

联邦异质性数据下半监督颈椎 MRI 分割模型

潘恩元, 钟原*, 李平

(西南石油大学计算机科学学院, 四川 成都 610500)

摘要: 利用分割的医学图像进行诊断在临床和医学研究上是一种有效的辅助方法,但由于医学图像的隐私性、分散性和标注困难等问题严重影响了其实际应用效果。对颈椎磁共振成像(MRI)图像分割来说,其图像数据获取更困难,且标注成本高昂,颈椎分割模型在面对不同来源的异质性数据时难以有效提取颈椎细节信息。因此,在联邦学习场景下,针对标注信息缺少以及数据异质性导致分割精度下降的问题,提出一种基于标签分离与引导的多尺度半监督分割网络 M-FedLO。M-FedLO 通过标签分离的方式分别对椎块与椎间盘进行分割,同时实现多尺度输出,使得椎块与椎间盘的边缘信息得到进一步提取,更好地分离出椎块与椎间盘。在联邦“全局+本地”的模式下,利用全局模型的标签引导,使本地模型在无标签数据上提取的特征与全局模型逼近一致,从而增强本地模型对无标签数据的利用。同时使用随机权重平均(SWA)算法对参数进行优化,缓解模型权重震荡问题,提升模型泛化能力。实验结果表明,与半监督基准分割模型相比,提出的模型不仅在非异质性上的颈椎 MRI 医学图像分割效果上取得一定的提升,而且在异质性的颈椎图像上也具有较好的成果。在颈椎数据集上与实验结果最好的 ICT 模型相比较,Disc 相似性系数(DSC)指标达到 86.86%,提升了 1.72 个百分点。

关键词: 颈椎分割;联邦学习;异质性数据;标签分离;多尺度;标签引导

源代码链接: <https://github.com/panyuan/M-FedLO>

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0068283

Semi-Supervised Cervical Spine MRI Segmentation Model in Federated Heterogeneous Data

PAN Enyuan, ZHONG Yuan*, LI Ping

(School of Computer Science, Southwest Petroleum University, Chengdu 610500, Sichuan, China)

【Abstract】 Segmented medical images for diagnosis serve as an effective auxiliary method in clinical and medical research. However, challenges such as privacy concerns, data dispersion, and labeling difficulties hinder their practical application. For example, in the case of cervical spine Magnetic Resonance Imaging (MRI) image segmentation, it is more challenging to obtain image data, and labeling costs are high. It is difficult for the cervical spine segmentation model to effectively extract detailed cervical spine information when encountering heterogeneous data from different sources. Therefore, in the federated learning scenario, this paper proposes M-FedLO. It is a multi-scale semi-supervised segmentation network based on label separation and bootstrapping. It aims to address the challenges of limited labeled information and reduced accuracy when handling heterogeneous data. M-FedLO employs label separation to separately segment the vertebrae and intervertebral discs while achieving multi-scale outputs. This allows for further edge information extraction and better separation between vertebral blocks and intervertebral discs. In the "global + local" mode of federated learning, the labels from the global model guide the local models. This ensures that the features extracted by the local models from unlabeled data approximate those of the global model. This, in turn, enhances the utilization of unlabeled data by the local models. Additionally, the approach uses Stochastic Weight Averaging(SWA) to optimize the parameters to alleviate model weight oscillation issues and enhance the model's generalization capability. The experimental results demonstrate that the proposed model outperforms the semi-supervised baseline segmentation models in the segmentation of non-heterogeneous cervical spine MRI medical images and heterogeneous cervical spine images. Specifically, compared with the best-performing ICT model on the cervical spine dataset, the proposed approach achieves an improvement in the Dice Similarity Coefficient(DSC) metric to 86.86%. This represents an enhancement by 1.72 percentage points.

【Key words】 cervical spine segmentation; federated learning; heterogeneous data; label separation; multi-scale; label-guided

收稿日期: 2023-08-24 修回日期: 2023-10-16

基金项目: 国家自然科学基金(62276099);四川省自然科学基金面上项目(2023NSFSC0501);西南石油大学创新基金(642)。

通信作者 E-mail: *strangeryy0202@163.com

0 引言

颈椎综合症^[1]是一种常见的颈椎疾病,其特征是颈脊髓、神经根和椎动脉的压迫导致相关功能障碍。磁共振成像(MRI)广泛应用于临床实践中,清晰的细节有助于医生准确诊断和制定治疗方案。然而,颈椎 MRI 图像的解析仍具挑战性,由于图像中的组织密度、对比度和噪声等因素的影响,人工提取和分割感兴趣区域变得复杂且耗时。在临床实践中,准确且高效地对颈椎 MRI 图像进行分割,对于病变检测、骨折判断和手术规划等具有重要意义。

