

DOI: 10.13382/j.jemi.B2306789

填充材料 CT 图像中脱粘缺陷识别与深度测量*

钟翼龙¹ 张晓凤¹ 刘祎斌¹ 王小荣²

(1. 重庆科技大学电气工程学院 重庆 401331; 2. 重庆科技大学建筑工程学院 重庆 401331)

摘要: 脱粘缺陷是影响填充材料物理安全性能的重要指标, 计算机层析成像 (CT) 是进行脱粘缺陷检测的有效方法。但填充材料脱粘缺陷紧贴外轮廓、面积小, 对比度低, 分割时易受其他信息干扰, 传统活动轮廓模型难以适用。本研究提出了一种基于 SoftMax 和正则项的 Chan-Vese (SRCV) 模型用于填充材料脱粘缺陷分割, 系统比较了 SRCV 模型与多种活动轮廓模型对脱粘缺陷分割效果的差异, 利用不同图片分割效果揭示了 SRCV 模型的抗干扰能力和兼顾全局与局部信息的能力, 利用分割曲线的欧氏距离实现脱粘深度测量。研究表明, SRCV 模型对填充材料脱粘缺陷分割更贴近脱粘边缘, 分割曲线更光滑, 准确度达 99.56%, Dice 系数为 99.82%, 脱粘深度误差不超过 6%, 特别适用于有大量干扰信息的微小脱粘缺陷的分割, 较其他活动轮廓模型具有明显的优势。

关键词: SoftMax; 活动轮廓模型; 脱粘缺陷识别与分割; 脱粘深度测量; 填充材料

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Identification and depth measurement of debonding defects in CT images of packing materials

Zhong Yilong¹ Zhang Xiaofeng¹ Liu Yibin¹ Wang Xiaorong²

(1. School of Electrical Engineering, Chongqing University of Science and Technology, Chongqing 401331, China;

2. School of Civil Engineering and Architecture, Chongqing University of Science and Technology, Chongqing 401331, China)

Abstract: The debonding defect is a crucial indicator affecting the physical safety performance of packing materials, and computed tomography (CT) stands as an effective method for its detection. However, due to the debonding defects' close to the outer contour and small area, low contrast, they are susceptible to interfere from other information during segmentation, making traditional active contour models less suitable. In order to segment the packing materials debonding defects, SoftMax and regular term Chan-Vese (SPCV) model based on Chan-Vese is proposed by introducing SoftMax and regular term in this paper. Differences in segmentation effects between the SRCV model and various active contour models were systematically compared. Segmentation results on different images are utilized to demonstrate anti-interference capabilities and balance global and local information capabilities of SRCV model. The depth of debonding was measured using Euclidean distance. When the SRCV model is used to segment the debonding defects of packing materials, the segmentation curves are closer to the debonding edges and smoother. The accuracy and the Dice coefficient were 99.56% and 99.82%, respectively. And the error of the debonding depth was not more than 6%. The results show that the SRCV model is particularly suitable for the segmentation of tiny debonding defects with a large amount of interfering information, and has obvious advantages over other active contour models.

Keywords: SoftMax; active contour model; debonding identification and segmentation; debonding depth measurement; packing materials

收稿日期: 2023-07-30 Received Date: 2023-07-30

* 基金项目: 重庆市自然科学基金面上项目 (CSTB2022NSCQ-MSX1209)、重庆科技学院人才引进科研启动项目 (ckrc2021045)、重庆科技学院科技创新项目 (YKJX2120423) 资助

0 引言

填充材料广泛应用于军工、航天等领域^[1]。填充材料在生产过程中易出现填料与壳体间的脱粘问题,这种缺陷易使填料与壳体间发生摩擦、冲击,产生热点、引起爆炸^[2],严重影响其物理和安全性能^[3]。因此,填充材料脱粘缺陷分析是评价其性能的重要指标。

无损检测是表征填充材料脱粘的有力途径,现有的无损检测技术主要有:计算机层析成像(computed tomography, CT)、超声波、红外热成像等技术。其中 CT 与超声波和红外热成像相比拥有更高的精度,达到了亚微米级。因此,使用 CT 进行填充材料脱粘检测具有很大的优势。CT 技术广泛地用于各类材料内部气孔、裂纹等的表征^[4-5]。但 CT 成像存在金属伪影、对比度低、干扰大,且灰度不均匀、边缘不明显等问题^[6]。在进行各类缺陷分割或识别时,常需对 CT 图像进行降噪、增强,再进行缺陷分割、识别。活动轮廓模型是近年来发展较快的一种图像分割方法^[7],它既能保证分割曲线的闭合,又具有精度高、可解释性强的特点,在图像处理和计算机视觉领域,尤其是 CT 图像分割中得到了广泛地应用。但现有活动轮廓模型研究主要集中在医学图像病症分割^[8-9]和材料内部结构^[10-11]、裂纹的分割^[12]等方面,尚未应用于材料脱粘缺陷分割与识别。文献[13]中提到现有活动轮廓模型中,C-V(Chan-Vese)模型、距离正则化的水平集演化(distance regularized level set evolution, DRLSE)模型关注图像全局信息;文献[14]中提到局部 Chan-Vese(local Chan-Vese, LCV)模型、局部图像拟合(local image fitting, LIF)模型和局部可伸缩拟合(region-scalable fitting, RSF)模型又受限于局部信息,易受其他不分割区域和初始轮廓的干扰。而对填充材料进行脱粘缺陷分割时需兼顾全局信息与局部信息以评价其物理和安全性能,因此,传统分割方法都难以直接适用。另外,脱粘缺陷位于填料与壳体交界边缘,脱粘尺寸微小,易受界面边缘信息干扰,这对其图像分割方法的抗干扰能力又提出了更高的要求。

