

水平集与深度学习融合的分割算法

孙 兵

吉首大学数学与统计学院, 湖南 吉首

收稿日期: 2026年5月5日; 录用日期: 2026年5月29日; 发布日期: 2026年6月9日

摘 要

使用水平集方法处理弱边界分割问题时, 经常需要人工选择初始轮廓的位置, 严重限制了水平集方法在实际中的应用。针对此问题, 第一阶段使用基于小波去噪技术的级联网络做前处理, 为后处理提供优秀的初始轮廓。第二阶段基于初始轮廓使用基于高斯分布的变分框架对初始轮廓进行进一步细化。实验表明此法不仅解决了手动调整初始位置的麻烦, 在皮肤病数据集中表现良好。

关键词

水平集, 弱边界, 图像分割, 活动轮廓, 卷积神经网络

Segmentation Algorithm Combining Level Set and Deep Learning

Bing Sun

College of Mathematics and Statistics, Jishou University, Jishou Hunan

Received: May 5, 2026; accepted: May 29, 2026; published: June 9, 2026

Abstract

When using the level set method to address weak boundary segmentation problems, the initial contour position often needs to be manually selected, which severely limits the practical application of level set methods. To tackle this issue, a two-stage approach is proposed. In the first stage, a cascaded network based on wavelet denoising technology is employed for preprocessing to generate a high-quality initial contour for subsequent refinement. In the second stage, a Gaussian distribution-based variational framework is applied to further refine the initial contour. Experiments demonstrate that the proposed method not only eliminates the need for manual adjustment of the initial contour but also achieves excellent performance on dermatological image datasets.

Keywords

Level Set, Weak Boundary, Image Segmentation, Active Contour, Convolutional Neural Network

Copyright © 2026 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

在医学图像分析、自动驾驶、跟踪与检测等任务中，图像分割占有很重要的地位。它的基本任务是将图像精确地划分成若干个互不重叠的子区域。近些年来，基于能量最小化的水平集方法因其优秀的拓扑性质得到了广泛的关注。Chan 和 Vese 在文献[1]中将该方法从依赖梯度信息转变为依赖灰度差异信息后，活动轮廓模型得到了更加广泛的应用[2]。水平集方法目前分为两大类：基于边缘的模型和基于区域的模型，如文献[3] [4]。

对于弱边界问题而言，片段常数 Piecewise Constant (PC)模型[5]，片段光滑 Piecewise Smooth (PS)模型[6]都是通过最小化 Mumford-Shah 泛函而设计的方法，但 PC 模型依赖于图像内外部灰度的一致性假设，PS 模型的计算量很大。因此，李纯明等人开发了 Local Binary Fitting (LBF) [7]型和 Local Gaussian Intensity Fitting (LGIF)模型[8]其中 LBF 模型利用局部信息来处理灰度不均匀问题，但在处理灰度分布均值相同而方差不同的任务时会遇到困难。而 LGIF 则通过高斯分布来对方差变化的情况。这些方法对初始轮廓的依赖性都很强。

相对于传统的方法，卷积神经网络(CNN)以其强大的特征提取能力在视觉任务中大放异彩，全卷积网络(FCN)在 CNN 的基础上舍弃全连接层，使模型在图像尺寸问题上展现了极大的灵活性。基于 FCN，后续出现了 U-Net, Dense-U-Net [9]等框架。U-Net 因其对细节的捕捉能力不足导致无法识别精确的边界。

针对以上问题，本文提出了一个两阶段分割框架。第一阶段使用新的网络架构得到初始分割掩码；第二阶段使用基于高斯分布的水平方法细化初始分割掩码并得到最后分割结果。本文的主要贡献如下：

本文的主要贡献如下：

(1) 本文设计了一个融合小波去噪技术的网络架构，该网络通过监督学习为后处理操作提供优异的初始轮廓。

(2) 两阶段的分割框架具备较好的数学可解释性。

2. 基于级联 U-Net 的前处理网络框架设计

为了增加 U-Net 对细节的捕捉能力，研究人员进行了很多改进，其中就包括 Dense U-Net [9]。该模型有以下优点：第一，改善梯度流动；第二，增强了对细节的捕捉能力。模型也存在着很明显的缺点：第一，相对复杂的结构需要更大的计算量；第二，模型的优化相对困难；第三，模型需要很大的内存来储存信息；第四，模型的复杂度较高，数据较少时容易发生拟合。该模型对于小样本问题不友好，对硬件的要求较高，这使得模型的使用受限。

