

李红光, 刘颖, 石凌霄. 能量自适应的快速水平集图像分割模型[J]. 智能计算机与应用, 2024, 14(7): 174–181. DOI: 10.20169/j.issn.2095–2163.240728

能量自适应的快速水平集图像分割模型

李红光, 刘颖, 石凌霄

(广西电网有限责任公司 贵港供电局, 广西 贵港 537100)

摘要: 针对灰度不均匀图像和噪声图像的分割难问题, 本文提出一种高斯窗口和权重自适应的快速水平集图像分割模型。首先, 融入新边缘指示函数生成全局能量项, 利用新边缘指示函数构造自适应高斯核函数, 并由此构建局部能量项; 其次, 利用演化曲线内外灰度拟合均值差和局部可变区域灰度均值差构造自适应权控函数, 使模型能自适应地调节全局力和局部力的比重; 最后, 采用有限差分法进行数值求解。实验结果表明, 本文模型能有效分割灰度不均匀图像和噪声图像, 提高了分割效率和对初始轮廓的鲁棒性。

关键词: 图像分割; 边缘指示函数; 高斯窗口; 自适应权控函数

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 2095–2163(2024)07–0174–08

A fast-level set image segmentation method with adaptive energy

LI Hongguang, LIU Ying, SHI Lingxiao

(Guigang Power Supply Bureau of Guangxi Power Grid Co., Ltd, Guigang 537100, Guangxi, China)

Abstract: A fast-level set image segmentation model-method with adaptive energy is proposed for the segmenting of gray scale inhomogeneous images and noisy images. Firstly, the global energy term is generated by incorporating the new edge indicator function in the global fitting term. The adaptive Gaussian kernel function is constructed using the new edge indicator function. constructing the local energy term. The adaptive weight control function is constructed using the difference between the mean value of the gray scale fitting inside and outside the evolution curve and the mean value of the gray scale difference in the local variable region. The model can thus adjust the weight of the global force and the local force adaptively. Finally, the finite difference method is used for the numerical solution. The results show that the model in this paper can effectively segment gray scale inhomogeneous images and noisy images. The model can also improve the segmentation efficiency and robustness to the initial contours.

Key words: image segmentation; edge indicator function; Gaussian window; adaptive weight control function

0 引言

图像分割是图像处理的关键步骤, 其目的是从图像中分割出感兴趣目标^[1]。目前, 基于水平集的几何活动轮廓模型是图像分割领域的研究热点, 本质是将二维空间的演化曲线嵌入到高一维可变动的水平集函数中, 使演化曲线能够产生各种复杂的拓扑形状, 是一种灵活多样的数值计算方法, 具有计算精度高、稳定性好的优点^[2–3]。几何活动轮廓模型又可归纳为基于边缘的模型和基于区域的模型, 分别利用图像边缘信息和区域统计特性引导活动轮廓向目标边界靠近^[4–6]。

Chan 和 Vese 提出 C-V 模型, 利用图像全局灰

度信息驱动演化曲线向目标边界运动, 对初始轮廓的鲁棒性较好, 具有一定抗噪性, 但不能分割灰度不均匀图像^[7]; 为解决灰度不均匀图像分割问题, Li 等^[8]借助高斯核函数来拟合图像局部信息, 提出局部二值拟合 (Local Binary Fitting, LBF) 模型, 对灰度不均匀图像的分割取得了突破性成功; He 等^[9]通过“软化”核和局部熵来改进区域可扩展拟合模型, 提高了模型处理强度不均匀性的能力, 增强了模型对初始化和噪声的鲁棒性; Zhang 等^[10]利用极大似然函数和高斯分布特征提出局部统计活动轮廓模型 (Locally Statistical Active Contour Model, LSACM), 提高了对灰度不均匀图像的分割准确度, 降低了模型对初始轮廓的敏感度; 为了充分利用图像全局和

作者简介: 刘颖 (1991–), 女, 学士, 工程师, 主要研究方向: 继电保护; 石凌霄 (1990–), 男, 学士, 工程师, 主要研究方向: 变电站运维。

通讯作者: 李红光 (1977–), 男, 学士, 高级工程师, 主要研究方向: 变电站运维。Email: 81772832@qq.com

收稿日期: 2023–05–18

局部信息,Wang 等^[11]采用图像全局和局部信息互补的方式提出了局部和全局灰度拟合(Local and Global Intensity Fitting, LGIF)模型,不仅增强了模型对灰度不均匀图像的分割能力,而且增强了对初始轮廓鲁棒性。为实现权重自适应,张旭梅等^[12]利用演化曲线内外局部灰度拟合均值占全局均值的比例构建权重函数,实现了自动权衡局部能量项和全局能量项的比重,提高了模型对灰度不均匀图像分割的自适应能力;Ma 等^[13]通过在局部可变区域灰度拟合中引入局部灰度方差和偏离参数,提出自适应局部拟合(Adaptive Local Fitting, ALF)模型;Osher 和 Sethian^[14]提出水平集方法,广泛应用在图像分割领域。随着水平集方法在图像分割领域的广泛应用,产生基于水平集活动轮廓的图像分割模型,可主要分为基于边缘的活动轮廓模型和基于区域的活动轮廓模型两大类^[15-16]。近年来,研究者利用图像的边缘信息和区域信息相结合的思想,提出更多基于水平集方法的图像分割模型,在很大程度上提高图像分割方法的性能^[17-19]。

