

基于 2D-OSTU 图像边缘检测的回转窑工况识别方法

徐逸峰, 朱远明, 钟伟民, 钱 锋[†]

(华东理工大学 信息学院, 上海 200237)

摘 要: 回转窑作为水泥窑炉煅烧过程的核心热工设备, 其正常运转率与产品产量、质量及能耗紧密相关. 由于回转窑内部核心反应区温度高且装置持续旋转, 接触式温度传感器无法安装在窑内核心反应区域, 而筒扫系统借助红外扫描装置能够实时监测回转窑筒体表面温度并间接反映窑内热工状况. 本文提出了一种基于筒扫图像 2D-OSTU 边缘检测的回转窑异常工况识别新方法. 该方法首先构建了基于灰度梯度和局部灰度标准差信息的融合模型, 并利用相对熵概念计算模型权重系数, 进而通过 1D-OSTU 预搜索策略提升识别算法的效率. 此外, 本文给出了一种 2D 双阈值检测阈值分割策略以保证边缘的连续性. 最后, 采用工业现场实际的回转窑筒扫图像对所提方法与其它典型检测方法进行比较研究. 对比实验结果表明, 所提方法的检测率和单位误报次数均优于其他算法并具备一定鲁棒性, 能够有效地检测回转窑内异常工况, 达到提高回转窑运转率的目的.

关键词: 回转窑; 筒扫系统; 边缘检测; 异常工况识别; 相对熵; 预搜索策略

中图分类号: TP14

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0348

Condition Recognition Method of Rotary Kiln Based on 2D-OSTU Image Edge Detection

Xu Yi-feng, Zhu Yuan-ming, Zhong Wei-min, Qian Feng[†]

(EastChinaUniversityofScienceandTechnology, Shanghai 200237, China)

Abstract: Rotary Kiln is the core thermal reaction equipment of cement calcination process, whose operation state is closely related to the yield, the quality and the energy consumption and of products. Contact temperature measurement can not be installed in the core area inside the kiln due to high temperature and continuous rotation. Rotary Kiln Shell Scanning System(RKSSS) is available to monitor the temperature of kiln shell and reflect the thermal condition inside the kiln indirectly in real time. A new method of abnormal conditions identification which is based on 2D-OSTU-Edge-Detection is proposed in this paper. The fusion model based on gray gradient and local gray standard deviation information is firstly constructed, and the weight coefficient of the model is calculated by using the concept of relative entropy. 1D-OSTU pre-searching strategy is then adopted to improve the efficiency of the algorithm. In addition, a 2D threshold segmentation strategy is proposed to ensure the continuity of the edge. By applying images from the RKSSS, the proposed method is tested and compared with other typical methods. The results demonstrate that the proposed method made a promotion in detection rate and false alarm probability with robustness. Therefore, the proposed method is available to detect the abnormal condition and to extend operation cycle of the rotary kiln.

Keywords: Rotary Kiln; Rotary Kiln Shell Scanning System; Edge Detection; Abnormal Conditions Identification; Relative Entropy; Pre-searching Strategy

0 引 言

回转窑是水泥窑炉煅烧过程中的核心设备, 它的正常运行与整条生产线的产量、能耗以及产品质量密切相关. 回转窑内部热工状况不稳定 (温度过高或波动幅度过大) 将会降低生产线产能, 并影响运行效率; 极端情况下可能会导致耐火砖脱落, 必须停窑检修, 给企业带来安全隐患和经济损失^[1-2]. 为保证

回转窑的安全运行、预防各类严重异常工况的发生, 对回转窑的运行状态进行实时有效地监测具有重要意义. 由于回转窑内部固相反应最高温度超过 1400℃ 以及窑筒体持续旋转等特点, 常规的接触式温度传感器无法安装在回转窑内核心反应区域^[3]. 目前, 水泥生产企业主要通过人工监测二次风温、三次风温以及窑主电机电流等关键过程变量对窑的运行

收稿日期: 2020-03-26; 修回日期: 2020-06-04.

基金项目: 国家重点研发计划项目 (2016YFB0303403), 国家杰出青年科学基金 (61725301, 61925305)

[†]通讯作者. E-mail: fqian@ecust.edu.cn.

状况进行判断与调控^[4], 这种方法无法具体地反映窑内工况, 并且会受到操作人员的主观因素影响. 近年来, 图像处理技术在工业生产领域中的应用不断延伸, 通过窑头的燃烧器火焰图像和回转窑筒体表面红外热成像(筒扫图像)判断窑内工况成为了两个可行的研究方向.

