

基于KFCM与多特征融合的皮肤镜病变区域提取

栗碧悦, 侯俊, 王子硕, 薛渊, 摆惟圆

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2023年7月13日; 录用日期: 2023年9月11日; 发布日期: 2023年9月18日

摘要

病变轮廓的检测是病灶提取、定性研究和探明病灶与其周围组织间关系的基础。针对皮肤镜图像病变区域灰度强度不均匀导致病变区域难以提取的问题, 本文提出一种基于模糊核聚类算法(KFCM)与多特征融合的病变区域提取算法。首先, 将原始图像进行模糊核聚类, 把得到的聚类结果作为多特征融合轮廓提取模型的初始轮廓, 其次利用轮廓曲线演化对图像全局信息与局部信息采用自适应加权, 构建符号压力函数(Signed Pressure Force, SPF), 最后利用轮廓曲线演化来分割图像, 提取出病变区域。通过真实皮肤镜图像验证了提出的模型在SPF函数和自适应函数引入两方面均能提升提取性能, 且在定性和定量对比评价上均优于其他方法, 同时对噪声具有鲁棒性。

关键词

病变提取, KFCM, 活动轮廓模型, 符号压力函数, 全局和局部信息

Extraction of Dermoscopic Lesions Based on KFCM and Multi-Feature Fusion

Biyue Li, Jun Hou, Zishuo Wang, Yuan Xue, Weiyuan Bai

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Jul. 13th, 2023; accepted: Sep. 11th, 2023; published: Sep. 18th, 2023

Abstract

The detection of lesion contour is the basis of lesion extraction, qualitative study and the relationship between lesion and surrounding tissue. Aiming at the problem that the lesion area is dif-

difficult to extract due to the uneven gray intensity of the lesion area in dermoscopic images, this paper proposes a lesion area extraction algorithm based on fuzzy kernel clustering algorithm (KFCM) and multi-feature fusion. Firstly, the original image is fuzzy kernel clustering, and the clustering result is used as the initial contour of the multi-feature fusion contour extraction model. Secondly, the global and local information of the image is weighted by adaptive contour curve evolution, and a Signed Pressure Force (SPF) function is constructed. Finally, the contour curve evolution was used to segment the image and extract the diseased area. Through real dermoscopic images, it is verified that the proposed model can improve the extraction performance in both SPF function and adaptive function, and is superior to other methods in qualitative and quantitative comparison evaluation, and is robust to noise.

Keywords

Lesion Extraction, KFCM, Active Contour Model, Signed Pressure Force, Global and Local Information

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

恶性黑色素瘤是一种常见的临床恶性皮肤肿瘤，严重威胁着人们的生命健康。在借助皮肤镜进行临床辅助诊断时，由于实际中采集角度、光线环境和患者的病症表现等差异，造成病变皮损边界模糊、病变形状不规则和颜色分布不均匀等情况。准确检测出皮肤镜图像的病变边界是提取病变特征、黑色素瘤稳定性和分类的前提，帮助患者尽早确诊、及时治疗。

常用的皮肤镜病变区域图像分割算法，主要分为阈值分割、边缘检测、聚类分割、活动轮廓等，由于受到皮肤镜图像病变区域灰度不均匀的限制，这些方法很难从皮肤镜图像准确提取出病变区域。Faal 等人[1] [2]利用皮肤镜图像的灰度直方图设定合适的阈值，最终提取出病变区域。该方法计算简单，但当病灶区域与正常皮肤区域之间对比度较低的情况下，难以找到合适的阈值；Mag 等人[3]采用预处理以及微分算子方式得到皮损病变区域的边界，由于皮肤病变图像边界模糊且存在毛发、气泡等不同噪声的干扰，在一定程度上影响了分割出的病变边界；Liu 等人[4]依据图像内部结构划分为多个类别将均值漂移算法引入皮肤镜图像分割中，Devanathan 等人[5]利用核函数的思想将模糊 C 均值聚类方法引入皮肤镜图像分割中，当病变灰度分布参差不齐的时候，这两种方法分割效果均不佳；随着活动轮廓方法的发展，Chan 和 Vese [6]设计 C-V 模型利用图像的区域统计信息来构造轮廓演化的驱动力，该模型对强度均匀的目标图像有较好的分割效果，却不能准确分割灰度不均匀图像，后续 Zhang 等人[7]提出了基于区域符号压力函数驱动的活动轮廓模型，将测地线模型[8]和 CV 模型结合，然而还是不能有效地分割灰度不均匀的图像。