为解决灰度不均匀图像分割难问题,同时提高分割效率,本文提出一种高斯窗口和权重自适应的快速水平集图像分割模型。对 C-V 和 LBF 模型的拟合项进行改进,分别生成全局能量项和局部能量项;利用演化曲线内外全局灰度拟合均值差和局部区域灰度拟合均值的差构建自适应权控函数,实现自适应调节全局力和局部力大小,保证分割准确度。

1 相关背景

1.1 C-V 模型

C-V 模型是将原始图像 I_0 假定为两个平均灰度相差较大的同质区域(目标和背景),通过一个二值分段函数近似该图像,其水平集形式的能量泛函为

$$E^{CV}(\Phi, c_1, c_2) = \lambda_1 \int_{\Omega} |I_0 - c_1|^2 H_{\varepsilon}(\Phi) dx + \lambda_2 \int_{\Omega} |I_0 - c_2|^2 (1 - H_{\varepsilon}(\Phi)) dx + \mu \int_{\Omega} \delta_{\varepsilon}(\Phi) |\tilde{N}\Phi| dx \quad (1)$$

其中, λ_1, λ_2 和 μ 为正常数,一般取 1; Φ 为水平集函数; c_1 和 c_2 分别为水平集演化过程中演化曲线内部和外部的平均灰度值,最后一项为长度项; $H_{\varepsilon}(x)$ 和 $\delta_{\varepsilon}(x)$ 分别为规范化的 Heaviside 函数和 Dirac 函数,表达式分别为式(2)和式(3):

$$H_{\varepsilon}(x) = \frac{1}{2} \left[\frac{\text{erf}\left(\frac{x}{\varepsilon}\right)}{\text{erf}\left(\frac{1}{\varepsilon}\right)} + 1 \right] + \frac{2}{\pi} \arctan \frac{\text{erf}\left(\frac{x}{\varepsilon}\right)}{\text{erf}\left(\frac{1}{\varepsilon}\right)} \quad (2)$$

$$\delta_{\varepsilon}(x) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + x^2} \quad (3)$$

由变分法和最速下降法,得到该模型的水平集演化的偏微分方程:

$$\frac{\partial \Phi}{\partial t} = \delta_{\varepsilon}(\Phi) (-\lambda_1 (I_0 - c_1)^2 + \lambda_2 (I_0 - c_2)^2) + \mu \delta_{\varepsilon}(\Phi) \text{div} \left(\frac{\tilde{N}\Phi}{|\tilde{N}\Phi|} \right) \quad (4)$$

C-V 模型利用图像全局信息,有一定的抗噪性和鲁棒性,但该模型由于没有涉及图像局部信息,当分割灰度不均图像时,由于全局拟合值误差较大,不能正确分割灰度不均图像。

1.2 LBF 模型

基于区域可变的局部信息拟合的 LBF 模型,由水平集函数表示的局部拟合能量泛函为

$$E^{LBF}(\Phi, f_1(x), f_2(x)) = \sum_{i=1}^2 \lambda_i \int_{\Omega} K_{\sigma}(x - y) |I_0(y) - f_i(x)|^2 M_i(\Phi) dy \quad (5)$$

其中, Ω 为图像区域; Φ 为水平集函数; λ_1 和 λ_2 为正常数; $M_1(\Phi) = H_{\varepsilon}(\Phi)$, $M_2(\Phi) = 1 - H_{\varepsilon}(\Phi)$; $K_{\sigma}(x)$ 为高斯核函数,表达式为

$$K_{\sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{|x|^2}{2\sigma^2}\right\} \quad (6)$$

为避免周期性的重新初始化,增加惩罚项^[14], LBF 模型的能量泛函为

$$E^{LBF} = \int_{\Omega} E^{LBF}(\Phi, f_1(x), f_2(x)) dx + v \int_{\Omega} \delta(\Phi) |H(\Phi)| dx + \frac{1}{2} \mu \frac{\varepsilon}{\varepsilon} N^2 \Phi - \text{div} \left(\frac{\varepsilon \tilde{N}\Phi}{\varepsilon |\tilde{N}\Phi|} \frac{\ddot{\Phi}}{\varepsilon} \right) \quad (7)$$

其中, $f_1(x)$ 和 $f_2(x)$ 为图像在像素点 x 处的局部灰度拟合值。

固定 Φ 不变,极小化能量泛函得 $f_1(x)$ 和 $f_2(x)$:

$$\begin{cases} f_1(x) = \frac{K_{\sigma}(x) \times [H(\Phi)I_0]}{K_{\sigma}(x)H(\Phi)} \\ f_2(x) = \frac{K_{\sigma}(x) \times [(1 - H(\Phi))I_0]}{K_{\sigma}(x) \times [(1 - H(\Phi))]} \end{cases} \quad (8)$$

