

基于集成学习的铸件缺陷识别方法*

林庭武¹, 罗坤宇², 常建涛², 程 涵², 冯世杰²

(1. 中兴通讯股份有限公司, 陕西 西安 710065; 2. 西安电子科技大学, 陕西 西安 710071)

摘要: 针对铸件图像噪声多和对比度不足引起的缺陷识别困难的问题, 文中提出了一种基于集成学习的铸件缺陷识别方法。首先, 该方法采用灰度变换法、双边滤波以及自适应图像分割法对铸件图像进行预处理。然后, 通过提取方向梯度直方图 (Histogram of Oriented Gradients, HOG) 特征、不变矩特征和局部二值模式 (Local Binary Pattern, LBP) 纹理特征构建全信息特征集, 并结合支持向量机递归特征消除 (Support Vector Machine - Recursive Feature Elimination, SVM-RFE) 算法筛选铸件缺陷敏感特征。最后, 利用 Adaboost-RF (Adaptive Boosting - Random Forest) 方法构建铸件缺陷识别模型。对比实验结果表明, 该模型不仅可以有效提取缺陷敏感特征, 而且相较于其他分类器具有更好的分类性能和泛化能力。

关键词: 缺陷识别; 特征提取; SVM-RFE; Adaboost-RF; 集成学习

中图分类号: TG115.28 文献标识码: A 文章编号: 1008-5300(2020)05-0055-07

Casting Defect Recognition Method Based on Ensemble Learning

LIN Tingwu¹, LUO Kunyu², CHANG Jiantao², CHENG Han², FENG Shijie²

(1. ZTE Corporation, Xi'an 710065, China; 2. Xidian University, Xi'an 710071, China)

Abstract: Aiming at the difficulty in identifying defects caused by excessive noise and insufficient contrast in casting images, a method for identifying defects in castings based on ensemble learning is proposed in this paper. At first, grayscale transformation, bilateral filtering and adaptive image segmentation are employed to preprocess the casting image. Then, the HOG (Histogram of Oriented Gradients) feature, moment invariant feature, and LBP (Local Binary Pattern) texture feature are extracted to construct the full-information feature set. Meanwhile, the SVM-RFE (Support Vector Machine - Recursive Feature Elimination) algorithm is utilized to select sensitive features. In the end, the Adaboost-RF (Adaptive Boosting - Random Forest) method is used to recognize the casting defect. The results of the comparison experiment show that this method can effectively extract the sensitive features from the full-information feature set. Moreover, it has better classification performance and generalization ability than other classifiers.

Key words: defect recognition; feature extraction; SVM-RFE; Adaboost-RF; ensemble learning

引 言

铸造产品由于质量轻、机械性能好等特点, 已经在制造生产领域得到广泛运用。但是因为铸造工艺、生产条件等问题的制约, 铸件在生产过程中容易产生对产品质量有较大影响的缺陷^[1], 如气孔、夹渣、偏析和裂纹等。这些缺陷在生产和使用中会进一步发展成疲劳裂纹或应力腐蚀裂纹, 从而导致产品失效, 造成重大安全隐患。因此, 准确识别铸件产品的缺陷对产品的安全生产和使用至关重要。

目前, 铸件缺陷的检测主要依靠无损检测技术。

无损检测技术主要包括超声波检测法、磁粉检测法和 X 射线检测法等。磁粉检测法可以直观呈现出缺陷的形状、大小和位置^[2]。超声波检测法利用超声波实现缺陷检测。然而, 这两种方法对材料性质和结构具有一定的限制。X 射线检测法具有穿透力强、不受材料外形与结构影响等特点, 已经广泛运用于工业领域的无损探伤中^[3]。

随着工业信息物理系统 (Cyber-Physical System, CPS) 技术^[4] 和互联网技术的快速发展, 智慧工厂^[5] 中的机器视觉感知技术应用条件逐渐成熟。铸造产品的缺陷检测目前主要采用基于数据驱动的产

* 收稿日期: 2020-08-11

基金项目: 陕西省重点研发计划项目 (2020ZDLGY07-08); 国家自然科学基金资助项目 (51875432, 51505357)

