DOI: 10.13382/j.jemi.B2205334

基于可调证明滤波器的球团矿生球图像裂缝检测方法*

周淑伊 刘小燕 陈玉如 孙浠汉
(湖南大学电气与信息工程学院 长沙 410082)

摘 要:球团矿生球制造是炼钢工业中的重要环节,而裂缝检测是生球质量指标(落下强度)检测中的关键步骤。目前生球裂缝检测仍采用人工目测,效率低且检测结果具有主观性,而现有的基于图像处理的裂缝自动检测方法主要针对桥梁、道路、太阳能电池等物体的平直表面上的裂缝,对生球这种小目标曲面上的裂缝检测能力有限,且难以克服生球图像中原材料污渍、生球边缘轮廓、球面反光等多种噪声的干扰,易造成裂缝的误检与漏检。针对这一问题,提出一种基于可调证明滤波器(SEF)的球团矿生球图像裂缝检测方法。首先,针对图像背景中存在的原材料污渍与碎屑干扰,采用主动轮廓模型从图像中分割出感兴趣区域(AOI);然后,针对生球边缘轮廓和球面反光造成的干扰,采用可调证明滤波器生成生球裂缝响应图,实现 AOI 图像粗分割;接着,利用形态学处理与连通域分析法消除粗分割图像中的生球边缘及噪声点,获得精确的分割结果;最后,采用连通域分析法检测生球是否存在裂缝,并计算出裂缝条数。为验证所提出的方法,搭建了生球图像实验采集平台,采集了约 300 张具有不同背景和裂缝数量的生球图像。实验结果表明,与现有的 5 种裂缝检测方法相比,本文方法在裂缝分割准确率、精确率、加权调和平均评价指标上均具有明显优势,检测生球是否存在裂缝的准确率为 96%,检测裂缝数量的准确率为 90%。本文研究成果为生球落下强度质量指标的自动化、智能化检测奠定了基础。

关键词:裂缝检测;裂缝分割;可调证明滤波器;球团矿生球。
中图分类号:TN911.73;TP391.41 **文献标识码**:A **国家标准学科分类代码**:510

Crack detection for iron ore green pellet image based on steerable evidence filter

Zhou Shuyi Liu Xiaoyan Chen Yuru Sun Xihan
(College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: Manufacturing of iron ore green pellet is a significant step in metallurgy industry. Crack detection for green pellet is a key step in the measuring process of the important pellet quality metric (drop strength). However, current image-based methods are mainly used to detect cracks on the flat surface of bridges, roads and solar cells. Therefore, their crack detection ability is limited on pellet with curved surface, and is easily affected by the raw material stains, pellet edge contour, strong light reflection or other interferences in pellet images, resulting in the false detection or missed detention. To solve the problem, a crack detection method for green pellet based on steerable evidence filter (SEF) is proposed. Firstly, the target area of green pellet is segmented by the active contour model, which is used to eliminate the raw material stains in the image background. In order to overcome the interfaces of pellet edge contour and strong light reflection, steerable evidence filter is used to generate the response map of pellet crack, followed by the morphological processing and connected domain analysis method used to eliminate the pellet edge response and noise in response map of pellet crack, so that more accurate crack segmentation results can be obtained. Finally, the connectivity domain method is used to detect cracks and calculate the number of cracks. In order to verify the proposed method, experimental platform was built to establish dataset of green pellet, and about 300 green pellet images with different backgrounds and the number of cracks were captured. Results show that our method outperforms five crack detection methods in crack segmentation metrics including accuracy, precious, F1. Accuracy of detecting cracks in pellet is 96%, and the accuracy of detecting the number of cracks is 90%. The crack detection results lay a foundation for the automatic and intelligent detection of drop strength quality metric of green pellet.

Keywords: crack detection; crack segmentation; steerable evidence filter; iron ore green pellet

收稿日期:2022-03-31 Received Date:2022-03-31
*基金项目:国家自然科学基金(61973108)、湖南省科技计划(2020GK2025)项目资助

0 引　言

球团矿生球制造是炼钢工业中的重要环节,其制造过程如下:将铁精粉、粘稠剂、膨润土等原材料加水混合后送入高速旋转的圆盘造球机,原材料随着圆盘的转动逐渐滚粘成大球,并在离心力的作用下从圆盘下料口排出并形成生球。在生球制造过程中通常需要对生球的质量进行监测,以保证最终产品质量和生产效率的稳定[1-2]。落下强度是生球的重要质量指标之一,反映了生球在转运、堆积过程中承受挤压能力的强弱,需严格控制在一定范围内。目前,生球落下强度的测量仍采用人工检测法,即,操作工人手持生球样品将其高到一定高度(0.5 m),然后松手使生球砸落到钢板上,针对同一颗生球反复进行多次"抬高-落下"过程,直至肉眼观察到生球表面出现裂缝。生球出现裂缝前的下落次数,就是该生球的落下强度。这种人工检测法具有主观性强、可对比性差、效率低等缺点,易造成测量结果不准确,且缺乏对裂缝的量化分析,不利于生球制造过程的优化控制。

在生球落下强度自动测量方面,虽然现有的研究工作通过设计自动化装置代替人手,实现了生球的自动抬高和下落。但是,生球下掷后的裂缝检测关键环节仍采用肉眼观察方式,智能化程度较低。因此,本文采用工业相机代替人眼获取生球图像,然后采用图像处理算法自动检测出生球裂缝,并计算出生球裂缝的数量,为实现落下强度这一生球质量指标的自动测量奠定基础,具有较高的理论研究意义与应用价值。

目前,基于图像的裂缝检测方法可分为如下3种:

1)基于空间域的裂缝检测方法[3-9]。基于空间域的裂缝检测方法根据裂缝与图像背景之间像素强度值的差异来检测裂缝。Su 等[3]提出了一种形态学方法来检测道路裂缝,该方法通过构建具有不同角度的线性掩膜对图像进行开操作来增强裂缝特征,然后采用自动阈值分割法和连通域偏心度法检测道路裂缝。Sun 等[4]提出了加权邻域法对道路裂缝进行检测,通过对比道路图像中整体灰度值和局部灰度值之间的差异给每个像素点赋予权重值,再根据权重值大小对图像进行阈值分割从而检测出裂缝。然而,这类方法易受图像阴影和污渍等噪声的影响,鲁棒性较低,仅能检测出简单背景下的裂缝。

2)基于光谱域的裂缝检测法[10-11]。基于光谱域的裂缝检测法通常采用时频变换法,通过获得图像的频域信息来检测出裂缝。Zalama 等[10]提出了一种利用 Gabor 滤波器检测道路裂缝的方法,该方法首先对图像进灰度值校正来消除图像阴影对裂缝检测的影响,然后采用 Gabor 滤波器对道路中的纵向和横向裂缝进行检测;Li 等[11]采用傅里叶变换对太阳能电池的裂缝图像进行重建,然后通过评估原始裂缝图像和重建图像之间的灰度差异对裂缝进行检测。然而,这类方法同样对图像背景的要求较高,只适用于光照均匀且噪声干扰较少的单一背景,难以在复杂背景环境中正确检测出裂缝。