通过进一步文献调研发现,Li 等^[15]通过加入贝叶斯概率为 RSF 模型提供了先验概率减少了初始轮廓对模型的影响与分割精度。Abdelkader 等^[16]通过模糊 C 均值聚类算法为 RSF 模型提供了图像的初始概率分布作为初始轮廓提升了模型分割的速度。Dong 等^[17]使用了自组织映射聚类算法为活动轮廓模型选定了局部信息区域,提高了模型的分割能力和鲁棒性。这些都是基于分布概率的活动轮廓模型,在分割精度和速度等方面都有提升。另外,在 Panda 等^[18]在脉冲神经网络中使用混合 SoftMax 函数来修改其配置,提高了模型的学习能力,减

少了参数,这说明 SoftMax 函数作为分布概率在深度学习中也有良好的性能。但目前文献尚未涉及 SoftMax 函数在活动轮廓模型中的应用,这为将 SoftMax 函数作为能量拟合项引入 C-V 模型提供了机遇。

本研究针对填充材料图像分割时易受边缘信息干扰,脱粘尺寸微小,材料性能评价时需兼顾全局信息与局部信息的需求。将图像分割任务转化为对每个像素进行分类的问题,生成更严格的分类决策边界,以增强对局部能量的拟合及抗干扰能力。针对面积项引入机器学习防止过拟合的正则项,以降低模型的复杂程度,提高模型的泛化能力,保证图像分割的光滑性与准确性。在此基础上,提出了引入 SoftMax 和正则项的改进 C-V 模型(SoftMax and regular term C-V model, SRCV)。利用 SRCV 模型实现了填充材料脱粘缺陷的有效分割。再利用脱粘缺陷边缘曲线,通过壳体轮廓到分割轮廓的欧氏距离计算脱粘深度,利用阈值识别脱粘缺陷,最终实现填充材料脱粘缺陷的有效识别与脱粘深度的精准测量。

1 基本原理

1.1 预处理与降噪

由于填充材料的 CT 图像存在冗余信息,将其剔除可避免过多轮廓信息对后续脱粘分割、识别与判断造成干扰,同时还要避免有用信息的丢失。实验通过 Canny 边缘算子去除壳体,除掉图像中冗余信息和伪影,保留脱粘部分的边缘信息。再把壳体外的像素点全部变为白色,改变背景颜色,即为预处理。在此基础上,利用双边滤波降噪,在保证边缘细节信息的完整同时兼顾空间信息和值域信息^[19],为后期图像精准分割做好准备。

1.2 C-V 模型

C-V 模型是基于区域的水平集方法,它对于要分割对象与背景的像素平均值具有明显不同的图像具有很好的效果。根据定义,C-V 模型的能量公式如式(1)所示。

$$F(c_1, c_2, C) = \mu \cdot L(C) + \nu \cdot A(C) + \lambda_1 \int_{\Omega_a} [I(x, y) - c_1]^2 dx dy + \lambda_2 \int_{\Omega_b} [I(x, y) - c_2]^2 dx dy \quad (1)$$

式中: C 表示演化曲线, Ω_a 表示曲线的内部区域, Ω_b 表示曲线外部区域。 c_1 和 c_2 表示曲线 C 内部和外部的灰度均值, μ 为长度项系数, ν 为面积项系数。 λ_1 和 λ_2 为曲线内外能量系数,一般情况下都等于 1。由于曲线 C 难以表示,所以引入水平集函数 $\Phi(x, y)$ 表示曲线 C , $\Phi(x, y)$ 为 c_0 时表示曲线内部, $\Phi(x, y)$ 为 $-c_0$ 时表示曲线外部, $\Phi(x, y)$ 为 0 时表示曲线本身,一般令 c_0 为像素点到 C 的最小距离值。把水平集函数引入至式(1)可得式(2),

其 c_1, c_2 如式(3)所示:

$$F(c_1, c_2, \Phi) = \mu \int_{\Omega} H'(\Phi) |\nabla \Phi| dx dy + \nu \int_{\Omega} H(\Phi) dx dy + \lambda_1 \int_{\Omega_a} [I(x, y) - c_1]^2 H(\Phi) dx dy + \lambda_2 \int_{\Omega_b} [I(x, y) - c_2]^2 [1 - H(\Phi)] dx dy \quad (2)$$

$$\begin{cases} c_1 = \frac{\int_{\Omega_a} I(x, y) H(\Phi) dx dy}{\int_{\Omega_a} H(\Phi) dx dy} \\ c_2 = \frac{\int_{\Omega_b} I(x, y) [1 - H(\Phi)] dx dy}{\int_{\Omega_b} [1 - H(\Phi)] dx dy} \end{cases} \quad (3)$$

式中: $H(\Phi)$ 为 Heaviside 函数。为了方便后续计算 Heaviside 函数对其取近似, 如式(4)所示, $H'(\Phi)$ 为狄拉克函数, 如式(5)所示:

$$H(\Phi) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{\Phi}{\varepsilon}\right) \right] \quad (4)$$

$$H'(\Phi) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + \Phi^2} \quad (5)$$

式中: ε 为大于 0 的常数, 其受图像灰度差影响。由于公式复杂难以求解, 使用梯度下降法可得能量泛函的偏微分方程为, 如式(6)所示:

$$\frac{\partial \Phi}{\partial t} = H'(\Phi) \left\{ \mu \cdot \operatorname{div} \left(\frac{\nabla \Phi}{|\nabla \Phi|} \right) - \nu - \lambda_1 [I(x, y) - c_1]^2 + \lambda_2 [I(x, y) - c_2]^2 \right\} \quad (6)$$

