

# 基于反向 P-M 扩散的钢轨表面缺陷视觉检测

贺振东<sup>1,2</sup> 王耀南<sup>1</sup> 毛建旭<sup>1</sup> 印峰<sup>1</sup>

**摘要** 研制了一种基于反向 P-M (Perona-Malik) 扩散的钢轨表面缺陷视觉检测装置, 该装置可自动获取钢轨表面图像, 并实现实时检测与定位钢轨表面缺陷. 钢轨图像具有光照变化、反射不均、特征少等特点, 为了在运动过程中从复杂的钢轨表面图像提取缺陷, 首先将图像进行反向 P-M 扩散, 然后将扩散后的图像与原图像进行差分, 从而减小了上述因素的影响, 最后将差分图像进行二值化操作, 根据缺陷边缘特性和面积进行滤波, 分割出缺陷图像. 实验仿真和现场测试结果表明, 该方法能很好地识别块状缺陷和线状缺陷, 并且检测速度、精度、识别率和误检率都能很好地满足要求.

**关键词** 反向 P-M 扩散, 图像差分, 钢轨表面缺陷, 视觉检测

**引用格式** 贺振东, 王耀南, 毛建旭, 印峰. 基于反向 P-M 扩散的钢轨表面缺陷视觉检测. 自动化学报, 2014, 40(8): 1667–1679

**DOI** 10.3724/SP.J.1004.2014.01667

## Research on Inverse P-M Diffusion-based Rail Surface Defect Detection

HE Zhen-Dong<sup>1,2</sup> WANG Yao-Nan<sup>1</sup> MAO Jian-Xu<sup>1</sup> YIN Feng<sup>1</sup>

**Abstract** A vision machine is developed for rail surface defects detection based on the inverse P-M (Perona-Malik) diffusion. The rail surface defects images can be obtained through an image acquisition system. The rail surface images show illumination variation, reflection inequality, and heterogeneous texture, they make the automated visual inspection task extremely difficult. The faultless region of the rail surface image is preserved by an inverse P-M model, but the fault region is smoothed after diffusing by an inverse P-M model. Therefore, by subtracting the inverse diffused image from the original image, the defects can be distinctly enhanced in the difference image. The influence of illumination variation, reflection inequality, and heterogeneous texture can also be decreased. A simple binary thresholding, followed by filter operations based on the edge performance and the size of defects, can then easily segment the defect. The simulation and field experiments indicate that the inspection machine can detect the rail surface defects effectively and the detection speed, accuracy, detection ratio and the fault ratio also satisfy the needs of automated rail track.

**Key words** Inverse P-M (Perona-Malik) diffusion, image difference, rail surface defects, vision detection

**Citation** He Zhen-Dong, Wang Yao-Nan, Mao Jian-Xu, Yin Feng. Research on inverse P-M diffusion-based rail surface defect detection. *Acta Automatica Sinica*, 2014, 40(8): 1667–1679

随着铁路行车速度、密度和载重量的不断提高, 由钢轨表面缺陷引起的断轨事故也在逐年增加<sup>[1–2]</sup>. 因此, 需要对铁路钢轨缺陷进行周期检测. 然而, 采用传统的超声波、脉冲涡流、电磁和人工检测技术已很难适应现代铁路轨道交通对钢轨缺陷检测的要求<sup>[3–4]</sup>. 目前, 采用机器视觉检测技术可以实现对钢轨轮廓、磨损、轨距、擦伤<sup>[5]</sup> 和扣件缺损进行快速自

动检测, 并且可满足最高 320 km/h 行车速度的检测条件要求, 但在进行钢轨表面缺陷检测时, 则要求将行车速度降至 3 km/h ~ 4 km/h<sup>[6]</sup>, 这显然无法满足实际行车检测的需求.

目前, 针对钢轨表面缺陷视觉检测相关的研究文献比较少. 文献 [5] 提出基于滤波特征选择的波纹擦伤视觉检测算法, 该技术目前已应用于铁路视觉实时检测系统. 奥地利数字图像处理研究所开发的机器视觉系统利用光谱图像差分产生三维图像进行钢轨表面缺陷检测, 其图像采集速度可达 60 km/h, 该系统已经应用到钢轨生产线上. 但是, 受光照、振动等因素的影响, 该系统对服役中铁路钢轨的检测效果仍有待验证<sup>[7]</sup>. 中佛罗里达大学计算机视觉实验室针对螺栓检测、扣件丢失、轨枕检测、擦伤和裂纹检测问题, 提出了用于室内环境下的检测算法, 该算法对阈值有较高灵敏性, 易受光照变化、阴影和反射不均的影响, 漏检和误检率较高<sup>[8]</sup>. 北京交通大学

收稿日期 2013-05-07 录用日期 2013-12-20  
Manuscript received May 7, 2013; accepted December 20, 2013  
国家自然科学基金 (60835004, 61072121, 61172160, 61175075), 河南省科技攻关计划 (142102210514) 资助  
Supported by National Natural Science Foundation of China (60835004, 61072121, 61172160, 61175075), and the Key Science and Technology Program of Henan Province (142102210514)  
本文责任编辑 潘泉  
Recommended by Associate Editor PAN Quan  
1. 湖南大学电气与信息工程学院 长沙 410082 2. 郑州轻工业学院电气信息工程学院 郑州 450002  
1. College of Electrical and Information Engineering, Hunan University, Changsha 410082 2. College of Electrical and Information Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002

开发了轨头离散缺陷视觉检测系统,通过引入局部归一化算法,对钢轨图像进行图像增强,以减弱光照变化和反射不均的影响,同时采用投影法对缺陷定位检测<sup>[9]</sup>.该方法的主要问题是只能检测离散的块状缺陷,无法检测线状缺陷(如裂纹、划痕等).

针对表面缺陷检测问题, Xie 对纹理分析技术进行了综述<sup>[10]</sup>,但该技术无法解决钢轨表面缺陷检测问题. Tsai 等<sup>[11-12]</sup>和 Chao 等<sup>[13-17]</sup>对表面缺陷检测问题进行了大量的研究,通过对各向异性扩散模型进行改进,分别实现了对非均匀纹理溅射表面、低对比度玻璃基板及微小缺陷的检测<sup>[11-17]</sup>,但由于光照变化和反射不均的影响和实时性要求,尚不能确定其在钢轨表面缺陷检测中的有效性.在 Mrázek 等<sup>[18]</sup>和 Shih 等<sup>[19]</sup>分析小波与非线性扩散关系的基础上, Yue 等<sup>[20]</sup>综合小波的稀疏和多尺度特性以及非线性扩散的迭代边缘增强特征,提出了非线性多尺度小波扩散算法,用于抑制斑点噪声和边缘增强.刘伟菟等在带钢表面缺陷检测中,针对纹理背景,提出了小波扩散滤波算法:首先将图像进行小波分解,然后对高频分量进行各向异性扩散,最后再进行小波重构,实现在去除图像噪声和纹理背景的同时,较好地保留图像边缘信息<sup>[21]</sup>.但是,由于小波扩散算法顺序进行了小波分解、扩散和小波重构几个步骤,所以它的实时性难以得到保证.同时,由于带钢为一平面,未能考虑光照变化和反射不均的影响.

