

基于3D ERA U-Net的MRI海马体分割

沈菲, 华云松, 陈聪茏

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10日; 录用日期: 2023年8月31日; 发布日期: 2023年9月7日

摘要

海马体萎缩率是痴呆症等神经系统类疾病的早期诊断标志, 因此精确地对海马体进行分割有利于准确测算海马体萎缩率, 从而更高效地辅助医生预诊断病人的健康状态。传统图像分割技术在分割体积小、形状复杂的海马体时效果并不理想, 因此本文提出了一种3D Efficient Residual Attention U-Net模型(3D ERA U-Net)。首先, 利用改进的残差注意力机制将高层特征信息与低层特征信息融合, 丰富二者的信息交流, 使模型高质量地学习海马体细节信息。其次, 在编码器和解码器过渡区加入一个扩张模块, 在解码之前强化模型的感受野, 对MR图像这样的三维图像起到了联系全局信息的作用。最后, 改进了一种复合损失函数, 加强关注边界分割。将该模型在ADNI数据集上进行实验, 相比较其他海马体模型, 整体精度提高, 左右海马体平均Dice系数为89.38%、Precision为88.44%、Recall为89.29%, 优化效果提升明显。

关键词

海马体, 图像分割, 注意力机制, 深度学习, 扩张卷积

MRI Hippocampus Segmentation Based on 3D ERA U-Net

Fei Shen, Yunsong Hua, Conglong Chen

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

Received: Jul. 10th, 2023; accepted: Aug. 31st, 2023; published: Sep. 7th, 2023

Abstract

The rate of hippocampal atrophy is a marker of early diagnosis of neurological diseases such as dementia. Therefore, accurate segmentation of the hippocampus is beneficial to accurately meas-

ure the rate of hippocampal atrophy, so as to more efficiently assist doctors to predict the health status of patients. Traditional image segmentation techniques are not effective in segmenting the small volume and complex shape of the hippocampus, so this paper proposes a 3D Efficient Residual Attention U-Net model (3D ERA U-Net). Firstly, the improved residual attention mechanism was used to integrate the high-level feature information with the low-level feature information to enrich the information exchange between the two, so that the model could learn the details of the hippocampus in high quality. Secondly, a Dilation Module is added to the transition area between encoder and decoder to strengthen the receptive field of the model before decoding, which plays a role in connecting global information for 3D images such as MR Images. Finally, a compound loss function is improved to pay more attention to boundary segmentation. The model was tested on the ADNI data set. Compared with other models, the overall accuracy was improved, with the average Dice coefficient of the left and right hippocampus being 89.38%, the Precision 88.44%, and the Recall 89.29%. The optimization effect was significantly improved.

Keywords

Hippocampus, Image Segmentation, Attention Mechanism, Deep Learning, Dilated Convolution

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

海马体是人脑重要组成部分, 负责记忆相关工作, 以及辅助边缘系统来调节情绪、学习等[1]。右侧海马体参与环境位置记忆处理, 左侧海马体负责上下文记忆及自传性记忆[2]。海马体作为最早受影响区域之一[3], 其损失程度往往是判断痴呆相关神经系统疾病的依据, 如: 自闭症和阿兹海默症(AD)等。AD 临床试验中, 海马体萎缩率[4]是诊断和预后的标志物, 轻度认知障碍(MCI)患者海马体萎缩率约 10%~15%, 早期 AD 患者萎缩率约 15%~30%, 中度 AD 患者萎缩率可达 50% [5]。因此, 通过医学辅助手段准确、高效地诊断出病患海萎缩率, 有助于医生在早期诊断中预防或者减缓由于海马体萎缩引起的健康问题。

从生物组织上说, 海马体包含灰质和白质, 像素信息杂乱。从物理形态上说, 海马体体积小, 边缘形状复杂。传统图像分割算法有图谱法, 形变模型法等。Somasundaram [6]提出了一种基于图谱的方法, 通过识别海马体感兴趣区域后, 进行分割。Ge [7]提出了一个灰质体积协方差算法, 提高了对海马体结构分析的效果。但是由于海马体的复杂性, 这些传统方法分割后的精确度不高。

深度卷积神经网络(CNN)广泛应用于医学图像分割, 2015年, U-Net [8]提出后, 极大地改善了医学图像分割数据集样本量小的难题[9] [10]。Zhu [11]将扩张密集网络嵌入到 U-Net 中, 在保持高分辨率前提下, 生成多尺度特征, 实现收缩路径中低层次特征与扩展路径中高层次特征的融合。Hazarika [12]将 U-Net 网络中的卷积核替换成不同尺寸, 充分融合不同邻域的图像信息。曹平[13]提出结合序列学习和 U-Net 结合的方法, 将双向卷积长短期记忆网络引入相邻切片之间。刘昭[14]尝试在 3D U-Net [15]网络后添加 CBAM 注意力机制, 微曲率边界收敛效果提升, 不过大曲率边界收敛效果仍不理想。Hung [16]通过特征切换注意力模块实现特征选择和反馈。以上方法在一定程度上提高了海马体整体分割效果, 但边界区域部分仍然存在欠分割和过度分割问题。