由变分法和最速下降法,得 LBF 模型的水平集演化偏微分方程:

$$\frac{\partial \Phi}{\partial t} = -\delta(\Phi) (\lambda_1 e_1 - \lambda_2 e_2) + v \delta(\Phi) \text{div} \left(\frac{\varepsilon \tilde{N}\Phi}{\varepsilon |\tilde{N}\Phi|} \frac{\ddot{\Phi}}{\varepsilon} \right) + \mu \frac{\varepsilon}{\varepsilon} N^2 \Phi - \text{div} \left(\frac{\varepsilon \tilde{N}\Phi}{\varepsilon |\tilde{N}\Phi|} \frac{\ddot{\Phi}}{\varepsilon} \right) \quad (9)$$

其中,

$$\begin{aligned} e_1(x) &= \int_{\Omega} K_{\sigma}(x-y) |I_0(y) - f_1(x)|^2 dy \\ e_2(x) &= \int_{\Omega} K_{\sigma}(x-y) |I_0(y) - f_2(x)|^2 dy \end{aligned} \quad (10)$$

LBF模型充分利用了局部图像信息,故能够分割灰度不均匀图像。由于未考虑图像全局信息,故对初始轮廓很敏感,也不具有抗噪性。

2 高斯窗口和权重自适应的快速水平集分割模型

本文模型能量泛函由全局能量项 E_1 、局部能量项 E_2 、长度项 E_3 、惩罚项 E_4 组成,全局能量项和局部能量项之间通过自适应权控函数相连接。

1) 全局能量项 E_1

利用区域梯度信息构造新的边缘指示函数 g_p ,以加快目标和背景轮廓点水平集函数值的改变,提高全局灰度拟合速度,式(11):

$$g_p(I_0(x)) = \begin{cases} 1, & |\tilde{N}I_0(x)| < P \\ \frac{1}{1 + |\tilde{N}I_0(x)| - P}, & |\tilde{N}I_0(x)| \geq P \end{cases} \quad (11)$$

其中, $P = 0.08 \times \max\{|\tilde{N}I_0|\}$, $\tilde{N}I_0$ 为原始图像的梯度。

在 g_p 作用下,演化曲线能够快速扫过图像梯度变化均匀的区域,到目标边缘附近图像梯度较大,此时局部力发挥主导作用。将 g_p 融入到 C-V 模型全局拟合项中生成全局能量项 E_1 :

$$E_1 = \sum_{i=1}^2 \lambda_i \int_{\Omega} g_p |I^* - c_i^*|^2 M_i(\Phi) dx \quad (12)$$

其中, $\lambda_1 = \lambda_2 = 1$ 为权重系数; $M_1(\Phi) = H_{\varepsilon}(\Phi)$, $M_2(\Phi) = 1 - H_{\varepsilon}(\Phi)$; I^* 为原始图像 I_0 经过滤波卷积后的新图像,其作用是消除图像中的椒盐噪声,增强模型的抗噪性,使灰度拟合过程更加稳定; c_1^* 和 c_2^* 分别为优化后的演化曲线内外全局灰度拟合均值,表达式为

$$\begin{aligned} c_1^*(x) &= \frac{\int_{\Omega} I^* H_{\varepsilon}(\Phi) dx}{\int_{\Omega} H_{\varepsilon}(\Phi) dx} \\ c_2^*(x) &= \frac{\int_{\Omega} I^* (1 - H_{\varepsilon}(\Phi)) dx}{\int_{\Omega} (1 - H_{\varepsilon}(\Phi)) dx} \end{aligned} \quad (13)$$

2) 局部能量项 E_2

为了加快局部可变区域灰度拟合速度,防止出现局部极小值,本文采用式(11)中的 $g_p(I_0)$ 构建自

适应高斯窗口尺度 σ_g :

$$\sigma_g = \text{mean}(\alpha g_p(I_0(x)) + 1) \quad (14)$$

其中, α 为修正系数,取值为正常数,当图像较大时, α 取较大值;反之, α 取较小值。

当像素点 x 处于梯度变化比较平稳的区域时, $|\tilde{N}I_0(x)|$ 较小,此时边缘检测函数 $g_a(I_0(x))$ 较大,使得 σ_g 较大,以获取更多的图像信息;当像素点 x 处于梯度变化比较大的区域时, $|\tilde{N}I_0(x)|$ 较大,此时边缘检测函数 $g_p(I_0)$ 较小,使得 σ_g 也较小,以更好地捕获局部细节。由 σ_g 得到自适应高斯核函数 K_{σ_g} 表达式为

$$K_{\sigma_g}(x) = \frac{1}{\sqrt{2\pi}\sigma_g} \exp\left\{-\frac{|x|^2}{2\sigma_g^2}\right\} \quad (15)$$

用 K_{σ_g} 替换式中的高斯核函数 K_{σ} ,得到本文模型的局部能量项 E_2 :

$$E_2 = \sum_{i=1}^2 \lambda_i \iint_{\Omega} K_{\sigma_g}(x-y) |I^*(y) - f_i^*(x)|^2 M_i^*(\Phi) dx dy \quad (16)$$

其中, f_1^* 和 f_2^* 为优化后的演化曲线内外局部灰度拟合值,其表达式为

$$\begin{aligned} f_1^*(x) &= \frac{K_{\sigma_g}(x) \times [H_{\varepsilon}(\Phi) I^*]}{K_{\sigma_g}(x) H_{\varepsilon}(\Phi)} \\ f_2^*(x) &= \frac{K_{\sigma_g}(x) \times [(1 - H_{\varepsilon}(\Phi)) I^*]}{K_{\sigma_g}(x) \times [(1 - H_{\varepsilon}(\Phi))]} \end{aligned} \quad (17)$$