虽然机器视觉系统已经在铁路连接件、轨枕、扣件缺失检测等领域得到了初步应用,但在钢轨表面缺陷检测领域的应用却非常有限<sup>[22]</sup>,主要原因有:

- 1) 形状不同、方向各异、大小不一的锈迹斑点在钢轨表面会形成非均匀纹理.采用传统的纹理分析算法,难以对钢轨表面缺陷进行准确识别.
- 2) 受不同季节、不同时刻光照的影响,极大增加了钢轨缺陷检测的难度.
- 3) 受钢轨表面形状决定,轨头表面会产生不均匀反射,同样增大了钢轨缺陷检测的难度.
- 4) 缺陷特征信息非常少,只有灰度和梯度信息可用于识别,这会使基于纹理和形状等特征的识别算法失效.
- 5) 由于钢轨表面缺陷检测系统搭载于快速运行的轨检车上,因此要求系统必须具有很高的处理速度.

针对上述问题,本文提出了基于反向扩散差分的钢轨表面缺陷检测方法:首先,将一维线阵图像拼接成二维原图像  $I_0$ ,并对此图像进行反向 P-M 扩散处理,该过程利用钢轨表面图像的灰度和梯度信息调整扩散因子,对具有低灰度值和高梯度值特征的缺陷像素区进行平滑;而具有高灰度值和(或)低梯度值的非缺陷像素区则被保留,经过一定次数的反

向 P-M 扩散处理,可得到扩散图像  $I_t$ ;然后,将图像  $I_0$  与  $I_t$  相减,保留缺陷边缘部分,利用自适应阈值将钢轨缺陷分割出来;最后,通过滤波处理识别出钢轨缺陷.

本文算法以梯度信息为主要特征.钢轨表面图像的梯度信息具有以下两个特征:1)沿钢轨水平方向所得图像梯度值接近于 0;2)沿钢轨垂直方向所得图像灰度值无跃变,即图像梯度值较小.因此,可以忽略反射不均对本文算法的影响.因为钢轨表面图像灰度值随光照变化大致呈线性变化,因此光照变化不会改变所得钢轨表面图像梯度的特性;另外,差分处理可以减少甚至去除光照变化对图像的影响,因而光照变化对算法的影响也可以忽略.污渍和锈迹斑点虽然有一定的梯度,但不同时具有低灰度值和高梯度值信息.因此,反向 P-M 扩散差分算法可以显著增强缺陷区域,而不受复杂非纹理背景、光照变化和反射不均等因素影响,利用简单的二值化方法,即可快速有效地将缺陷从背景中分割出来.

## 1 钢轨表面缺陷视觉检测系统

### 1.1 机械结构

考虑到光照和振动等因素的影响,为了获得高质量钢轨表面图像,我们设计了如图 1 所示的钢轨表面缺陷视觉检测装置,主要包括成像系统和运动机构两大模块.




图 1 钢轨表面缺陷视觉检测装置机械结构图

Fig. 1 Structure of inspection machine for rail surface defects detection

1) 成像系统. 成像系统是本装置的核心模块,主要包括线扫相机、镜头、光源、光源安装角度调节槽、光源安装方式调节架和成像系统调节槽.由于成像质量受光强  $I$ 、曝光时间  $t$ 、入射角度  $\theta$ 、运动速度  $v$ 、采集频率  $f$  和振动等因素的影响,为了得到更好的钢轨表面图像,本文设计的成像系统如图 2 所示.其中,光源控制器用于调节光照强度,光源安装

角度调节槽用于调节光照入射角度, 成像系统调节槽用于模拟和控制系统振动效果. 实验得出上述因素对成像质量的影响规律  $\max Q(I, t, \theta, v, f)$ , 对钢轨表面的图像进行补偿, 从而得到更加清晰的图像.




图 2 成像系统  
Fig. 2 Imaging system

2) 运动机构. 运动机构分为低速平动机构和高速转动机构. 低速平动机构由电机、减速箱、编码器、滚珠丝杠和支撑光杠组成, 用于带动成像系统在钢轨上方做往复运动, 以便于采集钢轨表面图像. 低速平动机构受行程限制, 只能带动相机做低速图像采集. 高速转动机构由电机、编码器和轮盘组成. 轮盘外周表面模拟钢轨表面, 由电机带动做高速旋转运动; 成像系统安置于轮盘正上方, 每一时刻只采集最高处一线图像. 随着圆盘转动, 可得到圆盘外周的整幅图像. 通过高速转动机构可模拟高速运动时的图像采集过程.

### 1.2 电气控制系统

图 3 为钢轨表面缺陷视觉检测系统电气控制系统图, 该系统由工控机和控制器组成. 为了匹配检测车的运行速度和图像采集速度, 保证采集图像的质量, 避免图像被压缩或拉伸, 该系统采用编码器发出的晶体管-晶体管逻辑集成电路脉冲信号触发相机采集钢轨表面图像. 通过采集脉冲数可得到检测车运行速度, 而每帧图像的位置信息可以通过航迹推算得到, 该位置信息可用于缺陷定位分析. 工控机的主要工作包括: 1) 运行检测软件; 2) 完成图像分析和缺陷分类; 3) 将缺陷数据存储在磁盘阵列. 工作人员可以通过网络, 对视觉检测装置工作状态进行监视.

## 2 钢轨表面缺陷检测算法

### 2.1 钢轨表面缺陷分析

钢轨表面缺陷类型多样, 大体可分为线状缺陷

和块状缺陷两类. 其中, 裂纹缺陷比较细长, 类似于线条, 长宽比较大, 属于线状缺陷; 块状缺陷类似于圆形, 长宽比不大, 如砸伤、剥落和波纹擦伤等, 如图 4 所示.

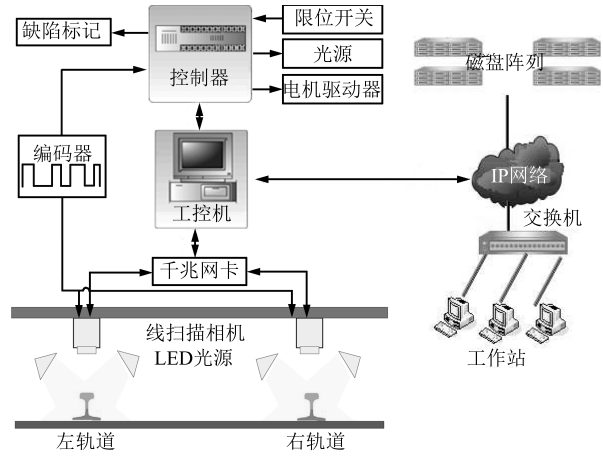


图 3 钢轨表面缺陷视觉检测电气控制系统  
Fig. 3 Electrical control system of inspection machine for rail surface defects detection