3)基于深度学习的裂缝检测法[12-15]。近年来,基于深度学习的裂缝检测法被广泛应用于桥梁、道路和建筑物等场景,这类方法需要对大量图像进行手动标注,然后将标注好的图像输入深度网络中进行训练,通过将待测图像输入训练好的深度网络中实现裂缝检测。基于深度学习的裂缝检测法能够自动提取裂缝特征,具有较强的鲁棒性。但是,这种方法需要标注大量的数据集用于网络训练,且需调节的网络参数较多,模型训练耗时较长。

根据文献调研可知,目前的裂缝检测方法主要针对于桥梁、道路、建筑物、太阳能电池等物体的平直表面上的裂缝,还没有针对生球这种小目标曲面裂缝检测的相关研究报导。而现有的裂缝检测方法不能直接应用于生球裂缝检测,这是因为:

1)与桥梁和路面图像不同,生球粒径尺寸较小,表面轮廓与裂缝外形类似,对检测造成干扰。

2)不同生球的粒径和密度不同,因此生球下落后产生的裂缝在长度、宽度、形态、数量上都存在较大差异。此外,有些生球表面凹凸不平,光照后导致图像中存在局部阴影。这些复杂因素易造成裂缝漏检或者误检,使得裂缝检测算法的准确率降低。

3)生球含水量较高,表面潮湿,成像过程中导致球面反光现象,给图像分割带来困难。

4)潮湿的生球在多次落下后,不可避免地在钢板上留下污渍和碎屑,造成图像背景复杂多变,对裂缝检测算法的鲁棒性提出较高要求。

可调证明滤波器(steerable evidence filtering, SEF)是由 Chen 等[16]于2019年为解决太阳能电池裂缝检测问题而提出的一种裂缝检测算法。与目前常用的裂缝检测算法相比,SEF 能够有效检测出复杂背景下的裂缝,具有较高的鲁棒性。因此,本文针对生球图像特点,提出一种基于可调证明滤波器的生球裂缝检测方法,为生球落下强度质量指标的自动化、智能化检测奠定基础。

本文的主要内容如下:首先,搭建图像采集平台,建立包含不同复杂背景的生球图像数据集,用于对本文所提裂缝检测方法进行评估测试;然后,提出一种基于可调证明滤波器的生球裂缝检测方法,实现复杂背景下生球裂缝的准确检测;最后,将所提方法在生球图像数据集上进行测试,并与其他裂缝检测方法进行性能对比分析。

1 生球图像数据集

目前,国内外学者公开了一些裂缝图像数据集[17-19]

用于测试不同的裂缝检测算法。但是这些数据集中主要是桥梁、道路、混凝土的裂缝图像,目前还没有针对生球裂缝的相关数据集。因此,本文搭建生球图像采集实验平台,获得复杂背景下具有多种裂缝类型的生球图像,用于对本文生球裂缝检测方法进行研究与实验验证。

生球图像采集实验平台如图 1 所示,由工业相机、LED 光源、厚度为 10 mm 的钢板组成。其中,工业相机采用德国 Baumer 公司生产的 VLG-02 M 相机(分辨率 400×400),所选用的生球是从本地钢铁厂采集而来的生球样品。本文实验中,生球下落过程与落下强度检测过程一致,只不过用相机代替人眼获取生球落下后的图像。具体步骤如下:1)固定相机位置并调整相机参数;2)选取一颗生球样品,将其抬高至钢板上方 0.5 m 高处,然后掷落到钢板上;3)相机采集掷落后的生球图像;4)重复步骤 2)~3)直到生球出现裂缝。

本文选取了约 200 个生球样品进行实验,建立了生球图像数据集,包括 197 张有裂缝的生球图像和 100 张无裂缝的生球图像,如图 2 所示。本文数据集具有以下

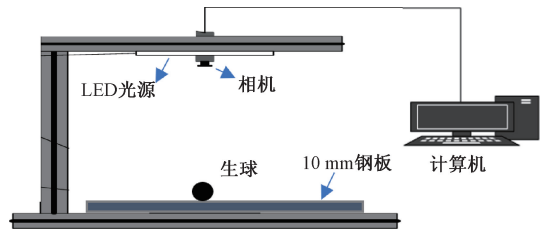

图 1　生球图像采集平台

Fig. 1　Platform of green pellet image acquisition

特点:1)采集到的生球裂缝在数量、长度、宽度、形态上具有较大差异,包括了长裂缝、短裂缝、宽裂缝、细裂缝等多种类型的裂缝;2)生球图像背景复杂,存在原材料碎屑、污渍、水渍等干扰(见图 2 中#2、#3、#7)。此外,生球图像中还存在局部阴影(见图 2 中#1);3)生球表面凹凸不平(见图 2 中#6),这些突起或内凹的区域易对裂缝检测算法造成干扰。本文生球数据集较为完备,包含了复杂背景及多种裂缝类型,对生球裂缝检测算法提出了挑战。

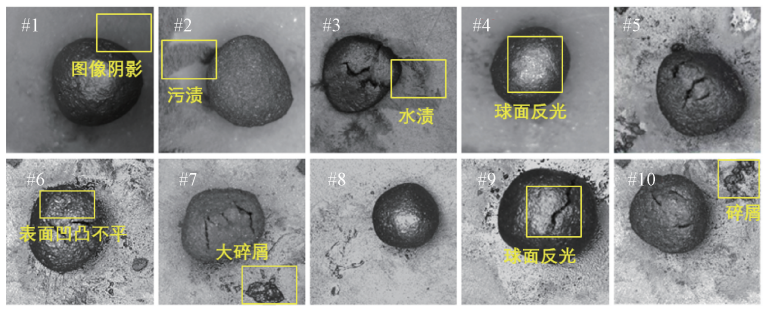

图 2　生球图像数据集示例

Fig. 2　Example of green pellet dataset

2　本文方法流程与原理

本文方法的总体流程如图 3 所示。首先,采用中值滤波与双边滤波对输入的生球图像进行预处理,以去除图像中的噪声,同时保留生球裂缝的特征。然后,通过求解主动轮廓模型能量函数的最小值提取出目标生球区域,从而消除复杂背景中原料污渍、碎屑或其他噪声对裂缝检测算法的干扰。针对生球边缘轮廓和球面反光造成的干扰问题,采用可调证明滤波器来获取生球裂缝响应图,再利用形态学处理与连通域分析法消除生球裂缝响应图中的边缘响应和噪声,实现生球裂缝的准确分割。最后,采用连通域分析法检测出生球表面是否存在裂缝并计算出裂缝条数。

2.1　生球图像预处理

由于采集到的生球图像中存在椒盐噪声干扰,有必要对生球图像进行预处理,从而提高后续生球裂缝分割的准确率。为去除生球图像中的噪声并保留图中裂缝特征,本文采用中值滤波与双边滤波对生球图像进行预处理。

对于一副生球图像 I,首先采用中值滤波对其进行平滑去噪:

$$I_M = Med_{\Omega}(I) \tag{1}$$

其中,Med 为中值滤波器,Ω 为窗口大小为 7×7 的模板。然后,对中值滤波后的图像 I_M 进行双边滤波,经过预处理后的图像 I_B 为:

$$I_B = \frac{1}{W_p}\sum_{q\in S} G_{\sigma_s}(\|p-q\|)G_{\sigma_r}(|I_M(p)-I_M(q)|)I_M(p) \tag{2}$$