窑头火焰图像能够反映窑头燃烧器的火焰喷射情况、燃烧状态以及对应温度^[5-6], 但窑内反应产生的飞灰和烟气会一定程度地影响图像的质量. 而回转窑筒体表面热成像是由红外扫描装置对窑表面的一条轴向基线进行扫描, 当回转窑旋转一周后生成一张筒体表面热成像, 又称筒扫图像. 筒扫图像具备实时性、精确性的特点, 能够间接反映窑内热工状况, 因而受到了研究人员的广泛关注. Morocho 通过模板匹配技术 (Match Template Function) 对筒扫图像中的异常色块进行搜索, 识别异常区域^[7], 但实际情况中异常工况的几何特征(形状、面积)以及区域色阶(实际温度)不尽相同, 因此该方法的泛化能力不强. Yang 和 Sun 认为耐火材料出现异常的区域通常会发生热震荡, 将筒扫图像还原为温度场数据后通过经验模式分解 (EMD, Empirical Mode Decomposition) 将窑表面温度曲线分解为各个频段的分量, 再利用希尔伯特-黄变换 (HHT, Hilbert-Huang Transform) 计算图像各位置频谱值对相应位置耐火材料进行断裂预测, 该算法精确度较高, 对耐火材料断裂的情况从频域的角度进行细致研究^[8], 但在回转窑实际运行过程中掉窑皮、结窑皮以及结圈等现象对窑内工况同样会造成影响, 这些异常工况未被纳入研究内容.

从图像的角度分析, 异常工况通常表征为色阶与周围差距较大的闭合型区域. 因此, 本文使用图像边缘检测技术为核心手段, 对筒扫图像中异常区域进行甄别. 目前, 图像边缘检测主要方法可以分为以下三类:

1) 主动轮廓模型, 该类方法将像素转换成距离场, 并定义曲线能量由内部能量项与外部能量项组成, 其中内部能量项使轮廓曲线在收敛演化的过程中保持连续与光滑, 而外部能量项则驱使轮廓曲线向检测目标边缘靠近. 主动轮廓模型通过最小化能量泛函使轮廓曲线逼近检测目标边缘, 最终分割出目标^[9-11]. 由于筒扫热成像展示的是回转窑筒体温度场分布, 不存在明确的“目标”概念, 异常区域与周围邻域的边缘较为模糊, 因此主动轮廓模型不适用于本研究.

2) 深度学习模型, 随着对卷积神经网络研究的

深入, 其在图像处理领域的潜力逐渐被发掘, 2015 年的 Holistically-Nested Edge Detection 算法与 2017 年的 Richer Convolutional Features 算法都是利用了卷积神经网络框架的深层特征表达能力, 在公共图像边缘检测数据集上获得了较好的结果^[12-14]. 深度学习模型由于需要大量已标注的标准训练数据, 而本问题中难以获取大量的标准筒扫图像.

3) 阈值分割模型, 阈值分割算法通过提取能表征图像边缘的数据信息, 使用阈值分割的手段进行像素点的分类. 该算法计算复杂度低、检测效果较好、泛用性强^[15-17]. 综上所述, 阈值分割模型受目标与环境对比度影响小, 并且计算方便、可行性高, 适用于依据筒扫图像进行窑内工况识别的研究.

阈值分割模型会涉及到阈值选取问题, 主流的思路是通过图像数据的统计信息进行阈值自适应. 这类思想最早由 Nobuyuki Otsu 提出, 因此该方法被称为 OTSU 法. OTSU 法将图像分为背景与目标两部分, 通过最大化类间方差计算最优分类阈值^[18], 从而实现背景与目标的分离. 类似地, 将这种思想延展至边缘检测任务中, 将图像分为“强边缘”, “弱边缘”以及“非边缘”三类像素点, 通过图像梯度信息的单特征类间方差最大化完成阈值自适应^[19].

本文提出了一种基于 2D-OTSU 阈值分割的边缘检测方法, 用以对筒扫图像中异常区域进行识别与判断, 主要应对异常工况为掉窑皮与结窑皮. 通过相对熵的概念得到了模型权重系数, 以此构建基于灰度梯度和局部灰度标准差信息的融合模型, 同时提出了 1D-OTSU 预搜索策略提高算法效率, 并给出了一种有效的 2D 双阈值检测策略, 最后使用工业现场筒扫图像验证了中所提方法的可行性、有效性和鲁棒性.

