



计算机科学

COMPUTER SCIENCE

共享浅层参数多任务学习的脑出血图像分割与分类

赵凯, 安卫超, 张晓宇, 王彬, 张杉, 相洁

引用本文

赵凯, 安卫超, 张晓宇, 王彬, 张杉, 相洁. [共享浅层参数多任务学习的脑出血图像分割与分类](#)[J]. 计算机科学, 2022, 49(4): 203-208.

ZHAO Kai, AN Wei-chao, ZHANG Xiao-yu, WANG Bin, ZHANG Shan, XIANG Jie. [Intracerebral Hemorrhage Image Segmentation and Classification Based on Multi-task Learning of Shared Shallow Parameters](#)[J]. Computer Science, 2022, 49(4): 203-208.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于时空自适应图卷积神经网络的脑电信号情绪识别](#)

EEG Emotion Recognition Based on Spatiotemporal Self-Adaptive Graph Convolutional Neural Network
计算机科学, 2022, 49(4): 30-36. <https://doi.org/10.11896/jsjcx.210900200>

[基于多级特征融合与注意力模块的场景识别方法](#)

Scene Recognition Method Based on Multi-level Feature Fusion and Attention Module
计算机科学, 2022, 49(4): 209-214. <https://doi.org/10.11896/jsjcx.210100135>

[基于 CNN 的血液细胞图像自动识别算法](#)

Automatic Identification Algorithm of Blood Cell Image Based on Convolutional Neural Network
计算机科学, 2022, 49(4): 247-253. <https://doi.org/10.11896/jsjcx.210200093>

[基于混合字词特征的中文短文本分类算法](#)

Chinese Short Text Classification Algorithm Based on Hybrid Features of Characters and Words
计算机科学, 2022, 49(4): 282-287. <https://doi.org/10.11896/jsjcx.210200027>

[基于特征定位与融合的行人重识别算法](#)

Person Re-identification Based on Feature Location and Fusion
计算机科学, 2022, 49(3): 170-178. <https://doi.org/10.11896/jsjcx.210100132>

共享浅层参数多任务学习的脑出血图像分割与分类



赵凯 安卫超 张晓宇 王彬 张杉 相洁

太原理工大学信息与计算机学院 太原 030600

(573239668@qq.com)

摘要 非增强 CT 扫描是急诊室诊断疑似脑出血的首选方法, 医疗人员通常借助 CT 图像对疑似急性脑出血患者病灶部位进行手动分割, 进而根据临床经验进行分类, 这种人工诊断的方式对医师的经验要求较高, 主观性较强, 将分割和分类任务分开执行, 不能充分利用两个任务间相关联的特征信息, 时间成本高, 增大了基于 CT 图像快速进行脑出血病灶部位分割及分类的难度。针对上述问题, 文中提出了一种共享浅层参数多任务学习的脑出血图像分割及分类模型, 一方面, 根据不同任务学习的难易程度对损失函数的权值进行优化, 另一方面, 在多任务学习网络的浅层实现公有信息共享, 深层提取不同任务的私有信息, 获取更具代表性的特征, 从而快速、准确地对脑出血患者的 CT 图像进行分割及分类。实验结果表明, 共享浅层参数多任务学习网络生成的分割标注与真实标注有较好的视觉一致性。在最优权值下所有被试的平均 Dice 系数 (DSC) 为 0.828, 敏感度为 0.842, 特异度为 0.985, 阳性预测值 (PPV) 为 0.838。共享浅层参数多任务学习网络分类的准确率、敏感度、特异度和 AUC 值分别为 95.00%, 90.48%, 100.00% 和 0.982。与单任务深度学习、Y-Net 以及借助分类辅助的多任务学习相比, 该方法更加有效地利用了相关任务信息, 同时通过调节损失函数权值, 提升了出血病灶区域的分割和分类精度。

关键词: 脑出血; CT; 3DU-Net; 卷积神经网络; 多任务学习

中图法分类号 TP391

Intracerebral Hemorrhage Image Segmentation and Classification Based on Multi-task Learning of Shared Shallow Parameters

ZHAO Kai, AN Wei-chao, ZHANG Xiao-yu, WANG Bin, ZHANG Shan and XIANG Jie

College of Information and Computer, Taiyuan University of Technology, Taiyuan 030600, China