近年来,计算机辅助分析技术在医学图像处理领域展现出巨大潜力^[2-3],基于深度学习的方法成为医学图像研究分析的趋势。U-Net 作为编码器-解码器结构的卷积神经网络,被广泛应用于医学图像分割^[4]、医学图像分类^[5]、医学图像生成^[6]等领域^[7]。对于 CT 和 MRI 的脊柱图像分割,标准的 U-Net 模型可在训练过程中使用增强的数据^[8]提高训练效果。也有研究人员使用交叉注意力和关键点识别辅助学习的分割网络^[9]来提高网络的泛化能力和分割精度。基于生成对抗网络(GAN)^[10]的循环 GAN,实现了椎间盘、椎骨以及神经孔的分割。此外,DGMSNet^[11]通过检测引导和混合监督的方法,实现了对 MRI 图像中脊柱的自动分割。然而,模型分割结果的精确程度在很大程度上受限于可用的训练数据量以及大量且精准的标注信息。医学图像的标注是一项耗时且昂贵的工作,导致许多可用的医学图像缺少优质的标签。因此,使用半监督学习方法可以在有限的标注信息下最大程度地提高模型的分割质量。也有研究人员基于半监督学习的脊柱分割框架,在 2D 和 3D 的数据集上展现出了较高的性能^[12]。此外,由于医学图像的隐私性,获取足够数量的影像数据也是非常困难的。来自多机构的数据进行集中式学习成为了一种思路,但由于检测设备和操作方式的差异,可能导致拍摄的图像存在非独立同分布的情况,即存在数据异构性问题。同时,由于颈椎的结构信息复杂,这使得颈椎图像分割面临更加困难的异质性问题,难以确保分割精度。

为了解决上述问题,提升异质性的颈椎 MRI 医学图像的分割精度,本文提出一种联邦学习模式下基于 U-Net 的半监督分割方法(M-FedLO)。该方法基于 U-Net,利用联邦学习的全局模型来对伪标签进行引导,并使用随机权重平均(SWA)算法^[13]获得更高鲁棒性的模型。本文的主要创新点包括:

1)在联邦学习框架下,采用基于 U-Net 的编码器进行特征提取,通过两个解码器分别融合椎块和椎间盘特征,并输出多尺度的结果,以此来充分捕捉不同分割对象的数据特征。

2)针对无标签的数据,利用联邦学习中的全局模型来生成伪标签进行标签引导,并与有标签的数据进行一致性检验与不确定性纠正,使得局部模型不断靠近全局模型,有效提升整体模型对异质性图像的分割效果。

3)在训练后期,使用随机权重平均对模型参数进行平均,更好地适应异质性数据,提升模型的鲁棒性与分割性能。

1 相关工作

1.1 联邦学习

目前,联邦学习^[14]是一种在分布式环境下进行机器学习的方法,其中多个客户端共同训练模型而不需要共享原始数据。在保护图像隐私性的同时,可有效提升模型对异质性数据的分割效果。结合个体分布和群体分布的联邦学习算法,可缓解由于异质性的数据带来的客户端漂移现象^[15]。每个客户端在本地维护其数据,并通过交流模型更新来实现知识的聚合。在面对非独立同分布的数据时,联邦平均(FedAvg)算法^[16]是一种简单且有效的联邦学习算法,可以使得每个客户端在其私有数据集上独立地进行模型训练和更新,不仅提高了模型的性能,而且同时也保护了数据隐私。

在联邦学习算法中,各个客户端协同优化中央深度学习模型的权重,每个客户端利用自己的私有数据进行训练,并通过伪分布式模拟多个客户端的情况。在每个轮次中,FedAvg 随机选择 K 个客户端的子集,并向它们发送中心模型的当前参数 w_t 。选定的客户端使用其本地数据集,在固定数量的训练轮次内对参数进行优化,并将优化后的参数上传回中央深度学习模型。随后,通过对局部优化参数进行加权平均更新中心模型的参数。不断地重复这个过程,直到全局模型收敛。

此外,还有一些其他的联邦学习方法,旨在充分利用具有异构性的数据解决多中心数据共享的问题以及提升模型性能。文献[17]提出的 SplitAVG 方法通过结合异质感知的聚类算法,动态地为不同数据源分配权重,从而提高医学图像处理任务的性能和泛化能力。文献[18]提出基于隐私保护联邦学习和领域适应的方法,用于多中心功能磁共振成像(fMRI)分析,以解决多中心数据共享的隐私和域偏

移问题,并在 ABIDE 数据集上获得了较好的实验结果。此外,文献[19]提出了一种针对 U-Net 图像分割模型的联邦蒸馏优化算法,结合联邦学习和知识蒸馏的概念,在分布式数据上训练多个 U-Net 模型,并使用蒸馏技术提升整体模型性能。

1.2 医学图像分割

医学图像分割^[20]是指将医学图像中感兴趣的区域准确地分离出来的过程。由于医学图像的标注需要医学专家的参与,这是一项耗时且昂贵的工作,这使得可用的医学图像往往缺乏足够的标签,限制了传统有监督学习方法在医学图像分析中的应用。因此,半监督学习方法成为解决这一问题的重要途径之一。在半监督医学图像分割领域,研究者提出了一系列方法,旨在利用有限的标签数据和大量的无标签数据来提高分割的准确性和鲁棒性。半监督医学图像分割方法的核心思想是通过结合有标签数据和无标签数据来学习具有强泛化能力的分割模型。在这些方法中,有标签数据通常用于训练有监督的分割模型,而无标签数据则用于辅助模型的训练和提高鲁棒性。例如,文献[21]提出的教师-学生模型(MT),通过平均学生网络和老师网络的预测结果,实现对无标签数据的分割任务,并利用有标签数据进行监督学习,提高分割性能。文献[22]提出的熵最小化(EM)方法通过最小化无标签数据的预测熵,引入额外的类内一致性,在缺少标签的情况下提高分割结果的准确性。文献[23]提出的交叉伪监督(CPS)方法利用预测的伪标签来训练模型,通过伪标签与真实标签的一致性损失函数共同优化分割任务,从而提高模型的性能。文献[24]提出的插值一致性训练(ICT)使用线性插值策略在无标签样本和带标签样本之间构建虚拟样本,通过保持虚拟样本与真实样本之间的一致性来进行分割任务的训练。文献[25]提出不确定性纠正金字塔一致性(URPC)方法通过使用分层一致性约束来减轻无标签数据的噪声影响,并引入不确定性估计,提高不确定性较大区域分割结果的准确性。