为了解决上述问题，本文提出了一种基于 KFCM 与多特征融合的病变区域提取模型。采用模糊核 C 均值聚类方法，将样本空间映射到高维的特征空间并聚类，聚类结果作为初始轮廓，利用全局和局部符号压力函数并用自适应权重系数构建的多特征融合的活动轮廓演化模型，提取皮肤镜病变区域。

2. 病变区域聚类

由于皮肤镜图像边界模糊以及受到毛发、气泡等噪声的干扰，通过模糊核聚类算法对图像进行聚类，

在聚类皮肤边缘信息的同时降低了图像中各种噪声的干扰。模糊核聚类算法(KFCM)是基于模糊 C 均值算法改进的算法, 将核函数引入到模糊 C 均值聚类算法中, 该方法利用核函数将数据预处理集映射到高维特征空间上, 通过迭代优化目标函数, 实现对输入样本的模糊聚类[9]。核函数聚类的方法实用性强于传统的 FCM 算法, 迭代次数较少, 同时能够聚类被噪声污染、不对称的数据。

待聚类的样本数据集 $X = \{x_1, x_2, \dots, x_n\}$ 表示图像灰度值的集合, n 为样本总数, 数据集到特征空间 F 的映射关系为: $\varphi = X \rightarrow \phi(x_j) \in F$ 。利用径向基函数改变 FCM 中的距离的定义方式, 得到目标函数[10]:

$$J_{\text{KFCM}}(U, V) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \left\| \phi(x_j) - \phi(v_i) \right\|^2 \quad (1)$$

其中, 参数 c 是聚类数, m 是模糊加权指数参数, 决定最终结果的模糊程度, 参数 u_{ij} 表示像素 k 归属于第 i 类的隶属度, 参数 v_i 表示是第 i 类的聚类中心, 式中 $\left\| \phi(x_j) - \phi(v_i) \right\|^2 = k(x_j, x_j) + k(v_i, v_i) - 2k(x_j, v_i)$, 同时 $k(x_j, x_j)$ 、 $k(v_i, v_i)$ 和 $k(x_j, v_i)$ 的运算公式选取常用的高斯径向基函数:

$$k(a, b) = e^{-\frac{\|a-b\|^2}{\tau^2}} \quad (2)$$

其中, τ 表示核函数的宽度, 由于 $k(x_j, x_j)$ 和 $k(v_i, v_i)$ 的值都为 1, 因此目标函数可简写为:

$$J_{\text{KFCM}}(U, V) = 2 \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m (1 - k(x_j, v_i)) \quad (3)$$

对于任意 j , 样本数据 x_j 对于所有聚类中心的隶属度和为 1; 对于任意 i, j , u_{ij} 隶属度取值范围为区间 $[0, 1]$; 对于一个类中所有样本数据的隶属度和范围为 $[0, n]$; 在约束条件下使目标函数 $J_{\text{KFCM}}(U, V)$ 最小, 为此使用 Lagrange 乘法求极值得到隶属度矩阵 $U = [u_{ij}]_{c \times n}$ 和聚类中心 V 为:

$$u_{ij} = \frac{\frac{1}{(1 - k(x_j, v_i))^{m-1}}}{\sum_{k=1}^c \frac{1}{(1 - k(x_j, v_k))^{m-1}}} \quad (4)$$

$$v_i = \frac{\sum_{j=1}^n u_{ij}^m k(x_j, v_i) x_j}{\sum_{j=1}^n u_{ij}^m k(x_j, v_i)} \quad (5)$$