为提高海马体分割的精准度, 本文提出了 3D ERA U-Net 网络。该网络以 3D Res U-Net [17]为主干。首先, 融合了一个高效残差注意力模块, 强化了各层信息流动性。其次, 添加了一个扩张模块, 提高了

全局信息完整性。最后，设计了一个复合损失函数，额外关注海马体边界训练效果。本文工作优化了对 MR 图像海马体在细节上的分割精度。

2. 3D ERA U-Net 网络

2.1. 3D ERA U-Net 网络结构




Figure 1. Encoder Block residual structure of the second layer

图 1. 第二层 Encoder Block 残差结构

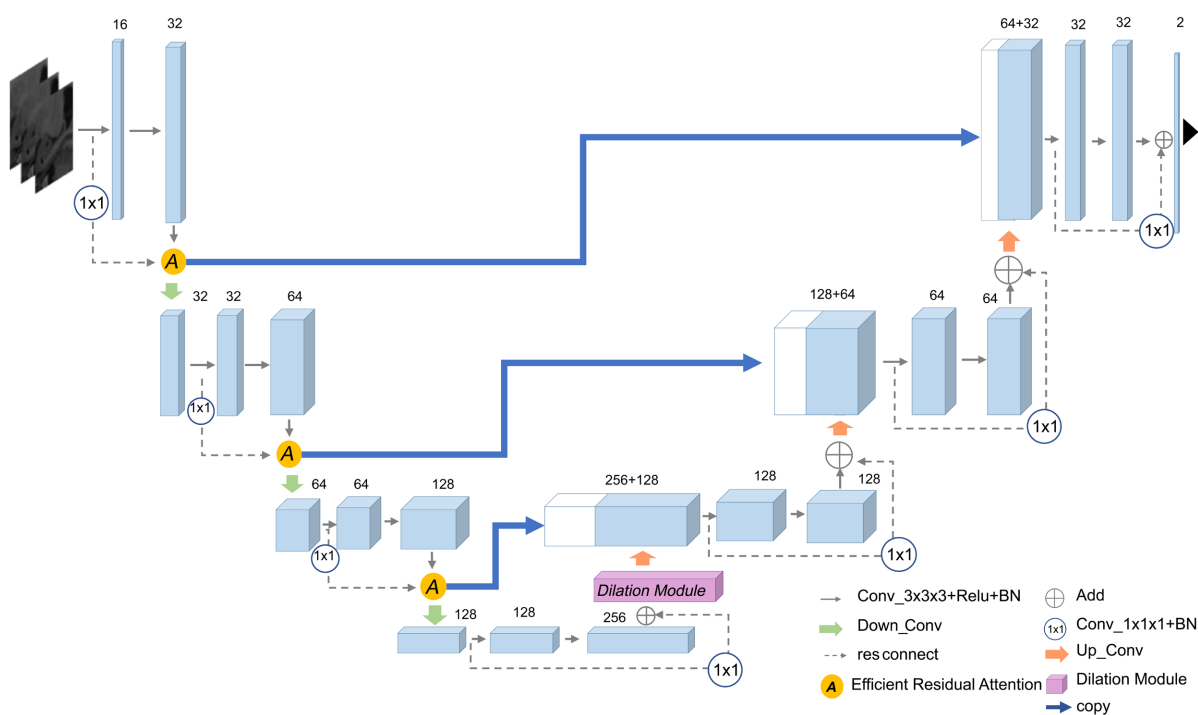


Figure 2. 3D ERA U-Net structure

图 2. 3D ERA U-Net 结构

本文针对海马体分割问题，改进了 3D Res U-Net 主干网络，提出 3D ERA U-Net 网络结构。海马体形态复杂的部分与其邻域形态之间是连贯统一存在的，跳跃连接可以增加网络深度，在高低层特征间建立恒等映射，提高训练准确率。本文在各 Encoder Block 和 Decoder Block 中嵌入残差结构。以前一个 Block

上采样(或下采样)后的输出为当前 Block 残差结构的输入(Input),在当前 Block 上采样(或下采样)前相加,相加后的信息作为该 Block 残差结构的输出(Output),再继续进行上采样(或下采样),上采样(或下采样)后的特征信息再作为下一个 Block 残差结构的输入(Input)。跳跃连接时利用 $1 \times 1 \times 1$ 卷积,调整输入的通道数量和输出通道数量一致,图 1 所示为第二层 Encoder Block 的残差结构(后称 Block 均为嵌入残差结构后)。

