

## 直线导轨面缺陷检测与分类方法

周友行<sup>1,2</sup>, 李勇<sup>1</sup>, 孔拓<sup>1</sup>, 赵晗斌<sup>1</sup>

(1. 湘潭大学机械工程学院, 湘潭, 411105; 2. 复杂轨迹加工工艺及装备教育部工程研究中心, 湘潭, 411105)

**摘要:**为解决复杂背景下直线导轨面缺陷识别难的问题,提出了一种基于灰度共生矩阵(Gray level co-occurrence matrix, GLCM)和非负矩阵分解(Non-negative matrix factor, NMF)的纹理背景抑制来实现缺陷特征增强的方法。首先,利用GLCM多特征统计量重构导轨面背景纹理图,实现一定程度上的纹理背景抑制;接着,将纹理图均分成若干子图像块,随机抽取一定的子图像块进行NMF训练;然后,将NMF分解出的基图像同纹理图中相同大小图像块遍历求其欧式距离,并将距离平均后赋值给纹理图中相应图像块的中心像素点,以进一步实现纹理背景抑制和缺陷特征增强。最后,基于K-means聚类和支持向量机对缺陷进行分类识别。实验结果中对测试集中的划痕、裂纹和撞伤缺陷识别准确率分别为89.06%, 88.46%和95.12%,表明该方法能抑制纹理背景和增强缺陷特征,有效分离出缺陷并识别其类型。

**关键词:** 直线导轨面;灰度共生矩阵;非负矩阵分解;特征增强;缺陷识别

**中图分类号:** TP391      **文献标志码:** A

## Defect Detection and Classification Method of Linear Guide Surface

ZHOU Youhang<sup>1,2</sup>, LI Yong<sup>1</sup>, KONG Tuo<sup>1</sup>, ZHAO Hanyun<sup>1</sup>

(1. School of Mechanical Engineering, Xiangtan University, Xiangtan, 411105, China; 2. Engineering Research Center of Complex Tracks Processing Technology and Equipment of Ministry of Education, Xiangtan, 411105, China)

**Abstract:** In order to solve the difficulty of segmenting the linear guide surface defects from image with a complex background, a method based on gray level co-occurrence matrix (GLCM) and non-negative matrix factorization (NMF) to suppress the texture background to realize defect feature enhancement was proposed. Firstly, the GLCM multi-feature statistics was used to reconstruct the background texture map of the linear guide surface to achieve a certain degree of texture background suppression. Then, the texture was divided into several sub-image blocks, and a certain sub-image block was randomly selected for NMF dimension reduction. Next, the basic matrix decomposed by NMF was traversed by the same size image block in the texture map to find its Euclidean distance, and the averaged distance was assigned to the center pixel of the corresponding image block in the texture image to realize texture background suppression and features enhancement. Finally, the defects were classified based on K-means clustering and support vector machine. In the experiment, the recognition accuracy of scratches, cracks and crash defects in the test set are 89.06%, 88.46% and 95.12%, which shows that the proposed method can suppress the texture background effectively and enhance the defect features of the linear guide surface image, and it can separate

the defects and identify their types accurately.

**Key words:** linear guides face; gray level co-occurrence matrix (GLCM); non-negative matrix factorization (NMF); feature enhancement; defect identification

## 引 言

直线导轨表面质量对设备使用寿命和产品加工精度具有重要影响<sup>[1]</sup>。而在实际应用中导轨材料自身缺陷、重量过载、滑动速度异常和加工刀具破损等因素,导致导轨表面产生多种类型缺陷,如裂纹、划伤、撞伤等<sup>[2]</sup>。快速准确的导轨面缺陷实时检测,有助于企业减少生产成本和保证加工质量。