经过前面的分析，本文选用 U-Net 作为底层框架。U-Net 架构简单、易于优化且对于小样本数据比较友好。但对于细节的捕捉能力较差，所以在不显著增加模型复杂度的前提下，进行适当的修改以增强其对细节的捕捉能力。因此，本文选用了级联设计，但级联个数太多也会显著增加复杂度，所以我们控制级联的模型个数。第一个 U-Net 负责对图像进行粗提取，第二个 U-Net 负责细化。底层的基础架构见图 1。

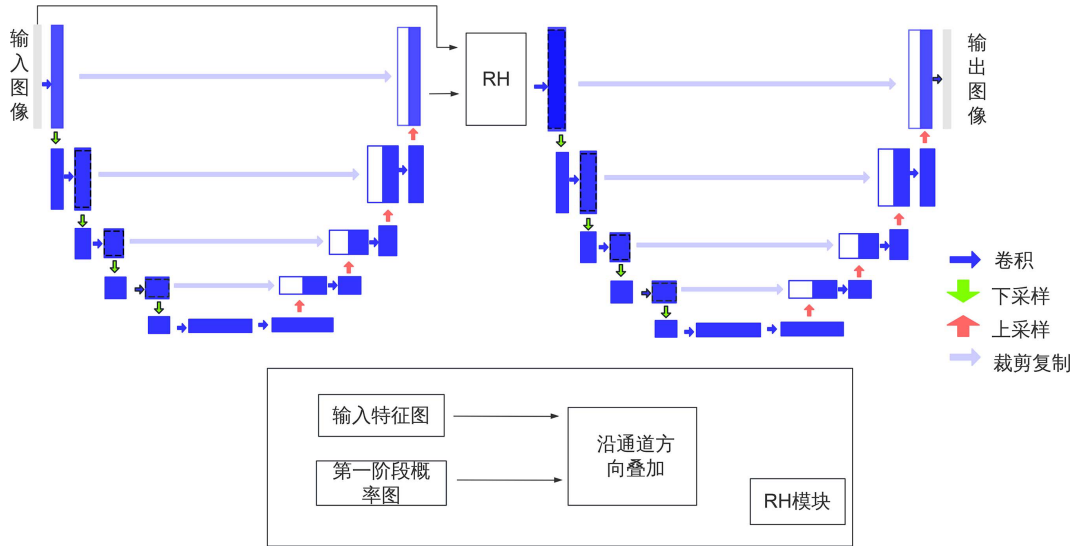


Figure 1. Cascade U-Net network architecture diagram
图 1. 级联 U-Net 网络架构图

我们位置监督器的架构如图 2 如下：




Figure 2. Position supervisor architecture diagram
图 2. 位置监督器架构图

最后我们给出本文前处理的网络架构图(图 3)。

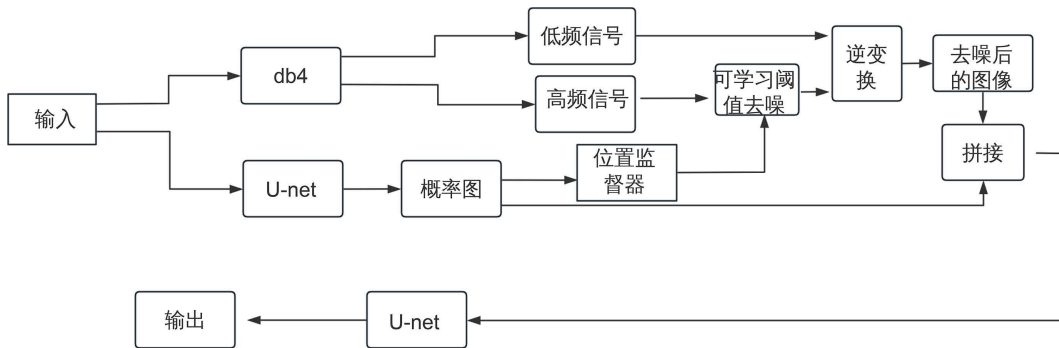


Figure 3. Preprocessing network architecture diagram
图 3. 前处理网络架构图

2.1. 多阶段监督损失函数构建

为提升模型的分割精度与鲁棒性，本文采用多任务联合优化策略，构建了一个由主干分支损失、辅

助监督损失与图像重建损失三部分组成的复合损失函数。其中，主干分支损失用于监督第二阶段 U-Net 的输出与真实标签之间的一致性；辅助监督损失作用于第一阶段 U-Net 的中间输出，通过早期监督机制增强梯度回传，增强模型的稳定性；图像重建损失通过重建图像与原始图像之间的像素级别差异的监控，促使模型在保留主体结构的同时抑制潜在噪声干扰。下文将对上述三类损失函数进行详细阐述。

