

文章编号 1004-924X(2026)18-2891-16

基于全局高斯分布和统计范数度量的图像分割

刘相国^{1,2}, 刘国军^{1*}, 马月梅¹, 宋新年¹, 李更生³

(1. 宁夏大学 数学统计学院, 宁夏 银川 750021;

2. 巢湖学院 数学与大数据学院, 安徽 合肥 238000;

3. 陇南师范学院 人工智能学院, 甘肃 陇南 742500)

摘要:针对传统水平集分割算法对初始轮廓敏感以及噪声鲁棒性较差的问题,提出了一种基于全局高斯分布和统计范数度量的分割模型,该模型融合了图像的边缘信息和全局区域信息,实现了对目标边界的提取,提高了初始轮廓和噪声的鲁棒性。首先,采用全局信息融合的策略,设计了一个全新的全局能量项作为数据项。同时,利用全局能量项和正则化项将初始轮廓驱动到目标边界,达到对目标区域的精确分割。其次,定义了一个用水平集函数拟合能量的全局高斯分布,并将全局均值和方差作为变量。最后,在迭代过程中,通过交错的水平集演化和全局强度均值和方差的估计来实现能量最小化。在合成图像、真实图像及自然图像上的实验结果表明,所提模型对高斯噪声、斑点噪声及椒盐噪声均展现出良好的分割效果。此外,在分割精度与算法运行时间等方面,该模型均优于其他经典的主动轮廓模型。本文模型提升了高噪声图像的分割准确性,较好地实现了目标边界的提取,在分割精度与计算效率方面均展现出优越性能。

关键词:图像分割;活动轮廓;统计范数;水平集;高斯分布

中图分类号: TN911.73 **文献标识码:** A

doi:10.37188/OPE.20263418.2891 **CSTR:**32169.14.OPE.20263418.2891

Image segmentation based on global Gaussian distribution and statistical paradigm measures

LIU Xiangguo^{1,2}, LIU Guojun^{1*}, MA Yuemei¹, SONG Xinnian¹, LI Gengsheng³

(1. School of Mathematics and Statistics, Ningxia University, Yinchuan 750021, China;

2. School of Mathematics and Big Data, Chaohu University, Hefei 238000, China. ;

3. School of Artificial Intelligence, Longnan Normal College, Longnan 742500, China)

* Corresponding author, E-mail: liugj@nux.edu.cn

Abstract: To address the sensitivity to initial contours and poor noise robustness in traditional level set segmentation algorithms, this paper proposed a segmentation model based on global Gaussian distribution and statistical norm metric. By fusing edge information with global region information, the model achieved accurate target boundary extraction and enhanced robustness against initial contour placement and noise interference. First, a novel global energy term was designed as the data term using a global information fusion strategy. This term, combined with a regularization term, drove the initial contour toward target

收稿日期: 2026-04-01; **修订日期:** 2026-06-08.

基金项目: 国家自然科学基金项目(No. 62061040); 宁夏自然科学基金项目(No. 2026AAC030099); 安徽省高校自然科学研究重点项目(No. 2024AH051338); 甘肃省高校教师创新基金项目(No. 2025B-456)

boundaries for precise region segmentation. Second, a global Gaussian distribution was defined to fit the energy using the level set function, with global mean and variance treated as variables. Finally, energy minimization was achieved through alternating level set evolution and estimation of global intensity mean and variance during iterations. Experiments on synthetic, real, and natural images demonstrate that the proposed model exhibits excellent segmentation performance for Gaussian noise, speckle noise, and salt-and-pepper noise. Furthermore, the model outperforms other classical active contour models in terms of segmentation accuracy and computational efficiency. The proposed model improves segmentation accuracy for high-noise images, achieves effective target boundary extraction, and demonstrates superior performance in both segmentation precision and computational efficiency.

Key words: image segmentation; active contours; statistical norm; level set; Gaussian distribution

1 引 言

图像分割是图像处理中最复杂和最重要的数学问题之一,在医学图像分析、车辆流量检测、智能交通等领域都有广泛的应用。已经建立的分割方法包括基于学习的方法(机器和深度学习)^[1-4]和主动轮廓法(Active Contour Method, ACM)^[5-8]。基于学习的方法依赖大量数据,在小样本下精度不足;而ACM作为变分数学模型,不依赖数据量,通过最小化能量泛函驱动水平集演化曲线,在目标边界处停止,是实现分割的有效方法。而ACM模型主要分为两类:基于边缘的模型^[6]和基于区域的模型^[7-8]。

基于边缘的模型依赖局部梯度驱动轮廓演化,在清晰边界上效果显著,但对噪声和弱边界敏感,且初始位置影响较大。基于区域的模型则利用全局或局部区域属性引导分割,对噪声和弱边缘更具鲁棒性。基于区域的模型可以分为两类:全局区域模型和局部区域模型。其中,全局区域模型旨在分割所有目标边界,而局部区域模型则依据特定几何约束仅提取感兴趣目标。

为解决灰度图像分割的强度不均匀性问题,局部区域信息被引入活动轮廓模型,例如,局部图像拟合(local Image Fitting, LIF)方法^[9]和局部强度聚类(Local Intensity Clustering, LIC)方法^[10]。基于LIC, Zhang等^[11]提出了局部统计活动轮廓模型(Local Statistic Active Contour Model, LSACM)。此外, Weng等^[12]提出了一种基于强度非均匀性的图像分割加性偏差校正(Additive Bias Correction, ABC)模型;文献[13]提出