目前,基于机器视觉表面检测技术具有非接触、低成本、响应快等优点,为导轨面缺陷的快速在线检测提供了可能<sup>[3-6]</sup>。但实际导轨面图像缺陷检测存在以下问题:缺陷目标在整个图像中像素占比少且信噪比较低;纹理背景与缺陷目标灰度区分不明显;光照等图像采集环境不理想<sup>[7]</sup>;同时导轨面从加工到完成会经过铣削、磨削和刮削等多个加工工序,不同加工工艺产生不同的加工纹理,形成了导轨面图像纹理背景的紊乱复杂性,特别是当缺陷纹理与机械加工纹理方向一致时,缺陷就会很难被检测到甚至可能检测失效;此外,在复杂纹理背景的干扰下,常用的边缘提取算子难以区分导轨面纹理和缺陷纹理,且算法复杂和计算量较大,通常难以满足实时性处理要求。这些问题给导轨面检测带来很大困难,因此如何抑制复杂纹理背景来实现缺陷特征增强是导轨面质量检测的关键。有关通过抑制纹理背景来提高目标与其之间对比度问题,国内外许多学者对其开展了相关研究。如张东波等<sup>[8]</sup>结合各向异性纹理抑制和滞后多阈值处理技术,实现了对手机配件金属表面划痕的增强检测;李凡<sup>[9]</sup>提出了一种基于多尺度奇异值分解背景抑制算法,实现红外图像中背景抑制和弱小目标增强;Shakenov<sup>[10]</sup>结合双边滤波算法和自相关分析实现了对边界背景的准确估计和非目标区域纹理背景的有效抑制。Mak等<sup>[11]</sup>设计了一个优化的形态学滤波器来增强图像缺陷和背景的对比如,解决了缺陷和非缺陷之间的低对比度问题。但通过抑制机械表面复杂加工纹理背景来增强缺陷目标的研究还存在不足,而上述这些研究表明:抑制纹理背景有利于目标特征的增强,这为直线导轨面的缺陷检测提供了新思路。

要实现导轨面纹理背景抑制和缺陷特征增强的前提是有效提取纹理背景特征。灰度共生矩阵(Gray level co-occurrence matrix, GLCM)是目前公认的有较强适应性与鲁棒性的纹理特征提取方法之一<sup>[12]</sup>,其针对实际导轨面纹理紊乱无序,检测环境光照不均等难题,通过像素及其周围空间邻域的灰度分布来反映图像灰度关于方向相邻间隔、变化幅度的综合信息<sup>[13]</sup>。因此,本文引入GLCM获取导轨面纹理特征统计量,以增强导轨面缺陷区域和非缺陷对比为目的,分析选取其中熵、对比度和相关性特征加权平均后重生成新的纹理图像以增强缺陷和非缺陷区域背景纹理的对比如。同时采用非负矩阵分解(Non-negative matrix factorization, NMF)对新构建的纹理图像进行分解获得基图像,将其同原纹理图中相同大小图像块遍历求得的欧式距离平均后赋值给相应图像块的中心像素点,以实现纹理背景抑制和缺陷特征增强;最后,基于K-means聚类和SVM完成对导轨面缺陷的识别及分类,结果表明本文提出的方法较传统的边缘提取算法表现出更优的性能。

## 1 直线导轨面缺陷图像特点分析

原始样本采集于国内某导轨生产厂家,整个采集系统核心装置为江苏天准集团的VM222高端全自动摄像机,如图1所示。其图像传感器采用基于感光耦合组件CCD芯片的高清晰彩色工业摄像机,内置可选配可升降的程控式6环8区环形轮廓光、表面光 and 同轴光LED冷光源,能提供45°~75°多种种射角度照明,同时256级亮度可调功能为图像采集环境提供可靠性高和光均匀稳定的光照条件。

采样精度 10 bit, 像元大小为  $4.65 \mu\text{m} \times 4.65 \mu\text{m}$ , 拍摄的每一幅图像大小为 256 像素  $\times$  256 像素, 12.5:1 连续变倍镜头可实现运动物体的高质量成像, 图 2 为所采集现场的直线导轨面样本。