对式(6)进行迭代, 即可对图像分割。

1.3 SRCV 模型

1) 引入 SoftMax 函数

C-V 模型只考虑了像素点是否属于目标对象或背景, 而忽略了每个像素点属于不同类别的概率。因此, C-V 模型在分割时会受到其他信息的干扰, 也影响对微小目标的分割效果。SoftMax loss 函数是一种常用的损失函数, 其原理是利用 SoftMax 函数得到输出概率分布。然后使用交叉熵损失函数计算预测概率分布和真实标签之间的差异。它可以用于衡量模型预测的每个类别与真实类别之间的差异。在分类问题中, SoftMax 函数可以将模型的预测值映射到 $[0, 1]$ 的概率分布上。对于每个类别的预测值, SoftMax 函数都会将其映射为一个概率值, 表示该类别被选择的概率。因此, SoftMax 函数的输出可以被解释为模型对每个类别的置信度。在图像分割中, SoftMax 函数的优势在于它考虑了每个像素点属于不同类别的概率^[20], 从而能够更好地衡量模型预测的准确性。因此, SoftMax loss 函数可以更准确地衡量模型的分割效果以引导模型正确的进行分割。此外, SoftMax loss

函数还可以处理不均衡的数据集, 即不同类别的样本数量不均衡的情况, 有效增强了模型抗噪声能力。SRCV 模型中, 定义了前景概率为 $p = H(\Phi)$ 以及生成真实标签图像 y_{true} , 其公式如式(7)所示。

$$y_{true}(I(x, y)) = \frac{1}{(1 + \exp(I(x, y)))} \quad (7)$$

接着使用交叉熵损失函数计算损失即 SoftMax loss 函数, 记为 $loss$, 其公式如式(8)所示。

$$loss(p) = - \int \sum p \times \log(y_{true}) dp \quad (8)$$

为了提高该模型的精度, 计算扰动后的损失, 分别记为 $loss_{perturbed}$, 并重新计算 $loss$ 的值如式(9)所示。

$$loss = \frac{(loss_{perturbed} - loss)}{e^{-5}} \quad (9)$$

对 $loss$ 进行归一化处理, 得到最终的能力拟合项 c_3 , 如式(10)所示。

$$c_3 = \operatorname{sigmoid}(loss) = \frac{1}{(1 + e^{-loss})} \quad (10)$$

以式(10)为基础, 构造基于 SoftMax loss 函数的能量拟合 $E^{softmax}$ 如式(11)所示。

$$E^{softmax} = - \lambda_3 \int_{\Omega_a} [I(x, y) - c_3]^2 H(\Phi) dx dy \quad (11)$$

2) 引入正则项

采用 C-V 模型进行图像分割计算时, 因图像被离散化会产生一定的误差。随着 C-V 模型不断的迭代, 水平集函数会发生震荡, 模型需不断初始化, 从而影响分割的精度。加之填充材料脱粘缺陷微小, 对分割精度需求高, 因此 C-V 模型难以满足。为此, 在 C-V 模型中引入带符号距离函数的正则项, 在水平集函数尚未演化完成时对演化曲线进行引导, 当水平集演化到最小时保证该正则项为 0, 避免水平集函数发生震荡、模型不断被初始化、对演化曲线产生错误引导。

因此, 引入的正则项需满足: 1) 具有最小点; 2) 符号距离函数的模为 1; 3) 在某一点斜率为 0; 4) 函数曲线光滑, 具体如式(12)所示:

$$P(\Phi) = \int \frac{1}{2} (|\nabla \Phi(x)| - 1)^2 dx \quad (12)$$

式中: $P(\Phi)$ 为正则项函数, $|\nabla \Phi(x)|$ 为水平集函数梯度的模。当水平集函数梯度的模 $|\nabla \Phi(x)|$ 为 1 时, 正则项 $P(\Phi)$ 为最小值 0。具体实施过程: 用正则项 $P(\Phi)$ 替换式(1)原模型中的面积项 $A(C)$ 再结合式(12), 结果如式(13)所示:

$$F(c_1, c_2, c_3, \Phi) = \nu \int_{\Omega} \frac{1}{2} (|\nabla \Phi| - 1)^2 dx dy +$$

$$\mu \int_{\Omega} H'(\Phi) |\nabla \Phi| dx dy + \lambda_1 \int_{\Omega_a} [I(x, y) - c_1]^2 H(\Phi) dx dy +$$

$$\lambda_2 \int_{\Omega_b} [I(x,y) - c_2]^2 [1 - H(\Phi)] dx dy + \lambda_3 \int_{\Omega} [I(x,y) - c_3]^2 H(\Phi) dx dy \quad (13)$$

由此 SRCV 模型的梯度流公式为式 (14) 所示:

$$\frac{\partial \Phi}{\partial t} = H'(\Phi) \left\{ \mu \cdot \operatorname{div} \left(\frac{\nabla \Phi}{|\nabla \Phi|} \right) - \nu \left[\nabla^2 \Phi - \operatorname{div} \left(\frac{\nabla \Phi}{|\nabla \Phi|} \right) \right] - \sum_{i=1}^3 \lambda_i [I(x,y) - c_i]^2 \right\} \quad (14)$$