3. 病变区域提取

3.1. 经典活动轮廓模型

3.1.1. Chan-Vese 模型

Chan 和 Vese [6]提出的 C-V (Chan-Vese, CV)模型是经典的活动轮廓模型, 该模型利用图像全局灰度信息构建能量函数, 能够有效的解决图像弱边界的问题, 极小化能量函数[11]:

$$E(f(x), c_1, c_2) = \lambda_1 \int_{\text{inC}} |I(x) - c_1|^2 dx + \lambda_2 \int_{\text{outC}} |I(x) - c_2|^2 dx + \mu \int \delta(f(x)) |H(f(x))| dx \quad (6)$$

其中, $I(x)$ 为原图像, λ_1, λ_2 均大于 0, μ 为加权系数, $\phi(x)$ 为水平集函数, 式中 $H(\phi)$ 为 Heaviside 函数, $\delta(\phi(x))$ 为 Dirac 函数, 定义分别为:

$$H(\phi) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan \left(\frac{\phi}{\varepsilon} \right) \right] \quad (7)$$

$$\delta(\phi(x)) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + \phi^2} \tag{8}$$

以交替迭代算法的方式极小化能量函数，先固定水平集函数 $\phi(x)$ ，得到变量 c_1 和 c_2 的极小值点：

$$c_1 = \frac{\int I(x)H(\phi(x))dx}{\int H(\phi(x))dx} \tag{9}$$

$$c_2 = \frac{\int I(x)(1-H(\phi(x)))dx}{\int (1-H(\phi(x)))dx} \tag{10}$$

c_1, c_2 分别是轮廓曲线 C 内外的灰度均值，固定 c_1 和 c_2 引入时间变量 t ，利用变分法和梯度下降法得到能量函数关于水平集函数 $\phi(x)$ 的极小点，最终得到演化方程的稳态解为：

$$\frac{\partial \phi}{\partial t} = \delta(\phi) \left[\mu \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \lambda_1 |I(x) - c_1|^2 + \lambda_2 |I(x) - c_2|^2 \right] \tag{11}$$

由于 C-V 模型是基于全局信息对图像进行分割，即利用轮廓曲线内外的灰度均值，对于目标和背景对比明显的图像处理效果好，但是由于受到其能量泛函的限制，不能有效分割灰度不均匀的图像。

3.1.2. SLGS 模型

Zhang 等人[7]提出了基于区域的符号压力函数驱动的活动轮廓模型(SLGS)，该模型在保持了 CV 模型的优点的基础上，又构造了符号压力函数(SPF)，以活动轮廓内外的平均灰度为驱动，计算输入图像与驱动中心的灰度差值来引导曲线的演化，其水平集演化方程为：

$$\frac{\partial \phi}{\partial t} = \operatorname{spf}(I(x)) \cdot \alpha |\nabla \phi| \tag{12}$$

其中， $I(x)$ 表示原图像， α 为气球力参数，调节水平集演化的速率，SPF 为符号压力函数[12] [13]定义如下：

$$\operatorname{spf}(I(x)) = \frac{I(x) - \frac{c_1 + c_2}{2}}{\max \left(\left| I(x) - \frac{c_1 + c_2}{2} \right| \right)} \tag{13}$$

SLGS 模型比 C-V 模型效率更快，但是该模型和 C-V 模型一样基于图像全局信息，图像的局部信息没有参与模型的构建，致使对灰度不均匀图像的分割效果不理想，易受噪声干扰。

3.2. 多特征融合的轮廓提取模型

考虑到经典的活动轮廓模型不能有效的分割灰度不均匀的图像，本文采用 Zhang 等人的水平集的方法，同时结合全局信息与局部熵、局部标准差和局部梯度构造的局部信息设计新的符号压力函数，并通过自适应权重系数来设计总 SPF 函数，通过此函数来构造模型的演化方程。