Abstract Non-enhanced CT scanning is the first choice for the diagnosis of suspected cerebral hemorrhage in the emergency room. Medical staffs usually use CT images to manually segment the lesions of patients with suspected acute cerebral hemorrhage, and then classify them based on clinical experience. This method of manual diagnosis requires the physician's experience and is highly subjective. Moreover, the segmentation and classification tasks are performed separately, and the characteristic information associated between the two tasks cannot be fully utilized, and the time cost is high, which increases the difficulty of quickly segmenting and classifying cerebral hemorrhage lesions based on CT images. In response to the above problems, the paper proposes a model for segmentation and classification of cerebral hemorrhage images based on multi-task learning. On the one hand, the weight of the loss function is optimized according to the difficulty of learning different tasks. On the other hand, public information sharing is realized in the shallow layer of the multi-task learning network, and private information of different tasks is extracted deeply to obtain more representative features, so as to quickly and accurately segment and classify the CT images of patients with cerebral hemorrhage. The experimental results show that the segmentation annotations generated by the multi-task learning network have good visual consistency with the real annotations. Under the optimal weight, the average Dice coefficient (DSC) of all subjects is 0.828, the sensitivity is 0.842, the specificity is 0.985, and the positive predictive value (PPV) is 0.838. The accuracy, sensitivity, specificity and AUC value of multi-task learning network classification are 95.00%, 90.48%, 100.00% and 0.982, respectively. Compared with single-task deep learning, Y-Net and multi task learning assisted by classification, this method

到稿日期:2020-10-27 返修日期:2021-03-16 本文已加入开放科学计划(OSID), 请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61503272, 61873178, 61876124); 山西省自然科学基金(201801D121135)

This work was supported by the National Natural Science Foundation of China(61503272, 61873178, 61876124) and Natural Science Foundation of Shanxi Province, China(201801D121135).

通信作者:相洁(xiangjie@tyut.edu.cn)

makes more effective use of relevant task information, and at the same time improves the segmentation and classification accuracy of hemorrhage lesions by adjusting the weight of the loss function.

Keywords Cerebral hematoma, CT, 3DU-Net, Convolutional neural network, Multi-task learning

1 引言

在我国,脑出血病例占全部脑卒中病例的 30% 左右,病死率和致残率较高,常见的脑出血病因有高血压^[1]、淀粉样变性^[2]和脑动静脉畸形^[3]等。其中脑动静脉畸形(Arteriovenous Malformation, AVM)出血由动脉和静脉直接连通形成结构异常的血管团造成^[4],是临床上常见的颅脑血管病变,占所有畸形类型中 90% 以上^[5]。由于畸形血管团邻近脑实质常发生脑萎缩甚至缺血性坏死,因此对脑动静脉畸形的早期诊断是一个亟需解决的问题。

非对比增强 CT (Non-contrast-Enhanced CT, NECT) 扫描是急诊室诊断疑似急性脑出血的首选方法,医疗人员通常使用疑似急性脑出血患者的 NECT 图像对病灶部位进行手动分割和分类。这样的方式不仅耗时,还依赖医疗人员的专业知识和临床经验,诊断结果带有较强的主观性。因此,计算机辅助分割和分类工具的开发成为近年来的热点话题。

随着人工智能技术的发展,深度学习被广泛应用于医学图像分割领域,主要算法有全卷积网络(Fully Convolutional Networks, FCN)^[6]和 U-Net^[7]网络。Dhar 等^[8]使用全卷积网络模型实现了对脑出血图像出血及水肿部的分割; Ironside 等^[9]受到 U-Net 网络结构的启发,构建了一个由 31 个卷积层和 7 个池化层组成的网络结构,该结构通过收缩和扩张路径实现了脑出血图像的端对端学习; Ye^[10]等提出了一种融合时序模型与注意力机制的分割网络,实现了对脉络膜新生血管的分割; Wang 等^[11]提出了一种包含 logistic 和 Dice 复合损失函数的 V-Net 网络,将扩张路径的各层输出结果放大到与原始图像相同的尺寸做深度监督,并构建带有深度监督的 V-NET 网络,以分割脑动静脉畸形出血; Cicek 等^[12]提出了 3D U-Net 用于医学图像的分析,与 U-NET 相比,3D U-Net 能更好地提取医学图像的空间特征。

