

复杂场景下动车底部螺栓丢失故障的自动检测

路绳方

北京航空航天大学仪器科学与光电工程学院, 北京 100083

摘要 动车底部闸瓦部位的螺栓,对列车整体制动系统起着关键作用。闸瓦部位螺栓的丢失,会给列车安全制动以及安全行驶带来严重威胁。以螺栓丢失故障检测为例,提出动车中零部件丢失故障的在线检测与识别算法,为动车重点部位的故障诊断进行针对性检测提供了一种指导方法。结合螺栓几何结构的特点,提出了一种基于图像 Sobel 梯度边缘的完备局部二进制模型特征提取算法,结合二值分类器的训练与学习,完成螺栓丢失故障的自动检测。结果表明,所提算法对复杂场景下螺栓丢失故障的识别有很强的稳健性,其检测效率和精度也很高,能够满足现场应用需求。

关键词 机器视觉; 故障检测; 特征提取; 二值分类器; 螺栓

中图分类号 U216.3 **文献标识码** A

doi: 10.3788/LOP54.111501

Automatic Inspection of Bolt Missing at the Bottom of Multiple Unit Trains Under Complex Environment

Lu Shengfang

School of Instrumentation Science and Optoelectronics Engineering, Beihang University, Beijing 100083, China

Abstract The bolt at the bottom of multiple unit train plays a key role in the overall braking system of the train. The bolt missing will bring serious challenges for the train safety braking and safety running. By the example of fault inspection of bolt missing, an online inspection and recognition algorithm is proposed for the fault of components missing in a train, which provides a guidance for the targeted inspection on the key parts of the train. Due to the characteristics of the bolts geometry, a complete local binary patterns feature extraction algorithm based on the image Sobel gradient edge is proposed, and the training and learning of a binary classifier is combined to complete the automatic fault inspection of bolt missing. The results show that the proposed algorithm has strong robustness to inspect the fault in complex scenes with high inspection efficiency and precision, which can meet the demand of the site application.

Key words machine vision; fault inspection; feature extraction; binary classifier; bolt

OCIS codes 150.1135; 150.3040; 330.7325; 330.5000

1 引言

随着中国铁路的快速发展,中国高铁技术日益成熟。高速铁路建设不仅在国内如火如荼地开展,也在积极地向国外推广,“高铁外交”已成为目前我国外交领域中的一张新名片^[1]。高速铁路的快速发展给人们的出行带来便捷,同时也给自身维修带来了挑战。列车长时间的高速运行以及零部件数量繁多和多样化,可能导致高速列车在运行中出现各种各样的问题。传统的人工检修方式不仅效率低,而且受人为主观因素影响大,难以适应高速列车高效率、高质量的检修要求。因此,利用计算机视觉与图像理解的相关知识,实现列车

收稿日期: 2017-05-02; **收到修改稿日期:** 2017-06-02

基金项目: 国家重大科学仪器设备开发专项(2012YQ140032)、科学研究与研究生培养共建项目—成果转化与产业化项目—列车弓网运行状况在线动态检测系统

作者简介: 路绳方(1985—),男,博士研究生,主要从事机器视觉、视觉测量、图像处理 and 模式识别等方面的研究。

E-mail: lshf14240@163.com

零部件故障的在线检测是目前铁路运输领域中的一项迫切需求^[2]。动车底部闸瓦部位的螺栓是连接制动钳和闸瓦的重要结构件,螺栓的丢失会造成列车制动失效,甚至会导致列车脱轨等重大事故。针对螺栓丢失故障的问题,本文提出了一种基于 Sobel^[3]梯度预处理的完备局部二值模式(CLBP)^[4]算法,结合机器学习知识,实现动车底部螺栓是否丢失的判断。

2 螺栓丢失故障的自动识别

动车是高铁的一种车型,其运行主要有以下特点^[2]:1) 动车编组固定;2) 同一类型的车辆结构相同;3) 车体零部件结构状态统一;4) 列车运行线路固定。列车转向架上两个轮轴处的螺栓位置固定,采用轮轴精确外部触发方式启动像机拍摄图片,可以获取螺栓精确位置的图像。

