

融合双特征的玻璃缺陷图像分割算法

卢印举^{1,2}, 郝志萍¹, 戴曙光²

(1. 郑州工程技术学院 信息工程学院, 郑州 450044; 2. 上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 目的 针对玻璃的材料透明性以及条带噪声等固有属性使得传统玻璃缺陷分割算法准确率较低等问题, 提出一种基于双特征高斯混合模型的玻璃缺陷分割方法。方法 首先, 利用分数阶运算对玻璃缺陷增强, 用灰度共生矩阵获取纹理特征, 从而构建玻璃缺陷的双特征向量; 将双特征向量引入高斯混合模型, 并利用马尔科夫随机场的相邻像素空间信息对玻璃缺陷分割高斯混合模型进行改进, 通过交替进行玻璃缺陷像素点与标号场之间映射关系的估计和基于高斯核函数空间约束更新, 完成玻璃缺陷分割; 最后, 应用模糊熵对缺陷图像分割结果进行后续处理。结果 对疖瘤、污点、气泡以及夹杂等4种典型缺陷样本图像进行性能测试和不同算法对比分析实验, 实验结果表明, 所提算法的 D_{ice} 指标达到98.59%, M_{cr} 指标达到7.03%, 衡量指标优于其他算法。结论 将灰度特征和纹理特征引入玻璃缺陷分割的马尔科夫随机场, 能够抑制非缺陷目标, 并保留低对比度玻璃缺陷, 提高玻璃缺陷分割算法的鲁棒性和准确性。

关键词: 玻璃缺陷; 图像分割; 最大期望算法; 马尔科夫随机场; 模糊熵

中图分类号: TB487; TP312 文献标识码: A 文章编号: 1001-3563(2021)23-0162-08

DOI: 10.19554/j.cnki.1001-3563.2021.23.023

Glass Defect Image Segmentation Algorithm Fused with Dual Features

LU Yin-ju^{1,2}, HAO Zhi-ping¹, DAI Shu-guang²

(1. College of Information Engineering, Zhengzhou University of Technology, Zhengzhou 450044, China;

2. School of Optical Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

ABSTRACT: The work aims to propose a glass defect segmentation method based on a dual feature Gaussian mixture model to solve the low accuracy of traditional glass defect segmentation algorithm caused by inherent properties of glass material, such as transparency and stripe noise. Firstly, fractional calculation and gray-level co-occurrence matrix were adopted to enhance glass defects, and obtain texture features, respectively, and thereby construct dual feature vectors of glass defects. The dual feature vector was introduced into the Gaussian mixture model, and the adjacent pixel spatial information of the Markov random field was used to improve the glass defect segmentation Gaussian mixture model. Then, the glass defect segmentation was completed by alternately performing the estimation of the mapping relationship between the glass defect pixels and the label field and the updating based on the space constraint of the Gaussian kernel function. Finally, fuzzy entropy was applied to the subsequent processing of the defect image segmentation results. The performance test and comparative analysis experiment of different algorithms were performed on four typical defect sam-

收稿日期: 2021-04-01

基金项目: 河南省科技攻关计划(212102110168); 河南省高等学校重点科研项目(20B520037, 22B410001); 郑州市科技局基础研究及应用基础研究项目(zkz202103, zkz202105)

作者简介: 卢印举(1976—), 男, 博士, 郑州工程技术学院副教授, 主要研究方向为机器视觉检测及智能仪器仪表。

ple images of furuncle, stain, bubble and inclusion. The experimental results showed that the D_{ice} index of the proposed algorithm reached 98.59% and the M_{cr} index reached 7.03%, which was better than that of other algorithms. Introducing gray-level features and texture features into the Markov random field of glass defect segmentation can suppress non-defect targets, retain low-contrast glass defects, and improve the robustness and accuracy of the glass defect segmentation algorithm.

KEY WORDS: glass defect; image segmentation; expectation-maximization algorithm; Markov random field; fuzzy entropy

玻璃的抗腐蚀能力、可视性以及密封性,使得玻璃在食品、医药以及饮料包装方面得到广泛应用,但是,在生产过程中玻璃容易产生夹杂、疖瘤、气泡以及污点等各种缺陷^[1]。这些缺陷破坏了玻璃包装制品的光学均匀性、透明性和外观质量,有些缺陷由于应力集中而削弱了玻璃包装制品的热稳定性和机械强度^[2],因此,玻璃缺陷检测是玻璃制造业的一个关键步骤。传统的人工及其半自动检测存在以下缺点:人工抽检存在遗漏的可能,导致玻璃缺陷检测的准确率降低;人工检测主要依靠工人主观感觉判断,对于玻璃缺陷的评判标准带有主观性。玻璃材料的透明性和玻璃缺陷的多样性,玻璃缺陷有效分割是玻璃检测技术中的一个难题。