图 4 典型钢轨表面缺陷类型  
Fig. 4 Types of rail surface defects

图 5 (a1) 为一段表面有疤痕缺陷和污渍的钢轨图像, 沿钢轨方向画有两条线, 实线 A1 通过无缺陷区域, 虚线 A2 通过缺陷区域. 垂直于钢轨方向, 实线 B1 通过非缺陷区域, 虚线 B2 通过缺陷区域. 图 5 (a2)~(a5) 分别为 4 条线所通过图像区域的灰度值变化曲线图. 从图中可以看出, 当沿钢轨方向无缺陷时, 灰度值变化很小; 当存在缺陷或垂直于钢轨方向时, 灰度值变化较大. 图 5 (b2)~(b5) 分别是图 5 (a2)~(a5) 对应的梯度值变化曲线图, 虽然图 5 (a2) 和图 5 (a3) 污渍处 (横坐标 400~500 处) 灰度值有一定变化, 但是从对应的梯度图来看, 污渍处的梯度值较小, 可以说明: 沿钢轨方向无缺陷时, 其梯度值较小; 而垂直于钢轨方向虽然因钢轨弧面

影响, 灰度值变化较大, 但其梯度值较小, 只有缺陷边缘具有很高的梯度值. 综上所述, 缺陷区域的图像同时具有低灰度值和高梯度值的特征; 而非缺陷区域 (除钢轨边缘部分外), 不同时具备上述两个特征.

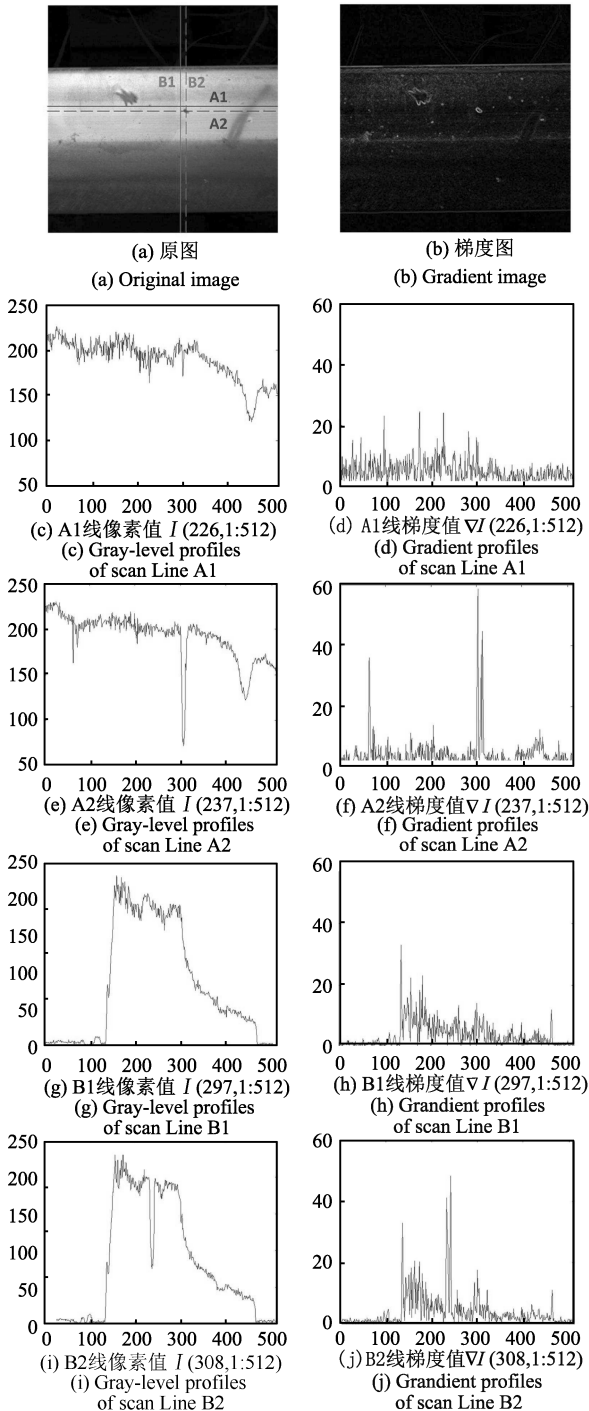


图5 钢轨表面纵横轮廓线及梯度

Fig. 5 Transverse and longitudinal contour lines and their gradient of rail surface

## 2.2 钢轨表面缺陷检测算法描述

本文提出的基于反向 P-M 扩散的检测算法处理流程如图 6 所示. 首先, 将采集的线状图像进行拼接, 得到二维原图像; 然后, 对二维原图像作反向 P-M 扩散处理, 将扩散后的图像与原图像差分, 利用自适应阈值对差分图像进行二值化处理; 最后, 通过滤波和形态学处理确定钢轨表面缺陷.

### 1) 线阵图像拼接

线扫描相机与物体之间必须做相对运动, 才能将多条线图像组成面图像, 而线扫相机的拍摄频率会影响拍摄的图像效果. 如图 7 所示, 当线扫相机拍摄频率与物体之间的移动速度匹配时, 线扫相机可拍摄出与物体形状一致的图像; 当相对移动速度高于相机本身的拍摄频率时, 拍摄出来的图像将被压缩; 反之, 获取到的图像将被拉伸.

为了得到保真图像, 解决相机拍摄频率和相机与钢轨之间的移动速度的匹配问题, 本文设计了两种方案: 1) 硬件方案, 将相机设置为外部触发模式, 利用编码器发出的晶体管-晶体管逻辑集成电路电平信号, 触发相机采集, 通过实验得到编码器脉冲数与相机采集频率之间的比例关系, 使之匹配; 2) 软件方案, 将相机设置为内部触发模式, 固定相机的采集频率, 通过计算机读取编码器信息, 根据编码器反馈的速度快慢抽取对应的线图像进行拼接, 以保证获得保真图像. 方案 1) 直接采用硬件连接, 具有速度快、可靠性高的特点; 方案 2) 速度较慢, 但读取到的编码器信息可用于航迹推算, 便于钢轨缺陷位置信息的获取和定位, 本文采用方案 1). 钢轨图像位置信息采用 GPS 或通过读取相机采集频率计算编码器脉冲数, 从而推算出位置信息, 拼接后效果如图 8 所示.

### 2) 反向 P-M 扩散

扩散是一种不改变原有物质成分浓度平衡过程<sup>[23-24]</sup>, 用于描述扩散的数学模型在图像分割、边缘检测、去噪、复原等技术领域得到了广泛的应用<sup>[25-29]</sup>.

#### a) P-M 扩散模型

Peron 等结合图像先验知识, 引入了扩散因子, 提出了著名的 P-M 扩散模型<sup>[30]</sup>:

$$\begin{cases} \frac{\partial I}{\partial t}(x, y, t) = \nabla(c(x, y, t)\nabla I), t > 0 \\ I(x, y, 0) = I_0(x, y), t = 0 \end{cases} \quad (1)$$

其中,  $(x, y) \in \mathbf{R}^2$ ,  $I(x, y, t)$  为  $t$  时刻的图像,  $I_0$  为原始图像,  $\nabla$  为梯度算子,  $c$  为非线性扩散因子, 如下所示:





图 6 基于扩散差分的缺陷检测算法框图

Fig. 6 Flow chart of defect detection algorithm based on diffusion-difference

$$c(\nabla I) = \frac{1}{1 + \left(\frac{\nabla I}{K}\right)^2} \quad (2)$$

上式为一单调递减函数, 其值由局部梯度值决定, 当  $\nabla I \rightarrow 0$  时,  $c \rightarrow 1$ , 图像被平滑; 当  $\nabla I \rightarrow \infty$  时,  $c \rightarrow 0$ , 图像被保持. 因此, 可以在扩散的同时保持目标边界.



