

文章编号 1004-924X(2018)12-3087-13

基于稀疏编码空间金字塔匹配和 GA-SVM 的列车故障自动识别

孙国栋^{1*}, 周 振¹, 王俊豪¹, 张 杨^{1,2}, 赵大兴¹

(1. 湖北工业大学 机械工程学院, 湖北 武汉 430068;

2. 南京大学 计算机科学与技术系, 江苏 南京 210023)

摘要:针对货车运行故障动态图像中车辆挡键、集尘器和安全链锁紧螺栓的故障检测,提出一种基于稀疏编码空间金字塔匹配和遗传算法优化的支持向量机相结合的通用故障自动识别算法。首先在不同尺度空间对样本图像进行划分,对每个部分提取尺度不变特征变换特征,利用随机抽取样本的 SIFT 特征通过迭代学习生成字典并进行稀疏编码;其次利用主成分分析定义编码后的特征对故障识别准确率的贡献值,并据此对编码特征进行降维;然后利用编码降维后的特征结合遗传算法对线性 SVM 分类器进行训练;最后用训练好的分类器模型对挡键、集尘器和安全链锁紧螺栓的故障进行识别。实验结果表明,本文提出的算法能较好的应用于 3 种不同类型的故障识别,识别率分别为 97.25%、99.00% 和 97.50%,同时对噪声和光照变化具有一定的鲁棒性,能满足车辆故障的实际检测需求。

关键词:故障动态图像检测;稀疏编码;空间金字塔;尺度不变特征变换;遗传算法;支持向量机

中图分类号:TH703 文献标识码:A doi:10.3788/OPE.20182612.3087

Automatic fault recognition algorithm for key parts of train based on sparse coding based spatial pyramid matching and GA-SVM

SUN Guo-dong^{1*}, ZHOU Zhen¹, WANG Jun-hao¹,
ZHANG Yang^{1,2}, ZHAO Da-xing¹

(1. School of Mechanical Engineering, Hubei University of Technology, Wuhan 430068, China;

2. Department of Computer Science, Nanjing University, Nanjing 210023, China)

* Corresponding author, E-mail: sgdeagle@163.com

Abstract: A general automatic fault recognition algorithm based on sparse-coding-based spatial pyramid matching and Genetic Algorithm Optimized Support Vector Machine (GA-SVM) was proposed for fault detection of the bogie block key, dust collector, and fastening bolt in the Trouble of moving Freight car Detection System (TFDS). First, the image of a sample was divided into patch areas in different scale spaces, and the Scale-Invariant Feature Transforms (SIFT) of each patch area was extracted. Sparse coding was then performed by iteratively learning dictionaries using the SIFT features of randomly extracted samples. Second, principal component analysis was used to define the contribution of the encoded features towards fault recognition accuracy and reduce the dimensionality of the

收稿日期:2018-04-13;修订日期:2018-06-16.

基金项目:国家自然科学基金资助项目(No. 51775177, No. 51675166)

coding features. Then, the SVM classifier was trained using the reduced dimension features after coding and optimization with the genetic algorithm. Finally, the trained classifier was used to detect the bogie block key, dust collector, and fastening bolt faults from their images. The experimental results show that the algorithm can adaptively recognize the three different kinds of faults. The fault recognition rates were 97.25%, 99.00%, and 97.50% for bogie block key, dust collector, and fastening bolts, respectively. This technique is robust to noise and illumination changes and can meet the actual detection requirements of a vehicle's structural faults.

Key words: Trouble of Moving Freight Car Detection System(TFDS); sparse coding; space pyramid; Scale-invariant Feature Transform(SIFT); genetic algorithm; Support Vector Machine(SVM)

1 引 言

随着中国经济的高速发展,铁路运输行业已经成为国民经济的支柱,随之而来的铁路安全问题也日益受到重视。列车制动和转向系统故障检测是确保货运列车安全的重要日常工作。长期以来,这项工作都是由列检人员完成,存在着检测准确率低、效率低等诸多弊端。为此,我国自主研发了货车运行故障动态图像检测系统^[1](Trouble of Moving Freight Car Detection System, TFDS),通过安装在轨道两侧的高速摄像机采集行驶中列车的关键部位图像。由于图像采集环境为全天候野外采集,受到恶劣天气、光照和列车运行抖动等因素影响,采集到的图像容易出现光照不同、噪声和模糊等情况,使得故障图像的视觉检测变得十分困难。针对这些问题,国内外广大学者对基于 TFDS 的自动故障识别算法进行了深入的研究^[2-4]。

姜媛等^[5]利用 Haar 特征和 AdaBoost 算法构建层叠分类以识别枕簧故障图像,该方法虽能进行有效识别,但算法准确率不高。Liu 等^[6]提出一种基于灰度共生矩阵和 SVM 的制动梁安全链紧固螺栓丢失识别算法,该算法准确率较高,但其特征描述简单,无法应对复杂环境。Liu 等^[7]通过提取图像灰度共生矩阵的梯度编码特征,结合 AdaBoost 算法实现挡键的快速检测,其算法准确率高。Li 等^[8]提出一种基于图像轮廓的形状描述子和支持向量机(Support Vector Machine, SVM)的方法来检测列车安全链紧固螺栓丢失,该方法通过增强处理后的方向自适应灰度投影来进行特征区域定位,使用凹凸形状描述子结合 SVM 来实现故障识别,识别效果较好。Sun

等^[9]提出一种挡键丢失的故障自动识别算法,该方法能有效识别挡键丢失,但是受特殊几何模型的限制,部分有转向架的挡键识别效果不佳。Liu 等^[10]提出了一种由故障区域提取和目标检测组成的分层检测框架,并结合稀疏算法表示方向梯度直方图(Histograms of Oriented Gradients, HOG)和 SVM 的构建目标检测器,检测挡键是否丢失。实验表明,该系统实现了高准确率和高速度的状态检测。Sun 等^[11]人利用卷积神经网络(Convolutional Neural Network, CNN)对挡键、轴螺栓等故障进行识别,算法识别准确率较高。除了上述故障外,广大学者还对列车上的一些其他关键零部件故障检测进行了广泛研究:车轮轴承螺栓^[12]、锁紧板^[13]、折角塞门^[14]及高摩闸瓦^[15]。