随着机器视觉检测技术的发展,越来越多的研究者将图像处理技术应用于玻璃缺陷检测和识别之中,主要包括基于玻璃缺陷特征值、阈值分割、神经网络、小波分析以及支持向量机等方法。Anubhav 等^[3]研究多种边缘检测算子对玻璃缺陷纹理分析的可行性,以参考分割图像为基准,通过大量不同算子对玻璃缺陷分割的对比实验,验证了 Log 边缘检测算子比其他边缘检测算法具有较好的分割效果。Sachdeva 等^[4]利用灰度共生矩阵提取玻璃缺陷纹理特征,实现玻璃缺陷的识别与检测。Jin 等^[5]在缺陷图和相位图融合基础上利用灰度的分段线性变换来提高玻璃缺陷图像信噪比,然后选择三值缺陷图的 4 个特征和 HU 不变矩运算得到的 7 个特征作为共轭梯度神经网络的输入特征参数来完成玻璃缺陷的优化识别。亓宁宁等^[6]以浮法玻璃缺陷灰度较低为先验知识,提出了一种玻璃缺陷的 2 次 Otsu 分割算法,并用三层神经网络实现玻璃缺陷分类识别。Zhou 等^[7]将小波变化理论应用到玻璃缺陷的噪声消除,提出了一种基于熵阈值的缺陷分割算法来完成玻璃缺陷的检测。Liu 等^[8]以基于灰度范围限制的大津法为准则,为消除背景条纹提出了一种基于自适应阈值的分割方法,并根据缺陷纹理特征对虚假缺陷进行删除,最终实现缺陷的分割。玻璃缺陷的形态多样性严重影响上述算法的分割效果。

最近,作为深度学习的重要分支之一,卷积神经网络(Convolutional Neural Network, CNN)通过权值共享及其局部感受野来减少训练参数的数量,在语义分割、图像识别以及目标检测等领域得到广泛应

用^[9-10]。Hanzaci 等^[11]将传统 CNN 算法引入玻璃缺陷图像亮度校正模块,实现玻璃缺陷的有效检测,该算法的敏感性、准确度和特异性等 3 个衡量指标分别达到了 89.4%, 91%, 93%。熊红林等^[12]提出了多尺度卷积神经网络方法来解决玻璃缺陷的复杂性、图像照度不均匀性, F_1 衡量指标比传统卷积神经网络提高了 5.0%,但是分类器选择直接影响识别的准确性。文献[13]提出一种融合模糊支持向量机和卷积神经网络的玻璃缺陷分割算法,该算法仅检测到缺陷所在区域而无法确定缺陷的精准位置。张丹丹等^[14]提出了一种基于卷积神经网络的玻璃检测方法,采用 4 层卷积神经网络完成玻璃方块图像特征的提取,与传统引进依靠灰度特征提取缺陷特征相比,该方法的检测效果得到提高,但是,缺陷检测的深度学习模型中多层网络训练的参数设置容易导致过分割现象,计算耗时复杂。

上述这些玻璃缺陷分割方法依简单的几何特征和灰度,没有综合考虑玻璃的透明性以及缺陷形态多样性,使得算法的分割效果不佳,因此,文中提出一种基于双特征随机场的玻璃缺陷分割算法,将玻璃缺陷灰度特征和纹理特征引入玻璃缺陷分割的马尔科夫随机场,以提高缺陷分割的鲁棒性和准确性。

1 问题描述

1.1 双特征描述子

文中采用 G-L 形式^[15]的阶导数定义,分数阶微分运算对玻璃缺陷边缘增强和细节保留并抑制条带噪声,选取微分运算前 3 项算子,得到:

$$D^v f(t) = f(t) + (-v)f(t-1) + \frac{(-v)(-v+1)}{2} f(t-2) \quad (1)$$

利用分数阶微分算子模板在各个方向上的旋转不变性质,将分数阶微分阶数拟定为 0.5,并将分数阶微分运算结果用 t_0 标识,用于描述玻璃缺陷的灰度特征。所引入的灰度共生矩阵为描述图像纹理特征信息一共定义了 14 种统计量^[16],选取熵、能量、相关性、对比度以及逆差矩这 5 个统计量来描述图像纹理特征,分别用 t_1-t_5 标识。取 0° , 90° , 180° 和 270° 共 4 个方向,选取 4 组数据的平均值作为每个像素的最终特征值。融合玻璃缺陷灰度特征和玻璃缺陷纹理