2.1 螺栓特征提取

动车底部每一个转向架上有 6 个制动盘,每个制动盘附近有一组制动钳,每组制动钳上有两个固定螺栓,如图 1 所示。由于外部光线变化不均,螺栓目标部位会出现不同灰度值,给螺栓的稳健性特征提取带来一定困难。通过观察螺栓的几何特征可知,螺栓具有规则几何形状和很强的边缘响应。根据目标特点,提取目标的稳健性特征对目标进行识别是机器学习中一种常见方法^[5-7]。特征是图像表现的外在形式,是图像内容的抽象表征。特征提取常用于图像配准、目标检测与识别等^[8-10]。Ojala 等^[11]提出了一种理论上计算简单且具有很强纹理表征效果的特征提取算子——局部二值模型(LBP)。LBP 对图像光线变化有较强的稳健性,适用于复杂环境或者光照不均情况下物体表面纹理特征的提取。很多学者围绕 LBP 算法进行了扩展,常见的 LBP 扩展方法有 CLBP 和局部三进制模型(LTP)^[12],其中,CLBP 方法包含更完整的局部特征信息,因而更适合复杂图像特征的表达。为了减小外部光线变化的背景因素对目标特征提取的干扰,提出了在 Sobel 梯度域下对螺栓进行 CLBP 特征提取,并结合基于交叉核函数支持向量机分类器(ICSVM)^[13]对目标状态进行识别的算法。Sobel 梯度化预处理,不仅保留了图像的边缘梯度信息,而且滤去了不相干的背景灰度信息,使图像中的目标纹理更加简洁和具有代表性,再结合其他稳健性特征的表达,可以快速实现目标状态的自动检测。CLBP 模型不仅包含了局部二进制中心模型(CLBP_C),还包括了局部二进制符号模型(CLBP_S)和局部二进制梯度模型(CLBP_M)。CLBP 特征具有丰富的局部纹理信息,因而更适合图像局部特征的表达。目标图像在经过 Sobel 梯度化处理后,在目标图像的 3 pixel×3 pixel 的局部区域中,计算中心点的向量梯度模的信息 m_p 和符号信息 s_p 为

$$m_p = |g_p - g_c|, \quad (1)$$

$$s_p = f_1(g_p - g_c), \quad (2)$$

式中 p 为 LBP 基本算子的邻域像素个数, c 为 CLBP 基本算子的中心像素, g_p 和 g_c 分别为邻域和中心像素的灰度值, $f_1(x)$ 定义为

$$f_1(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}. \quad (3)$$

则组成 CLBP 的 3 个分量分别定义为




图 1 转向架上的螺栓示意图。(a)螺栓;(b)转向架;(c)螺栓

Fig. 1 Schematic of bolts on the bogie. (a) Bolt; (b) bogie; (c) bolt

$$S_{p,R} = \sum_{p=0}^{P-1} 2^p s_p = \sum_{p=0}^{p-1} 2^p f_1(g_p - g_c), \quad (4)$$

$$M_{p,R} = \sum_{p=0}^{p-1} 2^p t(m_p, c), \quad (5)$$

$$C_{p,R} = t(g_p, c), \quad (6)$$

式中 R 为窗口半径, $t(x, \varphi) = \begin{cases} 0, & x < \varphi \\ 1, & x \geq \varphi \end{cases}$, c 为整幅图像的平均灰度值。

对上述 3 个特征梯度直方图进行级联, 形成 CLBP 特征。取局部 LBP 算子 p 为 8 邻域的窗口, 窗口半径设 $R=1$ 。为了使目标特征更加稳定, 利用滑动窗口法^[14] 扫描整个样本图像, 对每个窗口提取的 Edge-CLBP 特征进行级联。每个正样本和负样本的大小均为 $80 \text{ pixel} \times 80 \text{ pixel}$, 滑动窗口大小设为 $20 \text{ pixel} \times 20 \text{ pixel}$, 滑动间隔在水平方向和竖直方向上设为 20 pixel , 图片被分为 $4 \times 4 = 16$ 个窗口块。之后, 对每个样本中的 16 个窗口块分别进行 Edge-CLBP 特征提取, 并对这 16 个梯度直方图进行级联, 形成一个 480 维的 Edge-CLBP 特征。图 2 为 Edge-CLBP 特征的提取过程, 其中图 2(a) 为螺栓正样本图(无故障); 图 2(d) 为螺栓负样本图(螺栓丢失); 图 2(b) 和图 2(e) 分别为正负样本的 Sobel 梯度图; 图 2(c) 和图 2(f) 分别为正负样本对应的 Edge-CLBP 特征的提取结果。由图 2 可知, 梯度图过滤掉了大部分无关背景信息, 减少了背景对目标地干扰, 突出了目标的边缘信息; 正负样本纹理特征表现出很大的差异。