图 1 天准 VM222 高端摄像仪

Fig.1 Tianzhun VMU222 imaging equipment



图 2 直线导轨面图像


Fig.2 Linear guide surface image

在获取各类导轨面缺陷图像后, 分析各类缺陷的特点有利于对其进行识别和分类。图 3 是常见的缺陷图像, 下面对直线导轨面常见缺陷特点进行说明。

(1) 划伤。大多是加工过程中被工具刮擦而产生的, 其在图像中的表现形式是呈细长状分布且边缘相对光滑。

(2) 撞伤。大多由于加工过程或搬运过程中的不合理操作与其他工件产生碰撞而产生的, 其在图像中表现为块状分布, 且具有明显的下巴特征。

(3) 裂纹。由于在加工过程中直线导轨面局部存在过大的扩张应力, 从而产生的具有一定深度和长度的条形裂缝, 其在图像中的表现形式为细长状且边缘不平整。



(a) 划伤  
(a) Scratch

(b) 撞伤  
(b) Crash

(c) 裂纹  
(c) Crack

图 3 直线导轨面常见缺陷图像

Fig.3 Common defect images of linear guide surface

## 2 导轨面缺陷识别流程及其算法设计

### 2.1 缺陷识别思路和流程

本文提出了如图 4 所示的直线导轨面缺陷识别方法。针对机床导轨表面图像的特点, 结合 GLCM 和 NMF 实现直线导轨面的纹理背景抑制和缺陷特征增强。具体地, 基于 GLCM 多特征统计量构建背景纹理图并均分为  $n$  个大小为  $8 \times 8$  的子图像块; 随机抽取 200 幅子图像块作为输入进行 NMF 降维; 将 NMF 分解出的基图像同纹理图中相同大小图像块遍历求其欧式距离, 并将距离平均后赋值给纹理图

中相应图像块的中心像素点,以抑制纹理背景实现缺陷特征增强;最后,基于K-means聚类 and SVM对缺陷进行分类识别。

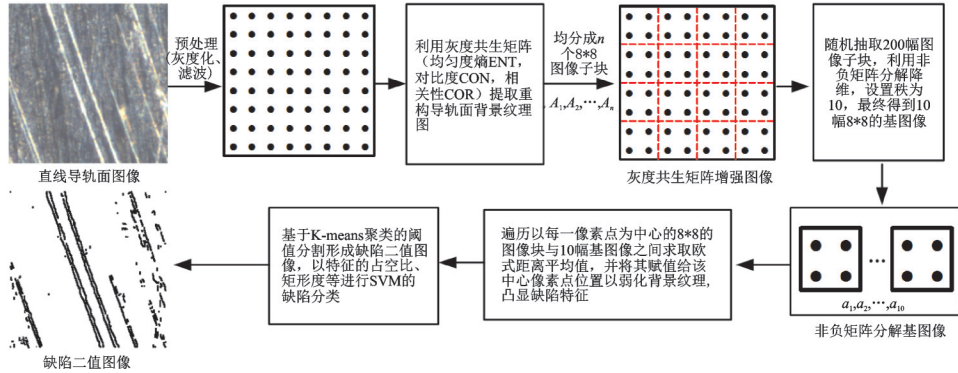


图4 直线导轨面缺陷识别算法流程

Fig.4 Flow of defect recognition algorithm for linear guide surface

## 2.2 缺陷识别算法设计

### 2.2.1 GLCM的纹理特征提取

直线导轨面缺陷检测中,缺陷区域和非缺陷区域具有不同的纹理特征。基于该假设,本文提出利用GLCM构建直线导轨面纹理图,通过抑制非缺陷区域纹理背景来突显缺陷特征。

假定实验中所拍摄的直线导轨面图像大小为  $N_x * N_y$ , 定义GLCM方向为  $\theta$ , 其中为避免纹理方向性的干扰,  $\theta$  取  $0^\circ, 45^\circ, 90^\circ$  和  $135^\circ$  四个方向, 则GLCM元素可定义为<sup>[14]</sup>

$$\begin{cases} p(i, j, 0^\circ) = \#\{(i_1, j_1)(i_2, j_2) \in N_x * N_y \mid i - i_1 = 0, j - j_2 = 1; f(i, i_1) = i, f(j, j_1) = j\} \\ p(i, j, 45^\circ) = \#\{(i_1, j_1)(i_2, j_2) \in N_x * N_y \mid i - i_1 = -1, j - j_2 = 0; f(i, i_1) = i, f(j, j_1) = j\} \\ p(i, j, 90^\circ) = \#\{(i_1, j_1)(i_2, j_2) \in N_x * N_y \mid i - i_1 = 0, j - j_2 = 1; f(i, i_1) = i, f(j, j_1) = j\} \\ p(i, j, 135^\circ) = \#\{(i_1, j_1)(i_2, j_2) \in N_x * N_y \mid i - i_1 = -1, j - j_2 = -1; f(i, i_1) = i, f(j, j_1) = j\} \end{cases} \quad (1)$$

