

DOI:10.20033/j.1003-7241.(2026)04-0097-05

# 基于多尺度特征融合的医学图像信息分割研究

韩明林

(临沭县卫生健康局,山东临沂 276700)

**摘要:**医学图像分割是辅助医生进行疾病诊断与治疗规划的关键技术。目前,基于单一尺度特征的医学图像分割方法难以充分利用图像中不同层次的特征信息,导致分割精度受限,Dice 相似系数(Dice similarity coefficient, DSC)偏低。为此,提出一种基于多尺度特征融合的医学图像信息分割方法。首先,采用 Laplacian 金字塔对医学图像进行多尺度分解与重构,增强图像细节信息;其次,应用统计聚类算法对增强后的图像进行初始分割,完成像素级的初步区域划分。在此基础上,构建一种融合改进 InceptionNext 结构与密集连接的多尺度特征融合模型,有效提取并融合图像的浅层细节特征与深层语义特征。为进一步提升边界分割精度,引入边缘引导注意力机制,通过深层特征引导浅层特征,突出图像中的结构边界信息,从而实现医学图像的精细分割。为验证所提方法的有效性,选取包含高、低级别胶质瘤的脑肿瘤 MRI 图像数据集进行实验,并与现有典型分割方法进行对比。实验结果表明,本文方法在增强肿瘤(enhancing tumor, ET)、整个肿瘤(whole tumor, WT)及肿瘤核心(tumor core, TC)等多个区域的分割任务中,Dice 相似系数均保持在 0.72 以上,显著优于对比方法,能够满足临床医学图像处理对分割精度的要求,具备良好的鲁棒性与实用性。

**关键词:**医学图像;多尺度特征融合;图像分割;注意力机制;边缘增强;Laplacian 金字塔

中图分类号: TP391.413

文献标志码: A

文章编号: 1003-7241(2026)04-0097-05

## Research on medical image information segmentation based on multiscale feature fusion

HAN Minglin

(Linshu County Health Bureau, Linyi 276799, Shandong, China)

**Abstract:** Medical image segmentation is a key technology assisting physicians in disease diagnosis and treatment planning. Current medical image segmentation methods based on single-scale features fail to fully utilize information from different hierarchical features, leading to limited segmentation accuracy and a low Dice similarity coefficient (DSC). To address this issue, this study proposes a medical image segmentation method based on multi-scale feature fusion. Firstly, the Laplacian pyramid is used to decompose and reconstruct medical images at multiple scales, enhancing image detail information. Subsequently, a statistical clustering algorithm is applied to perform initial segmentation on the enhanced images, achieving pixel-level preliminary region division. On this basis, a multi-scale feature fusion model incorporating an improved InceptionNext structure and dense connections is constructed to effectively extract and integrate shallow detail features and deep semantic features. To further improve boundary segmentation accuracy, an edge-guided attention mechanism is introduced, which uses deep features to guide shallow features, highlighting structural boundary information in the images, thereby achieving fine segmentation of medical images. To validate the effectiveness of the proposed method, experiments are conducted on a brain tumor MRI dataset containing both high-grade and low-grade gliomas, and comparisons are made with existing typical segmentation methods. Experimental results show that the proposed method maintains a Dice similarity coefficient above 0.72 across multiple segmentation tasks, including enhancing tumor (ET), whole tumor (WT), and tumor core (TC), significantly outperforming the compared methods. It meets the precision requirements for clinical medical image processing and demonstrates good robustness and practicality.

**Keywords:** medical images; multi-scale feature fusion; image segmentation; attention mechanism; edge enhancement; Laplacian pyramid

医学图像信息分割的根本目的,是将图像中的不同区域或结构准确划分出来,以便医生能够更直观地理解病情并制定相应的治疗方案,该技术对于疾病的诊断、治疗规划以及疗效评估具有深远的影响<sup>[1]</sup>。但随着医学成像技术的不断进步,医学图像表现出多样性和复杂性,使得医学图像信息分割成为了一个既具挑战性又充满机遇的研