在主干网络的基础上,首先,将每个 Encoder Block 残差信息融合的相加节点,替换成融合高层特征信息和低层特征信息的高效残差注意力模块(efficient residual attention, ERA),让低层信息即时矫正注意力机制学习到的重要特征,再将经过注意力机制学习后的特征信息下采样,作为下一个 Block 的输入。同时,将注意力机制学习到的特征信息与对应的 Decoder Block 级联。其次,在最后一个 Encoder Block 输出后,加入了一个扩张模块(dilation module, DM),利用扩张卷积的不同扩张率注入不同感受野的信息,整体网络结构如图 2 所示。

2.2. 高效残差注意力模块

本文在 3D Res U-Net 的 Encoder Block 中间均嵌入了一种高效残差注意力模块(ERA),该模块改进于 ECA [18]。残差结构在高低层特征之间建立起一个实时通道,当网络进行反馈传播时,高层特征可以和低层特征即时地进行信息交流。

ECA 模块是一种精简、高效的注意力机制,其设计了一个自适应卷积核的非线性函数,令每个通道及其 K 领域进行局部跨通道交互信息,相比传统的注意力机制,增加了通道之间的信息交互覆盖率。首先,将 ECA 模块扩展成 3D 模块。然后,由于海马体本身既有白质,又有灰质,而 ECA 原本使用的全局最大池化层在保留多种信息方面的效果略微逊色,因此并行添加一个全局平均池化层,注入海马体的多样特征。接着,让两个特征信息相加,用 1 维卷积降维,令每个通道只包含 $1 \times 1 \times 1$ 的信息。而后,利用 ECA 的自适应卷积核紧密覆盖邻近通道信息,覆盖率 $K = 3$ 。将这个综合通道信息经过 Sigmoid 函数后与当前 Encoder Block 输出相乘,再利用残差跳跃,与当前 Encoder Block 输入相加。最后,将该模块的输出通过卷积核大小为 $2 \times 2 \times 2$,步长为 2 的卷积降采样,代替了原来的池化下采样,高效残差注意力模块结构如图 3 所示。

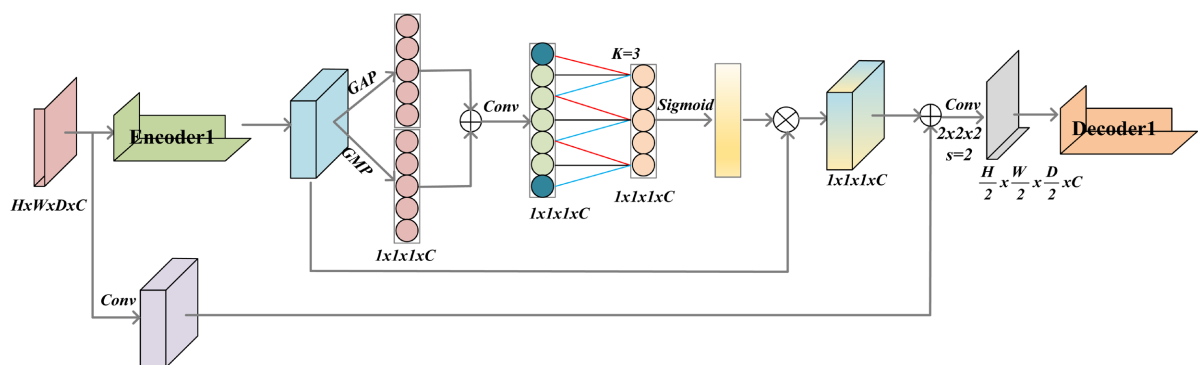


Figure 3. Efficient residual attention module

图 3. 高效残差注意力模块

2.3. 扩张模块

在三维图像的分割任务中,除了学习重点信息以外,还需要整合全局上下文。扩张卷积通过不同的膨胀系数,灵活获得特征信息不同视野。因此本文在编码和解码过渡区添加了一个扩张模块(DM),其

包含两层扩张卷积。根据 Encoder 阶段的计算，最后一个 Encoder Block 输出为 $128 \times 8 \times 8 \times 8$ 。在该特征信息后接上扩张模块，第一个扩张卷积层的扩张率为 1，第二个扩张卷积层的扩张率为 2。两个扩张卷积的感受野分别为 3 和 7，第一个扩张卷积映射了每个海马体小邻域的特征，第二个扩张卷积映射了每个海马体大邻域的特征。最后再将输入在内的三个特征信息加在一起，上采样之后作为第一个 Decoder Block 的输入，扩张模块的结构如图 4 所示。




