

DOI:10.3969/j.issn.1001-4551.2019.05.002

基于 BOW-HOG 特征的活塞裂纹在线识别研究

陈 睿, 刘震涛*

(浙江大学 动力机械及车辆工程研究所, 浙江 杭州 310027)

摘要:为解决疲劳模拟台架试验中裂纹在线识别问题,应用并改进了基于 BOW-HOG 特征的机器学习方法,采用 HOG 特征提取方法提取了多种形态的裂纹特征。通过词袋模型和 k-means 聚类方法生成了裂纹的特征描述词典,以旋转、对称的增强训练方法改善了方向保持性,以图像金字塔的方式改善了尺寸保持性;采用联合灰度级分布图像差分法提取了图片感兴趣区域,以支持向量机作为分类器实现了复杂化环境下的活塞裂纹在线识别功能。试验及研究结果表明:改进后 BOW-HOG 算法准确率达到 84.1%,表现出了良好的尺寸和旋转保持性,消耗更少的计算资源,显著提高了训练样本较为有限和复杂情况下的裂纹识别算法的准确率和鲁棒性。

关键词: 活塞;灰度梯度直方图;词袋模型;特征提取;支持向量机

中图分类号:TH871.3;TP242.6⁺2

文献标志码:A

文章编号:1001-4551(2019)05-0458-06

Online identification of piston crack based on BOW-HOG feature

CHEN Rui, LIU Zhen-tao

(Power Machinery and Vehicular Engineering Institute, Zhejiang University, Hangzhou 310027, China)

Abstract: Aiming at solving the problem of online crack identification in fatigue simulation bench test, the machine learning method based on BOW-HOG feature was applied and improved. The HOG feature extraction method was used to extract crack features of various shapes, and the word bag model and k-means clustering were used to generate a characterization dictionary for cracks. The directional retention was improved by the enhanced training method of rotation and symmetry and the dimensional retention was improved by image pyramid. Then the image region of interest was extracted by the joint gray level distribution image difference method and the online recognition of the piston crack in the complex environment was realized by support vector machines. The results indicate that the improved BOW-HOG algorithm has an accuracy of 84.1%, showing better size and rotation retention, consuming less computing resources, and significantly improving the accuracy and robustness of crack identification algorithm limited to few training samples.

Key words: piston; gray gradient histogram; bag of words model; feature extraction; support vector machine

0 引 言

随着内燃机强化燃烧、增压技术、高压共轨等技术的广泛运用,活塞火力面承受交变载荷的频率越来越高,载荷越来越大^[1],新机型活塞的可靠性试验不可避免。

活塞的可靠性试验采取的主流加热方式一般有燃气加热、电感加热、激光加热^[2],试验目的是探索活塞火力面的失效形式、失效位置及失效工况,其中,失效

现象的检测是试验过程中的重要环节。到目前为止,在役试验台的试件失效还是靠试验人员亲自观察试件或者试件的照片,暂时没有出现低成本的裂纹全自动识别方案。前人也做过相关尝试,比如,三菱重工研究人员通过金属丝的通断判断裂纹是否产生^[3],伍茜^[4]通过计算机视觉方案实现了裂纹扩展信息的提取。但是,现有的活塞裂纹的识别存在一定的局限性,比如,要对裂纹可能出现的位置有提前预测并布置好相应的

收稿日期:2018-12-11

作者简介:陈睿(1994-),男,江苏泰州人,硕士研究生,主要从事疲劳可靠性试验台方面的研究。E-mail:chenruiupup@foxmail.com

通信联系人:刘震涛,男,教授,博士生导师。E-mail:liuzt@zju.edu.cn

传感器,没有抓住本身的宏观特征进行识别,对活塞上可能出现的异物抗干扰性较差。

为实现活塞模拟试验台的裂纹在线识别,本文将在以激光为热源的热冲击试验台上安装工业相机作为图像采集装置,结合裂纹的宏观特征,通过机器学习实现活塞模拟试验台中的裂纹在线识别功能,应用并改进最新提出的BOW-HOG特征提取方法^[5]。

1 热冲击试验台

该热冲击试验台采用激光加热的方式,激光头位于活塞试件上方,通过XYZ三轴滑台移动激光头精准控制加热区域,用于活塞裂纹在线检测的工业相机位于活塞上方,通过USB 3.0线缆与工控机连接,进行控制信号通讯与图片数据传输。