CE 是分类任务中最常用的损失函数之一，用于衡量模型预测结果与真实标签之间的差异。其定义如下：

$$CE(y, \hat{y}) = -\sum_i y_i \log(\hat{y}_i),$$

其中， y_i 表示第 i 类的真实标签， \hat{y}_i 表示第 i 类的预测结果。

FL 是基于前者做了改进，特别适用于前景与背景像素数量极度不平衡的场景。它通过动态缩放因子降低易分类样本的损失权重，迫使模型更加关注难以分类的样本。该损失函数的数学表达式如下：

$$FL = -\alpha_i (1 - p_i)^\gamma \ln(p_i)$$

其中， p_i 表示模型能够正确分类的概率， α_i 是类别权重因子， γ 为聚焦参数。

主干损失由 L_{focal} (前面的 FL) 和 L_{sdl} 构成， L_{focal} 是前面章节已经定义过，此处不再赘述。该损失适用于前景与背景像素数量极度不平衡的场景。该损失函数的数学表达式如下：

$$L_{\text{focal}} = -\alpha_i (1 - p_i)^\gamma \ln(p_i)$$

其中， p_i 表示模型能够正确分类的概率， α_i 是类别权重因子， γ 为聚焦参数。 L_{sdl} 衡量的仅是前景预测结果和标签的重合度。 L_{sdl} 的表达式为：

$$L_{\text{sdl}} = 1 - 2 \cdot \frac{\sum_{i=1}^{i=N} p_i g_i + \varepsilon}{\sum_{i=1}^{i=N} p_i + \sum_{i=1}^{i=N} g_i + \varepsilon},$$

其中， $g_i \in \{0,1\}$ 表示图像中第 i 个像素的真实标签值， $p_i \in [0,1]$ 表示为模型预测的第 i 个像素的概率值。 ε 是十分小的数值。最终的主干损失表达式为

$$L_{\text{main}} = L_{\text{focal}} + L_{\text{sdl}}.$$

辅助监督损失函数的构成与主干损失函数的成员构成一致。对应的损失函数表达式为

$$L_{\text{aux}} = L_{\text{focal}} + L_{\text{sdl}},$$

但辅助监督损失衡量的是第一阶段 U-Net 的输出与标签的差异量，其他并无差别。

图像重建损失函数监控重建后的图像与原始图像的像素级别的差异，促使模型恢复出尽可能干净完整的图像，并增强模型的鲁棒性。该损失通过像素级别的均方误差来实现。该损失的表达式形式为：

$$L_{\text{denoi}} = \frac{1}{N} \cdot \sum_{i=1}^N (\hat{m}_i - m_i)^2,$$

其中 $\hat{m} \in \mathbb{R}^{B \times 3 \times H \times W}$ (含批次、通道数、空间维度) 表示重建后得到的图像的基本形态， $m \in \mathbb{R}^{B \times 3 \times H \times W}$ 表示输入图像的基本形态。该损失鼓励模型在保留图像整体结构的同时，抑制潜在的噪声干扰，从而促进主干网络学习更具判别性的特征表示。本文的最终损失函数表达式为：

$$L_{\text{total}} = L_{\text{main}} + \alpha \cdot L_{\text{aux}} + \beta \cdot L_{\text{denoi}}$$

损失函数中的权重参数设定采用控制变量法, 通过验证集上的消融实验确定。具体地, 固定其他参数, 对 α 在 $\{0.1, 0.3, 0.5, 0.7, 1\}$ 范围内搜索, 以验证集为指标, 最终选定 $\alpha = 0.5$; 类似地, β 在 $\{0.01, 0.05, 0.1, 0.2\}$ 中测试, 取 $\beta = 0.1$; 聚焦参数 $\gamma = 2$ 为常用设置, 验证表明其稳定。上述参数在后续所有实验中固定不变。

2.2. 实验与结果分析

2.2.1. 数据集和评价指标

本文使用 ISIC 2017 皮肤病数据集, 该数据集包含了大量的弱边界图像且是公开的数据集。

交并比(IOU): 交并比是度量预测结果与真实标签之间的重叠程度的指标。它是本文的核心指标, 若预测结果与真实标签十分接近, 则 IOU 指标会接近于 1。令 A 为预测前景的面积, B 为标签的面积, 则交并比计算公式如下:

$$\text{IOU} = \frac{A \cap B}{A \cup B},$$

准确率(Precision): 准确率可以很好地评价模型的整体性能, 它代表着正确分类的像素与图像像素总数的比值。TP: 被正确识别的正例; TN: 被正确识别的负例; FP: 被错误识别的正例; FN: 被错误识别的负例。

$$\text{Precision} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}},$$

召回率(Recall): 召回率代表正样本有多少被准确地识别出来, 它对于衡量模型在正样本数据时的表现上至关重要。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