以上学者提出的故障识别算法主要是针对 TFDS 中的特定故障进行研究,算法的通用性和鲁棒性难以保证。而深度学习算法需要针对每一类缺陷建立大量图像的样本库,样本的数量和质量对网络模型的拟合效果产生直接影响,难以保证识别准确率,且算法训练时间较长,对硬件需求较大。由于 TFDS 中包含的故障类型种类繁多,采集到的图像中存在大量的低质量图像,所以提出一种针对复杂背景下的列车关键零部件故障通用检测算法具有巨大的实用价值。

基于物体上的一些局部外观的兴趣点与影像的大小和旋转无关的尺度不变特征变换(Scale-invariant Feature Transform, SIFT)特征最早由 David 等^[16]提出,是一种检测局部特征的算法,其对于光线、噪声、微视角改变的鲁棒性非常高^[17]。S. Lazebnik 等^[18]在 SIFT 特征的基础上,结合空间金字塔模型对图形特征进行二次处理,提出空间金字塔匹配(Spatial Pyramid Matching, SPM)算法。SPM 对图像的描述能力强,鲁棒性好,广

泛应用于图像检索、对象识别和场景分类等领域^[19]。但是,SPM 在编码时一个描述子只能投影到一个字典的中心上,这样造成了明显的重构误差。稀疏编码(Sparse Coding, SC)是一种无监督学习方法,用来寻找一组“超完备”基向量来更高效地表示样本数据。引入稀疏编码可以有效降低重构误差,提升识别准确率。其中,SC 模型已经成功应用在超分辨率重建^[20]、图像分割^[21]和目标跟踪^[22]等技术领域。

鉴于此,本文提出一种基于稀疏编码空间金字塔匹配(Sparse Coding Based on Spatial Pyramid Matching, SC-SPM)的故障检测算法。该算法首先对所有样本图像提取尺度 SIFT 特征,然后在此基础上引入稀疏编码完成对样本图像的重构,生成稀疏表示的特征矩阵。同时通过遗传算法(Genetic Algorithm, GA)对线性 SVM 分类器进行参数优化,通过融合区域定位和故障识别两个步骤,实现定位和识别同步完成,有效提升了算法效率。

2 算法结构

TFDS 中的列车型号种类繁多,常见故障主要集中在转向架、制动系统和车身结构等部位。而其中制动系统内部结构复杂,安全隐患较大,是 TFDS 检测的重点环节。本文主要针对 TFDS 制动系统中的挡键(Bogie Block Key, BBK)、集尘器(Dust Collector, DC)和安全链锁紧螺栓(Fastening Bolt, FB)这 3 类关键零部件进行检测。

算法结构主要分为两个过程:训练过程和识别过程。整个算法结构如图 1 所示。

训练过程中,首先针对每个故障类型,分别选取正常和故障的 TFDS 原始图像,对图像进行预处理遍历分割成目标区域正样本、目标区域负样本和非目标区域样本 3 个类别的样本数据库,然后对所有样本提取 SIFT 特征并通过稀疏编码和 PCA 降维处理生成编码特征;最后结合特征相应的标签属性来训练线性 SVM 分类器。识别过程中,输入图像为 TFDS 采集到的原始图像,首先设计一个与训练样本大小相同的 ROI(Region of Interest)窗口对图像进行遍历,提取所有遍历所得图像的 SC-SPM 特征,最后将特征输入训练好的分类器完成定位识别。

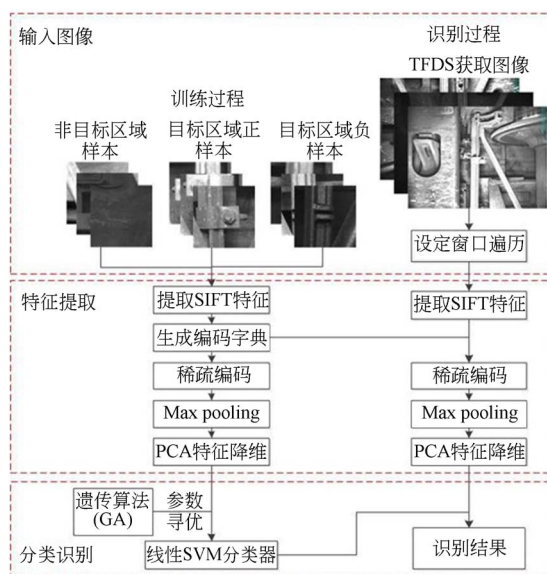


图 1 算法流程图

Fig. 1 Flow chart of proposed algorithm

3 训练过程

3.1 特征提取

3.1.1 SIFT 特征提取

SIFT 特征提取首先建立高斯尺度空间,通过高斯函数进行卷积运算实现对图像的模糊处理,得到高斯尺度空间。搜索所有尺度空间上的图像,利用差分高斯来检测空间极值点。

将所有不同尺度空间内的特征点利用高斯窗口对其进行加权运算。最后以每个 4×4 像素的块(bin)为单位绘制 8 个方向的梯度直方图,计算每个梯度方向的累加值,形成对特征点的特征描述。

具体步骤如下:

算法 1:提取图像 SIFT 特征

输入:原图像 I , I 大小为 $M \times M$, patch 大小 16×16 , 搜索步长为 8。

Step 1: 读取图像 I , 以步长 8, 将图像划分为 m 个 patch 的子区域, $m = (M/8 - 1) \times (M/8 - 1)$ 。

Step 2: 每个 patch 均为图像 I 的一个描述子, 将所有的 patch 在不同尺度空间 $I = 2^l \times 2^l$, 将图像划分为 $2^l \times 2^l$, 共计 21 个子块, 不同的尺度赋予不同的权重大小。每个 bin 大小为 4×4 。对每个 bin 提取 SIFT(8 维), 如图 2 所示, 每个 patch 包含 16 个 bins, 即每个 patch 的特征维数为 $16 \times 8 = 128$ 维。

Step 3: 计算得到 patch 的 SIFT 特征, 将所有 patch 的特征向量进行特征融合, 组成一个 $m \times 128$ 的特征矩阵, 即为图像 I 的特征表述。