此外,文献[26]提出了一种基于联邦学习和伪标签去噪的方法用于医学图像分割任务。通过基于从标签客户端学习的嵌入式知识,开发无标签客户端的联合伪标签策略,能够提高分割准确性和泛化能力。文献[27]提出一种新的客户端间关系匹配方案,改进了传统的一致性正则化方法,以利用标签和无标签客户端的数据来学习联邦模型,减轻无标签客户端的任务知识不足,并提高分类性能。

2 方法

2.1 M-FedLO 联邦学习策略

为了提升分布式条件下非独立同分布的异质数据的半监督分割效果,本文提出了一种基于联邦学习的半监督分割方法 M-FedLO,其联邦运行模式如图 1 所示(彩色效果见《计算机工程》官网 HTML 版,下同)。




图 1 M-FedLO 方法的联邦运行模式

Fig. 1 Federated operation mode of M-FedLO method

来自不同的医疗机构或检测设备(客户端)的颈椎 MRI 图像可能具有不同的扫描参数、分辨率和图像质量,这使得数据的特征表示和集中式模型的训练变得复杂而困难。与传统的集中式模型训练相比,M-FedLO 利用联邦学习的优势,允许在每个客户端独立训练模型,更好地适应其数据分布。同时,通过服务端模型从不同客户端模型中学习更全面和综合的特征表示,M-FedLO 能够提高模型的泛化性能。这种联邦学习的模式确保了数据不离开客户端,有效保护个人隐私,并解决了由于本地样本数量倾斜和特征分布倾斜而带来的异质性问题。

基于上述联邦学习模式,M-FedLO 半监督分割方法主要由标签分离的多尺度分割网络、联邦学习下全局模型的标签引导和 SWA 三部分组成。其中,多尺度分割网络获得了更加精确的边缘信息,服务器端的全局模型生成的标签能为客户端的本地模型提供更准确的标签信息,优化本地模型使其接近全局模型的性能,加快收敛速度,而 SWA 模块可进一步提升模型的泛化性与鲁棒性。

M-FedLO 的伪代码如算法 1 所示。

算法 1 训练策略

输入 客户端学习率初始值 L_i ; 客户端训练迭代次数 $Epoch_L$; 全局训练迭代次数 $Epoch_G$; 随机选择客户端数量

K :被选择的客户端集合 Clients;初始模型聚合权重 W_k ; 初始聚合模型 M

输出 聚合模型 M_{SWA}

```

1. 图像预处理
2. 根据客户端数量初始化  $Epoch_L$ ,  $Epoch_G$ 
3. for  $e$  in range( $Epoch_G$ ) do
4.   Clients = random.sample(all_clients, K) //随机
//选择 K 个客户端加入 Clients
5.   for  $c$  in Clients do
6.      $c = M$  //将聚合模型赋予选择的所有客户端
7.     for  $i$  in range( $Epoch_L$ ) do
8.        $pred_1, pred_2 = local\_model(data)$  //调用局
//部模型获得椎块与椎间盘的预测结果
9.        $un\_pred_1, un\_pred_2 = global\_model(data_{unlabel})$ 
//使用全局模型对无标签数据进行预测
10.       $Loss = \lambda \times Loss_1(pred_1, un\_pred_1, data) +$ 
 $(1 - \lambda) \times Loss_2(pred_2, un\_pred_2, data)$  //分别对椎块和椎间

```

//盘计算联合损失

```

11.       $c_{new} = train\_model(c)$  //通过客户端数据训
//练得到模型  $c_{new}$ 

```

```

12.       $diff = c_{new} - c$  //获取模型差异

```

```

13.    end for

```

```

14.     $M = W_k \times diff + M$ 

```

```

15.     $M_{SWA} = \frac{1}{T} \sum_{i=1}^T M_i$  //训练末期,使用 SWA 聚合多

```

//个全局模型

```

16.  end for

```

```

17. end for

```

2.2 标签分离的多尺度分割网络

椎块与椎间盘之间交错相连,使得边缘部分的提取变得尤为困难。并且,椎块与椎间盘的尺寸不同,因此使用标签分离的多尺度分割网络可以更有效地获得分割结果。M-FedLO 中多尺度分割网络主体结构如图 2 所示。




图 2 M-FedLO 模型结构示例

Fig.2 Example of M-FedLO model structure

在该分割网络中,编码器部分由连续的卷积层和下采样层组成,用于逐步提取图像的特征并降低特征图的尺寸。这些层的堆叠使得网络可以学习到不同的抽象特征,并构建图像的上下文信息。

解码器部分由上采样层和卷积层组成,用于将编码器提取的特征图进行逐步恢复和重建。在上采样过程中,特征图的尺寸逐渐增加,同时进行特征拼接操作将其与对应的编码器层的特征图进行连接。这种跨层连接使得解码器可以利用编码器中丰富的上下文信息和低级别的细节特征,从而提高分割结