式中:  $p(i, j, \theta)$  表示导轨面图像矩阵在第  $i$  行第  $j$  列像素值,  $\#\{N\}$  表示矩阵像素点个数。  $i, j$  表示矩阵  $i$  行  $j$  列在  $\theta$  方向上, 相邻间隔为  $d$  的像素中, 一个取  $i$  值, 一个取  $j$  值的相邻对点数。构建完成4个共生矩阵后, 将其按相同的权重构建灰度共生矩阵

$$p(i, j) = [p(i, j, 0^\circ) + p(i, j, 45^\circ) + p(i, j, 90^\circ) + p(i, j, 145^\circ)] / 4 \quad (2)$$

为使GLCM特征统计量有更高的纹理分辨率, 对灰度共生矩阵进行归一化

$$p(i, j) = \frac{p(i, j)}{R} \quad (3)$$

$$\text{式中 } R = \begin{cases} 2N_y(N_x - 1) & \theta = 0^\circ, 90^\circ \\ (N_x - 1)(N_y - 1) & \theta = 45^\circ, 135^\circ \end{cases}$$

通过GLCM构建的纹理图像是通过灰度共生矩阵特征值来描述的, 常用的灰度共生矩阵特征值有8种。通过对比实验本文将灰度级量化到128级后依次选取表征均匀度熵特征值ENT、表征平滑度的对比度特征值CON与表征线性相关性的相关特征值COR重构灰度共生矩阵导轨面纹理图, 其相关定义如下<sup>[15]</sup>:

(1) ENT 熵

$$p_{\text{ENT}}(i, j) = - \sum_{i=1}^k \sum_{j=1}^k p(i, j) * \log p(i, j) \quad (4)$$

(2) CON 对比度

$$p_{\text{CON}}(i, j) = \sum_n^{G-1} n^2 \left\{ \sum_{i=1}^G \sum_{j=1}^G p(i, j) \right\} \quad |i-j|=n \quad (5)$$

(3) 相关性 COR

$$p_{\text{COR}}(i, j) = - \sum_{i=1}^k \sum_{j=1}^k (i, j) - \mu_x \mu_y / \delta_x^2 \delta_y^2 \quad (6)$$

式中:  $\mu_x, \mu_y$  和  $\delta_x, \delta_y$  分别是  $p_x, p_y$  的均值和方差, 表达式分别为

$$\begin{cases} \mu_x = \mu_y = \sum_{i=1}^G \sum_{j=1}^G p(i, j) \\ \delta_x^2 = (i - \mu_x)^2 \sum_{i=1}^G \sum_{j=1}^G p(i, j) \\ \delta_y^2 = (i - \mu_y)^2 \sum_{i=1}^G \sum_{j=1}^G p(i, j) \end{cases} \quad (7)$$

式中  $G(i, j)$  代表灰度图像矩阵中位于第  $i$  行第  $j$  列的像素点的灰度值。

分别求取上述 GLCM 特征值后, 等比例加权求均值, 并赋予 GLCM 矩阵相应像素点, 即

$$p(i, j) = p_{\text{ENT}}(i, j) + p_{\text{CON}}(i, j) + p_{\text{COR}}(i, j) / 3 \quad (8)$$

### 2.2.2 NMF 纹理背景抑制

GLCM 纹理图包含导轨面不同表面区域的纹理信息, 但非缺陷区域纹理背景会对缺陷纹理获取产生严重干扰, 如当缺陷纹理和机械加工纹理方向一致时, 缺陷纹理容易被覆盖。基于此, 提出将 GLCM 纹理图划分为若干相同大小的子图像块, 随机抽取一定数量的子图像块作为输入进行 NMF 训练。

将 GLCM 纹理特征图均为  $8 \times 8$  图像块, 随机抽样 200 幅子图像块, 向量化后作为输入进行 NMF, 设基矩阵秩为 10。其目标函数和迭代规则表示为<sup>[16]</sup>

$$F = \sum_{i=1}^n \sum_{u=1}^m [V_{iu} \log (WH)_{iu} - (WH)_{iu}] \quad (9)$$

$$\begin{cases} W_{ia} \leftarrow W_{ia} \cdot \frac{\sum_u [H_{au} V_{iu} / (WH)_{iu}]}{\sum_u H_{au}} \\ H_{au} \leftarrow H_{au} \cdot \frac{\sum_i [W_{ia} V_{iu} / (WH)_{iu}]}{\sum_i W_{ia}} \end{cases} \quad (10)$$