图 2 Edge-CLBP 特征的提取。

(a) 正样本; (b) Sobel 梯度图; (c) Edge-CLBP 特征; (d) 负样本; (e) Sobel 梯度图; (f) Edge-CLBP 特征

Fig. 2 Feature extraction of Edge-CLBP. (a) Positive samples; (b) Sobel gradient; (c) Edge-CLBP feature; (d) negative samples; (e) Sobel gradient; (f) Edge-CLBP feature

2.2 检测分类器的选择

利用图像特征对特定分类器进行训练, 完成图像特征空间的划分, 形成某些具有相似特性的特征分块集合, 进而实现图像中目标识别。这种训练方法属于分类判别模型^[15], 由数据驱动, 通过从底层向上的方式对训练样本进行监督学习, 在样本的特征空间中生成合适的分类函数。支持向量机(SVM)属于分类判别模型, 以结构风险最小化为原则, 在核函数特征空间中, 寻找一个能够满足最优化的特征分类函数对特征进行精确地划分。与其他常见判别模型相比, SVM 方法在训练效率上更具优势, 特别是线性 SVM 分类器, 由于其线性特点, 样本训练速度快、识别精度高, 常用于目标的在线实时检测^[16]。对于一些复杂特征, 特别是对一些高维向量线性不可分特征, 通常利用基于核函数的 SVM 分类器将特征映射到高维空间, 使非线性特征变为线性可分。采用核函数还可以避免维度灾难和过度拟合等问题, 并且不增加计算复杂度。IKSVM^[13] 对高维向量具有较好的分类性能和较高的分类执行效率。假设样本特征向量为 $\mathbf{x}_i \in \mathbf{R}^n$, 其对应的标志集为 $l_i \in (-1, 1)$, 式中 $i=1, 2, 3, \dots, N$, N 为特征向量的个数。为了得到不同特征集间的最优分类超平面, 定义目标函数为

$$L(\mathbf{w}, \vartheta) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \vartheta_i, \quad (7)$$

式中 $y_i(\omega_i \mathbf{x}_i + b) \geq 1 - \vartheta_i, \vartheta_i \geq 0, C > 0$ 。 ω_i 为向量对应的系数, ϑ_i 为松弛变量, C 为错误代价系数。

通过目标函数最小化, 即可求得最优分类器对应各个系数中的参数值, 进而确定最优分类器。由于特征为高维且非线性可分, 引入核函数 $k(\mathbf{x}, \mathbf{z}) = \varphi(\mathbf{x}) \cdot \varphi(\mathbf{z})$, 则

$$L(\alpha) = -\frac{1}{2} \sum_{ij} \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) + \sum_{i=1}^N \alpha_i. \quad (8)$$

基于核函数的决策函数为

$$h(\mathbf{x}) = \sum_{l=1}^m a_l y_l k(\mathbf{x}, \mathbf{x}_l) + b, \quad (9)$$

式中 m 为分类器的支持向量的个数。

交叉核函数定义为

$$k(\mathbf{x}_i, \mathbf{x}_l) = \sum_{i=1}^n \min(\mathbf{x}_i, \mathbf{x}_l), \quad (10)$$

式中 n 为特征向量的维数。

将(10)式代入(9)式可得:

$$h(\mathbf{x}) = \sum_{l=1}^m a_l y_l \sum_{i=1}^n \min[\mathbf{x}(i), \mathbf{x}_l(i)] + b = \sum_{i=1}^n \sum_{l=1}^m a_l y_l \cdot \min[\mathbf{x}(i), \mathbf{x}_l(i)] + b = \sum_{i=1}^n h_i[\mathbf{x}(i)] + b, \quad (11)$$

$$h_i(\mathbf{s}) = \sum_{l=1}^m a_l y_l \min[\mathbf{s}, \mathbf{x}_l(i)]. \quad (12)$$