(a) 频率适中 (b) 频率过低 (c) 频率过高  
(a) Moderate frequency (b) Low frequency (c) High frequency

图 7 相机采集频率与运动速度关系图

Fig. 7 Relation of camera capture frequency and movement speed




图 8 图像拼接

Fig. 8 Image stitching

### b) 反向 P-M 扩散

为了更好地分割出缺陷区域, 首先对图像进行平滑处理后, 再与原图像进行差分. 为了尽可能地凸显缺陷区域, 应保留图像的非缺陷区域, 而仅对缺陷区域进行平滑处理, 这一过程与 P-M 扩散过程相逆, 因而记为反向 P-M 扩散.

传统的 P-M 扩散模型只利用单一的梯度信息, 受钢轨图像中污渍、阴影等梯度值的影响, 此时无法有效区分缺陷和污渍等干扰因素. 为此, 本文根据钢轨缺陷的特点, 以灰度值和梯度值为变量, 设计了反

向 P-M 扩散因子, 即

$$g(\nabla I, f) = \frac{1}{1 + f \left(\frac{K}{\nabla I}\right)^2} \quad (3)$$

为了避免灰度值对扩散因子单独起决定作用, 将  $f$  作归一化处理, 即令  $f = I_0/255$ . 其中,  $\nabla I(x, y)$  为在  $(x, y)$  处的梯度,  $K$  为正则化因子. 当  $\nabla I \rightarrow 0$  时,  $g \rightarrow 0$ , 图像保持不变; 当  $\nabla I \rightarrow \infty$  时,  $g \rightarrow 1$ , 图像被平滑. 反向扩散过程与式 (1) 相同, 仅将扩散因子  $c$  用反向扩散因子  $g$  替代. 其离散化形式为:

$$I(x, y, t+1) = I(x, y, t) + \lambda \sum_i g_i(x, y, t) \nabla I_i(x, y, t) \quad (4)$$

其中,  $i = N, S, E, W$ ,  $I(x, y, t)$  为第  $t$  次扩散时在坐标  $(x, y)$  处的图像灰度值,  $t = 1, 2, \dots, T$ ,

$$\nabla I_N(x, y, t) = I(x-1, y, t) - I(x, y, t)$$

$$\nabla I_S(x, y, t) = I(x+1, y, t) - I(x, y, t)$$

$$\nabla I_E(x, y, t) = I(x, y+1, t) - I(x, y, t)$$

$$\nabla I_W(x, y, t) = I(x, y-1, t) - I(x, y, t)$$

$$\nabla g_i(\nabla I_i, f) = \frac{1}{1 + f \left(\frac{K}{\nabla I_i}\right)^2}, i = N, S, E, W$$

为了保证该方法的稳定性, 取  $0 \leq \lambda \leq 1/4$ <sup>[14]</sup>.

根据式 (3), 反向扩散因子大小与  $\nabla I$  成正比, 与  $f$  成反比. 因此, 当  $\nabla I$  增大或  $f$  减小时, 反向扩散因子都将增大. 由于缺陷部分同时具有低灰度值和高梯度值的特征, 因此得到的反向扩散因子更大. 图 9 说明了  $g$  与  $\nabla I$  和  $f$  的关系. 从图 9 可以看出, 当  $\nabla I$  增大  $f$  减小时,  $g$  迅速增大. 因此, 缺陷区域被迅速平滑. 而低灰度值、低梯度值的非钢轨区域像素和高灰度值、高梯度值的阴影和污渍区域像素与缺陷区域像素相比, 产生的反向扩散因子较小, 平滑效果较弱, 因此可以将缺陷与非缺陷区域分割开.






图 9 反向扩散系数与  $\nabla I$  和  $f$  关系图

Fig. 9 Plot of the inverse diffusion coefficient  $g(\nabla I, f)$  as a function of gray-level  $f$  and gradient  $\nabla I$

对图 10 (a) 拼接图像进行反向 P-M 扩散, 得到图 10 (b) 的结果. 图 10 (c) 为原图像和扩散后图像第 267 行的灰度值,  $I_0$  为原图像像素值,  $I_t$  为反向 P-M 扩散后的图像像素值. 为了便于比较, 对图 10 (c) 横坐标 330~410 处进行局部放大, 如图 10 (d) 所示. 由图 10 (c) 和 (d) 与原图对比可知, 经反向 P-M 扩散处理后, 缺陷边缘的扩散程度很高, 而对于非缺陷区域的扩散程度基本为 0. 因此将二者作差时, 可以将缺陷区域突显出来.



(a) 原图像 (a) Original image  
(b) 扩散后图像 (b) Image after diffusion



(c) 原图与扩散图像第 267 行的灰度值 (c) Gray-level profile of the 267<sup>th</sup> line of original image and diffusion image  
(d) 图 10 (c) 的局部放大 (d) Enlargement of a segment of Fig. 10 (c)

图 10 经反向 P-M 扩散后结果及与原图的比较

Fig. 10 Image after diffusion and comparison between original image and diffusion image

3) 图像差分与二值化处理

记  $I_0$  为拼接图像,  $I_t$  为反向扩散得到的图像. 将拼接图像与反向扩散后的图像的差定义为差分图像, 即

$$\Delta I(x, y) = |I_0(x, y) - I_t(x, y)|, \forall(x, y) \quad (5)$$


为了在差分图像中分割出缺陷区域, 定义阈值:

$$th = \mu_{\Delta I} + C\delta_{\Delta I} \quad (6)$$

其中,  $\mu_{\Delta I}$  和  $\delta_{\Delta I}$  分别为差分图像  $\Delta I(x, y)$  的平均值和标准差, 控制因子  $C$  为常数. 在差分图像中, 如果  $\Delta I(x, y) > th$ , 则像素点  $(x, y)$  为缺陷点, 标记为 1; 反之, 则为非缺陷点, 标记为 0. 二值化后的图像可用下式表示:

$$B(x, y) = \begin{cases} 1, & \Delta I(x, y) > th \\ 0, & \text{否则} \end{cases} \quad (7)$$

图 10 (a) 和 (b) 的差分图像及其二值化图像如图 11 所示. 从图 11 (b) 可以看出, 缺陷区域可以从二值化图像中较好的分割出来. 但是, 二值化图像中存在大量的噪声, 影响缺陷的识别.



(a) 差分图像 (a) Difference image  
(b) 二值化图像 (b) Binary image

图 11 差分图像和二值化图像

Fig. 11 Difference image and binary image

4) 图像滤波

为了去除二值化图像中的噪声点, 本文提出了基于缺陷边缘特性和缺陷面积大小的图像滤波算法.