3) 长度项 E_3

在演化过程中,为了保持演化曲线光滑,同时避免在分割结果中产生残余小区域,本文引入长度项 E_3 :

$$E_3 = \int_{\Omega} \delta_{\varepsilon}(\Phi) |\tilde{N}\Phi| dx \quad (18)$$

4) 惩罚项 E_4

为了能够实时修正水平集函数与符号距离函数之间的偏差,避免重新初始化,以保障数值计算的效率和稳定性,加入惩罚项 E_4 :

$$E_4 = \int_{\Omega} \frac{1}{2} (|\tilde{N}\Phi(x)| - 1)^2 dx \quad (19)$$

得所提模型的能量泛函 E , 表达式为

$$E = p(x)E_1 + (1 - p(x))E_2 + vE_3 + \mu E_4 \quad (20)$$

其中, $v > 0$ 为长度项系数,当分割较小的目标对象时取较小值,当分割较大目标时取较大值; $\mu > 0$ 为惩罚项系数; $p(x)$ 为自适应权控函数,函数值范围为 $p(x) \in [0, 1]$ 。

本文自适应权控函数 $p(x)$ 的表达式为

$$p(x) = \frac{1}{|c_1^*(x) - c_2^*(x)|^2 + |f_1^*(x) - f_2^*(x)|^2 + \theta} \quad (21)$$

其中, θ 为一个很小的正数, 为了防止分母为 0, 本文取 $\theta = 1e^{-6}$; c_1^* 和 c_2^* 为优化后的演化曲线内外灰度拟合均值; f_1^* 和 f_2^* 为优化后的演化曲线内外局部邻域内灰度拟合均值, 表达式分别为式 (13) 和式 (17)。

演化曲线逼近目标轮廓的过程中, 演化曲线内外全局灰度均值的差越来越大, 同时演化曲线内外局部可变邻域内灰度均值差也越来越大。因此在演化初期, $p(x) > 1 - p(x) > 0$; 随着演化曲线的逐

渐逼近, $1 - p(x) > p(x) > 0$ 。所以将 $p(x)$ 作为全局能量项系数, $1 - p(x)$ 作为局部能量项系数, 可实现自适应地调节全局力和局部力的比重。

自适应权控函数的控制过程如图 1 所示。当分割图像灰度不均匀图像时, $p(x)$ 的运行机制如下: 在演化初期, 目标边界距离演化曲线较远, $p(x)$ 较大, 全局能量项发挥主导作用, 协同加速引导函数, 使演化曲线快速逼近目标边界; 当演化曲线演化到目标轮廓附近时, 由于演化曲线内外部全局灰度均值差和内外局部邻域灰度均值差都增大, 导致 $p(x)$ 骤降, 使局部能量项作用增强, 保证分割精度。

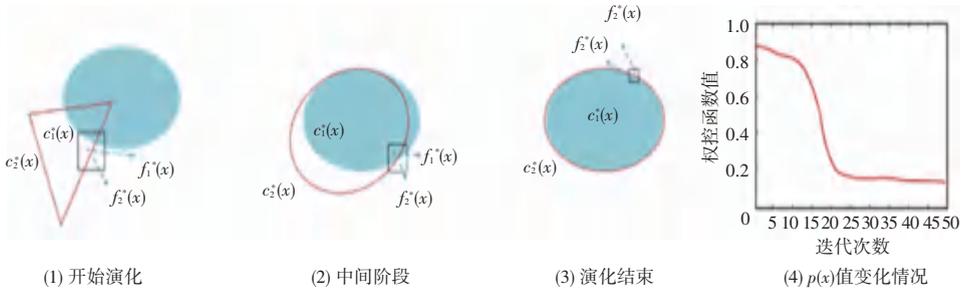


图 1 自适应权控函数的控制过程

Fig. 1 Control process of adaptive power control function

根据变分法和最速下降法, 由式 (20) 得到本文模型的水平集演化方程:

$$\frac{\partial \Phi}{\partial t} = -\delta_\epsilon(\Phi)(pF_1 + (1-p)F_2) + v\delta_\epsilon(\Phi) \operatorname{div} \frac{\tilde{\mathcal{N}}\Phi}{|\tilde{\mathcal{N}}\Phi|} + \mu \frac{\tilde{\mathcal{N}}^2\Phi}{\tilde{\mathcal{N}}\Phi} - \operatorname{div} \frac{\tilde{\mathcal{N}}\Phi}{|\tilde{\mathcal{N}}\Phi|} \quad (22)$$

其中,

$$F_1 = \lambda_1 g_p (I^*(x) - c_1^*(x))^2 - \lambda_2 g_p (I^*(x) - c_2^*(x))^2 \quad (23)$$

$$F_2 = \lambda_1 \int_{\Omega} K_{\sigma_g}(x-y) |I^*(y) - f_1^*(x)|^2 dx - \lambda_2 \int_{\Omega} K_{\sigma_g}(x-y) |I^*(y) - f_2^*(x)|^2 dx \quad (24)$$