(12)式表示的意义为, 将 m 个向量 \mathbf{s} 逐个地同每个样本的第 i 维 $\mathbf{x}_l(i)$ 进行比较, 对二者之间的最小值进行累加。为了优化决策函数 $h_i(\mathbf{s})$, 将 m 个向量 $\mathbf{x}_l(i)$ 按照数值大小升序构建向量集合 $\mathbf{x}_l(i)$, 并且定义, 如果输入向量 $\mathbf{s} < \mathbf{x}_l(i)$, \mathbf{s} 为向量集合 $\mathbf{x}_l(i)$ 的最小值, 此时 $h_i(\mathbf{s}) = 0$; 如果 $\mathbf{s} \geq \mathbf{x}_r(i)$, r 定义为小于 \mathbf{s} 向量时所对应的最大序号。因此,

$$h_i(\mathbf{s}) = \sum_{i=1}^m a_l y_l \cdot \min[\mathbf{s}, \mathbf{x}_l(i)] = \sum_{i=1}^m a_l y_l \cdot \min[\mathbf{s}, \mathbf{x}_l(i)] = \sum_{1 < l < r} a_l y_l \mathbf{x}_l(i) + \mathbf{s} \sum_{r < l < m} a_l y_l = \mathbf{A}_i(r) + \mathbf{s} B_i(r), \quad (13)$$

式中 $\mathbf{A}_i(r) = \sum_{1 < l < r} a_l y_l \mathbf{x}_l(i)$, $B_i(r) = \sum_{r < l < m} a_l y_l$ 。

由(13)式可知, $h_i(\mathbf{s})$ 为线性分段函数, 并且 $h_i(\mathbf{s})$ 的计算复杂度被降到 $O[\lg(m)]$, 因此决策函数 $h(\mathbf{x})$ 的整体计算复杂度被降为 $O[n \lg(m)]$ 。与原来的计算复杂度 $O(mn)$ 相比, 通过交叉核函数的优化, 算法复杂度降低为原来的 $O[m/\lg(m)]$ 。正是由于这种原因, 交叉核函数很大程度地降低了计算复杂度, 提高了计算速度, 保证了分类的高效率。

3 实验设计与分析

3.1 螺栓故障检测与识别

为了自动检测和识别出螺栓是否存在丢失的故障问题, 对检测分类器 h_{det} 进行训练。选取 467 个图像作为训练样本集, 其中包含 334 个无故障正样本, 133 个有故障负样本, 每个样本图像的大小均为 $80 \text{ pixel} \times 80 \text{ pixel}$, 如图 3 所示。由图 3 可以看出, 由于光线变化不均、物体遮挡以及油渍侵蚀等原因, 各个正负样本的目标图像的灰度值不尽相同。对训练样本集中的正负样本分别进行 Edge-CLBP 特征提取, 然后将训练样本集的特征代入 IK SVM 分类器进行线下训练, 得到螺栓丢失故障检测分类器 h_{det} 的训练结果, 通过计算可以得到分类器的各项系数, 如图 4 所示。利用上述训练好的分类器, 对实时拍摄的图像中的螺栓丢失故障进行检测, 其检测结果如图 5 所示。图 5(a) 中制动钳包含 6 个固定螺栓, 其中 5 个为无故障螺栓, 1 个出现了




图3 用于训练故障检测分类器的(a)正样本和(b)负样本

Fig. 3 (a) Positive and (b) negative samples used for training the fault inspection classifier




图4 正负样本训练后得到的分类器结果

Fig. 4 Results of the classifier after positive and negative samples training

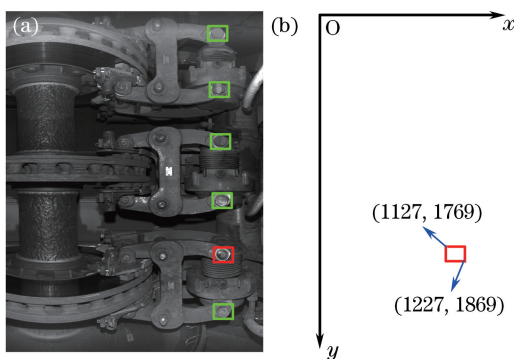


图5 螺栓丢失故障检测结果。(a)螺栓丢失检测结果;(b)故障在图像坐标中的位置

Fig. 5 Fault inspection result of bolt missing. (a) Inspection result of bolt missing; (b) position of fault in the image coordinate

丢失故障;绿色矩形框表示检测出的螺栓没有出现丢失故障,红色矩形框表示为检测出的螺栓出现了丢失故障。图5(b)中显示了螺栓丢失故障在实际图像坐标中的位置,记下此时图像的序列号和故障位置,发送给终端服务器,提醒现场列检人员该处螺栓出现丢失,需现场重点查看并确认。