了非均匀图像的(Local Gaussian Distribution Fitting, LGDF)模型;文献[14]通过自适应拟合与正则化能量驱动轮廓演化,提出了一种自适应局部拟合(Adaptive Local Fitting, ALF)模型。局部区域模型虽能利用局部统计特征改善非均匀图像分割,但缺乏全局信息,导致对初始轮廓敏感且易受噪声干扰。

基于主动轮廓法的全局区域图像分割模型依赖全局信息引导轮廓演化,近二十年来,统计方法在该领域的应用日益广泛^[15],例如高斯分布^[16]、伽马分布^[17]、瑞利分布^[18]及Fisher-Tippett分布^[19]等全局区域图像分割模型。最经典的全局区域模型是Chan-Vese(C-V)模型^[20],其假设前景与背景灰度均匀,因此不适用于非均匀图像。为处理该问题,后续研究提出了多种改进策略, Niaz等^[21]结合局部与全局区域能量拟合统计信息,建立混合活动轮廓模型; Wang等^[22]通过构建全局和局部高斯拟合能量的线性组合,进一步降低了对初始轮廓选择的依赖; Yang等^[23]提出了基于最大覆盖的全局分割方法,利用贝叶斯决策评估全局相似性,以克服过度分割问题。

李等^[24]提出了一种融合局部信息的统计范数分割方法,通过将灰度不均匀性建模为独立分量以提取纹理结构信息,在复杂背景中表现良好。但该方法缺乏全局特征引导,对初始轮廓敏感且抗噪性不足。因此,针对局部区域模型在图像分割过程中对初始轮廓位置的选取和噪声敏感的问题,本文提出了一种基于全局高斯分布和统计范数(Global Gaussian distribu-

tions and Statistical Paradigms, GGDSP) 度量的分割模型。

2 相关工作

在基于区域的活动轮廓模型中,通常使用局部或全局区域信息来定义模型的能量泛函。在本节中,为引入所提出的模型,先简要回顾经典的自适应局部拟合(Adaptive Local Fitting, ALF)模型^[14]以及局部和全局高斯分布(Local and Global Gaussian Distributions, LGGD)模型^[22]。

2.1 ALF 模型

ALF 模型设计了基于局部强度方差的自适应拟合项,优化了最小化过程,但所提出方法的分割效率低,有待改进,该模型的能量泛函如下:

$$E^{\text{ALF}} = \int \sum_{i=1}^N (\kappa_i \int \omega^x(x-y) M_i(\phi(y)) \times \\ |I(y) - \mu_i(x) - \lambda(x) \tilde{\sigma}(y)|^2 dy) dy + \\ \beta \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx + \nu \int \delta(\phi(x)) |\nabla \phi(x)| dx,$$

其中: κ_i, β, ν 是常量, ∇ 是梯度算子, x, y 是 I 中的像素位置, $\mu_i(x)$ 可视为 o_x 中的平均强度值, $\tilde{\sigma}(y)$ 描述 y 处的灰度值与平均强度值 $\mu_i(x)$ 的偏差程

度。 $\lambda(x)$ 是调整与 $\mu_i(x)$ 的偏差的乘数。 $M_i(\phi(y))$ 是满足以下条件的隶属函数:

$$M_i(\phi(y)) = \begin{cases} 1, & y \in \Omega_i \\ 0, & \text{else} \end{cases}.$$

通过变分法可求得梯度下降流方程是:

$$\tilde{\sigma}(x) = I(x) - \text{mean}(I_{o_x}), \quad (1)$$

其中, $\text{mean}(I_{o_x})$ 表示区域 O_x 内像素的强度平均值。

$$\frac{\partial \phi}{\partial t} = - \sum_{i=1}^N \frac{\partial M_i(\phi)}{\partial \phi} e_i + \beta \text{div} \left(\nabla \phi - \frac{\nabla \phi}{|\nabla \phi|} \right) + \\ \nu \delta(\phi) \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right).$$

2.2 LGGD 模型

利用图像的全局和局部信息建模,文献[22]提出一种具有局部和全局高斯分布(Local and Global Gaussian Distributions, LGGD)拟合能量的活动轮廓模型,但所提出的模型计算量大,且对某些图像的自适应权值效果不佳。LGGD 模型的能量泛函如下:

$$E_{\epsilon}^{\text{LG}}(\phi) = \mu R_p(\phi) + E_{\epsilon}(\phi),$$

其中: $R_p(\phi)$ 是惩罚项, $E_{\epsilon}(\phi, u_1(x), u_2(x), \sigma_1^2(x), \sigma_2^2(x), u_3, u_4, \sigma_3^2, \sigma_4^2)$ 为数据拟合项, μ 是大于 0 的参数。

$$E_{\epsilon}(\phi, u_1(x), u_2(x), \sigma_1^2(x), \sigma_2^2(x), u_3, u_4, \sigma_3^2, \sigma_4^2) = \\ \int |\nabla H(\phi(x))| dx + (1 - \theta) \iint K_{\sigma}(x-y) H(\phi(x)) \times \\ (\log \sqrt{2\pi} + \log \sigma_1(x) + \frac{(I(y) - u_1(x))^2}{2\sigma_1^2(x)}) dy dx + \\ \iint K_{\sigma}(x-y) (1 - H(\phi(x))) \times (\log \sqrt{2\pi} + \log \sigma_2(x) + \frac{(I(y) - u_2(x))^2}{2\sigma_2^2(x)}) dy dx + \\ \theta \int \left(\log \sqrt{2\pi} + \log \sigma_3 + \frac{(I(x) - u_3)^2}{2\sigma_3^2} \right) H(\phi(x)) dx + \\ \int \left(\log \sqrt{2\pi} + \log \sigma_4 + \frac{(I(x) - u_4)^2}{2\sigma_4^2} \right) (1 - H(\phi(x))) dx.$$

