

融合注意力和 Inception 模块的脑白质病变端到端分割

赵欣^{1*}, 王欣¹, 王洪凯²

¹大连大学信息工程学院, 辽宁 大连 116622;

²大连理工大学生物医学工程学院, 辽宁 大连 116024

摘要 针对目前磁共振脑影像上脑白质高信号区域的自动分割存在分割精度较低和细小病灶易漏识等问题, 提出一种融合注意力和 Inception 的 U-Net 分割模型。在 U-Net 的编码阶段加入 Inception 模块以增加网络宽度, 使其具有多尺度特征的提取能力, 并加入注意力模块以增强网络对分割目标的关注度, 两者的加入和融合可以有效提升网络的特征提取和表达能力。同时, 在解码阶段的每一个卷积层上增加残差连接, 可以提高网络的优化速度。此外, 针对样本不均衡易导致分割结果中假阴性过多的问题, 采用具有均衡调节能力的 Tversky 损失函数优化网络训练。实验结果表明, 所提方法能够较好地分割脑白质的高信号区域, 特别是小病灶区, 且各项分割指标优于多个对比方法。

关键词 图像处理; 深度学习; 脑白质高信号; U-Net; Inception; 注意力机制; 残差

中图分类号 O436

文献标志码 A

doi: 10.3788/AOS202141.0910002

End-to-End Segmentation of Brain White Matter Hyperintensities Combining Attention and Inception Modules

Zhao Xin^{1*}, Wang Xin¹, Wang Hongkai²

¹ School of Information Engineering, Dalian University, Dalian, Liaoning 116622, China;

² School of Biomedical Engineering, Dalian University of Technology, Dalian, Liaoning 116024, China

Abstract Aiming at solving the problems of low segmentation accuracy in the automatic segmentation of brain white matter hyperintensity region on magnetic resonance imaging brain images and easy to miss small lesions, a U-Net segmentation model combining attention and inception is proposed. In the coding stage of U-NET, the Inception module is added to increase the width of the network, so that it has the ability to extract multi-scale features, and the attention module is added to enhance the attention of the network to the segmentation target. The addition and fusion of the two can effectively improve the feature extraction and expression capabilities of the network. Simultaneously, adding residual connections on each convolutional layer in the decoding stage can improve the optimization speed of the network. In addition, because of the problem that sample imbalance easily leads to too many false negatives in the segmentation results, the Tversky loss function with balance adjustment ability is employed to optimize network training. The experimental results show that the proposed method can segment brain white matter hyperintensity region, especially the small lesion area, and each segmentation index is better than those of multiple comparison methods.

Key words image processing; deep learning; brain white matter hyperintensity; U-Net; Inception; attention mechanism; residual connection

OCIS codes 100.3008; 100.4996; 100.6890

收稿日期: 2020-09-30; 修回日期: 2020-12-08; 录用日期: 2020-12-30

基金项目: 国家自然科学基金(61971424)、辽宁省自然科学基金指导计划(2019-ZD-0305)、大连市科技创新基金(2018J12GX042, 2019J13SN100)

* E-mail: zhaoxin@dlu.edu.cn

1 引 言

随着人工智能技术的发展,计算机辅助诊断成为现代医学影像学中的研究热点之一。脑白质病变也称脑白质高信号(White Matter Hyperintensity, WMH),其在核磁共振的 T2 加权成像(T2 图像可以较好地观察组织病变)及 FLAIR (Fluid Attenuated Inversion Recovery)磁共振成像上呈现高信号状态^[1]。医学研究表明,脑白质病变与多种神经性脑部疾病有关,例如脑卒中^[2]、阿尔茨海默病^[3]和多发性硬化症^[4]等,因此脑白质病变的分割对相关脑部疾病的诊断具有重要意义。传统的人工分割方法是由医生在 MRI (Magnetic Resonance Imaging)上通过肉眼识别和手动分割来找到脑白质病变的部位,这种方法不仅耗费大量的时间和精力,同时分割结果也会因医生经验的不同而产生差异,因此研究一种高效且快捷的脑白质病变自动分割方法尤为重要。

早期,学者们多采用传统的机器学习法对脑白质病变的部位进行分割。如 2012 年,余黎煌等^[5]采用了马尔可夫随机场与模糊 C-均值聚类法;2016 年,Morel 等^[6]采用了形态学算子和最大树表示法;2017 年,Bento 等^[7]采用了随机森林法;2017 年,Isa 等^[8]采用了 K-均值聚类算法等。上述算法具有训练时间短和所需样本集小的优点,但需要人工提取特征。由于受到认知因素的限制,将会很难人为地确定脑白质病变的影像特征,因此传统的机器学习法的分割结果不佳。

近年来,随着深度学习在图像处理领域的发展^[9-11],越来越多的学者将深度学习法应用在脑白质病变的分割方面。2016 年,Andermatt 等^[12]将一个多维的门控递归单元网络在 3D 图像块上进行训练,但该网络忽视了图像的空间信息,其更擅长于描述时间上连续状态的输出,而非图像的静态输出。2017 年,Ghafoorian 等^[13]采用了多尺度图像块和 3D 卷积神经网络(Convolutional Neural Network, CNN)模型来分割脑白质病变的区域,其中多尺度图像块有利于获取多尺度的特征信息,同时在模型中添加一组明确的空间信息特征图,可以辅助网络在学习过程中关注病灶位置的特征。2017 年,Xu 等^[14]使用了全卷积神经网络(Fully Convolutional Network, FCN)和迁移学习对脑白质病变的区域进行分割,该网络迁移了 FCN 在自然图像上的学习参数,加快了模型的训练速度。2018 年,Rachmadi