式中:  $V$  为待分解矩阵,  $W$  和  $H$  为分解后的基矩阵和系数矩阵。

在该迭代规则下, 当目标函数达到局部最大值时, 将得到  $W$  和  $H$  的最优估计, 从而实现图像的纹理背景数据挖掘。NMF 分解图是对原始图像的一种低维的近似, 它是由 10 列元素个数为  $8 \times 8$  的向量按行排列而成, 而灰度共生矩阵纹理图也被划分成了若干个  $8 \times 8$  大小的像素块, 依次计算灰度共生矩阵纹理特征图中每一个像素块与 NMF 分解出的 10 个基图像的欧式距离, 求平均值将其赋值给像素块的中心像素点, 由于缺陷特征的纹理特征值与 NMF 分解出的向量距离较大, 因而可以实现纹理背景抑制和缺陷特征增强。最后基于 K-means 聚类法则对赋值后像素块进行阈值分割, 获得机床导轨面的缺陷

二值图像以完成缺陷图像特征的提取。

### 3 直线导轨面缺陷识别与分类

#### 3.1 缺陷增强提取

以实验中采集到的某样本裂纹图像图 5(a)为例。利用 GLCM 熵、对比度和相关性特征图 5(b)—(f) 构建新的 GLCM 特征纹理图 5(e), 从图 5(e) 可以发现通过 GLCM 三特征值重构图像纹理图与图 5(a) 相比, 缺陷区域到非缺陷区域像素变化更加明显, 即缺陷边缘得到了一定增强。利用 NMF 降维后并对纹理背景进行抑制得到缺陷特征增强图 5(f) 进一步凸显了缺陷特征, 最终对其进行 K-means 聚类算法形成缺陷二值图 5(g), 从而实现缺陷增强提取。

基于 K-means 聚类算法获取缺陷二值图像方法的主要流程为: 首先, 定义聚类数目  $k=2$ , 将得到的直线导轨面背景纹理抑制图像同样划分为大小为  $8 \times 8$  的  $N$  个像素块作为输入, 任意选取其中的  $K$  个