在 LGGD 模型的能量泛函中,通过变分法可求得梯度下降流方程是:

$$\frac{\partial \phi}{\partial t} = \mu \text{div}(d_p(|\nabla \phi|) \nabla \phi) + \nu \delta_{\epsilon}(\phi) \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \\ \delta_{\epsilon}(\phi) [(1 - \theta)(e_1 - e_2) + \theta(e_3 + e_4)].$$

3 提出的模型

在基于区域的模型中,本文引入了统计方法。为了简单起见,假设 $I: x \in \Omega \rightarrow R$ 是给定的图像,其中 x 是表示图像域 Ω 中的像素向量。类似于文献^[25-26],假设每个点的强度是一个随机

变量,并且它在每个局部区域中的像素强度是独立且同分布的。一般而言,基于概率密度函数最大化似然估计或最大化后验概率的问题等同于于最小化具有如下负对数形式的能量泛函^[14]:

$$E(I(x), C) = - \int_{\Omega_1} \log p(I(x); \Omega_1) dx - \int_{\Omega_2} \log p(I(x); \Omega_2) dx.$$

其中, Ω_1 和 Ω_2 分别表示轮廓 C 的内部区域和外部区域。

3.1 建立能量泛函

ALF 模型和 LGGD 模型各有优缺点,因为前者主要基于局部区域信息,而对后者来说,局部和全局区域信息是关键。从统计学的角度来看,在所提出的模型中,拟合能量分别由具有不

$$E(\phi, \mu_1(x), \mu_2(x), \lambda(x), \sigma_1^2(x), \sigma_2^2(x)) = \lambda_1 \int (\log \sqrt{2\pi} + \log \sigma_1(x) + \frac{(I(x) - \mu_1(x) - \lambda(x)\tilde{\sigma}(x))^2}{2\sigma_1^2(x)}) H(\phi(x)) dx + \lambda_2 \int (\log \sqrt{2\pi} + \log \sigma_2(x) + \frac{(I(x) - \mu_2(x) - \lambda(x)\tilde{\sigma}(x))^2}{2\sigma_2^2(x)}) (1 - H(\phi(x))) dx. \quad (4)$$

3.2 参数求解

首先初始化水平集函数 ϕ :

$$\phi^0 = \begin{cases} -2, & x \in \Omega_0 - \partial\Omega_0 \\ 0, & x \in \partial\Omega_0 \\ 2, & x \in \Omega - \Omega_0 \end{cases}, \quad (5)$$

其中: Ω_0 是图像域 Ω 的子区域, $\partial\Omega_0$ 表示 Ω_0 的边界。表 1 是 GGDSP 模型的伪代码。

在 (4) 中 $\mu_i(x)$, $\lambda(x)$, $\sigma_i^2(x)$, $\lambda(x)$ 是未知变量,对 (4) 求偏导数。解得:

$$\mu_1(x) = \frac{\int (I(x) - \lambda(x)\tilde{\sigma}(x)) H(\phi(x)) dx}{\int H(\phi(x)) dx}. \quad (6)$$

同理,可解得其他变量为:

$$\mu_2(x) = \frac{\int (I(x) - \lambda(x)\tilde{\sigma}(x)) (1 - H(\phi(x))) dx}{\int (1 - H(\phi(x))) dx}, \quad (7)$$

$$\sigma_1^2(x) = \frac{\int (I(x) - \mu_1(x) - \lambda(x)\tilde{\sigma}(x))^2 H(\phi(x)) dx}{\int H(\phi(x)) dx}, \quad (8)$$

同均值和方差的全局高斯分布来描述。首先,定义了如下能量泛函:

$$E(c, \mu_1(x), \mu_2(x), \lambda(x), \sigma_1^2(x), \sigma_2^2(x)) = - \int_{\Omega_1} \log p_{1,x}(I(x), \mu_1(x), \sigma_1^2(x), \lambda(x)) dx - \int_{\Omega_2} \log p_{2,x}(I(x), \mu_2(x), \sigma_2^2(x), \lambda(x)) dx, \quad (2)$$

其中: $\Omega_1 = in(C)$, $\Omega_2 = out(C)$ 。

$$p_{i,x}(I(x), \mu_i(x), \sigma_i^2(x)) = \frac{1}{\sqrt{2\pi} \sigma_i(x)} \exp\left(-\frac{|I(x) - \mu_i(x) - \lambda(x)\tilde{\sigma}(x)|^2}{2\sigma_i^2(x)}\right). \quad (3)$$

定义为高斯分布的全局区域强度的概率密度函数,其中, $i = 1, 2$, 对应于轮廓 C 的内部和外部区域。由公式 (2) 和 (3) 得:

$$\sigma_2^2(x) = \frac{\int (I(x) - \mu_2(x) - \lambda(x)\tilde{\sigma}(x))^2 (1 - H(\phi(x))) dx}{\int (1 - H(\phi(x))) dx}, \quad (9)$$

$$\lambda(x) = \frac{N_1 + N_2}{D_1 + D_2}, \quad (10)$$

其中:

$$N_1 = \frac{1}{\sigma_1^2(x)} \int (I(x) - \mu_1(x)) \tilde{\sigma}(x) H(\phi(x)) dx,$$

$$N_2 = \frac{1}{\sigma_2^2(x)} \int (I(x) - \mu_2(x)) \tilde{\sigma}(x) (1 - H(\phi(x))) dx,$$

$$D_1 = \frac{1}{\sigma_1^2(x)} \int \tilde{\sigma}^2(x) H(\phi(x)) dx,$$

$$D_2 = \frac{1}{\sigma_2^2(x)} \int \tilde{\sigma}^2(x) (1 - H(\phi(x))) dx.$$

3.3 能量泛函正则项

为了准确地计算水平集函数及其演化,需要通过惩罚水平集函数与符号距离函数^[27]的偏差来使水平集函数正则化。符号距离函数可以用以下能量泛函来表示:

$$p(\phi(x)) = \int_{\Omega} \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx.$$