在试验进行的过程中,试验循环分为加热和冷却两个过程,试验台控制软件用定时器每隔45 s拍摄活塞试件火力面照片,用于活塞的裂纹识别。

2 裂纹在线识别

2.1 裂纹特征分析

活塞火力面的疲劳失效常见为热疲劳失效,从宏观上看,疲劳失效区域一般分为3个区域:起源区、扩展区、瞬断区^[6],其在宏观上有如下几个特征^[7]:

- (1) 光照良好情况下,裂纹区域和其他非裂纹区域相比,像素的灰度值有明显不同;
- (2) 裂纹具有连续性,形态可能是多线段或者弧形甚至是网状延伸;
- (3) 裂纹两侧的灰度变化存在一定的对称性,而非正常结构的单侧梯度变化较大;
- (4) 裂纹大小在不同的活塞表面存在尺度变化;
- (5) 裂纹的局部几何、灰度特征具有重复性。

从以上总结的裂纹特征出发,针对裂纹的灰度梯度特性,本研究采用方向梯度直方图法(histogram of oriented gradient, HOG),通过灰度梯度特点提取裂纹特征;同时,任意裂纹的某一局部几乎都能在其余裂纹中找到极为相似的对应部分,宏观视觉上均表现为接近于直线或者弧线的、两侧对称的、边缘锯齿状的、有一定宽度的“黑线”;最终,裂纹可通过这些相似的“黑线”进行“拼接”得到。

因此,识别裂纹就是要识别画面中裂纹重复的、固定的特征。针对这种固定的特征的组合,可采用词袋(bag of words, BOW)模型进行裂纹特征的组合,形成属于裂纹的HOG特征视觉词袋。最终,针对裂纹的宏

观视觉特征,本文采用BOW-HOG方法提取活塞裂纹特征,用于分类器的训练和预测。

2.2 裂纹HOG特征提取

HOG特征描述子可以通过局部边缘梯度和梯度方向分布,很好地描述局部目标的外表和形状,而忽略其在图片中的具体位置^[8]。HOG特征提取的具体步骤为:

- (1) 将大小为 n 的图片转化为灰度图,每16个像素作为一个细胞单元,每2个细胞单元作为一个区块,最终得到 $(m/16) \times n$ 个细胞单元、 $(m/32) \times n$ 个区块;
- (2) 将2个细胞单元组成为一个区块,利用区块对先对其所包含的细胞单元做对比度归一化处理,将区块内的灰度值都转到区间中。
- (3) 对于每个细胞单元, I 为坐标处的灰度值,由以下两式求出像素点处的水平方向梯度 G_x 和垂直方向梯度 G_y 。

$$G_x(x, y) = I(x+1, y) - I(x-1, y) \quad (1)$$

$$G_y(x, y) = I(x, y+1) - I(x, y-1) \quad (2)$$

实际中分别使用和进行水平方向和垂直方向的卷积操作;然后以水平向右、垂直向下为正方向,再得到该像素点处的梯度幅值和梯度方向:

$$G(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (3)$$

$$\alpha(x, y) = \tan^{-1}\left(\frac{G_y(x, y)}{G_x(x, y)}\right) \quad (4)$$

(4) 以每个细胞单元为统计单位,统计每个像素点的梯度方向,形成以梯度方向角度为横坐标,梯度幅值累加值为纵坐标的直方图,若将 360° 分割成9个bin,每个bin包含 40° 的范围,横坐标即为、直至。

某细胞单元灰度梯度直方图如图1所示。

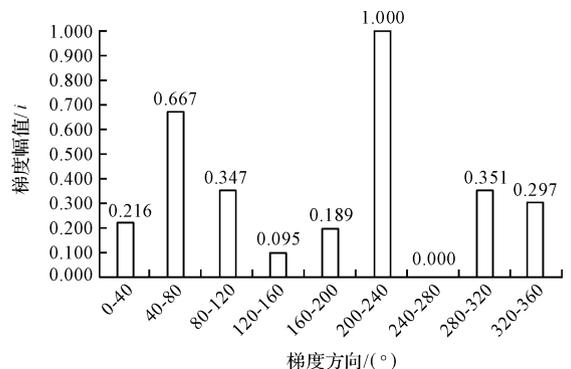


图1 某细胞单元灰度梯度直方图

以细胞单元中某点 (x, y) 为例,若梯度方向为 35° ,梯度幅值为0.103,就在直方图“0-40”对应的bin中加上0.103,新值变更为 $0.216 + 0.103 = 0.319$ 。最终,灰度梯度直方图的9个纵轴值构成的矩阵 $[b_1, b_2, b_3, \dots, b_8, b_9]$,便是这个细胞单元的HOG特征描述子 B ,而一个区块的