果的准确性和细节保留能力。由于椎块与相邻椎间盘之间上下边缘紧密相连,本文采用了两个解码器分别对椎块与椎间盘进行分割预测。通过分别训练两个任务的解码器,模型能够更加准确地捕捉到不同结构的特征信息,从而提高分割精度和鲁棒性。在获得椎块和椎间盘各自的分割结果后,将两者进行融合时,对于重叠部分采取设置概率最高的椎块或椎间盘的策略。

此外,本文引入了多尺度的输出策略,以更全面地利用单个模型在不同尺度上的预测差异。在 U-

Net 网络的解码器部分,本文选择使用最上面两个上采样层进行输出,并舍弃最下面的两个上采样层。这样可以避免过于剧烈的特征变换,在特征对齐过程中使得变换更加平滑以及在模型训练过程中避免梯度消失的问题,从而提升分割结果的一致性和稳定性。

2.3 联邦学习下全局模型的标签引导

面临由于样本数量、特征分布而具有异质性的数据,传统的联邦学习基于隐私和数据安全的考虑,参与者不会共享原始数据,而是共享模型参数。因此,对于单个参与者而言,无法利用其他参与者的标签数据进行训练。为了更好地利用其他参与者的参数,兼具安全性的考量,因此加深对全局模型的使用。全局模型比本地模型能学习到更为丰富的表征,通过将全局模型的预测结果作为本地模型无标签数据的标签,可以对比两个模型的性能和效果,以使本地模型更为接近全局模型,如图 3 所示。




图 3 模型对比示例

Fig.3 Model comparison example

首先,服务端向各个客户端发放模型参数 w^g ,各个客户端使用接收到的全局模型参数在其私有数据集上进行训练,得到本地模型参数 w^l 。其次,使用全局模型参数 w^g 和本地模型参数 w^l 对相同无标签图像进行预测,分别得到全局预测结果 Z_{global} 和本地预测结果 Z_{local} 。最后,将全局预测结果 Z_{global} 作为无标签数据的标签,计算交叉熵损失。通过最小化交叉熵损失,本地模型的参数可以不断更新,以逐渐接近全局模型。

将全局模型作为标签引导,能够利用到其他参与者的模型参数来改善本地模型的性能,同时保护了数据的隐私和安全性。通过与全局模型进行比较,本地模型可以更好地融合不同数据源的信息,从而提高预测的准确性和泛化能力。

2.4 随即权重平均优化

在训练到一定轮次后,为了缓解权重震荡问题并提升模型的泛化能力,本文采用 SWA 算法来对

全局模型进行权重平均。由于颈椎 MRI 图像结构信息较为复杂,椎块与椎间盘的尺度也存在差异,因此在模型训练的初期,难以高效地提取到图像的深度特征信息。

SWA 算法通过在训练过程中周期性地对历史模型权重进行平均,将这些平均权重作为最终模型的权重。这种平均操作可以提高模型的稳定性和泛化能力。SWA 的使用可以有效地加强模型的鲁棒性,更好地应对数据的不确定性,并提升模型在测试集上的性能。SWA 算法对模型参数的更新如式(1)所示:

$$\theta_{SWA} = \frac{1}{T} \sum_{i=1}^T \theta_i \quad (1)$$

式中: θ_{SWA} 表示经过随机权重平均之后的模型参数; T 表示参与随机权重平均的模型数量; θ_i 表示第 i 个模型的模型权重。

2.5 损失函数

基于多任务的考量,本文所使用的损失函数包含两部分,一部分为椎块的损失函数,另一部分为椎间盘的损失函数。具体如式(2)所示:

$$\text{Loss} = \lambda \times \text{Loss1} + (1 - \lambda) \text{Loss2} \quad (2)$$

式中: λ 表示损失函数的权重;Loss1 表示椎块的损失函数;Loss2 表示椎间盘的损失函数。

考虑到有标签数据集和无标签数据集的不同情况,椎块的损失函数由两部分组成:作用在有标注样本上的有监督训练损失 L_{sup} 与应用于包含无标注样本的全部训练样本的无监督训练损失 L_{unsup} 。

对于有标签的数据集,模型采用 Dice 损失 L_{dice} 和交叉熵损失 L_{ce} 的组合作为监督损失 L_{sup} ,多尺度特征分别与标签计算损失,如式(3)所示:

$$L_{sup} = \frac{1}{S} \sum_{s=0}^{s-1} \frac{L_{dice}(p_s, y) + L_{ce}(p_s, y)}{2} \quad (3)$$

式中: L_{sup} 表示有标签数据的分割损失函数; S 表示解码器模块的输出层数; p_s 表示第 s 层的输出; y 表示标签。

对于无标签的颈椎 MRI 图像,使用多尺度特征计算一致性损失,包括不确定性纠正函数及不确定性最小化项。同时,使用全局模型的标签引导,将全局模型对无标签数据的预测作为其标签,如式(4)所示:

$$L_{unsup} = \left[\frac{1}{S} \frac{\sum_{s=0}^{s-1} \|p_s - p_{avg}\|_2 \cdot w_s}{\sum_{s=0}^{s-1} w_s} + \frac{1}{S} \sum_{s=0}^{s-1} D_s + L_{ce}(p_{global}, p_{local}) \right] \cdot \frac{1}{3} \quad (4)$$

