

DOI: 10.19650/j.cnki.cjsi.J2210656

联合自然梯度和 AdamW 算法的 RSF 图像分割模型^{*}

蔡玉芳^{1,2}, 王 涵^{1,2}, 李 琦^{1,2}, 王小军^{1,2}

(1. 重庆大学光电工程学院 重庆 400044; 2. 重庆大学工业 CT 无损检测教育部工程研究中心 重庆 400044)

摘 要: 关键零件内部复杂结构的精密测量是高端制造领域攻克的难题。当采用工业 CT 技术实现对象内部结构精密测量时, 面临目标图像灰度不均匀性、边缘模糊、伪影等问题。有鉴于此, 本文研究了局部能量最小化模型(RSF)的图像分割方法, 引入自然梯度和 AdamW 算法分别提高了 RSF 模型的收敛速度和参数自适应性。首先, 在统计流形上计算自然梯度, 提高梯度下降效率和 RSF 模型收敛速度; 其次, 采用 AdamW 算法实现 RSF 模型的高斯核函数尺度大小自适应控制。与经典 RSF 模型相比, 改进后的 RSF 模型迭代次数减少了 1 353 次, 迭代次数降低约 76.79%, 迭代时间减少约 43.61%, 测针球面半径和航空燃油喷嘴圆柱直径测量误差均较小, 既保持了原模型亚像素分割精度, 又大幅提高了模型收敛速度和鲁棒性。

关键词: 主动轮廓模型; 水平集; 自然梯度; AdamW 算法; 高斯核函数; 参数自适应; 图像分割

中图分类号: TP391 TH89 **文献标识码:** A **国家标准学科分类代码:** 520.6040

RSF image segmentation model joint natural gradient and AdamW algorithm

Cai Yufang^{1,2}, Wang Han^{1,2}, Li Qi^{1,2}, Wang Xiaojun^{1,2}

(1. College of Optoelectronic Engineering, Chongqing University, Chongqing 400044, China; 2. Engineering Research Center of Industrial Computed Tomography Nondestructive Testing of the Ministry of Education, Chongqing University, Chongqing 400044, China)

Abstract: The internal complex structure precision measurement of key part is a challenge in the field of high quality manufacturing. When the industrial CT technology is used to achieve precise measurement of the internal structure of the object, it faces problems of grayscale inhomogeneity, blurred edges, and artifacts of the target image. In view of these, the local energy minimization model (RSF) image segmentation method is investigated in this article. The natural gradient and AdamW algorithms are used to improve the convergence speed and parameter adaptivity of the RSF model, respectively. First, the approximate natural gradients are computed on the statistical manifold to improve gradient descent efficiency and RSF model convergence speed. Secondly, the AdamW algorithm is utilized to realize the adaptive control of the scale of the Gaussian kernel function of the RSF model. Compared with the classical RSF model, the improved RSF model reduces the number of iterations by 1 353, the number of iterations by about 76.79%, the iteration time by about 43.61%, and the low measurement errors of the probe-radius and the diameter of jet fuel nozzle cylinder, which not only maintains the sub-pixel segmentation accuracy of the original model, but also significantly improves the convergence speed and robustness of the model.

Keywords: active contour model; level set; natural gradient; AdamW algorithm; gaussian kernel function; parameter adaptation; image segmentation

0 引 言

随着智能制造时代和工业 4.0 的快速推进, 高精度和高效已成为高端制造领域的重要目标^[1], 利用工业

CT 技术实现复杂结构精密零件的高精度测量也是重要行业的迫切需求。工业 CT 图像感兴趣区域的精确分割, 不仅是高精度测量的前提保障, 也是工业 CT 技术研究重点和热点问题之一。工业 CT 图像区别于其他类型图像, 如合成孔径雷达图像与核磁共振图像, 存在着目标图像

灰度不均匀、边缘模糊及环状伪影等问题,其严重影响图像的分割精度。同时,高分辨率成像意味着巨大数据量,对图像分割方法的计算效率提出了更高的要求。

主动轮廓模型(active contour model, ACM)不仅能得到光滑且封闭的轮廓,而且边缘定位精度为亚像素级,因此引起研究者广泛关注。主动轮廓模型按照分割形式分为基于边缘和基于区域两大类;按照局部信息利用程度又分为基于局部信息、全局信息以及联合局部信息和全局信息^[2]三大类。相比基于全局信息的模型,基于局部信息的主动轮廓模型具有对噪声和初始轮廓不敏感、鲁棒性强等优点^[3-4],同时更适用于多材质、异形物体的准确分割。针对工业 CT 图像的特点,基于局部区域信息的主动轮廓模型^[4]更有利于轮廓的精确定位。

Bai 等^[5]采用基于图形的双向生成森林(bothway spanning forest, BSF)算法实现预分割,并采用区域可扩展拟合(region-scalable fitting, RSF)模型的水平集方法精细分割。该算法有效地应用于声纳图像的精确分割;文献^[6]成功将距离正则化水平集演化模型、RSF 模型和局部图像拟合模型(local image fitting, LIF)用于大脑磁共振成像(magnetic resonance imaging, MRI)图像尾状核的分割,实验结果表明 3 种模型对强度不均匀的医学图像均能取得良好的分割效果。

综合来讲,RSF 模型在实际的应用中表现更为优异^[7]。由于利用局部信息的模型均存在计算复杂、收敛性差等问题,要实现高精度、高效率分割,简单地增加计算设备性能并不能满足实际生产要求。因此,分割算法收敛性能的优化是需要研究解决的问题。