HOG 特征描述子就是一个 1 行 $4 \times 9 = 36$ 列的行矩阵。

2.3 裂纹 BOW 特征构建

近年来, BOW 模型开始广泛应用于计算机视觉领域, 比如图像分类领域。2004 年, CSURKA G、DANCE C R 等人^[9-12]最先将词袋模型用于图像领域, 图像的词袋是图像的某些特征向量的集合, 而图像的 BOW 特征就是基于这个特征向量集合统计出来的频次直方图。其中, 特征向量的提取方法目前只有尺度不变特征方法、加建稳定特征方法等, 直到邹北骥等人提出了 BOW-HOG 特征, HOG 特征才作为 BOW 模型的特征提取方法, 且 BOW-HOG 并没有得到广泛关注, 应用极少。

BOW 特征的构建主要分为两大步骤: 构造特征向量词典和确定特征向量单词分类。具体的构建图像 BOW 特征的步骤如下:

(1) 提取所有训练图片的裂纹标记区域的 HOG 特征描述子, 得到若干 36 列行矩阵, 即区块的 HOG 特征描述子, 汇总所有的区块 HOG 特征描述子;

(2) 筛选 HOG 特征描述子, 虽然已经用方形区域标记出裂纹区域, 但是, 方形区域中仍有留白区域为金属表面, 金属表面很光滑或者含有极少的纹理特征。因此, 引入筛选因子, 为一个区块 HOG 特征描述子的平均值, 平均值过小时, 意味着该区块很“光滑”, 不含有裂纹信息, 可以作为无用的区块 HOG 特征描述子去除; 经过试验, 取值为 0.018 左右时, 可以较好的过滤“无用”的区块 HOG 特征描述子, 减少特征描述子总量;

(3) 将筛选后的区块 HOG 特征描述子用 K-means 聚类算法分为 K 类, 得到 K 个视觉单词, 即每一类视觉单词中心处的区块 HOG 特征描述子; 至此, 特征词典构造完成, 共包含 K 个“单词”;

(4) 对于每一张待检测的图片, 提取其区块 HOG 特征描述子, 并通过筛选因子剔除部分特征描述子, 计算剩下的各个区块 HOG 特征描述子和各个视觉单词的距离, 并将区块 HOG 特征描述子归类到距离最小的视觉单词那一类中, 最终得到此图片的视觉单词的频次直方图, 直方图的 bin 的个数即为视觉单词的个数 K 。距离为:

$$d = \sqrt{\|B - K_i\|_2^2} \quad (5)$$

式中: B — 区块 HOG 特征描述子; K_i — 视觉单词特征向量。

(5) 为了避免某些图片视觉单词频次的绝对值过大过小的影响, 需要对视觉单词频率直方图进行归一化处理, 最终, 所有的 n'_i 均在区间, 即:

$$n'_i = \left(\frac{n_i}{\sum_{i=1}^K n_i} \right) \quad (6)$$

式中: K — 视觉单词的个数, 即为单词频次直方图 bin 的个数; n_i — 第 i 个单词的频次; n'_i — 归一化后第 i 个单词的频次。

2.4 分类器训练

2.4.1 分类器及参数

在结构裂纹的检测领域, 大量使用了支持向量机作为分类器^[13]。结合本文中训练样本的特点, 由于活塞裂纹的样本不算多, 属于样本有限的情况; 同时, 支持向量机的输入特征的维数等于视觉单词个数 K , 维数在百位级别, 在试验台工控机计算能力有限的情况下, 维数稍高。综合以上情况, 笔者采用支持向量机作为本文的分类器^[14]。