特征, 构建玻璃缺陷的双特征向量 t_1-t_5 。

1.2 高斯混合模型

设玻璃缺陷图像 $X = \{x_i\}_{1 \leq i \leq N}$, N 为像素总数量, x_i 为第 i 个像素, 其邻域为 N_i , 每个像素的双特征向量元素为式 (1) 获取到的 t_1-t_5 。引入隐含变量 $Z = \{z_i = j\}_{j=1}^K$, 令 $p_{ij} = P(z_i = j)$ 表示像素 x_i 分配给第 j 个高斯分量的先验概率, 且约束 $\sum_{j=1}^K p_{ij} = 1$ 。给定 $z_i = j$, 像素 x_i 的条件概率分布服从高斯分布, 即:

$$P(x_i | z_i = j) = \mathcal{N}(\mu_j, \Sigma_j) = \frac{1}{(2\pi)^{D/2} |\Sigma_j|^{1/2}} \exp\left\{-\frac{1}{2}(x_i - \mu_j)^T \Sigma_j^{-1} (x_i - \mu_j)\right\} \quad (2)$$

式中: D 为玻璃缺陷观测数据的维数, 由玻璃缺陷双特征向量可知, $D=6$; μ_j , Σ_j 分别为第 j 个高斯分量的均值和方差矩阵。

由式 (2) 得到玻璃缺陷分割的高斯混合模型:

$$P(X | \Theta) = \prod_{i=1}^N \sum_{j=1}^K p_{ij} \mathcal{N}(\mu_j, \Sigma_j) \quad (3)$$

式中: Φ 为玻璃缺陷分割高斯混合模型的完整参数集合, $\Phi = \{\mu_j, \Sigma_j, p_{ij}\} (i=1, 2, \dots, N, j=1, 2, \dots, K)$ 。

2 双特征随机场图像分割算法

2.1 双特征随机场模型

利用贝叶斯定理计算观测数据的后验概率的密度分布函数, 对式 (3) 取对数, 忽略常数项, 得到玻璃缺陷分割马尔科夫随机场能量函数:

$$L(\Pi, \Theta | X) = \sum_{i=1}^N \sum_{j=1}^K \alpha_{ij} (\ln p_{ij} + \ln \mathcal{N}(\mu_j, \Sigma_j)) + \sum_{j=1}^K \sum_{i=1}^K G_{ij}^{(i)} \ln p_{ij} \quad (4)$$

式中: $G_{ij}^{(i)}$ 为玻璃缺陷图像像素 x_i 关于 N_i 邻域像素的先验概率分布, $G_{ij}^{(i)} = \exp\left\{\frac{\beta}{2M_i} \sum_{m \in N_i} (z_{im}^{(i)} + p_{im}^{(i)})\right\}$; M_i 为玻璃缺陷图像像素 x_i 与其 N_i 邻域内像素数量, 参数 β 反映了邻域系统中相邻像素间相互作用的强度。

对式 (4) 的最大化通过最大期望 (Expectation-Maximization, EM) 算法来实现, 将玻璃缺陷分割问题转换为缺陷像素标签区域后验最大化优化求解问题。将式 (2) 和式 (3) 代入式 (4), 使用贝叶斯定理计算给定图像像素 x_i 条件下 $z_i = j$ 的后验概率:

$$\alpha_{ij} = \frac{p_{ij} |\Sigma_j|^{-1/2} \exp(-\frac{1}{2} \|x_i - \mu_j\|_{\Sigma_j}^2)}{\sum_{k=1}^K (p_{ik} |\Sigma_k|^{-1/2} \exp(-\frac{1}{2} \|x_i - \mu_k\|_{\Sigma_k}^2))} \quad (5)$$

式中: $\|x_i - \mu_j\|_{\Sigma_j}^2$ 为马氏距离的平方, $\|x_i - \mu_j\|_{\Sigma_j}^2 = (x_i - \mu_j)^T \Sigma_j^{-1} (x_i - \mu_j)$ 。

2.2 图像分割模型参数更新

在 EM 算法中, 首先由式 (5) 得到式 (4) 目标似然函数的下界, 然后进一步最大化下界来完成参数集合优化。对式 (5) 目标函数求偏导, $\partial \varphi / \partial u_j = 0, \forall j \in [1, \dots, K]$, 得到:

$$\mu_j^q = \frac{\sum_{i=1}^K \alpha_{ij}^q x_i}{\sum_{i=1}^K \alpha_{ij}^q} \quad (6)$$