1 基础知识

1.1 图像预处理

对 RGB 图像进行式 (1) 所示的灰度转换.

$$I = 0.299R + 0.587G + 0.114B. \quad (1)$$

图像去噪采用双边滤波法代替常规的高斯滤波法, 该方法综合考虑局部图像的空间欧式距离和像素的相似度, 相比于高斯滤波能够更为有效地保留

边缘信息^[20], 其滤波核形式如式 (2) 所示.

$$\begin{cases} d(i, j, k, l) = \exp \left\{ -\frac{(i-k)^2 + (j-l)^2}{2\sigma_d^2} \right\}; \\ r(i, j, k, l) = \exp \left\{ -\frac{\|I(i, j) - I(k, l)\|^2}{2\sigma_r^2} \right\}; \\ \gamma(i, j, k, l) = d(i, j, k, l) * r(i, j, k, l); \\ g(i, j) = \frac{\sum_{(k, l) \in S_1} I(k, l) \gamma(i, j, k, l)}{\sum_{(k, l) \in S_1} \gamma(i, j, k, l)}. \end{cases} \quad (2)$$

其中, σ_d^2 为空间域标准差, σ_r^2 为值域标准差, $I(i, j)$ 和 $I(k, l)$ 分别为 (i, j) 个 (k, l) 的灰度值, S_1 为 $m_1 * m_1$ 邻域卷积核, $g(i, j)$ 为滤波后像素值.

1.2 梯度计算

灰度梯度计算通常使用式 (3) 所示的 3*3 离散差分 Sobel 算子与图像卷积求取灰度梯度.

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}; S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}. \quad (3)$$

其中, S_x, S_y 分别为水平与垂直方向 Sobel 算子. 按式 (4) 计算得到图像灰度梯度幅值.

$$g_d(i, j) = \sqrt{G_x(i, j)^2 + G_y(i, j)^2}. \quad (4)$$

其中, $G_x(i, j), G_y(i, j), g_d(i, j)$ 分别为像素 (i, j) 处的垂直方向梯度幅值、水平方向梯度幅值和梯度幅值.

1.3 局部灰度标准差计算

局部灰度标准差计算方式如下式:

$$\begin{cases} g_m(i, j) = \frac{1}{(2l+1)^2} \sum_{(i, j) \in S_2} g(i, j); \\ g'_s(i, j) = \sqrt{\frac{\sum_{(i, j) \in S_2} (g(i, j) - g_m(i, j))^2}{(2m_2+1)^2 - 1}}. \end{cases} \quad (5)$$

其中, $g(i, j)$ 为双边滤波后像素 (i, j) 的灰度值, $g_m(i, j)$ 为像素 (i, j) 的 $m_2 * m_2$ 邻域 S_2 的局部灰度均值.

2 研究方法

2.1 数据标准化

由于本方法是基于梯度信息和局部灰度标准差的综合模型, 因此首先将灰度数据缩放至梯度数据的值域范围以平衡数据范围:

$$g_s(i, j) = \frac{g'_s(i, j) - g_{smin}}{g_{smax} - g_{smin}} * g_{dmax}. \quad (6)$$

其中, g_{smin} 和 g_{smax} 分别为局部灰度标准差数据最小值和最大值, g_{dmax} 为梯度数据最大值.

2.2 2D-OTSU 求解

将图像分为非边缘像素 C_0 、弱边缘像素 C_1 以及强边缘像素 C_2 三分类进行 OTSU 阈值求解. 对于梯度数据 (或局部灰度标准差数据), 若取值为 i 的像

素点共 n_i 个, 则各类出现概率为:

$$p_i = \frac{n_i}{N}. \quad (7)$$

其中, N 为图像总像素点数量. 设高低阈值分别为 s 和 t , 计算各分类的像素点总概率 w_j 以及其类平均值 μ_j 为:

$$\begin{cases} w_0 = \sum_{i=0}^{t-1} p_i; \\ w_1 = \sum_{i=t}^{s-1} p_i; \\ w_2 = \sum_{i=s}^{g_{dmax}} p_i. \end{cases} \quad (8)$$

$$\begin{cases} \mu_0 = \frac{\sum_{i=0}^{t-1} i p_i}{w_0}; \\ \mu_1 = \frac{\sum_{i=t}^{s-1} i p_i}{w_1}; \\ \mu_2 = \frac{\sum_{i=s}^{g_{dmax}} i p_i}{w_2}. \end{cases} \quad (9)$$