一般情况下, 训练样本的特征都不是线性可分的, 因此, 需要使用核函数对输入的单词频次直方图进行映射, 最常用的核函数是径向基函数 (RBF) 的高斯核函数, 其形式为:

$$K(\|X - XC\|) = e^{-\frac{\|X - XC\|^2}{2\sigma^2}} \quad (7)$$

式中: XC — 核函数中心; σ — 函数的宽度参数。

训练集测试集都已经确定的情况下, 宽度参数有最优值使分类效果最好; 但是, 越小越有过拟合趋势, 越大越有欠拟合趋势^[14]。

过拟合会在特定的训练集上达到很好的效果, 但是泛化推广效果较差; 欠拟合在特定训练集上的效果较为一般, 但是推广泛化的效果比较稳定。因此, 要达到良好的泛化和测试集预测效果的平衡, 需要通过网格搜索等方式, 找出合适的惩罚系数 C 和宽度参数的组合。

2.4.2 训练增强

为了改善 HOG 特征提取的方向保持性, 提取 HOG 特征之前, 本文将训练样本图片进行多角度旋转、对称操作, 增强训练样本的角度多样性。

2.5 在线检测

2.5.1 图像金字塔

邹北骥等人提出, 对于待检测的图片, 先进行归一化操作, 再分割为小方块分别提取 HOG 特征。而对待检测图片的归一化操作的尺寸大小对准确率有较大影响, 具体表现为: 只有训练样本中的特征的尺度和待检测图中的特征的尺度相差不大时, 文本分析中的召回率 R 、准确率 P 和综合衡量值 F 达到最高。这种归一化尺寸对准确率的影响, 归根结底是 HOG 特征描述不具有尺寸保持性。在实际的裂纹检测的过程中, 裂纹的像素尺寸大小具有很大的随机性, 和活塞的内部结

构、单个活塞的制造工艺、具体的热冲击情况以及工业相机的参数和实际工作距离等关系密切,并且活塞的裂纹并没有统一的、规范化的训练集,训练样本所包含的特征的尺寸相差较大。因此,为了提高目标检测的准确性,在图片检测阶段引入图像金字塔^[15-16]。

金字塔图像模型结构示意图如图2所示。

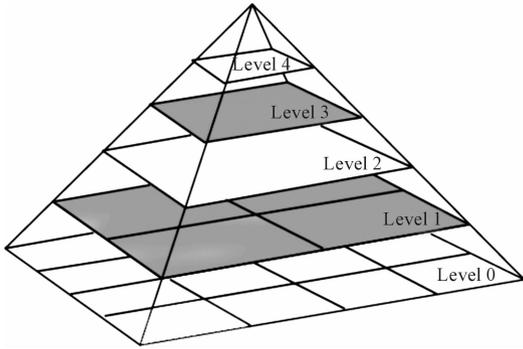


图2 金字塔图像模型结构示意图

图像金字塔的本质是同一张图片的不同分辨率的合集。构建图像金字塔的方式有两种:高斯金字塔和拉普拉斯金字塔。本文采用高斯金字塔构建多尺度的HOG特征描述子用于特征匹配,先用高斯卷积核对 N 级(Level N)的图片进行平滑处理,再进行下采样,将图片的长和宽同除以比例系数,得到 $N+1$ 级(Level $N+1$)的图片。为了尽量保存图片中的裂纹信息,平滑采用的高斯卷积核的标准差不能取太大,本文的取值为0.5。

2.5.2 感兴趣区域切割

由于HOG特征描述子的匹配是以到各个视觉词典中心的欧式距离 d 为度量的,如果视觉金字塔有 P 级的话,每一级图片都要计算一次距离,单张图片的计算量就是原来的 P 倍,新增的计算量不小。为了降低CPU持续占用率和内存占用,本研究采用感兴趣区域切割的方法,只对ROI区域进行HOG特征提取。

本文结合试验台的实际工作流程,根据试验开始时的活塞都是完好无损的这一特点,将图像差分法作为ROI的提取方法,且由于试验现场存在光照、粉尘的等因素的影响,简单的图像差分和阈值滤波相结合的方式分存在局限性,ROI区域仍然过大,甚至无法差分出存在的裂纹。伍茜采用基于联合灰度级分布的动态图像差分法,有效降低了灰度梯度变化较大区域的细节损失,极大减弱了光照的影响,适用于较为复杂的、变化活塞试验环境。