究领域,研究者们不断探索新的医学图像信息分割方法,期望提高分割的准确性和效率。

文献[2]设计包含全局特征重构模块、局部特征重构模块的图像分割模型,通过提取全局上下文特征和特征上采样,分析不同特征元素之间的相关性,并将其应用到图像分割任务中,生成最终信息分割结果。但是,该方法重

收稿日期:2024-11-12;录用日期:2024-12-16

基金项目:山东省自然科学基金项目(CRKS2023017)

作者简介:韩明林(1979—),男,工程师,研究方向:自动化技术。

引用本文:韩明林. 基于多尺度特征融合的医学图像信息分割研究[J]. 自动化技术与应用, 2026,45(4):97-100,163. (HAN Minglin. Research on medical image information segmentation based on multiscale feature fusion[J]. Techniques of Automation and Applications, 2026,45(4):97-100,163.)

构的低层级特征中包含较多噪声,其对高层级特征的影响难以消除,导致最终图像分割结果豪斯多夫距离较长。文献[3]应用域对抗网络,设计一种无监督图像分割方法。通过对源域和目标域的特征不断进行对抗学习,避免出现域偏移问题,得出高质量的图像信息分割结果。实验结果表明,该方法的效果在很大程度上依赖于所选的源域和目标域数据集,当源域和目标域之间存在较大差异时,其分割结果存在较大误差。文献[4]基于全尺度密集卷积网络,建立包含特征提取模块、高维语义特征信息获取模块、全尺度跳跃连接模块的图像分割网络模型,将目标图像输入其中即可自动得出图像分割结果。但是,由于引入了全尺度密集卷积和混合注意力级联卷积等复杂结构,该图像分割方法运行效率较低。文献[5]针对现有的监督学习方法进行分析,选用合适的骨干网络、网络块和损失函数,构建弱监督图像分割网络,通过迁移学习、交互式分割等操作步骤,生成最终的图像分割结果。但是,该方法对噪声和伪影的敏感性,导致其应用局限性较大。

多尺度特征融合是一种有效的图像处理技术,它能够在不同尺度上提取图像中的特征信息,并将其进行融合以获取更全面、更准确的特征表示。将这一思想应用到医学图像信息分割领域,借助于深度卷积网络实现不同尺度特征的有效融合,基于此对医学图像信息完成精确分割,为医生提供更准确的病情信息和治疗建议。

## 1 医学图像信息分割方法研究

### 1.1 医学图像信息增强方案建立

在医学图像信息分割之前,以凸显图像内细节信息为目标,建立基于 Laplacian 金字塔的图像处理方案,实现原始医学图像的多尺度增强,具体操作模式如图 1 所示。




图 1 基于 Lap-2DHE 模型的图像增强示意图

Fig. 1 Schematic diagram of image enhancement based on the Lap-2DHE model

对于任意一幅医学图像来说,通过重复低通滤波和下采样,获取高斯金字塔每一层对应的子图像,每层图像可以表示为

$$A_i(x, y) = \sum_{m=-2}^2 \sum_{n=-2}^2 \alpha(m, n) A_{i-1}(2x + m, 2y + n) \quad (1)$$

式中,  $i$  表示金字塔层数,  $A$  表示单层图像,  $m \times n$  表示图像分解所需的窗口尺寸,  $\alpha$  表示低通窗口函数,  $(x, y)$  表示图像中心像素坐标。

参考高斯金字塔逆运算过程,设计 Laplacian 金字塔分解模式,针对每层图像进行上采样<sup>[6]</sup>,并与上一层图像

做差,即可得到 Laplacian 金字塔分解后的图像细节层。

$$A'_i(x, y) = 4 \sum_{m=-2}^2 \sum_{n=-2}^2 \alpha(m \times n) A_i\left(\frac{m+x}{2}, \frac{n+y}{2}\right) \quad (2)$$

$$L_i = A_i - A'_i \quad (3)$$

式中,  $A'_i$  表示上采样后金字塔单层图像,  $L$  表示低通滤波后的图像细节层。

按照上述操作模式,获取每层金字塔图像对应的细节图,并通过式(4)完成图像的逐层重构。

$$B_i = L_i + \chi A'_i \quad (4)$$

式中,  $\chi$  表示图像细节增强所需的参数,  $B$  表示重构图像。

将所有重构图像叠加起来,即可输出细节增强后的医学图像,作为后续分割处理的基础。

### 1.2 设计医学图像初始分割算法

从增强处理后医学图像的灰度值入手,应用统计聚类算法对不同灰度的图像像素进行聚类<sup>[7]</sup>,并将同一类的像素点划分为一个独立区域,从而实现对医学图像信息的初始分割。