其中, g_{dmax} 为式 (6) 中梯度幅值数据最大值. 定义每类像素点的方差:

$$\begin{cases} \sigma_0^2 = \frac{\sum_{i=0}^{t-1} p_i * (i - \mu_0)^2}{w_0}; \\ \sigma_1^2 = \frac{\sum_{i=t}^{s-1} p_i * (i - \mu_1)^2}{w_1}; \\ \sigma_2^2 = \frac{\sum_{i=s}^{g_{dmax}} p_i * (i - \mu_2)^2}{w_2}. \end{cases} \quad (10)$$

定义类间方差 σ_A^2 以及类内方差 σ_B^2 :

$$\begin{cases} \sigma_A^2 = \sum_{j=0}^2 w_j * (\mu_0 - \mu_T)^2; \\ \sigma_B^2 = \sum_{j=0}^2 w_j * \sigma_j^2. \end{cases} \quad (11)$$

最大化类间方差 σ_A^2 以及最小化类内方差 σ_B^2 以求解最优阈值 s 和 t , 即获得最佳的 C_0, C_1, C_2 分类效果. 因此定义式 (12) 所示的目标函数:

$$\begin{cases} O(s, t) = \sigma_B^2 / \sigma_A^2; \\ Obj(s_d, t_d, s_s, t_s) = O_d(s_d, t_d) + \beta O_s(s_s, t_s). \end{cases} \quad (12)$$

其中, s_d, t_d 和 s_s, t_s 分别为梯度阈值和局部灰度标准差阈值, β 为模型权重系数将在 2.3 节说明, $Obj(s_d, t_d, s_s, t_s)$ 为综合模型的目标函数.

上述目标函数最小化的参数求解问题可以表示为式 (13) 所示优化问题, 通过求解能够获得本问题的最佳阈值 $(s_d^*, t_d^*, s_s^*, t_s^*)$.

$$(s_d^*, t_d^*, s_s^*, t_s^*) = \underset{s_d, t_d, s_s, t_s}{\operatorname{argmin}} \{Obj\}. \quad (13)$$

2.3 模型权重系数 β

权重系数 β 反映梯度数据和局部灰度标准差数据之间的相对重要程度, 本文通过它们各自的概率分布序列与标准可分割三峰分布的相似度来确定这一系数.

相对熵 (Relative Entropy, RE) 通常用来计算两

种分布之间相似度的非对称性度量,RE 值越小,分布越相似:

$$R_E(Q|F) = \sum Q(i) \log(Q(i)/F(i)). \quad (14)$$

其中, Q 和 F 为两个离散分布序列. 由于需要一种标准的离散三峰分布, 因此定义一种叠加型三峰离散序列:

$$F(b, c) = a_0 M(b_0, c_0) + a_1 M(b_1, c_1) + a_2 M(b_2, c_2). \quad (15)$$

其中, $M(b, c)$ 是以 b 为均值, c 为标准差的正太分布 $M'(b, c)$ 随机生成 N 次数据 (N 为图像像素个数) 在 $[0, g_{dmax}]$ 范围内的统计序列; a_0, a_1, a_2 为叠加权重系数, 满足 $a_0 + a_1 + a_2 = 1$.

由于相对熵的非对称性, 模型权重系数 β 的计算方式如下式:

$$\beta = \frac{R_E(Q_d|F) + R_E(F|Q_d)}{R_E(Q_s|F) + R_E(F|Q_s)}. \quad (16)$$

其中, Q_d 、 Q_s 分别为梯度数据和局部灰度标准差数据的离散概率统计序列, F 即为式 (15) 中的叠加型三峰序列.

2.4 1D-OTSU 预搜索策略

在灰度阈值搜索精度为 1 的前提下, 使用遍历的方式对式 (13) 2D-OTSU 优化问题求解的求解效率与 g_{dmax} 相关, 其时间复杂度为 $O(n^4)$.