等^[15]将 CNN 与深度玻尔兹曼机、支持向量机和随机森林算法进行比较,证实了深度学习算法在脑白质病变的分割方面优于传统的机器学习算法。2018 年,Li 等^[16]使用了集成三个不同初始化参数训练的 U-Net 模型分割脑白质病变的区域并判别病灶属性,以减少预测偏差。2018 年,Jin 等^[17]提出了两步分割策略,首先基于 U-Net 模型从 T1 图像(T1 图像可以较好地观察解剖结构)中分割出脑白质,再使用残差 U-Net 模型在 T1 图像和 FLAIR 图像上分割出脑白质高信号,该方法将分割出的脑白质区域作为掩模过滤的最终结果,但增加了分割的复杂度,因为不仅需要对病变区域进行分割,还需要对脑白质区域进行分割,而且脑白质区域的分割结果又会影响病变区域的分割。2018 年,Zhang 等^[18]采用了一种后处理的方法解决随机初值对 U-Net 模型的影响,该方法的本质是模型集成方法。2019 年,Li 等^[19]通过集成两种不同尺寸的卷积核的 U-Net 模型来适应不同尺寸的脑白质病灶区域,同时在编码器的第一层使用卷积堆栈替代原始卷积操作以增强网络深度,提高了特征提取能力,但训练负载过大。2019 年,Jeong 等^[20]采用了带有扩张卷积的 U-Net 模型对 FLAIR 和 IAM(Irregularity Map)两路信息进行特征提取,并将提取的两路特征编码融合后再进行上采样处理,该模型虽然缩减了 U-Net 模型的层数和训练时间,但 IAM 的处理增加了处理的复杂度。2019 年,Wu 等^[21]提出在原有 U-Net 模型的基础上增加跨层连接以缓解逐渐消失的梯度,可以改进优化收敛速度。2020 年,Lee 等^[22]提出了一个带有激励和压缩(Squeeze-and-Excitation, SE)块的 U-Net 模型,SE 块利用空间压缩操作和通道激励操作来学习各通道对最终分割结果的贡献,从而达到自适应调整各通道的特征响应值的目的,而且解决了 U-Net 模型无法捕获全局特征的问题。

尽管深度学习方法比传统的机器学习方法取得较好的成果,但在分割的准确度上还有待提升。此外,脑部组织结构复杂,脑白质病变的大小和形状各异,而且病变位置不定,这些因素客观地增加了脑白质病灶的分割难度,特别是对于细小病灶的分割,容易产生漏识,这也是脑白质病变分割的难题之一。为了解决上述问题,本文提出一种基于 U-Net 模型并融合注意力机制和 Inception 模块的脑白质病变分割方法。该方法增强了 U-Net 模型的特征提取能力,提升了对细小病变的识别能力。此外,与整个脑部相比,病变区域非常小。针对这种数据不平衡

的问题,本文采用与以往多数方法不同的损失函数,即 Tversky 损失函数,使用该函数优化模型以提升模型对病灶的敏感性。概括起来,本文的主要工作和贡献:1)利用 Inception 模块拓展 U-Net 模型的宽度,增强特征提取能力;2)利用注意力机制约束 U-Net 模型的注意力,提高网络对细小病变的识别能力;3)使用 Tversky 损失函数优化训练,提升模型对病灶的敏感性。

2 所提算法

基于 3D U-Net 架构提出一种融合 Inception 模块和注意力机制的 3D U-Net 模型。该模型将 Inception 模块替代传统的 U-Net 模型中编码部分的卷积核,原因在于 Inception 模块包含多个不同尺

寸的卷积核,可以获得不同尺度的特征图,将这些多尺度的特征结合起来可得到更丰富的特征信息,从而提高网络的特征提取能力和表达能力。同时,在编码器的每一层以及编码器与解码器中间的瓶颈层增加注意力模块,目的是通过注意力机制使网络更多地关注脑白质病灶的区域,从而提高分割的准确率,特别是对于细小病灶的检测。此外,在解码阶段的每个卷积层之间增加残差连接(残差连接只跳跃一个卷积层),用来提高网络的优化速度。网络结构如图 1 所示。该模型共有 22 层,其中包括 8 个 Inception 卷积模块层、4 个卷积注意力模块层(Convolutional Block Attention Module, CBAM)、6 个残差卷积层、3 个反卷积层(后接跨层拼接)和 1 个像素分类层(最后一层)。

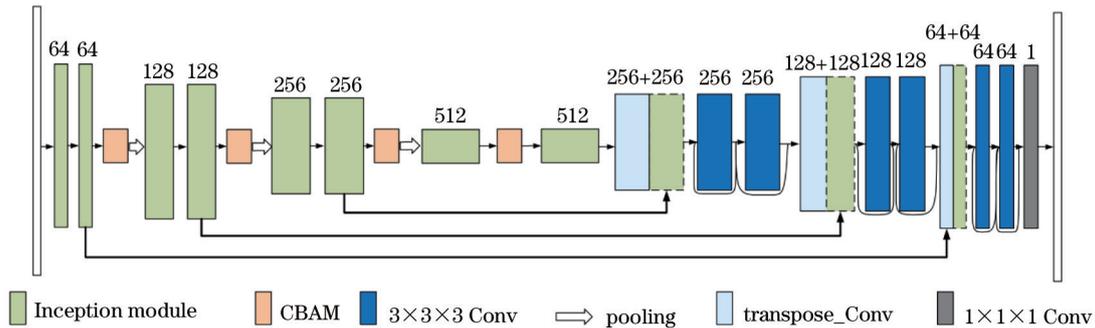


图 1 整体模型的结构

Fig. 1 Structure of overall model

2.1 Inception 模块

网络的宽度和深度是影响卷积神经网络性能的重要指标。自 Szegedy 等^[23]提出 Inception 结构以来,Inception 结构在深度卷积网络的发展中占有至关重要的地位,其既提供了增加网络宽度的方法,又解决了参数过多的问题,同时还减少了计算量。与此可比拟的还有 ResNet^[24],其是在网络局部层与层的输入与输出之间建立一条直接连接的通道,以此解决网络层次过深所容易存在的梯度消失和梯度爆炸的问题,从而使网络在层次深度上得到拓展和突破。Inception-ResNet^[25]结合了上述两种方法的优点,既增加了网络的宽度,又解决了网络深层优化困难的问题。受到文献[25]的启发,采用改进的 Inception-ResNet-A 模块替代传统 U-Net 模型中编码器部分的单一卷积层,改进后的结构如图 2 所示,其中 n 为编码层(包含瓶颈层在内)的层数, $n \in \{1, 2, 3, 4\}$, ReLU 为模块中使用的一种激活函数,这是深度学习领域常见的一个激活函数, \oplus 为加和操作。采用的 Inception 模块含有三条卷积支路,各