Charpiat 等^[8]分析指出传统主动轮廓模型定义的梯度主要取决于内积的选择,于是提出了优化梯度流的方法,以减少传统主动轮廓模型曲线演化过程中陷入不相关局部最小值的概率;Bar 等^[9]根据变化微积分框架中的一般准则,推导出一种广义的牛顿迭代方法,实验结果表明,其在计算效率和抗噪性能方面具有优势。

同时,对比 RSF 模型与 CV 模型^[10]的能量泛函,RSF 模型本质是强度信息局部化的近似 CV 模型。实际上,两者能量拟合项可以近似归纳为 Lankton 等^[4]提出的梯度下降能量项一类。参照 Pereyra 等^[11]提出的快速收敛的黎曼梯度下降法,本文在统计流形上构造自然梯度(natural gradient),从而有效优化参数空间。

相比其他基于局部信息的主动轮廓模型,RSF 模型的优势是区域可伸展性,其拟合能量的强度是以当前像素为中心的局部区域,且区域大小由核函数控制,因此核函数的尺度是 RSF 模型一个重要参数。在初始轮廓相同的情况下,不同尺度的核函数有着不同的收敛速度和分割结果。因此,对 RSF 模型主要参数的恰当控制是提高收敛速度和分割精度的重要环节。

最速梯度下降具有一阶收敛速度,而自适应动量估计(adaptive moment estimation, Adam)是梯度二阶矩,具有二阶收敛速度,Adam 及其改进算法 AdamW 已广泛用于深度学习中最优化算法学习率的提升^[12-14]。

综上所述,针对 RSF 模型计算复杂度高、收敛速度慢、对参数敏感等问题,利用自然梯度和 AdamW 算法对 RSF 模型从参数空间和参数控制两个方面进行优化,既提高 RSF 模型收敛速度,又实现核函数尺度的自适应变化,在保证图像分割质量的同时大幅提升分割效率。

1 理论基础

1.1 RSF 模型

为解决灰度不均匀图像的分割问题,Li 等^[3]引入高斯核函数优化活动轮廓模型,提出了 RSF 模型使得模型具有良好的局部特性,较好地实现了图像区域的分割。RSF 模型图像分割基本原理简述如下。

设 x 是灰度图像域 Ω 中的一点, $x \in \Omega, I: \Omega \in \mathbb{R}^2; C$ 是图像 Ω 中的一个闭合曲线,它将图像 Ω 分为两个子区域 Ω_1 和 Ω_2 , $f_1(x)$ 和 $f_2(x)$ 分别是对应子区域的灰度近似值,RSF 模型的能量泛函公式为:

$$\varepsilon(C, f_1(x), f_2(x)) = \sum_{i=1}^2 \lambda_i \iint_{\Omega} K(x-y) |I(y) - f_i(x)|^2 dx dy + \nu |C| \quad (1)$$

其中, $I(y)$ 代表以 x 为中心的局部区域内一点 y 的灰度值, $\lambda_1 \geq 0, \lambda_2 \geq 0$, 为内外轮廓的权重系数, ν 为长度项系数。

进一步,增加正则化项的 RSF 模型能量泛函水平集形式为:

$$F^{\text{RSF}}(\varphi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \iint_{\Omega} K(x-y) |I(y) - f_i(x)|^2 M_i[\varphi(y)] dx dy + \nu \int |\nabla H_{\varepsilon}[\varphi(x)]| dx + \frac{1}{2} \mu \int (|\nabla \varphi(x)| - 1)^2 dx \quad (2)$$

其中, $M_1[\varphi(y)] = H[\varphi(y)], M_2[\varphi(y)] = 1 - H[\varphi(y)], f_i(x)$ 表示轮廓两侧图像强度近似拟合函数:

$$f_i(x) = \frac{K_{\sigma}(x) \cdot [M_i(\varphi(x))I(x)]}{K_{\sigma}(x) \cdot M_i(\varphi(x))}, i = 1, 2 \quad (3)$$

通常用光滑的 Heaviside 函数 H_{ε} 来近似 H 。 H_{ε} 和 δ_{ε} 分别是 Heaviside 函数和 Dirac 函数的正则化函数,且 δ_{ε} 是 H_{ε} 的导数,它们的表达式分别为:

$$\begin{cases} H_{\varepsilon}(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{x}{\varepsilon}\right) \right] \\ \delta_{\varepsilon}(x) = H'_{\varepsilon}(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2} \end{cases}, \quad (4)$$

通常,采用梯度下降法来计算最小化能量拟合函数,如式(5)所示。

$$\frac{\partial \varphi}{\partial t} = -\delta_\varepsilon(\varphi)(\lambda_1 e_1 - \lambda_2 e_2) + \nu \delta_\varepsilon(\varphi) \operatorname{div}\left(\frac{\nabla \varphi}{|\nabla \varphi|}\right) + \mu \left[\nabla^2 \varphi - \operatorname{div}\left(\frac{\nabla \varphi}{|\nabla \varphi|}\right) \right] \quad (5)$$