相似系数(Dice Similarity Coefficient, DSC)用于量化预测分割掩码与真实标注之间的空间重叠程度。二值分割任务中定义为:

$$\text{DSC} = 2 \cdot \frac{|X \cap Y|}{|X| + |Y|} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN} + \xi}$$

其中 $||$ 表示像素的数量, ξ 为平滑因子以避免除零。

2.2.2. 前处理实验效果图

U-Net 作为医学图像任务中常用的网络框架, 性能十分优越。因此我们有必要选取其为衡量对象进行对比试验, 这样才能显示出我们新设计模块的优势。为了清晰的表达出相应的结论, 会给出对应的定量和定性的分析。图 4 展示了三幅实验对比图(图像 a, b, c; 对应分别为原图、标签、U-Net、新架构), 表 1 给出了两种架构在指标 IOU 上的对比指标。

从图 4 中看到, a 图的 U-Net 初始输出图中出现的大部分的不明确像素点围绕在分割图像的周围, 而新架构则将不明确的像素点进行了部分明确判定。b 图的两幅二值分割图像也呈现出类似的情况, 这体现了新架构在提取图像的细节方面优于使用单 U-Net 的网络架构。但从 c 图可以看到, 无论是新架构还是 U-Net 效果均很差。新架构虽然比 U-Net 好很多, 但是与真实图像相比仍相差很多, 这与模型的训练数据质量相关。因此, 在不显著增加数据量的情况下, 就需要更加精细化的后处理操作来处理该问题。从表 1 也可以看到两个框架之间的区别。(此处为了简化只取了一个指标)。




Figure 4. Comparison diagram between the new architecture and U-Net
图 4. 新架构与 U-Net 之间的对比图

Table 1. Comparison of segmentation metrics between the new architecture and U-Net

表 1. 新架构与 U-Net 之间的分割指标对比

Methods	Image1	Image2	Image3
U-Net	0.346	0.601	0.647
新架构	0.627	0.627	0.710

3. 基于均值和方差变化的高斯分拟合水平集方法

为了更好地阐述本文模型使用的理论基础,需要将图像区域进行划分。 $\Omega_1, \Omega_2, \Omega_3$ 代表像素 X 的邻域被分割后形成的子区域。区域总数取 N 时满足如下关系:

$$\Omega = \bigcup_{i=1}^N \Omega_i, \quad \Omega_i \cap \Omega_j = \emptyset, \quad i \neq j,$$

为了不失一般性的讨论,取 $N=3$ 。像素 X 的圆形邻域定义 $O_x = \{y: |y-x| \leq r\}$, r 负责控制领域的大小。

对于弱边界图像分割问题,实质就是将像素 X 圆形邻域内的每个像素点 y 最优地分配到不同的区域。在已知圆形领域内的每个像素 y 的灰度 $I(y)$ 的前提下,求解 $p(y \in \Omega_i \cap O_x | I(y))$ 的最大值,根据贝叶斯定理可推得

$$p(y \in \Omega_i \cap O_x | I(y)) = \frac{p(I(x) | y \in \Omega_i \cap O_x) p(y \in \Omega_i \cap O_x)}{p(I(y))}, \quad (3.1)$$

其中分母是前文中假设的已知数,所以在讨论(3.1)的最大值问题时可以忽略。而 $p(y \in \Omega_i \cap O_x) = \frac{1}{N}$, 故

只需求解 $p(I(y)|y \in \Omega_i \cap O_x)$ 的最大值即可。令 $p_{i,x}(I(y)) = p(I(y)|y \in \Omega_i \cap O_x)$ ，若每个区域内的像素是相互独立的，则 $p_{i,x}(I(y))$ 的联合概率为公式(3.2):

$$\prod_{y \in \Omega_i \cap O_x} p_{i,x}(I(y)) \tag{3.2}$$

为了实现总体能量的最小化，我们对(3.2)取负对数并求最小，得到等价式

$$\min \prod_{y \in \Omega_i \cap O_x} -p_{i,x}(I(y)) = \min \sum_{y \in \Omega_i \cap O_x} -\log p_{i,x}(I(y)).$$