目前,医学图像分类领域广泛使用卷积神经网络(Convolutional Neural Networks, CNN)来构建深度学习模型。Hamidian 等^[13]提出两阶段检测网络,第一阶段使用三维 FCN 筛选疑似病灶区域,第二阶段使用三维 CNN 对被试进行分类。Gao 等^[14]提出将二维 CNN 和三维 CNN 结合,根据得到的 Softmax 分数的平均值协调两个 CNN 网络分类。Silva 等^[15]采用粒子群优化(PSO)算法对 CNN 中的网络超参数进行优化,提高了分类网络的性能。

上述分割或分类的方法只针对单一的任务,在获取特征时往往会忽略一些任务之间相关联的信息,不能得到最佳的分割或分类性能。为了更好地利用分割和分类任务之间的关联信息,提升分割和分类的精度,He 等^[16]使用了多任务学习(Multi-Task Learning, MTL)模型,该模型的编码部分使用

DenseNet/ResNet 结构,解码部分使用上采样和级联操作,其呈现出非对称结构的端对端学习网络,在最后分为分割和分类两支输出,借助分类任务辅助学习关联信息,提升分割精度。Y-Net^[17]采用了两阶段结构,第一部分像 U-Net 一样输出分割掩模;第二部分在底层热图处添加输出分类标签的并行分支。但是,脑动静脉畸形出血相比其他类型出血在成分上不均匀,且出血周围扩张的静脉可能会使边界凹陷,在形态上出现差异^[18],因此需要尽可能多地提取分类任务深层的私有特征。He 等^[16]提出的将分割和分类任务参数全部共享的模型不能提取两个任务深层的私有特征,而 Y-Net 网络在编码部分底层实现并行分支,共享了全部编码参数和部分分类参数,但不能提取分割任务深层的私有特征。

基于上述研究,本文提出了一种共享浅层参数的多任务学习(Multi-task Learning of Shared Shallow Parameters, MLSSP)模型,用于脑出血图像的分割和分类。该模型从 3D U-Net 浅层输出多任务分支,既能共享图像浅层的公有特征,又可以在网络深层分别提取各个任务需要的深层私有特征,有效利用了多个任务之间不同层次的特征来获取更加丰富的信息。此外,本文还对多任务复合损失函数的权值进行了优化,从网络结构和损失函数的角度提升了脑出血 CT 图像语义分割和分类的精度,为脑出血诊断提供新的视角。

2 MLSSP 脑出血分割及分类模型

为了更好地共享两个任务的公有信息并提取不同任务的私有信息,提升分割和分类任务的精度,本文使用了脑出血分割及其相关的分类任务结合构造共享浅层参数的多任务学习模型。MLSSP 模型包含脑出血语义分割模块和脑出血分类模块两部分。脑出血语义分割模块整体基于 3D U-Net 结构,脑出血分类模块选用 CNN 结构。

MLSSP 模型将脑出血的 VOI 作为网络的输入,在两次卷积后分为两个分支:分割分支传入基于 3D U-Net 的脑出血分割网络,分类分支传入基于卷积神经网络的脑出血分类网络。因为两个网络的浅层卷积层都起到了提取图像低阶特征的作用,而深层卷积层的目的是提取不同任务需要的高阶特征,所以通过浅层卷积层实现硬参数共享来构建多任务学习模型是可行的。与文献[16]提出的借助分类辅助学习输出和 Y-Net 在编码部分底层实现并行分支相比,本文所提模型不仅可以提取两个任务的浅层公有特征进行硬参数共享,还能够网络深层分别提取两个任务需要的深层私有特征,有效利用了两个任务之间不同层次的特征来获取更加丰富的信息,提高了两个任务的训练效果。U-Net, Y-Net 和 MLSSP 的体系结构如图 1 所示。