然后使用最速下降法对模型进行迭代以分割图像。

3) 脱粘深度测量计算方法

通过 SRCV 模型得到分割结果后,利用沿壳体边缘法方向,计算壳体边界上第 i 点 (x,y) 到脱粘轮廓最近点的欧氏距离 ρ_i ,可得到边缘处脱粘的深度 d_i 。欧氏距离和脱粘深度计算公式如式 (15) 所示:

$$d_i = \rho_i = \sqrt{(x - x_0)^2 + (y - y_0)^2} \quad (15)$$

其中, x_0 和 y_0 分别为脱粘轮廓点的纵坐标和横坐标。通过阈值设定,可判定材料的脱粘缺陷。计算方法示意图如图 1 所示。颜色稍浅方块代表壳体轮廓上像素点,颜色稍深方块代表分割曲线上像素点, P_1 代表壳体上一像素点, P_2 代表分割曲线上像素点, L_1 代表 P_1 像素点的切线, L_2 代表切线的法向切线。脱粘深度具体计算方法为:1) 根据像素点 P_1 的前后 1 个像素带点拟合出切线 L_1 ;2) 根据 L_1 求取其法向切线 L_2 ;3) 沿 L_2 的方向搜索对应分割轮廓上的像素点 P_2 ;4) 计算 P_1 和 P_2 两点间的欧氏距离;5) 重复以上步骤直到壳体上每一个像素点都被计算过为止;6) 根据计算的欧氏距离画出脱粘深度图,并利用线性插值使曲线更为平滑。

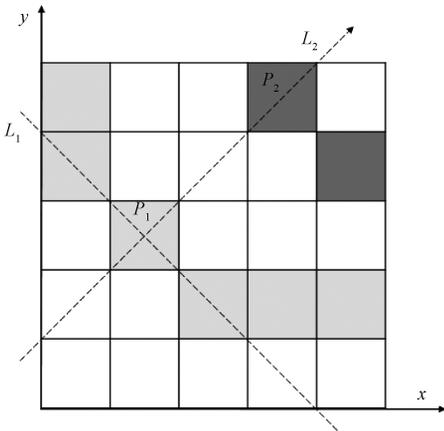


图 1 脱粘深度计算方法示意图

Fig. 1 Schematic diagram of debonding depth calculation method

2 实验结果与分析

2.1 SRCV 模型分割结果

对填充材料 CT 图像进行去除壳体、改变背景颜色的

预处理,再利用双边滤波进行降噪,图像预处理和双边滤波后结果如图 2 所示。



图 2 预处理和双边滤波后图像比较

Fig. 2 Comparison of images after pre and BF

图像分割过程中的评价标准采用 Dice 相似系数。Dice 系数是一种集合相似度量指标,通常用于计算两个样本的相似度。此处 Dice 系数是通过计算分割结果与专业工程师人工分割结果间的相似程度计算,Dice 系数使用(Dice similarity coefficient, DSC)值对两个样本评价,值的范围为 0~1,分割结果最好即与人工分割最相似时值为 1,最差时值为 0。其公式为:

$$DSC = \frac{2TP}{2TP + FP + FN} \quad (16)$$

式中: TP 表示分割与实际相同的部分, FP 表示分割出来与目标不同的部分, FN 表示未分割到的部分。

实验使用操作系统为 Window10 专业工作站版,CPU 型号为 Intel(R) i7-11800H,内存 16 GB,使用编程语言为 C++。利用 SRCV 模型进行图像分割时,通过多次实验优化,采用 $\lambda_3 = 0.1, \nu = 0.003 \times 255 \times 255, \varepsilon = 5$, 步进 step=0.1,迭代次数 $n = 50$ 次,选择初始轮廓位置为以图像中坐标 (10, 10) 为左上角起点的 20x20 的矩形,得到分割结果如图 3 所示。

由图 3(b)可看出,采用 SRCV 模型分割出的曲线与填充材料界面轮廓贴合得较好,对全局信息拟合较好。由图 3(a)和(c)可看出,分割出的曲线能明显区分出所有脱粘部分,且对于微小的脱粘区域也能进行较好的拟合。这说明利用 SRCV 模型,兼顾了图像的局部信息与全局信息,可实现对填充材料脱粘缺陷的分割。

2.2 SRCV 模型与其他算法的比较

为了更进一步验证实验提出的 SRCV 模型在填充材料脱粘缺陷分割的优势,原始样本图像经预处理和双边滤波降噪后,分别采用 RSF 模型、LIF 模型、DRLSE 模型、局部和全局强度拟合(Local and global intensity fitting, LGIF)模型、C-V 模型和 SRCV 进行图像分割,比较其在脱粘界面的分割效果。各模型参数均经大量实验调试,在最优的情况下获得,结果如图 4 所示。

由图 4 可知,采用 C-V 模型和 DRLSE 模型时更关注

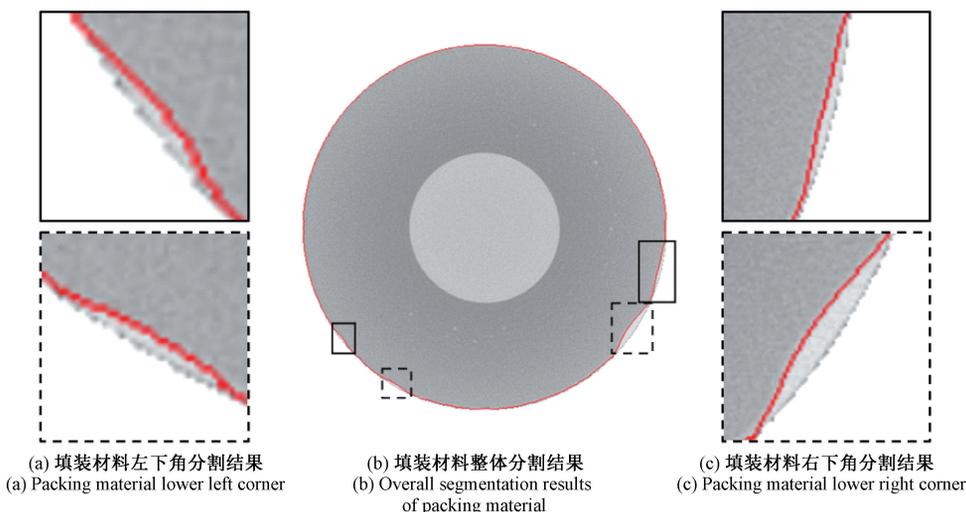
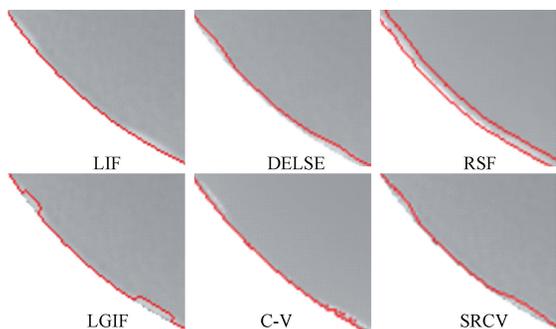
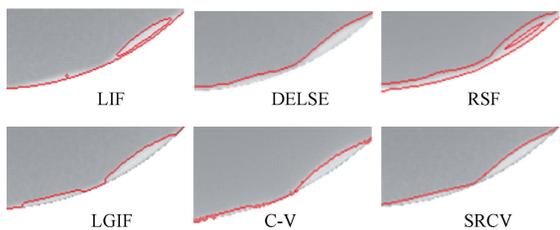