式中:等式右边第1项为数据拟合项,表征轮廓向目标边界移动量;第2项调节轮廓的长度和平滑程度, ν 为长度项系数;第3项为水平集正则项,用来维持水平集函数的正则性, μ 为水平集正则化系数, $e_i(x)$ 的表达式为:

$$e_i(x) = \int K_\sigma(y-x) |I(x) - f_i(y)|^2 dy, \quad i = 1, 2 \quad (6)$$

由式(5)可以看出,RSF模型参数多且对初始参数敏感,同时梯度的各向异性导致迭代过程易陷入局部最优,仅具有一阶收敛速度。

1.2 利用自然梯度提高 RSF 模型的收敛性

本文针对灰度不均匀图像其灰度变化具有各向异性和随机性的特点,在RSF模型中引入自然梯度。自然梯度是黎曼流形变化的度量,类似于欧式空间牛顿下降法具有二阶收敛速度和各向同性等优点^[15-19]。

依据Pereyra等^[11]通用黎曼最速下降法,先利用信息几何获取与活动轮廓相关的统计流形,然后在统计流形上求解自然梯度^[20]可极大提高收敛效率。

设 Ω 是 $\mathbb{R}^D$ 的有界子集, $y: \Omega \rightarrow \mathbb{R}^p$ 为由 p 个通道组成的 D 维图像,本文研究图像为二维灰度图,即 $D=2$, $p=1$ 。假设 y 由前景 Ω_1 和背景 $\Omega_2 = \Omega/\Omega_1$ 构成,在点 $x \in \mathbb{R}^D$ 图像值有如下统计分布模型:

$$\begin{aligned} y(x) &\sim f(\cdot | \theta_1) \quad \text{if } x \in \Omega_1 \\ y(x) &\sim f(\cdot | \theta_2) \quad \text{if } x \in \Omega_2 \end{aligned} \quad (7)$$

其中, θ_1 和 θ_2 分别是与前景和背景相关的统计参数, $f: \mathbb{R}^p \rightarrow \mathbb{R}^+$ 表示指数分布的概率密度函数。应用水平集方法^[21-22]来求解能量最小化的曲线,并引入虚拟时间 t 的扰动以求解欧拉-拉格朗日方程,即得到实际处理的梯度下降流:

$$\phi_{t+1} = \phi_t + \gamma_t \nabla_\phi E(y; \phi_t) \quad (8)$$

$$(\nabla_\phi E(y; \phi_t))_i = -\delta((\phi_t)_i)(\log f(y_i | \theta_1) - \log f(y_i | \theta_2)) \quad (9)$$

其中, $\delta(x)$ 函数为:

$$\delta(x) = \frac{1}{\pi} \left(\frac{\varepsilon}{\varepsilon^2 + x^2} \right) \quad (10)$$

式(8)中各向异性梯度是模型需要大量迭代才可能收敛的根本原因,采用正定矩阵 $\mathbf{A}(\phi)$ 对梯度进行优化^[19]。考虑到水平集函数属于非欧几里德空间,可通过内积 $\langle \phi', \mathbf{A}(\phi) \phi \rangle$ 直接在 ϕ 空间上求梯度,设空间 M 是由 ϕ 参数化的统计流形^[23],其概率密度函数 $F(y|\phi)$

为:

$$F(y|\phi) = \prod_{\{i: \phi_i > 0\}} f(y_i | \theta_1) \prod_{\{i: \phi_i < 0\}} f(y_i | \theta_2) \quad (11)$$

其中, $f(y_i | \theta)$ 为指数族概率密度函数。 M 上的点 ϕ 表示随机变量 Y 的概率分布 $F(y|\phi) = P[Y \leq y]$ 。

对比式(9)和(11)可知,计算能量最小化与计算给定 y 的 ϕ 的最大似然估计量的意义相同。 ϕ 和另一点 ϕ' 之间的距离在流形空间 M 难以直接计算,我们采用具有黎曼度量张量的Fisher信息矩阵 $\mathbf{G}$ 来度量:

$$(\mathbf{G}(\phi))_{(i,j)} = -E_{Y|\phi} \left\{ \frac{\partial^2}{\partial \phi_i \partial \phi_j} \log[f(Y|\phi)] \right\} \quad (12)$$

则在流形空间 M 上能量 E 的最陡下降梯度流为:

$$\phi_{t+1} = \phi_t + \gamma_t \mathbf{G}^{-1}(\phi_t) \nabla_\phi E(y; \phi_t) \quad (13)$$

其中, $\mathbf{G}^{-1}(\phi_t) \nabla_\phi E(y; \phi_t)$ 表征能量 $E(y; \phi) = -\log f(y|\phi)$ 在黎曼流形空间的自然梯度,表示 E 相对于 ϕ 的概率分布 $F(y|\phi)$ 的变化,而不是相对于 ϕ 自身的变化。

1.3 AdamW 自适应 RSF 模型参数

在统计流形空间用自然梯度替代欧式空间梯度,从本质上提升了RSF模型的收敛速度,但由于模型参数较多,需要参数自适应优化算法。

Li等^[3]的研究表明,在初始轮廓和其余参数相同条件下,不同尺度的卷积核其图像分割结果也迥然不同。本文旨在曲线演化过程中自适应改变卷积核尺度,从而在保证精度的前提下提升收敛速度。

相比于传统梯度优化算法,自适应优化算法引入学习率作为迭代步长,其可以沿着负梯度方向不断逼近最优值,因而能够大幅节省计算时间^[24]。在诸多自适应优化算法中,Diederik等^[13]提出的Adam算法充分利用了梯度二阶矩,提高了算法的鲁棒性和收敛速度。Loshchilov等^[25]引入加权衰减思想提出优化的AdamW算法,既继承了Adam算法的高效、内存占用小等优点,又提升了算法性能,解决了Adam算法可能不存在最优解^[26]和收敛速度慢等问题。因此,本文在RSF模型迭代过程中引入AdamW算法,以达到参数自适应调整的目的。AdamW优化模型为:

$$h_t = h_{t-1} - \eta_t \left(\frac{\alpha \hat{m}_t}{\sqrt{\hat{v}_t} + \varepsilon_{Adamw}} + w h_{t-1} \right) \quad (14)$$