在统计得到医学图像中所有像素点对应的灰度值后,筛选出每个局部区域的灰度峰值,将该点看作初始聚类中心。观察初始聚类中心与周边像素点之间的灰度值差异<sup>[8]</sup>,按照最小距离准则将像素点合理分配给聚类中心,具体的分配条件为

$$\begin{cases} d(z, C_k^{(l)}) < d(z, C_u^{(l)}), & z \in Q_u \\ d(z, C_k^{(l)}) \geq d(z, C_u^{(l)}), & z \in Q_k \end{cases} \quad (5)$$

式中,  $d$  表示距离,  $z$  表示待分配像素点,  $C$  表示初始聚类中心,  $k, u$  聚类编号,  $Q$  表示聚类。

为了提升聚类质量,面向初始聚类中心完成图像像素聚类处理后,赋予每个聚类中心一个新的向量值,具体计算公式为

$$C_k^{(l+1)} = \frac{1}{\delta_k} \sum_{z \in Q_k} z \quad (6)$$

式中,  $l$  表示迭代序号,  $\delta$  表示目标聚类中包含的像素点个数,  $M$  表示医学图像内待分配像素数量。

面向新的聚类中心,定义公式(7)所示的像素点聚类目标函数。

$$J = \sum_{k=1}^K \sum_{z \in Q_k} \|z - C_k^{(l+1)}\|^2 \quad (7)$$

式中,  $J$  表示聚类目标函数,  $K$  表示聚类中心数量。

以满足式(7)计算值最小为目标,更新医学图像基于灰度值的聚类结果,完成图像信息初始划分。

### 1.3 构建图像多尺度特征融合模型

想要实现对医学图像信息的进一步精细分割,就要充分考虑图像特征<sup>[9]</sup>。因此,以深度卷积神经网络为基础,融合注意力机制,构建包含编码器和解码器两个组成部分的网络模型,实现医学图像多尺度特征的提取和融合。其中,编码器模块的核心是改进 InceptionNext 网络,如图 2 所示,充分结合了大核深度卷积结构和注意力机制<sup>[10]</sup>,可以在医学图像输入后提取全局和局部特征。

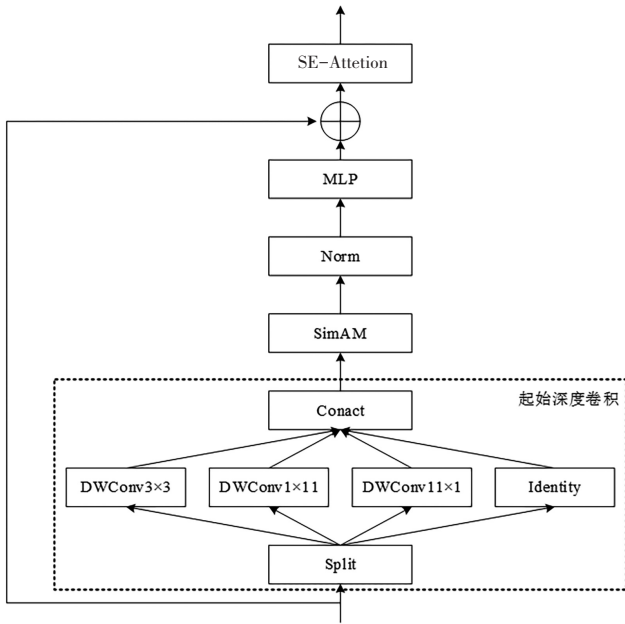


图 2 改进 InceptionNext 结构

Fig. 2 Improved InceptionNext structure

如图 2 所示,医学图像输入改进 InceptionNext 结构后会按照通道维度进行切分,形成四组并行特征,分别输入一个独立的卷积层进行运算,分别并行卷积层特征之间的联系,将多个卷积层输出特征拼接起来,并通过 MLP 层完成激活运算,即可得到

$$\begin{cases} \psi' = G(\psi_{v_1}, \psi_{v_2}, \psi_{v_3}, \psi_{v_4}) \\ \psi'' = \tilde{\omega}(\lambda(\tau(\psi'))) \end{cases} \quad (8)$$