根据变分法，将这个离散的求和转换为一个积分的形式，可得到

$$\min \sum_{y \in \Omega_i \cap O_x} -\log p_{i,x}(I(y)) = \int_{\Omega_i \cap O_x} -\log p_{i,x}(I(y)) dy,$$

将 Ω_i 的范围扩大到整个区域，就可以得到全局能量

$$NGDF_x = \sum_{i=1}^N \int_{\Omega_i \cap O_x} -\log p_{i,x}(I(y)) dy. \tag{3.3}$$

因此原问题将转变为处理(3.3)中的 $p_{i,x}(I(y))$ 上来。表达式

$$p_{i,x}(I(y)) = p(I(y)|y \in \Omega_i \cap O_x)$$

实际代表着区域的概率分布。在本文中，概率分布服从均值和方差变动的高斯分布。高斯分布表达式如下定义:

$$p_{i,x}(I(y)) = \frac{1}{\sqrt{2\pi}\sigma_i(x)} \exp\left(-\frac{(u_i(x) - I(y))^2}{2\sigma_i^2(x)}\right),$$

其中 $u_i(x), \sigma_i(x)$ 为均值和标准差。将权重函数整合进(3.3)可推得

$$NGDF_x = \sum_{i=1}^N \int_{\Omega_i \cap O_x} -\omega(x-y) \log p_{i,x}(I(y)) dy.$$

其中 $\omega(k)$ 的函数表达式为:

$$\omega(k) = \begin{cases} \frac{1}{\alpha} \exp\left(-\frac{|k|^2}{2s^2}\right) & |k| \leq r \\ 0 & |k| > r \end{cases} \tag{3.4}$$

由于(3.4)的截断效应。公式(3.3)可进一步转化为

$$NGDF_x = \sum_{i=1}^N \int_{\Omega_i} -\omega(x-y) \log p_{i,x}(I(y)) dy. \tag{3.5}$$

我们将公式(3.5)在 Ω 上再进行一次积分，得到全局能量泛函

$$NGDF = \int_{\Omega} \left(\sum_{i=1}^N \int_{\Omega_i} -\omega(x-y) \log p_{i,x}(I(y)) dy \right) dx.$$

因此，我们使用与文献[10]相一致的表达方式，前景 $\Omega_1 = \{(x, y) | \phi(x) > 0\}$ ，背景 $\Omega_2 = \{(x, y) | \phi(x) < 0\}$ ，通过使用 Heaviside 函数和水平集方法，公式(3.5)可转化为

$$\begin{aligned} & \text{NGDF}_x(\phi, u_1(x), u_2(x), \sigma_1^2(x), \sigma_2^2(x)) \\ &= -\int \omega(x-y) \log p_{1,x}(I(y)) M_1(\phi(y)) dy - \int \omega(x-y) \log p_{2,x}(I(y)) M_2(\phi(y)) dy \end{aligned} \quad (3.6)$$

其中, $M_1(\phi(y)) = H(\phi(y)), M_2(\phi(y)) = 1 - H(\phi(y))$ 。进而公式(3.6)可进一步转化为

$$\text{NGDF}(\phi, u_1(x), u_2(x), \sigma_1^2(x), \sigma_2^2(x)) = \int_{\Omega} \text{NGDF}_x dx, \quad (3.7)$$

为了简化, 我们令 $E_{\text{NGDF}} = \text{NGDF}(\phi, u_1(x), u_2(x), \sigma_1^2(x), \sigma_2^2(x))$ 。

本文使用 Heaviside 函数的近似表达式, 函数的具体形式如下:

$$H_{\varepsilon}(x) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan \left(\frac{x}{\varepsilon} \right) \right); \quad \delta_{\varepsilon}(x) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + x^2}.$$

为了使得我们的模型能够产生更加平滑的曲线, 本文参考使用了光滑项, 具体表达式为

$$L_{\varepsilon}(\phi) = \int |\nabla H_{\varepsilon}(\phi(x))| dx.$$

为了进一步增强水平集函数的数值稳定性并抑制噪声干扰, 本文还引入了全变差(Total Variation, TV)正则项, 用来控制全局平滑性。该项的表达式为

$$M(\phi) = \int |\phi(x)| dx.$$

为了解决演化过程中重新初始化问题, 需要添加一个正则项用于惩罚水平集与标准的符号距离函数之间的偏差。

$$P(\phi) = \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx.$$

综上所述, 本文的能量泛函的最终形式如下:

$$E_{\varepsilon}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = \alpha E_{\text{NGDF}} + \beta L_{\varepsilon}(\phi) + \gamma P(\phi) + \eta M(\phi),$$