式中: L_{unsup} 表示无标签数据的分割损失函数; 第一项表示不确定性最小化项; 第二项表示不确定性纠正函数; 第三项表示模型对比; D_s 表示平均尺度输出和不同尺度输出之间的 KL 散度; p_s 表示解码器模块第 s 层的输出; p_{avg} 表示解码器模块第 s 层的输出的平均值; w_s^i 表示 KL 散度的指数运算。

对于椎间盘的损失函数, 类似于椎块的处理方式, 具体的形式和原理与椎块的损失函数相似。

3 实验与结果分析

3.1 实验条件与数据概况

实验基于 PyTorch 实现, 硬件环境为: NVIDIA GeForce RTX 3090 显卡; RAM 为 24 GB; CPU 型号为 Intel® Core™ i9-10900KF CPU@3.70 GHz。软件环境为: PyTorch 1.10.0 + cu111; Python 3.8.12; CUDA 11.6; CUDNN 8.4.2。

在式(2)中, λ 表示椎块与椎间盘间损失函数的权重, 根据实验经验, λ 的取值范围在 0~1 之间。 λ 初始化为 0.1, 并以 0.1 为间隔取值。图 4 为 λ 取不同值时模型训练后在测试集上的表现, 可以观察到当 $\lambda=0.7$ 时, 分割网络效果最好, 因此在后续的分割实验中, 在 M-FedLO 中 λ 均设置为 0.7。




图 4 λ 取不同值时的性能

Fig. 4 Performance for different values of λ

本文使用的颈椎 MRI 数据集包含两部分: 真实图像数据集和生成图像数据集。真实图像数据集来源于颈椎 MRI T2 矢状切片图像, 总共包括 175 例病例。对于每个病例, 从十多张切片中选择了椎块和椎间盘显影效果最佳的两张切片, 共计 350 张图像。这些切片都包含了关于椎块和椎间盘的标注信息, 标注信息包括椎块、椎间盘和背景等。生成图像数据集基于 DDPM^[28], 使用非线性的噪声方案配合混合高斯噪声, 以及含有 Attention 模块的 ResUNet 模型而产生。生成数据作为无标签数据使用, 以缓解分割任务中训练样本不足的问题。

3.2 异质性数据模拟

本实验为了模拟联邦分布式场景下的异质数据, 首先构建如图 1 所示的模拟场景, 并将数据集划分到 3 个不同的客户端, 同时分析原始数据集之间的分布情况, 随后对数据集进行处理以确保获得异质性数据, 实现联邦场景下对异质图像数据的分割与评估。划分方式如表 1 所示。

表 1 数据划分与客户端说明

数据集	图像	训练集/张	测试集/张	操作	客户端
Dataset 1	真实图像	70	35	无	Client 1
	生成图像	70	—		
Dataset 2	真实图像	80	35	无	Client 2
	生成图像	80	—		
Dataset 3	真实图像	85	35	无	Client 3
	生成图像	85	—		

为验证构建在不同客户端下的 3 个独立数据集之间的分布关系, 对数据进行基于其数据集归属的分类模型的训练及测试, 以验证处于 3 个客户端上的数据集之间的相似性, 如表 2 所示。

表 2 独立同分布数据分类结果

Table 2 Classification results for independently identically distributed data

数据集	准确率		
	Dataset 1	Dataset 2	Dataset 3
Dataset 1	1.000 0	0.567 6	0.512 50
Dataset 2	0.567 6	1.000 0	0.535 70
Dataset 3	0.512 5	0.535 7	1.000 00

由表 2 可以看出, 3 个数据集之间分类准确率相对较低, 分类结果约等于随机猜测。通过数据从属客户端的分类结果可以看出, 不同客户端上的数据集之间存在一定的相似, 不同客户端上的数据集并不独立, 3 个数据集具有相同的分布。通过单纯的数据拆分, 数据集之间并不具有独立同分布属性。

因此, 通过裁剪、加噪以及风格转换^[29]等操作, 分别将各个数据集进行修改, 其中将 Client3 中的图像风格转换成公开的矢状面腰椎分割 MRI 数据集^[30]中的图像风格, 数据处理如表 3 所示。

表 3 数据处理与客户端说明

数据集	图像	训练集/张	测试集/张	操作	客户端
Dataset 1	真实图像	70	35	无	Client 1
	生成图像	70	—		
Dataset 2	真实图像	80	35	裁剪+ 加噪	Client 2
	生成图像	80	—		
Dataset 3	真实图像	85	35	裁剪+ 风格转换	Client 3
	生成图像	85	—		

经过分类模型的实验验证,各数据集两两之间的差异性如表 4 所示。

表 4 非独立同分布数据分类结果

Table 4 Classification results for non-independently identically distributed data

数据集	准确率		
	Dataset 1	Dataset 2	Dataset 3
Dataset 1	1.000	1.000	1.000
Dataset 2	1.000	1.000	1.000
Dataset 3	1.000	1.000	1.000

由表 4 可以看出,经过处理后的分类网络具有较高的准确率,可以准确地识别每张图像所属的客户端。这表明分类网络能够很好地对不同客户端数据进行分类,高数值的分类准确性说明位于不同客户端上的数据集之间存在巨大差异性,3 个数据集处于具有较强的非独立同分布性,为后续实验提供了数据环境。

3.3 集中式图像分割实验

本实验测试和分析了在集中式模式下,当图像数据为异质性数据时对模型分割性能的影响。

实验设置如下:使用 245 张真实图像与 245 张生成图像作为训练集,其中 49 张真实图像含有标注信息,35 张图像作为验证集,70 张图像作为测试集。优化器统一使用 AdamW,损失函数包含两部分:有标签的数据使用交叉熵损失和 Dice 损失的平均值;无标签的图像使用一致性损失。批处理大小 Batch 统一设置为 18,每轮次使用 6 张标签,模型的迭代次数 Epoch 统一设置为 350 次。