输出: SIFT 特征矩阵

3.1.2 学习编码字典

在完成对所有样本图像 SIFT 特征提取后,从每张样本图像的 SIFT 特征矩阵中分别随机抽取部分组成矩阵 \mathbf{X} ,令 \mathbf{X} 表示 D 维特征空间中的 SIFT 特征描述符集合,即组成学习字典的特征样本, $\mathbf{X}=[x_1, \dots, x_m]^T \in \mathbf{R}^{M \times D}$ 。字典学习时,采用 SC 方法:

$$\min_{\mathbf{U}, \mathbf{V}} \sum_{m=1}^M \|x_m - u_m \mathbf{V}\|^2 + \lambda \|\mathbf{U}\|_1, \quad (1)$$

$$s. t. |v_k| \leq 1, \forall k=1, 2, \dots, K$$

其中: $\mathbf{V}=[v_1, \dots, v_k]^T$ 为 K 个聚类中心,称作字典; M 表示 patch 的数量; $\|\cdot\|$ 表示向量的 L2 范数, $\mathbf{U}=[u_1, \dots, u_m]^T$ 是聚类矩阵, $|u_m|$ 为 u_m 的 L1 范数。

通过先验经验设计字典大小,使得字典 \mathbf{V} 是一组过完备基,即 $K > D$ 。构造简单变换: $[\mathbf{V}^T, -\mathbf{V}^T] \rightarrow \mathbf{V}^T$, $[\mathbf{u}_{m+}^T, -\mathbf{u}_{m-}^T] \rightarrow \mathbf{u}_m^T$, 满足非负约束,其中 $\mathbf{u}_{m+} = \min(0, u_m)$, $\mathbf{u}_{m-} = \max(0, u_m)$ 。训练过程中,通过随机抽取所有 patch 中的部分特征描述子组成矩阵 \mathbf{X} ,通过 \mathbf{X} 对式(2)中的 \mathbf{U} 和 \mathbf{V} 进行迭代优化求解。

具体步骤如下:

算法 2: SC 字典生成

输入:样本矩阵 \mathbf{X} ,字典 \mathbf{V} 大小为 1024。

Step 1:读取图像 \mathbf{I} 的 SIFT 特征矩阵,随机抽取 n 列组成字典学习样本矩阵 \mathbf{X} 。

Step 2:通过式(2)对字典 \mathbf{V} 进行随机初始化,令 \mathbf{V} 保持不变,使用 Feature-sign search 算法^[25]对 \mathbf{U} 进行更新。

Step 3:令 \mathbf{U} 保持不变,使用拉格朗日对偶法^[25]对 \mathbf{V} 进行更新。

Step 4:重复上述步骤 2、步骤 3 进行迭代直至算法收敛,将字典 \mathbf{V} 保存。

输出:字典 \mathbf{V}

3.1.3 计算 SC-SPM 特征

如图 2 所示,对图像建立空间金字塔模型。字典学习完成后,统计字典中每个 bin 在图像每个 patch 中出现的次数,将不同尺度空间的结果进行排列生成该 patch 的频率直方图,统计该图像所有 patch 的频率直方图编码排列成矩阵 \mathbf{N} ,最后对矩阵 \mathbf{N} 计算 max pooling 得到图像的特征向量。

具体步骤如下:

算法 3:计算 SC-SPM 特征

输入:字典 \mathbf{V} ,原图像 \mathbf{I} 的 SIFT 特征矩阵。

Step 1:读取图像 \mathbf{I} 的 SIFT 特征矩阵。

Step 2:统计字典中每个 bin 在图像每个 patch 中出现的次数,将不同尺度空间的结果进行排列生成该 patch 的频率直方图。计算采用主流的特征直方图计算方式:

$$z = \frac{1}{M} \sum_{m=1}^M u_m$$

Step 3:统计该图像所有 patch 的频率直方图编码排列成矩阵 \mathbf{N} , \mathbf{N} 的行数是 patch 个数,列数为字典中的原子个数,最后对矩阵 \mathbf{N} 进行 max pooling 计算,即对 \mathbf{N} 每一列取最大值,并归一化得到的向量就是该图像的特征向量。

输出:SC-SPM 特征向量




图 2 基于稀疏编码的空间金字塔

Fig. 2 Sparse coding based on spatial pyramid

3.2 特征降维

稀疏编码后的特征维数较多,直接用于训练计算负担较大,为进一步提高故障识别效率,对编码特征进行降维。主成分分析法(Principal Component Analysis, PCA)是一种应用广泛的降维算法。其原理是计算给定的特征矩阵 $\mathbf{X} \times \mathbf{Y}$ (\mathbf{X} 为样本数, \mathbf{Y} 为特征)的协方差矩阵 \mathbf{C} ,计算 \mathbf{C} 的特征值和特征向量,然后按特征值大小将对应的特征向量排序组成一个新的矩阵,最后根据特征值的贡献率,即前 P 列特征值之和占全部特征值之和的比例,选取前 P 列组成降维矩阵 \mathbf{F}_{sc} 。而贡献率的选择对算法的准确率有一定影响,为方便比较,定义贡献值为贡献率的选择阈值,实验选取贡献率小于或等于贡献值的所有列组成降维矩阵。