品缺陷自动识别技术, 主要包括图像预处理、图像分割、特征提取、分类器构建4个阶段^[6]。工业现场采集的图像通常包含噪声, 因此首先通过图像预处理改善图像质量^[7-8]。随后, 在此基础上, 运用图像分割技术将图像分解成若干个互不交叠的区域, 每个区域内部, 某种特征相同或接近, 而不同区域则有明显差别^[9-10]。文献[11]利用缺陷边缘的分形特性从铸件边缘线图中确定缺陷的边缘线, 以聚类方法将缺陷边缘线聚集的区域分割出来。

在特征提取阶段, 通过统计法、信号处理法和模型法等特征提取技术从图像中提取具有区分性的缺陷特征, 用于后续的建模分析。文献[12]对带钢缺陷进行形状和纹理特征的提取, 获得了针对性强、准确度高的特征。文献[13]针对轮胎缺陷复杂多样难以用预先定义固定不变的基函数表达缺陷特征的问题, 提出了一种自适应生成基函数的特征提取算法。文献[14]采用 Gabor 滤波方法有效提取了试件表面缺陷特征。文献[15]采用主成分分析(Principal Component Analysis, PCA)方法提取了3种具有复杂外形的轧钢表面缺陷特征。

在分类器构建阶段, 利用提取的图像特征对分类器进行训练, 进而有效识别图像缺陷。目前常用的分类器算法主要包括神经网络、支持向量机(Support Vector Machine, SVM)和随机森林(Random Forest, RF)等。文献[16]采用基于PCA和SVM的方法对典型冷轧带钢表面缺陷进行识别, 对带钢表面的几种缺陷都具有很高的识别率。文献[17]提出一种基于RF的激光超声金属表面缺陷识别方法, 该方法利用RF有效提高了金属表面缺陷识别准确率。文献[18]利用神经网络构建产品缺陷分类器, 有效提高了缺陷识别的准确率。

如今, 众多学者通过研究先进的特征提取技术和模式识别方法, 在金属、冷轧带钢以及焊缝等典型产品的缺陷自动识别方面取得了很大的成果。然而, 在铸件缺陷识别方面还存在一些困难亟待解决。一方面, 由于铸件缺陷的多样性, 需要丰富图像特征表征铸件缺陷, 然而, 过多的无效特征会给模型的精度带来影响; 另一方面, 单一分类器的性能主要取决于训练数据特性, 性能稳定性差, 泛化能力较弱。因此, 本文提出了一种基于集成学习的铸件缺陷识别方法。利用支持向量机递归特征消除(Support Vector Machine-Recursive Feature Elimination, SVM-RFE)技术从多类缺陷特征中提取敏感特征, 结合集成

学习思想融合多个基分类器的分类结果, 提高铸件缺陷识别模型的性能和鲁棒性。

1 缺陷识别

基于 SVM-RFE 和 Adaboost-RF (Adaptive Boosting - Random Forest) 的铸件缺陷自动识别技术的具体实现流程如图1所示。首先, 对工业现场 X 射线检测的铸件缺陷图像进行图像预处理与分割, 采用灰度变换去除图像中无关的颜色信息同时减少了处理数据量, 结合双边滤波去除图像中的噪声, 利用自适应阈值分割凸显缺陷信息。然后, 采用 HOG 特征、不变矩特征以及局部二值模式(Local Binary Pattern, LBP) 纹理特征的提取方法多角度提取图像特征, 构建全信息特征集, 并结合 SVM-RFE 算法对全信息特征集中的特征进行评价筛选, 获得敏感特征集。最后, 利用敏感特征集训练 Adaboost-RF 模型从而构建铸件缺陷识别模型。不同的铸件图像经过预处理与分割及特征提取与筛选处理后, 输入铸件缺陷识别模型, 最后由模型自动划分铸件状态, 从而实现