支路的卷积感受野分别为 $1 \times 1 \times 1$ 、 $3 \times 3 \times 3$ 和 $5 \times 5 \times 5$,因此该 Inception 模块具有三个不同尺度的特征提取能力和融合能力,可以弥补原始 U-Net 模型单一尺度卷积操作的局限性,从而提高模型对病变部位的分割能力。从图 2 可以看到,改进的模块与原始 Inception-ResNet-A 模块的不同之处:1)改进的模块采用的是 3D U-Net 架构,因此改进的模块的卷积核是三维结构;2)改进的模块的卷积核个数随着编码层次的递增而加倍,目的是使其与原始 U-Net 模型中编码阶段的卷积核个数保持一致;3)原始 Inception-ResNet-A 模块在每条支路中分别添加了 1×1 卷积以减少通道数,改进的模块不需要减少通道数,因此去掉了支路上的 $1 \times 1 \times 1$ 卷积;4)改进的模块使用叠加替换原始 Inception-ResNet-A 模块中的串联,原因在于串联增加的是特征信息维度,而叠加未增加信息维度,但增加了每一维的信息量,这对有小病变的大脑图像信息融合是有益的,本文实验也证实了这一点。

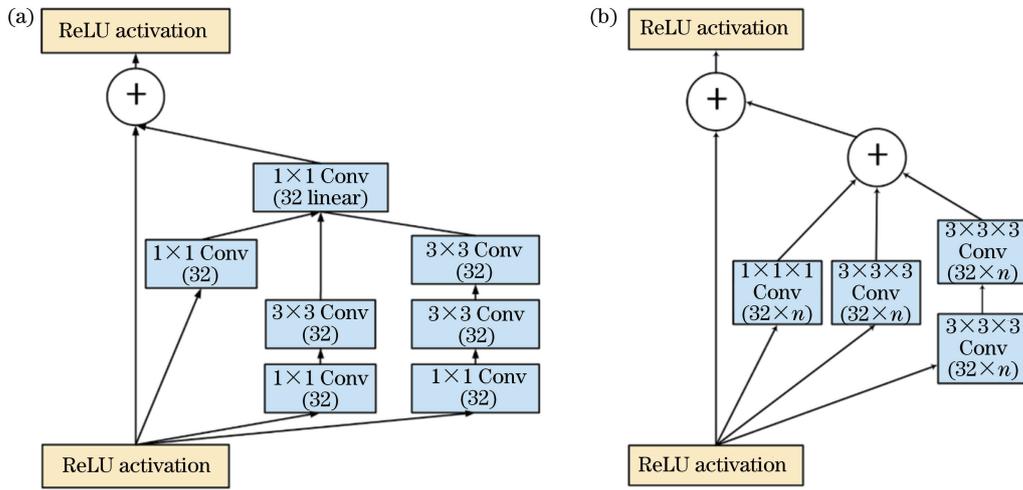


图 2 Inception 模块。(a)原始 Inception-ResNet-A 模块;(b)改进的模块

Fig. 2 Inception module. (a) Original Inception-ResNet-A module; (b) improved module

2.2 注意力机制

虽然在编码器部分使用 Inception 模块可以有效提取更多尺度的脑白质病变特征,但实验结果表明,引入 Inception 模块后仍有部分细小病灶被漏识,同时分割出的病变区域轮廓不精确。为了进一步提高分割精度,在模型中引入 CBAM^[26],其是一种用于前馈卷积神经网络的简单而有效的增强注意力模块。给定一个中间特征图,CBAM 会沿着通道和空间两个独立的维度依次推断注意力图,然后将注意力图与输入特征图相乘以自适应优化特征图,优化过程如图 3 所示,其中 M_c 为通道注意力图,

$M_s \in \mathbf{R}^{C \times 1 \times 1 \times 1}$, C 为通道数, M_s 为空间注意力图, $M_s \in \mathbf{R}^{C \times 1 \times 1 \times 1}$, MLP 为多层感知机, F 为卷积过程中所产生的特征图, F' 为 M_c 与 F 逐体素相乘后得到的特征图, F'' 为 M_s 与 F' 逐体素相乘后得到的特征图。由于 CBAM 是一个轻量级的通用模块,因此可以忽略开销,从而可以将其无缝集成到任何 CNN 的架构中,并与基础的 CNN 一起进行端到端训练。编码阶段,在两个连续的 Inception 模块之后以及瓶颈层的 Inception 模块中间加入一个 CBAM(图 1),目的是将特征提取的注意力集中到病变部位。

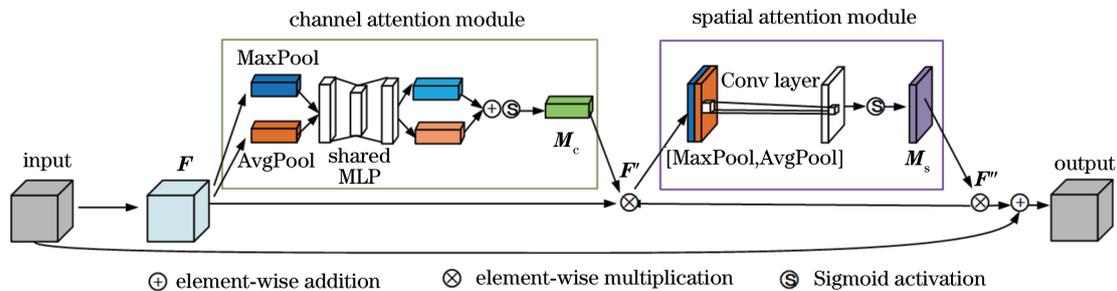


图 3 基于 CBAM 的模型的优化过程

Fig. 3 Optimization process of model based on CBAM

从图 3 可以看到, F 通过一个通道注意力模块后生成通道注意力图,与 F 逐体素相乘后得到 F' , F' 通过一个空间注意力模块后生成空间注意力图 M_s , M_s 与 F' 逐体素相乘后得到 F'' 。通道注意力模块主要关注输入特征图中哪些特征是有意义的,而空间注意力模块主要关注位置信息,即特征图上的哪些位置是有意义的。