通过一系列对比实验发现,算法的准确率和特征维数与贡献值之间的关系如图 3 和图 4 所示。

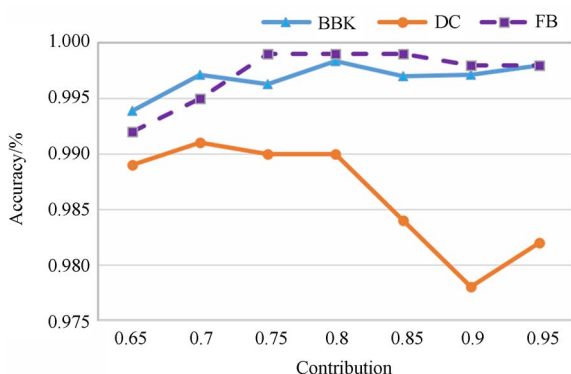


图 3 贡献值与准确率关系

Fig. 3 Relationship between the contribution value and the accuracy rate

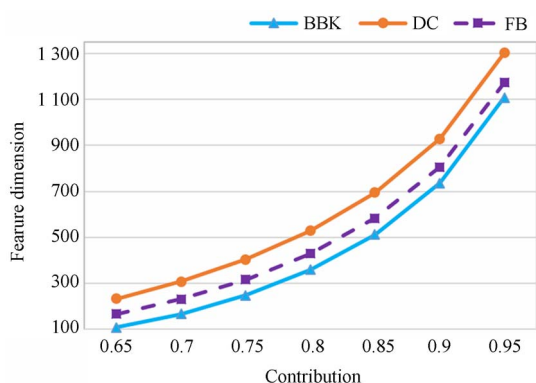


图 4 贡献值与特征维数关系

Fig. 4 Relationship between contribution value and feature dimension

由实验结果得到,随着贡献值的增大,不同故障场景下算法的准确率均会有一定提升,但特征维数会大幅增加,计算成本和效率也随之增加;当贡献值超过一定数值之后,准确率反而开始下降。因此,综合考虑准确率和计算效率的问题,针对 BBK、DC 和 FB 三类不同的故障应用场景,贡献值分别取 0.8、0.7 和 0.75。

3.3 分类器参数选择

SVM 做分类预测时需要调整相关参数才能得到比较理想的预测分类准确率,而相关参数主要以惩罚参数 c 和核函数参数 g 为主。对于参数 c 和 g 的选择,传统方法主要采用交叉验证 (Cross Validation, CV) 的思想,通过将原始数据分为训练集和验证集,选取获得最佳分类器性能的 c 和 g 的值。而在 CV 方法中,常用网格划分

来寻找最佳的参数 c 和 g 。虽然采用网格搜索能够找到最高分类准确率的参数,即全局最优解。但 TFDS 图像背景环境复杂,需要在更大的范围内寻找全局最优解,同时在搜索设定上,还需要基于一种先验方式,计算效率不高。而启发式算法不必遍历网格内所有参数点即可找到全局最优解,故采用 GA 作为参数寻优算法。

GA 起源于对生物系统所进行的计算机模拟研究,适用于复杂系统优化的自适应概率优化。GA 作为一种实用、高效、鲁棒性强的优化技术,发展极为迅速,引起国内外学者的广泛研究^[23]。

本文利用 GA 对 SVM 分类器参数进行优化,其算法流程如图 5 所示。

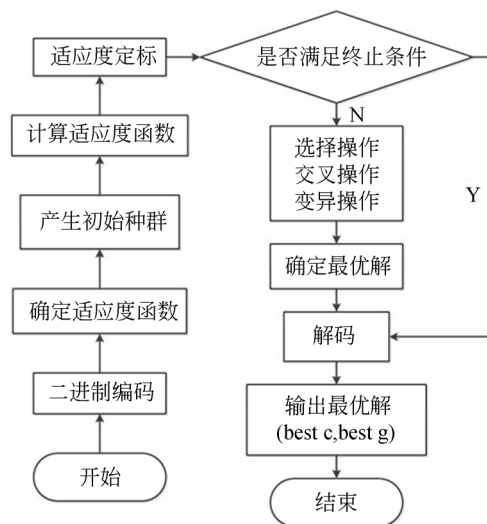


图 5 GA 参数寻优流程图

Fig. 5 Flow chart of genetic algorithm parameter optimization

3.4 分类器训练

首先是核函数的选择,由于 SC-SPM 输出的特征为非线性特征,所以可以采用一种简单的线性核函数:

$$k(\mathbf{z}_i, \mathbf{z}_j) = \mathbf{z}_i^T \mathbf{z}_j = \sum_{t=0}^2 \sum_{s=1}^{2^l} \sum_{t=1}^{2^l} \langle \mathbf{z}_i^l(s, t), \mathbf{z}_j^l(s, t) \rangle, \quad (3)$$

其中: \mathbf{z}_i 表示图像 \mathbf{I}_i 的特征向量, $\langle \mathbf{z}_i, \mathbf{z}_j \rangle = \mathbf{z}_i^T \mathbf{z}_j$; $\mathbf{z}_i^l(s, t)$ 为图像 \mathbf{I}_i 在尺度空间 l 下第 (s, t) 个描述符的 max pooling 计算。即 SVM 的决策函数可表示为:

$$f(\mathbf{z}) = \left(\sum_{i=1}^n \alpha_i \mathbf{z}_i \right)^T \mathbf{z} + \mathbf{b} = \mathbf{w}^T + \mathbf{b}. \quad (4)$$

由于采用线性核函数,计算效率可以大幅度提升,算法可以适用于大量样本计算的场景,符合本文的识别环境。

分类器训练过程中,首先选取部分 TFDS 采集的正常和故障图像,对图像进行预处理遍历分割成非目标区域样本、目标区域正样本和目标区域负样本 3 个类别。提取 3 类样本的 SIFT 特征并经过 3.1 节中所述的 SC 得到特征矩阵,再经过 3.2 节所述的 PCA 降维后得到特征矩阵 F_{sc} ,将 F_{sc} 输入到 SVM 分类器并引入 GA 进行训练。

4 识别过程

如图 6 所示,识别过程的输入为 TFDS 采集得到的列车原始图像。包括设定窗口遍历、提取 SC-SPM 特征和线性 SVM 分类识别这三个步骤。

提取 TFDS 采集到的 BBK、DC 和 FB 图像,输入到 SC-SPM 算法中,通过设定大小分别为 320×320 、 180×180 和 200×200 的窗口遍历图像,将遍历得到的所有 patch 提取 F_{sc} 特征,最后将其输入到训练好的分类器进行测试。设置标签概率输出,概率为遍历所得图像与目标区域的相似度,取标签 1 和 2 中概率最大项为目标区域图像。当最大项为标签 1 时,即为正常图像,用绿色矩形标记;当最大项为标签 2 时,即为故障图像,用红色矩形标记(彩图见期刊电子版)。

5 实验结果及分析

实验环境如下:Windows 7($\times 64$)操作系统, Intel(R) Xeon(R) CPU E5-2640 v4 @2.40 GHz 和 64 GB 的 RAM, MATLAB R2016b 软件。在挡键(BBK)、集尘器(DC)和安全链锁紧螺栓(FB)3 种类型故障库上进行算法性能测试。所有实验结果采取均值法,即同样实验条件随机重复 5 次对结果取均值,保证实验结果的有效性。