于是,GGDSP 模型的能量泛函梯度下降流为:

$$\frac{\partial \phi}{\partial t} = -\delta(\phi(x))(\lambda_1 e_1 - \lambda_2 e_2) + \left(\nabla^2 \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right), \quad (11)$$

其中:

$$e_j = \log \sigma_j(x) + \frac{(I(x) - \mu_j(x) - \lambda(x)\tilde{\sigma}(x))^2}{2\sigma_j^2(x)},$$

这里 $j=1, 2$ 。

表 1 基于全局高斯分布和统计范数度量的算法

Tab. 1 Algorithms based on global Gaussian distribution and statistical norm metrics

算法:GGDSP算法

输入:原始图像 I ;

输出:分割结果 ϕ^n ;

第一步:设置参数: $\Delta t, \sigma, \epsilon, N$, 根据式(5)初始化水平集函数;

第二步:根据式(1),计算 $\tilde{\sigma}$;

第三步:根据式(6),计算 μ_1 ;

第四步:根据式(7),计算 μ_2 ;

第五步:根据式(8),计算 σ_1^2 ;

第六步:根据式(9),计算 σ_2^2 ;

第七步:根据式(10),计算 λ ;

第八步:通过式(11),更新水平集函数 ϕ 。

4 数值实验

为了验证 GGDSP 模型的有效性,实验分为两部分:第一部分为模型验证实验,通过设置不同大小和形状的初始轮廓,分别对灰度图像、自然图像以及含噪图像进行了分割测试;第二部分为对比实验,将本方法与其他主流方法在灰度图像和彩色图像的分割效果上进行了比较分析。实验平台为: Intel(R) Core(TM), i7-11800H, 2.30 GHz, 16 GB RAM, Matlab R2018b, Windows10。

4.1 GGDSP 模型的验证实验

为了验证模型的有效性,对灰度图像、自然图像以及噪声图像进行了实验。


4.1.1 GGDSP 模型对初始轮廓的鲁棒性

对初始轮廓的鲁棒性进行初步验证,通过设置不同大小和形状的初始轮廓,进行实验,分割结果如图 1 所示(绿色表示初始轮廓,红色表示分割结果,彩图见期刊电子版)。

整个分割结果显示,无论初始轮廓的形状是矩形、圆、三角形还是梯形,还是初始轮廓包含一个目标区域、两个目标区域、三个目标区域,甚至不包含目标区域,GGDSP 模型都可以对图像进行准确分割。

4.1.2 GGDSP 模型对于噪声的鲁棒性

为了验证 GGDSP 模型对于噪声的鲁棒性,






图 1 不同初始轮廓的分割结果

Fig. 1 Segmentation results with different initial contours

从主观评价和客观评价两个方面进行验证。

4.1.2.1 主观评价

将初始轮廓设置为圆,选取真实的图像并在图像中依次加入均值为 0,方差为 0.015,0.02,0.025 和 0.03 的高斯噪声以及 0.01,0.012,0.014 和 0.016 的椒盐噪声,分割结果如图 2 所示。

由图 2 的分割结果可知,GGDSP 模型可以实现对不同等级的高斯噪声以及不同等级的椒盐噪声的图像分割,对高斯噪声和椒盐噪声具有很好的鲁棒性。

为了验证 GGDSP 模型对自然图像的有效性,在 Berkely Segmentation Dataset BSDS500^[28]




图 2 不同噪声不同等级的分割结果

Fig. 2 Segmentation results under different types and levels of noise

和 ECSSD^[29]数据集上选取了 7 张自然图像进行实验,其实验结果如图 3 所示。





图 3 自然图像的分割结果

Fig. 3 Segmentation results on natural images

由图 3 可以发现,GGDSP 模型可以实现对不同场景下的自然图像的分割,也可以实现噪声的自然图像在不同场景下的分割。从而验证了 GGDSP 模型对自然图像分割的可行性和有效性。

为系统评估 GGDSP 模型在噪声干扰下的分割鲁棒性,分别以灰度图像、合成图像及自然图像为测试对象,叠加由两类不同噪声构成的混合噪声,并通过调整各噪声分量的参数取值,以模拟不同信噪比条件下的退化场景。实验共设置

四组混合噪声配置(图 4):(a)斑点噪声与散粒噪声复合,参数分别设为 0.06,0.08,0.10 及 0.12;(b)零均值高斯噪声(方差依次为 0.010,0.015,0.020 及 0.025)与散粒噪声复合;(c)零均值高斯噪声(方差依次为 0.005,0.007,0.009 及 0.011)与参数设置为 0.05 的斑点噪声复合;(d)斑点噪声(参数依次为 0.07,0.09,0.11 及 0.13)与参数设置为 0.01 的椒盐噪声复合。在上述参数配置下的分割结果如图 4 所示。