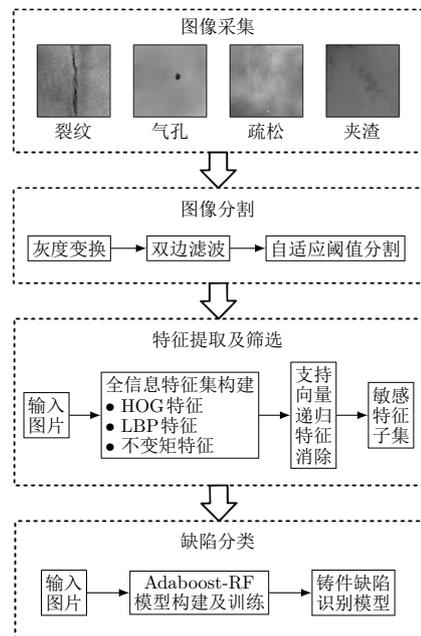


图1 本文方法流程图

1.1 图像预处理与分割

工业现场的铸件图像受环境和采集过程影响, 常常包含大量噪声或者图像对比度不足。因此, 需要对铸件图像进行预处理, 提高图像质量, 并采用图像分割技术将铸件缺陷凸显出来, 为后续建模分析提供良好的数据资源。

首先, 通过灰度变换对铸件图像进行线性灰度变换处理, 减少图像曝光度不足或者过度的问题。灰度变换公式为:

$$O(h, w) = I(h, w)T(h, w) + b, \quad (1)$$

$$(0 \leq h < H, 0 \leq w < W)$$

式中: I 表示原始输入图像; O 表示变换后图像; W 和 H 分别为 I 的宽度和高度; T 表示转换矩阵图像; b 表示偏置值; h 、 w 为像素坐标。

灰度变换后, 图像中仍然存在一些噪声, 本文采用双边滤波方法降低噪声。双边滤波是一种具有良好边缘保持能力的非线性滤波。该方法能够有效滤除噪声并保留边缘信息。双边滤波的数学表达式为:

$$J(h, w) = O(h, w) \star W'(h, w) \quad (2)$$

式中: W' 表示权重模板; “ \star ” 表示卷积。

最后, 为凸出铸件图像中存在的缺陷, 采用自适应阈值分割法对铸件图像进行处理。自适应阈值分割法为每一个像素设置相应的阈值, 可以有效规避光照对图像分割法的影响。自适应阈值矩阵 $T'(h, w)$ 可由式 (3) 计算:

$$T'(h, w) = (1 - r)f_s(J(h, w)) \quad (3)$$

式中: f_s 为尺寸为 $H \times W$ 的平滑算子; r 一般取 0.15。进一步, 利用局部阈值分割规则对图像进行阈值分割。

$$O(h, w) = \begin{cases} 255 & J(h, w) < T'(h, w) \\ 0 & J(h, w) \geq T'(h, w) \end{cases} \quad (4)$$

1.2 特征提取与选择

为了进一步提取铸件缺陷区域的有效信息, 需要对预处理后的铸件图像提取敏感特征。由于单一特征无法充分表征铸件图像缺陷, 因此, 本文采用多种方法进行特征提取, 构成全信息特征集。同时, 为了进一步剔除无关特征对建模的影响, 提高建模分析效率, 降低特征维度, 采用 SVM-RFE 算法对全信息特征集中的特征进行评价, 结合筛选阈值构建敏感特征集, 用于后续建模分析。

铸件缺陷可通过 HOG 特征、不变矩特征以及 LBP 纹理特征进行表征, 各个特征提取过程如下所述。

1.2.1 HOG 特征

HOG 特征由 Dalal 和 Triggs 提出。HOG 特征通过计算图像梯度方向及其直方图来表示图像的局部特征。提取 HOG 特征时, 首先用 Gamma 方法对图像进行全局归一化, 并采用式 (5) 和式 (6) 计算梯度大小 $G(x, y)$ 和梯度方向 $\theta(x, y)$ [19]。

$$G(x, y) = \sqrt{G_x^2(x, y) + G_y^2(x, y)} \quad (5)$$

$$\theta(x, y) = \arctan \frac{G_y(x, y)}{G_x(x, y)} \quad (6)$$

式中: $G_x(x, y)$ 和 $G_y(x, y)$ 分别表示水平和垂直梯度。然后, 将图像分割为多个单元, 并统计每个单元的梯度直方图, 即可形成单元 HOG 特征。随后, 将单元组成块, 并对单元内的 HOG 特征进行串联和归一化, 构成块 HOG 特征。最后, 串联所有块 HOG 特征, 即可得到该图像的 HOG 特征。

1.2.2 不变矩特征

由于不变矩特征具有平移、灰度、尺度和旋转的不变性的性质, 因此, 可以利用不变矩特征的不对称特点表示铸件缺陷的形态特征。大小为 $M \times N$ 的数字图像 $f(x, y)$ 的二阶矩定义为:

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} x^p y^q f(x, y) \quad (7)$$

式中: $p = 0, 1, 2, \dots$; $q = 0, 1, 2, \dots$ 。

相应的 $p + q$ 阶中心矩定义为:

$$\mu_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (8)$$

式中: $p = 0, 1, 2, \dots$; $q = 0, 1, 2, \dots$; x 的均值 \bar{x} 和 y 的均值 \bar{y} 分别为:

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad (9)$$

$$\bar{y} = \frac{m_{01}}{m_{00}} \quad (10)$$

由二阶矩及三阶矩可以得出图像的 7 种不变矩特征 $[I_1 I_2 \dots I_7]$, 其中:

$$I_1 = \mu_{20} + \mu_{02}$$

$$I_2 = (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2$$

$$I_3 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - 3\mu_{03})^2$$

$$I_4 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - 3\mu_{03})^2$$

$$\begin{aligned}
I_5 &= (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12}) \cdot \\
&\quad [(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2] + \\
&\quad (3\mu_{21} - \mu_{03})(\mu_{03} + \mu_{21}) \cdot \\
&\quad [(\mu_{30} + \mu_{21})^2 - (\mu_{21} + \mu_{03})^2] \\
I_6 &= (\mu_{20} - \mu_{02}) \cdot \\
&\quad [(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] + \\
&\quad 4\mu_{11} [(\mu_{30} + \mu_{12})^2 (\mu_{21} + \mu_{03})] \\
I_7 &= (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12}) \cdot \\
&\quad [(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2] + \\
&\quad (3\mu_{21} - \mu_{03})(\mu_{03} + \mu_{21}) \cdot \\
&\quad [(\mu_{30} + \mu_{12})^2 - 3(\mu_{03} + \mu_{21})^2]
\end{aligned}$$

1.2.3 LBP 纹理特征

LBP 特征是一种具备旋转不变性和灰度不变性的图像局部纹理特征^[20]。LBP 特征的提取过程如下：

$$\text{LBP}(x_c, y_c) = \sum_{p=0}^{P-1} 2^p S(i_p - i_c) \quad (11)$$

式中： i_c 是图像坐标 (x_c, y_c) 处的灰度值； i_p 为 3×3 像素区域内除中心点位置外其他位置处的灰度值； P 为局部区域内像素个数； S 为阶跃函数。

采用铸件图像的 HOG 特征、不变矩特征以及 LBP 纹理特征 3 类特征组成铸件缺陷全信息特征集。然而，铸件缺陷全信息特征集包含图像的整体信息，其中必然包含冗余信息。冗余信息会影响后续分析建模的准确率。因此，本文采用 SVM-RFE 算法对特征进行评价，并结合筛选阈值选择合适的特征向量，实现对全信息特征集的降维操作，构建铸件缺陷敏感特征集。

SVM-RFE 是一种基于 SVM 最大间隔原理的序列后向选择算法^[21]。该算法在模型训练过程中对特征进行评价，获取特征得分 r' ，筛选并排除得分最低的特征，并用其余特征进行下一次训练，直到剩下特征数量满足筛选阈值为止。SVM 中求最大间隔距离的约束参数 w 的计算如式 (12) 所示，特征得分 r' 的计算如式 (13) 所示：

$$w = \sum_k a_k y'_k x'_k \quad (12)$$

$$r' = w^2 \quad (13)$$

式中： y' 为类标签； x' 为样本； a 为拉格朗日乘数。

1.3 基于 Adaboost-RF 的缺陷识别模型构建

利用敏感特征集训练分类器，构建铸件缺陷识别模型。RF 算法因其出色的性能而被广泛使用，算法主要由多个决策树构成，可以有效解决数据不平衡和非线性等问题。为了进一步提高 RF 算法的性能，本文将 RF 算法和 Adaboost 方法^[22] 进行有效结合，构建基于 Adaboost-RF 的铸件缺陷识别分类器。Adaboost-RF 算法可以通过增大错分样本的权值，减小正确分类样本的权值来产生新的样本分布，并将拥有新权值的数据集持续输入新的分类器，以产生更具针对性的分类器。结合投票法将所有分类器进行融合，从而实现 Adaboost-RF 的构建。算法实现步骤如下：