其中,p 和 q 表示像素点在图像中的位置,S 代表空间域,$\|\cdot\|$ 为欧氏距离算子,G_{σ} 为高斯核函数,σ_s 和 σ_r 是用于控制滤波的程度的两个参数。W_p 是归一化

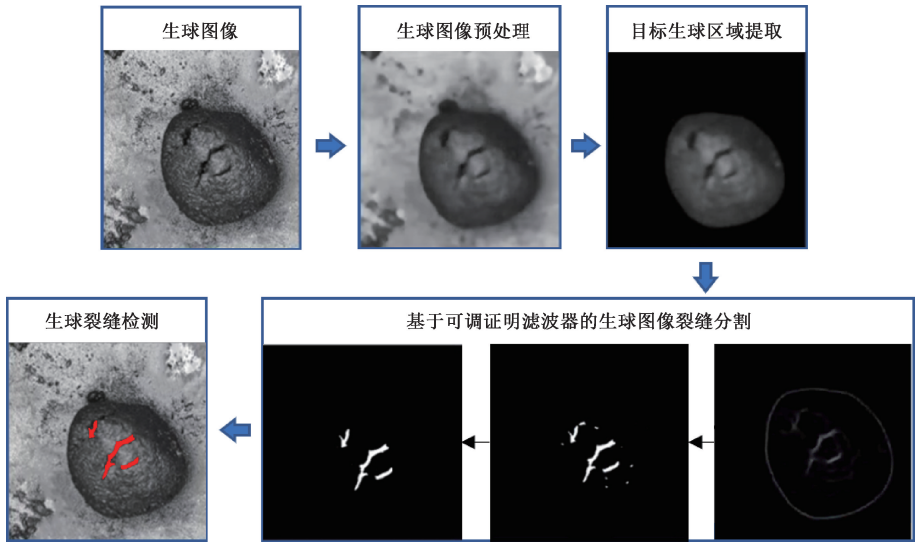

图 3　本文方法的总体流程

Fig. 3　Flowchart of our method

常数：

$$W_p = \sum_{q \in S} G_{\sigma_x}(\| p - q \|) G_{\sigma_r}(| I_p - I_q |) \quad (3)$$

生球图像预处理后的结果如图 4 所示，与原始图像相比，预处理后的生球图像中大部分椒盐噪声被消除，同时生球图像中的裂缝特征被很好的保留，有利于后续的生球裂缝分割。

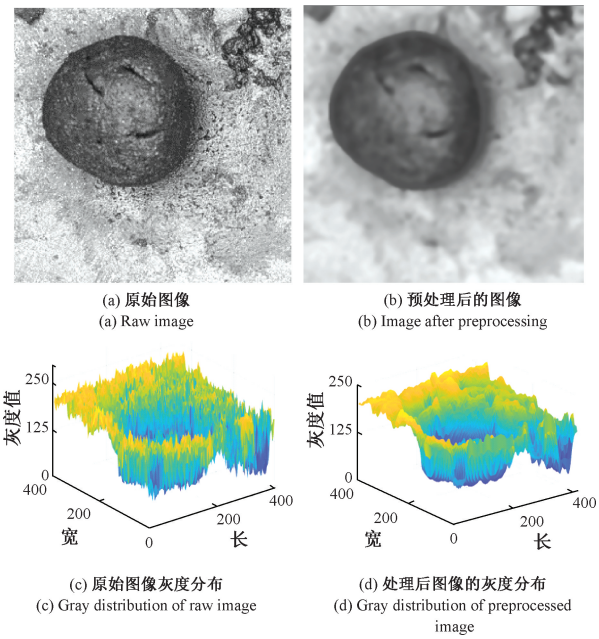

(a) 原始图像
(a) Raw image

(b) 预处理后的图像
(b) Image after preprocessing

(c) 原始图像灰度分布
(c) Gray distribution of raw image

(d) 处理后图像的灰度分布
(d) Gray distribution of preprocessed image

图 4　滤波后的生球图像

Fig. 4　Results of filtering for green pellet image

2.2　目标生球区域提取

由于生球是由铁精粉、膨润土、水等材料混合制成，在生球落下强度检测过程中易在钢板上留下原料污渍或水渍，导致采集到的生球图像背景复杂多变。因此，有必要将目标生球从背景中分割出来，从而消除生球图中复杂背景对裂缝检测算法的影响。主动轮廓模型是一种常用的图像分割方法[20]，具有良好的鲁棒性。因此，本文采用主动轮廓模型方法提出目标生球区域（area of interest，AOI）。

主动轮廓模型的基本原理如下：给定一条封闭的轮廓曲线，通过构造与轮廓曲线相关的能量函数，将图像分割问题转换成求解最小化能量函数的问题。在求解函数最小值的过程中，轮廓曲线逐渐向目标区域的边缘逼近，直至模型求解完成即可根据轮廓曲线提取出目标区域。对于生球图像，将其最大内接圆设定成初始轮廓曲线 $v(s)$：

$$v(s) = (x(s), y(s)) \quad (4)$$

其中，s 表示曲线上点的位置，取值范围为 $s \in [0,1]$。与轮廓曲线相关的能量函数表达式为：

$$E(s) = \int_0^1 E_{\text{int}}(s) + E_{ext}(s)\,\mathrm{d}s \quad (5)$$

其中，$E_{\text{int}}(s)$ 表示内部能量，$E_{ext}(s)$ 表示图像能量。内部能量 $E_{\text{int}}(s)$ 为：

$$E_{\text{int}}(s) = \frac{1}{2}\alpha(s) | v'(s) |^2 + \beta(s) | v''(s) |^2 \quad (6)$$

其中，$\alpha(s)$ 和 $\beta(s)$ 分别为弹性系数和刚性系数，$v'(s)$ 为一阶导数用于保证轮廓曲线的连续性，$v''(s)$ 为二阶导数用于保证轮廓曲线的平滑性。

图像能量 $E_{ext}(s)$ 为：

$$E_{ext}(s) = -| \nabla I_B(v(s)) |^2 \quad (7)$$

其中，∇ 表示图像梯度算子，通过求取图像梯度来控

制轮廓曲线向梯度较大的区域逼近。将式(5)~(6)代入式(3),得到主动轮廓模型能量函数:

$$E(s)=\int_0^1[\alpha\mid v'(s)\mid^2+\beta\mid v''(s)\mid^2]\mathrm{d}s-\int_0^1\mid\nabla I_B(v(s))\mid\mathrm{d}s \tag{8}$$

接着,通过采用梯度下降法[21]求解最小化主动轮廓模型能量函数:

$$v_0(s)=\mathrm{argmin}_sE(s) \tag{9}$$

即可得到目标轮廓曲线。图 5 为目标生球区域提取的结果,图 5(a)中的曲线为目标轮廓曲线。可以看出,主动轮廓模型方法能够克服图像背景中污渍的干扰,将生球图像分割成目标生球区域与背景区域两个部分,准确提取出目标生球。