通道注意力模块首先将特征图在空间维度上进行压缩,得到一个一维矢量后再进行操作。压

缩过程中不仅使用平均值池化操作,还使用了最大值池化操作,该过程可以聚合特征映射的空间信息。然后将压缩后的两种特征图分别输入到含有隐藏层的多层感知机网络中,输出的特征进行体素级加和操作后经过 Sigmoid 激活操作最终生成 M_c 。将该通道注意力图和输入特征图进行体素级乘法操作生成 F' ,作为空间注意力模块的输入。

通道注意力图的具体计算公式为

$$\mathbf{M}_c(\mathbf{F}) = \sigma \{x_{\text{MLP}}[x_{\text{AvgPool}}(\mathbf{F})] + x_{\text{MLP}}[x_{\text{MaxPool}}(\mathbf{F})]\}, \quad (1)$$

$$\mathbf{M}_c(\mathbf{F}) = \sigma \{W_1[W_0(\mathbf{F}_{c,\text{avg}})] + W_1[W_0(\mathbf{F}_{c,\text{max}})]\}, \quad (2)$$

式中: σ 表示 Sigmoid 函数; $x_{\text{AvgPool}}(\cdot)$ 表示平均池化函数; $x_{\text{MaxPool}}(\cdot)$ 表示最大池化函数; $\mathbf{F}_{c,\text{avg}}$ 和 $\mathbf{F}_{c,\text{max}}$ 分别表示经过平均池化和最大池化后的特征图; W_1 和 W_0 表示 MLP 中的两层参数。

空间注意力模块首先将 \mathbf{F}' 分别进行一个通道维度的全局平均池化和全局最大池化操作, 可以得到两个空间特征描述, 并将这两个特征描述按照通道拼接在一起, 拼接后的特征经过一个 $7 \times 7 \times 7$ 的卷积层后得到 \mathbf{M}_s , 将 \mathbf{M}_s 和 \mathbf{F} 进行体素级相乘后得到 \mathbf{F}'' 。空间注意力图谱的具体计算公式为

$$\mathbf{M}_s(\mathbf{F}') = \sigma \{f^{7 \times 7 \times 7}[x_{\text{AvgPool}}(\mathbf{F}'); x_{\text{MaxPool}}(\mathbf{F}')]\}, \quad (3)$$

$$\mathbf{M}_s(\mathbf{F}') = \sigma[f^{7 \times 7 \times 7}(\mathbf{F}_{s,\text{avg}}; \mathbf{F}_{s,\text{max}})], \quad (4)$$

式中: $\mathbf{F}_{s,\text{avg}}$ 和 $\mathbf{F}_{s,\text{max}}$ 分别表示经过平均池化和最大池化后的特征图; $f^{7 \times 7 \times 7}$ 表示 $7 \times 7 \times 7$ 的卷积运算。

2.3 损失函数

数据不平衡是医学图像分割过程中的常见问题之一。在脑白质病灶的分割过程中, 非病变体素的数量通常远远大于病变体素, 如果不采取均衡措施, 网络的预测会向非病灶类倾斜, 导致分割结果出现高精确率和低召回率。针对这一问题, 采用 Salehi 等^[27]提出的具有数据均衡作用的 Tversky 损失函数。Tversky 损失函数引入了 Tversky 系数, 该系数是 Dice 系数和 Jaccard 指数的一种广义系数。当计算相似度时, 引入权重系数来调整假阳性和假阴性之间的比重。基于 Tversky 系数的损失函数可表示为

$$L_c = \sum (1 - I_c), \quad (5)$$

其中

$$I_c = \frac{\sum_{i=1}^N p_{ic} g_{ic} + \epsilon}{\sum_{i=1}^N p_{ic} g_{ic} + \alpha \sum_{i=1}^N p_{i\bar{c}} g_{ic} + \beta \sum_{i=1}^N p_{ic} g_{i\bar{c}} + \epsilon}, \quad (6)$$

式中: c 表示病灶类; $g_{ic} \in \{0, 1\}$ 和 $p_{ic} \in \{0, 1\}$ 分别表示真实标签和预测结果; $g_{i\bar{c}}$ 和 $p_{i\bar{c}}$ 分别表示真实标签和预测结果中的背景体素; $p_{i\bar{c}} g_{ic}$ 表示分割结果中的假阴性; $p_{ic} g_{i\bar{c}}$ 表示分割结果中的假阳性; N 表示图像中的总体素数; ϵ 表示一个可以自由

选择的常数, 目的是避免分母为 0 而出现分子被 0 除的问题; α 和 β 分别表示控制假阴性和假阳性的惩罚力权重, 其中一个权重的增长就会增加与权重相关的错误类型的惩罚。 α 和 β 这两个参数的设置是保持训练平衡的关键一步。当 $\alpha > \beta$ 时, 就会加重惩罚假阴性, 从而抑制网络的预测向非病变类倾斜。本方法将 α 设为 0.7, β 设为 0.3。