3.2 不同特征下目标检测的对比分析

螺栓故障的识别分为两个过程,即检测分类器的训练和目标故障的识别。利用滑动窗口法提取目标的特征,对检测分类器进行线下训练。为了验证这种基于 Sobel 梯度边缘下的 CLBP 算法的优越性,利用 Edge-CLBP、LTP^[12] 和梯度编码直方图(GEH)^[16] 方法分别对训练集进行特征提取,并训练 IK SVM 分类器 h_{det} , 然后对测试集中的螺栓进行检测。选取了 750 张不同曝光时间下的图片作为测试样本集(图 6), 其中包含 90 张螺栓丢失故障的图片和 660 张无故障图片。利用上述 3 类特征训练好的分类器 h_{det} 对测试集分别进行检测, Edge-CLBP、LTP 和 GEH 方法的检测准确率分别为 96.32%、91.12% 和 92.59%, 所得测试样本工作特征(ROC)曲线^[16] 如图 7 所示。结果表明, Edge-CLBP 算法对复杂环境下目标故障的检测具有较好的检测性能、较高的检测精度, 且对光线变化具有较强的稳健性。

基于 Sobel 梯度边缘下的 CLBP 算法在故障检测精度和效率上具有明显的优势, 其主要原因在于:

1) Edge-CLBP特征对正负样本具有较强的分类能力,通过提取目标的梯度边缘信息,过滤掉大部分背景区域中无关的灰度干扰信息,尽可能地保留目标中不受灰度影响的纹理特征,确保所提取的特征对外部复杂环境具有较强的稳健性;2) Edge-CLBP特征维数小,对于 $80 \text{ pixel} \times 80 \text{ pixel}$ 大小的目标区域提取的级联 Edge-CLBP特征维数为 480,确保特征的快速提取和分类识别;3) IKSVM 分类器的选择,与其他分类器相比,IKSVM 具有较高的检测精度和数据处理效率。

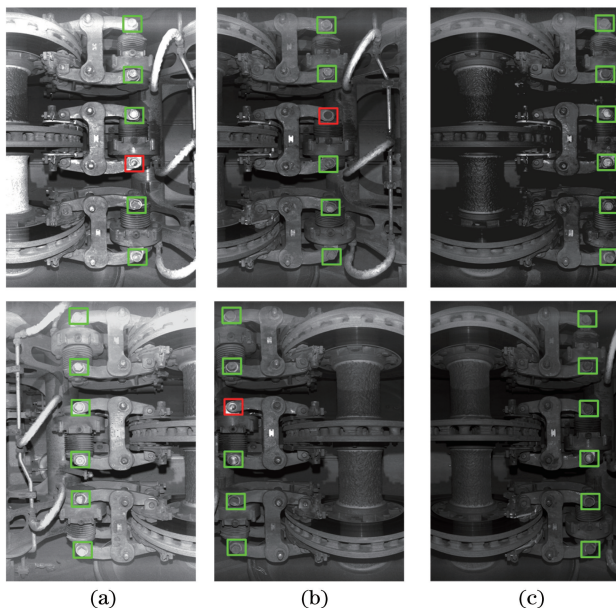


图 6 测试图像集。(a)过度曝光;(b)正常曝光;(c)曝光不足

Fig. 6 Test images. (a) Overexposed images; (b) normal images; (c) underexposed images

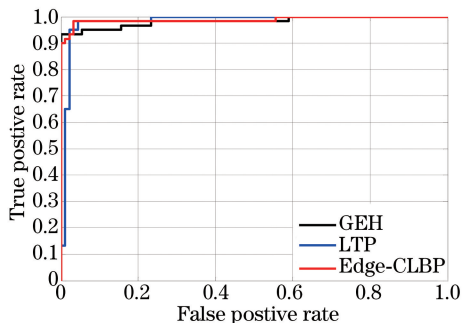


图 7 不同特征下对测试样本图像检测的 ROC 曲线

Fig. 7 ROC curves of test images using different features

4 结 论

针对复杂环境下动车底部螺栓丢失故障的自动检测,提出了一种基于 Sobel 梯度边缘下的 CLBP 算法,该算法尽可能地保留了目标的边缘信息,过滤掉了复杂背景的无关干扰信息,结合交叉核函数 SVM 分类器,可实现复杂环境下螺栓丢失故障的快速检测,为动车零部件的故障检测和安全运行提供一定的安全保障。对不同曝光时间的图像进行螺栓丢失故障检测,结果表明,该算法检测精度和效率优于其他几种常见的特征算法。另外,该算法对外部光线环境的变化具有较强的稳健性,可用于解决现场问题。

参 考 文 献

- [1] Yuan Yuqing. Analysis on China's high-rail diplomacy under the background of "the belt and road initiative" [D]. Nanjing: Nanjing University, 2016.