第二项和第三项的 Gâteaux 导数在很多文献中已经给出, 所以重点在于解决第一项的 Gâteaux 导数, 使用对数的基本性质可得

$$\begin{aligned} E_{\text{NGDF}} &= \int \left[\int \omega(x-y) \left(\log(\sqrt{2\pi}) + \log \sigma_1(x) + \frac{(u_1(x) - I(y))^2}{2\sigma_1^2(x)} \right) \cdot H_{\varepsilon}(\phi(y)) dx \right] dy \\ &+ \int \left[\int \omega(x-y) \left(\log(\sqrt{2\pi}) + \log \sigma_2(x) + \frac{(u_2(x) - I(y))^2}{2\sigma_2^2(x)} \right) \cdot (1 - H_{\varepsilon}(\phi(y))) dx \right] dy. \end{aligned}$$

采用交替优化策略求解 $u_i(x), \sigma_i(x)$ 。 $u_i(x), \sigma_i(x)$ 所满足的 Euler-Lagrange Equation(E-L)方程如下所示:

$$\begin{aligned} & \int \omega(x-y) (u_i(x) - I(y)) M_{i,\varepsilon}(f(y)) dy = 0, \\ & \int \omega(x-y) \left(\sigma_i^2(x) - (u_i(x) - I(y))^2 \right) M_{i,\varepsilon}(f(y)) dy = 0, \end{aligned}$$

由此可以得到 $u_i(x), \sigma_i(x)$ 的计算表达式:

$$\begin{aligned} u_i(x) &= \frac{\int \omega(x-y) I(y) M_{i,\varepsilon}(f(y)) dy}{\int \omega(x-y) M_{i,\varepsilon}(f(y)) dy}, \\ \sigma_i^2(x) &= \frac{\int \omega(x-y) (u_i(x) - I(y))^2 M_{i,\varepsilon}(f(y)) dy}{\int \omega(x-y) M_{i,\varepsilon}(f(y)) dy}. \end{aligned}$$

其中 $M_{1,\varepsilon}(f(y))=H_\varepsilon(f(y))$, $M_{2,\varepsilon}(f(y))=1-H_\varepsilon(f(y))$ 。添加辅助变量并取梯度的负方向进行演化, 水平集演化的方程为

$$\frac{\partial \phi}{\partial t} = -\alpha \delta_\varepsilon(e_1 - e_2) + \beta \delta_\varepsilon(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \gamma \left(\Delta \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right) + \eta \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right).$$

其中 e_1, e_2 的定义如下:

$$e_1(x) = \int_{\Omega} \omega(y-x) \left[\log(\sigma_1(y)) + \frac{(u_1(y) - I(x))^2}{2\sigma_1^2(y)} \right] dy,$$

$$e_2(x) = \int_{\Omega} \omega(y-x) \left[\log(\sigma_2(y)) + \frac{(u_2(y) - I(x))^2}{2\sigma_2^2(y)} \right] dy.$$

为了更加清晰的表达出本文前后框架之间的逻辑关系和基本的计算过程, 我们给出了**算法 1**。

算法 1. 整体时间演化方法算法流程

输入: 图像 I 与真实标签 I_{Mask} ; 新架构模型 M ; 符号距离函数 SDF ; 参数 $\alpha, \beta, \gamma, \lambda_1, \lambda_2, r, N_{\text{max}}$;
输出: I 的二值分割掩码 I_{mask} ;

$I_c = M(I), \phi_0 = SDF(I_c)$;

if $k \leq N_{\text{max}}$:

1: 更新 $u_i(x)$; $\sigma_i^2(x)$;

2: 更新水平集函数 $\phi^{k+1} = \phi^k + \Delta t \cdot \frac{\partial \phi}{\partial t}$;

3: 计算 $\{(x, y) | \phi^{k+1} > 0\}$ 与 I_{Mask} 之间的 IOU^{k+1} ;

4: 若 $\text{IOU}^{k+1} > \text{IOU}^k$ 则 $\text{IOU}_{\text{best}} = \text{IOU}^{k+1}$, 否则 $\text{IOU}_{\text{best}} = \text{IOU}^k$;