3 数值求解

本文采用有限差分法对水平集演化方程求解。将水平集函数 $\Phi(x, y, t)$ 用离散网格的形式表示, 设离散网格的间隔为 h , 时间步长为 Δt , 则 n 时刻的水平集函数在网格点 (i, j) 处可表示为 $\Phi_{i,j}^n(ih, jh, n\Delta t)$, 记为 $\Phi_{i,j}^n$, 则式 (22) 被离散化为式 (25):

$$\frac{\Phi_{i,j}^{n+1} - \Phi_{i,j}^n}{\Delta t} = -\delta_\epsilon^*(\Phi_{i,j}^n)(pF_1(\Phi_{i,j}^n) + (1-p)F_2(\Phi_{i,j}^n)) +$$

$$v\delta_\epsilon^*(\Phi_{i,j}^n) \operatorname{div} \frac{\tilde{\mathcal{N}}\Phi_{i,j}^n}{|\tilde{\mathcal{N}}\Phi_{i,j}^n|} + \mu \frac{\tilde{\mathcal{N}}^2\Phi_{i,j}^n}{\tilde{\mathcal{N}}\Phi_{i,j}^n} - \operatorname{div} \frac{\tilde{\mathcal{N}}\Phi_{i,j}^n}{|\tilde{\mathcal{N}}\Phi_{i,j}^n|} \quad (25)$$

其中, $\operatorname{div}(\frac{\tilde{\mathcal{N}}\Phi_{i,j}^n}{|\tilde{\mathcal{N}}\Phi_{i,j}^n|})$ 为曲率 $k = \operatorname{div}(\frac{\tilde{\mathcal{N}}\Phi}{|\tilde{\mathcal{N}}\Phi|})$ 的离散形式, 采用二阶中心差分可近似为式 (26):

$$k = \operatorname{div} \frac{\tilde{\mathcal{N}}\Phi_{i,j}^n}{|\tilde{\mathcal{N}}\Phi_{i,j}^n|} = \frac{\Phi_{xx}\Phi_y^2 - 2\Phi_{xy}\Phi_x\Phi_y + \Phi_{yy}\Phi_x^2}{(\Phi_x^2 + \Phi_y^2)^{3/2}} \quad (26)$$

其中, Φ_x, Φ_y 为一阶中心差分, $\Phi_{xx}, \Phi_{yy}, \Phi_{xy}$ 为二阶中心差分, 各自表达式如式 (27) 所示:

$$\begin{aligned} \Phi_x &= \frac{1}{2h}(\Phi_{i+1,j} - \Phi_{i-1,j}) \\ \Phi_y &= \frac{1}{2h}(\Phi_{i,j+1} - \Phi_{i,j-1}) \\ \Phi_{xx} &= \frac{1}{h^2}(\Phi_{i+1,j} + \Phi_{i-1,j} - 2\Phi_{i,j}) \\ \Phi_{yy} &= \frac{1}{h^2}(\Phi_{i,j+1} + \Phi_{i,j-1} - 2\Phi_{i,j}) \\ \Phi_{xy} &= \frac{1}{h^2}(\Phi_{i+1,j+1} - \Phi_{i-1,j+1} - \Phi_{i+1,j-1} + \Phi_{i-1,j-1}) \end{aligned} \quad (27)$$

将演化过程中相邻两次零水平集轮廓的面积差作为本文模型迭代停止条件:

$$|S_{\text{area}}(\Phi_{i,j}^{n+1}) - S_{\text{area}}(\Phi_{i,j}^n)| < \xi \quad (28)$$

其中, $S_{\text{area}}(\Phi_{i,j}^{n+k})$ 为第 k 次迭代后的零水平集轮廓面积, $\xi = 0.001$ 为预设阈值。当满足条件时则停止迭代, 否则进行演化。

本文模型核心算法流程:

(1) 读入图像 I_0 , 并初始化水平集函数 $\Phi^0(x) = \Phi(x, 0)$ 为二值函数;

(2) 根据式 (13) 和式 (17) 分别计算 $c_1^*(\Phi_{i,j}^n)$ 、 $c_2^*(\Phi_{i,j}^n)$ 和 $f_1^*(\Phi_{i,j}^n)$ 、 $f_2^*(\Phi_{i,j}^n)$;

(3) 根据式 (14) 和 (21) 计算出每个像素点对应的自适应高斯窗口尺度 σ_g 和权控函数 $p(x)$ 值;

(4) 根据式 (25) 对水平集函数进行迭代更新得到 $\Phi_{i,j}^{n+k}$;

(5) 判断式 (28) 是否成立: 若成立, 则停止迭代; 否则, 继续迭代直到满足条件或者达到最大迭代次数;

(6) 输出最终分割结果 $\Phi(x) = \Phi^{n+k}(x)$ 。

4 实验与结果分析

本文针对灰度不均图像和噪声图像进行分割实验, 分别采用 LBF 模型、C-V 模型、LGIF 模型和本文模型进行对比, 以验证本文模型的分割性能。实验中, 保持相同的编译环境, 和相同的硬件配置, 并根据实际情况设置修正系数 α 值, 在无说明时, 本文模型其余参数设定为: $\Delta t = 0.1$, $\lambda_1 = \lambda_2 = 1$, $\varepsilon = 1$, $v = 0.001 \times 255^2$, $\mu = 1$, 其他 3 种模型参数分别设置为默认值。