由于算法效率与搜索范围 g_{dmax} 直接相关, 为进一步提高算法执行效率, 因此提出一种预搜索算法策略以缩小搜索规模: 根据两种数据分别以式 (12) 中的 $O_d(s_d, t_d)$ 和 $O_s(s_s, t_s)$ 为目标函数进行一次阈值搜索得到 1D-OTSU 情况下各自最优解 (s'_d, t'_d) 和 (s'_s, t'_s) . 再以 $[-0.2 * g_{dmax}, 0.2 * g_{dmax}]$ 为相对搜索范围进行 2D-OTSU 搜索获得式 (13) 的近似解.

2.5 2D 双阈值检测

边缘检测算法通常希望得到闭合边缘, 双阈值检测方法能够有效保证边缘检测结果的连续性. 如图 1 所示为 2D 双阈值检测方法示意, 红色区域代表非边缘像素 C_0 , 直接标记为非边缘点; 蓝色区域代表弱边缘像素 C_1 ; 绿色区域代表强边缘像素 C_2 , 直接标记为边缘点. 对于弱边缘像素, 若其 3×3 邻域内存在强边缘像素则标记为边缘点, 否则抑制为非边缘点.




图 1 双阈值检测

2.6 异常工况说明

回转窑是窑炉煅烧过程中最复杂的热工设备, 本文研究的两种异常工况为掉窑皮与结窑皮, 其两种主要工况说明如表 1 所述.

表 1 异常工况说明

工况现象		图像特征
掉窑皮	局部窑壁物料粘附, 窑皮变厚	块状相对低温区域
结窑皮	局部窑皮过度脱落, 窑皮变薄	块状相对高温区域

掉窑皮与结窑皮现象会导致窑工况的恶化, 影响窑炉煅烧的稳定和安全生产: 窑皮掉落程度十分严重时, 耐火材料直接暴露, 可能会造成掉砖现象, 导致窑烧穿, 从而必须进行停窑检修; 窑皮粘附过厚时会使窑内通风不畅, 物料燃烧不充分导致产品质量不达标. 因此需要对这两种异常工况进行实时有效的监控与识别.

综上所述, 本文所提算法的检测流程如图 2 所示. 对于输入的筒扫图像首先进行灰度化以及双边滤波的预处理; 接着计算得到图像的灰度梯度数据以及灰度局部标准差数据; 为保证算法运行效率, 梯度与标准差数据分别进行一次 1D-OTSU 预搜索; 在预搜索结果的 $[-0.2 * g_{dmax}, 0.2 * g_{dmax}]$ 相对范围内进行 2D-OTSU 最优阈值搜索; 然后根据给出的双阈值检测策略进行边缘点和非边缘点的标定; 结合相应区域的温度信息进行工况的具体判定并最终输出检测结果.




图2 算法检测流程

3 实验与分析

3.1 实验准备

本研究原始图像数据源自国内某水泥生产企业 12000 吨/天生产线的筒扫热成像系统. 实验所使用计算机配置为 Intel i5-8300H 2.30GHz 64 位处理器. 截取筒扫图像中核心反应区域作为检测输入图像, 如图 3 所示, 图像像素为 250*320, 图像偏左侧深蓝色方块状区域为回转窑窑门, 不纳入检测范围.




图3 筒扫核心反应区域图像

3.2 参数设定

式 (3) 中双边滤波卷积核 S_1 大小为 3*3(即 $m_1=3$), 空间域标准差 $\sigma_d^2=0.95$, 值域标准差 $\sigma_r^2=150$; 式 (5) 邻域 S_2 大小为 3*3(即 $m_2=3$); 式 (15) 三峰序列确定为: $F = 0.6M(20, 4) + 0.3M(40, 5) + 0.1M(65, 2)$.

3.3 温度信息获取

工艺中对掉窑皮和结窑皮等工况的判定需要结合异常区域的温度信息, 这需要通过现场回转窑红外测温系统伪彩色编码机制进行解码获得.

通过读取筒扫系统界面温度色板的 RGB 值对红外扫描系统伪彩色编码机制进行解码, 获得了相应的 RGB 伪彩色编码解码函数, 通过 RGB 值与温度的对应关系能够在已知像素点 RGB 值的情况下能够得到对应的温度信息. 通过比较目标区域内部

平均温度以及邻近区域平均温度的即可得到异常工况的识别结果.