图 3 SRCV 模型的图像分割结果

Fig. 3 Results of SRCV model



(a) 对应分割图左下部位
(a) Left part of the image



(b) 对应分割图右下部位
(b) Right part of the image

图 4 不同算法分割效果比较

Fig. 4 Comparison of segmentation results using different algorithms

于图像的全局信息,分割出的曲线不够光滑,且 C-V 模型不能对较小的脱粘缺陷进行分割。采用 LIF 模型、LGIF 模型和 RSF 模型时更关注于局部信息,对较小的脱粘缺陷分割能力较差,且 RSF 与 LIF 分割出多个轮廓增加了干扰。而采用 SRCV 模型时,分割出的曲线相对较光滑,与脱粘和图像边缘的拟合程度较好。结合图 3(b) 填充材料整体分割效果可知,利用 SRCV 模型分割得到的曲

线和材料轮廓贴合度较好,这说明 SRCV 模型还能较好地兼顾全局信息。各分割方法 Dice 指标、准确率、迭代次数以及计算时间如表 1 所示。

表 1 Dice 指标、准确率、迭代次数与时间比较

Table 1 Comparison of Dice, accuracy, Number of iterations and time

算法	DSC 指标	准确率	迭代次数	时间/s
LIF	0.925 9	86.21	80	18.85
DRLSE	0.992 7	98.55	200	45.44
RSF	0.950 4	90.55	100	28.82
LGIF	0.990 0	98.02	120	33.45
C-V	0.996 9	99.40	80	20.89
SRCV	0.998 2	99.56	50	8.02

由表 1 可知, SRCV 模型的 DSC 值和准确率最高,与真实轮廓更接近,分割效果最好。这说明 SRCV 增加的正则项是有效的,使模型兼顾全局与局部,微小区域能分割,同时保持壳体区域的光滑。同时 SRCV 模型分割图像时所需的迭代次数和时间也最少,说明实验采用的预处理、双边滤波与 SRCV 模型联合的方法更适用于填充材料的脱粘缺陷分割,精度最高,速度最快只需 8.02 s,这有利于后续脱粘深度计算。

为了进一步验证 SRCV 模型的抗干扰能力,实验选用典型色盲识别图片,由大小不一的各种轮廓组合成“25”和背景。若只分割目标图形“25”时,其背景信息必对其产生大量干扰,具体分割结果如图 5 所示。

由图 5 可知, LIF 模型分割出了目标图形“25”,但在 1 000 次迭代情况下,依然未完成整个图像的全部分割。DRLSE 模型、RSF 模型、LGIF 模型和 C-V 模型同时分割出了“25”和背景中各种大小不一的轮廓,但无法实现只

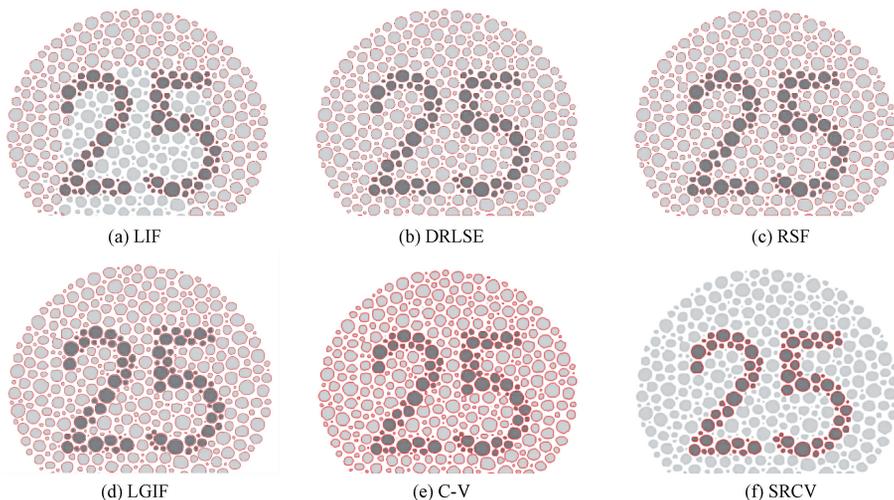


图 5 不同算法抗干扰能力比较

Fig. 5 Comparison of anti-interference ability of different algorithms

对目标图形“25”的有效分割,依然受不分割背景信息的干扰,说明其抗干扰能力较差。而 SRCV 模型可在较低迭代次数 (<100) 的情况下针对性地分割出目标图形“25”,而不分割背景信息,这说明 SRCV 模型可针对局部