3 实验结果与分析

3.1 数据准备

使用的数据源自 MICCAI 2017 脑白质病变分割竞赛的公开数据集 (<http://wmh.isi.uu.nl/>), 该数据集包含从 5 个不同扫描设备上获得的 60 个 3D 脑部 MRI。将 60 个样本分成训练集 (包含 48 个样本)、验证集 (包含 6 个样本) 和测试集 (包含 6 个样本)。为了防止模型因数据样本过少而出现过拟合, 对训练集采用旋转、仿射和透视等变换操作进行数据增强, 增强后的训练集包含 384 个样本。

3.2 实验环境和参数设置

在谷歌云平台上对模型进行训练和测试。实验使用的硬件和软件环境均由谷歌云平台提供, 包括 TensorFlow 2.0、CUDA 10.1、PyThon 3.6、NVIDIA-SMI 450.57、Tesla T4, 内存为 25.51 G。由于受到硬件条件的限制, 实验将一次训练所选取的样本数设为 2。实验采用自适应矩估计 (Adaptive moment estimation, Adam) 优化器, Adam 优化器的学习率设为 0.0001。为了防止模型过拟合, 当验证集上的损失函数在 8 个迭代周期内不再减小时, 停止训练。

3.3 评价指标

实验使用召回率、精度和 DSC (Dice Similarity Coefficient) 作为分割脑白质病灶的评价指标。召回率反映实际为脑白质病变的体素中被正确分割出的比例, 用来衡量脑白质病灶分割的完整性。精度反映分割的体素中实际为脑白质病变的比例, 用来衡量脑白质病灶分割的精确度。综上可知, 召回率的关注点与精度不同。为了兼顾分割的完整性和精确度, 引入 DSC, 其反映分割结果与真实标签之间的相似度, DSC 值越大, 分割结果越接近于真实标签。具体公式可表示为

$$R = \frac{x_{\text{TP}}}{x_{\text{TP}} + x_{\text{FN}}}, \quad (7)$$

$$P = \frac{x_{\text{TP}}}{x_{\text{TP}} + x_{\text{FP}}}, \quad (8)$$

$$x_{DSC} = \frac{2x_{TP}}{x_{FN} + x_{FP} + 2x_{TP}}, \quad (9)$$

式中： x_{TP} 表示真实标签为脑白质病变类且被分割为脑白质病变类的体素个数； x_{FP} 表示真实标签为非脑白质病变类但被分割为脑白质病变类的体素个数； x_{FN} 表示真实标签为脑白质病变类被分割为非脑白质病变类的体素个数。

3.4 实验结果分析

3.4.1 模型改进的对比分析

对改进模型进行对比验证实验,即对比分析 3D U-Net 模型在被逐步改进的过程中所产生的结果。共进行 9 组实验:第 1 组采用 3D U-Net 模型和 Dice 损失函数进行分割,简称 UD 组;第 2 组在第 1 组的基础上增加图 2(a)的原始 Inception-ResNet-A 模块,简称 UDI* 组;第 3~5 组在第 1 组的基础上分别增加图 2(b)的 Inception 模块(以下简称 Inception 模块)、注意力机制,以及同时加入 Inception 模块与注意力机制,分别简称 UDI 组、UDA 组和 UDIA 组;第 6 组采用 3D U-Net 模型和 TL 损失函数进行分割,简称 UT 组;第 7~9 组在第 6 组的基础上分别增加 Inception 模块、注意力机制,以及同时加入 Inception 模块与注意力机制,分别简称 UTI 组、UTA 组和 UTIA 组。实验结果如表 1 所示。

表 1 不同改进模型的评估指标对比

Table 1 Comparison of evaluation indexes of different improved models

Model	Recall	Precision	DSC
UD	0.65	0.82	0.72
UDI*	0.63	0.77	0.74
UDI	0.67	0.85	0.75
UDA	0.70	0.84	0.76
UDIA	0.74	0.79	0.76
UT	0.69	0.77	0.72
UTI	0.76	0.74	0.75
UTA	0.74	0.79	0.76
UTIA	0.84	0.71	0.77

在计算机辅助诊断的系统中,往往不希望出现高精度和低召回率的情况,而是期望两者尽量平衡^[18]。由于在医学图像的分割过程中,召回率是一项非常重要的指标,其表明了有多少病变组织被找到,因此在 DSC 值相同或相近的情况下,实验更关注召回率的提升。从表 1 可以看到,UD 组的召回率低,精度高,说明分割结果中有大量的假阴性体素,很多真实病灶未被分割出来;UDI* 组虽然采用 Inception-ResNet-A 模块后能够提升 DSC 值和精度,但召回率不升反降,这不是所期望的;对比

UDI* 和 UDI 的指标可以看到,UDI* 组的三项指标都没有 UDI 好,这说明原始 Inception-ResNet-A 模块中先串联不同尺寸的特征图,再使用 $1 \times 1 \times 1$ 卷积进行特征融合的效果,不如改进的 Inception 模块中直接叠加不同尺寸特征图的效果好。

此外,UDI 组、UDA 组和 UDIA 组的数据结果表明,单独添加或混合添加 Inception 模块和注意力机制都会提升 DSC 值,但三者的提升效果接近。从召回率方面来看,UDI 组的召回率为 0.67,比 UDA 组和 UDIA 组低,说明单独添加 Inception 模块的召回率不如单独添加注意力机制和混合添加 Inception 模块与注意力机制,并且 UDIA 组对召回率的提升更明显,说明混合添加比单独添加 Inception 模块或注意力机制,可以使网络更能关注病灶区域,减少分割结果中的假阴性体素,识别出更多的病灶区,从 UTI 组、UTA 组和 UTIA 组也可以看到这一点。综上,引入 Inception 模块和注意力机制对提升病灶的分割能力有效,且同时添加效果更好。此外,从 UD 组和 UT 组的对比可以看到,引入损失函数虽然没有提升 DSC 值,但可以提升召回率,这也进一步认证了损失函数的能力,即防止网络向非病灶区域倾斜,均衡假阳性和假阴性之间的比重。从表 1 可以看到,在 UT 组的基础上添加的 Inception 模块和注意力机制的改进效果比在 UD 组基础上进行改进更好。其中,UTIA 组的召回率比 UD 组提升 0.19,DSC 指标提升 0.05,效果最好,其是最终确定的分割模型。美中不足的是,召回率的提升会伴随着精度的降低,这说明在有更多病灶被分割出来的同时,也扩大了假阳性的分割区域,这不是所期望的,但在 DSC 值不变的情况下,召回率和精度不可能同时提升,此时更倾向于召回率这一指标。

