

DOI:10.16410/j.issn1000-8365.2021.10.003

基于机器学习的铝合金铸锭夹杂物的定量检测方法

刘锦林, 杜群贵

(华南理工大学机械与汽车工程学院, 广东 广州 510640)

摘要:为解决人工检测铸造铝合金锭含渣量效率低、误差大的问题,在K模检测技术的基础上,提出基于机器学习的利用卷积神经网络和误差逆传播网络双网络结合的方式检测方法,实现对铸造铝合金锭含渣量定量化检测。首先利用卷积神经网络定性分析K模断面是否含渣,再利用误差逆传播网络和滑动窗口对K模断面进行特征提取和定量计算含渣量,最后利用非极大值抑制算法对检测结果进行优化和后处理。结果表明,利用卷积神经网络判断K模断面含渣与否的准确率为85.88%,能够较为准确地判断K模断面是否含渣以及计算K模断面的含渣量,满足生产实际的基本需求。

关键词:铝合金锭;含渣量检测;K模;卷积神经网络;误差逆传播算法

中图分类号: TG247

文献标识码: A

文章编号: 1000-8365(2021)10-0845-07

Quantitative Detection Method of Inclusion in Aluminum Alloy Ingots Based on Machine Learning

LIU Jinlin, DU Qungui

(School of Mechanical & Automotive Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: In order to solve the problems of low efficiency and large error in manual detection of Inclusion content in cast aluminum alloy ingot, based on k-mode detection technology, a detection method combining convolutional neural network and error reverse propagation network based on machine learning was proposed to realize quantitative detection of Inclusion content in cast aluminum alloy ingot. Firstly, the convolution neural network was used to qualitatively analyze whether the K-Die fracture surface contained Inclusion. Then, the backpropagation network and sliding window were used to extract features and calculate the Inclusion content quantitatively. Finally, the non-maximum suppression algorithm was used to optimize and post-process the detection results. The results show that the accuracy of the convolutional neural network is 85.88%, which can accurately judge whether the fracture surface of K-Die contains Inclusion and calculate the Inclusion content of the fracture surface of K-Die, so as to meet the basic requirements of actual production.

Key words: aluminum alloy ingot; slag content detection; K-mode; convolutional neural network; error back propagation algorithm

近年来,铝合金的应用趋于高精度、高质量、高性能化^[1-2],对铝材料提出了更高的要求。在生产过程中,铝原料的纯净度直接决定了铸件的质量,因此对铝合金锭含渣量进行准确地检测尤为重要。目前,对铝合金锭的含渣量检测方法主要有真空过滤法和K模检测技术等。前者效率低,后者主观性强,误差大。因此,对已有的检测手段进行改善显得非

常有必要。

为改善铝合金锭含渣量检测误差大、效率低的问题,本文对K模检测技术进行改进,利用机器学习实现铝合金锭含渣量的定量化检测。机器学习是用某些算法指导计算机从大量样本数据来建立适当的模型并不断完善,最终达到利用此模型对新的情境做出判断的过程。目前机器学习在缺陷检测上的应用层出不穷,如赵卫东等利用深度学习实现电表字符缺陷的检测^[3];许悦等利用机器学习实现铸件的表面缺陷检测^[4]。

受到以上研究启发,对K模检测技术进行改进,改进主要有如下两点:①利用机器学习来代替肉眼进行断面渣点计数;②利用批次断面渣点面积占比(含渣率)代替K值来评判原料含渣程度。

收稿日期: 2021-06-15

作者简介: 刘锦林(1996—),江西赣州人,硕士生,研究方向:机器学习及图像处理。电话: 15800951191,

Email: 1371174718@qq.com

通讯作者: 杜群贵(1965—),山东莱州人,博士,教授,研究方向:计算机仿真和机器学习。电话: 13922468938,

Email: ctqgdu@scut.edu.cn

1 K 模检测技术

K 模检测技术由袁晓东^[5]提出,其检测过程为:

(1)将铸造铝合金锭熔炼成铝汤浇铸得到样块,该样块称之为 K 模。

(2)将 K 模压断,统计 K 模断口的颗粒物,按照以下折算方法折算成大颗粒物:

大颗粒物(≥0.8 mm):1 颗折成 1;

中颗粒物(0.3~0.79 mm):5 颗折成大 1;

小颗粒物 (≤0.29 mm):100 颗以下忽略,100~299 颗折成中 1,300 颗以上折成大 1。

(3)将折算后的颗粒数进行 K 值计算,计算公式如下:

$$K \text{ 值} = \frac{\text{颗粒物总数(大+中+小)}}{\text{被统计块数}}$$

(4)根据 K 值判定铝合金锭纯净度,根据相应对策改善铝汤纯净度以保障产品质量。

K 模检测技术依靠肉眼进行大中小颗粒物进行分类和渣点计数,尽管有具体的直径范围,但是难以进行准确地量取,因此往往造成铝合金锭含渣量检测不够准确,且效率低。

2 含渣量检测系统设计

针对 K 模检测技术铝合金锭含渣量检测存在

的问题,设计了含渣量检测系统,该系统含硬件和软件两部分。硬件部分主要包含 CMOS(Complementary Metal Oxide Semiconductor)工业相机、LED(light emitting diode)环形光源、LED 背光源、USB(Universal Serial Bus)双路继电器、相机支架以及计算机等,如图 1 所示;软件部分主要包含软件算法以及图像用户界面(Graphical User Interface, GUI)如图 2 所示。

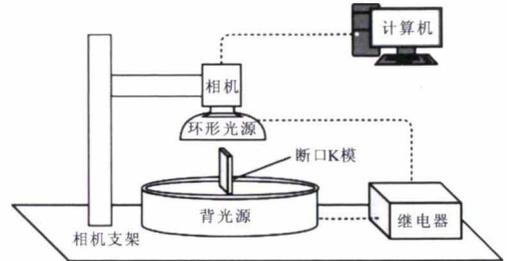


图 1 含渣量检测装置
Fig.1 Inclusion content detection device

采用的工业相机是 630 万像素的黑白相机,镜头为 16 mm 的定焦镜头,光源的自动开闭通过 USB 双路继电器控制,由计算机供电。软件开发语言为 Python,开发环境为 Windows10+Pycharm, GUI 可视化开发库为 PYQT5 库。

3 含渣量检测算法研究与结果分析

含渣量检测的总流程如图 3 所示。开启不同光

■ K模断口截面渣点检测系统

K模断口截面渣点检测系统

检测图像



BP+NMS检测结果图



目标掩模Mask图



渣点检测结果图



检测结果

Result: Unqualified

SpotRate: 6.24%

已检测截面个数: 1

不合格截面个数: 1

当前截面检测用时: 0.9856(s)