式中:

$$g_t = \nabla f_t(h_{t-1}) \quad (15)$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (16)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (17)$$

$$\hat{m}_t = m_t / (1 - \beta_1^t) \quad (18)$$

$$\hat{v}_t = v_t / (1 - \beta_2^t) \quad (19)$$

本文初始参数设定为:学习率 $\alpha = 0.01$, 当前估计的指数衰减率 $\beta_1 = 0.9, \beta_2 = 0.999$, 权重衰减因子 $w = 0.01$, 迭代系数 $\eta_i = 1$, $f(h)$ 为参数 h 下的损失函数, 一阶矩动量 $m_{i=0} = 0$, 二阶矩动量 $v_{i=0} = 0$, 初始化时间步长 t , 迭代参数 $h_{i=0}$, 为防止除数为 0, 采用 $\varepsilon_{Adamw} = 10^{-8}$ 。

其中, 式(16)和(17)实际上是对动量指数做加权平均, 而式(18)和(19)是对 m_i 和 v_i 进行偏差修正。

2 联合自然梯度和 AdamW 算法的 RSF 模型

RSF 模型在精细化分割图像时表现优异, 但存在计算复杂、收敛速度较慢等问题。实际应用中, 虽然可以借用多分辨率图像框架^[27-29]低分辨图像的思想对模型进行加速, 但是只能简单加快运算速度, 难以实现尺寸大且边缘模糊的复杂图像的精确分割。

本文提出的联合自然梯度和 AdamW 算法的 RSF 图像分割模型(以下简称 NGA-RSF 模型)首先采用自然梯度方法提高 RSF 模型的收敛性, 再利用 AdamW 算法自适应调整 RSF 模型参数, 既避免陷入局部最优, 又提升 RSF 模型收敛速度和鲁棒性。NGA-RSF 模型实现过程描述如下。

首先, 计算黎曼度量张量的 Fisher 信息矩阵 $\mathbf{G}$ 。由式(11)和(12)可知, 直接求解 Fisher 信息矩阵 $\mathbf{G}$ 较为困难^[30-32], 一般采用自然梯度的近似计算。本文将 RSF 模型中局部拟合值 $f_1(x)$ 和 $f_2(x)$ 分别替代为模型中强度均值, 利用能量项局部化后的简化梯度下降流来计算 Fisher 信息矩阵 $\mathbf{G}$ 。

其次, 考虑到 RSF 模型的水平集正则项本质上保留了水平集函数的正则性, 同时又避免了水平集函数迭代过程中重新初始化^[3], 本文主要采用 Fisher 信息矩阵 $\mathbf{G}$ 对原梯度流进行优化, 最后得到以下水平集迭代方程:

$$\phi_{i+1} = \phi_i + \gamma_i \mathbf{G}^{-1} \left((\phi_i) \left(-\delta(\phi_i) (\lambda_1 e_1 - \lambda_2 e_2) + v \delta(\phi_i) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \left(\nabla^2 \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right) \right) \right) \quad (20)$$

$$e_i(x) = \int K_\sigma(y-x) |I(x) - f_i(y)|^2 dy \quad (21)$$

其中, ϕ_i 表示第 i 次迭代的水平集函数, γ_i 为时间步长, $\mathbf{G}$ 是根据式(12)计算得到的 Fisher 信息矩阵, $\delta(\cdot)$ 为式(10)所示的狄拉克三角函数, λ 表示为轮廓内外能量拟合项的系数, e_i 表示能量拟合项, μ 表示模型的正则项系数, v 表示模型的长度项系数。

综上, 本文所提出的 NGA-RSF 模型如式(22)所示。为了减少模型的卷积运算次数, 保证迭代条件可控, 本文设置了 AdamW 算法的参数控制条件, 即在指定迭代次数后才对指定参数进行控制, 使得 AdamW 算法在控制条件

下都能保证梯度下降, 如式(22)所示, 其中 σ_i 代表当前高斯核函数参数, 计算公式如式(23)所示, 核函数公式如(24)所示, $\mathbf{G}^{-1}(\phi_i)$ 可以通过式(12)计算。NGA-RSF 模型实现流程如下: 首先, 对图像预处理。根据实际情况, 对图像进行降噪等处理以提高分割准确性^[33]; 然后, 设置目标函数和初始参数。接着, 目标函数迭代。在执行完初始迭代次数后, 再根据参数控制条件, 采用 AdamW 算法来自适应调节 RSF 模型的高斯核大小 σ ; 若满足收敛条件, 则结束流程并输出分割结果。

$$\phi_{i+1} = \phi_i + \gamma_i \mathbf{G}^{-1}(\phi_i) \left\{ \left\{ -\delta(\phi_i) \sum_{i=1}^2 \left[(-1)^{i+1} \times \lambda_i \int K_{\sigma_i}(y-x) \left| I(x) - \frac{K_{\sigma_i}(y) \cdot [M_i(\phi(y))I(y)]}{K_{\sigma_i}(y) \cdot M_i(\phi(y))} \right|^2 dy \right] \right\} + v \delta(\phi_i) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \left(\nabla^2 \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right) \right\} \quad (22)$$

$$\sigma_i = \sigma_{i-1} - \eta_i (\alpha \hat{m}_i / (\sqrt{\hat{v}_i} + \varepsilon_{adamw}) + w \sigma_{i-1}) \quad (23)$$

$$K_{\sigma_i}(y) = \frac{1}{(2\pi)^{n/2} \sigma_i^n} e^{-|y|^2 / 2\sigma_i^2} \quad (24)$$