3.2.1. 全局项

为了避免演化曲线陷入局部最小值，同时使曲线可以快速通过灰度均匀的背景，本文利用图像全局灰度平均信息形成全局项，符号可以指导曲线演化的方向，使曲线收缩或者膨胀，定义为：

$$\text{SPF}_{\text{global}}(u, v) = I(u, v) - (c_1 \cdot H(\phi) + c_2 \cdot (1 - H(\phi))) \quad (14)$$

$I(u, v)$ 表示原图像， $\text{SPF}_{\text{global}}$ 函数的第二项表示拟合图像，利用 $H(\phi)$ 函数将轮廓内外的平均强度组合起来。当原图像 $I(u, v)$ 与拟合图像的差值最小时 $\text{SPF}_{\text{global}}$ 趋于 0，轮廓曲线停止演化。

3.2.2. 局部项

仅考虑全局灰度信息分割灰度不均匀的病变图像效果是不理想的，为了更精确地指导演化方向，还要结合局部熵、局部标准差和局部梯度信息一同构造局部信息[14]。在中心像素 (u, v) 的周围设一个大小为 $n \times n$ 的局部窗口 W_n ，则图像的熵、标准差和梯度分别为：

$$I_{\text{en}}(u, v) = \sum_{i=0}^L p_i \log p_i \quad (15)$$

$$I_{\text{std}}(u, v) = \sqrt{\frac{1}{n \times n} \sum_{(u, v) \in W_n} (I(u, v) - \mu)^2} \quad (16)$$

$$I_{\text{grad}}(u, v) = \sqrt{(I(u+1, v) - I(u, v))^2 + (I(u, v+1) - I(u, v))^2} \quad (17)$$

其中， L 代表图像灰度最大值， i 代表某一灰度值， n_i 代表 i 对应的像素数， p_i 代表为 i 的灰度值在窗口区域内出现的概率大小， μ 指的是窗口内灰度均值。同时，在局部熵、局部标准差和局部梯度中引入高斯核函数 K_δ ，* 代表卷积， $M_1(\phi) = H(\phi)$ ， $M_2(\phi) = 1 - H(\phi)$ ，轮廓内外的局部特征信息定义如下：

$$\sum_{\text{in}}(u, v) = \begin{cases} \text{entro}_{\text{in}}(u, v) = \frac{K_\delta * [M_1(\phi) I_{\text{en}}(u, v)]}{K_\delta * M_1(\phi)} \\ \text{std}_{\text{in}}(u, v) = \frac{K_\delta * [M_1(\phi) I_{\text{std}}(u, v)]}{K_\delta * M_1(\phi)} \\ \text{grad}_{\text{in}}(u, v) = \frac{K_\delta * [M_1(\phi) I_{\text{grad}}(u, v)]}{K_\delta * M_1(\phi)} \end{cases} \quad (18)$$

$$\sum_{\text{out}}(u, v) = \begin{cases} \text{entro}_{\text{out}}(u, v) = \frac{K_\delta * [M_2(\phi) I_{\text{en}}(u, v)]}{K_\delta * M_2(\phi)} \\ \text{std}_{\text{out}}(u, v) = \frac{K_\delta * [M_2(\phi) I_{\text{std}}(u, v)]}{K_\delta * M_2(\phi)} \\ \text{grad}_{\text{out}}(u, v) = \frac{K_\delta * [M_2(\phi) I_{\text{grad}}(u, v)]}{K_\delta * M_2(\phi)} \end{cases} \quad (19)$$