SpotRate Threshold: 0.02

控制面板

开始检测 重新检测

停止检测 保存结果

图 2 图像用户界面

Fig.2 Graphical user interface

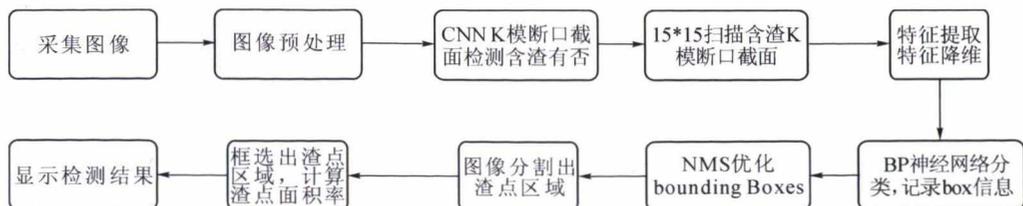


图 3 含渣量检测流程图

Fig.3 Flow chart of Inclusion content detection

源进行图像采集;图像预处理获得K模断面图像;利用卷积神经网络(Convolutional Neural Network, CNN)^[6]判断K模断面是否含渣,若不含渣直接结束检测返回结果,若含渣则进行下一步;利用滑动窗口技术以一定步长按行扫描K模断面,对每一步扫描的窗口图像进行特征提取,将特征向量输入误差后向传播(Error Back-Propagation, BP)^[7]神经网络进行渣点窗口与否判断,若是渣点窗口,渣点窗口总数加1,若不是则继续扫描,直到扫描完整个断面,记录渣点窗口信息;对断面扫描检测结果进行后处理,主要包含利用非极大值抑制算法(Non-Maximum Suppression, NMS)^[8]剔除大面积重叠的渣点窗口、统计最终渣点窗口数并计算含渣率、根据渣点窗口得到渣点区域蒙版Mask、根据Mask利用最小外接矩形得到各个渣点区域的具体位置;最后将渣点检测结果以及检测图像显示在GUI上。

3.1 图像预处理

图像预处理主要包含图像分割、图像滤波和数据增强等。其主要目的是消除图像中与检测无关的冗余信息,便于提取特征和提高检测的准确性与可靠性。

3.1.1 图像分割

单独采用条形光照明,表面凸起背光处出现低灰度值阴影,不利于后续的渣点检测;单独采用环形光照明虽然解决了上述问题,但由于背景复杂,不易于分割,给后续检测带来麻烦。为了解决上述问题,采用背光源和环形光源相结合的方式

进行照明。

具体步骤如下:
Step1:开启环形光源,关闭背光源,相机采集环形光源图像如图4(a)所示。

Step2:关闭环形光源,开启背光源,相机采集背光源图像如图4(b)所示。



(e)最终K模断面图

图4 图像分割过程

Fig.4 The process of Image segmentations

Step3:采用大津法(OSTU)对图4(b)进行阈值分割得到二值图如图4(c)所示。OSTU算法^[9-10]的主要思想:遍历0-255作为阈值T,分别计算低于T和高于T图像像素集合的方差,然后将使下式最小的值作为最终阈值。相应关系式为:

$$\sigma_w^2 = w_2(t)\sigma_1^2 + w_2(t)\sigma_2^2$$

其中,σ_w表示最小化优化目标,σ₁表示低于T的像素集合的方差,σ₂高于T的像素集合的方差,w₂(t)和w₁(t)分别是对应的权重,一般设置为1。

Step4:利用图4(c)来对图4(a)进行图像分割,得到如图4(d)所示的纯背景断面图。

假设图4(a)的像素值为x₁,图4(c)的像素为x₃,图4(d)的像素为x₄则x₄和x₁,x₃的关系式如下:

$$x_4 = \begin{cases} x_1, & x_3 = 0 \\ 255, & x_3 = 255 \end{cases}$$

Step5:采用最小外接矩形将断面从图4(d)中裁剪出来,得到如图4(e)所示的最终K模断面图。

3.1.2 图像滤波与数据增强

采用高斯低通滤波进行图像滤波,保证滤波效果良好的同时不会损坏图像的细节特征。二维高斯函数^[4]如下面公式所示:

$$g(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

数据增强主要针对小样本数据集,因为含渣K模断面样本少,而机器学习需要一定量的样本进行训练,因此采用翻转、裁剪、加噪等多种方式^[11],对图像进行数据增强。含渣K模断面样本称之为正样本,不含渣K模断面样本称之为负样本。原始数据集为85张,其中正样本52张,负样本33张,通过数据增强将85张图像扩充为935张。935张数据集按7:3:1的比例分为训练集、验证集和测试集,其中各个数据集中的正负样本比例均一致,且样本具有随机性。

3.2 基于 CNN 卷积神经网络的 K 模断面含渣与否判断

3.2.1 CNN 卷积神经网络结构

卷积神经网络是一种前馈性神经网络,其构成主要包含卷积层、池化层、激活层、全连接层,是一种端对端的网络,典型的 CNN 网络有 Lenet5^[12-13]和 Alexnet^[14]。本文采用的 CNN 结构如图 5 所示,主要