3.4 实验不确定因素分析

本研究原始数据红外图像温度分布的可靠性依赖于红外检测扫描仪的准确性, 因此对实际应用场景中粉尘遮染、极端气候条件等系统不确定因素进行分析. 针对粉尘问题, 应对扫描仪镜头进行定期乙醚清洁, 同时如需要打开扫描仪应该避免杂质进入光学模块中以影响其光学检测性能; 针对环境因素, 工业现场所使用的 MTENK 扫描仪使用条件为环境温度 $[-25^{\circ}\text{C}, 55^{\circ}\text{C}]$ 以及相对湿度 $[10\%, 100\%]$.

粉尘问题以及高湿度环境问题在图像中通常表现为椒盐噪声以及高斯噪声. 常规情况下, 噪声的加入会很大程度影响梯度数据的分布, 使得所提方法的边缘检测异常识别功能失效. 本方法所使用的双边滤波在滤除噪声的同时一定程度上保留了边缘信息, 因此对这两种不确定性环境参数的摄动具备一定的鲁棒性. 值得注意的是, 图像噪声无法避免地会降低算法对异常区域边缘的定位精确性, 下节中将对本问题进行实验.

3.5 实验结果与分析

通过现场技术人员对某生产线 2019 年 10 月 25 日至 11 月 4 日每四小时截取的共 66 张筒扫图像进行异常区域的人工标定: 共标定结窑皮区域 87 处以及掉窑皮区域 46 处 (共 133 处异常区域). 使用本文所提出算法对该图片集进行检测并记录检测结果, 设标定异常区域共 l_0 个, 检测成功异常区域共 l_1 个, 检测框重合率达到 60% 即认为检测成功, 误报的异常区域共 l_2 个. 定义检测成功率 q_1 以及单位异常区域误报次数 q_2 如下式所示, 对 2.4 节 1D-OTSU 预搜索算法策略进行对比实验, 结果如表 2 所示.

$$\begin{cases} q_1 = \frac{l_1}{l_0} * 100\%; \\ q_2 = \frac{l_2}{l_0}. \end{cases} \quad (17)$$

表2 预搜索策略实验结果

不同方法	$q_1(\%)$	q_2	耗时 (s)
无预搜索算法	91.72	0.195	9.28
本文方法	90.23	0.203	6.73

因为 1D-OTSU 预搜索策略通过提前确定相对较小的搜索范围以提高算法执行效率, 所以该策略最终能会使用到式 (13) 优化问题的近似解作为最后的分割阈值. 理论分析易知本策略在牺牲一定性能的前提下提高了算法执行效率, 有助于对异常工况提前预警. 表 2 的实验结果显示, 预搜索算法策略在牺牲 1.6% 检测率以及 4.1% 的单位误报次数的情况下获

得了 27.5% 的算法耗时下降, 具备可行性与有效性.

将本文所提算法与两种单特征 1D-OTSU 算法、一种主动轮廓 (snake) 算法以及传统的过程变量观察法进行对比实验, 综合检测结果如表 3 所示, 典型检测结果如图 4 所示, 其中红色边缘对应掉窑皮, 深蓝色边缘对应结窑皮区域.

表 3 算法对比实验结果

不同方法	$q_1(\%)$	q_2	耗时 (s)
梯度单特征	84.21	0.541	3.13
标准差单特征	66.92	0.699	2.45
Snake	63.16	0.766	5.81
区域生长算法	69.17	0.398	1.82
2D-OTSU	90.23	0.203	6.73




图 4 (a) 原始图像 (b) 梯度单特征边缘检测 (c) 灰度标准差单特征边缘检测 (d) snake 算法检测 (e) 区域生长算法检测 (f) 本文算法检测结果 (g) 本文算法最终检测框 (h) 标定结果检测框

表 3、图 4 的对比实验结果显示:

1) 实验计算了筒扫图像的平均模型权重系数 $\bar{\beta}$ 为 0.526, 表明在融合模型中梯度信息的权重更高. 根据两种单特征的 1D-OTSU 算法检测结果, 基于梯度信息的方法得到了更好的效果, 这一实验结果也验证了模型权重系数 β 计算理论的可靠性;

2) 本文算法的检测率较两种 1D-OTSU 算法分别提高了 7.14% 和 34.83%, 单位误报次数降低了 62.4% 和 70.9%, 这一实验结果也证明了本文的融合模型在参考了更多能够表征图像边缘的特征信息后, 检测的有效性获得显著提升;

3) 由于筒扫图像色阶呈渐进式变化不存在目标概念, 因此主动轮廓 Snake 算法无法精确定位到异常区域的边缘, 这与引言文献中的理论分析一致; 区域生长算法的检测性能由于过度依赖初始生长种子坐标的位置, 自适应能力较差. 实验结果显示本文所提方法的检测率较这两种方法分别提高 42.8% 和 30.4%, 单位误报次数分别降低 73.4% 和 49.1%.