所提方法对脑白质病变分割的视觉效果如图 4 所示,蓝色表示正确分割的体素,绿色表示假阳性体素,红色表示假阴性体素。从图 4 可以看到,与真实标签相比,UD 组的分割结果未被正确识别出 a-g 处的病灶;与 UD 组相比,在 UD 组的基础上添加 Inception 模块和注意力机制后的 UDIA 组明显分割出来 b、d 和 g 处的病灶,此时模型的召回率提高了 0.09;使用 Tversky 损失函数替换 Dice 损失函数后的 UTIA 组,其分割结果不仅比 UDIA 组更接近真实标签,而且可以精确地分割出 c 处和 f 处的病灶,并显著改善 a 处和 e 处的分割细节,召回率和 DSC 分别提高了 0.19 和 0.05。

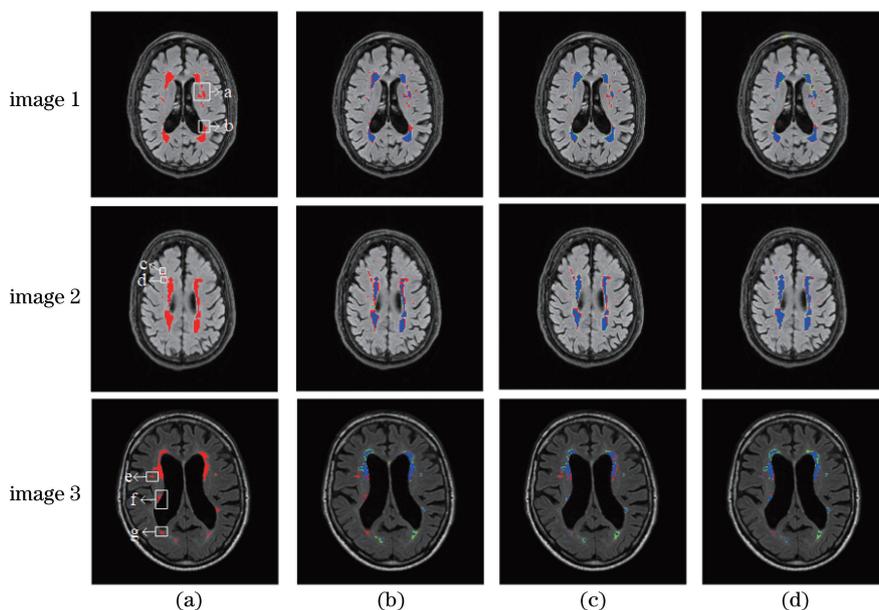


图 4 不同改进模型的分割结果。(a)真值标签;(b) UD;(c) UDIA;(d) UTIA

Fig. 4 Segmentation results of different improved models. (a) Ground truth; (b) UD; (c) UDIA; (d) UTIA

3.4.2 与其他文献方法的对比

为了验证所提方法相对于其他方法的优越性,将所提方法与其他方法进行对比,结果如表 2 所示,其中所有方法的数据源均源自 MICCAI 2017 脑白质病变分割竞赛的公开数据集。表中除了文献[7]采用随机森林算法外,其他文献均采用深度神经网络。从表 2 可以看到,几种深度学习方法的分割结果均优于随机森林算法;综合来看,所提方法的评价指标在对比方法中表现较好,召回率仅次于文

献[19],DSC 值稍弱,但不是最差。为了更直观地比较所提方法与对比方法的分割效果,在相同的实验条件下复现 ResU-Net 模型^[17],并将其分割结果与所提方法进行对比,结果如图 5 所示。从图 5 可以看到,所提方法比 ResU-Net 模型多识别出了 a~d 处的小病变,而且从第三行图像上可以明显看到,ResU-Net 模型分割出的假阳性体素(绿色区域)较多,这说明所提方法在识别小病灶和病灶边界的精确度上比 ResU-Net 模型好。

表 2 所提方法与其他方法的评估指标对比

Table 2 Comparison of evaluation indexes between proposed method and other methods

Method	Model	Recall	Precision	DSC
Ref. [7]	Random forest	0.27	0.29	0.50
Ref. [12]	MD-GRU	0.81	0.69	0.75
Ref. [16]	Ensemble U-Net	0.84	0.76	0.80
Ref. [17]	ResU-Net	0.83	0.70	0.78
Ref. [19]	Multi-scale U-Net	0.86	0.76	0.80
Ref. [21]	SC-UNet	0.81	0.70	0.78
Proposed method	UTIA	0.84	0.71	0.77

3.4.3 残差分析

神经网络在解决复杂问题上的表现比浅层网络好,但是随着网络深度的增加,梯度消失和梯度爆炸的问题也随之而来。实验在解码阶段增加残差连接,因为残差连接不仅为前向传播提供了支路,也为反向传播提供了直接的回传路径,而且能够解决梯度消失和梯度爆炸的问题,同时可加快网络优化的速度^[24]。为了直观地验证残差连接加快了模型

的训练速度,进行两个对比实验。第一个实验是基于图 1 的模型,第二个实验是在图 1 模型的基础上去掉了解码阶段中的残差连接。图 6 为两个不同模型的损失函数曲线。从图 6 可以看到,在有残差连接的模型中,第 17 个训练轮次的损失值就下降到了 0.2,并且第 66 个训练轮次后结束训练;在无残差连接的模型中,第 29 个训练轮次后损失值才能下降到 0.2,第 93 个训练轮次后结束训练,这证明添加残差