Figure 4. Dilation module
图 4. 扩张模块

2.4. 损失函数

本文主要将海马体和其余脑组织的分割看作是一个二分类问题。海马体为前景，其余脑组织为背景。为了使训练更加关注边界信息，设计了一个区域损失和边界损失的复合损失函数，公式如下：

$$Loss_{TB} = \alpha Loss_{TS} + \beta Loss_{BD} \quad (1)$$

其中， α 、 β 是两个函数的权重系数，通过训练测试，令 $\alpha = 0.7$ ， $\alpha + \beta = 1$ 。 $Loss_{TS}$ 是 Tversky Loss [19]，它衡量了预测结果 P 和真实结果 G 之间的重叠程度，并对识别错误的海马体、识别错误的背景进行了加权，优化了海马体在整个脑部占比小所带来的类不平衡问题。

$$Loss_{TS} = \frac{P \cap G}{P \cap G + m|P - G| + n|G - P|} \quad (2)$$

但仅仅使用 TverskyLoss 函数，在边界上的分割仍然不理想。Kervadec [20]提出了一种通过形状上的距离度量的边界损失函数 $Loss_{BD}$ ，我们将其用于预测分割边界与海马体标签边界之间的距离，其公式如下：

$$Loss_{BD}(\theta) = \int_{\Omega} \phi_G(q) S_{\theta}(q) dq \quad (3)$$

其中， $\Omega \rightarrow R^3$ 代表训练的 MR 海马体图像， q 是图像上的任意一点。 G 表示专家标注的海马体区域， $S_{\theta}(q)$ 是 q 点分类正确的概率， $\phi_G(q)$ 是距离惩罚项，与边界的距离映射 $D_G(q)$ 有关。

$$\phi_G(q) = \begin{cases} D_G(q), & q \in G \\ -D_G(q), & q \notin G \end{cases} \quad (4)$$

$D_G(q)$ 计算了 $q \in \Omega$ 到边界 ∂G 最近点 $z_{\partial G}(q)$ 的距离。

$$D_G(q) = \|q - z_{\partial G}(q)\| \quad (5)$$

当图像中两个点 m 、 n 预测出来的概率接近时，假设 m 点距离海马体标签较远，那么 m 点会被赋予较大的距离惩罚权重 $\phi_G(m)$ ，这样 m 比 n 对 $Loss_{BD}$ 贡献就更大了。因此，通过对不同体素点赋予不同的距离惩罚权重，对海马体的边界形状进行了约束。

3. 实验设置

3.1. ADNI 数据集

本研究使用的海马体数据集来源于阿尔茨海默病神经成像计划数据库(ADNI)下的 EADC 项目 (<http://www.hippocampal-protocol.net>)。该数据集包括 135 个 T1 加权脑部 MR 图像以及由专家标注的掩码图像。具体临床统计学特征参见表 1。所有 MR 图像尺寸均为 $198 \times 233 \times 183$ ，体素大均为 $1 \times 1 \times 1$ mm，采用 NIFTI 格式保存，本文使用三维医学处理软件 ITK-SNAP 可视化，见图 5 所示。

Table 1. Clinical statistical characteristics

表 1. 临床统计学特征

诊断	性别		年龄		
	女性	男性	60~70	70~80	80~90
CN	22	22	7	23	10
MCI	19	27	15	13	13
AD	24	13	15	17	13




Figure 5. Visualization of dataset

图 5. 数据集可视化

由于海马体在整个大脑中占据的体积很小且相对位置比较固定，实验先将数据粗裁剪，以降低参数量和计算量。首先，利用 MATLAB 中的 SPM12 工具箱对所有 MR 图像进行 AC 校准。接着，通过对 ADNI 数据集中掩码图像的测试发现， $64 \times 64 \times 64$ 这个尺寸的空间盒可以充分容纳每个海马体。因此根据 AC 校准后的新原点所在的位置信息，向三个方向各拓展 64 个体素，图 6 以右海马体为示。




Figure 6. ADNI dataset preprocessing

图 6. ADNI 数据集预处理

3.2. 实验环境和参数

实验环境为 Windows 操作系统，在 Pycharm 平台上，使用 Python3.8 和 Pytorch1.11.0 框架，GPU 为 RTX3060，采用 CUDA11.3 加速计算。学习率为 0.001，使用 Adam 优化器，batchsize 大小设为 2，预设的训练轮数为 100。