对 K 模断面是否含渣进行判断。

3.2.2 CNN 卷积神经网络的训练与结果分析

CNN 卷积神经网络训练结果优劣主要通过混淆矩阵^[15]、查全率、召回率、F1 得分和准确率等指标进行评判。混淆矩阵的形式以及相关术语定义如图 6 所示。

查全率 (precision)、召回率 (recall)、F1 得分

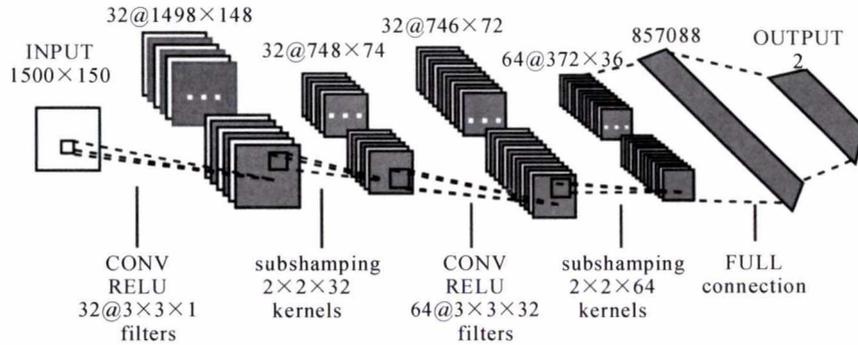


图 5 CNN 网络结构

Fig.5 CNN network structure

	Actual	0	1
Predict	0	TN	FN
	1	FP	TP

图 6 混淆矩阵

Fig.6 Confusion matrix

混淆矩阵
Confusion Matrix

True Positive(TP):真阳性
True Negative(TN):真阴性
False Positive(FP):假阳性
False Negative(FN):假阴性

(F1-score)以及准确率(accuracy)的表达式如下所示:

$$\text{precision} = \frac{TP}{TP+FP}$$

$$\text{recall} = \frac{TP}{TP+FN}$$

$$F1_score = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

$$\text{accuracy} = \frac{TP+TN}{TP+TN+FP+FN}$$

CNN 卷积神经网络的输入是图 4 (e) 所示图像,输入后图像尺寸被统一缩放为 1 500×150,输出格式为 one-hot 格式^[16],取概率最大的类别作为输出类别。将 850 张图像(628 张训练集和 212 张验证集)输入 CNN 进行训练,其中正样本 520 张,负样本 330 张。经过 20 轮迭代训练,误差降到预期的 0.02 以下。

为了保证含渣检测的准确性,应使 FN 尽可能地小,避免含渣断面被错误过滤掉。记 CNN 输出断面不含渣概率为 p_1 ,含渣概率为 p_2 ,只有当 p_1 大于 p_2 超过 α 时才将 K 模断面判定为不含渣。区别于以最大概率的类别作为最终类别的判断方法,判断方法如下式(取 $\alpha=0.3$):

$$\text{断面含渣与否:} \begin{cases} p_2 > p_1, \text{ 断面含渣} \\ p_1 - p_2 \geq \alpha, \text{ 断面不含渣} \end{cases}$$

取 85 张测试集中的图像进行 K 模断面含渣与否判断,其中 52 张正样本,33 张负样本。最终两种判别方法下 CNN 检测结果的各项指标对比如表 1 所示。由表 1 可知,断面含渣与否判断,最大值法准确率为 82.35%,本文提出的判别方法准确率为 85.88%,提高了 3.53%,因此,提出的判别方法是合理有效的。

3.3 基于 BP 神经网络的窗口渣点与否判断

3.3.1 特征提取

特征提取就是从渣点窗口中提取出信息,然后利用这些信息去描述渣点窗口,这些提取出来的信息就被称之为特征。共选取灰度特征、不变矩特征、LBP 特征和灰度共生矩阵特征^[17]中的 94 个特征,部分样本特征参数如表 2 所示(样本编号 1~3 为渣点窗口,4~6 为非渣点窗口)。