5: 若连续 50 次迭代 IOU_{best} 无变化, 则终止迭代; 否则, 令 $k = k + 1$ 并返回 1 继续迭代。

$I_{\text{mask}} = \{\phi < 0\}$ 。

End if

3.1. 对比试验

为了使我们的模型能够更加便捷地处理不同情况的图像, 需要对边缘信息清晰和模糊两大类图像进行专门的参数设置, 这样才能可以根据前景和背景的权重, 得到最终结果。当测试图像边缘信息清晰明确时, 实验的相关参数组合 1 取

$$\alpha = 30, \beta = 0.05, \gamma = 0.1, \lambda_1 = 5, \lambda_2 = 1, r = 5.$$

当测试图像的边缘信息模糊不明确时, 对应参数组合 2 取

$$\alpha = 1, \beta = 0.05, \gamma = 0.1, \lambda_1 = 1, \lambda_2 = 10, r = 3.$$

上述参数组合通过网格搜索在少量验证图像(各 10 张, 分别代表清晰边界与模糊边界)上优化得到。搜索范围: $\Delta t \in [0.01, 0.2]$, $\lambda_1, \lambda_2 \in [0.5, 2.0]$, $\lambda_3 \in [0.1, 0.5]$, $u, v \in [0.01, 0.1]$, $\varepsilon \in [1, 2]$ 。以最终分割 IOU 为目标, 优先保持演化稳定。网格搜索表明, 清晰边界时模型对初始轮廓依赖较小, 增大 λ_1, λ_2 并采用较大时间步长可加速收敛; 模糊边界时需减小步长并适当降低数据项权重, 增加正则强度以防止轮廓泄漏。两组参数在测试集中均表现稳定。

为了测试我们算法的鲁棒性，我们进行了两组实验，第一组是针对于图像边缘信息清晰的场景，第二组则是弱边缘场景。图像的边缘信息清晰时，使用参数组合 1 来进行实验，定性分析见图 5(a)~(d)，量化指标见表 2。a 图的前处理输出形状与真实标签之间相差甚远，而我后处理操作虽然没有与真实标签完全重合，但是在分割的形状上与真实标签一致，且整体趋势均向左。b 图后处理操作明显将前处理做了进一步的细化，且细化的结果更加符合真实标签。c 图可以更加直观地看到，图像的大部分指标在显著提高。从表 3 来看，后处理把前处理中的干扰像素点做了进一步的筛查。

图像的前景与背景比较模糊时，我们使用实验参数组合 2 来进行数值实验。定性分析见图 6(a)~(d)。b 图和 d 图的后处理操作将图像左下方的边缘做了细化分割。从 d 图中可以看到更加明显的区别，前处理提供的初始轮廓很差，但我们的后处理能够在一定程度上修复中间的断裂部分。在 c 图中看到，后处理在一定程度上修复了左侧出现的虚假边缘以及右侧部分像素点的位置确认。从表 3 也可以看到各个图像在三个指标上变化，综合三个指标的数值变化来看，后处理模块细化了前处理的分割结果，使得最终的分割结果更加可靠。

Table 2. The segmentation effect index of the time evolution method at clear boundaries

表 2. 时间演化方法在清晰边界处的分割效果指标

Image	新架构			全局时间演化		
	IOU	Precision	Recall	IOU	Precision	Recall
a	0.813	0.862	0.935	0.822	0.886	0.919
b	0.587	0.588	0.997	0.730	0.847	0.841
c	0.693	0.693	1.000	0.905	0.944	0.957
d	0.686	0.686	0.999	0.826	0.873	0.939

Table 3. The segmentation effect index of the time evolution method at the fuzzy boundary

表 3. 时间演化方法在模糊边界处的分割效果指标

Image	新架构			全局时间演化		
	IOU	Precision	Recall	IOU	Precision	Recall
a	0.754	0.985	0.763	0.790	0.923	0.846
b	0.627	1.000	0.627	0.861	0.946	0.906
c	0.711	0.976	0.723	0.825	0.920	0.889
d	0.335	1.000	0.335	0.604	0.852	0.675

3.2. 计算效率与性能权衡分析

为了全面评估本文两阶段框架的实用性，本节报告第一阶段(级联 U-Net)与第二阶段(水平集演化)的平均推理时间，并与两种端到端深度学习模型(U-Net)进行对比。所有时间测量均在相同硬件环境下进行：第一阶段网络使用 NVIDIA RTX 3080 GPU，第二阶段水平集使用 Intel i5-1155G7 CPU (单线程)。

U-Net 为纯 GPU 推理，时间仅包含前向传播；本文第一阶段时间包含两次 U-Net 级联及后处理(小波去噪、阈值转换)，已集成到模型；本文两阶段时间 = 第一阶段(GPU) + 第二阶段(CPU)，其中第二阶段时间取对应参数组合下的平均迭代次数计算；平均 IOU 为验证集上所有图像的平均值(清晰/模糊图像分别统计，表中“本文两阶段(清晰)”对应参数组合 1 的结果，“模糊”对应参数组合 2 的结果)。