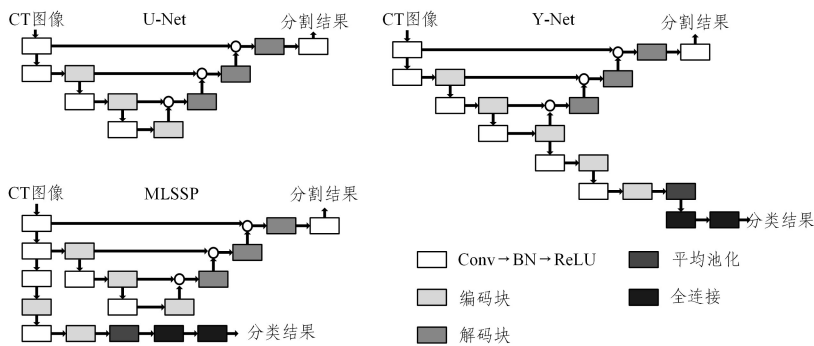


图1 U-Net, Y-Net 和 MLSSP 体系结构的比较

Fig. 1 Comparison of U-Net, Y-Net and MLSSP architectures

2.1 脑出血分割模块

脑出血分割模块采用3D-U-Net网络结构,脑出血图像由输入层接收并传入呈对称结构的网络,网络左侧为4层收缩路径,每一层都由两个大小为 $3 \times 3 \times 3$ 、步长为1的卷积层和一个大小为 $2 \times 2 \times 2$ 、步长为2的下采样卷积核组成,使用ReLU作为激活函数,防止数据过拟合。下采样4次,通过三维卷积来获取各个层级的语义信息。网络右侧为扩张路径,对收缩路径进行4次上采样操作,每一层都有特征图与对应收缩路径的跳跃连接进行级联作为输入,经过两个大小为 $3 \times 3 \times 3$ 、步长为1的卷积层和一个大小为 $2 \times 2 \times 2$ 、步长为2的反卷积层,使用ReLU作为激活函数,将高级语义特征图恢复到原始图片的分辨率。在收缩路径和扩张路径的同一阶段使用跳跃连接,补充卷积过程中丢失的低阶特征信息,同时在扩张过程中融合不同尺度的特征,提升分割精度。最后使用大小为 $1 \times 1 \times 1$ 、激活函数为Sigmoid的卷积层进行语义分割。

本文使用Dice系数作为脑出血语义分割算法的损失函数,如式(1)所示:

$$Loss_{DSC}(G, P) = 1 - \frac{2 \times V(G \cap P) + \epsilon}{V(G) + V(P) + \epsilon} \quad (1)$$

其中, V 表示区域的体积; G 表示真实分割图像; P 表示预测分割图像; ϵ 设为常数1,以防止计算时分母出现0的情况。

2.2 脑出血分类模块

本文的脑出血分类算法选择了卷积神经网络。网络第一层为输入层,用于接收大小为 $64 \times 64 \times 64$ 的脑出血图像,输入层之后经过两个卷积层,接下来的分类网络由5个块组成,前两个块结构相同,包括大小为 $3 \times 3 \times 3$ 、步长为1的卷积层和一个大小为 $2 \times 2 \times 2$ 、步长为2的最大池化层,使用ReLU作为激活函数。第3个和第4个块使用大小为64的全连接层,激活函数为ReLU。第4层的输出全连接到第5层,通过Sigmoid激活函数得到2个输出。这2个输出即为输入脑出血图像类型的概率。

在训练脑出血分类算法时,本文使用了交叉熵损失(cross entropy)作为损失函数,如式(2)所示:

$$Loss_{CE}(y, \hat{y}) = -[y \cdot \log(\hat{y}) + (1-y) \cdot \log(1-\hat{y})] \quad (2)$$

其中, y 表示样本的期望输出,即标签值; \hat{y} 表示样本经过模型的预测输出。

2.3 损失函数

本文通过计算Dice系数分割损失和交叉熵损失的加权来作为多任务学习网络的损失函数,如式(3)所示:

$$Loss_{MTL} = \alpha Loss_{DSC} + (1-\alpha) Loss_{CE} \quad (3)$$

其中, α 为语义分割和脑出血分类任务损失权重所占的比重,通过对每项任务损失的比重进行调节,使两项任务的训练效果达到最优。

2.4 评价标准

2.4.1 分割评价指标

为了评估脑出血分割的性能,本文计算了4个指标: Dice系数(DSC)、敏感度(Sensitivity)、特异度(Specificity)和阳性预测值(Positive Predicted Value, PPV)。其表达式如下:

$$DSC = \frac{2TP}{2TP + FP + FN} \quad (4)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (5)$$

$$Specificity = \frac{TN}{TN + FP} \quad (6)$$

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

其中, TP 表示真阳性,即在标记真实出血区域内预测的脑出血体素; FP 代表假阳性,即在标记真实出血区域外预测的脑出血体素; TN 表示真阴性,即在标记真实出血区域外预测的背景体素; FN 表示假阴性,即在标记真实出血区域内预测的背景体素。