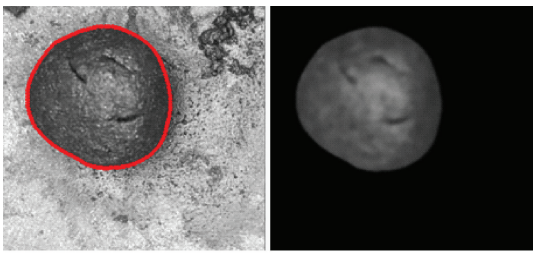

(a) 目标轮廓曲线　(b) 目标生球区域

(a) Target contour curve　(b) Target area of green pellet

图 5　目标生球区域提取结果

Fig. 5　Extraction result of target area of green pellet

2.3　基于可调证明滤波器的生球裂缝分割

由于生球图像中存在边缘轮廓和球面反光的干扰,再加上生球表面凹凸不平造成图像中存在阴影,使得生球裂缝分割具有挑战性。为克服上述干扰并准确分割出生球裂缝,本文采用基于可调证明滤波器的方法(SEF)对生球裂缝进行分割。主要步骤包括 1)采用 SEF 方法生成生球裂缝响应图,获得裂缝初步分割结果;2)采用形态学处理与连通域分析方法,消除生球边缘响应并剔除噪声点,获得裂缝的精确分割结果。

1)生球裂缝响应图的生成

可调证明滤波器是由基本可调滤波器 $e_0(p_0)$ 与两个具有一定偏移量的方向滤波器 $e_1(p_1)$ 和 $e_2(p_2)$ 组合而成的滤波器:

$$E(p_0)=e_0(p_0)+e_1(p_1)+e_2(p_2) \tag{10}$$

其中,基本可调滤波器 $e_0(p_0)$ 用于描述图像中某点 $p_0(x_0,y_0)$ 在方向 $u_\theta=(\cos\theta,\sin\theta)^{\mathrm{T}}$ 上的曲率,其表达式为:

$$e(p_0)=G_{xx}\cos^2\theta+G_{yy}\sin^2\theta+G_{xy}\sin2\theta \tag{11}$$

式中:θ 为空间偏移角度,G_{xx},G_{xy},G_{yy} 为不同的高斯核函数:

$$G_{xx}(p_0)=\frac{(x_0^2-\sigma^2)}{\sqrt{2\pi}\sigma^5}\exp\left(-\frac{x_0^2+y_0^2}{2\sigma^2}\right) \tag{12}$$

$$G_{xy}(p_0)=\frac{x_0y_0}{\sqrt{2\pi}\sigma^5}\exp\left(-\frac{x_0^2+y_0^2}{2\sigma^2}\right) \tag{13}$$

$$G_{yy}(p_0)=\frac{(y_0^2-\sigma^2)}{\sqrt{2\pi}\sigma^5}\exp\left(-\frac{x_0^2+y_0^2}{2\sigma^2}\right) \tag{14}$$

其中,σ 为高斯核标准差。

由于基本可调滤波器未考虑检测点周围的局部信息,难以检测出多类型的裂缝。因此,可调证明滤波器在基本可调滤波器的基础上引入两个附加的定向滤波器 $e_1(p_1)$ 和 $e_2(p_2)$,使检测点在角度和空间距离上的具有一定偏移,从而增加滤波器的检测范围。两个附加的定向滤波器的具体表示为:

$$e_1(p_1)=G_{xx}\cos^2(\theta+\varphi)+G_{yy}\sin^2(\theta+\varphi)+G_{xy}\sin2(\theta+\varphi) \tag{15}$$

$$e_2(p_2)=G_{xx}\cos^2(\theta+\varphi)+G_{yy}\sin^2(\theta+\varphi)+G_{xy}\sin2(\theta+\varphi) \tag{16}$$

其中,p_1、p_2 为附加点:

$$p_1=[x-d\cos(\theta+\varphi),y+d\cos(\theta+\varphi)] \tag{17}$$

$$p_2=[x+d\cos(\theta+\varphi),y-d\cos(\theta+\varphi)] \tag{18}$$

式中:φ 为附加点空间偏移角度,d 为空间偏移距离。

图 6 所示为可调证明滤波器的检测区域示意图。图 6 中检测点 p_0 的坐标为(1,1),空间偏移距离 $d=1$,偏移角度 $\theta\in[-\pi/2,\pi/2]$,$\varphi\in[-\pi/6,\pi/6]$。可以看到附加点构成了一个半径为 d 的局部搜索区域,使得滤波器能够对检测点附近的整个圆形区域进行裂缝检测。

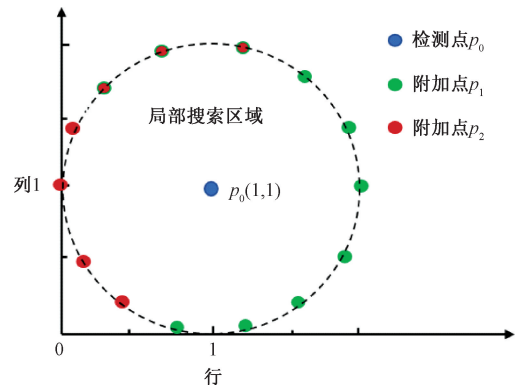

图 6　可调证明滤波器检测区域示意图

Fig. 6　Diagram of detection area of steerable evidence filtering

相较于单一的基本可调滤波器,可调证明滤波器扩大了检测范围,更加适用于检测具有复杂背景的生球裂缝。本文将空间偏移距离 d 值设置为 1 用于生球裂缝检测,其取值的合理性将在后续的 3.3 节中进行讨论。

最后,将目标生球图像与具有不同空间偏移角度的可调证明滤波器进行滤波处理,取其大响应即可生成生

球裂缝响应图：

$$R = \max_{\theta,\varphi}(E(p_0) * I_{roi}) \tag{19}$$

其中，I_{roi} 表示目标生球区域，* 表示卷积操作。

2）生球边缘响应与噪声点的去除

由于生球边缘轮廓与球面反光的影响，导致获得的生球裂缝响应图中包括生球边缘响应及噪声点。因此，本文采用形态学处理方法用于去除生球边缘响应，接着采用连通域分析法消除裂缝响应图中的噪声点，从而得到更加精确的生球裂缝分割结果，具体步骤如下：

1）生球边缘响应的去除。首先，采用大津法对生球裂缝响应图进行自动阈值分割，获得裂缝及边缘轮廓更加清晰的生球裂缝显著图 $R1$。然后利用 2.2 节获得的目标轮廓曲线生成生球区域掩膜 M，并对 M 进行腐蚀操作，用于消除 M 中的生球边缘轮廓区域。将腐蚀后的生球区域掩膜和生球裂缝显著图 $R1$ 进行与操作，得到无边缘响应的生球裂缝显著图 $R2$：

$$R2(i,j) = \min_B M(i,j) \& R1(i,j) \tag{20}$$

其中，i,j 为图中像素点的位置，$\min_B M(i,j)$ 表示对 M 进行腐蚀操作，B 是大小为 3×3 的正方形模板，& 表示与操作。

2）噪声点的去除。由于生球裂缝所占据的像素点较多，而噪声点的像素个数相对较少。因此，本文对生球裂缝显著图 $R2$ 中所有连通域的像素点个数进行统计，然后设定一个阈值 P，若连通域中像素点的个数小于 P，则将该连通域判定为噪声点并剔除该连通域。本文将 P 的取值设定成 35 用于满足生球裂缝分割，最终得到精确的生球裂缝分割结果。图 7 所示为采用基于可调证明滤波器方法分割生球裂缝的中间过程示例图。