3.3. 评价指标

为精确度量海马体的分割效果，本文将 Dice 系数、Precision 和 Recall 作为评价指标。

1) Dice 系数

Dice 系数在分割任务中衡量了两个样本相似程度。其中 P 表示预测值集合， G 表示真实值集合。

$$\text{Dice} = \frac{2|P \cap G|}{|P| + |G|} \quad (6)$$

2) Precision 和 Recall

Precision 反映了海马体预测的可信度，Precision 越高表示预测结果越准；Recall 用以评价算法对海马体预测的查全率，Recall 值越高表示漏测的概率越小。

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

其中， TP 表示正确预测出海马体的体素数， FP 表示将海马体预测为背景的体素数， FN 表示将背景预测为海马体的体素数。

4. 实验结果与分析




Figure 7. Segmentation results of different models

图 7. 不同模型的分割结果

图 7 为各模型分割后的三视图，分别为横断面、矢状面、冠状面。由上往下分别是 3D U-Net、3D Res U-Net、3D ERA U-Net。为了对比各个模型在细节上的分割效果，特意挑选(29, 27, 36)位置的三视图。该

位置所呈现的海马体形态完整，边缘细节清晰，复杂程度相对较高。从图 7 可见，几种分割模型都存在一定的误判。3D U-Net 在海马体边界处几乎没有分割能力，大面积的将海马体周围相似的灰质组织错判了，过分割情况严重，这是因为 3D U-Net 特征提取能力不足。3D Res U-Net 利用跳跃连接加深了网络深度，虽然在海马体微曲率边界处分割效果明显提升，但是对于相似灰度的区域的区分度特征提取能力不够，在曲率较大处仍然出现了明显错判。而 3D ERA U-Net 模型通过高低语义层的特征信息融合以及边缘损失函数的约束，在海马体大曲率边界处和微曲率边界处分割效果都有了明显提升，特别是在海马体狭长处，更少的脑部周围组织被错判。




Figure 8. Loss curves of different models
图 8. 不同模型的损失函数曲线

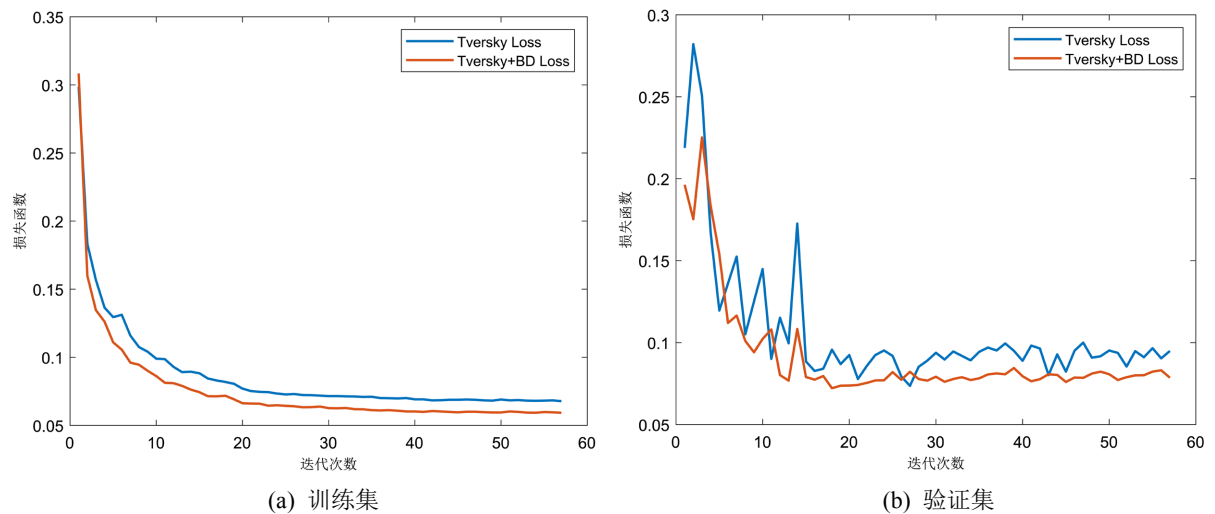


Figure 9. Loss curves of different loss functions
图 9. 不同损失函数的损失曲线

1) 损失函数

为验证模型性能，将 3D ERA U-Net 和 3D U-Net、3D Res U-Net 比较。图 8 给出了以 Tversky Loss 为损失函数的三种模型损失曲线。当模型迭代到 40 左右时，三个模型训练集收敛效果基本稳定。其中，