令 $\partial \varphi / \partial \Sigma_j = 0, \forall j \in [1, \dots, K]$, 可以实现对 Σ_j 的估计, 得到:

$$\Sigma_j^{q+1} = \frac{\sum_{i=1}^K \alpha_{ij}^q (\|x_i - \mu_j^q\|_{\Sigma_j^q}^2)}{\sum_{i=1}^K \alpha_{ij}^q} \quad (7)$$

根据 p_{ij} 的约束条件, 忽略式 (5) 中不依靠先验的常数项并利用拉格朗日乘数法, 目标函数变为:

$$\sum_{i=1}^N \sum_{j=1}^K (\alpha_{ij} \ln p_{ij} + G_{ij} \ln p_{ij}) - \sum_{i=1}^N \eta_i (\sum_{j=1}^K p_{ij} - 1) = 0 \quad (8)$$

令偏导函数等于 0, 得到:

$$p_{ij} = \frac{\alpha_{ij} + G_{ij}}{\sum_{k=1}^K \alpha_{ik} + G_{ik}} \quad (9)$$

$$\eta_i = 1 - \sum_{j=1}^K G_{ij} \quad (10)$$

到此完成了模型参数 Θ 的评价分析, 利用最大化后验准则, 得到像素 x_i 分配到第 j 个分类区域, 即 x_i 的最大标号场 $\hat{x}$ 。

2.3 模糊熵后处理

玻璃缺陷形态的多样性以及双特征描述的噪声敏感性, 分割结果容易呈现噪声点, 引入模糊熵后续处理进一步改善分割效果。模糊熵描述一个模糊集的模糊性程度, Sarkar 等^[17]定义一种具有非概率特性的特殊的模糊熵, 针对论域 $X = \{x_1, x_2, \dots, x_n\}$, 模糊集合 A 的模糊熵描述为:

$$H(A) = \frac{1}{n \ln 2} \sum_{i=1}^n S(\mu_A(x_i)) \quad (11)$$

式中: $S(\mu_A(x_i)) = -\mu_A(x_i) \ln(\mu_A(x_i)) - (1 - \mu_A(x_i)) \ln(1 - \mu_A(x_i))$ 为元素 x_i 对集合 A 的隶属度函数。

记 $\hat{x}$ 为马尔科夫随机场 (Markov Random Field, MRF) 分割算法获得的玻璃缺陷标号场, 其灰度级设置为 L , 将归一化处理后的所有灰度值集合描述为 $\hat{x}(i) \in (1, 2, \dots, L)$, 针对第 k 个分类区域, 该区域上隶属度函数的表达式为:

$$\mu_k(i) = \frac{1}{1 + \frac{|\hat{x}(i) - k|}{\lambda}} \quad (12)$$

式中： λ 为正参数且取值 $L-1$ ，约束条件为 $0.5 \leq \mu_k(i, j) \leq 1$ 。将像素点 $x(i)$ 为中心的 3×3 窗口用论域 W 表示，则模糊熵定义为：

$$E_k(i) = \frac{1}{n \cdot n \cdot \ln 2} \cdot \sum_{(i) \in W} S(u_k(i)), k \in (1, 2, \dots, L-1) \quad (13)$$

对于玻璃缺陷的所有像素，利用式 (13) 计算每个像素在 L 个模糊集的模糊熵，以模糊熵最小为决策评估准则，将模糊熵的最小值所对应的标号值判定为标号场的最佳映射。将模糊熵应用到玻璃缺陷分割的后续处理，能够减少错分点数量以及提高分割的抗噪鲁棒性。

2.4 算法流程

根据图像分割的标签类别数量，基于 K 均值算法计算出了图像分割模型初始状态下的各个参数。图像分割的算法描述如下所述。

- 1) 利用 K 均值算法进行参数初始化 p_{ij} ， μ_j 和 Σ_j 。
- 2) 计算目标下界。用当前的 p_{ij} ， u_j 和 Σ_j 利用式 (5) 估计 α_{ij} 的后验概率。
- 3) 最大化下界。利用当前新的 α_{ij} ，从式 (6) 估计新的均值向量 μ_j ；利用当前新的 α_{ij} ，从式 (7) 估计新的方差 Σ_j ；利用当前新的 α_{ij} ，从式 (9) 估计新的先验 p_{ij} 。
- 4) 收敛。算法达到最大迭代次数或者小于给定阈值，程序终止。
- 5) 利用式 (13) 对分割结果做后续处理。