表 1 两种判别方法下 CNN 检测结果的各项指标对比

Tab.1 Comparison of indicators of CNN detection results under the two methods

判别方法	真阳性(TP)		真阴性(TN)		假阳性(FP)		假阴性(FN)		查全率	召回率	F1 得分	准确率
	个数	比例	个数	比例	个数	比例	个数	比例				
最大值法	47	55.29%	23	27.06%	10	12.76%	5	4.89%	82.46%	90.38%	86.24%	82.35%
本文方法	52	61.18%	21	24.71%	12	14.11%	0	0.00%	81.25%	100.00%	89.66%	85.88%

表2 部分样本特征参数
Tab.2 Part of the sample characteristic parameters

样本	灰度平均值	灰度方差	能量	灰度对比度
1	61.351 1	217.516 7	4.890 0	63
2	51.511 1	53.893 2	4.650 0	48
3	56.453 3	194.060 0	6.500 0	63
4	113.462 2	87.928 5	7.070 0	45
5	109.204 4	611.193 8	9.670 0	129
6	109.751 1	348.640 3	7.840 0	88

3.3.2 BP神经网络设计

BP神经网络^[7]是对生物神经网络模拟,由大量的神经元组成,具有并行分布结构。通过误差的反向传播不断修正网络的权值系数和偏置系数从而得到合理的模型。它由输入层、隐层、输出层三部分构成,隐层可扩展至多层。输入层节点数为94和提取的特征数一致,输出层节点数为1和缺陷类别数一致(只研究渣点一种缺陷)。隐层设置为1层,其节点数按照 $n = \sqrt{n_0 + n_1} + \alpha$ ^[18]确定(其中n为隐层节点数, n_0 为输入层节点数, n_1 为输出层节点数, α 为0~10的常数),最终确定隐层节点数为10,具体BP网络结构如图7所示。BP前向传播表达式如下:

$$\text{label} = \begin{cases} 0, & \phi(w_2 \times \phi(w_1 \times X + b_1) + b_2) < 0.5 \\ 1, & \phi(w_2 \times \phi(w_1 \times X + b_1) + b_2) \geq 0.5 \end{cases}$$

其中, ϕ 表示的是激活函数,一般是sigmoid函数,其它参数含义见图7。

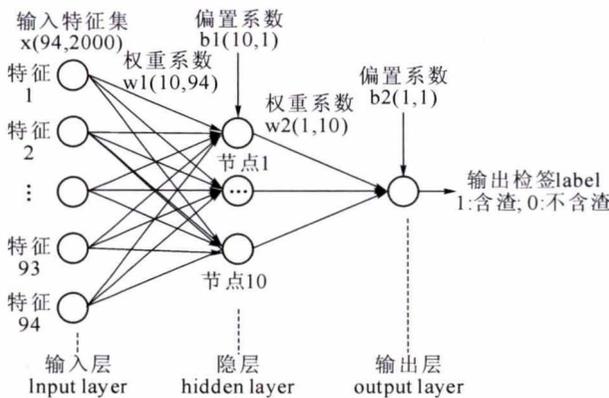


图7 BP神经网络
Fig.7 BP neural network

3.3.3 BP神经网络的训练与分类结果

从测试集的85张图像中随机裁剪3000张15*15大小的图像,按1:1分成训练集和测试集。规定渣点窗口为正样本,非渣点窗口为负样本,其中正负样本比例为1:1。将1500张训练图片进行特征提取后输入到BP中进行1000轮的迭代训练,误差降至0.01以内。再取剩余的1500张图像进行测试,同时利用支持向量机(Support vector machine, SVM)进行测试对比,测试结果如表3所示。

表3 BP神经网络与SVM检测结果对比
Tab.3 Comparison of detection results between BP neural network and SVM