2.4.2 分类评价指标

对于分类任务,本文计算了分类准确率、敏感度和特异度,并绘制了ROC曲线进行评估。分类准确率指正确分类的出血在所有被试中所占的比例。敏感度指正确分类的畸形出血在所有畸形出血被试的比例。特异度指正确分类的非畸形出血在所有非畸形出血被试的比例。ROC曲线以被试在不同阈值设置下所得真阳性率(TPR)和假阳性率(FPR)的曲线生成。

3 模型验证与分析

3.1 数据来源

本实验的NECT数据来自北京天坛医院神经放射科。实验使用了38位AVM患者和42位其他类型出血患者作为

被试。实验数据不包括位于小脑和脑干的出血。在被试出现出血 6 小时内使用西门子 SOMATOM Sensation 16 型 CT 扫描仪采集图像。扫描能量为 120 kVp, 自动 mAs 调制, 层厚 4.5 mm, 像素间距 $0.408 \times 0.408 \text{ cm}^2$ 。所有数据均具有出血类型标签及语义分割标签。其中语义分割标签由两位有丰富诊治经验的放射科主任医师对 NECT 图像进行手工标注, 以划定实质内出血的区域, 如图 2 所示, 白色区域为出血病灶区域, 将其像素值标记为 1, 其余区域像素值标记为 0。




图 2 AVM(A)和其他类型出血(B)的 CT 图像及语义分割

Fig. 2 CT images of AVM (A) and other types of hemorrhage (B) and semantic segmentation

3.2 数据预处理

(1) 颅骨剥离。使用基于轮廓进化技术的脑组织提取方法, 从获取的 NECT 图像中逐层提取脑组织^[19-20]。

(2) 重采样。在 CT 图像采集过程中, 不同的采集参数会使空间分辨率存在差异, 不同扫描面的像素尺寸和粗细粒度也有差异, 不利于之后网络的训练。因此需要将图像像素重采样到标准像素大小, 即 $1 \times 1 \times 1 \text{ mm}^3$ 的各向同性分辨率, 以确保输入网络的图像像素大小相同。

(3) 灰度归一化。选择窗位为 50Hu、窗宽为 100Hu 来增强图片对比度, 将此范围内的图像灰度归一化到 $[0, 1]$ 区间。

(4) 提取 VOI。为了降低计算成本, 将 CT 图像裁剪为包含病灶部位的大小为 $64 \times 64 \times 64$ 的像素感兴趣体积 (VOI) 作为网络输入。

(5) 数据扩充。对数据进行随机排列, 通过对图像沿 Y 轴、Z 轴旋转 90° , 沿 X 轴、Y 轴、Z 轴翻转以及对数据矩阵进行转置操作, 将数据扩充为原有数据的 $3 \times 8 \times 2 = 48$ 倍的数据量。

3.3 实验细节

在训练过程中, 采用 He 等^[21]提出的权重初始化方法, 使用 Adam (Adaptive Moment Estimation) 算法作为优化器, 计算每个参数的自适应学习率, 其梯度一阶矩和二阶矩估计的系数分别为 0.9 和 0.999。初始学习率设置为 0.00001, 经过一个 epoch 衰减 5%。使用 5 折交叉验证策略对多任务模型性能进行评估, 训练数据集和测试数据集保持基本相同的数据分布, 避免数据不平衡导致模型训练结果不能真正反映实际情况的问题发生。