1) 从样本空间随机抽取 m 组数据充当训练数据， n 组数据作为测试数据，并初始化训练数据的分布权值 D_t ，

$$D_t(x) = \frac{1}{m} \quad (14)$$

式中： t 表示训练轮数，每一轮产生一个分类器； x 表示输入样本。

2) 对训练数据进行归一化处理，根据样本输入输出维数初始化 RF 参数。采用训练数据对 RF 进行训练，并将测试数据输入 RF 得到预测误差 e_t ，

$$e_t = \sum_i D_t(x_i)(y_i - g(x_i)), \quad (t = 1, 2, \dots, m) \quad (15)$$

式中： i 表示不同数据样本； $g(x)$ 为实际输出序列； y 为期望输出。

3) 计算各分类器的权重 α_t ，

$$\alpha_t = \frac{1}{2} \ln \frac{1 - e_t}{e_t} \quad (16)$$

4) 根据 α_t 调整下一轮训练样本的权重，调整公式为：

$$D_{t+1}(x) = \frac{D_t(x) \exp[-\alpha_t y g_t(x)]}{B_t}, \quad (17)$$

$$(t = 1, 2, \dots, m)$$

式中： B_t 是归一化因子，目的是在权重比例不变的情况下使权重分布和为 1； $g_t(x)$ 为每次获得的弱分类器 RF。

5) 由 T 组弱分类器函数 $g_t(x)$ 组合得到强分类函数 $H(x)$ ，

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t g_t(x) \right) \quad (18)$$

2 实验与结果分析

2.1 铸件图像处理

下面将通过一个工业案例对基于 SVM-RFE 和 Adaboost-RF 的铸件缺陷自动识别算法的性能进行验证。在某单位铸造生产线中, 由于工艺条件限制, 铸件产品易出现裂纹、偏析和气孔等缺陷。因此, 该单位采用 X 光检测机对成型铸件进行扫描和成像, 共收集到裂纹缺陷 14 张, 偏析缺陷 14 张, 气孔缺陷 14 张和无缺陷 23 张。各类型缺陷如图 2 所示。本文采用翻转、裁剪等方式对铸件图像数据集进行扩充, 相关数据信息如表 1 所示。

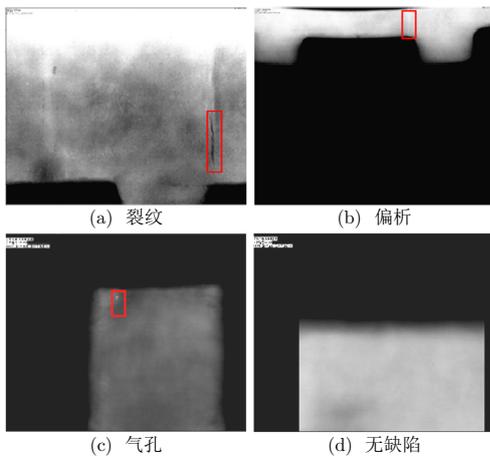


图 2 原始图像

表 1 采集铸件图像样本的数据量

样本类别	数据量	
	扩充前	扩充后
裂纹缺陷	14	112
偏析缺陷	14	112
气孔缺陷	14	112
无缺陷	23	184
合计	65	520

首先, 在图像预处理及分割阶段, 通过灰度变换增加铸件图像缺陷与背景之间的对比度。以铸件裂纹缺陷为例, 铸件原始图像如图 3(a) 所示, 灰度变换后的铸件图像如图 3(b) 所示。为了进一步处理铸件图像噪声, 采用双边滤波对铸件图像进行降噪处理。降噪处理后的铸件图像如图 3(c) 所示。双边滤波具体参数设置见表 2。最后, 采用自适应阈值图像分割技术对铸件图像进行图像分割操作。自适应阈值分割后的铸件图像如图 3(d) 所示。自适应阈值分割具体参数设置见表 2。由图 3(d) 可见, 分割后的图像与处理前相比, 缺陷更为明显。在特征提取与筛选阶段, 主要提取该图像的 HOG 特征、LBP 特征以及不变矩特