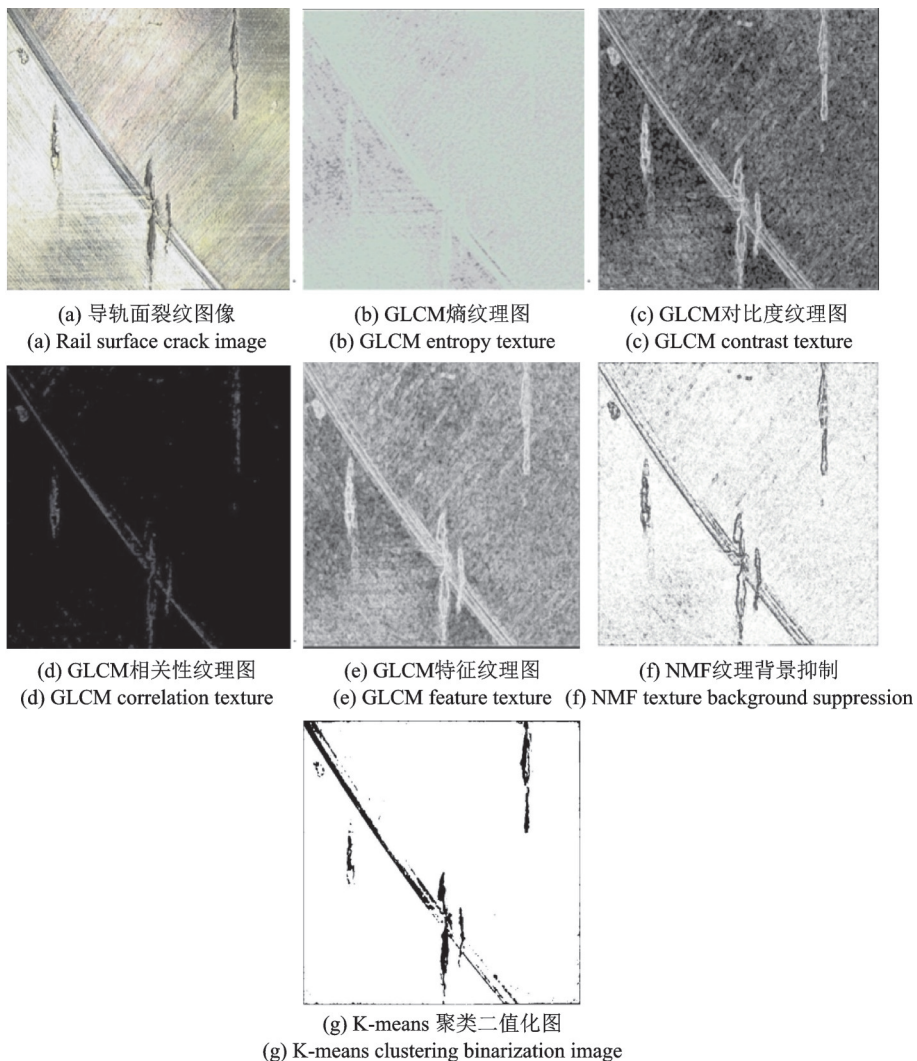


图5 基于GLCM和NMF导轨面缺陷特征增强

Fig.5 Feature enhancement of surface defect based on GLCM and NMF

像素块进行聚类中心初始化;接着分别计算每个像素块与聚类中心的欧氏距离,并将该像素块划分为距离聚类中心较小的一类;然后将聚类中心更新为已有分类的质心,重复上述步骤直到更新后的质心与上一个质心的距离保持不变时结束迭代;最后,将聚类后的两类向量进行均值二值化处理得到直线导轨面的缺陷二值图像。

### 3.2 缺陷识别与分类

为说明本文所提方法的有效性,采用常用的 Sobel 和 Canny 边缘提取算子对样本图 5(a)中的缺陷进行提取,结果如图 6 所示,与图 5(g)相比可以得出较传统方法,基于 GLCM 和 NMF 的缺陷特征提取方法能较好地对复杂加工纹理背景起到抑制作用,从而凸显缺陷目标。

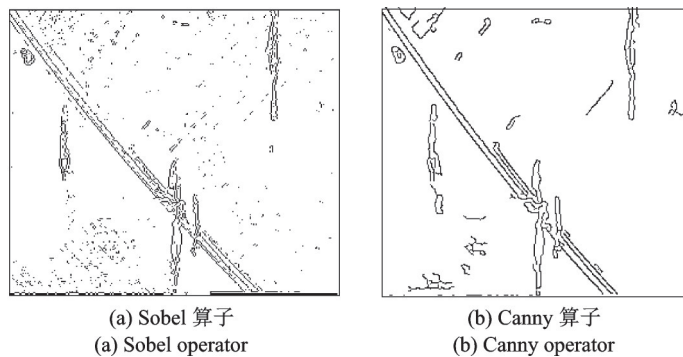


图 6 Sobel 和 Canny 算子缺陷提取

Fig.6 Sobel and Canny defect extraction

为获取充足的实验样本,通过前文对常见直线导轨面缺点的特点分析模拟了一定数量和实际现场采集的缺陷样本大致相同的补充“缺陷样本”,包括正常样本和缺陷样本共计 442 个样本,具体的样本类型及数量如表 1 所示。

分类器选择径向基高斯核函数支持向量机<sup>[17-18]</sup>,核参数  $\gamma$  以步长 0.01 在区间 $[0, 3]$ 上取值,惩罚因子  $C$  取默认值,实验计算基于 Matlab R2017a 软件环境,处理器型号为 Intel(R) Xeon (R) CPU E5-2640 v4 2.40 GHz。

综合分析直线导轨面常见撞伤、划痕和裂纹缺陷特点,同时考虑到过多特征提取造成算法实时性较差,不同特征组合对缺陷分类识别准确性的影响,最终选择了表 2 中的 5 种特征作为分类指标<sup>[19]</sup>。

从样本集中随机选取 3 种缺陷样本计算 5 个特征值,结果如表 3 所示,可以看出不同缺陷的特征区分比较明显。

将实验采集到的图像样本以 1:1 的比例分为训练集和测试集,即奇数号为训练样本,偶数号为测试样本。最终,经过 SVM 训练后的分类结果如表 4 所示,基本实现了缺陷的准确分类,其中对于撞伤类缺