通过 Heaviside 函数构成轮廓两侧的特征信息，因此我们可以得到由三个局部特征支配的 SPF，它们分别被定义为：

$$\text{spf}_{\text{en}}(u, v) = I_{\text{en}}(u, v) - [\text{entro}_{\text{in}}(u, v) \cdot M_1(\phi) + \text{entro}_{\text{out}}(u, v) \cdot M_2(\phi)] \quad (20)$$

$$\text{spf}_{\text{std}}(u, v) = I_{\text{std}}(u, v) - [\text{std}_{\text{in}}(u, v) \cdot M_1(\phi) + \text{std}_{\text{out}}(u, v) \cdot M_2(\phi)] \quad (21)$$

$$\text{spf}_{\text{grad}}(u, v) = I_{\text{grad}}(u, v) - [\text{grad}_{\text{in}}(u, v) \cdot M_1(\phi) + \text{grad}_{\text{out}}(u, v) \cdot M_2(\phi)] \quad (22)$$

利用局部特征信息得出局部项的 SPF 函数，其定义如下：

$$\text{SPF}_{\text{local}}(u, v) = \text{spf_en}(u, v) + \text{spf_std}(u, v) + \text{spf_grad}(u, v) \quad (23)$$

3.2.3. 自适应权重系数

在曲线演化的过程中，为了结合全局项和局部项以控制演化的方向，突出分割目标，引入自适应权重系数[15]，形成总的 SPF 函数：

$$\text{SPF}_{\text{total}} = w(u, v) \cdot \text{SPF}_{\text{global}} + (1 - w(u, v)) \cdot \text{SPF}_{\text{local}} \quad (24)$$

自适应权重系数 $w(u, v)$ 决定 SPF 函数主要受全局项还是局部项的影响，起到动态调整全局项和局部项的作用。当图像的强度变化显著时，只靠全局信息可能会造成错误分割；当图像强度变化缓慢时，应该增加全局项的比重，使曲线扩张并快速通过。因此，我们选择局部范围来定量地反映图像强度的变化，计算一个 $m \times m$ 大小窗口中的最大值与最小值的差值，其表示式如下：

$$\text{range}(u, v) = \max(W_m(u, v)) - \min(W_m(u, v)) \quad (25)$$

自适应权重系数的表达式如下：

$$w(u, v) = \frac{1}{1 + \lambda \cdot \text{range}(u, v)} \quad (26)$$

其中， $w(u, v) \in (0, 1)$ 且 λ 是一个常数，利用自适应权重系数，这样可以克服传统的符号压力函数仅利用全局区域信息或仅利用局部信息，而不能有效的处理灰度不均匀图像的缺点。通过结合符号压力函数 $\text{SPF}_{\text{total}}$ 和自适应权重系数 w ，给出新的水平集演化方程为：

$$\frac{\partial \phi}{\partial t} = \text{SPF}_{\text{total}} \cdot \alpha \cdot |\nabla \phi| = [w \cdot \text{SPF}_{\text{global}} + (1 - w) \cdot \text{SPF}_{\text{local}}] \cdot \alpha \cdot |\nabla \phi| \quad (27)$$

3.2.4. 提取流程

在传统的 ACM 中符号距离函数(SDF)用于表示从一个像素点到轮廓曲线上的最短距离，当曲线的位置发生改变时，SDF 的值也会相应的进行改变。为了减少 SDF 的计算时间和水平集初始化的过程，选择 Zhang 等人[7]提出的水平集函数：

$$\phi(u, v, t = 0) = \begin{cases} -c_0, (u, v) \in \Omega_0 - \partial\Omega_0 \\ 0, (u, v) \in \partial\Omega_0 \\ c_0, (u, v) \in \Omega - \Omega_0 \end{cases} \quad (28)$$

对于水平集函数重新正则化问题[16]，使用高斯函数对每次迭代后的水平集函数进行处理：

$$\phi_t = \phi_{t-1} * G_{\sigma_\phi} \quad (29)$$

符合以下条件时，曲线停止演化：

$$|\phi_t - \phi_{t-1}| < \delta \quad (30)$$

综合上述分析，该算法流程具体如下：

- 1) 初始化水平集函数 ϕ ，设置部分参数；
- 2) 开始循环。分别根据式(14)和(23)，计算图像的 $\text{SPF}_{\text{global}}$ 和 $\text{SPF}_{\text{local}}$ ；
- 3) 根据式(26)计算自适应权重 $w(u, v)$ ；
- 4) 根据式(24)计算 $\text{SPF}_{\text{total}}$ ；