3 实验与分析

为验证 NGA-RSF 算法的应用效果, 分别从总体分割效果、分割精度以及收敛性 3 个方面来比较 NGA-RSF 模型相对 CV、RSF 算法的优越性。本文实验在 Intel(R) Core(TM) i7-10700 CPU @ 2.90 GHz 处理器, 内存 16 GB, Windows 10 专业版 64 位, MATLAB R2018b 环境下完成。

除特别说明, 实验中采用以下基本参数: $\mu = 1, v = 0.001 \times 255 \times 255, c_0 = 2, \lambda_1 = \lambda_2 = 1, \Delta t = 0.1$, 涉及的参数 μ 表示模型的正则项系数, v 表示模型的长度项系数, c_0 表示初始水平集为二进制阶跃函数的幅值, λ_1 和 λ_2 分别表示为轮廓内外能量拟合项的系数, Δt 表示模型时间步长, n 表示模型的迭代次数, ε 表示函数 $H(\cdot)$ 与函数 $\delta(\cdot)$ 中参数, σ 表示 RSF 模型、NGA-RSF 模型的高斯核函数尺寸, n_0 表示 NGA-RSF 模型的参数控制前的初始迭代次数。

3.1 总体分割效果

为比较 CV 模型、RSF 模型、NGA-RSF 模型对伪影的鲁棒性和图像总体分割效果, 选择了含有多个强度不均匀圆、燃油喷嘴、复杂铸件、叶片等的 CT 图像作为实验对象, 如图 1 所示。

按照表 1 参数, 分别采用 CV、RSF、NGA-RSF 等模型得到分割结果如图 2 所示。其中, 实线为实验分割结果, 虚线为设置的初始轮廓。




图 1 总体分割效果对比实验用图像

Fig. 1 The images for the overall segmentation effect comparison

由图 2 可知,对于图 1(a)存在多个强度不同的圆形区域,利用全局信息的 CV 模型并不能分割出所有感兴趣目标,而基于局部信息的 RSF 模型和 NGA-RSF 模型均能找到目标,但 RSF 模型存在欠分割情况,目标图像周围尚存在未收敛的、不必要的轮廓,而 NGA-RSF 模型较好地分割出多个圆形目标,这表明尺度参数的合理控制能够增强模型的鲁棒性,取得良好分割结果;图 1(b)燃油喷嘴图像存在环状伪影和弱边缘,CV 模型易受到环形伪影干扰,导致内部空腔轮廓严重偏离真实边缘,RSF 模型则比 CV 模型表现较好,分割轮廓基本接近零件边缘,但在图像左下角所示局部区域轮廓并未完全分割,而 NGA-RSF 算法能获得较好的分割结果;图 1(c)铸件结构




图 2 各算法总体分割效果

Fig. 2 The overall segmentation effect of different algorithms

虽然复杂,但图像均匀且噪声水平低,3 种模型均能分割出良好结果;图 1(d)叶片图像尺寸较大,CV 和 NGA-RSF 模

表 1 总体分割效果对比实验参数				
Table 1 The parameters for the overall segmentation effect comparison				
图像	图像尺寸/Pixel	CV	RSF	NGA-RSF
图 1(a)	500×500	$n = 94$	$n = 94$	$n = 94$
		$\varepsilon = 4$	$\varepsilon = 4$	$\varepsilon = 4$
			$\sigma = 12$	$\sigma = 12$
				$n_0 = 80$
图 1(b)	576×576	$n = 10$	$n = 10$	$n = 10$
		$\varepsilon = 1$	$\varepsilon = 1$	$\varepsilon = 1$
			$\sigma = 40$	$\sigma = 40$
				$n_0 = 1$
图 1(c)	256×256	$n = 7$	$n = 7$	$n = 7$
		$\varepsilon = 5$	$\varepsilon = 5$	$\varepsilon = 5$
			$\sigma = 10$	$\sigma = 10$
				$n_0 = 1$
图 1(d)	844×844	$n = 19$	$n = 19$	$n = 19$
		$\varepsilon = 1$	$\varepsilon = 1$	$\varepsilon = 1$
			$\sigma = 10$	$\sigma = 10$
				$n_0 = 10$

型仅在 19 次迭代后均就能分割出完整叶片轮廓,而 RSF 模型在当前参数下仍存在欠分割,表现为多余的轮廓。

3.2 分割精度对比


为比较 CV 模型、RSF 模型、NGA-RSF 模型的图像分割精度,本实验选择球径为 6 mm、球度为 0.5 μm 的红宝石测针 CT 切片为实验对象,如图 3 所示,每层图像矩阵为 1 472 $\times$ 1 472,像素大小为 0.05 mm,测针球面半径实际长度为 60 pixel。利用 3 种模型分别对测针序列 CT 切片中球体切片进行分割和球半径拟合,最后与测针实际球面半径进行比较,实验所用参数如表 2,测针球面半径拟合结果及绝对误差见表 3。以测针球面半径像素长度 60 为真值,依据球面半径拟合结果经校准消除系统误差后的结果来评价 3 种模型的分割精度。从表 3 绝对误差可看出,除了第 1、7、8 号测针球半径误差较大外,NGA-RSF 模型分割测量误差较均小于 CV 和 RSF。总体上讲,NGA-RSF 模型分割精度优于 CV 和 RSF,满足实际测量需求。