3.4 脑出血分割对比实验

3.4.1 不同权重损失的脑出血分割实验

为了对比 MLSSP 模型两个分支的损失函数权重对分割性能的影响, 本实验选取的分割权重在 0.3~0.7 区间, 每隔 0.1 对模型进行训练, 5 个权值的模型表示为 MLSSP_0.3—MLSSP_0.7。表 1 为共享浅层参数的多任务学习下不同 α 测试的结果。图 3 给出了权重为 MLSSP_0.4 的模型的 DSC、敏感度、特异度和 PPV 指标。

表 1 不同 α 下 MLSSP 语义分割结果对比

Table 1 Comparison of semantic segmentation results of MLSSP

with different α				
方法	平均 DSC	敏感度	特异度	PPV
MLSSP_0.3	0.814	0.814	0.985	0.826
MLSSP_0.4	0.828	0.842	0.985	0.838
MLSSP_0.5	0.811	0.829	0.989	0.801
MLSSP_0.6	0.792	0.815	0.984	0.800
MLSSP_0.7	0.780	0.796	0.982	0.798




图 3 MLSSP_0.4 模型的指标

Fig. 3 Index of MLSSP_0.4 model

本实验对比分析了损失函数取不同权重的情况下模型的分割学习能力。由于 DSC 能够直观反映分割结果的相似度, 因此将 DSC 作为主要的分割评价指标, 其次的评价指标是 PPV, 其含义是预测出血像素占预测总体素的比值。表 1 结果显示, 在 5 个不同权重网络中, MLSSP_0.5 的网络特异度达到 5 个权重模型中特异度的最大值 0.989; 而在 MLSSP_0.4 的多任务学习模型中, 平均 DSC、敏感度和 PPV 均达到 5 个模型的最大值, 分别为 0.828, 0.842 和 0.838。图 3 结果显示, 在 MLSSP_0.4 模型下被试的分割指标分布大多较集中。由于分割与分类任务选取的损失函数不相同, 当 α 取 0.4 时, MLSSP 模型能够达到较好的脑出血图像病灶分割效果, 为脑出血分割的进一步研究提供了基础。

3.4.2 不同模型的脑出血分割实验

为了对比不同模型对分割性能的影响, 本实验对比了相同权重比下 MLSSP 模型、Y-Net 模型、He 等^[16]提出的多任务学习模型以及 3D-UNet 模型的平均 DSC 指标, 对比结果如图 4 所示。




图 4 4 种方法分割结果的对比

Fig. 4 Comparison of segmentation results of four methods

相比单任务 3D-UNet 模型, 加入多任务学习模型后得到

的分割结果的平均 DSC 指标更优。多任务学习模型更好地利用了分割和分类任务之间的关联信息,提升了分割精度。同时,MLSSP 模型的平均 DSC 高于 Y-Net 以及 He 等^[16]提出的多任务学习模型,其平均 DSC 达到最优。相比 He 等^[16]利用分类辅助任务共享全部参数和 Y-Net 共享全部编码参数,MLSSP 模型能更好地提取分割任务的私有特征,从而提升分割精度。

4 种模型在 5 个被试上对脑出血切片的分割效果如图 5 所示。其中图 5(a)、图 5(c)两列为 AVM 型出血,图 5(b)、图 5(d)、图 5(e)三列为非 AVM 型出血。且图 5(a)、图 5(b)、图 5(e)三列均为直径大于 3.0 cm 的出血,图 5(c)、图 5(d)两列的出血直径小于 3.0 cm。实验结果显示,MLSSP_0.4 模型对大尺寸脑出血和小尺寸脑出血均能进行较为完整的分割,对 AVM 型脑出血和非 AVM 型脑出血均有较好的分割效果。MLSSP_0.4 模型对脑出血的边缘区域分割更加精准,在图 5(a)、图 5(d)脑出血病灶边缘的突出部分的分割精度更高。同时,对于图 5(b)、图 5(e)中体积较小的不连续出血区域,MLSSP_0.4 模型表现出比其他模型更好的分割性能。这得益于 MLSSP_0.4 模型具有共享浅层公有特征,并能分别提取深层私有特征的特性。




图 5 语义分割结果

Fig. 5 Semantic segmentation results

3.5 脑出血分类对比实验

3.5.1 不同权重损失的脑出血分类实验

本实验使用准确率、敏感度、特异度和 AUC 评价模型在脑出血图像分类上的性能,敏感度表示被分类正确的 AVM 数量与所有 AVM 的比值,特异度表示被分类正确的其他类型出血与所有其他类型出血的比值。表 2 列出了 MLSSP 在 5 个 α 取值下的测试结果。