由 3.4 节分析可知, 实际应用场景复杂, 因此针对粉尘遮染问题以及环境湿度过大问题分别进行模拟了两种图像噪声进行模拟实验: 其中, 椒盐噪声信噪比 NSR=0.15, 高斯噪声方差为 g_{dmax} 的 10%, 同

时将 σ_r^2 上调至 180, 综合实验结果与典型结果分别如表 4、图 5 所示.

表 4 不确定性因素鲁棒性实验结果

不同方法	$q_1(\%)$	q_2
无噪声情况	90.23	0.203
噪声 1: 椒盐噪声	81.20	0.368
噪声 2: 高斯噪声	83.45	0.315




图 5 (a) 噪声 1 原始图像 (b) 噪声 1 无滤波检测结果 (c) 噪声 1 本文方法检测结果 (d) 噪声 2 原始图像 (e) 噪声 2 无滤波检测结果 (f) 噪声 2 本文方法检测结果

模拟噪声实验发现, 在不添加滤波环节时, 所提方法的检测功能无法正常工作, 如图 5(b)(e) 所示; 添加滤波环节后, 对比图 5(c)(f) 与图 4(f) 能够发现, 虽然方法对异常区域边缘定位的精准程度出现下降, 但依旧能够检测到相关异常工况, 这与 3.4 节中的理论分析一致. 表 4 实验结果显示, 噪信比为 0.15 的椒盐噪声和方差为 $0.1g_{dmax}$ 的高斯噪声会使检测率稍有下降以及单位误报次数上升, 但依旧具备较好的检测性能.

4 结论

针对目前回转窑异常工况识别的迫切需求和对筒扫图像的研究和应用尚未成熟的现状, 本文利用水泥现场的回转窑筒扫红外图像, 结合图像灰度梯度以及局部灰度标准差特征数据, 提出了一种基于 2D-OTSU 图像边缘检测的回转窑异常工况识别方法. 通过对比试验证明相比于其它四种图像异常工况的检测方法, 本文提出的方法具有更高的检测率以及更低的单位误报次数, 能够有效检测出回转窑中掉窑皮、结窑皮等工况, 并具备应对复杂环境下不确定性噪声的能力.

本文算法依托图像边缘检测技术完成了对两类工况的实时化、自动化、智能化识别. 该方法无需设置分割阈值具备自适应的特点, 能够避免传统方法 (人工观察关键过程变量) 存在的主观因素以及过程系统时滞因素造成的影响. 综合本文若干实验结果可以得出结论, 本文方法具备可行性、有效性和鲁棒性, 原始数据源于筒扫红外图像, 能够广泛适用于安装筒扫设备的水泥生产企业, 具备一定的工程适

用性. 可以助力水泥窑炉煅烧过程智能优化制造. 本研究后续的展望为提高对回转窑核心反应区域边缘, 即深蓝色区域边缘出现的异常工况的识别能力, 进一步提高检测率.

参考文献 (References)