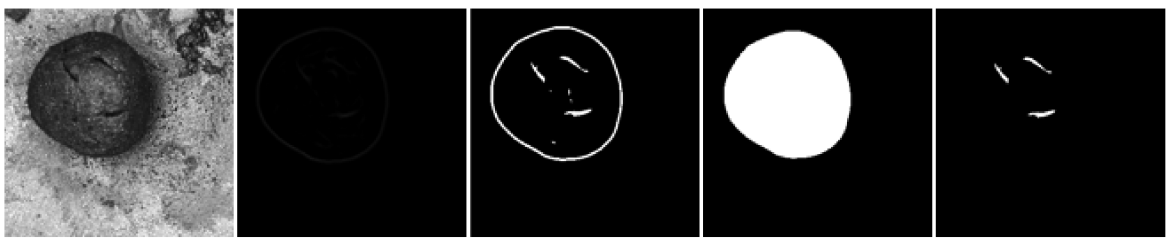

(a) 原始图像 (a) Raw image　(b) 裂缝响应图 (b) Crack response map　(c) 裂缝显著图 (c) Crack saliency map　(d) 目标生球区域掩膜 (d) Mask of IOA　(e) 裂缝分割结果 (e) Result of crack segmentation

图 7　生球裂缝分割结果

Fig. 7　Result of crack segmentation of green pellet

2.4　生球图像裂缝检测

通过上述步骤获得生球裂缝分割结果图，然后采用连通域分析法来检测生球是否存在裂缝，如果有裂缝，则进一步计算出裂缝条数，具体步骤如下：

1）统计生球裂缝分割图中连通域 $r_i(i=1,2,3,\cdots,L)$ 的个数 L（$L \geqslant 0$），若不存在连通域（$L=0$），那么该生球图像为无裂缝生球图像，输出检测结果“无裂缝”；若生球裂缝分割图存在连通域（$L \neq 0$），则该生球图像的为有裂缝生球裂缝，输出检测结果“有裂缝”：

$$\text{检测结果}\begin{cases}\text{“无裂缝”}, L = 0\\ \text{“有裂缝”}, L \neq 0\end{cases} \tag{21}$$

2）由于每条生球裂缝独立分布，裂缝与裂缝之间存在一定距离。因此，本文将生球裂缝分割图中的连通域个数 L 记为生球裂缝条数，并输出检测结果“L 条裂缝”。

2.5　评价指标

为对本文的生球裂缝检测方法进行定量评价，采用准确率 *Acc*、召回率 *Recall*、精确率 *Precision*、和加权调和平均 *F*1 用于衡量算法的裂缝分割性能。其中，准确率 *Acc* 表示生球裂缝分割的总体性能；召回率 *Recall* 表示查全率，其值越高表示未被分割出的裂缝像素点越少；精确率 *Precision* 表示查准率，其值越高表示分割错误的裂缝像素点越少；*F*1 是 *Precision* 和 *Recall* 的综合评价指标。这 4 个指标的表达式为：

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \tag{22}$$

$$Recall = \frac{TP}{TP + FN} \tag{23}$$

$$Precision = \frac{TP}{TP + FP} \tag{24}$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \tag{25}$$

其中，*TP* 表示被正确分割的生球裂缝像素点个数；*FN* 表示被错误分割的生球裂缝像素点个数；*TN* 表示被正确分割的非生球裂缝像素点个数；*FP* 表示被错误分割的非生球裂缝像素点个数。

3　实验验证

本文以 Python 3.6 为编程语言，在内存为 16 GB 的 Intel Core i5-9400 CPU 上实现了所提方法。为验证本文算法的有效性，利用采集到的 297 张生球裂缝图像（包括

197 张含裂缝生球图,100 张不含裂缝生球图)对本文方法进行验证。首先,将本文方法与 5 种对比方法的裂缝分割效果进行比较,这 5 种方法包括形态学方法[3]、Gabor 变换法[10]、加权邻域法[4]和自适应阈值法[9],基本可调滤波器;接着,对本文方法裂缝检测的准确率进行测试,并采用消融实验对本文方法中各个步骤的必要性进行验证;最后,对本文方法中的空间偏移距离参数的取值合理性进行了分析与验证。

3.1　结果与讨论

1)生球裂缝分割结果与分析

图 8 以 6 幅生球图像为例,测试了本文方法与 5 种对比方法的裂缝分割性能。所用测试图像在裂缝类型、裂缝条数、生球表面反光程度、图像背景上存在较大差异,有助于对裂缝分割算法的性能进行验证。其中,图 8 中的生球#1 有一条长裂缝,生球表面和钢板存在较强反光;生球#2 有两条裂缝,生球周围存在较多原材料碎屑干扰;生球#3 有 4 条裂缝,每条裂缝的长度、宽度和形态各不相同,生球表明凹凸不平,生球周围有大块原材料碎屑干扰;生球#4 没有裂缝,表面存在反光,图像背景中存在大片阴影;生球#5 无裂缝,图像背景中存在水渍干扰;生球#6 无裂缝,其表面反光严重且存在局部阴影。

从图 8 可以看出,基于形态学的裂缝分割方法[3]会导致生球边缘及边缘附近的阴影区域被错误分割成裂缝。这是因为该方法通过构建具有不同角度的线性结构掩膜,对图像进行开操作用于增强裂缝特征,然而该方法在增强裂缝特征的同时还增强了生球边缘及原材料污渍特征,从而导致裂缝分割错误。自适应阈值法[9]根据图像中的亮度分布,计算图像中局部区域的阈值大小从而分割出生球裂缝,然而该方法同样无法区分生球裂缝与生球边缘,并且对背景干扰敏感,易将图像中的原材料污渍及碎屑错误分割出来。加权邻域法[4]通过给每个像素点赋予权重值来分割出生球裂缝,该方法能够检测出长裂缝和宽裂缝,但由于短裂缝与细裂缝占据的像素点较少、对权重的影响不大,因此难以检测出短裂缝与细裂缝。另外,该方法同样无法克服生球边缘与复杂背景的干扰。Gabor 变换法[10]通过分析图中的频域信息来对裂缝进行分割,该方法对图像背景噪声敏感,易将原材料污渍及碎屑错误分割成裂缝。基本可调滤波器由于未考虑检测点周围的局部信息,难以克服噪声干扰,导致生球表面反光严重的区域被错误分割成裂缝。

与上述 5 种方法相比,本文所提方法通过采用主动轮廓模型提取出目标生球区域,从而消除了图像背景中原料污渍、碎屑带来的干扰;此外,还采用了可调证明滤波器来获取生球裂缝响应图,并通过大津法与形态学方法消除其中的生球边缘响应和噪声点,从而克服了生球边缘和球面反光的干扰,生球裂缝分割更为精确。