表 1 直线导轨面样本图像的类型与数量

Table 1 Type and quantity of sample image of linear guide surface

类型	撞伤	划痕	裂纹	正常	合计
数量	83	127	52	180	442

表 2 缺陷样本的 5 种特征

Table 2 Five features of defect samples

序号	特征量名称
1	缺陷区域面积 $S$
2	缺陷矩形度 $R_a$
3	缺陷长宽比 $r$
4	不变矩 $M_1$
5	不变矩 $M_2$

陷的识别率达 95.12%，对于裂纹和划痕类缺陷的识别率分别达 88.46% 和 89.06%，经过分析其原因在于划痕和裂纹缺陷特征比较相似，此外由于实验条件限制导致样本数量不足，使分类器得不到足够的训练，但总体上基本完成了对直线导轨面缺陷的识别分类。

表 3 部分样本缺陷特征参数值

样本号	面积 $S$	矩形度 $R_a$	长宽比 $r$	不变矩 $M_1$	不变矩 $M_2$	缺陷类型
8	0.426	0.722	0.380	-0.762	-0.437	裂纹
56	1.000	0.419	0.104	-0.694	-0.557	划痕
89	0.456	0.822	-0.988	-0.909	1.000	撞伤

表 4 SVM 测试样本缺陷分类结果

Table 4 Defect classification results of test sample sets using SVM

缺陷类型	正确识别个数	错误识别个数	总数	正确率/%
划痕	57	8	64	89.06
裂纹	23	3	26	88.46
撞伤	39	2	41	95.12

## 4 结束语

(1) 基于 GLCM 多特征统计量重构直线导轨面纹理图，较传统边缘提取算子提高了直线导轨面缺陷区域和非缺陷区域在复杂加工纹理背景下的对比，保留了缺陷纹理特征信息，并有效增强缺陷区域边界。

(2) 利用 NMF 对 GLCM 导轨面纹理图训练获得基图像后，将其与纹理图遍历后求得的欧氏距离平均值来更新原像素点，使得非缺陷区域纹理得到了抑制，并凸显了缺陷目标特征。

(3) 基于 K-means 聚类算法提取导轨面缺陷二值图像，选取的面积、矩形度、长宽比和不变矩特征对不同缺陷类型进行了准确表征，实验中利用 SVM 对测试集中常见的划痕、裂纹和撞伤的识别准确率分别为 89.06%、88.46% 和 95.12%。

## 参考文献:

- [1] 李聪波, 杜彦斌. 基于 Archard 模型的机床导轨磨损模型及有限元分析[J]. 机械工程学报, 2016, 52(15): 106-113.  
LI Congbo, DU Yanbin. Archard model based machine tool wear model and finite element analysis[J]. Journal of Mechanical Engineering, 2016, 52(15): 106-113.
- [2] 何娇. 基于有限元的机床导轨磨损拟合模型及可靠性研究[D]. 重庆: 重庆大学, 2016.  
HE Jiao. Fitting model of machine tool wear and reliability study based on finite element analysis[D]. Chongqing: Chongqing University, 2016.
- [3] 徐科, 王磊, 王璟瑜. 基于 Tetrolet 变换的热轧钢板表面缺陷识别方法[J]. 机械工程学报, 2016, 52(4): 13-19.  
XU Ke, WANG Lei, WANG Jingyu. Surface defect recognition of hot-rolled steel plates based on Tetrolet transforms[J]. Journal of Mechanical Engineering, 2016, 52(4): 13-19.
- [4] HUANG D, LIAO S, SUNNY A I, et al. A novel automatic surface scratch defect detection for fluid-conveying tube of coriolis mass flow-meter based on 2D-direction filter[J]. Measurement, 2018, 126: 332-341.
- [5] RAO J B, SEVENTLINE J B. Estimation of roughness parameters of a surface using different image enhancement techniques [J]. International Journal of Engineering Transactions B Applications, 2017, 30(5): 652-658.
- [6] HUI Z, JIN X, WU Q M J, et al. Automatic visual detection system of railway surface defects with curvature filter and improved gaussian mixture model[J]. IEEE Transactions on Instrumentation & Measurement, 2018, 99: 1-16.
- [7] 赵君爱, 贾民平. 工件表面微小缺陷的检测与识别方法[J]. 东南大学学报, 2014, 44(4): 735-739.  
ZHAO Junai, JIA Minping. Detection and recognition method of small defects in workpiece surface[J]. Journal of Southeast University, 2014, 44(4): 735-739.
- [8] 宋迪, 张东波, 刘霞. 基于 Gabor 和纹理抑制的手机配件划痕检测[J]. 计算机工程, 2014, 40(9): 1-5.