使用 Dice 相似性系数(DSC)^[31]和平均交并比(MIoU)^[32]作为评价指标。采用教师-学生模型(MT)、熵最小化(EM)、交叉伪监督(CPS)、插值一致性训练(ICT)和确定性纠正金字塔一致性(URPC)等半监督分割方法对椎块和椎间盘进行分割。同时在 URPC 上进行修改,使其更适应颈椎 MRI 图像,并使用 U-Net 网络作为它们的基础网络,颈椎 MRI 图像样本扩充后椎块和椎间盘分割性能的测试结果对比如表 5 所示(其中,加粗数字为最优值,±号后面数字为方差)。

如表 5 所示,当数据集未经过异质性处理时,使用不同的半监督方法都可以取得良好的效果。尤其是修改后的 Light-URPC,DSC 和 MIoU 指标分别比次优的 ICT 高 1.16 和 1.37 个百分点。

为了充分说明各个数据集之间的异质性,将这些经过处理后的图像进行分割实验。实验设置如下:将 245 张真实图像以及 245 张生成图像作为训

表 5 不同模型集中式学习时的性能对比

Table 5 Performance comparisons of different models in centralized learning

模型	真实图像/ 张	生成图像/ 张	DSC/%	MIoU/%
MT	245	245	84.03±0.26	75.77±0.26
EM	245	245	83.60±0.25	74.05±2.72
CPS	245	245	82.56±0.33	74.19±0.47
ICT	245	245	85.03±0.21	77.25±0.13
Light-URPC	245	245	86.19±0.28	78.62±0.24

练集,其中 49 张真实图像含有标注信息,105 张图像作为测试集。该测试集为上一个未经过异质性处理的分割实验的验证集与测试集的集合。优化器与损失函数同上,Light-URPC 使用第 2.5 节中所提损失函数。批处理大小 Batch 统一设置为 20,每轮次使用 2 张标签,模型的迭代次数 Epoch 统一设置为 350 次。分割结果如表 6 所示。

表 6 异质性数据下不同分割模型的性能对比

Table 6 Performance comparisons of different segmentation models under heterogeneous data

模型	真实图像/张	生成图像/张	DSC/%	MIoU/%
MT	245	245	82.36±1.64	74.35±1.9
EM	245	245	82.97±3.07	74.74±4.33
CPS	245	245	82.64±2.17	74.35±2.60
ICT	245	245	83.66±1.12	75.56±1.81
Light-URPC	245	245	85.55±1.10	77.83±1.19

如表 6 所示,在集中式学习中,异质性的数据给分割模型带来了挑战,使得各个分割模型的稳定性和准确性大幅下降。其中,Light-URPC 模型在面临异质性的数据时,DSC 指标降低 0.64 个百分点,MIoU 降低 0.79 个百分点。尽管其依然保持了优良的性能,但也受到了较大的扰动影响。

3.4 联邦异质数据下模型性能实验

本实验使用第 3.2 节中经过异质性处理后的数据集,按照图 1 所示构建伪分布式的联邦学习环境。

实验设置如下:将数据集划分给 3 个客户端,对于客户端 1 而言,训练集包含 70 张真实图像和 70 张生成图像,测试集包含 35 张真实图像;对于客户端 2 而言,训练集为 80 张真实图像和 80 张生成图像,测试集包含 35 张真实图像;对于客户端 3 而言,训练集为 85 张真实图像和 85 张生成图像,测试集包含 35 张真实图像。为了避免本地模型出现过拟合以及利于全局模型的收敛,对于客户端,本地 Epoch 设置为 2,全局 Epoch 设置为 200。其余同上所述。不同分割模型在部分病例的可视化结果如图 5 所示,分割结果如表 7 所示。




图 5 不同模型在颈椎数据集上的可视化结果

Fig.5 Visualization results of different models on the cervical vertebra dataset

表 7 联邦学习下不同分割模型在异质数据下的性能对比

Table 7 Performance comparisons of different segmentation models in heterogeneous data under federated learning

模型	真实图像/ 张	生成图像/ 张	DSC/%	MIoU/%
MT	245	245	84.19±0.31	75.8±0.26
EM	245	245	83.59±0.11	74.94±0.04
CPS	245	245	84.78±0.19	76.33±0.05
ICT	245	245	85.14±0.02	77.07±0.16
M-FedLO	245	245	86.86±0.03	79.19±0.02

如表 7 所示,与其他模型相比,M-FedLO 在联邦学习的场景下取得了最佳的效果,其在 DSC 指标和 MIoU 指标上表现出色,证明了 M-FedLO 在当前异质性数据集上的可用性。相较于 MT、EM、CPS 和 ICT 等模型,M-FedLO 的细节部分与标注最为接近,对于边缘部分,M-FedLO 既不会像 CPS 一样漏掉多余部分,也不会同 EM 一般完全地将边缘部分纳入到分割区域。M-FedLO 的 DSC 指标分别提高了 2.67、3.27、1.82 和 1.72 个百分点。而在 MIoU 指标上,M-FedLO 超过了其他模型,分别提