表 2 MLSSP 在不同 α 下的分类结果对比

Table 2 Comparison of classification results of MLSSP with

方法	准确率/%	敏感度	特异度
MLSSP_0.3	88.75	0.881	0.895
MLSSP_0.4	95.00	0.905	1.000
MLSSP_0.5	92.50	0.881	0.974
MLSSP_0.6	93.75	0.905	0.974
MLSSP_0.7	90.00	0.905	0.895

本实验对比了损失函数取不同权重情况下模型的学习能力。结果显示,在 5 个不同权重网络中,MLSSP_0.4 模型的准确率、敏感度和特异度均优于其他权重网络。实验结果证明,当 α 取 0.4 时,MLSSP 模型能够达到较好的分类性能,为脑出血分类的进一步研究提供了基础。

3.5.2 不同模型的脑出血分类实验

为了对比不同模型对分类性能的影响,本实验对比了相同权重下 MLSSP 模型、Y-Net 模型、He 等^[16]提出的多任务学习模型以及 CNN 模型的准确率、敏感度和特异度,如表 3 所列。图 6 为上述模型的 ROC 曲线。

表 3 分类结果比较

Table 3 Comparison of classification results

方法	准确率/%	敏感度	特异度
MLSSP	95.00	0.905	1.000
Y-Net	93.75	0.881	1.000
He 等	93.75	0.905	0.974
CNN	92.50	0.881	0.974




图 6 ROC 曲线

Fig. 6 ROC curve

相同权重下,相比其他 3 种方法 MLSSP 模型在准确率、敏感度和特异度方面均达到最优。其分类准确率较 Y-Net 模型以及 He 等^[16]提出的多任务学习模型提升了 1.25%,较 CNN 分类准确率提升了 2.50%;其敏感度与 He 等^[16]提出的多任务学习模型持平,但较 Y-Net 模型和 CNN 提升了 2.38%;其特异度与 Y-Net 模型持平,但较其余两个模型提升了 2.63%;在 AUC 值方面,MLSSP 表现最优,达到 0.982。实验证明,同等数据下多任务学习模型优于单任务模型,同时 MLSSP 模型通过共享浅层有限的公有特征,并提取各个任务的私有特征,表现出比 Y-Net 模型与 He 等^[16]提出的多任务模型更优的分类结果。

结束语 目前,基于 CT 图像的脑出血分类和分割是对脑出血患者进行诊断的重要手段,传统的手动分割及分类方式不但耗时且带有较强主观性判断,因此计算机辅助诊断开始成为帮助医生提高诊断质量的新方法。本文提出一种共享浅层参数的多任务学习模型,使用了复合损失函数,探究了在

多任务学习过程中复合损失函数权重的设置策略。并利用3D-UNet模型和卷积神经网络的浅层参数共享,实现了在浅层网络进行公有特征共享,而在深层网络提取各自任务的私有特征中,得到比单任务模型及其余结构多任务模型更丰富的特征,实现了对脑出血CT图像进行病灶区域分割和对脑动静脉畸形出血与其他类型出血的分类,提升了语义分割和畸形-非畸形出血分类的性能,为计算机辅助脑出血诊断提供了新方法。但是本文中的损失函数权重也存在一定的缺点,即选取的权重不连续,最佳权重有可能存在于所选权重附近,这个问题未来可以通过权值自适应^[22]等方法进行改进。