- 袁玉青. “一带一路”战略背景下的中国高铁外交探析[D]. 南京: 南京大学, 2016.
- [2] Li Jun. The design and implementation of TEDS system [D]. Beijing: Beijing University of Post and Telecommunications, 2012.
李俊. 动车组运行故障动态图像检测系统[D]. 北京: 北京邮电大学, 2012.
- [3] Sobel I. Camera models and machine perception[D]. California: Stanford University, 1970.
- [4] Guo Z H, Zhang L, Zhang D. A completed modeling of local binary pattern operator for texture classification[J]. IEEE Transactions on Image Processing, 2010, 19(6): 1657-1663.
- [5] Qiao Naosheng, Zhang Fen, Li Xiaoqin. Defect image preprocessing of printed circuit board [J]. Laser & Optoelectronics Progress, 2015, 52(2): 021003.
乔闹生, 张奋, 黎小琴. 印刷电路板板缺陷图像预处理研究[J]. 激光与光电子学进展, 2015, 52(2): 021003.
- [6] Song Xiaoyan, Bai Fuzhong, Wu Jianxin, *et al.* Wood knot defects recognition with gray-scale histogram features[J]. Laser & Optoelectronics Progress, 2015, 52 (3): 031501.
宋小燕, 白福忠, 武建新, 等. 应用灰度直方图特征识别木材表面节子缺陷[J]. 激光与光电子学进展, 2015, 52(3): 031501.
- [7] Mo Shaowen, Deng Xinpu, Wang Shuai, *et al.* Moving object detection algorithm based on improved visual background extractor[J]. Acta Optica Sinica, 2016, 36(6): 0615001.
莫邵文, 邓新蒲, 王帅, 等. 基于改进视觉背景提取的运动目标检测算法[J]. 光学学报, 2016, 36(6): 0615001.
- [8] Yang Sa, Yang Chunling. Image registration algorithm based on sparse random projection and scale-invariant feature transform[J]. Acta Optica Sinica, 2014, 34(11): 1110001.
杨飒, 杨春玲. 基于压缩感知与尺度不变特征变换的图像配准算法[J]. 光学学报, 2014, 34(11): 1110001.
- [9] Wang Xiangjun, Wang Yan, Li Zhi. Fast target recognition and tracking method based on characteristic corner[J]. Acta Optica Sinica, 2007, 27(2): 360-364.
王向军, 王研, 李智. 基于特征角点的目标跟踪和快速识别算法研究[J]. 光学学报, 2007, 27(2): 360-364.
- [10] Yang Sa, Xia Minghua, Zheng Zhishuo. Medical image registration algorithm based on polynomial deterministic matrix and SIFT transform[J]. Laser & Optoelectronics Progress, 2016, 53(8): 081002.
杨飒, 夏明华, 郑志硕. 基于多项式确定性矩阵的 SIFT 医学图像配准算法[J]. 激光与光电子学进展, 2016, 53(8): 081002.
- [11] Ojala T, Pietikäinen M, Mäenpää T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(7): 971-987.
- [12] Murala S, Maheshwari R, Balasubramanian R. Local tetra patterns: a new feature descriptor for content-based image retrieval[J]. IEEE Transactions on Image Processing, 2012, 21(5): 2874-2886.
- [13] Maji S, Berg A, Malik J. Classification using intersection kernel support vector machines is efficient [J]. IEEE Computer Vision and Pattern Recognition, 2008, 21: 1-8.
- [14] Lampert C, Blaschko M, Hofmann T. Efficient subwindow search: a branch and bound framework for object localization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2129-2142.
- [15] Gao Jun, Xie Zhao. Theory and method of image understanding[M]. Beijing: Science Press, 2009.
高隽, 谢昭. 图像理解理论与方法[M]. 北京: 科学出版社, 2009.
- [16] Zhou F Q, Zou R, Qiu Y F, *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.