Figure 5. Segmentation diagram of time evolution method at clear boundaries
图 5. 时间演化方法在清晰边界处的分割图




Figure 6. Segmentation diagram of time evolution method at fuzzy boundaries
图 6. 时间演化方法在模糊边界处的分割图

Table 4. Comparison of average inference time (seconds per image) and segmentation performance (IOU) for each method
表 4. 各方法平均推理时间(秒/张)与分割性能(IOU)对比

方法	阶段一	阶段二	总时间	平均 IOU
U-Net	1.2464	-	1.2464	0.7130
本文方法	1.4521	-	-	0.7204
两阶段(清晰)	1.4521	3.4987	4.9508	0.8610
两阶段(模糊)	1.4521	4.4673	5.9194	0.7505

从表 4 可以看出, 本文两阶段方法在分割精度上显着优于单独的深度学习模型, 尤其是在弱边界图像上。然而, 代价是推理速度的下降。与 U-Net 相比, 两阶段方法的单张图像处理时间升高, 主要瓶颈在于第二阶段的水平集演化, 该过程需在 CPU 上迭代数十至上百步。尽管如此, 对于离线医学图像分析等非实时应用, 这一时间开销是可接受的。若需加速, 可以考虑将水平集演化移植到 GPU, 或采用更高效的窄带策略。综合来看, 本文框架在性能优先的场景下具有显着优势, 用户可根据实际需求在速度与精度之间权衡。

4. 结论

本文提出了一个融合深度学习和水平集方法的分割模型, 第一阶段使用训练好的级联 U-Net 预测图像的初始掩码, 随后将掩码转换为初始水平集函数。第二阶段使用基于均值方差变化的高斯分布水平集方法在初始水平集函数的基础上进行轮廓演化。在皮肤病数据集上进行了两组实验, 分别是边缘清晰和边缘模糊的情况, 实验表明该框架为水平集提供了良好的初始轮廓并取得了不错的效果。

参考文献

- [1] 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>
- [2] Malladi, R., Sethian, J.A. and Vemuri, B.C. (1995) Shape Modeling with Front Propagation: A Level Set Approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **17**, 158-175. <https://doi.org/10.1109/34.368173>
- [3] Li, C., Xu, C., Gui, C., et al. (2005) Level Set Evolution without Re-Initialization: A New Variational Formulation. *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2005)*, San Diego, 20-25 June 2005, 430-436.
- [4] Zhang, K., Zhang, L., Song, H. and Zhou, W. (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>
- [5] Samson, C., Blanc-Feraud, L., Aubert, G. and Zerubia, J. (2000) A Variational Model for Image Classification and Restoration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **22**, 460-472. <https://doi.org/10.1109/34.857003>
- [6] Vese, L.A. and Chan, T.F. (2002) A Multiphase Level Set Framework for Image Segmentation Using the Mumford and Shah Model. *International Journal of Computer Vision*, **50**, 271-293. <https://doi.org/10.1023/a:1020874308076>
- [7] Wang, L., Li, C., Sun, Q., Xia, D. and Kao, C. (2008) Brain MR Image Segmentation Using Local and Global Intensity Fitting Active Contours/Surfaces. In: Metaxas, D., Axel, L., Fichtinger, G. and Székely, G., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2008*, Springer, 384-392. https://doi.org/10.1007/978-3-540-85988-8_46
- [8] Li, X., Chen, H., Qi, X., Dou, Q., Fu, C. and Heng, P. (2018) H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation from CT Volumes. *IEEE Transactions on Medical Imaging*, **37**, 2663-2674. <https://doi.org/10.1109/tmi.2018.2845918>
- [9] Wang, L., He, L., Mishra, A. and Li, C. (2009) Active Contours Driven by Local Gaussian Distribution Fitting Energy. *Signal Processing*, **89**, 2435-2447. <https://doi.org/10.1016/j.sigpro.2009.03.014>

- [10] Li, C., Huang, R., Ding, Z., Gatenby, C., Metaxas, D. and Gore, J. (2008) A Variational Level Set Approach to Segmentation and Bias Correction of Images with Intensity Inhomogeneity. In: Metaxas, D., Axel, L., Fichtinger, G. and Székely, G., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2008*, Springer, 1083-1091.
https://doi.org/10.1007/978-3-540-85990-1_130