- 5) 根据式(27), 更新水平集函数 ϕ ;
- 6) 选取高斯滤波对水平集函数 ϕ 正则化;
- 7) 判断 ϕ 是否达到停止条件。若达到, 停止演化; 否则, 继续转到步骤(2)。

4. 实验结果与分析

4.1. 数据集和评估指标

为验证本文所提算法对皮肤镜病变区域提取的可行性, 选择来自于 ISIC2018 数据集图像, 所有皮肤镜图像的真实分割结果由专业的皮肤科医生评审并整理, 验证本模型对于灰度不均匀和边界模糊形状不规则图像的提取能力以及噪声的鲁棒性。本实验的运行环境为: PC 机 CPU 为 Inter(R)Core(TM)i5-7200CPU@3.2GHz, 内存为 4 GiB, MATLAB 版本为 R2018a。实验采用 IOU (Intersection over Union, IOU) [16]和 Hausdorff 距离[17] (Hausdorff distance, HD)分别对提取的病变结果进行定量评价。

若 A 和 B 分别表示算法分割结果和真实分割结果, 则

$$\text{IOU} = \frac{|A \cap B|}{|A \cup B|} \quad (31)$$

$$\text{HD} = \max_{x \in A} \left\{ \min_{y \in B} \{d(x, y)\} \right\} \quad (32)$$

其中, $d(x, y)$ 代表的是像素点 x 和 y 的欧式距离。

IOU 是衡量分割的病变区域与真实的区域的匹配程度; HD 为衡量目标边缘与真实病变边缘的偏离程度。IOU 越大, HD 越小, 表示分割性能越好。

4.2. 实验结果分析

为了能看出病变区域轮廓的位置, 实验结果中用红色表示最终模型演化得到的病变分割轮廓。为验证本文模型对皮肤病变区域提取的有效性, 本文选取文献[6]中 CV 模型、文献[8]中 GAC 模型、文献[7]中 SLGS 模型与本文模型进行对比。图 1 展示出不同模型对皮肤病变区域提取的结果。图 1(a)~(d)来源于 ISIC2018 数据集, 从上到下依次为原始图像、聚类结果、分割结果、本文模型、CV、GAC、SLGS 提取的结果, 其中图 1(a)和图 1(b)为色素痣示例, 图 1(c)和图 1(d)为黑色素瘤示例。

图 1(a)所示的皮肤病变区域边界轮廓复杂, CV 和 GAC 作为基础的活动轮廓模型对目标区域提取的能力严重不足, SLGS 模型相对于前两种模型效果较好, 但在处理边界细节上还需要提高。而本文模型结合局部信息和全局信息共同指导曲线的演化, 增强了目标区域的提取能力, 使病变边界细节更清晰。

图 1(b)所示的皮肤镜图像分割目标为图像中部深色区域, 原图皮肤背景与病灶组织的交界区模糊度较小但存在气泡噪声, CV 模型对提取病变区域能力严重不足, SLGS 模型结合了 CV 和 GAC 模型的优点, 可以有效处理边界模糊的图像, 但是当目标局部强度不均匀时也会出现错误, 本文模型的局部信息中的三个特征模块能实现局部特征的提取, 同时对灰度不均匀边界都能正常分割。

图 1(c)中病灶内部区域灰度分布自上而下由稠密到稀疏, 病变形状不规则、病灶边界很模糊且存在大量噪声。CV 模型受到皮肤边界其他小区域的影响, 将较小感兴趣区域误提取为皮肤病变区域, 出现多个小病变块。而 SLGS 和本文模型引入 SPF 函数, 在一定程度上辨别出二者, 减少误分割。