能量进行快速拟合,分割目标可控,抗干扰能力强。

在此基础上,又进一步验证了 SRCV 模型对全局与局部信息的兼顾特性,以体现其分割优势。实验分析比较了 RSF、CV 和 SRCV 模型对图 6 的分割结果。

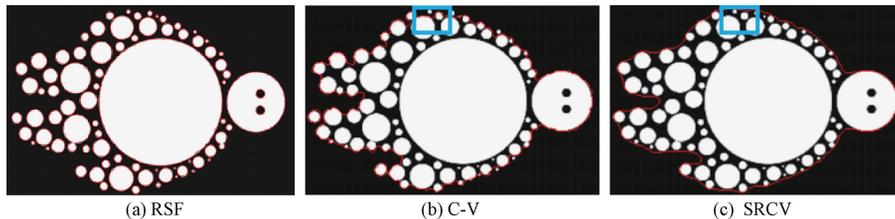


图 6 其他图像分割效果

Fig. 6 Other image segmentation effects

RSF 可以通过调节高斯核的大小来控制能量拟合区域的大小,由图 6 可知,即使在高斯核很大的情况下,RSF 模型也只能将样本中小圆分割出来,不能实现图像整体分割,说明其更关注局部信息,缺少对整体信息的把握。而 C-V 模型和 SRCV 模型能实现图像的整体分割,且在细节上 SRCV 分割的轮廓与图像边缘更为接近。这说明利用 SRCV 模型可实现同一张图片中不同目标的有效分割,分割更为精准,避免人工的参与,这些对填充材料的脱粘缺陷分析是非常有利的。

2.3 脱粘缺陷识别与深度测量

利用脱粘深度计算方法(图 1)计算脱粘深度,结果如图 7(a)所示。原图中每像素尺寸 0.781 mm,通过阈值设定,可判定材料的脱粘缺陷。实验设定阈值为 2 个像素点即 1.562 mm,以此为脱粘缺陷判定依据,如图 7(b)所示。

由图 7(b)可得,填充材料的脱粘缺陷有 4 处,脱粘

深度从高到低依次为 1.660、1.693、2.481 和 6.256 mm。这与通过人工依据像素点计算的结果:1.723、1.746、2.619 和 6.627 mm 误差在 6% 以内,故 SRCV 模型分割图像的精度较高,对于脱粘的检测较为准确,其深度计算的方法满足精度需求。图 7(c)为判定后的脱粘部分标识图,可明显体现出填充材料的脱粘情况。

2.4 应用

本研究针对填充材料 CT 图像的脱粘缺陷检测,提出了一种基于 SoftMax 和正则项函数的 SRCV 模型。为了验证该方法的有效性,分别比较了两个不同填充材料样本经 SRCV 分割前后的对比图,结果如图 8 所示。

由图 8 可知,样本 1、2 采用 SRCV 模型分割的脱粘缺陷效果均很好,分割曲线光滑与脱粘轮廓较为贴合,且对所有脱粘缺陷都有反应,得到的脱粘深度图与真实脱粘情况一致。这表明 SRCV 模型能兼顾全局和局部信息,非常适用于填充材料脱粘缺陷的分割。同时,本文使