模型	样本数/个	识别数/个	准确率(%)	平均用时/s
SVM	1 500	1 451	96.733 5	0.325 9
BP	1 500	1 470	97.983 0	0.324 2

由表3可以看出,BP神经网络窗口渣点与否判断的正确率可达97.9830%,比SVM高出1.2495%,两者在检测时间上不相上下,因此BP优于SVM。

3.4 含渣缺陷检测结果后处理

3.4.1 NMS非极大值抑制算法

利用滑动窗口技术,用长宽一致的窗口对含渣断面以一定的步长按行扫描,每一步扫描的窗口图像先进行特征提取,将特征向量输入到BP神经网络中进而判断窗口是否为渣点。为了保证不漏检,扫描步长应小于窗口尺寸。记录渣点窗口的左上角坐标、右下角坐标、得分score和标签label。滑动窗口尺寸为15*15,扫描步长为5。BP遍历完含渣断面后,根据记录的渣点窗口信息在断面上绘制出窗口。部分检测结果如图8所示。

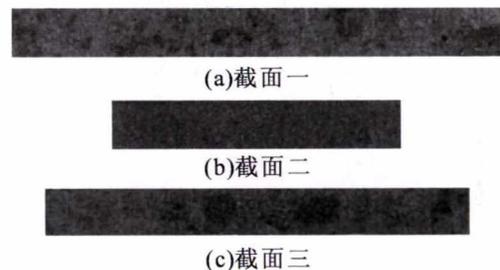


图8 渣点区域检测结果图
Fig.8 Detection results of Inclusion point area

由图8可知,含渣区域能够被准确地定位识别,但存在大面积重叠的渣点窗口,导致渣点窗口的数量严重偏差,影响含渣率的准确性,甚至出现含渣率大于1的情况。为了解决这个问题,采用深度学习中常用的NMS算法对检测结果进一步优化。NMS算法^[9]主要思路为选取score值大的渣点窗口,然后剔除与之重叠面积超过阈值 θ 的渣点窗口(本文阈值 θ 为0.1),如此循环,不存在重叠面积大于阈值的两个渣点窗口时循环结束。经NMS算法优化后部分结果如图9所示,剔除了大面积重叠的渣点窗口,优化了检测结果。渣点窗口覆盖区域更加地接近于含渣实际区域。

3.4.2 含渣率计算及结果分析

经NMS算法优化后,统计剩余渣点窗口的个数,进行断面含渣率的计算。记K模断面含渣率为spotRate,含渣率计算表达式如下所示:

$$\text{spotRate} = \frac{\text{numSpotWindow} \times 15 \times 15}{\text{height} \times \text{width} \times 100} (\%)$$

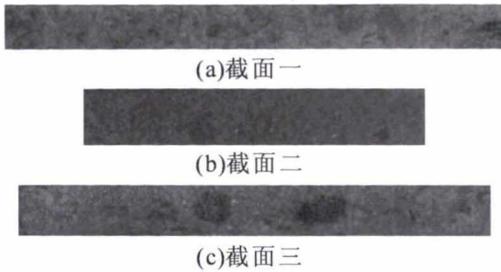


图 9 NMS 优化后的渣点区域检测结果图
Fig.9 Detection results of Inclusion point area after NMS optimization

其中,numSpotWindow 表示渣点窗口个数,15 表示滑动窗口的大小,height 表示 K 模断面图像的高,width 表示 K 模断面图像图像的宽。部分样本含渣率计算结果如表 4 所示,设置一个含渣率上限 β ,当含渣率大于 β 时,判定断面不合格,否则判定为合格。

对 NMS 优化的结果图进行二值化,二值化规则为:渣点窗口内像素值置为 255,其余像素值置为 0。白色区域即为含渣区域,二值化结果如图 10

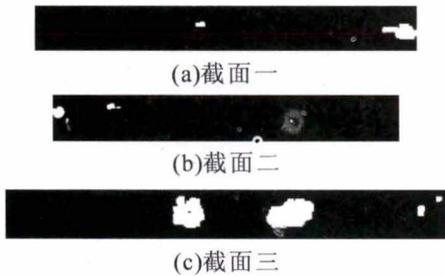


图 10 渣点区域 Mask 图
Fig.10 Mask images of spot area

表 4 部分样本含渣率计算与合格性判断结果
Tab.4 Calculation of Inclusion content in some samples and qualification judgment results