- SONG Di, ZHANG Dongbo, LIU Xia. Scratch detection for mobile phone accessories based on gabor and texture suppression [J]. Computer Engineering, 2014, 40(9): 1-5.
- [9] 李凡. 复杂背景抑制及弱小目标检测算法研究[D]. 西安:西安电子科技大学, 2010.  
LI Fan. A study of algorithms for complex background suppression and small target detection [D]. Xi'an: Xidian University, 2010.
- [10] SHAKENOV A K. Algorithms of background suppression in the problem of detection of point targets in images [J]. Optoelectronics Instrumentation & Data Processing, 2014, 50(4): 389-394.
- [11] MAK K L, PENG P, YIU K F C. Fabric defect detection using morphological filters[J]. Image & Vision Computing, 2009, 27(10): 1585-1592.
- [12] DUTTA S, PAL S K, SEN R. On-machine tool prediction of flank wear from machined surface images using texture analyses and support vector regression[J]. Precision Engineering, 2016, 43: 34-42.
- [13] 李慧娜, 郭超峰, 平原. 灰度共生矩阵在指纹图像分割中的应用[J]. 数据采集与处理, 2012, 27(1): 63-67.  
LI Huina, GUO Chaofeng, PING Yuan. The application of gray level co-occurrence matrix for fingerprint segmentation[J]. Journal of Data Acquisition & Processing, 2012, 27(1): 63-67.
- [14] GADELMAWLA E S. Estimation of surface roughness for turning operations using image texture features[J]. Proceedings of the Institution of Mechanical Engineers Part B Journal of Engineering Manufacture, 2011, 225(8): 1281-1292.
- [15] 赵蓉, 史红梅. 基于高阶谱特征提取的高速列车车轮擦伤识别算法研究[J]. 机械工程学报, 2017, 53(6): 102-109.  
ZHAO Rong, SHI Hongmei. Research on wheel-flat recognition algorithm for high-speed train based on high-order spectrum feature extraction[J]. Journal of Mechanical Engineering, 2017, 53(6): 102-109.
- [16] 韩素青, 贾茹. 基于稀疏约束非负矩阵分解的K-Means聚类算法[J]. 数据采集与处理, 2017, 32(6): 1216-1222.  
HAN Suqing, JIA Ru. K-means clustering algorithm based on non-negative matrix factorization with sparseness constraints[J]. Journal of Data Acquisition & Processing, 2017, 32(6): 1216-1222.
- [17] BHAT N, DUTTA S, VASHISTH T, et al. Tool condition monitoring by SVM classification of machined surface images in turning[J]. International Journal of Advanced Manufacturing Technology, 2016, 83(9/10/11/12): 1487-1502.
- [18] DUTTA S, PAL S K, SEN R. On-machine tool prediction of flank wear from machined surface images using texture analyses and support vector regression[J]. Precision Engineering, 2016, 43: 34-42.
- [19] DENG X, YE X, FANG J, et al. Surface defects inspection system based on machine vision[C]//Proceedings of International Conference on Electrical and Control Engineering. [S.l.]: IEEE, 2010: 2205-2208.

## 作者简介:



周友行(1971-),男,博士,教授,博士生导师,研究方向:数字化设计与制造、机器人学、制造过程监测与控制的研究, E-mail: zhouyouhang@xtu.edu.cn。



李勇(1993-),男,硕士研究生,研究方向:制造过程监测与控制的研究, E-mail: ly952726@163.com。



孔拓(1991-),男,硕士研究生,研究方向:制造过程监测与控制, E-mail: 308014069@qq.com。



赵晗云(1993-),女,硕士研究生,研究方向:制造系统自动检测与控制, E-mail: 1161449571@qq.com。