进一步,采用航空某燃油喷嘴样件检验模型的分割精度和测量误差。如图 4 所示,分别对喷嘴 A、B、C 三个部位序列 CT 切片中圆柱体部分进行分割和直径拟合。其中,图 4(a)为喷嘴 CT 三维重建图像,图 4(b)为 A/B 部位 CT 切片,图 4(c)为 C 部位 CT 切片。采用微焦 CT 对喷嘴进行扫描,具体扫描参数见表 4,各模型分割参数见表 5。


表 3 各模型分割测针球面半径拟合结果及绝对误差

Table 3 Fitting radius and absolute error of the probe sphere segmented by different models


测针 编号	切片序列	校准前/Pixel			校准后/Pixel			测量误差/mm		
		CV	RSF	NGA-RSF	CV	RSF	NGA-RSF	CV	RSF	NGA-RSF
1	114~132	60.279 5	60.203 8	60.163 0	60.014 1	59.985 8	60.125 7	0.000 7	-0.000 7	0.006 3
2	144~132	60.372 6	60.281 9	60.102 9	60.106 8	60.063 6	60.065 7	0.005 3	0.003 2	0.003 3
3	114~132	60.318 2	60.272 7	60.049 7	60.052 7	60.054 4	60.012 5	0.002 6	0.002 7	0.000 6
4	114~133	60.279 3	60.244 6	60.029 4	60.013 9	60.026 4	59.992 2	0.000 7	0.001 3	-0.000 4
5	114~132	60.212 9	60.192 4	60.022 3	59.947 8	59.974 4	59.985 1	-0.002 6	-0.001 3	-0.000 7
6	115~133	60.170 5	60.145 8	59.980 2	59.905 6	59.928 0	59.943 0	-0.004 7	-0.003 6	-0.002 8
7	115~133	60.277 7	60.228 5	59.990 9	60.012 3	60.010 4	59.953 7	0.000 6	0.000 5	-0.002 3
8	115~132	60.212 2	60.175 0	59.959 7	59.947 1	59.957 1	59.922 6	-0.002 6	-0.002 1	-0.003 9



(a) 三维图像
(a) 3D image



(b) A/B部位CT切片
(b) CT slice at A/B



(c) C部位CT切片
(c) CT slice at C

图 4 喷嘴 CT 三维图和切片图

Fig. 4 CT 3D image and slice of nozzle

以万分尺和塞规测定的圆柱直径为真值,来评价 3 种模型的测量误差,如图 5 所示,A 部位测量外径为 1.489 6 mm、C 部位测量外径为 7.801 3 mm,B 部位则采




图 3 测针 CT 三维图像

Fig. 3 CT 3D image of probes

表 2 各模型测针球面分割参数

Table 2 The segmentation parameters of probe sphere with different models

CV 模型	RSF 模型	NGA-RSF 模型
$n = 300$	$n = 300$	$n = 300$
$\varepsilon = 15$	$\varepsilon = 15$	$\varepsilon = 15$
	$\sigma = 55$	$\sigma = 55$
		$n_0 = 100$

表 4 CT 扫描参数

Table 4 CT scan parameters

源-物体距离 /mm	源-探测器距离 /mm	探测器单元 大小/mm	像素大小 /mm
30.250 0	1 100.000 0	0.200 0	0.005 5

用塞规测量内径为 0.401 0 mm。从表 6 圆柱直径拟合结果可看出,在分割喷嘴 A 部位时,各模型均能实现高精度分割,且本文模型测量误差最小;在分割喷嘴 B 部位细小圆柱时,CV 模型测量误差较大,原因是在分割 B 部位部

表 5 各模型喷嘴分割参数

Table 5 Segmentation parameters of nozzle images with different models

CV 模型	RSF 模型	NGA-RSF 模型
$n = 20$	$n = 20$	$n = 20$
$\varepsilon = 0.5$	$\varepsilon = 0.5$	$\varepsilon = 0.5$
	$\sigma = 400$	$\sigma = 400$
		$n_0 = 1$




图 5 万分尺测量喷嘴场景

Fig. 5 The scene of measuring nozzle with a micrometer

表 6 各模型分割燃油喷嘴圆柱直径拟合值及其误差

Table 6 Fitting diameters and errors for the fuel nozzle cylinder CT images segmented by different models

部位	真实直径/mm	CV 直径/mm	RSF 直径/mm	NGA-RSF 直径/mm	CV 误差/mm	RSF 误差/mm	NGA-RSF 误差/mm
A	1.489 6	1.512 6	1.508 1	1.507 4	0.023 0	0.018 5	0.017 8
B	0.401 0	0.541 5	0.425 3	0.420 2	0.140 5	0.024 3	0.019 2
C	7.801 3	7.826 6	7.825 0	7.825 1	0.025 3	0.023 7	0.023 8

分切片时未完全收敛,导致拟合圆柱误差较大,本文模型测量误差最小,且比 RSF 模型降低 20.95%;在喷嘴 C 部位,本文模型和 RSF 模型测量误差相近,均小于 CV 模型。总体上讲,本文模型在分割喷嘴各部位时保持了高精度分割优势,整体分割结果优于 RSF 模型和 CV 模型。