高了 3.39、4.25、2.86 和 2.12 个百分点。同时 M-FedLO 在 DSC 上的方差较小,仅比 ICT 低 0.01 个百分点,而 MIoU 的方差最小,表明模型十分稳定。为了展示各个模型的分割性能,本文选择了这些模型在一张实例下的分割效果,对比结果如图 5 所示。可以看出,M-FedLO 的效果更加优异。与传统的集中式学习相比,联邦学习在面对异质性的数据时,不仅模型的分割性能得到了提升,稳定性也得到了优化。同时,因为联邦学习具有的安全机制,数据的隐私也得到了保障。

3.5 消融实验

根据 M-FedLO 的多个模块设计,对结构中连续叠加的多个模块进行了不同的实验来验证多模块的有效性,证明各模块对模型的性能改善。各模块叠加过程实验模块有效性如图 6 所示。其中,A1 表示基于多尺度的输出引入多任务,A2 表示基于 A1 引入模型对比,A3 表示基于 A2 引入 SWA,mDSC 表示多个结果取平均,A+表示在基础模型上加了该部分。从图 6 可以看出,随着各模块的增加,模型的性能不断提高,且逐渐趋于较为稳定的状态。实验结果进一步验证了 M-FedLO 方法中各个模块的有效性。




图 6 模块叠加的性能变化

Fig.6 Performance changes in module stacking

4 结束语

本文提出了一种基于联邦学习场景下的半监督医学图像分割网络 M-FedLO, 用于实现颈椎 MRI 图像中椎块与椎间盘的准确分割。该方法通过构建多任务与多尺度输出, 并结合模型对比与 SWA 的优化, 实现颈椎 MRI 图像中椎体与椎间盘的精细分割。实验结果表明, 在联邦学习模式下, 相较于 MT、EM、CPS、ICT 等半监督分割方法, M-FedLO 在异质性颈椎 MRI 图像数据集上的分割性能取得了显著提升, 所获得的颈椎结构更加完整, 边缘部分也更加平滑。因此, 在联邦学习模式下, 本方法能够在保护数据隐私的同时进行有效的协作学习, 学习分布在不同客户端的异质数据的特征, 显著提升了分割效果和准确性, 为实现有效的协作学习和数据共享提供了可行性。下一步将继续关注和加强客户端与中心模型的交互安全性, 引入差分隐私等安全措施, 以确保模型参数的交互更加安全可靠。

参考文献

- [1] BADHIWALA J H, AHUJA C S, AKBAR M A, et al. Degenerative cervical myelopathy: update and future directions[J]. *Nature Reviews Neurology*, 2020, 16(2): 108-124.
- [2] TOH T S, DONDELINGER F, WANG D. Looking beyond the hype: applied AI and machine learning in translational medicine[J]. *EBioMedicine*, 2019, 47: 607-615.
- [3] 伍佳莉, 李东伦, 唐泳, 等. 人工智能辅助医学影像识别技术的应用研究进展[J]. *现代医药卫生*, 2022, 38(4): 603-607. WU J L, LI D L, TANG Y, et al. Research progress on the application of artificial intelligence aided medical image recognition technology[J]. *Journal of Modern Medicine & Health*, 2022, 38(4): 603-607. (in Chinese)
- [4] 刘文, 元文霞, 仲国强, 等. 基于 Concat-UNet 的食管癌肿瘤医学影像分割研究[J]. *计算机工程*, 2022, 48(12): 312-320. LIU W, QI W X, ZHONG G Q, et al. Research on medical image segmentation for esophageal cancer tumors based on concat-UNet[J]. *Computer Engineering*, 2022, 48(12): 312-320. (in Chinese)
- [5] 潘成成. 基于区域卷积神经网络的医学图像识别研究[D]. 贵阳: 贵州大学, 2020. PAN C C. Medical image recognition based on regional convolution neural network [D]. Guiyang: Guizhou University, 2020. (in Chinese)
- [6] KIM B, YE J C. Diffusion deformable model for 4D temporal medical image generation[C]//*Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention*. Berlin, Germany: Springer, 2022: 539-548.
- [7] 张相芬, 刘艳, 袁非牛. 基于倒金字塔深度神经网络的三维医学图像分割[J]. *计算机工程*, 2022, 48(12): 304-311. ZHANG X F, LIU Y, YUAN F N. 3D medical image segmentation based on inverted pyramid deep learning network[J]. *Computer Engineering*, 2022, 48(12): 304-311. (in Chinese)
- [8] KOLARIK M, BURGET R, RIHA K, et al. Suitability of CT and MRI imaging for automatic spine segmentation using deep learning[C]//*Proceedings of the 44th International Conference on Telecommunications and Signal Processing*. Washington D. C., USA: IEEE Press, 2021: 263-272.
- [9] LI H Y, WANG Z X, SHEN W, et al. SSCK-Net: spine segmentation in MRI based on cross attention and key-points recognition-assisted learner[J]. *Biomedical Signal Processing and Control*, 2023, 86: 105278.
- [10] HAN Z, WEI B, MERCADO A, et al. Spine-GAN: semantic segmentation of multiple spinal structures [J]. *Medical Image Analysis*, 2018, 50: 23-35.
- [11] PANG S M, PANG C L, SU Z H, et al. DGMSNet: spine segmentation for MR image by a detection-guided mixed-supervised segmentation network [J]. *Medical Image Analysis*, 2022, 75: 102261.
- [12] 张辰翰. 基于深度学习的脊柱 CT 图像分割[D]. 成都: 电子科技大学, 2021. ZHANG C H. Research on CT image segmentation of spine based on deep learning[D]. Chengdu: University of Electronic Science and Technology of China, 2021. (in Chinese)
- [13] 汤鹏. 基于 SU-SWA 与深度集成模型的皮肤病变分割与分类算法[D]. 长沙: 湖南大学, 2020. TANG P. Skin lesion segmentation and classification algorithm based on SU-SWA and deep ensemble model[D]. Changsha: Hunan University, 2020. (in Chinese)
- [14] 邹承明, 赵宁. 数据异质场景下的联邦学习模型校正与聚合[J]. *电子测量技术*, 2022, 45(20): 102-109. ZOU C M, ZHAO N. Model correction and aggregation in statistically heterogeneous federated learning[J]. *Electronic Measurement Technology*, 2022, 45(20): 102-109. (in Chinese)
- [15] 黄华. 异质性数据的联邦学习关键技术研究[D]. 西安: 西安电子科技大学, 2022. HUANG H. Research on key technologies of federated learning for heterogeneous data [D]. Xi'an: Xidian University, 2022. (in Chinese)
- [16] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[EB/OL]. [2023-07-20]. <https://arxiv.org/abs/1602.05629>.
- [17] ZHANG M, QU L Q, SINGH P, et al. SplitAVG: a heterogeneity-aware federated deep learning method for medical imaging[J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(9): 4635-4644.
- [18] LI X X, GU Y F, DVORNEK N, et al. Multi-site fMRI analysis using privacy-preserving federated learning and domain adaptation: abide results [J]. *Medical Image Analysis*, 2020, 65: 101765.
- [19] 林子谦, 樊重俊, 王琪. 一种 Unet 图像分割模型的联邦蒸馏