式中,  $\psi'$  表示拼接后的特征,  $G$  表示拼接层运算函数,  $V_1$ 、 $V_2$ 、 $V_3$ 、 $V_4$  分别表示 4 个通道,  $\psi$  表示卷积层输出特征,  $\psi'$  表示激活后的特征,  $\tilde{\omega}$ 、 $\lambda$ 、 $\tau$  分别表示轻量级注意力层、归一化层和全连接层运算函数。

最后,通过残差连接网络层将输入特征和拼接激活处理后的特征融合起来,即可初步得到多尺度特征融合结果。

$$\bar{\psi} = E(\psi_{v_1} + \psi_{v_2} + \psi_{v_3} + \psi_{v_4} + \psi'') \quad (9)$$

式中,  $\bar{\psi}$  表示多度特征初步融合结果,  $E$  小时残差运算。

考虑到编码器运算阶段直接展开特征拼接,面对语义差异较大的特征会出现信息丢失问题<sup>[11]</sup>。因此,在解码器设计阶段,给出了图 3 所示的双尺度特征密集融合网络结构。

如图 3 所示,通过多个阶段的密集连接,使得各个卷积层输出信息之间发生交换或互补,有助于充分理解医学图像中包含的深层特征和浅层特征之间的互补性,改善残差融合结果,得到充分考虑特征关联性的多尺度融合特征,为图像信息精细分割提供依据。

#### 1.4 生成图像信息精细分割结果

在获取医学图像信息精细分割结果时,引入边界信息增强思想,搭建图 4 所示的边界引导注意力模块。将多尺度特征融合结果输入其中,通过深层特征引导浅层特征,准确定位医学图像中的边界信息<sup>[12-13]</sup>,以便输出更加准确的分割结果。

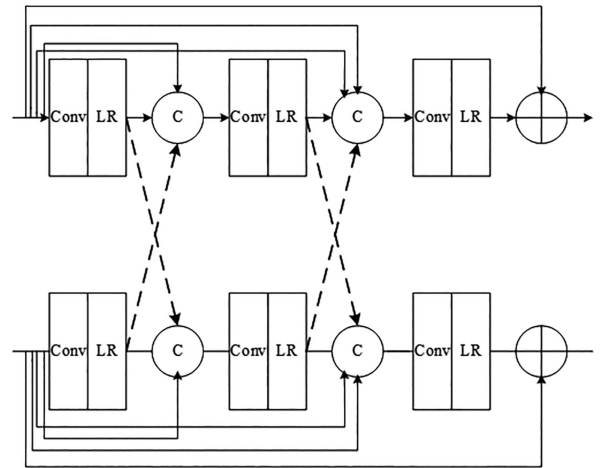


图 3 多尺度特征融合网络结构

Fig. 3 Multi-scale feature fusion network structure

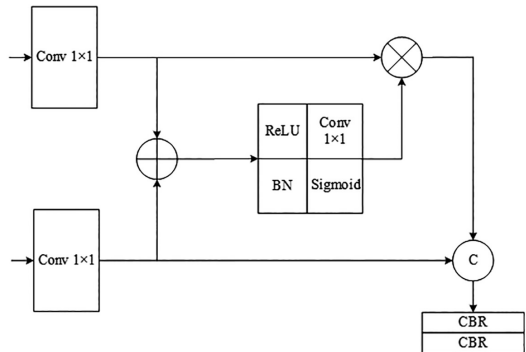


图 4 边界引导注意力模块

Fig. 4 Boundary-guided attention module

从图 4 可以看出,边界引导注意力模块运算过程中需要完成两次 CBR (卷积层-批量归一化层-激活函数层) 操作,才能输出增强后的边界特征<sup>[14-15]</sup>。

$$\gamma = \xi(\xi(\bar{\psi}_1 \parallel \rho \times \bar{\psi}_2)) \quad (10)$$