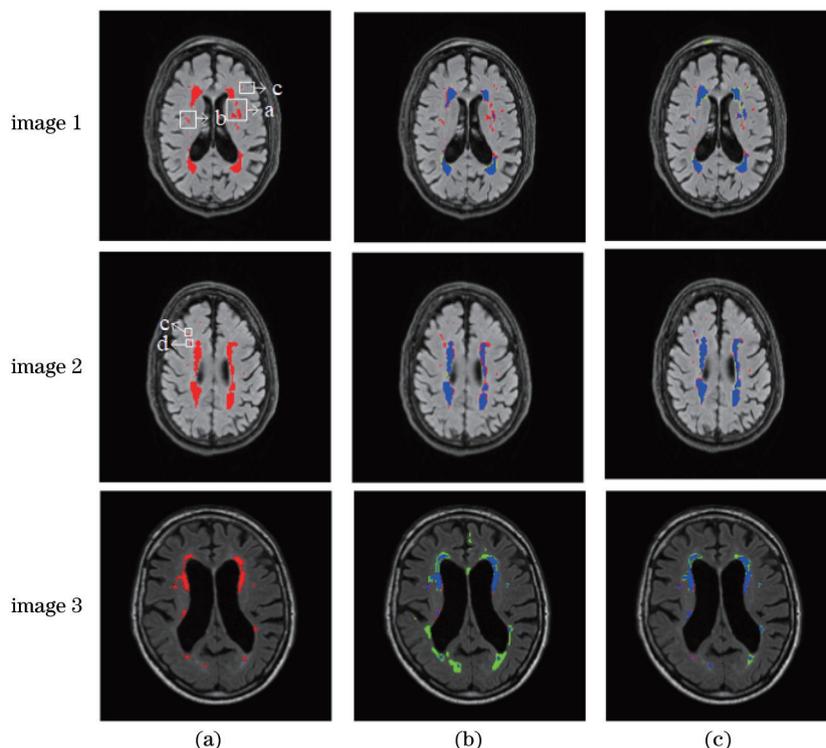


图 5 UTIA 与 Res-U-Net 的分割结果对比。(a) GT;(b) ResU-Net;(c) UTIA

Fig. 5 Comparison of segmentation results between UTIA and Res-U-Net. (a) GT; (b) ResU-Net; (c) UTIA

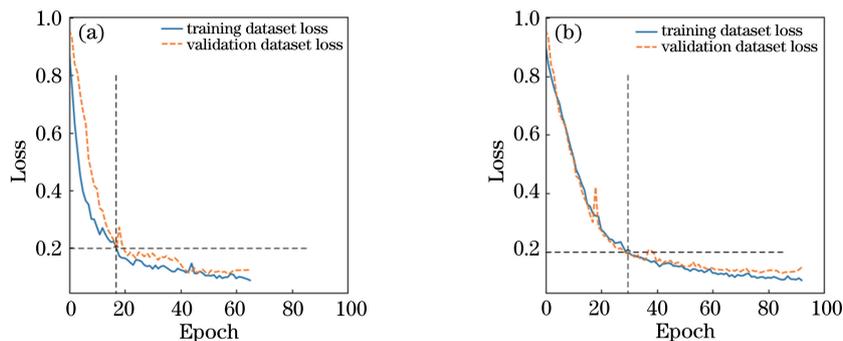


图 6 不同情况下的损失函数曲线对比。(a)有残差连接的模型;(b)无残差连接的模型

Fig. 6 Comparison of loss function curves under different conditions. (a) Model with residual connections; (b) model with no residual connections

连接后,所设计模型的训练速度得到了有效提升。此外,为了避免训练过拟合,实验过程中未采用简单的阈值终止法,而是在训练过程中监控验证集上的损失值,如果在 8 个训练轮次后内,验证集上的损失值不再下降,即停止训练。

4 结 论

U-Net 模型是一种经典的端到端图像分割的深度神经网络模型,但在实际应用中直接使用 U-Net 模型并不能得到理想的结果,在脑白质高信号分割的问题上同样如此。为了得到较好的分割结果,基于 U-Net 模型提出改进策略,使其解决脑白质高信

号分割的特异性问题。模型采用的 Inception 模块可以捕获不同尺寸的脑白质病灶,添加的注意力机制可以提高神经网络对分割目标的关注度,在训练过程中使用 Tversky 损失函数可以解决样本不平衡所致的假阴性过多问题。模型在 MICCAI 2017 脑白质高信号分割竞赛的公开数据集上得到了验证,并与其他文献的模型进行了对比。实验结果表明,所提方法的分割结果优于多数对比方法;从视觉上来看,所提方法可以较好地分割出脑白质高信号的区域,并且对细小病灶和病灶轮廓的分割效果较好。所提方法虽然是为了解决脑白质高信号的分割而设计,但对其他医学影像的分割应同样具有参考意义,在后