- 优化算法[J]. 小型微型计算机系统, 2023, 44(7): 1535-1541.
- LIN Z Q, FAN C J, WANG Q. Federal distillation optimization algorithm for unet image segmentation model[J]. Journal of Chinese Computer Systems, 2023, 44(7): 1535-1541. (in Chinese)
- [20] 邱越, 李秋秋, 王瑛, 等. 深度学习技术在医学图像分割中的应用[J]. 电脑知识与技术, 2022, 18(10): 74-75.
- QIU Y, LI Q Q, WANG Y, et al. Application of deep learning technology in medical image segmentation[J]. Computer Knowledge and Technology, 2022, 18(10): 74-75. (in Chinese)
- [21] TARVAINEN A, VALPOLA H. Mean teachers are better role models; weight-averaged consistency targets improve semi-supervised deep learning results[EB/OL]. [2023-07-20]. <https://arxiv.org/pdf/1703.01780>.
- [22] VU T H, JAIN H, BUCHER M, et al. ADVENT; adversarial entropy minimization for domain adaptation in semantic segmentation[C]// Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington D. C., USA; IEEE Press, 2019: 257-265.
- [23] CHEN X K, YUAN Y H, ZENG G, et al. Semi-supervised semantic segmentation with cross pseudo supervision[C]// Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington D. C., USA; IEEE Press, 2021: 2613-2622.
- [24] VERMA V, KAWAGUCHI K, LAMB A, et al. Interpolation consistency training for semi-supervised learning[J]. Neural Networks, 2022, 145: 90-106.
- [25] LUO X D, LIAO W J, CHEN J N, et al. Efficient semi-supervised gross target volume of nasopharyngeal carcinoma segmentation via uncertainty rectified pyramid consistency[C]// Proceedings of International Conference on Medical Image Computing and Computer Assisted Intervention. Berlin, Germany; Springer, 2021: 318-329.
- [26] QIU L, CHENG J R, GAO H X, et al. Federated semi-supervised learning for medical image segmentation via pseudo-label denoising[J]. IEEE Journal of Biomedical and Health Informatics, 2023, 27(10): 4672-4683.
- [27] LIU Q D, YANG H Z, DOU Q, et al. Federated semi-supervised medical image classification via inter-client relation matching[C]// Proceedings of International Conference on Medical Image Computing and Computer Assisted Intervention. Berlin, Germany; Springer, 2021: 325-335.
- [28] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[EB/OL]. [2023-07-20]. <https://arxiv.org/abs/2006.11239>.
- [29] LIU Z D, YANG X, GAO R, et al. Remove appearance shift for ultrasound image segmentation via fast and universal style transfer[C]// Proceedings of the 17th IEEE International Symposium on Biomedical Imaging. Washington D. C., USA; IEEE Press, 2020: 357-367.
- [30] MASOOD R F, HASSAN T, RAJA H, et al. A composite dataset of lumbar spine images with mid-sagittal view annotations and clinically significant spinal measurements[C]// Proceedings of the 2nd International Conference on Digital Futures and Transformative Technologies. Washington D. C., USA; IEEE Press, 2022: 125-134.
- [31] CARDENAS C E, MCCARROLL R E, COURT L E, et al. Deep learning algorithm for auto-delineation of high-risk oropharyngeal clinical target volumes with built-in dice similarity coefficient parameter optimization function[J]. International Journal of Radiation Oncology Biology Physics, 2018, 101(2): 468-478.
- [32] ZHAO S D, HAO G Z, ZHANG Y C, et al. A real-time semantic segmentation method of sheep carcass images based on ICNet[J]. Journal of Robotics, 2021, 2021: 8847984.

编辑 索书志