图 4 不同混合噪声的分割结果

Fig. 4 Segmentation results for different mixed noises

图 4 结果表明,GGDSP 模型在灰度图像、合成图像及自然图像上均能有效完成混合噪声条件下的分割任务,充分验证了该模型对混合噪声干扰具有较强鲁棒性。

4.1.2.2 客观评价

为了更好地对实验结果进行分析,对于上述图 3 进行以下客观评价,使用的四个指数如下:

Jaccard 指数(JSC)^[30]:

$$JSC = \frac{|G_S \cap G_{GT}|}{|G_S \cup G_{GT}|}.$$

骰子相似系数(DSC)率^[31]:

$$DSC = \frac{2|G_S \cap G_{GT}|}{|G_S| + |G_{GT}|}.$$

查全率^[32](Recall):

$$Recall = \frac{TP}{TP + FN} \times 100\%.$$

查准率^[33](Precision):

$$Precision = \frac{TP}{TP + FP} \times 100\%.$$

在以上四个常用的客观评价指标中, G_S 表示算法分割后的图像; G_{GT} 表示 GT 图像, $|\cdot|$ 表示区域中的像素数量, TP 表示真正例, FP 表示假正例, FN 表示假反例。

表 2 为 GGDSP 模型对自然图像分割的客观评价结果。其中,四个客观指标的取值范围为 $[0, 1]$,客观评价价值越接近 1,表明分割效果越好,

表 2 GGDSP 模型自然图像分割的客观评价结果

Tab. 2 Objective evaluation results of the GGDSP model for natural image segmentation

	DSC	Precision	Recall	JSC
图 3(a ₁)	0.987 1	0.988 8	0.985 4	0.974 5
图 3(a ₂)	0.994 8	0.995 9	0.993 6	0.989 6
图 3(a ₃)	0.980 3	0.989 1	0.971 6	0.991 4
图 3(a ₄)	0.977 9	0.986 7	0.969 3	0.956 8
图 3(a ₅)	0.988 9	0.999 9	0.978 0	0.978 0
图 3(a ₆)	0.986 1	0.995 6	0.976 7	0.972 5
图 3(b ₇)	0.989 6	0.984 1	0.995 1	0.979 4

越接近 0,表明分割效果越差。从表 2 可以看出,对于 DSC 评价指标,分割正确率在 97.79%~99.48% 范围内;对于 Precision 指标,分割正确率在 98.67%~99.99% 范围内;对于 Recall 评价指标,分割正确率在 97.16%~99.36% 范围内;对于 JSC 指标,分割正确率在 95.68%~99.14% 范围内,从而进一步验证了 GGDSP 模型的有效性。

4.2 GGDSP 模型的对比实验

4.2.1 GGDSP 模型在灰度图像分割上的对比实验

为了验证 GGDSP 模型对噪声的鲁棒性,在灰度图像中加入 0.001, 0.001 5, 0.002, 0.002 5 等级斑点噪声后,将 GGDSP 模型、LBF 模型^[34]、GLFIF 模型^[35]、ACM-LPF 模型^[36]、ABC 模型、

ALF 模型以及文献[24]模型进行对比实验,其分割结果如图 5 所示。

图 5 显示,由于 LBF 模型、GLFIF 模型、ABC 模型对斑点噪声比较敏感,随着噪声污染越来越严重,分割不够精确,出现欠分割的情况,甚至无法提取目标边界。ALF 模型不仅在前景和背景清晰还是模糊的情况下,都能把目标边界提

取出来,但是 ALF 模型所提取边界不光滑。而 ACM-LPF 模型、文献[24]模型、GGDSP 模型在分割质量方面表现最好,可以消除噪声的影响,准确提取出所需的目标轮廓。这些模型对斑点噪声都具有一定的鲁棒性。为了展示 GGDSP 模型的分割效率,各个模型的迭代次数和运行时间的对比结果如表 3 所示。




图 5 不同等级的斑点噪声的图像分割结果

Fig. 5 Segmentation results on images with different levels of speckle noise

表 3 不同斑点噪声的模型分割运行时间和迭代次数的比较

Tab. 3 Comparison of running time and iteration counts for model segmentation under different speckle noise levels

噪声强度模型	0.001		0.001 5		0.002		0.002 5	
	时间/s	迭代次数	时间/s	迭代次数	时间/s	迭代次数	时间/s	迭代次数
LBF	53.630	280	54.903	320	59.693	350	86.779	500
GLFIF	6.947	160	8.169	190	9.247	220	18.637	260
ACM-LPF	16.158 1	1 100	16.939	1 200	17.207	1 200	19.580	1 400
ABC	3.477	150	3.710	160	3.878	160	4.406	180
ALF	3 829.007	85	4 309.655	90	5 090.786	95	5 469.663	100
文献[24]	119.387 7	800	122.601 1	920	129.630	940	133.868 4	950
GGDSP	2.601	60	3.099	70	3.408 3	70	3.448	75

从表 3 可以看出,针对不同级别的斑点噪声图像,GGDSP 模型的分割时间和迭代次数均优

于其他模型,虽然 ACM-LPF 模型和 GGDSP 模型都能准确提取出所需的目标,但 ACM-LPF 模

型和文献[24]模型的迭代次数远远超过 GGDSP 模型。由此可以看出,GGDSP 模型的分割效率优于其他模型。

为了进一步验证 GGDSP 模型对高斯噪声的鲁棒性,对合成图像加入均值为 $\mu=0$ 方差为 $\sigma=0.01,0.015,0.02,0.025$ 的高斯噪声,与 LBF 模型、GRSF 模型^[37]、GLFIF 模型、ABC 模型、ALF 模型以及文献[24]模型进行对比实验,其分割结果如图 6 所示。此外,为了比较不同模型的分割效率,各个模型的迭代次数和运行时间