样本编号	1	2	3	4	5	6	7	8
含渣率	0.18%	0.69%	1.66 %	0.66%	0.23%	1.03%	0.74%	0.58%
合格与否($\beta=1\%$)	合格	合格	不合格	合格	合格	不合格	合格	合格

4 总结

主要介绍了一种基于机器学习的铝合金锭含渣量的定量检测方法,实验结果表明该检测方法能够实现对铝合金锭含渣量的定量检测,并且完成单断面面的渣点计数与含渣率计算,能够满足生产实际的基本需求。主要研究工作、创新点和期望具体如下所示:

(1)搭建了一套完整的铝合金锭含渣量定量检测系统。

(2)采用 USB 双路继电器光源进行照明,实现前背景分割。

(3)利用 CNN 对 K 模断面面含渣与否进行判断,采用差值的方式替代最大值法来决定 CNN 最

所示。

最后根据渣点区域 Mask 图计算含渣区域的最小外接矩形,并绘制在图 4(e)所示的 K 模断面图像中,以实现含渣区域的定位以及计数,一个含渣区域计为一个渣点,最后将检测结果和相关数据呈现在 GUI 上,具体可见图 2。部分结果如图 11 所示。

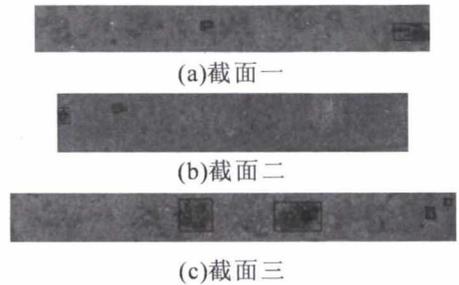


图 11 渣点检测结果图
Fig.11 Final results of spot detection

3.4.3 铸造铝合金锭含渣量判定

铝合金锭含渣量利用批次断面面含渣率均值 (spotRate_Mean) 进行表示,按照下式进行计算:

$$\text{spotRate_Mean} = \frac{\sum_{i=1}^n \text{spotRate}_i}{n}$$

其中,n 表示被检测 K 模断面面个数 ($n \geq 20$),spotRate_i 表示第 i 个 K 模断面面含渣率。

根据 spotRate_Mean 值和判定准则进行铸造铝合金含渣量的判定,本文判定准则比较简单,n 当 spotRate_Mean 值超过 2% 时即判定当前批次的铝合金锭不合格,纯净度不达标。

终的预测结果,准确率提升 3.53%,达到 85.88%。

(4)利用 BP 神经网络和滑动窗口技术结合的方式来对 K 模断面面进行逐窗口渣点检测判断,BP 神经网络窗口渣点与否判断正确率可达 97.983 0%。

(5)采用 NMS 算法对含渣检测结果进行优化,使断面含渣率计算更加准确。

(6)采用批次 K 模断面含渣率均值来取代 K 值进行铝合金锭含渣量的判定。

(7)对铸造铝合金含渣量的判定准则,后期有待进一步地进行细化。

参考文献:

[1] 刘雨蒙,马广鑫.中国铝资源行业现状研究及发展建议[J].中国矿业,2016,25(8):53-7.