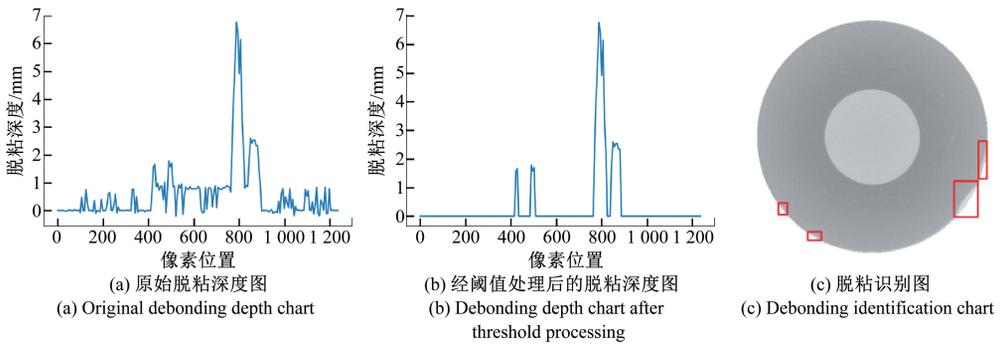


图 7 脱粘深度计算与判定

Fig. 7 Calculation and determination of debonding depth

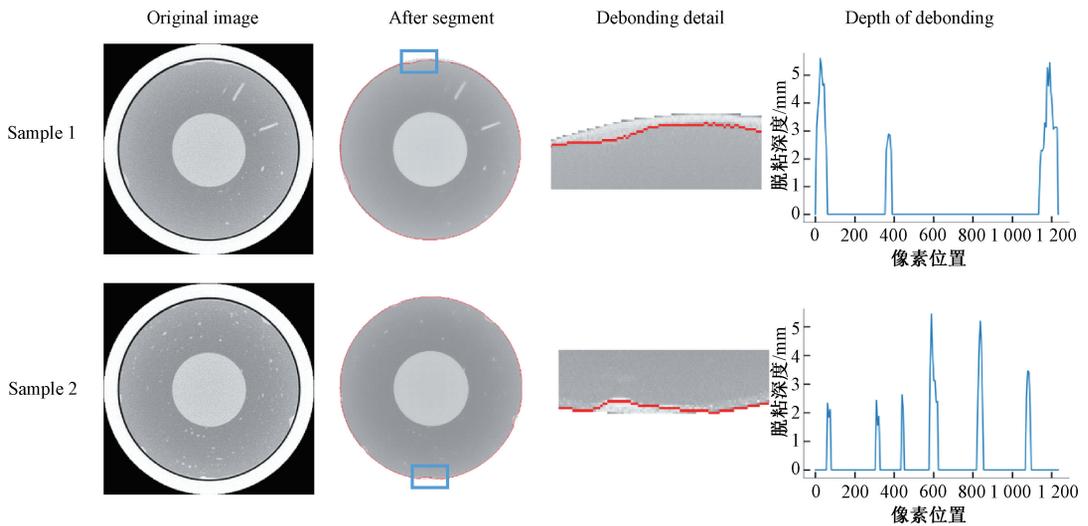


图 8 SRCV 模型在不同图像脱粘缺陷中的应用

Fig. 8 Application of SRCV model to different image debonding defects

用的测量方法也能正确反应脱粘曲线的真实数量与深度。

同时,为了检验 SRCV 模型的抗干扰能力,对填充材料 CT 图像中加入了不同种的噪声和不同强度的噪声,并使用 SRCV、C-V 以及 RSF 模型进行分割比较,结果如图 9 所示,其中从左到右分别为高斯核为 10,20,30 的高斯噪声、椒盐噪声以及泊松噪声。

由图 9 可知,SRCV 模型在加入高斯噪声、椒盐噪声以及泊松噪声时均能保证脱粘缺陷的正确分割,且未错误分割任何噪声,而其他模型存在脱粘缺陷漏分,错误分割噪声等情况,这表明 SRCV 模型抗干扰能力强,分割精准,在有干扰且微小区域图像的分割中有更大的优势。

3 结 论

针对填充材料 CT 图像中脱粘缺陷微小、噪声、背景信息与边缘信息干扰等问题,在对图像分割时需兼顾全

局信息与局部信息,常见活动轮廓模型难以实现其精准分割。本文通过引入 SoftMax 和正则项,提出了一种基于 C-V 模型的 SRCV 图像分割模型。实验结果表明:SRCV 模型能较精准的分割出微小区域脱粘缺陷,特别是存在边缘信息与背景信息干扰的微小区域脱粘的分割中,较其他活动轮廓模型抗干扰能力更强,分割的曲线更贴近脱粘界面边缘,分割的曲线更光滑,分割的效果更精准,其分割准确度达 99.56%,脱粘深度计算误差不超过 6%,较其他模型在分割精度上更具有有一定优势,可以满足工业上自动化脱粘识别及深度测量的需求。这对后续脱粘深度对于填充材料性能影响的研究有指导意义。

参考文献

[1] 李干,王志军,李运禄,等. 轻金属填充材料 PELE 的数值仿真研究 [J]. 兵器装备工程学报, 2016, 37(9): 54-57.

LI G, WANG ZH J, LI Y L, et al. Numerical calculation of light metal filling material PELE [J].

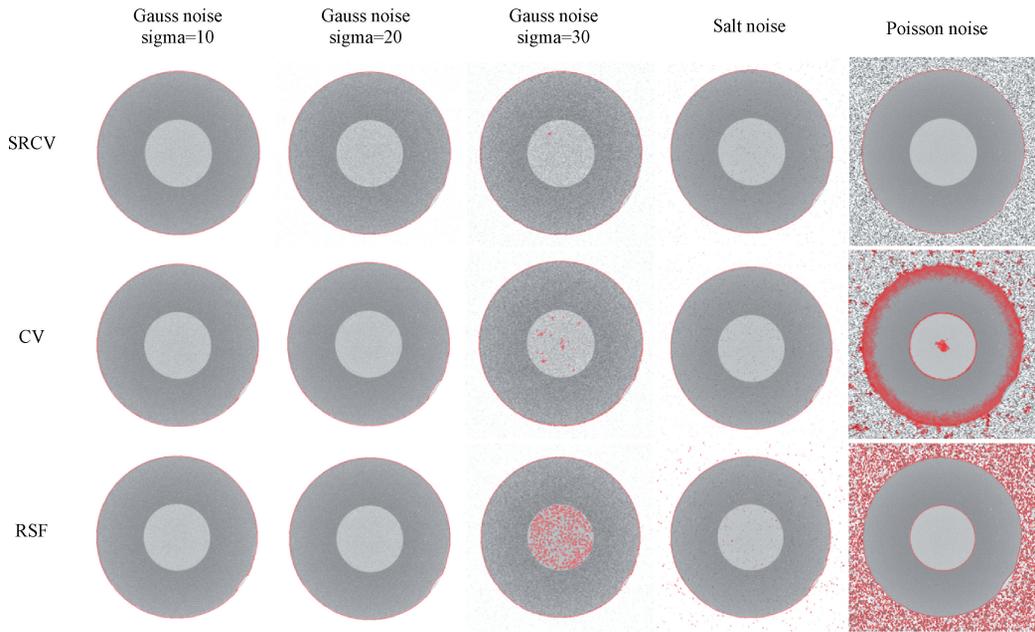


图 9 加噪声图像分割结果

Fig.9 Noisy image segmentation result

Journal of Ordnance Equipment Engineering, 2016, 37(9): 54-57.

- [2] 高峰, 张泽. 含装药缺陷的固体火箭发动机性能评估综述[J]. 兵工学报, 2021, 42(8): 1789-1802.

GAO F, ZHANG Z. Review on performance evaluation of solid rocket motors with charge defects [J]. Acta Armamentarii, 2021, 42(8): 1789-1802.

- [3] 周清春, 鞠玉涛, 韦震, 等. 端羟基聚丁二烯推进剂/衬层脱粘的断裂机理与断裂能获取研究[J]. 兵工学报, 2014, 35(7): 990-995.

ZHOU Q CH, JU Y T, WEI ZH, et al. Investigation of fracture mechanism and fracture energy of HTPB propellant/liner interface debonding [J]. Acta Armamentarii, 2014, 35(7): 990-995.

- [4] GARCEA S C, WANG Y, WITHERS P J. X-ray computed tomography of polymer composites [J]. Composites Science and Technology, 2018, 156: 305-319.