3.3 收敛性对比

当图像存在边缘模糊、噪声大或环状伪影,且目标图像间的灰度差异较大时,传统阈值分割算法难以得到理想分割结果,采用主动轮廓模型也难以确保准确地收敛。特别地,当图像尺寸较大时,主动轮廓模型迭代过程的卷积运算极为耗时。

为对比 CV、RSF 和 NGA-RSF 模型在处理大尺寸工业 CT 图像收敛性能,本文选取大小为 1 944 pixel×1 944 pixel 的 CT 图像为实验对象,如图 6(a)所示,图像中含有矩形钢制量块和陶瓷针规,由于射线硬化等因素的影响,量块图像灰度不均匀且呈现干涉条纹,导致该类图像的精确分割极为困难。采用式(25)作为迭代停止条件,各模型的实验参数如表 7 所示。分割结果如图 6(b)、(c)、(d),其中虚线为初始轮廓,实线为分割结果。

表 7 收敛性对比实验参数

Table 7 Experimental parameters for convergence comparison

CV 模型	RSF 模型	NGA-RSF 模型
$\varepsilon = 1$	$\varepsilon = 1$	$\varepsilon = 1$
	$\sigma = 80$	$\sigma = 80$
		$n_0 = 100$

$|S_{i+100} - S_i| < 10^{-5}$ (25)

$S_i = \frac{\|\phi_{i-1}\|_2}{\|\phi_i\|_2}$ (26)

S_i 的计算公式见式(26),其表示迭代前后水平集矩阵的 L_2 范数的比值。考虑到较大尺寸图像卷积运算较为耗时,而 RSF 模型与 NGA-RSF 模型均需要执行多个卷积运算,因此本文采用信号频域乘积的反傅里叶变换的原理^[34]实现模型初步加速,最终得到表 8 中各模型收敛需要的迭代次数和耗时情况。

表 8 各模型的迭代次数

Table 8 Interaction times of each model

模型	迭代次数	总耗时/s	单次迭代时长/s
CV 模型	1 921	1 820	0.947
RSF 模型	1 762	3 078	1.747
NGA-RSF 模型	409	1 737	4.242

进一步分析算法收敛性。从图 6(b)可以看出,CV 模型中量块欠分割且针规未被分割;当迭代次数相同时,图 6(c)RSF 模型中量块也存在欠分割,同时针规分割轮廓极不规则;NGA-RSF 模型则能够较好地分割量块和针规,不仅迭代次数少,而且对伪影和噪声有良好的抑制能力。综合分析迭代次数和耗时情况,如表 8 所示,CV 单次迭代时长较小,但多次迭代仍未收敛;RSF 模型不仅单次迭代耗时较长,且多次迭代仍未得到较好分割效果;NGA-RAF 模型尽管单次迭代较为耗时,但由于有良好的收敛特性,只需较少迭代次数能够得到精确分割结果;相比 RSF 模型,NGA-RAF 迭代次数降低约 76.79%(1 353 次),分割耗时减少 43.61%,实验表明 NGA-RSF 具有较好的收敛特性。




图 6 算法的收敛性对比
Fig. 6 Convergence comparison of algorithms

4 结 论

针对 RSF 模型收敛性能低等难题,通过分析研究 RSF 模型与 CV 模型能量拟合项异同,本文提出了基于自然梯度与 AdamW 算法的 RSF 模型,既保持了 RSF 模型亚像素分割精度的优势,又减小了迭代过程中陷入局部最优的概率,显著提高了 RSF 模型的收敛性能。实验结果表明,在分割多材质强度不均匀图像、复杂结构图像、弱边缘兼有伪影的图像时,提出的 NGA-RSF 算法均表现出较好的收敛性能和分割精度,满足高精度测量需求。

NGA-RSF 模型主要提高了 RSF 模型的收敛速度,后续研究工作将深入研究解决 RSF 模型对初始轮廓敏感、参数设置繁杂等问题。

参考文献

[1] 王荣峰,曹迪,林娜. 复杂零件精密尺寸测量方法的研究进展[J]. 机电工程技术,2021,50(7):12-14.
WANG R F, CAO D, LIN N. Research progress of precision dimension measurement method for complex parts [J]. Mechanical and Electrical Engineering Technology, 2021, 50(7):12-14.

[2] ZHANG K H, ZHANG L, SONG H H, et al. Active contours with selective local or global segmentation: A new formulation and level set method [J]. Image and Vision Computing, 2010,28(4):668-676.

[3] LI C,KAO C,GORE J C,et al. Minimization of region-scalable fitting energy for image segmentation [J]. IEEE Transactions on Image Processing, 2008, 17 (10): 1940-1949.

[4] LANKTON S, TANNENBAUM A. Localizing region-based active contours [J]. IEEE Transactions on Image Processing, 2008, 17(11):2029-2039.

[5] BAI Y, XIE X, LI G, et al. A fast graph-based method for object segmentation in sidescan sonar image [C]. 2018 7th International Symposium on Next Generation Electronics (ISNE), 2018.

[6] CHEN Y, CHEN G, WANG Y, et al. A distance regularized level-set evolution model-based MRI dataset segmentation of brain' s caudate nucleus [J]. IEEE Access,2019,7:124128-124140.

[7] 刘明,杨胜寒,高诚辉. 基于水平集方法的划痕形状表面视觉测量 [J]. 仪器仪表学报, 2020, 41 (2): 184-194.
LIU M, YANG SH H, GAO CH H. Surface shape vision measurement for scratch based on level set [J]. Chinese Journal of Scientific Instrument,2020,41(2):184-194.