- [2] 乔东,程书建,邱立宝. 铝合金熔体含渣量检测技术综述[J]. 铸造技术, 2018, 39(01): 246-8.
- [3] 赵卫东,陈凤,黄汉成,等. 基于深度学习的电表字符缺陷检测方法[J]. 安徽工业大学学报(自然科学版), 2021, 38(1): 76-81.
- [4] 许悦. 基于机器视觉的铸件表面缺陷检测研究[D]. 镇江: 江苏大学, 2019.
- [5] 袁晓东. 再生铝合金锭含渣量的定量检测方法 -K 模检测[C]// 绿色铸造与持续发展——2015(第 25 届)重庆市铸造年会. 中国重庆, F, 2015.
- [6] FUKUSHIMA K. Neocognitron: a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position [J]. Biological cybernetics, 1980, 36(4): 193-202.
- [7] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition [J]. Neural Computation, 1989, 1(4): 541-51.
- [8] FANG C, JAN M, JENS M, et al. Efficient non-maximum suppression [J]. Current Directions in Biomedical Engineering, 2018, 4(1): 555-558.
- [9] 覃晓,元昌安,邓育林,等. 一种改进的 Ostu 图像分割法 [J]. 山西大学学报(自然科学版), 2013, 36(4): 530-534.
- [10] OTSU N. A threshold selection method from gray-level histograms [J]. IEEE Transactions on Systems, Man and Cybernetics, 1979, SMC-9(1): 62-6.
- [11] 王云艳,周志刚,罗帅. 基于数据增强的太阳能电池片缺陷检测 [J]. 电子测量与仪器学报, 2021, 35(1): 26-32.
- [12] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the Ieee, 1998, 86(11): 2278-324.
- [13] NAIGONG Y, PANNA J, YULING Z. Handwritten digits recognition base on improved LeNet5 [C]. 2015 27 th Chinese Control and Decision Conference (CCDC), 2015: 4871-5.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet Classification with Deep Convolutional Neural Networks [J]. Communications of the Acm, 2017, 60(6): 84-90.
- [15] 钟跃崎,郭腾伟,路凯,等. 基于深度卷积神经网络的极相似动物纤维自动识别技术[J]. 毛纺科技, 2021, 49(5): 86-91.
- [16] OKADA S, OHZEKI M, TAGUCHI S. Efficient partition of integer optimization problems with one-hot encoding [J]. Scientific Reports, 2019, 9 (2):671-680.
- [17] 杨娟. 基于机器视觉的铸坯表面缺陷检测算法研究 [D]. 武汉: 华中科技大学, 2013.
- [18] 顾寄南,唐良颖,许悦,等. 机器视觉在网片缺陷检测与分类中的应用 [J]. 机械设计与制造, 2019(S1): 47-49, 53.

《特种铸造及有色合金》征订启事

期刊简介:《特种铸造及有色合金》杂志,是中国科学技术协会主管,中国机械工程学会铸造分会和武汉机械工艺研究所主办的中文核心期刊,为国内外权威数据库及检索系统收录,并荣获全国优秀科技期刊一等奖、国家期刊奖和新中国 60 年有影响力的期刊。

主要内容:各种特种铸造方法,如:熔模铸造、压力铸造、半固态铸造、金属型铸造、离心铸造、连续铸造、壳型铸造、消失模铸造(实型铸造)及电磁铸造等方面的理论、工艺、设备、造型材料、测试与控制、计算机应用技术等;各种有色合金及复合材料(包括新能源材料、高熵合金、非晶合金等)的熔炼和铸造工艺、凝固理论、测试与控制、计算机应用等方面的科研成果及生产经验,并介绍上述内容的国内外发展动向和学术、技术交流活动消息等。

期刊订阅:本刊为月刊,邮发代号 38-109,20 元/期,全年 12 期,共 240 元,邮局可订,平邮免邮费。电子版《特种铸造及有色合金》杂志与纸质版同步发行,每期定价 15 元,全年(12 期)优惠价 120 元(往年优惠价 100 元)。另有往年合订本、年会专刊、光盘等可向本刊编辑部邮购。

压铸、精铸等行业重要的技术参考!

联系方式:

地址:武汉市江岸区江大路 26 号(430019)

电话:027-85358206/85486024/85358127(传真)

邮箱: tzzz@special-cast.com 网址: www.special-cast.com