记  $(x, y)$  为  $3 \times 3$  窗口的中心,  $(x + i, y + j)$ ,  $i, j \in \{-1, 0, 1\}$  为其 8 个邻域. 在二值化图像  $B(x, y)$  中缺陷点标记为 1, 非缺陷点标记为 0. 在任意一个  $3 \times 3$  窗口中, 当缺陷点的个数  $\geq 3$  时, 记中心点  $(x, y)$  为边缘; 否则,  $(x, y)$  为噪声点, 即

$$BW(x, y) = \begin{cases} 1, & \sum_{i,j \in \{-1,0,1\}} B(x+i, y+j) \geq 3 \\ 0, & \text{否则} \end{cases} \quad (8)$$

由于只需要在标记为 1 的像素点进行去噪声处理, 因此可以保证算法的实时性. 为了检测出 1 mm

宽的缺陷, 需要在 1 mm 宽度区域上的像素点数超过 5 个, 考虑边缘斜坡效应, 取 16 个像素点为阈值, 区域面积大于此阈值的, 即为缺陷; 小于此阈值的, 则为噪声点. 图 12 是对图 11 (b) 去噪声后的结果. 由图 12 与图 11 (b) 相对比可知, 图像滤波能有效滤除图像中的孤立噪声, 进而检测出缺陷.




图 12 滤波后的缺陷图像

Fig. 12 Defects image after filtering

### 3 实验及参数分析

为了验证算法的有效性, 本文在实验环境和现场环境下分别对线状缺陷和块状缺陷进行了检测实验, 实验环境如图 13 所示. 图 13 (a) 为实验室低速平动平台, 图 13 (b) 为实验室手推车平台, 图 13 (c) 为现场手推车实验.



(a) 实验室低速平动平台  
(a) Low-velocity translational platform



(b) 实验室手推车平台  
(b) Inspection system cart  
(c) 现场手推车实验  
(c) Field experiment

图 13 实验室及现场实验

Fig. 13 Lab and field experiment

实验所用计算机为 3GHz 处理器的 PC 机, 对采集的 100 幅  $512 \times 512$  含 655 个大于  $1 \text{ mm} \times 1 \text{ mm}$  块状缺陷的钢轨表面图像和 10 幅含 12 个裂纹的钢轨表面图像进行了识别, 平均识别速度分别达到 86 ms 和 80 ms, 识别率分别为 95.4% 和 91.7%, 误检率分别为 3.2% 和 0%, 如表 1 所示.

表 1 钢轨表面缺陷检测性能指标

Table 1 Performance indexes of rail surface defects detection

缺陷类型	总个数	识别个数	误检个数	识别率 (%)	误检率 (%)	识别速度 (ms)
块状	655	625	21	95.4	3.2	86
线状	12	11	0	91.7	0	80

#### 3.1 参数分析

为了有效快速识别出钢轨表面缺陷, 在扩散模型中, 参数  $K$  和  $T$  的设置至关重要. 在二值化过程中, 控制因子  $C$  的选择, 会直接影响缺陷的识别.

##### 1) 参数 $K$ 的影响

从式 (3) 可以看出,  $K$  值越大, 反向扩散因子越小, 图像被保持, 扩散图像与原图像差分时, 难以将缺陷分割出来. 图 14 为  $K=1, 4, 30$  和 100 时, 钢轨表面缺陷分割情况. 其中, 扩散次数  $T=3$ , 二值化分割系数  $C=3$ . 图 14 (a1) 为无缺陷图像, 图 14 (a2) 为块状缺陷图像, 图 14 (a3) 为线状缺陷图像. 图 14 (b1)~(b3)、(c1)~(c3)、(d1)~(d3) 和 (e1)~(e3) 分别为  $K=1, 4, 30$  和 100 时的识别结果. 从图中可以看出,  $K$  值的变化对识别结果影响不大. 当  $K$  值较大时 (如  $K=100$ ), 反向扩散因子较小, 扩散不充分, 因此使识别结果的边缘出现断裂现象; 而当  $K$  值较小时 (如  $K=1$  和 4), 识别结果基本一致. 图 14 (a1) 的识别结果为黑色, 说明没有缺陷或缺陷面积小于  $1 \text{ mm}^2$ .

为了更好地说明  $K$  值对识别结果的影响, 随机在图 14 (a) 中选取三个点, 三个点所处的位置为边缘梯度较大处  $dI_1$ 、边缘梯度中等处  $dI_2$  和非边缘处  $dI_3$ . 当  $K$  在  $1 \sim 255$  变化时, 三次扩散后的图像与原图像在上述三个点处的差值见图 15 (a). 由于  $K$  值的不同,  $\Delta I$  也不同, 二值化分割时阈值的选取与差分图像的均值和方差有关, 所以不同的  $K$  值也对应不同的阈值, 为了有效地看出  $K$  值对阈值分割的影响, 将图 15 (a) 归一化, 归一化结果见图 15 (b). 从图 15 (b) 可以看出, 边缘梯度较大处  $dI_1$  被分割为缺陷, 而非边缘处  $dI_3$  则被分割为背景. 但是边缘梯度中等处  $dI_2$  当  $K$  值较小时, 容易被分割为缺陷; 而当  $K$  值较大时, 则被分割为背景. 因此可以说明当  $K$  值大时, 边缘容易断裂.

##### 2) 扩散次数 $T$ 的影响

因为基于扩散模型的缺陷识别算法的计算时间主要体现在扩散次数上, 所以从算法的实时性出发, 扩散次数越少越好, 因此  $T$  的上限由实际缺陷检测时间决定. 图 16 为不同  $T$  值时, 钢轨表面缺陷识别效果图, 此组图像与图 14 所用图像相同, 图 16 (a1)~(a3) 为钢轨表面原图像,




图 14 不同  $K$  值时, 钢轨表面缺陷识别效果图 (从左至右依次为: 原图像、 $K=1$ 、4、30、100 时的识别图像)  
 Fig. 14 Effect of changes in regularization value  $K$  (From left to right: original image and detected images with  $K=1, 4, 30, 100$ )




图 15  $K$  的变化对差分图像的影响  
 Fig. 15 Difference image in different  $K$




图 16 不同  $T$  值时, 钢轨表面缺陷识别效果图 (从左至右依次为: 原图像、 $T=1$ 、3、9、30 时的识别图像)  
 Fig. 16 Effect of changes in the number of diffusion iterations  $T$  (From left to right: original image and detected images with  $T=1, 3, 9, 30$ )

图 16 (b1)~(b3)、(c1)~(c3)、(d1)~(d3) 和 (e1)~(e3) 分别为  $T=1$ 、3、9 和 30 时的检测结果. 从图 16 可以看出,  $T$  值太小, 扩散不够充分, 边界容易断裂, 如图 16(b3) 所示; 而  $T$  值越大, 边界越完整, 但计算时间也相应增大. 因此, 取  $T=3$  可以很好地平衡边界完整性和计算时间之间的关系.