训练集(图 8(a))中 3D ERA U-Net 损失值在 0.0815 上下浮动,效果明显优于另外两个模型。验证集(图 8(b))前期曲线震荡明显,当模型迭代到 46 左右时,3D ERA U-Net 损失曲线的震荡减弱,逐渐稳定在 0.09 左右。图 9 以 3D ERA U-Net 为标准,对比了单独使用 Tversky Loss 损失函数和本文提出的以边界约束为辅的复合损失函数损失曲线。复合损失函数在多个体素预测正确且概率相近的情况下,权衡了这些体素离最近边界点的距离,将距离作为惩罚项,从而筛选出最接近标签位置同时又预测正确的边界点。经过该算法的优化,模型训练集(图 9(a))损失函数降到了 0.059 左右,验证集(图 9(b))损失函数降到了 0.078 左右。

2) 评价指标对比

对训练好的模型进行定量评估是评价模型的重要标准。表 2 展示了 3D U-Net [16]、3D Res U-Net [17] 以及 HGM-cNet [21]、ViT U-Net [22]的分割海马体的各项指标。3D U-Net 在海马体分割中表现一般。这是因为 3D U-Net 编解码器采用了普通卷积和简单的级联方式,存在特征提取能力不足和特征融合不足问题。3D Res U-Net 在 3D U-Net 的基础上设计了跳跃连接结构,进一步聚合了高级语义信息与低级语义信息,但是没有考虑到类别不平衡会产生很多冗余特征。HGM-cNet 和 ViT U-Net 是近几年新提出的海马体分割模型且均是在 3D UNet 的模型上进行改进。HGM-cNet 融合了海马体灰质概率图,矫正了灰质部分的错判,但是与大脑其他组织灰度相似处的特征提取仍然不足。ViT U-Net 在 nnU-Net 中整合了 transformer 模块,帮助模型保持了记忆,但是训练参数很大且边缘处损失仍相对严重。3D ERA U-Net 的左右海马体平均 Dice 为 89.38%、Precision 为 88.44%、Recall 为 89.29%,指标均高于其他模型,说明本文提出的模型分割精度更高。

Table 2. Segmentation of different models of quantitative evaluation indicators

表 2. 不同模型的分割定量评估指标

		3D U-Net	3D Res U-Net	HGM-cNet	ViT U-Net	3D ERA U-Net (ours)
左海马体	Dice/%	85.63	86.67	86.82	88.25	89.54
	Precision/%	82.68	84.52	86.21	87.28	88.87
	Recall/%	86.22	87.46	87.44	88.57	89.31
右海马体	Dice/%	85.96	86.81	86.93	88.43	89.22
	Precision/%	82.84	85.23	87.21	87.55	88.01
	Recall/%	85.31	87.62	86.64	88.78	89.28

3) 消融实验

为了验证本模型各模块的有效性,对各个模块进行了消融实验,如图 10 所示。将 3D Res U-Net 模型作为 backbone,用热力图体现各模块对特征提取优化的性能。仅使用 3D Res U-Net 时,网络对海马体的边缘分割和窄段分割效果不佳,注意力特征值较小。加入高效残差注意力模块后,网络对海马体的边界部分判别效果有所提升,注意力特征值有所提高,但是存在过分割的情况。加入扩张模块后,边界过分割情况被矫正,但是狭窄区存在欠分割的问题。改进损失函数后,海马的狭窄处和边界处都得到了更加精确的关注,过分割和欠分割情况都被有效的改善,分割效果大大提升,消融实验评价指标表 3。