3 实验结果与分析

3.1 实验环境与数据集

通过性能测试实验和不同算法的对比分析实验完成所提算法的实验与分析，在 Matlab R2010b 软件上实现文中算法，运行环境为 Intel(R)Core(TM) i7-9700 4.7 GHz 处理器以及 Windows 10 64 位操作系统。文中玻璃缺陷图像采集系统结构见图 1。在图 1 中，选择冷阴极荧光灯作为玻璃缺陷检测光源，光源




图 1 玻璃缺陷图像采集系统结构
Fig.1 Structure of glass defect image acquisition system

照明方式采用背光式，CCD 摄像头采集光源透射的玻璃缺陷，玻璃缺陷图像通过采集卡传送到计算机，计算机上对玻璃缺陷分析、处理和存储。

针对玻璃缺陷类型和特点，拍摄 200 张包含夹杂、疖瘤、气泡以及污点 4 类典型玻璃缺陷，经过裁剪构成 512×512 的玻璃缺陷数据集，随机选取 100 张图片作为高斯混合模型参数优化样本，其余为性能测试样本。与 MRF^[18]，GMM^[19]，CNN^[14] 3 种经典分割算法进行对照实验，选取 M_{cr} ^[20] 和 D_{ice} ^[21] 为衡量指标，对不同分割算法进行定量分析。衡量指标的计算式为：

$$M_{cr} = \frac{\text{错误分类像素数量}}{\text{整个像素数量}} \times 100\% \quad (14)$$

式 (14) 定义表明， M_{cr} 的范围为 $[0, 1]$ 区间， M_{cr} 值越高则表示分割的结果较差，等于 0 时说明不存在错误分类的像素则分割最为准确。

$$D_{ice} = \frac{2 \times R_k}{V_k + A_k} \times 100\% \quad (15)$$

式中： V_k 和 A_k 分别为第 k 类区域中基准模型和自动模型分割结果像素的数量； R_k 为第 k 类区域中基准模型和自动模型分割结果共同像素数量。 D_{ice} 值为 0 时说明基准模型和自动模型分割的结果不存在完全的重叠，该值为 1 时说明分割效果最正确。

3.2 性能测试式样

3.2.1 不同噪声水平对分割影响实验

实验对玻璃缺陷样本图像加入高斯噪声和椒盐噪声得到合成图像，以验证图像分割算法在不同水平下的噪声鲁棒性测试样本图像包含夹杂缺陷，并且背景存在由光源频闪所产生的线状条带噪声，具体见图 2。采集到的样本图像见图 2a，采用 5×5 分数阶模板窗口对样本图像增强结果见图 2b。不同噪声水平下的实验参数设置：温度系数 $\beta = 1$ ，高斯噪声均值为 0，方差范围 $[0, 0.3]$ ，椒盐噪声密度范围 $[0, 0.25]$ 。




图 2 玻璃缺陷图像
Fig.2 Glass defect image

3.2.1.1 高斯噪声

高斯合成图像的测试结果见图 3，从左到右分别为均值为 0、方差为 0.1 高斯噪声的合成图像、分割

结果、局部放大以及能量变化曲线。分割结果显示,文中所提算法引入了分数阶微分算子能够较好地识别和滤除高斯噪声,更好地保护图像边缘轮廓信息和纹理细节特征,大幅提升图像的边缘轮廓和噪声消除,并非线性保留了图像缺陷与非缺陷连接区域的中低频成分以及微小细节部分。能量函数变化曲线显示,算法的正则项能量函数依迭代次数的增加而持续减小,经过大约5次迭代运算趋于稳定某一定值,即得到标号场的优化最大后验概率,说明分割算法的收敛性较好,且对高斯噪声干扰具有良好的鲁棒性。

3.2.1.2 椒盐噪声

椒盐合成图像的测试结果见图4,从左到右分别为密度为0.1椒盐噪声的合成图像、分割结果、局部放大以及能量变化曲线。对样本图像的分割结果显

示,文中所提算法引入了分数阶微分算子能够对椒盐噪声具有良好的识别和消除能力,同时,提高了玻璃缺陷在图像中的对比度,在椒盐噪声消除时能够恢复缺陷的边缘轮廓信息和纹理细节。在缺陷区域依然存在部分的噪声点,说明文中算法对椒盐噪声识别能力较弱。能量函数变化曲线显示,算法的正则项能量函数依迭代次数的增加而持续减小,经过大约7次迭代运算趋于稳定某一定值,说明分割算法的收敛性较好,且对椒盐噪声干扰具有良好的鲁棒性。