式中,  $\gamma$  表示增强后的边界特征,  $\xi$  表示 CBR 操作所需的运算函数,  $\bar{\psi}_1$ 、 $\bar{\psi}_2$  分别表示浅层融合特征和深层融合特征,  $\rho$  表示权重系数。

获取图像边界特征后,以此为基础即可实现对医学图像信息的精准分割。

## 2 实验分析

### 2.1 实验数据

为了检验基于多尺度特征融合的医学图像信息分割方法实践应用效果,与某三甲医院进行沟通,获取大量脑肿瘤医学检测图像,组成实验数据集。在实验数据准备阶段,对所有脑肿瘤图像进行预处理,使得其尺寸统一为  $240 \times 240 \times 155$ 。

在神经放射科医生的帮助下,对每个样本图像进行标注和手动分割,使得每张脑肿瘤图像都可以分割出增强肿瘤(ET)、整个肿瘤(WT)、肿瘤核心(TC)和坏疽四个区域,如图 5 所示。完成所有样本图像的手动分割标注后,得到医学图像信息真实标签,与后续实验应用方法分割结

果进行对比,可以更加直观地体现分割结果的准确程度。




图5 医学图像样本标注

Fig. 5 Medical image sample annotation

经过统计可知,实验数据集中共包含 275 张脑肿瘤图像,其中 200 张图像属于高级别胶质瘤,剩余 75 张图像则属于低级别胶质瘤,这些样本混合起来,可以充分检验所提方法在不同环境下的应用效果。

## 2.2 评价指标

除了新提出的医学图像信息分割方法外,本次实验过程中应用文献[3]和文献[4]提出的两种方法,同样对实验数据集中的图像进行分割处理,并选择 Dice 相似系数作为评价指标,衡量不同方法分割精度,该指标计算公式为

$$\eta(S, L) = \frac{2|S \cap L|}{|S| + |L|} \quad (11)$$

式中,  $\eta$  表示 Dice 相似系数,  $S$  表示实际分割预测标签集合,  $L$  表示真实分割标签集合。

## 2.3 医学图像信息分割结果

依托于统计聚类算法实现图像初始分割后,设置多尺度特征融合网络参数如表 1 所示。

表 1 多尺度特征融合网络参数

Tab. 1 Multi-scale feature fusion network parameters

项目	数值
迭代次数	50
批处理大小	4
初始学习率	0.000 1
学习率衰减系数	0.1
优化器	Adam

在上述参数条件下,融合医学图像多尺度特征,并提取图像边界特征,基于此可以得到图像精细分割结果。以任意四张样本图像为例,不同方法给出的可视化分割结果如图 6 所示。

从图 6 显示的医学图像信息分割结果可以看出,以多尺度特征融合算法为核心的新方法应用后,所得分割结果与真实分割标签极为相近。而另外两种方法分割结果与真实标签之间存在显著差异,证明二者在实现医学图像信息分割时,出现了明显的区域混淆问题。相对来看,新提

出的方法是可行的,且应用效果较优。




图6 不同方法医学图像信息分割结果

Fig. 6 Segmentation results of medical image information using different methods

## 2.4 分割方法性能对比

为了加强实验分析结果的直观性,在 3 种方法对数据集内所有医学图像都完成分割后,统计各方法关于增强肿瘤、整个肿瘤、肿瘤核心 3 个区域的 Dice 相似系数,并绘制出图 7 所示的对比图像。




图7 不同方法分割结果 Dice 评分统计箱型图

Fig. 7 Box plot of dice score statistics for segmentation results obtained using different methods

图 7 中箱体上下两个组成区域分别代表 Dice 评分结果的上四分位数、下四分位数,中间的水平线则表示 Dice 评分统计结果的中位数。另外,箱型图中上下两侧的短横线,代表 Dice 评分取值的最大值和最小值界限。根据图 7 可知,新研究方法给出的图像分割结果 Dice 评分集中在较高值,且始终高于 0.72,相比其余两种方法分割结果表现出的 Dice 值明显更大,表明该图像分割方法具有优越的整体分割效果。

## 3 结论

通过研究可知,基于多尺度特征融合的医学图像信息 (下转第 163 页)