5.1 数据库与性能评价指标


如图 6 所示,TFDS 图像采集装置一般布置在室外,易受恶劣天气和光照等客观因素影响。为满足列车检验的实际需求,采用 TFDS-3 系统^[26],该系统采用黑白线阵相机,采集的图像为灰度图像,不可利用其颜色特征进行识别,图像分

辨率为 140 万,最高拍摄速度 70 000 线/s。实验通过 TFDS 将采集到的 BBK、DC 和 FB3 种类型故障图像进行遍历分割,建立 3 个数据集:非目标区域样本数据集、目标区域正样本数据集和目标区域负样本数据集,分别标记为标签 0、标签 1 和标签 2,其中标签 1 代表不含故障的正样本图像,标签 2 代表含故障的负样本图像,如图 7 所示。



图 6 TFDS 图像采集装置(a. 高速货运列车;b. 铁路;c. 图像采集系统)

Fig. 6 TFDS image acquisition device (a. high-speed train; b. railroad; c. image acquisition system)



(a)非目标区域样本 (b)目标区域正样本 (c)目标区域负样本
(a)Non-target region sample (b)Target region positive sample (c)Target region negative sample

图 7 样本数据库部分样本
Fig. 7 Part of sample database

同时,为了有效验证算法性能,建立 3 个评价指标^[7,24,26]:故障正确检测率(Correct Detection Rate, CDR),故障漏检率(Missing Detection Rate, MDR),故障误检率(False Detection Rate, FDR)。

5.2 分类效果比较

分别从 3 类故障数据库中选取部分样本分别作为训练样本和测试样本进行实验,不同场景下的不同故障样本尺寸大小和样本数量如表 1 所示。

表 1 3 种数据库图像大小和训练数量

Tab. 1 Training image sizes and numbers of three libraries

库	图像大小	图像总数	训练样本(0/1/2)	测试样本(0/1/2)
BBK	320×320	12 140	8 000/1 200/500	2 000/300/140
DC	180×180	11 640	8 000/1 000/300	2 000/200/140
FB	200×200	13 000	8 000/1 500/600	2 000/500/400

同时,为了验证算法的有效性,对目前主流的列车故障识别算法进行实验。由表 2 可知,本文提取的算法在不同故障库中都有较高的准确率,而其他几种算法在不同故障下的检测性能参差不齐

表 2 各对比实验结果

Tab. 2 Results of the comparison experiments

序号	特征+分类器	准确率/%		
		BBK	DC	FB
1	$F_{sc} + SVM$	99.84	99.70	99.20
2	LBP+BP-AdaBoost	97.42	95.55	93.71
3	GLCM+SVM	95.59	94.26	92.17
4	LBP+HOG+Haar-like+BP-AdaBoost	97.37	99.84	99.15

齐,通用性较差,难以满足实际检测需求。本文算法提取了图像的全局信息、局部信息和空间位置信息,图像表述误差控制在很小范围内,再通过将分类和识别拟合到一起,做到分类和识别同步完成,识别效率较高。

5.3 故障识别实验

TFDS-3 常采用黑白相机采集图像,由于列车的运动抖动、天气和光照变化等问题,即使有补充光源,仍旧存在一定噪声、光照不足和曝光过度等现象,采集到的图像质量较低。将采集到的原始图像输入到训练好的模型中,测试故障实际检测效果。测试图像数量及识别结果如表 3 所示。

由表 3 可知,本文算法对 3 类故障均有较好的检测效果,CDR 分别为 97.25%、99.00% 和 97.50%,MDR 均低于 1%。通常,在列车故障检测中,指标 MDR 比 FDR 更重要,这是因为如果非故障区域被错检为故障,对列检的影响并不十分严重^[24]。部分检测结果如图 8 所示。

表 3 测试图像数量及识别结果

Tab. 3 Numbers and inspection results of test images

库	图像总数	正常/故障图像数	MDR/%	FDR/%	CDR/%
BBK	400	336/64	0.75	2.00	97.25
DC	398	222/176	0.25	0.75	99.00
FB	600	237/363	1.00	1.50	97.50



(a) 正常图像 (a)Normal image (b)光照因素产生的低质量图像 (b)Images of low quality produced by lighting factors (c)噪声因素产生的低质量图像 (c)Images of low quality produced by noising factors

图 8 不同故障部分检测结果

Fig. 8 Part of inspection results in different faults

5.4 抗噪性实验

为了进一步验证算法的抗噪性,随机从 TFDS-3 系统采集的原始图像中分别选取 BBK、DC 和 FB 三个故障类型的正常图像和故障图像各 50 张,对其分别加载均值为 0、标准差(Standard Deviation, SD)分别为 10、20、30 和 40 的高

斯噪声。

如表 4 所示,少量噪声对算法基本没有影响,识别准确率均在 96%以上。随着噪声增加到 SD 为 40 时,识别准确率会有小幅度降低,不过依旧均保持在 91%以上,算法抗噪性较好,鲁棒性强。部分检测结果如图 9 所示。

表 4 加载高斯噪声后的识别结果

Tab. 4 Results of recognition after loading Gaussian noise

(%)

故障类型	MDR				FDR				CDR			
	SD:10	SD:20	SD:30	SD:40	SD:10	SD:20	SD:30	SD:40	SD:10	SD:20	SD:30	SD:40
BBK	1	1	3	4	0	1	1	2	99	98	96	94
DC	2	3	4	4	1	1	1	2	97	96	95	94
FB	0	1	2	2	2	3	6	7	98	96	92	91




图 9 不同故障加载高斯噪声后部分检测结果

Fig. 9 Part of inspection results in different faults after loading Gaussian noise

5.5 光照鲁棒性实验

为了方便评价光照变化对图像所产生的影响,以图像的平均灰度值(Average Gray Value, AGV)作为评价指标,对图像中的所有像素点的灰度值进行均值归一化。计算公式如下:

$$AGV = \frac{1}{255} \sum_{i=1}^n \frac{x_i}{n}, \quad (5)$$

其中: n 为每张图像中的像素数量, x 表示每个像素点的灰度值。

首先,随机从 TFDS-3 系统采集的原始图像中分别选取 BBK、DC 和 FB 三个故障类型的正常图像和故障图像各 50 张。对每张图像进行均值归一化,所有图像的统计结果如图 10 所示,BBK 的灰度变换区间为 0.166 6~0.362 5;DC 的灰度变换区间为 0.165 0~0.580 5;FB 的灰度变换区间为 0.132 7~0.745 5。