- [1] 高彦. 窑筒体温度图像在线监测系统研究 [D]. 西北工业大学, 2006.
(Gao Y, Research on online monitoring system of kiln temperature image[D]. Northwest Polytechnic University, 2006.)
- [2] Qian F, Zhong W M, Du W L. Fundamental Theories and Key Technologies for Smart and Optimal Manufacturing in the Process Industry[J]. Engineering, 2017, 3(2): 154-160.
- [3] 刘强. 基于红外测温的水泥回转窑状态监测系统研究 [D]. 上海交通大学, 2012.
(Liu Q, The Research on State Monitoring System for Rotary Cement Kiln Based on Infrared Temperature-Measurement[D]. Shanghai Jiao Tong University, 2012)
- [4] Ning F, Yu H, Lu S, et al. Study on Recognition of Thermal Efficiency Operating Conditions of Cement Rotary Kiln Based on K-means[C].2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). IEEE, 2019: 1-5.
- [5] Chen K, Wang J, Li W, et al. Simulated feedback mechanism-based rotary kiln burning state cognition intelligence method[J]. IEEE Access, 2017, 5: 4458-4469.
- [6] 周晓杰, 蔡元强, 夏克江, 等. 基于火焰图像显著区域特征学习与分类器融合的回转窑烧结工况识别 [J]. 控制与决策, 2017 (1): 187-192.
(Zhou X J, Cai Y Q, Xia K J, etc. Burning state recognition for rotary kiln sintering process based on burning salient zone image feature learning and classifiers fusion[J]. Control and Decision, 2017 (1): 187-192.)
- [7] Morocho V, Colina-Morles E, Bautista S, et al. Analysis of thermographic patterns using Open CV case study: A clinker kiln[C].2015 12th International Conference on Informatics in Control, Automation and Robotics (ICINCO). IEEE, 2015, 2: 479-484.
- [8] Yang M C, Sun T Y. Preliminary study on HHT-based refractory failure prediction for kiln shell[C].2016 IEEE International Conference on Industrial Technology (ICIT). IEEE, 2016: 968-972.
- [9] Wan M, Gu G, Qian W, et al. Hybrid active contour model based on edge gradients and regional multi-features for infrared image segmentation[J]. Optik, 2017, 140: 833-842.
- [10] 汤可宗, 柳炳祥, 徐洪焱, 等. 一种基于遗传算法的最小交叉熵阈值选择方法 [J]. 控制与决策, 2013(12):48-53+59.
(Tang K Z, Liu B X, Xu H Y, etc. A minimum cross entropy threshold selection method based on genetic algorithm[J]. Control and Decision, 2013(12):48-53+59.)
- [11] Rajinikanth V, Madhavaraja N, Satapathy S C, et al. Otsu's multi-thresholding and active contour snake model to segment dermoscopy images[J]. Journal of Medical Imaging and Health Informatics, 2017, 7(8): 1837-1840.
- [12] Xie S, Tu Z. Holistically-nested edge detection [C]. Proceedings of the IEEE international conference on computer vision. 2015: 1395-1403.
- [13] 焦安波, 何淼, 罗海波. 一种改进的 HED 网络及其在边缘检测中的应用 [J]. 红外技术, 2019, 41(1): 72-77.
(Jiao A B, He M, Luo H B. Research on Significant Edge Detection of Infrared Image Based on Deep Learning[J]. Infrared Technology, 2019, 41(1): 72-77.)
- [14] Liu Y, Cheng M M, Hu X, et al. Richer convolutional features for edge detection[C].Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 3000-3009.
- [15] Canny J. A computational approach to edge detection[J]. IEEE Transactions on pattern analysis and machine intelligence, 1986 (6): 679-698.
- [16] Santra S, Mandal S, Das K, et al. A Modified Canny Edge Detection Approach to Early Detection of Cancer Cell[C].2019 3rd International Conference on Electronics, Materials Engineering Nano-Technology (IEMENTech). IEEE, 2019: 1-5.
- [17] Dong L H , Zhao P B . Application of Improved Canny Edge Detection Algorithm in Coal-Rock Interface Recognition[J]. Applied Mechanics and Materials, 2012, 220-223:1279-1283.
- [18] Otsu N. A threshold selection method from gray-level histograms[J]. IEEE transactions on systems, man, and cybernetics, 1979, 9(1): 62-66.
- [19] Hao G, Min L, Feng H. Improved self-adaptive edge detection method based on Canny[C].2013 5th International Conference on Intelligent Human-Machine Systems and Cybernetics. IEEE, 2013, 2: 527-530.
- [20] Xiong C, Chen L, Pang Y. An adaptive bilateral filtering algorithm and its application in edge detection[C].2010 International Conference on Measuring Technology and Mechatronics Automation. IEEE, 2010, 1: 440-443.

作者简介

徐逸峰 (1996—), 男, 硕士生, 从事图像处理、水泥过程工况识别等研究, E-mail: y30180684@mail.ecust.edu.cn;
朱远明 (1986—), 男, 副教授, 从事工业过程的数据驱动控制等研究, E-mail: yuanmingzhu@ecust.edu.cn;
钟伟民 (1976—), 男, 教授, 博士生导师, 从事过程智能建模、控制与优化等研究, E-mail: wmzhong@ecust.edu.cn;
钱锋 (1961—), 男, 教授, 博士生导师, 从事化工过程系统运行智能控制等研究, E-mail: fqian@ecust.edu.cn.