征。其中 HOG 特征提取后维度过大, 采用 PCA 对该特征进行降维处理。将提取的 HOG 特征、LBP 特征以及不变矩特征共同组成全信息特征集。随后, 使用 SVM-RFE 算法对全信息特征集中的各个特征进行评价, 选择全信息特征集中重要性排名的前 20% 组成关键敏感特征集。在缺陷分类阶段, 本文设置模型迭代次数为 1000, 并采用十折交叉验证对本文方法的泛化能力进行验证^[23]。

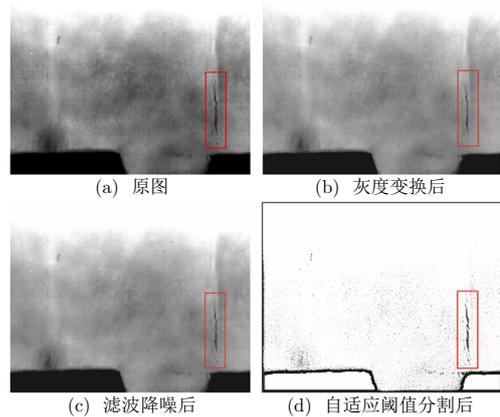


图 3 图像处理过程

表 2 图像预处理及分割阶段算法具体参数设置

算法	参数	值
双边滤波	权重模板尺寸 (H, W)	(5, 5)
	空间距离权重模板标准差 σ_1	20
	相似性权重标准差 σ_2	0.2
自适应阈值分割	平滑算子尺寸 (H, W)	(15, 15)
	r	0.15

2.2 评估结果与讨论

本文采用混淆矩阵作为性能评价指标, 混淆矩阵如图 4 所示。图 4 内变量为预测与真实情况相对应的铸件图片数量。

		预测			
		裂纹	偏析	气孔	健康
真实	裂纹	T_{11}	F_{12}	F_{13}	M_1
	偏析	F_{21}	T_{22}	F_{23}	M_2
	气孔	F_{31}	F_{32}	T_{33}	M_3
	健康	F_1	F_2	F_3	T_{44}

图 4 混淆矩阵

模型的输出目标主要包括 4 个类别: 裂纹缺陷、偏析缺陷、气孔缺陷和健康 (无铸件缺陷)。由混淆矩阵可以计算获得多种性能评价指标。这里采用准确率和漏报率两个指标对本文方法的性能进行评价, 计算公式如下:

$$A = \frac{T_{11} + T_{22} + T_{33} + T_{44}}{N} \quad (19)$$

$$R_1 = \frac{F_{12} + F_{13} + M_1}{T_{11} + F_{12} + F_{13} + M_1} \quad (20)$$

式中： A 表示缺陷识别的准确率； N 表示输入识别的图片总数； R_1 表示裂纹缺陷的漏报率，其他类型的计算方式与裂纹相同；其他变量均与图 4 中变量对应。

为了有效验证本文方法，主要讨论特征筛选阈值的选取对方法的影响，并与相关模型进行对比。选取 10%、20%、50% 和 100% 4 种不同的筛选阈值对本文方法进行验证，验证结果如表 3、图 5 和图 6 所示。由结果可知，选取前 20% 的特征数量在测试集准确率均值和测试集漏报率均值两方面均好于其他 3 个筛选阈值。由此可见，筛选阈值的提高会使输入模型的特征包含更多冗余信息，筛选阈值的降低会使输入模型的特征缺失一些较重要的信息，这都体现出本文方法在提取关键敏感信息方面的有效性。

表 3 SVM-RFE 算法特征筛选阈值对比

筛选阈值	各缺陷识别结果					
	裂纹		偏析		气孔	
	准确率	漏报率	准确率	漏报率	准确率	漏报率
10%	0.95	0.069	0.92	0.079	0.92	0.080
本文方法	0.98	0.063	0.96	0.072	0.96	0.076
50%	0.89	0.072	0.88	0.080	0.87	0.082
100%	0.87	0.078	0.84	0.082	0.82	0.084