4.1 灰度不均匀图像的分割

针对灰度不均的原始图像, 依次取 $\alpha = 3$ 、 $\alpha = 5$ 、 $\alpha = 6$ 、 $\alpha = 10$ 、 $\alpha = 15$ 、 $\alpha = 16$ 修正系数, 分别采用 4 种模型进行了 6 组灰度不均匀图像分割实验, 结果如图 2 所示。其中, LBF 模型对初始轮廓敏感, 个别分割结果并不理想; C-V 模型没有考虑图像局部信息, 不能实现正确分割; LGIF 模型融合了局部和全局信息, 均分割正确; 本文模型均能分割出正确的结果, 且效果最佳。

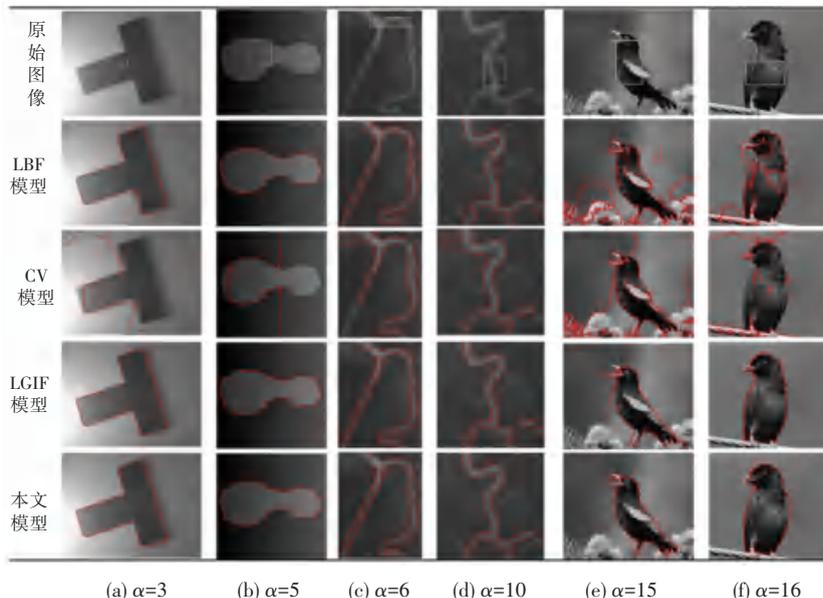


图 2 4 种模型对灰度不均匀图像的分割结果

Fig. 2 Segmentation results of four models for gray level inhomogeneous images

在 4 种模型迭代计算过程中, 其迭代步数和 CPU 计算时间见表 1, 当 4 种模型均分割正确时, 本文模型

的分割时间和迭代次数远小于其他模型, 本文模型对灰度不均匀图像的分割具有一定优势。

表 1 4 种模型所用迭代次数和 CPU 时间

Table 1 Number of iterations and CPU time used for the four models

模型	$\alpha = 3$	$\alpha = 5$	$\alpha = 6$	$\alpha = 10$	$\alpha = 15$	$\alpha = 16$
LBF 模型	400 (11.962 s)	300 (8.968 s)	300 (10.921 s)	250 (9.630 s)	350 (12.968 s)	350 (10.968 s)
C-V 模型	500 (9.363 s)	500 (11.795 s)	500 (11.962 s)	500 (10.695 s)	500 (10.609 s)	500 (11.795 s)
LGIF 模型	250 (9.281 s)	200 (6.187 s)	150 (5.343 s)	250 (9.453 s)	220 (10.609 s)	220 (11.187 s)
本文模型	15 (0.516 s)	16 (0.609 s)	26 (1.282 s)	24 (1.375 s)	20 (2.609 s)	20 (2.209 s)

4.2 噪声图像的分割

针对不同情况下的噪声图像,依次取方差为:0、0.05、0.10、0.15 的高斯噪声以及密度为 0.1 的椒盐噪声,采用 4 种模型进行 5 组噪声图像分割对比实验,分割结果如图 3 所示。当方差为 0,即不含高斯噪声时,4 种方法均分割出正确的结果;随着方差增

加,即高斯噪声增强,LBF 模型首先分割失败,而 C-V模型和 LGIF 模型能抵抗低强度的高斯噪声,但不能分割含有较高强度高斯噪声或椒盐噪声的图像;本文模型在一定强度高斯噪声和椒盐噪声的情况下仍能分割出正确结果,具有较好的抗噪性能。