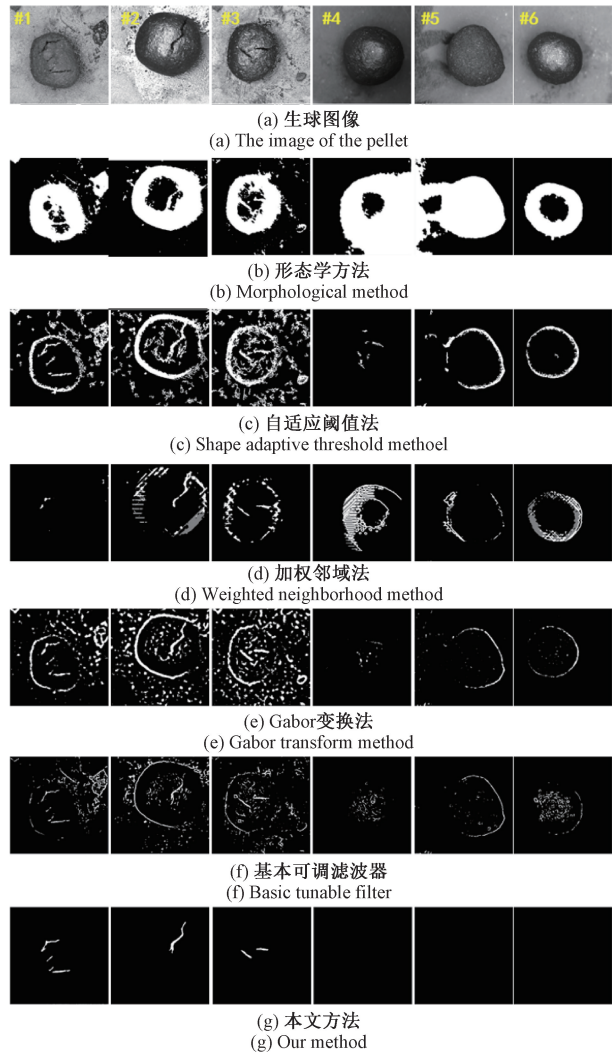

(a) 生球图像
(a) The image of the pellet

(b) 形态学方法
(b) Morphological method

(c) 自适应阈值法
(c) Shape adaptive threshold methoel

(d) 加权邻域法
(d) Weighted neighborhood method

(e) Gabor变换法
(e) Gabor transform method

(f) 基本可调滤波器
(f) Basic tunable filter

(g) 本文方法
(g) Our method

图 8　本文方法及现有方法的生球裂缝分割结果示例

Fig. 8　Examples of crack segmentation results of green pellets using our method and current methods

采用以上 6 种方法对数据集中的 297 张生球图像进行裂缝分割,各方法的分割性能指标如表 1 所示。可以看出,5 种对比方法的加权调和平均 $F1$ 指标很低(<25%),主要是因为这些方法的优势在于检测平直表面上的裂缝,对生球这种小目标曲面上的裂缝检测能力有限,受生球边缘、生球表面反光、图像阴影、生球污渍和碎屑等干扰的影响较大,难以分割出完整的生球裂缝,且裂缝分割结果中包含大量噪声。与之相比,采用本文方法获得的分割性能指标均明显优于其他方法,拥有最高的准确率 *Acc*(99.7%)、精确率 *Precision*(65.4%)和加权调和平均 $F1$(76.1%)。虽然本文方法的召回率 *Recall* 不是最优,但 *Recall* 与 *Precision* 的加权调和平均 $F1$ 是为最大值,说明本文方法能够克服背景噪声中原材料污渍、背景反光、表面阴影等干扰的影响,有效分割出生球裂缝,具有良好的鲁棒性。

表 1　本文方法与现有方法的生球裂缝分割指标评价结果

Table 1　Results of segmentation metrics of green pellet crack by our method and and current methods　(%)

对比方法	平均 *Acc*	平均 *Precision*	平均 *Recall*	平均 *F*1
形态学方法[3]	56.6	1.0	**98.1**	2.1
自适应阈值法[9]	99.5	12.0	85.9	21.2
基本可调滤波[22]	99.5	16.2	36.3	22
Gabor 变换法[10]	98.4	7.5	60.5	13.3
加权邻域法[4]	91.5	16.2	73.9	3.3
本文方法	**99.7**	**65.4**	91.2	**76.1**

2)生球裂缝检测结果与分析

采用本文方法对生球图像进行裂缝分割,然后采用连通域分析法来检测图像中是否含有裂缝及生球裂缝条数,结果如图 9 所示。从图 9 中可以看出,本文方法能够克服复杂背景的干扰有效分割出生球裂缝,从而能准确检测生球是否存在裂缝,并准确计算出生球裂缝条数。对数据集中的 297 张生球图像进行裂缝检测(即判断图像中是否存在裂缝),本文的检测准确率为 96%。对每张图像中的裂缝数量进行检测,结果表明,297 张图像中的 267 幅图像均给出了正确的裂缝数量检测结果,裂缝数量的检测准确率的 90%。采用本文方法对单幅生球图像的平均检测时间为 1.40 s,处理速度较快,能满足实际应用要求。本文的生球裂缝检测结果如表 2 所示。

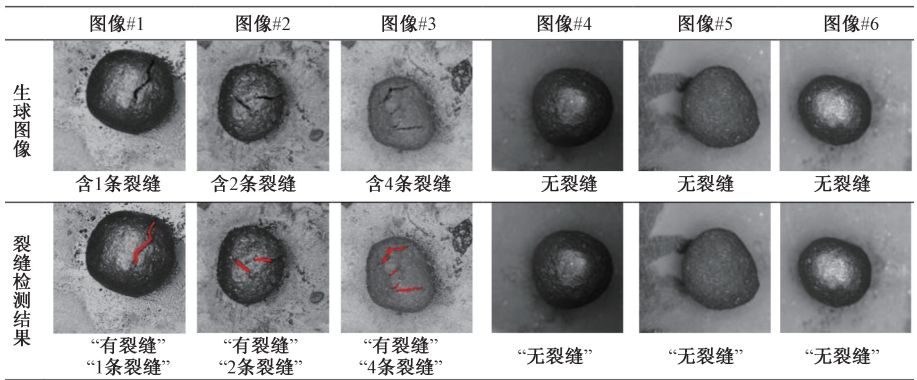

图 9　本文方法的裂缝检测结果示例

Fig. 9　Examples of crack detection results of green pellets using our method

表 2　本文方法生球裂缝检测结果

Table 2　Crack detection results of green pellets using our method

图像	实际生球图像数量	正确检测出是否有裂缝的图像张数	正确检测出裂缝数量的图像张数	检测生球是否存在裂缝的准确率	检测生球裂缝数量的准确率	单幅图像处理时间
有裂缝图像	197	197	179	96%	90%	1.40 s
无裂缝图像	100	88	–			

需要指出的是,虽然本文方法相较于其他 5 种方法有明显优势,但是在检测细窄裂缝时有一定局限性,导致个别生球裂缝检测错误。如图 10 所示,对于包含 9 条长短及宽度不同的生球裂缝图像#a,本文方法虽然能够正确检测出该图像中存在裂缝,但只能正确检测出其中的 7 条宽裂缝,而漏检了两条细裂缝;对于包含 1 条裂缝的图像#b,由于本文方法未分割出图中仅有的 1 条裂缝,导致图像被错误检测成无裂缝生球图像。