的对比结果如表 4 所示。

如图 6 所示,LBF 模型在图像清晰时能精确分割,但随高斯噪声增加,目标边界破坏加剧、光滑性变差,无法完全分割。GRSF 和 ALF 模型在清晰图像中可分割目标,但噪声严重时边界不光滑。GLFIF 模型在清晰图像中能提取目标曲线,噪声严重时边界提取效果变差。ABC 模型在清晰图像中出现过分割。文献[24]模型在清晰图像中能提取目标曲线,噪声严重时就无法分割((d_6)(d_7))。GGDSP 模型在清晰和模糊背景下均能提取光滑目标边界。




图 6 不同高斯噪声的图像分割结果

Fig. 6 Segmentation results on images with different levels of Gaussian noise

表 4 不同高斯噪声的活动轮廓模型运行时间和迭代次数

Tab. 4 Running time and iteration counts of active contour models under different Gaussian noise levels

模型	0.01		0.015		0.02		0.025	
	时间/s	迭代次数	时间/s	迭代次数	时间/s	迭代次数	时间/s	迭代次数
LBF	20.996	190	23.994	220	28.522	260	42.842	400
GRSF	22.842	1 000	27.576	1 180	28.680	1 280	35.678	1 580
GLFIF	17.588	500	18.855	540	20.482	590	22.848	650
ABC	8.666	500	9.498	550	11.106	580	12.602	650
ALF	39.895	300	46.409	350	50.635	380	55.685	420
文献[24]	9.894 9	450	18.755 7	785	18.416 3	820	19.729 1	850
GGDSP	1.974	150	2.240	180	2.509	200	2.733	220

LBF, GRSF, GLFIF, ABC, ALF 模型以及文献[24]模型对高斯噪声敏感,因能量泛函数据项采用 L_2 范数或高斯拟合函数,噪声严重时分割精度下降、过分割或无法分割。GGDSP 模型对清晰和模糊图像均有较好分割效果,对高斯噪声具有鲁棒性。

从表 4 可以看出,针对不同等级的高斯噪声,GGDSP 模型分割时间不仅是最短的,而且迭代次数也是最少的。从分割结果进行观察,GGDSP 模型不管是在前景和背景相对清晰还是模糊的情况下,都能分割出目标区域。

4.2.2 GGDSP 模型在彩色图像分割上的对比实验

为了进一步验证 GGDSP 模型对椒盐噪声的鲁棒性,对自然图像加入 0.05, 0.1, 0.15, 0.2 的椒盐噪声,并与 ABC 模型、LBF 模型、GRSF 模型、GLFIF 模型、ALF 模型及文献[24]模型进行对比实验,分割结果如图 7 所示。

图 7 显示,LBF 模型、GRSF 模型、GLFIF 模型、ALF 模型对椒盐噪声比较敏感,随着噪声增

强,分割结果不理想,甚至不能完全分割。ABC 模型虽然能把目标边界提取出来,但是随着噪声增强,出现了欠分割结果(d_1)。而文献[24]模型、GGDSP 模型能把目标边界提取出来,并且提取的边界光滑。所以文献[24]模型、GGDSP 模型对椒盐噪声具有一定的鲁棒性。为了展示模型的分割效率,其迭代次数和运行时间的对比结果如表 5 所示。

从表 5 中可以看出,LBF 模型、GRSF 模型、ALF 模型分割加椒盐噪声的自然图像时,迭代次数较多,并且分割效果也越来越差,而 ABC 模型、GLFIF 模型分割加椒盐噪声的自然图像时,运行时间较短,随着噪声的增强,ABC 模型出现了欠分割,而 GLFIF 模型效果也越来越不理想。文献[24]模型虽然对加椒盐噪声的自然图像有一定的鲁棒性,但在分割过程中所用时间和迭代次数都比 GGDSP 模型多。所以,在不同椒盐噪声图像分割过程中,GGDSP 模型在保证分割效果理想的前提下,展现出最短的运行时间和最少的迭代次数。




图 7 不同椒盐噪声的图像分割结果

Fig. 7 Image segmentation results with different levels of salt-and-pepper noise

表 5 不同椒盐噪声的模型分割运行时间和迭代次数的比较

Tab. 5 Comparison of model segmentation running time and iteration counts under different levels of salt-and-pepper noise

模型	0.05		0.1		0.15		0.2	
	时间/s	迭代次数	时间/s	迭代次数	时间/s	迭代次数	时间/s	迭代次数
ABC	5.282	40	5.465	50	6.646	160	9.807	260
LBF	433.469	260	497.833	300	537.106	320	594.089	350
GRSF	138.220	900	151.279	950	160.153	1 000	189.004	1 200
GLFIF	6.077	80	7.373	100	9.398	130	11.013	150
ALF	1 966.090	200	2 234.495	260	2 354.036	280	2 566.090	300
文献[24]	39.879 2	120	51.377 9	168	85.976 7	275	311.685 6	915
GGDSP	13.951	70	20.878	95	29.545	150	58.791	300

为了进一步验证 GGDSP 模型对高斯噪声的鲁棒性,给真实图像添加均值为 0,方差为 0.01,0.02,0.03,0.04 的高斯噪声,与 LSACM 模型、ACM-LPF 模型、GLFIF 模型、ABC 模型以及 ALF 模型进行对比实验,结果如图 8 所示。

如图 8 所示,ABC 模型和 GGDSP 模型,不仅能把目标边界完全提取出来,而且所提取的边界光滑,但 ABC 模型随着噪声污染的增加,出现了欠分割。而 LSACM 模型、ACM-LPF 模型、GLFIF 模型及 ALF 模型对高斯噪声比较敏感,无法提取目标边界。由图 8 第一行至第四行显示,随