然后,为进一步验证算法在光照变化下的有

效性,利用幂律变换函数分别对所有图像进行灰度变换,函数描述如下:

$$s = c \cdot r^\gamma, \quad (6)$$

其中 r 是原始像素灰度, s 是结果像素值, c 是一个缩放常数, γ 是一个正值。

最后,通过调整值使得变换后的图像 AGV 最大值大于对应故障类型的 AGV_{max} ,如图 11(a)所示;最小值小于对应故障类型的 AGV_{min} ,如图 11(c)。即可以保证包含了实际测试中图像光照

变化区间,满足实际检测需求,实验结果如表 5 所示。

由表 5 可知,在光照变化时,对算法影响很小,光照较为充足的条件下,三类故障识别准确率均在 96%以上;当曝光不足时,对算法有一定影响,但其识别准确率仍然保持在 93%以上。算法在光照变化时,鲁棒性强。部分检测结果如图 11 所示。

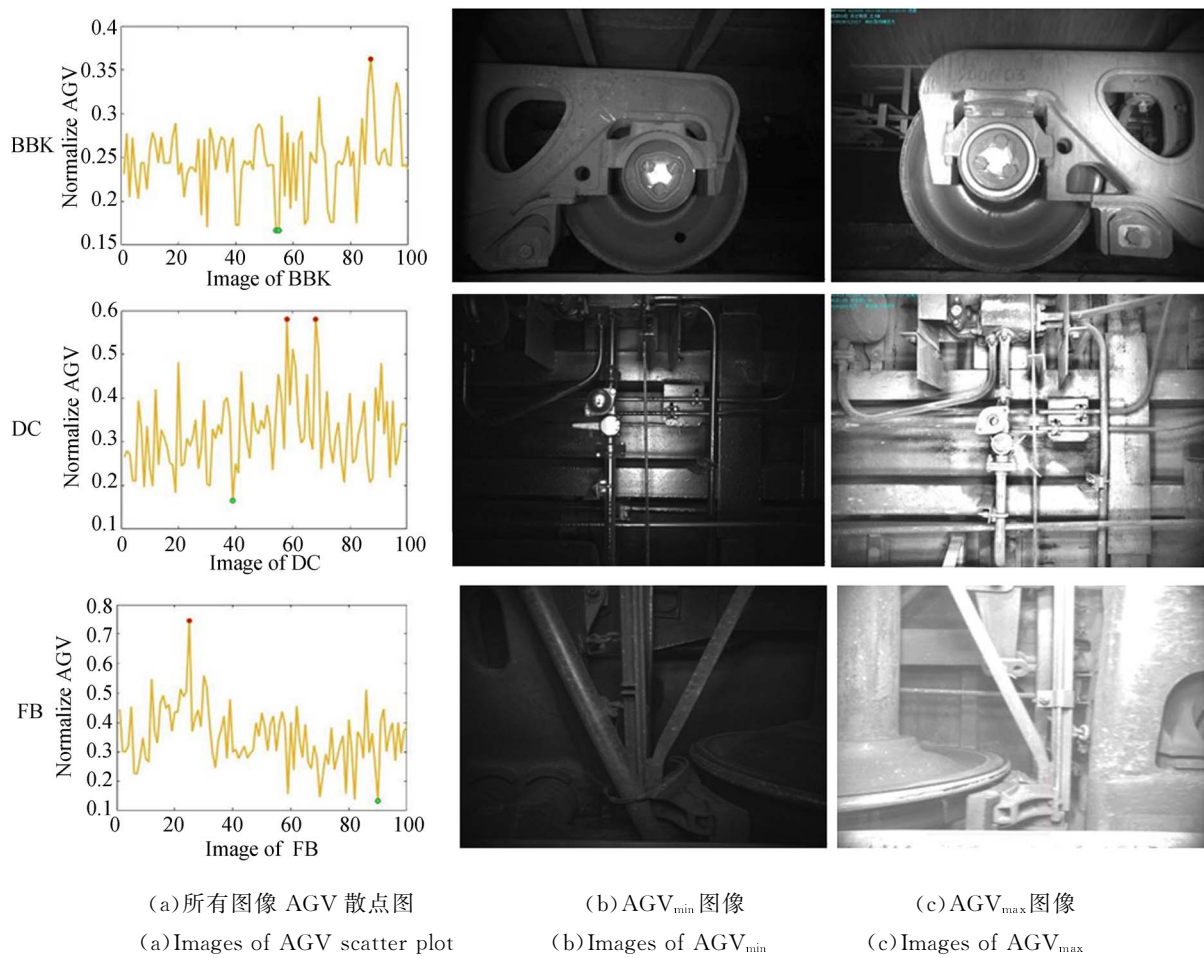


图 10 图像灰度均值归一化

Fig. 10 Image grayscale mean normalization

表 5 灰度变换后的识别结果

Tab. 5 Results of recognition after grayscale conversion

(%)

故障类型	MDR		FDR		CDR	
	$<AGV_{min}$	$>AGV_{max}$	$<AGV_{min}$	$>AGV_{max}$	$<AGV_{min}$	$>AGV_{max}$
BBK	2	1	4	2	94	97
DC	3	1	3	3	94	96
FB	3	1	4	1	93	98