因此,本文在图像检测前,采用基于联合灰度级分布的图像差分法标记出变化区域,再只对发生变化的区域进行HOG特征提取,可极大减小检测过程中的计算量。

2.6 训练和检测流程

由于整个裂纹识别过程较为复杂,本节将整个训练、检测流程以流程图的形式总结展现,训练和检测过程流程图如图3所示。

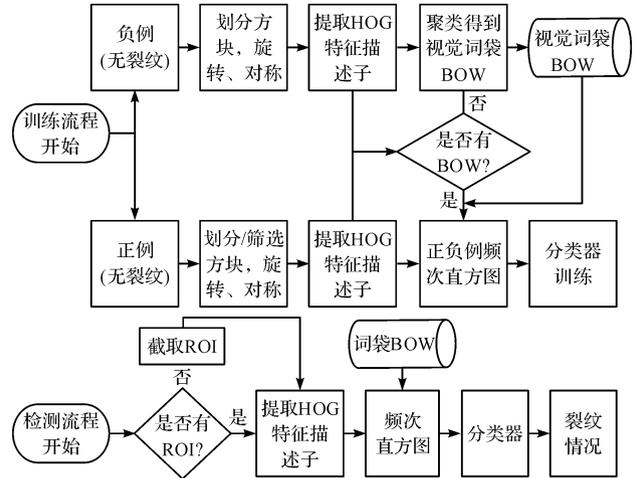


图3 训练和检测过程流程图

3 试验结果分析及对比

为了验证改进后的BOW-HOG特征的算法在裂纹检测场景下的有效性,本文从网络以及试验室数据中收集到含有裂纹的活塞图片93张,为正样本;不含有裂纹的活塞图片211张,为负样本。对所有正负样本进行旋转、对称操作增强训练后,正样本变为744张,负样本变为1688张,正负样本均按照的比例划分出训练集和测试集。

3.1 评价标准

准确率是评价分类问题的最常用的指标,即:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

式中: TP —True Positive, 为正例识别为正例的个数; TN —True Negative, 为负例识别为负类的个数; FN —False Negative, 为正例识别为负例的个数,即漏报的个数; FP —False Positive, 为负例识别为正例的个数,即误报的个数。

考虑到实际应用问题,将每张图片的平均预测时间作为评价标准,平均预测时间 T 为:

$$T = \frac{t_{end} - t_{start}}{N} \quad (9)$$

式中: t_{start} —预测开始的时间点; t_{end} —预测结束的时间点; N —预测的图片的张数。

3.2 参数优化

3.2.1 视觉词典大小

视觉词典的大小对裂纹特征的描述至关重要,由

于词典过大或者过小都会影响分类器的分类、泛化效果,在其余参数和条件不变的情况下,本文选取了从 100 ~ 800,步长为 100 的整数,作为词典大小,采用 10 折交叉验证的方式,对分类的平均准确率进行了比较。

不同词典大小对准确率的影响如图 4 所示。

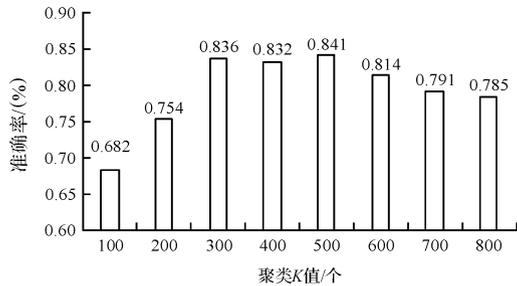


图 4 不同词典大小对准确率的影响

图 4 表明:词典大小过高或者过低都会导致平均准确率的下降,对于本文的裂纹场景下,词典大小在 300 ~ 500 的区间中,分类器能获得最好的分类性能。同时,考虑到训练和预测时的计算量,本研究选择 300 作为最终词典大小。

3.2.2 下采样系数

图像金字塔的下采样系数与训练样本和测试样本中相似特征的尺寸倍数密切相关,尤其是训练集和测试集的不规范的情况下,因此,有必要寻找最优的下采样倍率以提高平均准确率。

不同下采样系数对准确率的影响如图 5 所示。

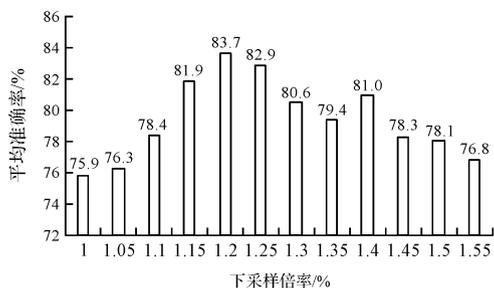


图 5 不同下采样系数对准确率的影响

采样率是 1.0 时,就是不进行下采样处理,等同于没有图像金字塔;随着下采样倍率的缓慢提升到 1.2 时,平均准确率达到最大的 83.7%;随着下采样率的继续增大,采样率开始缓慢下降,可能的原因是:采样后的部分图片的局部特征尺寸已经过小,无法和训练集中的特征尺寸相匹配;如果继续增大,平均准确率应该会接近于下采样倍率为 1.0 的 75.9%。因此,本文的下采样的比例系数为 1.2。