参 考 文 献


- [1] BALAMI J S, BUCHAN A M. Complications of intracerebral haemorrhage[J]. *Lancet Neurology*, 2012, 11(1): 101-118.
- [2] ROH D, SUN C, SCHMIDT J M, et al. Primary intracerebral hemorrhage: a closer look at hypertension and cerebral amyloid angiopathy[J]. *Neurocritical Care*, 2018, 29(1): 77-83.
- [3] FUKUDA K, MAJUMDAR M, MASOUD H, et al. Multicenter assessment of morbidity associated with cerebral arteriovenous malformation hemorrhages[J]. *Journal of NeuroInterventional Surgery*, 2017, 9(7): 664-668.
- [4] WANG Z F, YIN M L, LIU S, et al. Microsurgical treatment of cerebral arteriovenous malformation in children[J]. *Journal of Clinical Neurosurgery*, 2020, 17(2): 171-175, 181.
- [5] DING Z J, ZHANG X. The role of CT angiography in preoperative diagnosis and surgical evaluation of cerebral arteriovenous malformations and intracerebral hematoma[J]. *Chinese Clinical Doctor*, 2020, 48(5): 582-585.
- [6] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 39(4): 640-651.
- [7] RONNEBERGER O, FISCHER P, BROX T, et al. U-Net: convolutional networks for biomedical image segmentation[C]// *Medical Image Computing and Computer-Assisted Intervention*. 2015: 234-241.
- [8] DHAR R, FALCONE G J, CHEN Y, et al. Deep learning for automated measurement of hemorrhage and perihematomal edema in supratentorial intracerebral hemorrhage[J]. *Stroke*, 2020, 51(2): 648-651.
- [9] IRONSIDE N, CHEN C, MUTASA S, et al. Fully automated segmentation algorithm for perihematomal edema volumetry after spontaneous intracerebral hemorrhage[J]. *Stroke*, 2020, 51(3): 815-823.
- [10] YE Z Y, WU M L. Choroidal Neovascularization Segmentation Combining Temporal Supervision and Attention Mechanism[J]. *Computer Science*, 2021, 48(8): 118-124.
- [11] WANG T, LEI Y, TIAN S, et al. Learning-based automatic segmentation of arteriovenous malformations on contrast CT images in brain stereotactic radiosurgery[J]. *Medical Physics*, 2019, 46(7): 3133-3141.
- [12] CICEK O, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse an-

notation[J]. *arXiv: Computer Vision and Pattern Recognition*, 2016.

- [13] HAMIDIAN S, SAHINER B, PETRICK N, et al. 3D convolutional neural network for automatic detection of lung nodules in chest CT[J]. *Proceedings of SPIE*, 2017, 10134: 1013409.
- [14] GAO X W, HUI R, TIAN Z, et al. Classification of CT brain images based on deep learning networks[J]. *Computer Methods and Programs in Biomedicine*, 2017, 138: 49-56.
- [15] SILVA G L, VALENTE T L, SILVA A C, et al. Convolutional neural network-based PSO for lung nodule false positive reduction on CT images[J]. *Computer Methods and Programs in Biomedicine*, 2018: 109-118.
- [16] HE T, HU J, SONG Y, et al. Multi-task learning for the segmentation of organs at risk with label dependence[J]. *Medical Image Analysis*, 2020.
- [17] MEHTA S, MERCAN E, BARTLETT J, et al. Y-Net: joint segmentation and classification for diagnosis of breast biopsy images[J]. *arXiv*: 1806.01313.
- [18] ZHANG Y, ZHANG B, LIANG F, et al. Radiomics features on non-contrast-enhanced CT scan can precisely classify AVM-related hematomas from other spontaneous intraparenchymal hematoma types[J]. *European Radiology*, 2018, 29(4): 2157-2165.
- [19] NAJM M, KUANG H, FEDERICO A, et al. Automated brain extraction from head CT and CTA images using convex optimization with shape propagation[J]. *Computer Methods and Programs in Biomedicine*, 2019, 176: 1-8.
- [20] QIU W, YUAN J, UKWATTA E, et al. Prostate segmentation: an efficient convex optimization approach with axial symmetry using 3-D TRUS and MR images[J]. *IEEE Transactions on Medical Imaging*, 2014, 33(4): 947-960.
- [21] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]// *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*. 2015: 1206-1034.
- [22] LIU M, LI F, YAN H, et al. A multi-model deep convolutional neural network for automatic hippocampus segmentation and classification in Alzheimer's disease[J]. *NeuroImage*, 2019, 208: 116459.



ZHAO Kai, born in 1994, postgraduate. His main research interests include deep learning and medical imaging analysis.



XIANG Jie, born in 1970, Ph.D, professor, Ph.D supervisor, is a member of China Computer Federation. Her main research interests include medical imaging analysis and neuroimaging.