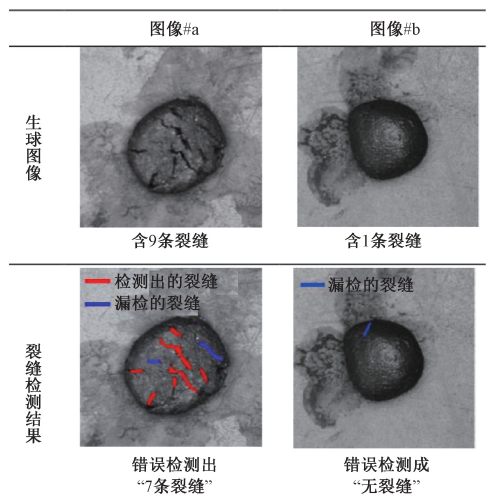

图 10　本文方法的生球裂缝错误检测示例

Fig. 10　Example of false crack detection of green pellet using our method

3.2　消融实验

本文方法中一共采用 4 个步骤来对生球裂缝进行检测,包括图像预处理、目标生球提取、基于可调证明滤波器的生球裂缝分割、生球裂缝检测。为验证本文方法中每个步骤的必要性,本文在 297 张生球图像上进行了消融实验,具体包括:1)删除本文方法中的图像预处理步骤;2)删除本文方法中目标生球提取步骤;3)将传统的基本可调滤波器(basic steerable filters,BSF)代替本文方

法中的基本可调证明滤波器(steerable evidence filtering, SEF)。

表 3 所示为 4 组消融实验的指标评价结果。对比实验#1 和实验#4 可以看出:当删除图像预处理步骤后,生球裂缝分割评价指标大幅度降低。这主要是由于算法易将生球图中大量噪声错误分割出来,无法正确检测出生球裂缝条数。对比实验#2 和实验#4 可以发现:当删除目标生球提取步骤后,算法受到生球边缘轮廓与背景污渍干扰的影响,同样无法检测出生球裂缝条数。对比实验#3 和实验#4 可以看出:当采用 BEF 代替 SEF 后,算法对噪声干扰敏感,难以检测出多类型裂缝,使得检测精度降低。与之相比,本文方法(实验#4)在裂缝分割准确率 *Acc*、精确率 *Precision*、加权调和平均 *F*1 指标上均取得了最高值,并且正确检测出是否有裂缝与裂缝条数的图像数量最多。由此说明,本文方法中各个步骤都对生球裂缝检测结果有重要影响,它们的组合能有效提升生球裂缝检测的效果,而删除或替换方法中的任一步骤都会使得裂缝分割评价指标与裂缝检测性能降低。

表 3　不同消融实验的生球裂缝分割与检测性能指标对比

Table 3　Performance metrics comparison of crack segmentation and detection metrics by ablation experiments

消融实验	所提方法中的步骤				分割评价指标				正确检测出有无裂缝的图像张数	正确检测出裂缝数量的图像张数
	图像预处理	生球提取	裂缝分割方法	裂缝检测	平均 *Acc*/%	平均 *Precision*/%	平均 *Recall*/%	平均 *F*1/%		
#1	–	√	SEF	√	85.2	3.0	**92.6**	5.8	197	0
#2	√	–	SEF	√	99.6	54.1	81.2	62.4	204	0
#3	√	√	BSF	√	99.5	60.7	74.3	64.2	216	134
#4(本文方法)	√	√	SEF	√	**99.7**	**65.4**	91.2	**76.1**	**285**	**267**

3.3　空间偏移距离对裂缝检测性能的影响

在本文方法中,空间偏移距离 d 是用于控制可调证明滤波器局部搜索区域范围的重要参数,其取值大小会直接影响生球裂缝检测结果。因此,有必要讨论空间偏移距离对生球裂缝分割与检测结果的影响,从而验证 d 取值的合理性。图 11 给出了不同 d(d=0.5、1.0、1.5、2.0)的生球裂缝检测结果,对比发现当 d=0.5 时,算法易将生球表面凹凸不平处误检成裂缝,导致裂缝条数检测错误;当 d=1.0 时,生球裂缝被有效分割出来,从而能够正确检测出 2 条裂缝;当 d=1.5 时,虽然能够正确检测出两条裂缝,但是无法将生球裂缝完全分割出来;当 d=2.0 时,生球裂缝同样未被完全分割出来,导致裂缝条数检测错误。

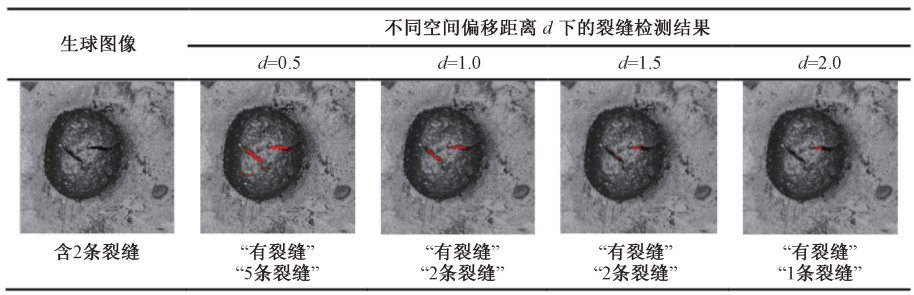

图 11　不同空间偏移距离取值对裂缝检测结果的影响

Fig. 11　Influence of different spatial offset distance on crack detection results

为对 d 的取值做进一步验证,本文采用 297 幅生球图像对不同 d 的生球检测性能进行定量比较,如表 4 所示。结果表明,当 d=1.0 时,生球裂缝检测的各项指标值最高,其分割性能指标中的准确率 *Acc*, 召回率 *Recall*, 精确率 *Precision* 和加权调和平均 *F*1 均为最大值,并且能正确检测出生球是否有裂缝和裂缝条数的图像数量最多,因此,本文取 d=1 用于生球裂缝的检测。值得一提的是,虽然不同 d 会对裂缝条数的检测准确率造成一定影响,但对于检测生球有无裂缝的影响较小,且裂缝分割结果仍优于其他 5 种对比方法(如表 1 所示),进一步验证了本文方法的有效性。

表 4 不同空间偏移距离下的生球裂缝检测性能指标对比

Table 4 Performance metrics comparison of green pellet by different spatial offset distances

空间偏移距离 d	分割评价指标				正确检测出有无裂缝的图像张数	正确检测出裂缝数量的图像张数
	平均 *Acc*/%	平均 *Precision*/%	平均 *Recall*/%	平均 *F1*/%		
d=0.5	99.6	68.3	62.5	65.3	282	178
d=1.0	**99.7**	**65.4**	**91.2**	**76.1**	**285**	**267**
d=1.5	99.6	68.2	62.5	65.2	279	264
d=2.0	99.6	73.7	51.9	60.9	273	225

4 结 论

生球裂缝检测是落下强度质量指标检测过程中的关键步骤,目前仍采用人工检测法,具有主观性强、可对比性差、检测结果不准确等缺点。当前的基于图像的裂缝检测方法主要应用于桥梁、道路、太阳能电池等物体平直表面上的裂缝,对生球这种小目标曲面上的裂缝检测能力有限,易受生球图像中原材料污渍与碎屑、生球边缘轮廓、生球表面反光等噪声的干扰,造成生球裂缝的误检与漏检。针对当前方法的局限性,本文提出了一种基于可调证明滤波器的球团矿生球裂缝检测方法,首先采用主动轮廓模型提取出目标生球,解决了生球背景中原材料污渍与碎屑的干扰。然后采用基于可调证明滤波器的方法对生球图像进行裂缝分割,消除了生球边缘轮廓与球面反光的干扰。最后,采用连通域分析法检测出生球是否存在裂缝并计算裂缝数量,较好的解决了复杂背景下的生球裂缝自动检测问题。利用 297 幅生球图像对本文方法和其他 5 种方法进行了测试,结果表明,本文方法的裂缝检测效果明显优于其他 5 种方法,检测生球是否存在裂缝的准确率为 96%,检测裂缝数量的准确率为 90%。单幅生球图像的平均检测时间约为 1.40 s,能够满足裂缝自动检测应用需求。本文研究成果为生球落下强度质量指标的自动化、智能化检测奠定了基础,具有较高应用价值。

参考文献

[1] WU X, LIU X Y, SUN W, et al. An image-based method for online measurement of the size distribution of iron green pellets using dual morphological reconstruction and circle-scan [J]. Powder Technology, 2019, 347(1): 186-198.