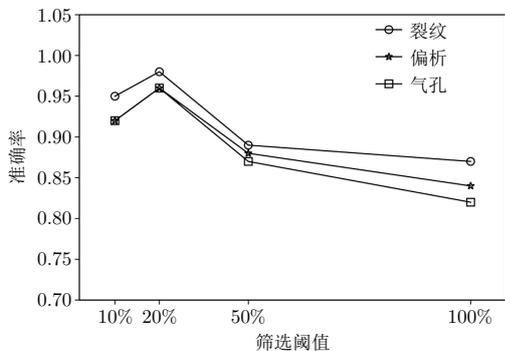


图 5 不同阈值下缺陷识别准确率

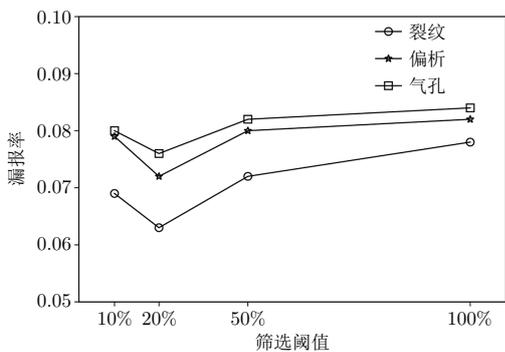


图 6 不同阈值下缺陷识别漏报率

为了进一步验证 Adaboost-RF 模型的性能，本文采用 SVM 和 RF 进行对比分析。对比方法均采用本文提取的敏感特征集作为模型的输入特征进行训练，识别结果如表 4、图 7 和图 8 所示。由结果可知，本文方法在 3 种缺陷的识别准确率和漏报率上都好于其他两种方法。因此，在铸件的缺陷识别中，本文方法更有优势。

表 4 分类器识别结果对比

分类器	各缺陷识别结果					
	裂纹		偏析		气孔	
	准确率	漏报率	准确率	漏报率	准确率	漏报率
SVM	0.82	0.075	0.79	0.085	0.75	0.085
RF	0.89	0.067	0.78	0.080	0.72	0.082
本文方法	0.98	0.063	0.96	0.072	0.96	0.076

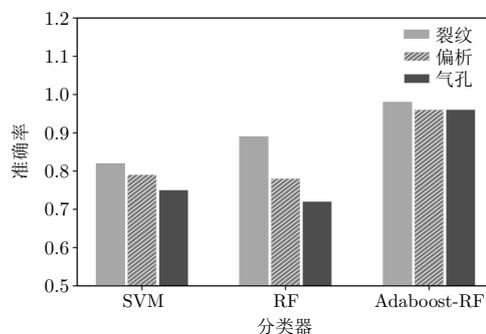


图 7 不同分类器缺陷识别准确率

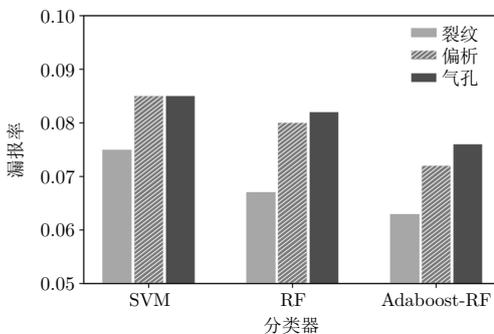


图 8 不同分类器缺陷识别漏报率

3 结束语

本文针对现有铸件缺陷识别技术存在泛化能力差、准确率不高的问题，提出一种基于 SVM-RFE 和 Adaboost-RF 的铸件缺陷自动识别技术。首先，采用图像预处理与分割技术提高铸件图像质量。然后，采用多类型特征提取方法构建全信息特征集，并结合 SVM-RFE 算法筛选特征，构建敏感特征集。最后，结合集成学习思想构建 Adaboost-RF 铸件缺陷识别模型，实现对铸件缺陷的智能识别。通过对工业现场采集的裂纹、偏析和气孔缺陷图像进行识别，并与不

同参数设置的方法及算法进行对比, 可以获得如下结论:

1) 本文提出的自动识别技术可以从全信息特征集中提取敏感特征集, 并且在 Adaboost-RF 铸件缺陷识别模型阈值为 20% 时具有最好的性能;