图 8 不同高斯噪声的图像分割结果

Fig. 8 Segmentation results on images with different levels of Gaussian noise

着噪声污染越来越严重,GGDSP模型不仅能把目标边界提取出来,而且所提取的边界光滑。而LSACM模型、ACM-LPF模型、GLFIF模型、ABC模型以及ALF模型对高斯噪声比较敏感,不能达到理想的分割结果。从图8可以看出,ABC模型虽然可以提取目标边界,但存在欠分割(d_4),最终导致分割任务失败。特别是LSACM模型、ACM-LPF模型、GLFIF模型分割效果最差。而GGDSP模型都能把目标边界全部提取出来,而且所提取的边界光滑,对高斯噪声具有一定的鲁棒性。

为了进一步验证GGDSP模型对噪声的鲁棒性,给真实图像添加0.005,0.01,0.015,0.02的

斑点噪声,并与LSACM模型、GRSF模型、GLFIF模型、ABC模型以及ALF模型进行对比实验,结果如图9所示。

图9显示,ALF模型对斑点噪声比较敏感,不能分割目标。ABC模型随着斑点噪声的增加,虽然能把目标边界提取出来,但出现了过分割(d_4),最终导致分割失败。LSACM模型、GRSF模型、GLFIF模型在斑点噪声污染小的时候能把目标边界提取出来,但是随着斑点噪声的增强,当斑点噪声强度为0.02时,目标边界就完全提取不出来。而GGDSP模型能把目标边界完全提取出来,并且提取边界光滑。所以,GGDSP模型对斑点噪声具有一定的鲁棒性。




图9 不同斑点噪声的图像分割结果

Fig. 9 Segmentation results on images with different levels of speckle noise

5 结 论

本文提出了一种基于全局高斯分布和统计

范数度量的分割模型。该模型有效地融合了图像的边缘信息和图像的全局区域信息,使其具有较强的目标与背景分离能力,并通过正则参

数对水平集函数进行约束,提高了对高噪声图像分割的准确性,较好地实现了目标边界的提取。最后在灰度图像、自然图像和真实图像上进行了实验,并与几种已知方法进行了比较。实验结果表明,GGDSP 模型能够从不同等级的噪声中对图像进行准确的分割,同时分割结果不受初始轮廓位置、大小以及形状的影响,而且该模型在精度和计算效率方面都具有优越的性能。

参考文献:

- [1] ZHAO Y Y, LI J J, REN L, *et al.* DTAN: Diffusion-based Text Attention Network for medical image segmentation [J]. *Computers in Biology and Medicine*, 2024, 168: 107728.
- [2] YE F F, LIU C C, WANG J M, *et al.* Kidney stone and tumor segmentation by analyzing medical images using deep learning technique [J]. *Engineering Applications of Artificial Intelligence*, 2025, 160: 111878.
- [3] PIAO J Z, HU K S, JUNG H S, *et al.* Deep learning-based segmentation of enamel, cementum, alveolar bone, and gingiva in periodontal ultrasound images [J]. *Journal of Dentistry*, 2026, 170: 106705.
- [4] CHEN Y, CHEN J, JIANG Y C, *et al.* A comparative study of deep learning-based zebrafish image segmentation methods [J]. *Cells & Development*, 2026, 186: 204083.
- [5] SINGH L, JANGHEL R R, SAHU S P. An empirical review on evaluating the impact of image segmentation on the classification performance for skin lesion detection [J]. *IETE Technical Review*, 2023, 40(2): 190-201.
- [6] PARAGIOS N, DERICHE R. Geodesic active contours and level sets for the detection and tracking of moving objects [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(3): 266-280.
- [7] ZHANG H L, TANG L M, HE C J. A variational level set model for multiscale image segmentation [J]. *Information Sciences*, 2019, 493: 152-175.
- [8] ZHAO W X, WANG W W, FENG X C, *et al.* A new variational method for selective segmentation of medical images [J]. *Signal Processing*, 2022, 190: 108292.
- [9] ZHANG K H, SONG H H, ZHANG L. Active contours driven by local image fitting energy [J]. *Pattern Recognition*, 2010, 43(4): 1199-1206.
- [10] LI C M, HUANG R, DING Z H, *et al.* A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI [J]. *IEEE Transactions on Image Processing*, 2011, 20(7): 2007-2016.
- [11] ZHANG K H, ZHANG L, LAM K M, *et al.* A level set approach to image segmentation with intensity inhomogeneity [J]. *IEEE Transactions on Cybernetics*, 2016, 46(2): 546-557.
- [12] WENG G R, DONG B, LEI Y. A level set method based on additive bias correction for image segmentation [J]. *Expert Systems with Applications*, 2021, 185: 115633.
- [13] WANG L, HE L, MISHRA A, *et al.* Active contours driven by local Gaussian distribution fitting energy [J]. *Signal Processing*, 2009, 89(12): 2435-2447.
- [14] MA D D, LIAO Q M, CHEN Z Q, *et al.* Adaptive local-fitting-based active contour model for medical image segmentation [J]. *Signal Processing: Image Communication*, 2019, 76: 201-213.
- [15] RANJBARZADEH R, DOROSTI S, JAFARZADEH GHOUSHCHI S, *et al.* Breast tumor localization and segmentation using machine learning techniques: Overview of datasets, findings, and methods [J]. *Computers in Biology and Medicine*, 2023, 152: 106443.
- [16] ZHU S C, YUILLE A. Region competition: unifying snakes, region growing, and Bayes/MDL for multiband image segmentation [J]. *IEEE Transac-*