续工作中会进一步证实这一点。同时,本文工作对推进脑部疾病的计算机辅助诊断具有积极意义。

参 考 文 献

- [1] Gouw A A, Seewann A, van der Flier W M, et al. Heterogeneity of small vessel disease: a systematic review of MRI and histopathology correlations [J]. *Journal of Neurology, Neurosurgery, and Psychiatry*, 2011, 82(2): 126-135.
- [2] Debette S, Markus H S. The clinical importance of white matter hyperintensities on brain magnetic resonance imaging: systematic review and meta-analysis [J]. *BMJ (Clinical Research Ed.)*, 2010, 341: c3666.
- [3] Hirono N, Kitagaki H, Kazui H, et al. Impact of white matter changes on clinical manifestation of Alzheimer's disease: a quantitative study [J]. *Stroke*, 2000, 31(9): 2182-2188.
- [4] Schoonheim M M, Vigeveno R M, Lopes F C R, et al. Sex-specific extent and severity of white matter damage in multiple sclerosis: implications for cognitive decline [J]. *Human brain mapping*, 2014, 35(5): 2348-2358.
- [5] She L H, Zhong H, Zhang S. Fuzzy C-means clustering algorithm combined with Markov random field for brain MR image segmentation [J]. *Journal of Image and Graphics*, 2012, 17(12): 1554-1560.
余黎煌, 钟华, 张石. 结合马尔可夫随机场与模糊 C-均值聚类的脑 MRI 图像分割 [J]. *中国图象图形学报*, 2012, 17(12): 1554-1560.
- [6] Morel B, Xu Y C, Virzi A, et al. A challenging issue: detection of white matter hyperintensities in neonatal brain MRI [C] // 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), August 16-20, 2016, Orlando, FL, USA. New York: IEEE Press, 2016: 93-96.
- [7] Bento M, de Souza R, Lotufo R, et al. WMH segmentation challenge: a texture based classification approach [M] // Crimi A, Bakas S, Kuijf H, et al. *Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries*. Lecture notes in computer science. Canada, Springer. 2017, 10670: 489-500.
- [8] Isa I, Sulaiman S N, Abdullah M F. Classification and grading of white matter hyperintensity severity by using automated detection [C] // 2017 7th IEEE International Conference on Control System, Computing and Engineering, November 24-26, 2017, Penang. New York: IEEE Press, 2017: 198-203.
- [9] Chen Y, Guo H G, Ai Y P. Single image dehazing method based on multi-scale convolution neural network [J]. *Acta Optica Sinica*, 2019, 39(10): 1010001.
陈永, 郭红光, 艾亚鹏. 基于多尺度卷积神经网络的单幅图像去雾方法 [J]. *光学学报*, 2019, 39(10): 1010001.
- [10] Li D X, Zhang Z. Improved U-Net segmentation algorithm for the retinal blood vessel images [J]. *Acta Optica Sinica*, 2020, 40(10): 1010001.
李大湘, 张振. 基于改进 U-Net 视网膜血管图像分割算法 [J]. *光学学报*, 2020, 40(10): 1010001.
- [11] Zheng T Y, Tang C, Lei Z K. Multi-scale retinal vessel segmentation based on fully convolutional neural network [J]. *Acta Optica Sinica*, 2019, 39(2): 0211002.
郑婷月, 唐晨, 雷振坤. 基于全卷积神经网络的多尺度视网膜血管分割 [J]. *光学学报*, 2019, 39(2): 0211002.
- [12] Andermatt S, Pezold S, Cattin P. Multi-dimensional gated recurrent units for the segmentation of biomedical 3D-data [M] // Carneiro G, Mateus D, Peter L, et al. *Deep learning and data labeling for medical applications*. Lecture notes in computer science. Cham: Springer, 2016, 10008: 142-151.
- [13] Ghafoorian M, Karssemeijer N, Heskes T, et al. Location sensitive deep convolutional neural networks for segmentation of white matter hyperintensities [J]. *Scientific Reports*, 2017, 7(1): 5110.
- [14] Xu Y, Geraud T, Puybureau E, et al. White matter hyperintensities segmentation using fully convolutional network and transfer learning [M] // Crimi A, Bakas S, Kuijf H, et al. *Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries*. Lecture notes in computer science. Cham: Springer, 2017, 10670: 501-514.
- [15] Rachmadi M F, Valdés-Hernández M D C, Agan M L F, et al. Segmentation of white matter hyperintensities using convolutional neural networks with global spatial information in routine clinical brain MRI with none or mild vascular pathology [J]. *Computerized Medical Imaging and Graphics*, 2018, 66: 28-43.
- [16] Li H W, Jiang G F, Zhang J G, et al. Fully convolutional network ensembles for white matter hyperintensities segmentation in MR images [J]. *NeuroImage*, 2018, 183: 650-665.
- [17] Jin D K, Xu Z Y, Harrison A P, et al. White matter hyperintensity segmentation from T1 and FLAIR images using fully convolutional neural networks enhanced with residual connections [C] // 2018 IEEE 15th International Symposium on Biomedical Imaging

- (ISBI 2018), April 4-7, 2018, Washington, DC, USA. New York: IEEE Press, 2018: 1060-1064.
- [18] Zhang Y, Chen W, Chen Y, et al. A post-processing method to improve the white matter hyperintensity segmentation accuracy for randomly-initialized U-Net [C] // 2018 IEEE 23rd International Conference on Digital Signal Processin, November 19-21, 2018, Shanghai, China. New York: IEEE Press, 2018: 18418115.
- [19] Li H, Zhang J, Muehlau M, et al. Multi-scale convolutionalstack aggregation for robust white matter hyperintensities segmentation [EB/OL]. (2019-02-27) [2020-09-29]. <https://arxiv.org/abs/1807.05153v1>.
- [20] Jeong Y, Rachmadi M F, Valdés-Hernández M D C, et al. Dilated saliency U-Net for white matter hyperintensities segmentation using irregularity age map[J]. *Frontiers in Aging Neuroscience*, 2019, 11: 150.
- [21] Wu J, Zhang Y, Wang K, et al. Skip connection U-Net for white matter hyperintensities segmentation from MRI [J]. *IEEE Access*, 2019, 7: 155194-155202.
- [22] Lee A R, Woo I, Kang D W, et al. Fully automated segmentation on brain ischemic and white matter hyperintensities lesions using semantic segmentation networks with squeeze-and-excitation blocks in MRI [J]. *Informatics in Medicine Unlocked*, 2020, 21: 100440.
- [23] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1-9.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [25] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning [EB/OL]. (2016-08-23) [2020-09-29]. <https://arxiv.org/abs/1602.07261>.
- [26] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 3-19.
- [27] Salehi S S M, Erdogmus D, Gholipour A. Tversky loss function for image segmentation using 3D fully convolutional deep networks [C] // Wang Q, Shi Y, Suk H I, et al. *Machine learning in medical imaging. Lecture notes in computer science*. Cham: Springer, 2017, 10541: 379-387.