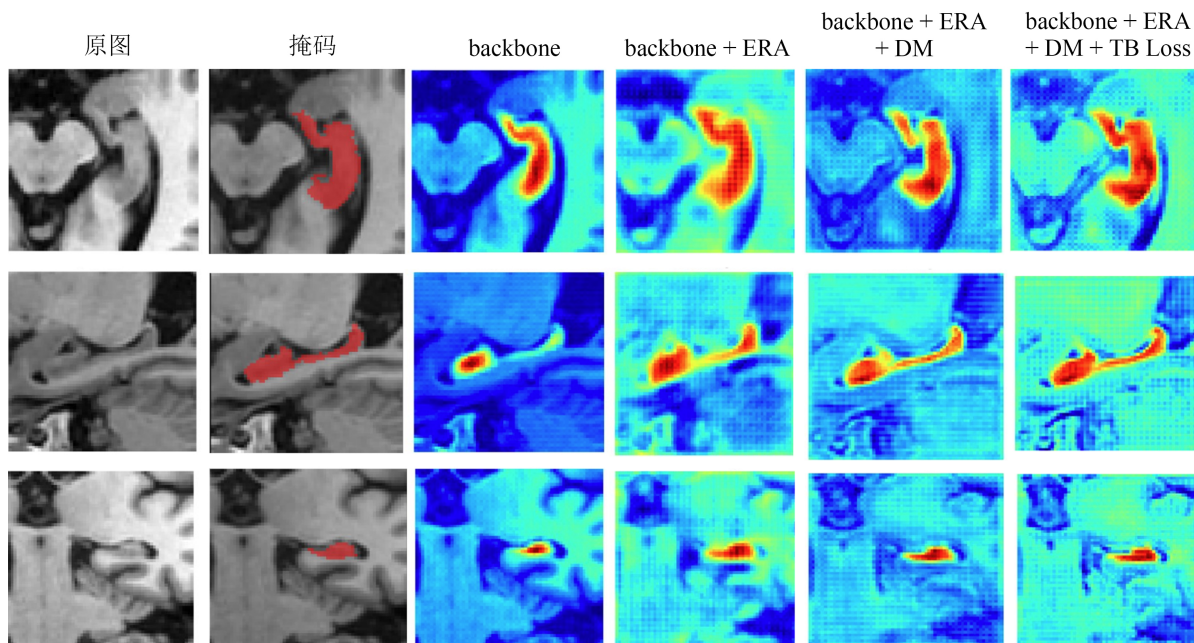


Figure 10. Heat map of Ablation experiment
图 10. 消融实验热力图

Table 3. Ablation experiment based on 3D Res U-Net
表 3. 基于 3D Res U-Net 的消融实验

		3D Res U-Net	3D Res U-Net + ERA	3D Res U-Net + ERA + DM	3D Res U-Net + ERA + DM + TB Loss
左海马体	Dice/%	86.67	88.43	89.12	89.54
	Precision/%	84.52	87.72	88.69	88.87
	Recall/%	87.46	87.95	88.01	88.31
右海马体	Dice/%	86.81	88.73	89.52	89.22
	Precision/%	85.23	87.55	87.81	88.01
	Recall/%	87.62	87.78	87.97	88.28

5. 结论

本文针对 MRI 海马体分割问题，提出了 3D ERA U-Net。该网络以 3D Res U-Net 作为主干。在编码结构中融合了高效残差注意力模块，通过灵活的通道覆盖率，实时帮助特征信息矫正，并行增加全局池化后，提高了模型识别类似海马体组织的能力。在编码 - 解码过渡区添加了扩张模块，通过学习不同感受野下的全局信息，进一步提高了模型对海马体和类似周围组织的分辨力，为解码提供了丰富的信息。两者综合改善了欠分割和过分割情况，缓解了类别不平衡问题。为训练设计的复合损失函数针对边界预测结果做了加权处理，在预测概率正确且相似的情况下，权衡了与最近边界点的距离因素，大大提高了正确边界点的筛选能力。通过在 ADNI 数据集上实验表明，该模型分割左右海马体平均 Dice 系数为 89.38%、Precision 为 88.44%、Recall 为 89.29%，均高于其他海马体分割模型。对网络进行消融实验，将输出特征

以热力图的形式可视化, 可以清晰地观察到, 高效残差注意力模块和扩张模块对海马体大面积区域的识别效果明显提升, 而复合损失函数在添加距离惩罚项后, 精细化了边界部分以及海马体的狭窄区域的判别, 由此证明, 本文提出的模块对于模型的特征提取能力确实起到了优化作用。因此, 该模型具有更精准的分割性能, 尤其是边界分割效果提升明显。