[8] CHARPIAT G, MAUREL P, PONS J P, et al. Generalized gradients: Priors on minimization flows [J]. International Journal of Computer Vision, 2007,73(3):325-344.

[9] BAR L, SAPIRO G. Generalized newton-type methods for energy formulations in image processing. [J]. Siam Journal on Imaging Sciences, 2009, 2(2):508-531.

[10] CHAN T F, VESE L A. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2):266-277.

[11] PEREYRA M, BATATIA H, MCLAUGHLIN S. Exploiting information geometry to improve the convergence of nonparametric active contours [J]. IEEE Transactions on Image Processing, 2014, 24 (3): 836-845.

[12] ZHAO L, SHANG Z, ZHAO L, et al. Software defect

- prediction via cost-sensitive siamese parallel fully-connected neural networks[J]. *Neurocomputing*, 2019, 352(AUG. 4):64-74.
- [13] DIEDERIK P K, JIMMY B. Adam: A method for stochastic optimization[C]. *International Conference on Learning Representations (ICLR)*, 2015.
- [14] 王浩然, 李国勇, 徐传洪, 等. 基于深度学习的开放域引导对话生成模型[J]. *计算机应用*, 2021, 41(S2):66-70.
- WANG H R, LI G Y, XU CH Q, et al. Open domain guided dialogue generation model based on deep learning[J]. *Journal of Computer Applications*, 2021, 41(S2):66-70.
- [15] AMARI S, NAGAOKA H. Methods of information geometry[M]. *American Mathematical Soc*, 2000, 191.
- [16] RAO C R. Information and the accuracy attainable in the estimation of statistical parameters[J]. *Reson. J. Sci. Educ*, 1945, 20: 78-90.
- [17] MARC A, FRÉDÉRIC B, YANG L. Riemannian medians and means with applications to radar signal processing[J]. *J. Sel. Topics Signal Processing*, 2013, 7(4):595-604.
- [18] ZHOU E, HU J. Gradient-based adaptive stochastic search for non-differentiable optimization [J]. *IEEE Transactions on Automatic Control*, 2014, 59(7):1818-1832.
- [19] AMARI S, DOUGLAS S C. Why natural gradient? [C]. *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP*, 1998(2):1213-1216.
- [20] AMARI S. Information geometry [J]. *International Statistical Review*, 2021, 89(2):1-48.
- [21] LI C, XU C, GUI C, et al. Distance regularized level set evolution and its application to image segmentation[J]. *IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society*, 2010, 19(12):3243-3254.
- [22] FAUGERAS O, KERIVEN R. Variational principles, surface evolution, PDE's, level set methods and the stereo problem [J]. *IEEE Transactions on Image Processing*, 1998, 7(3):336-344.
- [23] AMARI S. Differential-geometrical methods in statistics[J]. *Lecture Notes on Statistics*, 1985, 28:96-102.
- [24] 林文强. 自适应优化算法在比例风险模型上的一些应用[D]. 武汉: 武汉大学, 2019.
- LIN W Q. Some applications of adaptive optimization algorithm in proportional hazards model [D]. Wuhan: Wuhan University, 2019.
- [25] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization[C]. *International Conference on Learning Representations (ICLR)*, 2019.
- [26] SASHANK J R, SATYEN K, SANJIV K. On the convergence of Adam and beyond [C]. *International Conference on Learning Representations (ICLR)*, 2018.
- [27] THÉVENAZ P, RUTTIMANN U E, UNSER M. A pyramid approach to subpixel registration based on intensity[J]. *IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society*, 1998, 7(1):27-41.
- [28] DO M N, VETTERLI M. The contourlet transform: An efficient directional multiresolution image representation[J]. *IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society*, 2005, 14(12):2091-2106.
- [29] LIU J, YANG Y H. Multiresolution color image segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 1994, 16(7):689-700.
- [30] ROGER B G, JAMES M. A kronecker-factored approximate fisher matrix for convolution layers [C]. *International Conference on Machine Learning*, 2016.
- [31] MARTENS J. New Insights and perspectives on the natural gradient method[J]. *Journal of Machine Learning Research*, 2020, 1:1-76.
- [32] AMARI S I, KARAKIDA R, OIZUMI M. Fisher information and natural gradient learning of random deep networks [J]. *JMLR: Workshop and Conference Proceedings*, 2018, 2010:1-9.

[33] 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.

[34] GONZALEZ R C, WOODS R E. Digital image processing[J]. IEEE Transactions on Acoustics Speech and Signal Processing, 1980, 28(4):484-486.

作者简介



蔡玉芳 (通信作者), 1998 年于西北师范大学获得学士学位, 2002 年于重庆大学获的硕士学位, 现为重庆大学副研究员和硕士生导师, 主要研究方向为仪器科学与技术、模式识别与图像处理、工业 CT 技术与系统。

E-mail: caiyf@cqu.edu.cn

Cai Yufang (Corresponding author) received her B. Sc. degree from Northwest Normal University in 1998, and received her M. Sc. degree from Chongqing University in 2002. She is currently an associate fellow and a master advisor at Chongqing University. Her main research interests include instrument science and technology, pattern recognition and image processing, industrial computed tomography technology and system.



王涵, 2020 年于成都信息工程大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为仪器科学与技术、工业 CT 图像处理。

E-mail: 913524698@qq.com

Wang Han received his B. Sc. degree from Chengdu University of Information Technology in 2020. He is currently a master student at Chongqing University. His main research interests include instrument science and technology, and industrial CT image processing.