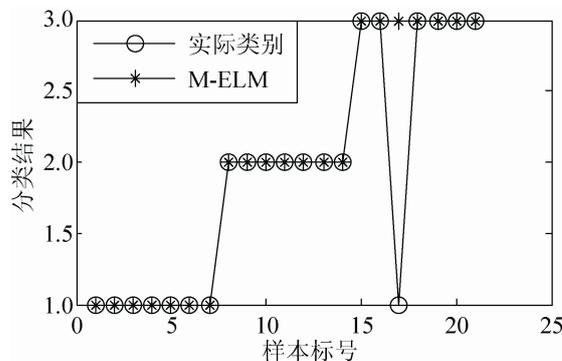


图 11 分类结果比较  
Fig. 11 Comparison of classification results

由图 11 可知, 本文方法在分析断路器各种状态时, 正常状态和机构卡涩状态的准确率达到 100%, 基座松动状态有一组数据出现判断错误, 整体的正确率为 95%。断路器状态诊断过程中出现误判的主要原因是由于基座松动状态时, 松动比较微弱使得获取到的信号和正常状态下的信号差别不大, 因此出现了误判。此时如果增加其它信号联合进行断路器的故障诊断, 则能提高诊断的准确率。

为了进一步验证本文方法的性能, 通过与 BPNN、SVM、ELM 和 M-ELM 模型对同样的断路器动触头运动过程中所获取的 200 组实验数据进行诊断, 对比结果表 5 所示。在对比中, BPNN

模型采用 3 层结构, 15 个输入节点, 31 个隐含层神经元, 1 个输出节点, 激励函数为 Sigmoid 函数, 学习率为 0.01; SVM 模型采用交叉验证法获得其正则化参数, 选用 RBF 核函数, 利用 GA 对 SVM 网络参数进行寻优, 惩罚参数  $C=100$ , 核参数  $\sigma=1.52$ ; ELM 隐含层神经元个数为 8, 隐层激活函数为 Sigmoid 函数; M-ELM 模型采用 Memetic 方法构造了最优参数矩阵, 然后用 ELM 进行故障诊断。4 种模型分类方法的收敛时间及分类精度统计结果如表 5 所示。

表 5 不同模型分类结果分析

Tab. 5 Analysis of classification results of different models

模型	平均绝对百分比 误差(MAPE)%	均方根误 差(RMSE)	收敛时间/s
BPNN	9.243 1	0.427 5	8.061 1
SVM	4.147 0	0.315 3	0.254 4
ELM	2.334 9	0.268 2	0.298 9
M-ELM	1.920 8	0.219 2	0.316 6

由表 5 可知, M-ELM 模型分类精度有明显的提高; 由于增加了参数选优的处理, 在分类速度上比 BPNN 模型快很多, 但比 SVM 和 ELM 的分类速度略慢。在相同条件下, M-ELM 与 BPNN 相比, 评价指标 MAPE、RMSE 及收敛时间分别降低了 79.2%、48.7% 和 96.1%; M-ELM 与 SVM 模型相比, 评价指标 MAPE 和 RMSE 分别降低了 53.7% 和 30.5%, 收敛时间增加了 24.4%; M-ELM 与 ELM 模型相比, 评价指标 MAPE 和 RMSE、MAE 分别降低了 17.7% 和 18.3%, 收敛时间增加了 5.9%。因此, 本文提出的基于稀疏表示和 M-ELM 的故障诊断模型能够对获取的断路器特征进行故障诊断, 并取得较好的诊断结果。

## 4 结论

针对传统断路器机械特性检测方法的不足, 本文提出了一种基于多特征联合稀疏表示的非接触式视觉检测方法。该方法采用基于计算机视觉的非接触测量方式, 不需要与断路器之间建立任何电气和机械连接, 便于现场安装、操作和测试, 在操作

过程中不仅可以获取断路器动触头的直线位移, 也可以获取主轴转动的角位移特性, 能够准确获得动触头运动轨迹, 使得动触头的空间和时间运动特性测量速度和精度方面都有了很大的提高。另外, 本文采用 M-ELM 进行故障诊断, 克服了传统神经网络训练数据量大和支持向量机需要设置多个参数的不便, 并对 ELM 进行了初始参数的优化, 提高了诊断的正确率。

## 参考文献:

- [1] 杨壮壮, 徐建源, 李斌, 等. 高压真空断路器机械状态监测系统研制[J]. 高压电器, 2013, 49(8): 26-34.  
Yang Zhuangzhuang, Xu Jianyuan, Li Bin, et al. Design of monitoring system for mechanical status of high voltage vacuum circuit breaker[J]. High Voltage Apparatus, 2013, 49(8): 26-34.
- [2] 赵书涛, 张佩, 申路, 等. 高压断路器振声联合故障诊断方法[J]. 电工技术学报, 2014, 29(7): 216-221.  
Zhao Shutao, Zhang Pei, Shen Lu, et al. Vibration and acoustic joint mechanical fault diagnosis method of high voltage circuit breakers[J]. Transaction of China Electrotechnical Society, 2014, 29(7): 216-221.
- [3] 缪希仁, 吴晓梅, 石敦义, 等. 采用 HHT 振动分析的低压断路器合闸同期辨识[J]. 电工技术学报, 2014, 29(11): 154-161.  
Miao Xiren, Wu Xiaomei, Shi Dunyi, et al. Switching synchronism identification of low voltage circuit breaker utilizing HHT analysis to vibration signal[J]. Transaction of China Electrotechnical Society, 2014, 29(11): 154-161.
- [4] 常广, 王毅, 王玮. 采用振动信号零相位滤波时频熵的高压断路器机械故障诊断[J]. 中国电机工程学报, 2013, 33(3): 155-162.  
Chang Guang, Wang Yi, Wang Wei. Mechanical fault diagnosis of high voltage circuit breakers utilizing zero-phase filter time-frequency entropy of vibration signal[J]. Proceedings of the CSEE, 2013, 33(3): 155-162.
- [5] Ni Jianjun, Zhang Chuanbiao, Yang S X. An adaptive approach based on KPCA and SVM for real-time fault diagnosis of HVCBs[J]. IEEE Trans. on Power Delivery (S0885-8977), 2011, 26(3): 1960-1971.
- [6] 李鹏飞, 周文俊, 曾国, 等. 高压断路器合闸弹簧动态特性及储能状态检测方法[J]. 电工技术学报, 2016, 31(3): 104-112.  
Li Pengfei, Zhou Wenjun, Zeng Guo, et al. The dynamic