图 1(d)图像形状规则但边界组织区域和病变区域对比度较低, GAC 和 SLGS 模型面对灰度值相近的病变区域时, 均不能正确提取。本文模型由于受到自适应系数的约束, 可以准确的指导演化曲线进行提取。可见无论形状是否规则, 本文模型都能够正确提取出病变区域。




Figure 1. Example of dermoscopic image extraction
图 1. 皮肤镜图像提取示例

表 1 列出了 4 种模型对真实皮肤镜图像病变区域提取的迭代次数和算法运行时间。可以看出, CV 模型和 GAC 模型由于其收敛性较差, 算法运行最耗时; SLGS 模型与本文模型算法运行速度较快, 但因 SLGS 模型只需要全局信息来指导曲线的演化, 局部信息并未参与, 对于本文方法, 在提取不同种类的图像时都拥有更少的迭代次数和运行时间, 优于其他 3 种类型。

表 2 定量评价了 4 种模型对 4 幅真实皮肤镜图像的提取结果。可以看出, 本文模型在提取区域(IOU)和提取边缘(HD)能更好地提取病变区域和皮肤背景。

Table 1. Comparison of iteration times and running time of four models

表 1. 4 种模型迭代次数和运行时间比较

图像	CV		GAC		SLGS		本文	
	迭代次数	耗时(s)	迭代次数	耗时(s)	迭代次数	耗时(s)	迭代次数	耗时(s)
a	100	11.7961	900	56.0781	100	19.3126	70	15.3303
b	50	6.2244	1000	78.4443	30	7.3552	50	6.7403
c	40	6.1983	500	33.5812	50	11.9955	45	14.8961
d	30	3.7889	450	27.7753	40	9.7127	27	10.8505

Table 2. Comparison of extraction accuracy of 4 models

表 2. 4 种模型提取精度比较

图像	CV		GAC		SLGS		本文	
	IOU	HD	IOU	HD	IOU	HD	IOU	HD
a	0.7646	13.8167	0.6901	15.0952	0.8009	11.5952	0.8712	8.2317
b	0.7311	8.1341	0.8479	7.4285	0.8681	7.0873	0.8816	6.689
c	0.7078	14.3108	0.7454	12.5082	0.7496	12.2465	0.8676	10.2961
d	0.8056	7.4736	0.7321	10.3854	0.8226	9.7821	0.8924	7.9582

5. 结论

针对医学图像中灰度不均匀、形状不规则的图像, 本文提出一种模糊核聚类和多特征融合的病变区域提取模型, 分别基于图像的全局信息和局部信息并用自适应权重系数构造符号压力函数, 形成多特征信息融合的提取模型, 该模型能够充分结合两类方法各自的优势, 使水平集演化更高效。实验结果证明, 本文所设计的模型能够提高不同类型皮肤镜病变区域的提取性能, 且分割精度由于多种活动轮廓模型, 具有一定的抗噪性。下一步的研究方向将探讨该模型与深度学习融合, 以实现高效率的皮肤镜病变分类。

参考文献

- [1] Faal, M., Miran Baygi, M.H. and Kabir, E. (2013) Improving the Diagnostic Accuracy of Dysplastic and Melanoma Lesions Using the Decision Template Combination Method. *Skin Research and Technology*, **19**, e113-e122. <https://doi.org/10.1111/j.1600-0846.2012.00617.x>
- [2] Emre Celebi, M., Wen, Q., Hwang, S., et al. (2013) Lesion Border Detection in Dermoscopy Images Using Ensembles of Thresholding Methods. *Skin Research and Technology*, **19**, e252-e258. <https://doi.org/10.1111/j.1600-0846.2012.00636.x>