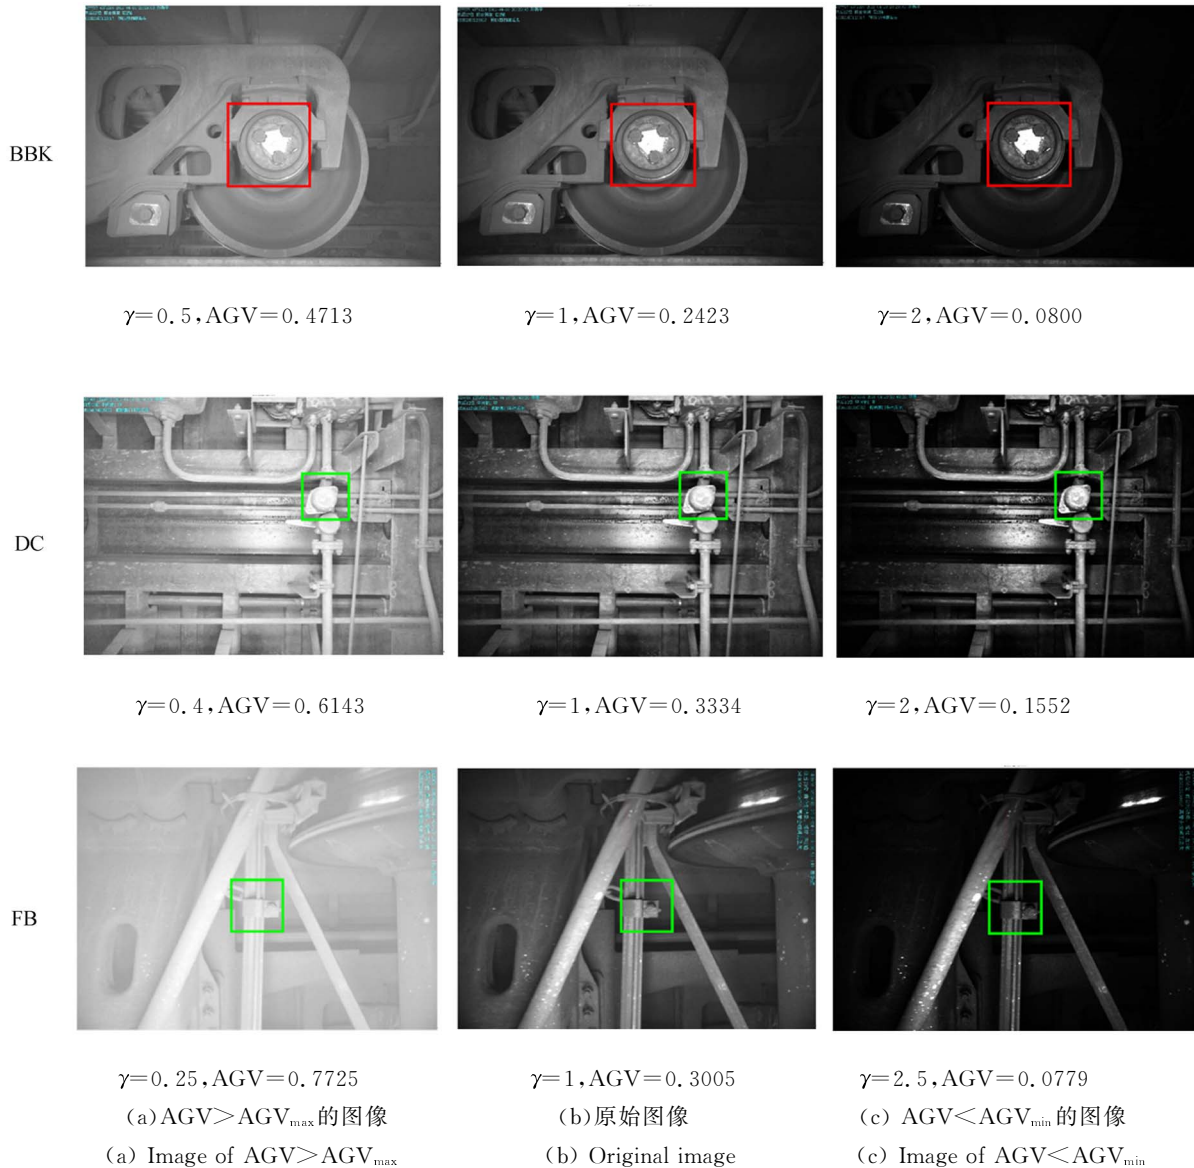


图 11 不同故障灰度变换后部分检测结果

Fig. 11 Part of inspection results in different faults after grayscale conversion

6 结 论

为了提高 TFDS 关键零件故障识别算法的检测率和通用性,从特征重构出发,采用 SIFT 特征结合稀疏编码双重描述方式,使其对图像形成一个更佳的表述方式。同时引入 GA 对 SVM 分类器进行参数寻优,提升算法效果。最后的实验结果证明,本文算法能实现 BBK、DC 和 FB 三种不同故障的识别, BBK、DC 和 FB 检测率分别高

达 97.25%、99.00% 和 97.50%, BBK 库上漏检率和误检率分别为 0.75% 和 2%, DC 库上漏检率和误检率分别为 0.25% 和 0.75%, FB 库上漏检率和误检率分别为 1% 和 1.5%。该算法识别准确率高,漏检率和误检率低,对噪声和光照变化具有一定的鲁棒性。

SIFT 特征的计算成本相对较高,后续研究将探索如何对 SC-SPM 特征进行改进和提纯,进一步提高算法的效率。

参考文献:

- [1] 刘瑞扬. 货车运行故障动态图像检测系统(TFDS)的原理与应用[J]. 中国铁路, 2005, (5): 26-37.
LIU R Y. Principle and application of trouble of moving freight car detection system (TFDS) [J]. *Chinese Railways*, 2005, (5):26-37. (in Chinese)
- [2] ZHENG C, WEI Z Z. Automatic online vision-based inspection system of coupler yoke for freight trains[J]. *Journal of Electronic Imaging*, 2016, 25(6): 061602.
- [3] 赵大兴, 王博, 周唯倜, 等. 基于有向线段重构轮廓与成对几何直方图的缓解阀盖图像匹配算法[J]. 中国机械工程, 2017, 28(6): 721-727.
ZHAO D X, WANG B, ZHOU W T, *et al.*. Image matching algorithm of release valve bonnet based on contours reconstructed by oriented line segment and pairwise geometrical histogram[J]. *China Mechanical Engineering*, 2017, 28(6): 721-727. (in Chinese)
- [4] 孙国栋, 汤汉兵, 林凯, 等. 基于多特征融合和 BP-AdaBoost 的列车关键零件故障自动识别算法[J]. 中国机械工程, 2017, 28(21): 1-6.
SUN G D, TANG H B, LIN K, *et al.*. Automatic fault recognition algorithm for key parts of train based on multi-feature fusion and BP-AdaBoost[J]. *China Mechanical Engineering*, 2017, 28(21): 2588-2594. (in Chinese)
- [5] 姜媛, 周富强, 张广军. 货车枕簧丢失故障动态图像识别方法[J]. 光学技术, 2007, 33(5): 662-665.
JIANG Y, ZHOU F Q, ZHANG G J. An automatic recognition method for trouble of sleeper springs of freight cars[J]. *Optical Technique*, 2007, 33(5): 662-665. (in Chinese)
- [6] LIU L, ZHOU F, HE Y. Automated status inspection of fastening bolts on freight trains using a machine vision approach[J]. *Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail & Rapid Transit*, 2016, 230(7): 1159-66.
- [7] LIU L, ZHOU F Q, HE Y Z. Automated visual inspection system for bogie block key under complex freight train environment[J]. *IEEE Transactions on Instrumentation and Measurement*, 2016, 65(1): 2-14.
- [8] LI N, WEI Z, CAO Z. Automatic fault recognition for Brake-Shoe-Key losing of freight train[J]. *Optik - International Journal for Light and Electron Optics*, 2015, 126(23): 4735-4742.
- [9] SUN G D, FENG W, ZHAO D X, *et al.*. An automatic fault recognition method for side frame key in TFDS[J]. *The Open Mechanical Engineering Journal*, 2015, 9(1): 22-27.
- [10] LIU L, ZHOU F, HE Y. Vision-based fault inspection of small mechanical components for train safety[J]. *Iet Intelligent Transport Systems*, 2016, 10(2): 130-139.
- [11] SUN J H, XIAO Z W, XIE Y X. Automatic multi-fault recognition in TFDS based on convolutional neural network [J]. *Neurocomputing*, 2017, 222: 127-136.
- [12] LI C, WEI Z, XING J. Online inspection system for the automatic detection of bolt defects on a freight train[J]. *Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail & Rapid Transit*, 2016, 230(4): 271-288.
- [13] 邹荣, 李健康, 徐家祥, 等. 复杂场景下铁路货车锁紧板偏转故障检测[J]. 铁道科学与工程学报, 2015, (4): 917-922.
ZOU R, LI J K, XU J X, *et al.*. Deflection fault detection for locking plate of freight trains under complex scene[J]. *Journal of Railway Science and Engineering*, 2015, (4): 917-922. (in Chinese)
- [14] ZHOU F, ZOU R, QIU Y, *et al.*. Automated visual inspection of angle cocks during train operation[J]. *Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail & Rapid Transit*, 2013, 228(7): 794-806.
- [15] LU S, NAN G, ZHANG G. Automated visual inspection of brake shoe wear[C]. *Applied Optics and Photonics China*, 2015: 96752F.
- [16] DAVID G. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.

- [17] 屈玉福,刘子悦,江云秋,等. 自适应尺度特征点提取方法[J]. *光学精密工程*, 2017, 25(1): 188-197.
- QU Y F, LIU Z Y, JIANG Y Q, *et al.*. Self-adaptive variable-metric feature point extraction method[J]. *Opt. Precision Eng.*, 2017, 25(1): 188-197. (in Chinese)
- [18] LAZEBNIK S, SCHMID C, PONCE J. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories[J]. *IEEE Conference Society Conference on Computer Vision & Pattern Recognition*, 2006, 2(1/2): 2169-2178.
- [19] DONG B. A new scene classification method based on spatial pyramid matching model[J]. *Journal of Information & Computational Science*. 2015, 12(3): 1073-1080.
- [20] 韩玉兰,赵永平,王启松,等. 稀疏表示下的噪声图像超分辨率重构[J]. *光学精密工程*, 2017, 25(6): 1619-1626.
- HAN Y L, ZHAO Y P, WANG Q S, *et al.*. Reconstruction of super resolution for noise image under the sparse representation[J]. *Opt. Precision Eng.*, 2017, 25(6): 1619-1626. (in Chinese)
- [21] 王雪虎,杨健,艾丹妮,等. 结合先验稀疏字典和空洞填充的 CT 图像肝脏分割[J]. *光学精密工程*, 2015, 23(9): 2687-2697.
- WANG X H, YANG J, AI D N, *et al.*. Liver segmentation in CT image based on priori sparse dictionary and hole filling [J]. *Opt. Precision Eng.*, 2015, 23(9): 2687-2697. (in Chinese)
- [22] ZHANG K, ZHANG L, YANG M H. Fast compressive tracking[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2014, 36(10): 2002-2015.
- [23] 杨洁,郑宁,刘董,等. 基于遗传算法的 SVM 带权特征和模型参数优化[J]. *计算机仿真*, 2008, 25(9): 115-117.
- YANG J, ZHENG N, LIU D, *et al.*. Optimization of features with weight and model parameters of SVM based on genetic algorithm[J]. *Computer Simulation*. 2008, 25(9): 115-117. (in Chinese)
- [24] 张杨. 基于改进马尔科夫随机场与精确高度函数的列车故障图像层次特征匹配[D]. 武汉: 湖北工业大学, 2017.
- ZHANG Y. *Hierarchical feature matching of the fault image based improved Markov random field and exact height function in TFDS* [D]. Wuhan: Hubei University of Technology, 2017. (in Chinese)
- [25] ZHAO Z, FENG G C. Efficient algorithm for sparse coding and dictionary learning with applications to face recognition[J]. *Journal of Electronic Imaging*, 2015, 24(2): 023009.
- [26] SUN G D, ZHANG Y, TANG H B, *et al.*. Railway equipment detection using exact height function shape descriptor based on fast adaptive Markov random field[J]. *Optical Engineering*, 2018, 57(5): 1.

作者简介:



孙国栋(1981—),男,湖北天门人,博士,教授,分别于2002年、2008年在华中科技大学获得学士、博士学位,主要从事图像处理和机器学习等方面的研究。E-mail:sgdeagle@163.com



周振(1991—),男,湖北黄冈人,硕士研究生,2015年于湖北工业大学获得学士学位,主要从事图像处理和深度学习等方面的研究。E-mail:cn_zhouzhen@163.com