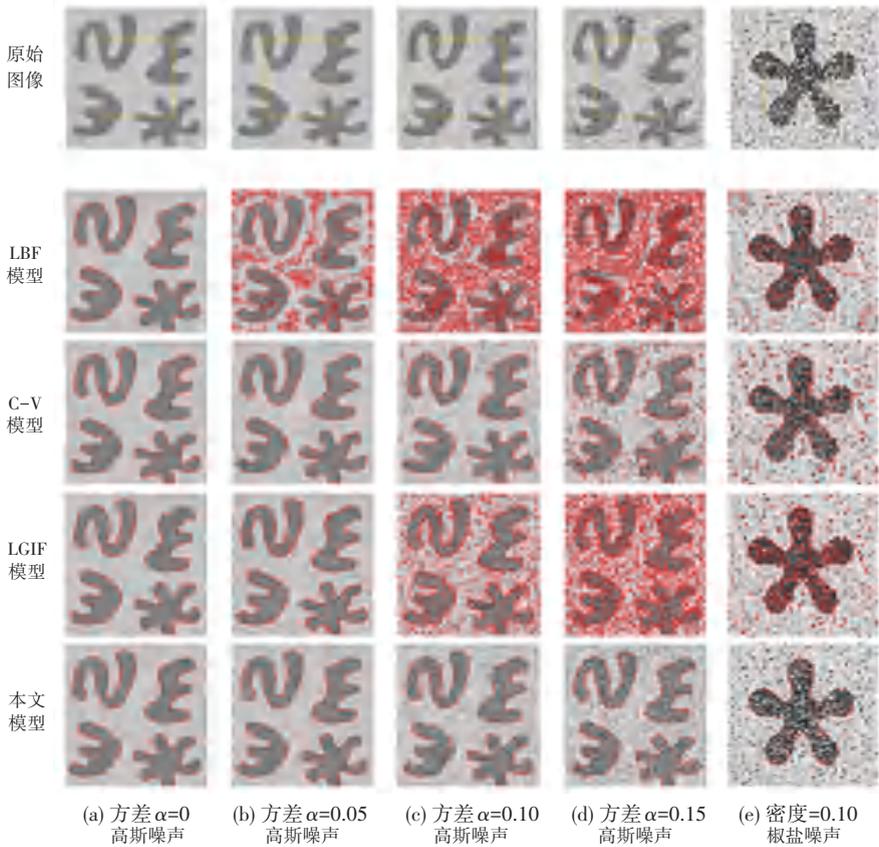


图3 4种模型对噪声图像的分割结果

Fig. 3 Segmentation results of four model for noisy images

4.3 分割效率和精度评估

为了评估本文模型的分割效果,以迭代次数和CPU处理时间作为分割效率的衡量指标,以相似性系数(DSC)和错误分割率(RSE)作为分割精度量化指标, DSC 值越接近1,且 RSE 越接近0时分割精度越高,计算如式(29)和式(30)。

$$DSC = \frac{2\text{Num}_{\text{Area}}(S_1 \cap S_2)}{\text{Num}_{\text{Area}}(S_1) + \text{Num}_{\text{Area}}(S_2)} \quad (29)$$

$$RSE = \frac{\text{Num}_{\text{Area}}(S_1/S_2) + \text{Num}_{\text{Area}}(S_2/S_1)}{\text{Num}_{\text{Area}}(\Omega)} \quad (30)$$

其中, $\text{Num}_{\text{Area}}(\cdot)$ 为闭合区域中的像素点个数; S_1 为标签的目标区域; S_2 为算法分割出的目标区域。

分别以含有边界截断多目标、双目标、深度凹陷

目标以及孔洞目标的图像作为待分割图像,进行LBF模型、C-V模型、LGIF模型和本文模型的图像分割对比实验,相关参数设置为 $\alpha = 18, \varepsilon = 5, v = 0.003 \times 255^2$; $\alpha = 20, \varepsilon = 3, v = 0.001 \times 255^2$; $\alpha = 20, \varepsilon = 5, v = 0.001 \times 255^2$; $\alpha = 20, \varepsilon = 4, v = 0.001 \times 255^2$,结果如图4所示。在4种情况下本文模型均能分割出正确结果且效果最佳。

迭代求解过程中的量化结果,见表2。本文模型的 DSC 均较高,最高可达 0.975 7,相比于对应的其他 3 种模型,本文分割精度提高约 30%。此外,当分割精度相差不大时,本文模型的迭代次数和 CPU 时间相较于其他 3 种模型大大减少,故本文模型在分割精度和分割效率方面有着较大的优势。

表2 4种模型分割效果的量化结果

Table 2 Quantitative results of the segmentation effects of the four models

参数设定	方法	迭代次数/次	CPU 时间/s	DSC	RSE
$\alpha = 18, \varepsilon = 5, \nu = 0.003 \times 255^2$	LBF 模型	300	21.051	0.726 2	0.156 3
	C-V 模型	100	6.521	0.706 8	0.115 3
	LGIF 模型	130	15.022	0.761 1	0.011 9
	本文模型	8	2.692	0.975 7	0.002 2
$\alpha = 20, \varepsilon = 3, \nu = 0.001 \times 255^2$	LBF 模型	240	9.671	0.942 2	0.005 1
	C-V 模型	30	3.121	0.942 6	0.004 6
	LGIF 模型	60	4.968	0.948 1	0.003 9
	本文模型	5	0.719	0.950 1	0.003 2
$\alpha = 20, \varepsilon = 5, \nu = 0.001 \times 255^2$	LBF 模型	350	11.163	0.922 6	0.022 1
	C-V 模型	170	10.361	0.921 2	0.022 0
	LGIF 模型	100	5.218	0.930 3	0.010 8
	本文模型	10	2.314	0.941 3	0.008 9
$\alpha = 20, \varepsilon = 4, \nu = 0.001 \times 255^2$	LBF 模型	320	11.365	0.865 4	0.088 9
	C-V 模型	100	5.042	0.938 1	0.020 2
	LGIF 模型	130	10.053	0.948 1	0.030 6
	本文模型	8	1.937	0.960 7	0.010 6