3.3 不同算法试验对比

为了验证本文对原 BOW-HOG 算法的改进效果,条件不变的情况下,再分别与以下方法进行对比:

- (1) 直接将 HOG 特征描述子作为训练的输入特征向量;
- (2) 原 BOW-HOG 算法;
- (3) 原 BOW-HOG 加上图像金字塔;
- (4) 原 BOW-HOG 加上对训练样本的旋转、对称操作以增强训练;
- (5) 原 BOW-HOG 加上训练增强和图像金字塔;
- (6) 原 BOG-HOG 加上训练增强、图像金字塔和 ROI。其中 BOW 模型的构建均取 $K = 300$,各方法准确率及平均预测时长如表 1 所示。

表 1 各方法准确率及平均预测时长

序号	方法	ACC/(%)	T/ms
1)	HOG	65.4	346
2)	BOW-HOG	71.7	494
3)	BOW-HOG(仅图像金字塔)	78.5	1282
4)	BOW-HOG(仅增强训练)	76.1	485
5)	BOW-HOG(增强训练、图像金字塔)	83.7	1581
6)	BOW-HOG(增强训练、图像金字塔、ROI)	84.1	272

表 1 显示:BOW-HOG 比 HOG 正确率提高 6.3%,可见 BOG-HOG 特征方法对裂纹识别的这一场景有更好的实用性。对两种方法识别标记的结果进行对比发现,准确率的提高主要来源于两个方面:

- (1) BOG-HOG 特征方法对短、小、陌生裂纹的识别更准确,漏判少。HOG 与 BOW-HOG 判别不同的区域如图 6 所示。

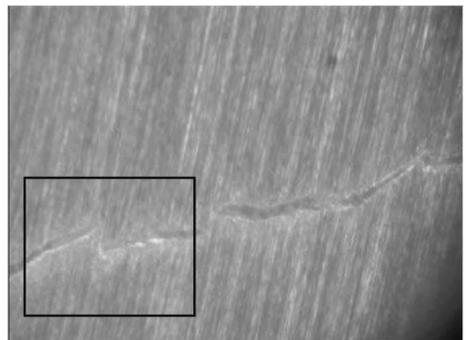


图 6 HOG 与 BOW-HOG 判别不同的区域

图 6 方框中的裂纹带有锐角折线,而训练集中恰好没有这种带有锐角折线的裂纹,HOG 方法对这段裂纹产生漏判,而 BOW-HOG 方法可能认为这个局部当中含有裂纹左右对称等裂纹的视觉单词,便对方框区域产生正确判断,与 BOW 特征模型的特征十分符合^[17];

- (2) BOG-HOG 特征方法对正常活塞表面结构的识别更加准确,误判更少,原因是 BOG-HOG 特征方法充分提取了局部结构的常见规律,负例抑制更加充分。

从 BOW-HOG(仅图像金字塔)比 BOW-HOG 提高的 6.8% 的准确率看,图像金字塔增强了 BOW-HOG

的尺寸保持性,提高了测试集中的极小尺寸和极大的裂纹的识别率,在训练样本的标准不统一且摄像头未标定的情况下,具有较大的提升作用。同时,图像金字塔使平均预测耗时变为原来的2.59倍。

从BOW-HOG(仅增强训练)BOW-HOG提高的4.4%的准确率看,通过对训练样本进行旋转、对称的方式增加样本数量,增强训练,有着重要的实际意义,因为活塞裂纹的方向不可预测,只有训练样本中包含相近的方向才能做出正确预测。同时,增强训练的方法并没有在预测过程中多加入任何计算过程,因此,平均预测时间几乎相等。