[2] TAVARES L M, DE ALMEIDA R F. Breakage of green iron ore pellets [J]. Powder Technology, 2020, 366(15): 497-507.

[3] SU T. Application of computer vision to crack detection of concrete structure [J]. International Journal of Engineering and Technology, 2013, 5(4): 457-461.

[4] SUN L, KAMALIARDAKANI M, ZHANG Y. Weighted neighborhood pixels segmentation method for automated detection of cracks on pavement surface images [J]. Journal of Computing in Civil Engineering, 2016, 30(2): 04015021.

[5] KAMALIARDAKANI M, SUN L, ARDAKANI M K. Sealed-crack detection algorithm using heuristic thresholding approach [J]. Journal of Computing in Civil Engineering, 2016, 30(1): 04014110.

[6] HOANG N D. Detection of surface crack in building structures using image processing technique with an improved Otsu method for image thresholding [J]. Advances in Civil Engineering, 2018, 2018:1-18.

[7] WANG W, LI L, HAN Y. Crack detection in shadowed images on gray level deviations in a moving window and distance deviations between connected components [J]. Construction and Building Materials, 2021, 271(15): 121885.

[8] 陶志勇,于子佳,林森. PSO_SVM 算法在太阳能电池板裂缝缺陷检测研究[J]. 电子测量与仪器学报, 2021,35(1):18-25.
TAO ZH Y, YU Z J, LIN S, Research on crack defect detection of solar cell based on PSO_SVM[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1):18-25.

[9] 刘伟,周建行,杨延西. 基于平行激光的便携式视觉裂缝测量系统[J]. 仪器仪表学报, 2020, 41(11): 235-243.
LIU W, ZHOU J X, YANG Y X. Portable vision crack measurement system based on parallel laser [J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 235-243.

[10] ZALAMA E, GÓMEZ-GARCÍA-BERMEJO J, AND R M, et al. Road crack detection using visual features extracted by gabor filters [J]. Computer-Aided Civil and Infrastructure Engineering, 2014, 29: 342-358.

[11] LI W. Defect detection of solar cells in electroluminescence images using Fourier image reconstruction [J]. Solar Energy Materials and Solar Cells, 2012, 99 :250-262.

[12] LIU Z, CAO Y, WANG Y, et al. Computer vision-based concrete crack detection using U-net fully convolutional

networks [J]. Automation in Construction, 2019, 104: 129-139.

[13] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.

[14] YANG Q, JI X. Automatic pixel-level crack detection for civil infrastructure using Unet + + and deep transfer learning [J]. IEEE Sensors Journal, 2021, 21(17): 19165-19175.

[15] JIANG W, LIU M, PENG Y, et al. HDCB-Net: A neural network with the hybrid dilated convolution for pixel-level crack detection on concrete bridges [J]. IEEE Transactions on Industrial Informatics, 2021, 17(8): 5485-5494.

[16] CHEN H, ZHAO H, HAN D, et al. Accurate and robust crack detection using steerable evidence filtering in electroluminescence images of solar cells [J]. Optics and Lasers in Engineering, 2019, 118: 22-33.

[17] LIU Y, YAO J, LU X, et al. DeepCrack: A deep hierarchical feature learning architecture for crack segmentation [J]. Neurocomputing, 2019, 338: 139-153.

[18] SHI Y, CUI L, QI Z, et al. Automatic road crack detection using random structured forests [J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(12): 3434-3445.

[19] MEI Q, GÜL M, AZIM M R. Densely connected deep neural network considering connectivity of pixels for automatic crack detection [J]. Automation in Construction, 2020, 110: 103018.

[20] 刘小园,杨磊. 基于加权全局图像拟合能量的主动轮廓图像分割模型[J]. 电子测量与仪器学报,2018,32(1):89-95.
LIU X Y, YANG L. Active contour image segmentation model based on weighted global image fitting energy [J]. Journal of Electronic Measurement and Instrumentation, 2018,32(1):89-95.

[21] KHIRIRAT S, FEYZMAHDAVIAN H R, JOHANSSON M. Mini-batch gradient descent: Faster convergence under data sparsity[C]. 2017 IEEE 56th Annual Conference on Decision and Control (CDC). IEEE, 2017: 2880-2887.

[22] 王依人,邓国庆,夏营威,等. 基于方向可调滤波器的血管图像增强算法[J]. 系统仿真学报,2018,30(6): 2095-2101.
WANG Y R, DENG G Q, XIA Y W, et al. Vascular image enhancement using steerable filters[J]. Journal of System Simulation,2018,30(6):2095-2101.

作者简介

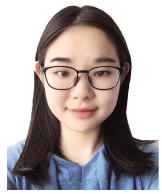

周淑伊,2019 年于湖南大学获得硕士学位,现为湖南大学博士研究生,主要研究为方向工业图像处理。
E-mail: 394311080@qq.com

Zhou Shuyi received the M. Sc. degree in 2019 from Hunan University. Now she is currently a Ph. D. candidate in Hunan University. Her main research interest includes industrial image processing.

刘小燕(通信作者),2005 年于德国马格德堡大学获得博士学位,现为湖南大学电气与信息工程学院教授,博士生导师,主要研究方向为图像处理、复杂过程建模与控制。
E-mail: xiaoyan.liu@hnu.edu.cn

Liu Xiaoyan (Corresponding author) received Ph. D. from Otto von Guericke University Magdeburg in 2005. Now she is a professor and Ph. D. supervisor in College of Electrical and Information Engineering, Hunan University. Her main research interests include image processing, modeling and control of complex processes.

陈玉如,2019 年于福州大学获得学士学位,现为湖南大学硕士研究生,主要研究为方向工业图像处理。
E-mail: 840538148@qq.com

Chen Yuru received the B. S. degree in 2019 from Fuzhou University. Now she is currently a M. Sc. candidate in Hunan University. Her main research interest includes industrial image processing.

孙浠汉,2019 年于武汉理工大学获得学士学位,现为湖南大学硕士研究生,主要研究为方向工业图像处理。
E-mail: 823577670@qq.com

Sun Xihan received the B. Sc. degree in 2019 from Wuhan University of Science and Technology. Now he is currently a M. Sc. candidate in Hunan University. His main research interest includes industrial image processing.