参考文献

- [1] Kuljeet Singh, A. and Vikas, D. (2012) Hippocampus in Health and Disease: An Overview. *Annals of Indian Academy of Neurology*, **15**, 239-246. <https://doi.org/10.4103/0972-2327.104323>
- [2] Miotto, E.C., Brucki, S.M.D., Cerqueira, C.T., et al. (2022) Episodic Memory, Hippocampal Volume, and Function for Classification of Mild Cognitive Impairment Patients Regarding Amyloid Pathology. *Journal of Alzheimer's Disease*, **89**, 181-192. <https://doi.org/10.3233/JAD-220100>
- [3] Mueller, S.G., Schuff, N., Yaffe, K., et al. (2010) Hippocampal Atrophy Patterns in Mild Cognitive Impairment and Alzheimer's Disease. *Human Brain Mapping*, **31**, 1339-1347. <https://doi.org/10.1002/hbm.20934>
- [4] Frisoni, G.B., Fox, N.C., Jack Jr, C.R., Scheltens, P. and Thompson, P.M. (2010) The Clinical Use of Structural MRI in Alzheimer Disease. *Nature Reviews Neurology*, **6**, 67-77. <https://doi.org/10.1038/nrneurol.2009.215>
- [5] Dhikav, V. and Anand, K. (2011) Potential Predictors of Hippocampal Atrophy in Alzheimer's Disease. *Drugs & Aging*, **28**, 1-11. <https://doi.org/10.2165/11586390-000000000-00000>
- [6] Somasundaram, K. and Genish, T. (2015) An Atlas Based Approach to Segment the Hippocampus from MRI of Human Head Scans for the Diagnosis of Alzheimers Disease. *International Journal of Computational Intelligence and Informatics*, **5**, 7-13.
- [7] Ge, R., Kot, P., Liu, X., et al. (2019) Parcellation of the Human Hippocampus Based on Gray Matter Volume Covariance: Replicable Results on Healthy Young Adults. *Human Brain Mapping*, **40**, 3738-3752. <https://doi.org/10.1002/hbm.24628>
- [8] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference*, Munich, 5-9 October 2015, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- [9] 邱拴虎, 杨文瀚, 廖苗, 等. 基于 RA-Unet 的 CT 图像肝脏肿瘤分割[J]. 仪器仪表学报, 2022, 43(8): 65-72. <https://doi.org/10.19650/j.cnki.cjsi.J2108756>
- [10] 秦俊豪, 李志忠, 冯家乐. 基于 Shuffle-Unet 的视网膜血管分割研究[J]. 电子测量技术, 2022, 45(20): 117-124. <https://doi.org/10.19651/j.cnki.emt.2209679>
- [11] Zhu, H., Shi, F., Wang, L., et al. (2019) Dilated Dense U-Net for Infant Hippocampus Subfield Segmentation. *Frontiers in Neuroinformatics*, **13**, Article 30. <https://doi.org/10.3389/fninf.2019.00030>
- [12] Hazarika, R.A., Maji, A.K., Syiem, R., et al. (2022) Hippocampus Segmentation Using U-Net Convolutional Network from Brain Magnetic Resonance Imaging (MRI). *Journal of Digital Imaging*, **35**, 893-909. <https://doi.org/10.1007/s10278-022-00613-y>
- [13] 曹平, 盛邱煊, 潘清, 等. 结合序列学习和 U 型网络的海马体分割方法[J]. 计算机辅助设计与图形学学报, 2019, 31(8): 1382-1390.
- [14] 刘昭. 基于海马体影像组学的 AD 辅诊模型的研究与实现[D]: [硕士学位论文]. 上海: 东华大学, 2021. <https://doi.org/10.27012/d.cnki.gdhuu.2021.000757>
- [15] Çiçek, Ö., Abdulkadir, A., Lienkamp, S.S., Brox, T. and Ronneberger, O. (2016) 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. In: Ourselin, S., Joskowicz, L., Sabuncu, M., Unal, G. and Wells, W., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2016*, Springer, Cham, 424-432. https://doi.org/10.1007/978-3-319-46723-8_49
- [16] Hung, H., Cong, R., Yang, L., et al. (2023) Feedback Chain Network For Hippocampus Segmentation. *ACM Transactions on Multimedia Computing, Communications and Applications*, **19**, 1-18.
- [17] Xiao, X., Shen, L., Luo, Z. and Li, S.Z. (2018) Weighted Res-UNet for High-Quality Retina Vessel Segmentation. *2018 9th International Conference on Information Technology in Medicine and Education (ITME)*, Hangzhou, 19-21 October 2018, 327-331. <https://doi.org/10.1109/ITME.2018.00080>
- [18] Wang, Q.L., Wu, B.G., Zhu, P.F., et al. (2020) ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 11531-11539. <https://doi.org/10.1109/CVPR42600.2020.01155>

- [19] Salehi, S.S.M., Erdogmus, D. and Gholipour, A. (2017) Tversky Loss Function for Image Segmentation Using 3D Fully Convolutional Deep Networks. In: Wang, Q., Shi, Y., Suk, H.I. and Suzuki, K., Eds., *MLMI 2017: Machine Learning in Medical Imaging*, Springer, Cham, 379-387. https://doi.org/10.1007/978-3-319-67389-9_44
- [20] Kervadec, H., Bouchtiba, J., Desrosiers, C., *et al.* (2019) Boundary Loss for Highly Unbalanced Segmentation. *Proceedings of Machine Learning Research*, **102**, 285-296.
- [21] Zheng, Q., Liu, B., Gao, Y., *et al.* (2023) HGM-cNet: Integrating Hippocampal Gray Matter Probability Map into a Cascaded Deep Learning Framework Improves Hippocampus Segmentation. *European Journal of Radiology*, **162**, Article ID: 110771. <https://doi.org/10.1016/j.ejrad.2023.110771>
- [22] Ranem, A., González, C. and Mukhopadhyay, A. (2022) Continual Hippocampus Segmentation with Transformers. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, New Orleans, 19-20 June 2022, 3710-3719. <https://doi.org/10.1109/CVPRW56347.2022.00415>