作者贡献声明:

刘相国:测量方法的提出,数据整理和分析
和撰写,论文撰写;

刘国军:测量实验的设计及论文审核和论文
构思;

马月梅:数据整理与论文审核;

宋新年:测量实验及数据采集;

李更生:数据整理与分析,论文审核。

- tions on Pattern Analysis and Machine Intelligence, 1996, 18(9): 884-900.
- [17] LU X Q, ZHENG H Z, LIU Y Q, *et al.* Segmentation-enhanced gamma spectrum denoising based on deep learning[J]. *IET Communications*, 2024, 18(1): 63-80.
- [18] CUI W C, MENG D, LU K, *et al.* Automatic segmentation of ultrasound images using SegNet and local Nakagami distribution fitting model[J]. *Biomedical Signal Processing and Control*, 2023, 81: 104431.
- [19] ROY R, GHOSH S, GHOSH A. Speckle noise removal: a local structure preserving approach[J]. *SN Computer Science*, 2024, 5(4): 367.
- [20] CHAN T F, VESE L A. Active contours without edges[J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277.
- [21] NIAZ A, RANA K, JOSHI A, *et al.* Hybrid active contour based on local and global statistics parameterized by weight coefficients for inhomogeneous image segmentation [J]. *IEEE Access*, 2020, 8: 57348-57362.
- [22] WANG H, HUANG T Z, XU Z B, *et al.* An active contour model and its algorithms with local and global Gaussian distribution fitting energies[J]. *Information Sciences*, 2014, 263: 43-59.
- [23] YANG X B, ZHANG Z X, ZHANG L, *et al.* Global superpixel-merging via set maximum coverage[J]. *Engineering Applications of Artificial Intelligence*, 2024, 127: 107212.
- [24] 李更生, 刘国军. 融合统计范数度量的局部区域图像分割[J]. *光学精密工程*, 2024, 32(16): 2550-2563.
- LI G S, LIU G J. Local region image segmentation by fusion of statistical norm metrics[J]. *Opt. Precision Eng.*, 2024, 32(16): 2550-2563. (in Chinese)
- [25] POSIRCA I, CHEN Y M, BARCELOS C Z. A new stochastic variational PDE model for soft Mumford - Shah segmentation [J]. *Journal of Mathematical Analysis and Applications*, 2011, 384(1): 104-114.
- [26] SARTI A, CORSI C, MAZZINI E, *et al.* Maximum likelihood segmentation of ultrasound images with Rayleigh distribution[J]. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 2005, 52(6): 947-960.
- [27] LIU H X, FANG J X, ZHANG Z J, *et al.* Localised edge-region-based active contour for medical image segmentation [J]. *IET Image Processing*, 2021, 15(7): 1567-1582.
- [28] SHI J P, YAN Q, XU L, *et al.* Hierarchical image saliency detection on extended CSSD [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(4): 717-729.
- [29] ARBELÁEZ P, MAIRE M, FOWLKES C, *et al.* Contour detection and hierarchical image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(5): 898-916.
- [30] DANG H Y, TANG L M, REN Y J, *et al.* A variational level set model based on local-global function approximation for image segmentation[J]. *Digital Signal Processing*, 2024, 146: 104357.
- [31] WALI S, LI C M, IMRAN M, *et al.* Level-set evolution for medical image segmentation with alternating direction method of multipliers[J]. *Signal Processing*, 2023, 211: 109105.
- [32] CAO J F, CHEN K, HAN H. A fractional-order image segmentation model with application to low-contrast and piecewise smooth images Image 1[J]. *Computers & Mathematics with Applications*, 2024, 153: 159-171.
- [33] SU J W, LUO Z M, LIAN S, *et al.* Mutual learning with reliable pseudo label for semi-supervised medical image segmentation [J]. *Medical Image Analysis*, 2024, 94: 103111.
- [34] LI C M, KAO C Y, GORE J C, *et al.* Implicit Active Contours Driven by Local Binary Fitting Energy[C]. 2007 *IEEE Conference on Computer Vision and Pattern Recognition*. June 17-22, 2007, Minneapolis, MN, USA. *IEEE*, 2007: 1-7.
- [35] FANG J X, LIU H X, LIU J, *et al.* Fuzzy region-based active contour driven by global and local fitting energy for image segmentation [J]. *Applied Soft Computing*, 2021, 100: 106982.
- [36] DING K Y, XIAO L F, WENG G R. Active contours driven by local pre-fitting energy for fast im-

age segmentation[J]. *Pattern Recognition Letters*, 2018, 104: 29-36.

[37] DING K Y, XIAO L F, WENG G R. Active con-

tours driven by region-scalable fitting and optimized Laplacian of Gaussian energy for image segmentation[J]. *Signal Processing*, 2017, 134: 224-233.

作者简介:



刘相国(1979—),男,宁夏银川人,副教授,博士研究生,2005年于北方民族大学获得学士学位,2008年于西安理工大学获得硕士学位,现为巢湖学院数学与大数据学院教师,主要从事偏微分方程图像处理的研究。E-mail: liuxiangguo888@163.com

通讯作者:



刘国军(1978—),男,宁夏吴忠人,教授,博导,2000年于宁夏大学获得学士学位,2003年于宁夏大学获得硕士学位,2013年于西安电子科技大学获得博士学位,现为宁夏大学数学统计学院教师,主要从事图像的数学方法,张量分析,图像质量评价,扩散生成建模的研究。E-mail: liugj@nux.edu.cn