- characteristics and energy storage detection method of high-voltage circuit breaker closing spring[J]. Transaction of China Electrotechnical Society, 2016, 31(3): 104-112.
- [7] 王小华, 荣命哲, 吴翎, 等. 高压断路器故障诊断专家系统中快速诊断及新知识获取方法[J]. 中国电机工程学报, 2007, 27(3): 95-99.  
WANG Xiaohua, RONG Mingzhe, WU Yi, et al. Method of quick fault diagnosis and new knowledge obtainment for high voltage circuit breaker expert system[J]. Proceedings of the CSEE, 2007, 27(3): 95-99.
- [8] 杨凌霄, 朱亚丽. 基于概率神经网络的高压断路器故障诊断[J]. 电力系统保护与控制, 2015, 43(10): 62-67.  
Yang Lingxiao, Zhu Yali. High voltage circuit breaker fault diagnosis of probabilistic neural network[J]. Power System Protection and Control, 2015, 43(10): 62-67.
- [9] 周阳, 王宝华. 基于多传感器信号融合的真空中断器机械特性状态评价[J]. 电气技术, 2016, 1(6): 30-35.  
ZHOU Yang, WANG Baohua. Mechanical characteristic state evaluation of vacuum circuit breaker based on multi-sensor signal fusion[J]. Electrical Engineering, 2016, 1(6): 30-35.
- [10] 姜生, 李世民, 王继元. 真空断路器机械特性的探讨[J]. 高压电器, 2002, 38(4): 61-64.  
Jiang Sheng, Li Shimin, Wang Jiyuan. Discussion on the mechanical characteristic of vacuum circuit breaker[J]. High Voltage Apparatus, 2002, 38(4): 61-64.
- [11] 陈建平, 胡占强, 苏晓东. 智能化断路器机械特性在线监测关键技术设计[J]. 高压电器, 2014, 50(4): 108-112.  
Chen Jianping, Hu Zhanqiang, Su Xiaodong. Key technology design to on-line monitoring of mechanical characteristics for intelligent vacuum circuit breaker[J]. High Voltage Apparatus, 2014, 50(4): 108-112.
- [12] 程序, 关永刚, 张文鹏, 等. 基于因子分析和支持向量机算法的高压断路器机械故障诊断方法[J]. 电工技术学报, 2014, 29(7): 209-215.  
Cheng Xu, Guan Yonggang, Zhang Wenpeng, et al. Diagnosis method on the mechanical failure of high voltage circuit breakers based on factor analysis and SVM[J]. Transaction of China Electrotechnical Society, 2014, 29(7): 209-215.
- [13] 钟家喜, 李保全, 李亚红. 高压断路器机械状态与监测技术的探索与实践[J]. 高压电器, 2011, 47(2): 53-60.  
Zhong Jiaxi, Li Baoquan, Li Yahong. Exploration and practices of mechanical state diagnosis and monitoring techniques for high voltage circuit breaker[J]. High Voltage Apparatus, 2011, 47(2): 53-60.
- [14] Jia Xu, Lu Huchuan, Yang Minghsuan. Visual tracking via adaptive structural local sparse appearance model [C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition, Los Alamitos, CA: IEEE Computer Society, 2012: 1822-1829.
- [15] Wu Yi, Lim Jongwoo, Yang Ming-hsuan. Online object tracking: A benchmark[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition, Los Alamitos, CA: IEEE Computer Society, 2013: 1-8.
- [16] B Babenko, M H Yang, S Belongie. Visual tracking with online Multiple Instance Learning[C]//Computer Vision and Pattern Recognition (CVPR), Miami, FL, 2009: 983-990.
- [17] Z Kalal, J Matas, K Mikolajczyk. P-N learning: Bootstrapping binary classifiers by structural constraints [C]//Computer Vision and Pattern Recognition (CVPR), San Francisco, CA, 2010: 49-56.
- [18] D Ross, J Lim, R-S Lin, et al. Yang. Incremental Learning for Robust Visual Tracking[J]. IJCV (S0920-5691), 2008, 77(1): 125-141.
- [19] T Zhang, B Ghanem, S Liu, N Ahuja. Robust visual tracking via multi-task sparse learning[C]. Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on, Providence, RI, 2012: 2042-2049.
- [20] Guangbin Huang, Qinyu Zhu, C K Siew. Extreme learning machine: theory and applications[J]. Neuro computing (S0925-2312), 2006, 70(1): 489-501.
- [21] 鄧萍, 繆希仁, 吴晓梅. 低压系统短路故障建模及电流预测技术[J]. 电力系统保护与控制, 2016, 44(7): 39-46.  
Zhi Ping, MIAO Xiren, WU Xiaomei. Low-voltage system short-circuit modeling and its current prediction technology[J]. Power System Protection and Control, 2016, 44(7): 39-46.
- [22] Huang Guangbin. An insight into extreme learning machines: random neurons, random features and kernels[J]. Cognitive Computation (S1866-9956), 2014, 6(3): 376-390.