- [5] 张理泽, 沈宽, 张博. 基于改进 SIFCM 和区域生长的三维 CT 图像缺陷体积测量[J]. 电子测量与仪器学报, 2023, 37(6): 77-85.

ZHANG L Z, SHEN K, ZHANG B. Defect volume measurement in 3D CT image based on improved SIFCM and region growing [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (6): 77-85.

- [6] 夏平, 彭程, 施宇, 等. 复 Contourlet 域 TS-MRF 模型的医学 CT 影像分割[J]. 国外电子测量技术, 2022,

41(10): 155-163.

XIA P, PENG CH, SHI Y, et al. CT image segmentation based on tree-structured MRF model in complex contourlet domain [J]. Foreign Electronic Measurement Technology, 2022, 41(10): 155-163.

- [7] 王蒙, 马意. 基于平流矢量场和弥散流改进的几何活动轮廓模型 [J]. 电子测量技术, 2021, 44 (1): 114-119.

WANG M, MA Y. Improved geometric active contour model based on advection vector field and diffusion flows [J]. Electronic Measurement Technology, 2021, 44(1): 114-119.

- [8] CHEN X, WILLIAMS B M, VALLABHANENI S R, et al. Learning active contour models for medical image segmentation [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11632-11640.

- [9] 陈业航, 李智, 冯宝, 等. 基于改进的活动轮廓模型的胸膜接触型肺结节分割[J]. 仪器仪表学报, 2019, 40(11): 107-116.

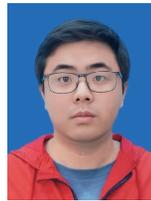
CHEN Y H, LI ZH, FENG B, et al. Pleural contact pulmonary nodule segmentation based on improved active contour model [J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 107-116.

- [10] 倪康, 吴一全, 庚嵩. 基于改进区域项 CV 模型的金相图像分割[J]. 光学学报, 2018, 38(4): 200-208.

NI K, WU Y Q, GENG S. Segmentation of metallographic image based on improved CV model

- integrated with local fitting term[J]. *Acta Optica Sinica*, 2018, 38(4): 200-208.
- [11] 王珏, 张秀英, 蔡玉芳, 等. 联合小波变换和 RSF 模型的 CT 图像分割方法[J]. *光学学报*, 2020, 40(21): 57-65.
WANG J, ZHANG X Y, CAI Y F, et al. CT image segmentation method combining wavelet transform and RSF model[J]. *Acta Optica Sinica*, 2020, 40(21): 57-65.
- [12] 赵振兵, 徐磊, 戚银城, 等. 基于 Hough 检测和 C-V 模型的航拍绝缘子自动协同分割方法[J]. *仪器仪表学报*, 2016, 37(2): 395-403.
ZHAO ZH B, XU L, QI Y CH, et al. Automatic co-segmentation method for aerial insulator based on Hough detection and C-V model [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(2): 395-403.
- [13] 王相海, 方玲玲. 活动轮廓模型的图像分割方法综述[J]. *模式识别与人工智能*, 2013, 26(8): 751-760.
WANG X H, FANG L L. Survey of image segmentation based on active contour model[J]. *Pattern Recognition and Artificial Intelligence*, 2013, 26(8): 751-760.
- [14] 蔡玉芳, 王涵, 李琦, 等. 联合自然梯度和 AdamW 算法的 RSF 图像分割模型[J]. *仪器仪表学报*, 2023, 44(3): 261-270.
CAI Y F, WANG H, LI Q, et al. RSF image segmentation model joint natural gradient and AdamW algorithm[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(3): 261-270.
- [15] LI Y, CAO G, WANG T, et al. A novel local region-based active contour model for image segmentation using Bayes theorem [J]. *Information Sciences*, 2020, 506: 443-456.
- [16] ABDELKADER R, RAMOU N, KHORCHEF M, et al. Segmentation of X-ray image for welding defects detection using an improved Chan-Vese model [J]. *Materials Today: Proceedings*, 2021, 42: 2963-2967.
- [17] DONG B, WENG G R. Active contour model driven by self organizing maps for image segmentation[J]. *Expert Systems with Applications*, 2021, 177: 114948.
- [18] PANDA P, AKETI S A, ROY K. Toward scalable efficient, and accurate deep spiking neural networks with backward residual connections stochastic SoftMax, and hybridization [J]. *Frontiers in Neuroscience*, 2020, 14: 653.
- [19] CHEN B H, TSENG Y S, YIN J L. Gaussian-adaptive bilateral filter [J]. *IEEE Signal Processing Letters*, 2020, 27: 1670-1674.
- [20] REN J, YU C, MA X, et al. Balanced meta-SoftMax for long-tailed visual recognition [J]. *Advances in Neural Information Processing Systems*, 2020, 33: 4175-4186.

作者简介



钟翼龙, 2020 年于重庆三峡学院获得学士学位, 现为重庆科技大学硕士研究生, 主要研究方向为 CT 图像处理。

E-mail: 3420588046@qq.com

Zhong Yilong received his B. Sc. degree from Chongqing Three Gorges University in 2020. Now he is a M. Sc. candidate in Chongqing University of Science and Technology. His main research interest includes CT image processing.



张晓凤(通信作者), 分别于 1999 年、2004 年和 2016 年在重庆大学获得学士、硕士及博士学位, 现为重庆科技大学副教授, 主要研究方向为图像处理、图像缺陷识别。

E-mail: 2021019@cqust.edu.cn

Zhang Xiaofeng (Corresponding author) received her B. Sc. degree, M. Sc. degree and Ph. D. degree from Chongqing University in 1999, 2004 and 2016, respectively. Now she is an associate professor in Chongqing University of Science and Technology. Her main research interests include image processing and image defect recognition.