为了更好地说明  $T$  值对识别结果的影响, 随机在图 16(a) 图像中选取三个点(同图 15 取的三个点), 当  $T$  在 1~30 变化时, 三个点处原图与扩散  $T$  次后的图像之间的差值如图 17 所示. 从图中可以看出, 随着  $T$  值的增加,  $dI_3$  处变化缓慢, 而  $\Delta I$  在  $dI_1$  和  $dI_2$  两处之间的差值是先增大后减小, 在  $T=3$  和 4 处最大. 随着  $T$  的继续增大, 两处的差值基本为 0, 从而使得弱边缘  $dI_2$  处被分割为缺陷, 更好地保持了边缘的完整性. 但是  $T$  值的增大使计算时间大幅度增加, 影响算法的实时性. 综合上述因素, 取  $T=3$  既能保持边缘的完整性, 又能满足实时性的要求.




图 17  $T$  值的变化对差分图像的影响  
Fig. 17 Difference image in different  $T$

### 3) 控制因子 $C$ 对阈值分割的影响

式 (6) 中控制因子  $C$  为图像二值化时控制阈值选取的重要参数.  $C$  值越大, 则阈值越大, 易使缺陷边界断裂; 反之,  $C$  值越小, 则阈值越小, 易产生噪声. 因此,  $C$  的取值对抑制噪声和保证缺陷的完整性是非常重要的.

切比雪夫不等式给出了数据集中数据与平均值和标准差之间的关系. 在任何数据集中, 比平均值超过  $C$  倍标准差的数据所占比例至多是  $1/C^2$ .  $C$  值越大, 超过  $C$  倍标准差的数据所占的比例则越小. 在二值化后的图像中表现为缺陷图像容易断裂; 反之, 在图像中表现为噪声多. 按照缺陷部分占整幅图像 10% 左右的比例计算, 当  $C=3$  时, 可更好地抑制噪声, 并保证缺陷的完整性.

## 3.2 实验结果

图 18 为面阵相机拍摄的现役钢轨表面图像, 该图像可以分为三个区域, 中间最亮的 A 处为与轮对

直接接触的部分, 最为平滑而且没有锈迹; B 处为少量锈迹和污渍的部分; C 处为钢轨外缘完全生锈的部分. 本文实验中所用图像是从上述钢轨采集的表面图像.




图 18 钢轨表面图像及区域说明

Fig. 18 Image of rail surface and different regions

本文针对光照变化、阴影、污渍、锈迹和反射不均等因素对算法的影响进行了实验, 其中参数  $K=4$ ,  $T=3$  和  $C=3$ , 实验结果如图 19 所示. 从左至右依次为原图像、反向 P-M 扩散图像、差分图像、二值化图像和滤波图像.

### 实验 1. 光照变化的影响

图 19(a1) 和 (a2) 分别为光照强弱图像. 随着光照的变化, 整个钢轨表面光照同时增强或减弱, 缺陷与非缺陷区域的差别基本不变. 而且, 由于二值化阈值随着光照增强而增大, 采用对差分图像进行二值化后再进行分割识别, 将使光照变化的影响变得更小, 因此, 光照变化对缺陷识别结果基本没有影响, 如图 19(e1) 和 (e2) 所示.

### 实验 2. 阴影的影响

图 19(a3) 和 (a4) 分别为有无阴影图像. 从图 19(a3) 可以看出, 虽然阴影与光亮部分像素值有差别, 但是像素值变化缓慢, 即梯度值小. 而且相对于缺陷来说, 阴影像素值较大, 因此阴影不同时具有高梯度值和低像素值的特征, 所以经扩散后与原图差分使得缺陷凸显出来, 故阴影对识别结果影响不大, 如图 19(e3) 和 (e4) 所示.

### 实验 3. 污渍、锈迹的影响

图 19(a5) 和 (a6) 分别为含污渍图像. 从图 19(a5) 和 (a6) 可以看出, 虽然污渍处灰度有变化, 但是变化比较平缓, 所以梯度值较小, 对识别结果影响也较小. 但是如果存在白色或黑色等污渍时, 由于其与周边区域梯度值增大, 对结果会产生一定的影响, 如图 19(a5) 中钢轨锈迹处的白灰. 从图 19(e1)~(e6) 可以看出, 锈迹对识别结果没有影响.

### 实验 4. 反射不均的影响

由图 18 可知, 钢轨表面 A、B、C 区域的反射率是不同的; 同理可知, 实验中所有图像也受反射不




图 19 在光照变化、阴影、污渍、锈迹和反射不均等情况下的钢轨缺陷识别结果图

Fig. 19 Defects detection results in different environment of illumination variation, shadow, stain, rust and reflection inequality

均的影响。但是，从对图 5(b2)~(b5) 的分析可知，钢轨表面图像具有沿钢轨水平方向梯度值接近于 0 和沿钢轨垂直方向梯度值较小的特点，因此由反射不均引起的梯度值较小，扩散较弱，所以反射不均对缺陷识别基本没有影响。

### 3.3 与其他方法的比较

为了进一步说明本文算法的有效性，针对光照变化、反射不均、阴影、污渍和锈迹对检测效果的影响，将本文所提反向 P-M 扩散算法与基于局部归一化和缺陷映射定位的离散表面缺陷检测算法 (Local normalization-defect localization based on projection profile, LN-DLBP)<sup>[19]</sup> 和小波扩散算法 (Wavelet diffusion, WD)<sup>[22]</sup> 进行了对比，结果如图 20 所示。其中，WD 算法中迭代次数取 3，边缘

检测算子为 Sobel 算子。LN-DLBP 算法中，局部归一化窗口取沿钢轨方向线状窗口，缺陷比例因子  $dp = 0.1$ ，滤波面积取 40 个像素点。

由于 LN-DLBP 算法对图像进行了局部归一化处理，因此减少了光照变化及反射不均对检测结果的影响，从图 20 第 4 列可以看出，图 18 中 A、B、C 区域没有明显的分界线。但是灰度值低的污渍、阴影、锈迹等受算法中按缺陷比例滤波的影响都保留了下来，对缺陷检测造成了干扰，降低了识别的成功率。同时，该算法对小缺陷和线状缺陷无法识别。

小波扩散算法虽然对噪声有很强的抑制作用，但是由于阴影和反射不均等因素影响，小波扩散后直接进行边缘检测并未得到理想的结果 (如图 20 第 3 列所示)。图 20 (c3) 和 (c4) 阴影的存在造成了检测结果的差异很大。图 20 (c4)~(c7) 中 A、B 区域

间有明显的分界线, 因此该算法易受反射不均的影响, 对不同的反射率不具有适应性. 同时, 由于小波扩散算法需要顺序进行小波分解、高频分量扩散、小波重构等过程, 其计算耗时比本文算法多.

为了客观地说明本文算法的有效性, 我们从识别率、误检率和识别速度三个性能指标对本文算法、LN-DLBP 和 WD 三种算法进行了对比, 结

果如表 2 所示. 从表 2 可以看出, 识别速度本文算法和 LN-DLBP 算法相当, 为 WD 算法的 4 倍多. 本文算法的识别率最高, 误检率也较低. LN-DLBP 算法识别率和误检率较低的原因是本文所选样本中缺陷的面积较小, 大部分小于  $80\text{mm}^2$ , 而  $80\text{mm}^2$  为 LN-DLBP 算法<sup>[9]</sup> 中缺陷最小可识别面积.