方法(5)同时综合了增强训练和图像金字塔,改进了HOG特征提取过程中的尺寸保持性和旋转保持性,相比于BOW-HOG方法有着12%的准确率的提升,改进后的BOW-HOG效果明显。为了弥补平均预测时间过长,本研究加入了基于联合灰度级分布的ROI提取方法后,图像的处理面积减小为原图面积的,极大地降低了计算量,适用于活塞模拟试验台的应用。

4 结束语

本文应用并改进了BOW-HOG特征提取方法,并与机器学习相结合,以较低的成本和简单方便的方式实现了活塞模拟试验台的裂纹在线识别;同时,改进后的特征提取方法更贴合活塞模拟试验台的使用实际,充分利用了一开始的原始图片,比原方法有更高的识别准确率和更少的计算量。

本试验台的裂纹识别方法有一定的局限性:本文划分图片时采用无重叠的划分方法,在局部特征区域恰好被分割时可能出现漏检的情况,可以用有重叠的“划窗法”对本文方法进行改进;本文为实现更低的计算量,过于依赖基准图片,当裂纹被积碳稍微覆盖导致裂纹灰度梯度较小时,分类效果较为一般,需要用额外的训练样本作为负例抑制误分类。

参考文献(References):

[1] 雷基林,王东方,邓晰文,等. 稳定和过渡工况下柴油机活塞顶面瞬态热负荷变化规律[J]. 农业工程学报,2018,34(21):65-73.

- [2] 韩开韦. 燃气热疲劳试验台综合性能优化[D]. 杭州:浙江大学能源工程学院,2018.
- [3] 李洪民. 活塞热疲劳模拟试验台的研发[D]. 昆明:昆明理工大学材料科学学院,2014.
- [4] 伍茜,沈季胜,刘震涛,等. 基本数字图像差分法在活塞热裂纹自动检测的研究[J]. 内燃机工程,2006,27(3):58-61.
- [5] 邹北骥,郭建京,朱承璋,等. BOW-HOG特征图像分类[J]. 浙江大学学报:工学版,2017,51(12):2311-2319.
- [6] 耿思远,杨柳生,赵昆渝. 高钴钼不锈钢轴承钢疲劳裂纹萌生及扩展行为[J]. 钢铁研究学报,2018,30(11):906-915.
- [7] 李廷强. WP58柴油机活塞频繁裂纹故障攻关与研究[D]. 南宁:广西大学机械工程学院,2017.
- [8] 刘琨,罗福兴,杨克己. 基于改进型正交匹配追踪的TOFD重叠信号分离研究[J]. 机电工程,2016,33(10):1176-1181.
- [9] 童辰辰. 基于多重特征的图像分类算法研究[D]. 杭州:浙江大学信息与电子工程学系,2013.
- [10] 唐晔. 基于词袋模型的图像分类关键技术研究[D]. 南京:南京大学计算机科学与技术系,2013.
- [11] WILLAMOWSKI J, ARREGUI D, CSURKA G, et al. Categorizing nine visual classes using local appearance descriptors[J]. *Illumination*, 2004,21(17):763-768.
- [12] YU Q, LIU F, SONG Y. Sketch me that shoe[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, New York: IEEE, 2016.
- [13] 徐科,杨朝霖,周鹏. 基于ICA-SVM算法的连铸坯表面裂纹在线检测技术[C]. 第八届(2011)中国钢铁年会,北京:中国金属学会,2011.
- [14] 刘东辉,卞建鹏,付平,等. 支持向量机最优参数选择的研究[J]. 河北科技大学学报,2009,30(1):58-61.
- [15] 马立新,黄大海,王伟,等. 基于小波变换的紫外光和可见光图像融合算法[J]. 机电工程,2014,31(10):1339-1342.
- [16] 陆海亮,向忠,胡旭东. 基于小波变换的机织物高密度检测[J]. 轻工机械,2017,35(1):59-63.
- [17] WALLACH H M. Topic modeling: beyond bag-of-words[C]. Proceedings of the 23rd international conference on Machine learning, New York: IEEE, 2006.

[编辑:李辉]

本文引用格式:

陈睿,刘震涛. 基于BOW-HOG特征的活塞裂纹在线识别研究[J]. 机电工程,2019,36(5):458-463.

CHEN Rui, LIU Zhen-tao. Online identification of piston crack based on BOW-HOG feature[J]. Journal of Mechanical & Electrical Engineering, 2019,36(5):458-463.

《机电工程》杂志: <http://www.meem.com.cn>