2) 相较于常用的单一分类器, 如 SVM 和 RF 算法, 本文方法具有更好的分类性能和泛化能力。

参考文献

- [1] 郑晓玲. 基于机器视觉的铝铸件表面缺陷检测[D]. 泉州: 华侨大学, 2015.
- [2] 于筱然. 浅析各种无损检测技术的优缺点[J]. 电子测试, 2019(19): 86-88.
- [3] 常海涛. 基于 Faster R-CNN 的工业 CT 图像缺陷检测研究[D]. 兰州: 兰州交通大学, 2018.
- [4] 刘棣斐, 田洪川, 刘贺贺. 工业 CPS 技术、架构及应用策略研究[J]. 中兴通讯技术, 2016, 22(5): 17-20.
- [5] 王耀南, 陈铁健. 智慧工厂机器视觉感知与控制关键技术综述[J]. 中兴通讯技术, 2016, 22(5): 26-30.
- [6] ZHAO X Y, HE Z X, ZHANG S Y, et al. A sparse-representation-based robust inspection system for hidden defects classification in casting components[J]. Neurocomputing, 2015, 153: 1-10.
- [7] BHUTADA G G, ANAND R S, SAXENA S C. Edge preserved image enhancement using adaptive fusion of images denoised by wavelet and curvelet transform [J]. Digital Signal Processing, 2011, 21(1): 118-130.
- [8] WANG S Q, ZHOU Y H, ZOU D W. Adaptive shrinkage de-noising using neighbourhood characteristic [J]. Electronics Letters, 2002, 38(11): 502-503.
- [9] BHATTACHARYYA S, MAULIK U, DUTTA P. Multilevel image segmentation with adaptive image context based thresholding [J]. Applied Soft Computing, 2011, 11(1): 946-962.
- [10] VANTARAM S R, SABER E, DIANAT S A, et al. Multiresolution adaptive and progressive gradient-based color-image segmentation [J]. Journal of Electronic Imaging, 2010, 19(1): 013001-1-013001-21.
- [11] 谈绍熙, 黄茜. 一种在铸件缺陷识别中的区域分形分割方法[J]. 中国图象图形学报, 2008(5): 918-923.
- [12] 李金凤. 基于图像处理的冷轧带钢表面缺陷检测与识别研究[D]. 西安: 西安建筑科技大学, 2009.
- [13] 崔雪红. 基于深度学习的轮胎缺陷无损检测与分类技术研究[D]. 青岛: 青岛科技大学, 2018.
- [14] TSAI D M, LIN C P, HUANG K T. Defect detection in coloured texture surfaces using Gabor filters[J]. The Imaging Science Journal, 2005, 53(1): 27-37.
- [15] LUIZ A O M, FLÁVIO L C P, PAULO E M A. Automatic detection of surface defects on rolled steel using computer vision and artificial neural networks [C] // IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society, 2010: 1081-1086.
- [16] 陈小改. 基于 PCA-SVM 的带钢表面缺陷识别[J]. 机械设计与制造工程, 2017, 46(6): 100-103.
- [17] 崔洁. 基于随机森林的激光超声金属表面缺陷识别方法研究[D]. 太原: 中北大学, 2019.
- [18] MARTÍNEZ S S, VÁZQUEZ C O, GARCÍA J G, et al. Quality inspection of machined metal parts using an image fusion technique[J]. Measurement, 2017, 111: 374-383.
- [19] ZHU Q, YEH M C, CHENG K T, et al. Fast human detection using a cascade of histograms of oriented gradients[C]//2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06), 2006, 2: 1491-1498.
- [20] ZHAO G, AHONEN T, MATAS J, et al. Rotation-invariant image and video description with local binary pattern features [J]. IEEE transactions on image processing, 2011, 21(4): 1465-1477.
- [21] GUYON I, WESTON J, BARNHILL S, et al. Gene selection for cancer classification using support vector machines[J]. Machine learning, 2002, 46(1-3): 389-422.
- [22] MEIR R, RÄTSCH G. An introduction to boosting and leveraging[M]. Berlin, Heidelberg: Springer, 2003: 118-183.
- [23] KOHAVI R. A study of cross-validation and bootstrap for accuracy estimation and model selection [C] // Proceedings of The 14th International Joint Conference on Artificial Intelligence, 1995, 2: 1137-1143.

林庭武 男, 1977年生, 高级工程师, 主要研究方向为工业图像、智能制造。

罗坤宇 男, 1996年生, 硕士研究生, 主要研究方向为工业大数据、工业图像识别。

常建涛 男, 1981年生, 博士, 副教授, 主要研究方向为智能制造与工业大数据。

程涵 男, 1994年生, 博士研究生, 主要研究方向为故障预测与健康管理。

冯世杰 男, 1994年生, 硕士研究生, 主要研究方向为工业大数据、工业图像识别。