3.2.1.3 算法的鲁棒性分析

在噪声不同水平下分割算法的鲁棒性测试结果曲线见图5。图5a显示了不同标准差的高斯噪声影响下,图像分割算法在50次迭代下的分割误差,横坐标为高斯噪声的方差,纵坐标为分割误差的对数。




图3 高斯噪声分割结果

Fig.3 Results of Gaussian noise segmentation




图4 椒盐噪声分割结果

Fig.4 Results of salt and pepper noise segmentation




图5 算法的鲁棒性分析

Fig.5 Robustness analysis of the algorithm

图 5b 为不同密度椒盐噪声影响下，图像分割算法在 50 次迭代下的分割误差，横坐标为椒盐噪声的密度，纵坐标为分割误差的对数。当高斯噪声方差小于 0.2 时，文中算法的分割误差较小，当高斯噪声方差大于 0.2 时，文中算法的分割误差缓慢增加，在不同密度椒盐噪声分割变化不大，表现出良好的鲁棒性。

3.2.2 温度系数 β 对玻璃缺陷分割结果的影响

实验主要验证式 (4) 先验能量函数中的温度系数 β 对玻璃缺陷分割的影响，参数 $\beta=[0.5,5]$ ，实验结果见图 6。图 6 分割结果显示如果选择 β 值足够小，分割算法对边缘和噪声比较敏感，虽然玻璃缺陷目标比较接近真实缺陷，但是，分割结果图像中玻璃缺陷出现毛刺、背景存在较多的噪声点现象，算法的鲁棒性弱且过分割现象比较严重。如果所选择的 β 值较大，分割结果中的噪声大量减少，但是，分割算法丢失细节问题，较小的区域容易连通，欠过分割现象比较严重。不同温度系数下的分割指标见表 1。指标显示 $\beta=1$ 时玻璃缺陷样本图像分割效果最佳。




图 6 不同温度参数 β 下玻璃缺陷分割结果
Fig.6 Crack image segmentation results under different temperature parameter β

表 1 不同温度参数 β 下分割结果指标比较
Tab.1 Comparison of segmentation results under different temperature parameter β

β 参数	$D_{ice}/\%$	$M_{cr}/\%$
$\beta=0.5$	90.76	3.01
$\beta=1$	98.86	1.78
$\beta=3$	88.34	8.17
$\beta=5$	76.89	12.03

3.3 不同分割算法的分割结果实验分析

3.3.1 不同算法的分割结果

为了验证文中算法的综合分割性能，不同算法下的玻璃缺陷分割结果见图 7。在图 7 中，第 1—4 行分别为含有疖瘤、污点、气泡以及夹杂玻璃缺陷的样本图像，第 1 列为玻璃缺陷原始图像，第 2 列至第 4 列依次为 GMM, MRF, CNN 以及文中算法的玻璃缺陷分割结果。玻璃缺陷图像分割结果显示，所有算法对玻璃缺陷目标均能够完成分割。

GMM 算法基于玻璃缺陷图像的灰度信息利用聚类方法来实现缺陷分割，由于没有融合像素上下文之间的纹理细节和灰度相似性，分割结果仅仅保留了缺陷组织的主题结构，图像中的孤立像素不仅数量较多，同时分布也十分密集，部分背景区域容易被划分为缺陷区域，而且不同目标区域之间处于连贯的状态，不满足原始影像的要求。例如，对疖瘤和夹杂缺陷分割结果出现大量的噪声，气泡分割出现大量的错误的连通区域，污点缺陷边界出现断裂现象；MRF 分割算法与 GMM 相比，马尔科夫随机场以图像的灰度值为随机场，在建模的时候应用了条件随机场来将上下文信息融合在观测域和标签域的描述，克服了 GMM 噪声敏感问题使得玻璃缺陷分割效果得到明显改善。该算法对图像的灰度值依赖性比较大，容易导致过分割现象，例如，疖瘤、气泡和夹杂缺陷错分了缺陷的连接区域，污点缺陷出现过分割；CNN 分割算法虽然解决了背景噪声问题，但出现过分割现象，例如气泡缺陷样本过分割、污点缺陷的边缘毛刺、疖瘤缺陷存在噪声；此算法采用多分布灰度有限混合模型并融合了图像的双特描述子，在一定范围内的测量刻度对缺陷图像的局部特性进行分析，能够增强缺陷目标并抑制非缺陷目标，同时将模糊熵应用到图像分割的后续处理，能够减少错分点数量以及提高图像分割的抗噪能力。分割结果细节更加丰富，缺陷目标连续，比其余分割算法具有较高的分割准确性。