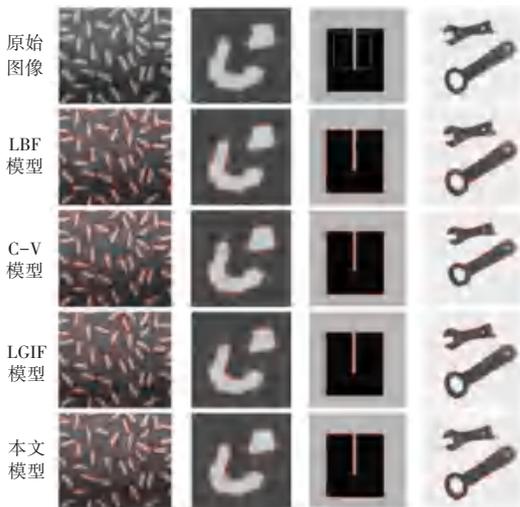


图4 4种模型对不同类型图像的分割结果

Fig. 4 Segmentation results of the four models for different types of images

5 结束语

本文提出一种高斯窗口和权重自适应的快速水平集图像分割模型,解决了灰度不均匀图像和噪声图像的分割难问题。首先,在全局能量项中融入新边缘停止函数,加快全局拟合速度,将自适应高斯核函数引入局部能量项中,使模型能自适应调节局部灰度拟合邻域范围;其次,利用演化曲线内外全局灰

度拟合均值差和局部区域灰度拟合均值差构造自适应权控函数,自适应地调节模型全局力和局部力的大小,保证分割精度。实验结果表明,本文模型能很好地分割灰度不均匀图像和噪声图像,新边缘指示函数和自适应高斯窗口尺度函数的引入,提高了模型的分割效率。

参考文献

- [1] WANG Z, MA B, ZHU Y. Review of level set in image segmentation [J]. Archives of Computational Methods in Engineering, 2021, 28(4): 2429-2446.
- [2] 刘金彦,何传江,吴永飞. 噪声鲁棒的水平集演化模型[J]. 计算机应用与软件, 2016, 33(4): 173-176.
- [3] 秦宇幸,羿旭明. 结合显著性和边缘信息的水平集图像分割方法[J]. 图学学报, 2021, 42(5): 738-743.
- [4] 齐国红,张晴晴,张云龙,等. 考虑梯度边缘信息的玉米叶片病斑图像分割[J]. 计算机仿真, 2020, 37(12): 396-399.
- [5] BIRANE A, HAMAMI L. A fast level set image segmentation driven by a new region descriptor [J]. IET Image Processing, 2021, 15(3): 615-623.
- [6] 鲁圆圆,强静仁,汪朝. 基于区域信息主动轮廓模型的图像分割[J]. 计算机工程与应用, 2018, 54(10): 208-212.
- [7] CHAN T F, VESE L A. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [8] LI C, KAO C Y, GORE J C, et al. Implicit active contours driven by local binary fitting energy [C]//Proceedings of 2007 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2007: 1-7.
- [9] HE C, WANG Y, CHEN Q. Active contours driven by weighted

- region-scalable fitting energy based on local entropy [J]. *Signal Processing*, 2012, 92(2): 587-600.
- [10] ZHANG K, ZHANG L, LAM K, et al. A level set approach to image segmentation with intensity inhomogeneity [J]. *IEEE Transactions on Cybernetics*, 2016, 46(2): 546-557.
- [11] WANG L, LI C, SUN Q, et al. Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation [J]. *Computerized Medical Imaging and Graphics*, 2009, 33(7): 520-531.
- [12] 张旭梅, 范虹, 乔柱. 融合全局和局部信息的水平集乳腺 MR 图像分割[J]. *计算机应用研究*, 2015, 32(1): 307-311.
- [13] MA D, LIAO Q, CHEN Z, et al. Adaptive local-fitting-based active contour model for medical image segmentation [J]. *Signal Processing: Image Communication*, 2019, 76: 201-213.
- [14] SETHIAN J A. Numerical algorithms for propagating interfaces; Hamilton-Jacobi equations and conservation laws [J]. *Journal of Differential Geometry*, 1990, 31(1): 131-161.
- [15] 张桂梅, 周飞飞, 储珺. 一种改进的变分水平集的图像分割算法 [J]. *图学学报*, 2015, 36(5): 740-746.
- [16] GE P, CHEN Y, WANG G, et al. An active contour model driven by adaptive local pre-fitting energy function based on Jeffreys divergence for image segmentation [J]. *Expert Systems with Applications*, 2022, 210: 118493.
- [17] LIU C, LIU W, XING W. An improved edge-based level set method combining local regional fitting information for noisy image segmentation [J]. *Signal Processing*, 2017, 130: 12-21.
- [18] SHI N, PAN J. An improved active contours model for image segmentation by level set method [J]. *Optik*, 2016, 127(3): 1037-1042.
- [19] LIU C, LIU W, XING W. An improved edge-based level set method combining local regional fitting information for noisy image segmentation [J]. *Signal Processing*, 2017, 130: 12-21.