-
- [3] Gaheen, M.A., Ibrahim, E. and Ewees, A.A. (2021) Edge Detection-Based Segmentation for Detecting Skin Lesions. In: Kumar, P., Kumar, Y. and Tawhid, M.A., Eds., *Machine Learning, Big Data, and IoT for Medical Informatics*, Academic Press, Cambridge, 127-142. <https://doi.org/10.1016/B978-0-12-821777-1.00008-2>
- [4] Liu, Z., Sun, J., Smith, M., et al. (2012) Unsupervised Sub-Segmentation for Pigmented Skin Lesions. *Skin Research and Technology*, **18**, 77-87. <https://doi.org/10.1111/j.1600-0846.2011.00534.x>
- [5] Devanathan, K. (2020) Lesion Segmentation in Dermoscopic Images Using Superpixel Based Fast Fuzzy C-Means Clustering. 2020 *IEEE Congreso Bienal de Argentina (ARGENCON)*, Resistencia, 1-4 December 2020, 1-6. <https://doi.org/10.1109/ARGENCON49523.2020.9505562>
- [6] Chan, T.F. and Vese, L.A. (2001) Active Contours without Edges. *IEEE Transactions on Image Processing*, **10**, 266-277. <https://doi.org/10.1109/83.902291>
- [7] Zhang, K., Zhang, L., Song, H., et al. (2010) Active Contours with Selective Local or Global Segmentation: A New Formulation and Level Set Method. *Image and Vision Computing*, **28**, 668-676. <https://doi.org/10.1016/j.imavis.2009.10.009>
- [8] Caselles, V., Kimmel, R. and Sapiro, G. (1997) Geodesic Active Contours. *International Journal of Computer Vision*, **22**, 61-79. <https://doi.org/10.1023/A:1007979827043>
- [9] Girolami, M. (2002) Mercer Kernel-Based Clustering in Feature Space. *IEEE Transactions on Neural Networks*, **13**, 780-784. <https://doi.org/10.1109/TNN.2002.1000150>
- [10] Miao, J., Zhou, X. and Huang, T.Z. (2020) Local Segmentation of Images Using an Improved Fuzzy C-Means Clustering Algorithm Based on Self-Adaptive Dictionary Learning. *Applied Soft Computing*, **91**, Article ID: 106200. <https://doi.org/10.1016/j.asoc.2020.106200>
- [11] 王星, 宗凯. 基于局部熵的图像分割算法研究与实现[J]. 电子测量技术, 2016, 39(12): 168-171.
- [12] 刘莹, 李筠, 杨海马, 等. 结合区域生长与水平集算法的宫颈癌图像分割[J]. 电子测量与仪器学报, 2020, 34(9): 146-152.
- [13] 孙林, 柯正友, 冯小博, 等. 基于双符号压力函数的活动轮廓图像分割方法[J]. 计算机工程与应用, 2018, 54(20): 213-218.
- [14] Liu, H., Fang, J., Zhang, Z., et al. (2020) A Novel Active Contour Model Guided by Global and Local Signed Energy-Based Pressure Force. *IEEE Access*, **8**, 59412-59426. <https://doi.org/10.1109/ACCESS.2020.2981596>
- [15] Huang, Q., Zhou, W., Wan, M., et al. (2021) Multi-Feature Driven Active Contour Segmentation Model for Infrared Image with Intensity Inhomogeneity. *Optical and Quantum Electronics*, **53**, Article No. 367. <https://doi.org/10.1007/s11082-021-03000-z>
- [16] Li, C., Kao, C.Y., Gore, J.C., et al. (2008) Minimization of Region-Scalable Fitting Energy for Image Segmentation. *IEEE Transactions on Image Processing*, **17**, 1940-1949. <https://doi.org/10.1109/TIP.2008.2002304>
- [17] Beauchemin, M., Thomson, K.P.B. and Edwards, G. (1998) On the Hausdorff Distance Used for the Evaluation of Segmentation Results. *Canadian Journal of Remote Sensing*, **24**, 3-8. <https://doi.org/10.1080/07038992.1998.10874685>