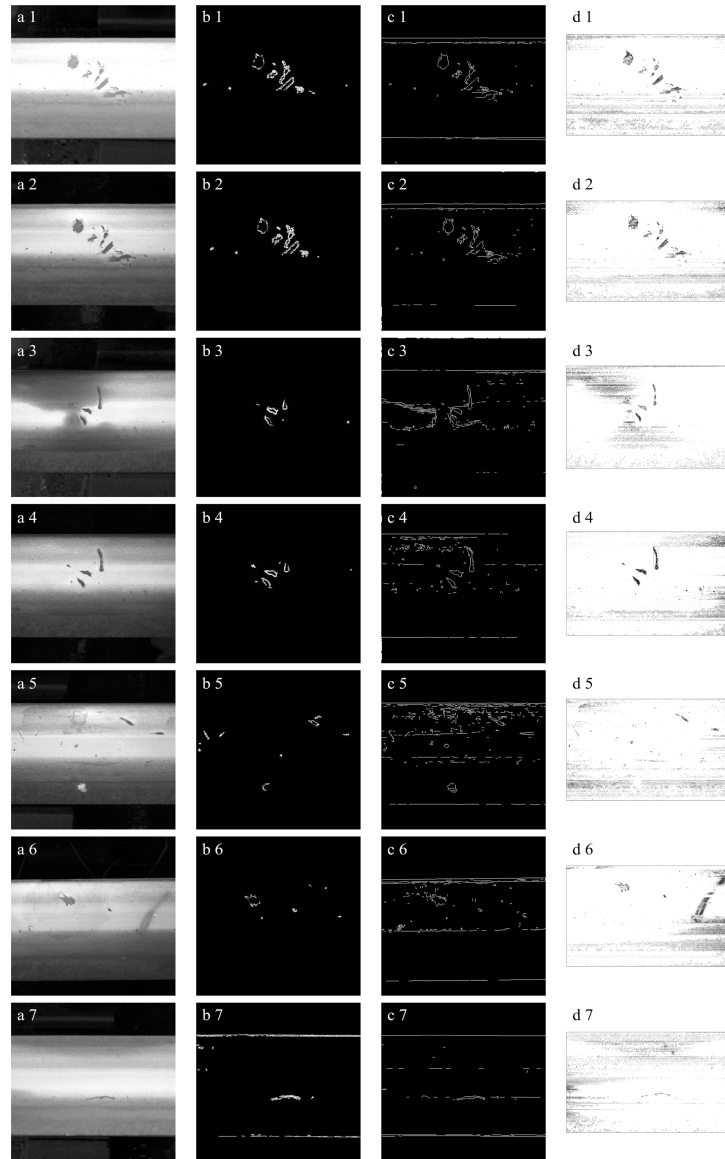


图 20 本文算法与其他算法比较 (从左至右依次为: 原图像、本文算法所得图像、WD 所得图像、LN-DLBP 所得图像)

Fig. 20 Comparison with other algorithms (From left to right: original image, image by proposed algorithm, image by WD, image by LN-DLBP)

表 2 3 种钢轨表面缺陷检测算法性能指标对比

Table 2 Comparison of the performance indexes of three rail surface defects detection algorithms

缺陷总数	识别个数			误检个数			识别率 (%)			误检率 (%)			识别速度 (ms)		
	本文算法	LN-DLBP	WD	本文算法	LN-DLBP	WD	本文算法	LN-DLBP	WD	本文算法	LN-DLBP	WD	本文算法	LN-DLBP	WD
491	460	52	359	16	9	37	93.7	10.6	73.1	3.26	1.83	7.53	85	83	372

## 4 结论


本文通过分析钢轨表面缺陷的特征, 根据动态采集的要求, 设计了基于反向 P-M 扩散的钢轨表面缺陷视觉检测装置. 深入研究了在图像获取过程中采集频率与行车速度之间的匹配关系, 完成了图像保真拼接. 根据缺陷同时具有低灰度值和高梯度值的特征, 设计了反向 P-M 扩散因子. 对图像进行反向 P-M 扩散后, 与原图像进行差分操作, 减小了光照变化、反射不均、阴影和污渍等环境因素对图像处理的影响. 提出了基于边缘特征和缺陷面积的滤波算法, 去除噪声点对缺陷识别的干扰. 分别对块状缺陷和线状缺陷进行了识别, 平均识别速度分别达到了每帧 86 ms 和 80 ms, 识别率分别为 95.4% 和 91.7%, 误检率分别为 3.2% 和 0%, 实现了钢轨缺陷在线高精度检测.

由于参数  $K$ 、 $T$  和  $C$  对识别结果有着重要的影响, 本文虽然给出了参数的选择原则, 但是参数的自适应选择是值得深入研究的问题. 从识别结果可以看出, 缺陷边缘存在空洞和断裂, 如何消除空洞和断裂, 保证边缘的完整性也是我们即将开展的工作.