为了进一步验证文中算法的有效性，将 4 种不同分割算法对 100 张玻璃缺陷图片进行缺陷分割测试，根据得到的 M_{cr} 和 D_{ice} 指标参数进行统计分析，以 M_{cr} 均值为横坐标， D_{ice} 指标方差为纵坐标，绘制了 $M_{cr}-D_{ice}$ 曲线，见图 8。图 8 显示，玻璃缺陷分割效果越好则性能指标数据分布在 $M_{cr}-D_{ice}$ 曲线的左下角，因此，在 M_{cr} 和 D_{ice} 指标上文中所提算法优于其他算法。

3.3.2 分割算法的定量分析

将 4 种不同分割算法对自建玻璃缺陷数据库中剩余的 100 张玻璃缺陷图片进行缺陷分割测试，分析图 7 中不同算法的分割结果并计算分割指标数值，对比结果见表 2。文中算法 D_{ice} 指标为 98.59%，分别比




图7 不同算法的分割效果

Fig.7 Segmentation effect of different algorithms




图8 分割算法评价平均指标

Fig.8 Average evaluation index of segmentation algorithms

GMM, MRF 和 CNN 算法高出 36.34%, 15.60%和 10.40%, M_{cr} 指标为 7.03%, 分别比 GMM, MRF 和 CNN 算法降低了 57.91%, 48.98%和 37.06%, 算法整体指标远远优于其对比的算法。这点与不同算法的定性比较结果基本一致。表 2 的处理时间显示, 文中算法处理时间远远低于其余算法。在工程应用中, 由于玻璃集中应力的存在, 玻璃缺陷检测的准确性相对于玻璃安全使用显得极为重要, 缺陷漏检具有更大的危害性, 因此, 针对玻璃缺陷检测的工程应用来说, 文中算法具有更为出色的正确性和完整性。

表2 算法比较分析结果统计

Tab.2 Algorithm comparison and analysis results statistics

分割算法	$D_{ice}/\%$	$M_{cr}/\%$	运行时间/ms
GMM	62.76	15.01	176
MRF	83.21	13.78	386
CNN	88.34	11.17	587
文中算法	98.59	7.03	121

4 结语

在分析玻璃缺陷的基础上, 首先, 提出用分数阶微分消除玻璃缺陷噪声并非线性保留玻璃缺陷的灰度特征, 选择熵、能量、相关性、对比度以及逆差距这 5 个统计量来描述玻璃缺陷图像纹理特征, 将灰度特征和纹理特征构造玻璃缺陷的双特征向量; 通过构建基于双特征向量的玻璃缺陷分割马尔科夫随机场, 利用 EM 算法迭代来完成玻璃缺陷分割; 最后, 利用模糊熵对分割结果做进一步后续处理。在实验分析部分, 不同噪声水平和参数对分割结果影响对算法的性能进行测试与分析, 证明所建立模型的合理性和有效性; 通过在自建玻璃缺陷数据集定性分析和定量分析实验, 所提算法能够克服玻璃缺陷多样性以及材料透明性给玻璃缺陷分割带来的影响, D_{ice} 指标为 98.59%,

M_{cr} 指标为 7.03%, 衡量指标优于其他对比的算法。

参考文献:

- [1] 张彩霞, 陈晓荣, 徐云洁, 等. 玻璃表面缺陷检测系统研究[J]. 包装工程, 2020, 41(13): 216—222.
ZHANG Cai-xia, CHEN Xiao-rong, XU Yun-jie, et al. Surface Defect Detection System of Glass[J]. Packaging Engineering, 2020, 41(13): 216—222.
- [2] 简川霞, 高健. 手机玻璃屏表面缺陷视觉检测方法研究[J]. 包装工程, 2018, 39(5): 16—21.
JIAN Chuan-xia, GAO Jian. Visual Detection Method for Surface Defect of Mobile Phone Screen Glass[J]. Packaging Engineering, 2018, 39(5): 16—21.
- [3] ANUBHAV T K, RENALDAS R. Identification and Characterization of Defects in Glass Fiber Reinforced Plastic by Refining the Guided Lamb Waves[J]. Materials, 2018, 11(7): 1173—1181.
- [4] SACHDEVA K, GIRDHAR A. A Technique for Glass Defect Detection[J]. International Journal of Innovative Research & Development, 2013, 2(13): 92—96.
- [5] JIN Y, WENG J, WANG Z. Conjugate Gradient Neural Network-Based online Recognition of Glass Defects[J]. Concurrency and Computation: Practice and Experience, 2017, 29(3): 3768.
- [6] 亓宁宁, 常敏, 刘雨翰. 基于机器视觉的玻璃缺陷检测[J]. 光学仪器, 2020, 42(1): 25—31.
QI Ning-ning, CHANG Min, LIU Yu-han. Glass Defects Inspection Based on Machine Vision[J]. Optical Instruments, 2020, 42(1): 25—31.
- [7] ZHOU X, WANG Y, ZHU Q, et al. A Surface Defect Detection Framework for Glass Bottle Bottom Using Visual Attention Model and Wavelet Transform[J]. IEEE Transactions on Industrial Informatics, 2020, 16(4): 2189—2201.
- [8] LIU H, CHEN Y, PENG X, et al. A Classification Method of Glass Defect Based on Multiresolution and Information Fusion[J]. The International Journal of Advanced Manufacturing Technology, 2011(56): 1079—1090.
- [9] ESCALONA U, ARCE F, ZAMORA E, et al. Fully Convolutional Networks for Automatic Pavement Crack Segmentation[J]. Computacion Sisytemas, 2019, 23(2): 451—460.
- [10] CHA Young-jin, CHOI W, BÜYÜKÖZTÜRK O. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361—378.
- [11] HANZAEI S H, AFSHAR A. Automatic Detection and Classification of the Ceramic Tiles' Surface Defects[J]. Pattern Recognition, 2017, 66: 174—189.
- [12] WANG W X, FU Y T, DONG F, et al. Infrared Ship Target Detection Method Based on Deep Convolution Neural Network[J]. Acta Optica Sinica, 2018, 38(7): 160—166.
- [13] 熊红林, 樊重俊, 赵珊, 等. 基于多尺度卷积神经网络的玻璃表面缺陷检测方法[J]. 计算机集成制造系统, 2020, 26(4): 900—909.
XIONG Hong-lin, FAN Chong-jun, ZHAO Shan, et al. Glass Surface Defect Detection Method Based on Multiscale Convolution Neural Network[J]. Computer Integrated Manufacturing Systems, 2020, 26(4): 900—909.
- [14] JIN Y, ZHANG D, LI M, et al. A Fuzzy Support Vector Machine-Enhanced Convolutional Neural Network for Recognition of Glass Defects[J]. International Journal of Fuzzy Systems, 2019, 21(6): 1870—1881.
- [15] 张丹丹, 金永, 胡缤予, 等. 基于集成深度学习的玻璃缺陷识别方法[J]. 计算机测量与控制, 2019, 27(2): 16—22.
ZHANG Dan-dan, JIN Yong, HU Bin-yu, et al. Glass Defect Recognition Method Based on Integrated Learning[J]. Computer Measurement & Control, 2019, 27(2): 16—22.
- [16] SHI J, MALIK J. Normalized Cuts and Image Segmentation[J]. IEEE Transactions on Pattern analysis and machine intelligence, 2000, 22(8): 888—905.
- [17] UMASELVI M, KUMAR S S, ATHITHYA M. Color Based Urban and Agricultural Land Classification by GLCM Texture Features[C]// Iet Chennai International on Sustainable Energy & Intelligent Systems, 2014: 1—4.
- [18] SARKAR S, DAS S, PAUL S, et al. Multi-Level Image Segmentation Based on Fuzzy-Tsallis Entropy and Differential Evolution[C]// 2013 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), IEEE, 2013: 1—8.
- [19] LIN M, ZHOU R, YAN Q, et al. Automatic Pavement Crack Detection Using HMRF-EM Algorithm[C]// 2019 International Conference on Computer, Information and Telecommunication Systems (CITS), 2019, 44(2): 502—513.
- [20] 王燕, 亓祥惠, 段亚西. 基于马尔科夫随机场的改进 FCM 图像分割算法[J]. 计算机工程与应用, 2020, 56(4): 197—201.
WANG Yan, QI Xiang-hui, DUAN Ya-xi. Improved FCM Image Segmentation Algorithm Based on Markov Random Field[J]. Computer Engineering and Applications, 2020, 56(4): 197—201.
- [21] ZHANG Y, BRADY M, SMITH S. Segmentation of Brain MR Images Through a Hidden Markov Random Field Model and the Expectation-Maximization Algorithm[J]. IEEE Transactions on Medical Imaging, 2001, 20(1): 45—57.
- [22] FELZENSZWALB P F, ZABIH R. Dynamic Programming and Graph Algorithms in Computer Vision[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(4): 721—740.