## References

- Jasiūnienė E, Žukauskas E. The ultrasonic wave interaction with porosity defects in welded rail head. *ULTRAGARSAS (ULTRASOUND)*, 2010, **65**(1): 12–18
- Vidaud M, Zwanenburg W J. Current situation on rolling contact fatigue—a rail wear phenomenon. In: Proceedings of the 9th Swiss Transport Research Conference. Monte Verità, Swiss, 2009. 1–27
- Marino F, Distante A, Mazzeo P L, Stella E. A real-time visual inspection system for railway maintenance: automatic hexagonal-headed bolts. *IEEE Transactions on Systems Man, and Cybernetics, Part C: Applications and Reviews*, 2007, **37**(3): 418–428
- Mandriota C, Stella E, Nitti M, Ancona N, Distante A. Rail corrugation detection by Gabor filtering. In: Proceedings of IEEE International Conference on Image Processing. Thessaloniki: IEEE, 2001. 626–628
- Mandriota C, Nitti M, Ancona N, Stella E, Distante A. Filter-based feature selection for rail defect detection. *Machine Vision and Applications*, 2004, **15**(4): 179–185
- Papaelias M P, Roberts C, Davis C L. A review on non-destructive evaluation of rails: state-of-the-art and future development. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and rapid transit*, 2008, **222**(4): 367–384
- Deutschl E, Gasser C, Niel A, Werschonig J. Defect detection on rail surfaces by a vision based system. In: Proceedings of IEEE Intelligent Vehicles Symposium. Parma, Italy: IEEE, 2004. 507–511
- Shah M. Automated Visual Inspection/Detection of Railroad Track, Technical Report, BD550-08, Computer Vision Lab, University of Central Florida, USA, 2010
- Li Q Y, Ren S W. A real-time visual inspection system for discrete surface defects of rail heads. *IEEE Transactions on Instrumentation and Measurement*, 2012, **61**(8): 2189–2199
- Xie X H. A review of recent advances in surface defect detection using texture analysis techniques. *Electronic Letters on Computer Vision and Image Analysis*, 2008, **7**(3): 1–22
- Tsai D M, Chao S M. An anisotropic diffusion-based defect detection for sputtered surfaces with inhomogeneous textures. *Image Vision Computing*, 2005, **23**(3): 325–338
- Tsai D M, Chang C C, Chao S M. Micro-crack inspection in heterogeneously textured solar wafers using anisotropic diffusion. *Image Vision Computing*, 2010, **28**(3): 491–501
- Chao S M, Tsai D M. An anisotropic diffusion-based defect detection for low-contrast glass substrates. *Image Vision Computing*, 2008, **26**(2): 187–200
- Chao S M, Tsai D M. Anisotropic diffusion with generalized diffusion coefficient function for defect detection in low-contrast surface images. *Pattern Recognition*, 2010, **43**: 1917–1931
- Chao S M, Tsai D M. An improved anisotropic diffusion model for detail and edge-preserving smoothing. *Pattern Recognition*, 2010, **31**(13): 2012–2023
- Chao S M, Tsai D M, Tseng Y H, Jhang Y R. Defect detection in low-contrast glass substrates using anisotropic diffusion. In: Proceedings of the 18th International Conference on Pattern Recognition. Hong Kong, China: IEEE, 2006. 654–657
- Chao S M, Tsai D M, Li W C, Chiu W Y. A generalized anisotropic diffusion for defect detection in low-contrast surfaces. In: Proceedings of the 20th International Conference on Pattern Recognition. Istanbul, Turkey: IEEE, 2010. 4408–4411
- Mrázek P, Weickert J, Steidl G. Correspondences between wavelet shrinkage and nonlinear diffusion. *Lecture Notes in Computer Science*, 2003, **2695**: 101–116
- Shih A C, Liao H M, Lu C S. A new iterated two-band diffusion equation-theory and its application. *IEEE Transactions on Image Processing*, 2003, **12**(4): 466–476
- Yue Y, Croitoru M M, Bidani A, Zwischenberger J B, Clark J W Jr. Nonlinear multiscale wavelet diffusion for speckle suppression and edge enhancement in ultrasound images. *IEEE Transactions on Medical Imaging*, 2006, **25**(3): 297–311
- Liu Wei-Wei, Yan Yun-Hui, Li Zhan-Yu, Li Jun. An image filtering algorithm for online detection system of steel strip surface defects. *Journal of Northeastern University: Natural Science*, 2009, **30**(3): 430–433  
(刘伟鬼, 颜云辉, 李瞻宇, 李骏. 带钢表面缺陷在线检测系统的图像滤波算法. 东北大学学报: 自然科学版, 2009, **30**(3): 430–433)
- Magel E E. Rolling Contact Fatigue: a Comprehensive Review, Technical Report, DTR53-05-H-00203, Centre for Surface Technology, Ottawa, Canada, 2011
- Weickert J. *Anisotropic Diffusion in Image Processing*. Stuttgart: Teubner-Verlag, 1998

- 24 Li Xiao-Guang, Shen Lan-Sun, Lam Kin-Man, Wang Su-Yu. An image magnification method with GVF-based anisotropic diffusion model. *Acta Electronica Sinica*, 2008, **36**(9): 1755–1758  
(李晓光, 沈兰荪, Lam Kin-Man, 王素玉. 一种基于 GVF 各向异性扩散模型的图像放大算法. 电子学报, 2008, **36**(9): 1755–1758)
- 25 Meng Xiang-Lin, Wang Zheng-Zhi. Image diffusion based on visual masking effect. *Acta Automatica Sinica*, 2011, **37**(1): 21–27  
(孟祥林, 王正志. 基于视觉掩蔽效应的图像扩散. 自动化学报, 2011, **37**(1): 21–27)
- 26 Li Can-Fei, Wang Yao-Nan, Xiao Chang-Yan, Lu Xiao. A new speckle reducing anisotropic diffusion for ultrasonic speckle. *Acta Automatica Sinica*, 2012, **38**(3): 412–419  
(李灿飞, 王耀南, 肖昌炎, 卢笑. 用于超声斑点噪声滤波的各向异性扩散新模型. 自动化学报, 2012, **38**(3): 412–419)
- 27 Zheng Qiang, Dong En-Qing. Narrow band active contour model for local segmentation of medical and texture images. *Acta Automatica Sinica*, 2013, **39**(1): 21–30  
(郑强, 董恩清. 窄带主动轮廓模型及在医学和纹理图像局部分割中的应用. 自动化学报, 2013, **39**(1): 21–30)
- 28 Wang Zhi-Ming, Zhang Li. Local-structure-adapted image diffusion. *Acta Automatica Sinica*, 2009, **35**(3): 244–250  
(王志明, 张丽. 局部结构自适应的图像扩散. 自动化学报, 2009, **35**(3): 244–250)
- 29 Cheng Jian-Gang, Tian Jie, He Yu-Liang, Yang Xin. Fingerprint enhancement algorithm based on nonlinear diffusion filter. *Acta Automatica Sinica*, 2004, **30**(6): 854–862  
(程建刚, 田捷, 何余良, 杨鑫. 基于非线性扩散滤波的指纹增强算法. 自动化学报, 2004, **30**(6): 854–862)
- 30 Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, **12**(7): 629–639



贺振东 湖南大学电气与信息工程学院博士研究生, 郑州轻工业学院讲师. 主要研究方向为图像处理和智能机器人. 本文通信作者.  
E-mail: hezhendong\_itl@163.com  
(**HE Zhen-Dong** Ph.D. candidate at the College of Electrical and Information Engineering, Hunan University,

and also lecturer of Zhengzhou University of Light Industry. His research interest covers image processing and intelligent robotics. Corresponding author of this paper.)



王耀南 湖南大学电气与信息工程学院教授. 1994 年获湖南大学控制科学与工程专业博士学位. 主要研究方向为智能控制, 图像处理和智能机器人.  
E-mail: yaonan@hnu.cn  
(**WANG Yao-Nan** Professor at the College of Electrical and Information Engineering, Hunan University. He received his Ph.D. degree from Hunan University in 1994. His research interest covers intelligent control, intelligent image processing and intelligent robotics.)



毛建旭 湖南大学电气与信息工程学院副教授. 1993 年获南昌大学学士学位, 1999 年获东华理工大学硕士学位, 2003 年获湖南大学控制理论与控制工程专业博士学位. 主要研究方向为计算机视觉, 图像处理与模式识别.  
E-mail: maojianxu@hnu.edu.cn  
(**MAO Jian-Xu** Associate professor at the College of Electrical and Information Engineering, Hunan University. He received his bachelor degree from Nanchang University in 1993, master degrees from East China Institute of Technology in 1999, and the Ph.D. degree from Hunan University in 2003. His research interest covers computer vision, image processing and pattern recognition.)



印峰 博士, 湘潭大学电子与通信工程系讲师. 主要研究方向为智能计算理论及应用. E-mail: yinfeng83@126.com  
(**YIN Feng** Ph.D., lecturer at the College of Electronics and Communication Engineering, Xiangtan University. His research interest covers intelligent computing theories and applications.)