

一种基于生成对抗网络的无监督域自适应磁共振图像分割方法



孙玉波^{1,2}, 刘嘉男^{1,2}, 孙泽文³, 韩建达^{1,2,4}, 于宁波^{1,2,4}

1. 南开大学 人工智能学院 (天津 300350)
2. 南开大学 天津市智能机器人技术重点实验室 (天津 300350)
3. 北京大学第三医院 运动医学研究所 (北京 100083)
4. 南开大学 深圳研究院智能技术与机器人系统研究院 (广东深圳 518083)

【摘要】 智能医学图像分割方法正在快速地发展和应用,但面临着域转移挑战,即由于源域和目标域数据分布不同导致算法性能下降。为此,本文提出了一种基于生成对抗网络(GAN)的无监督端到端域自适应医学图像分割方法。设计网络训练调整模型,由分割网络和鉴别网络组成。分割网络以残差模块为基本模块,增加对特征的复用能力,降低模型优化难度,并将分割损失与对抗损失相结合,在鉴别网络的作用下学习图像特征层面的跨域特征。鉴别网络采用卷积神经网络,并带入源域标签训练,用来区分生成网络的分割结果是来自源域或目标域,整个训练过程无监督。使用膝关节磁共振(MR)图像公开数据集和采集的临床数据集进行实验,与经典的特征级域自适应方法和图像级域自适应方法对比,所提方法的平均戴斯相似性系数(DSC)分别提高了2.52%与6.10%。本文方法有效提高了分割方法的域自适应能力,显著提高了对胫骨和股骨的分割精度,可以较好地解决磁共振图像分割中的域转移问题。

【关键词】 医学图像分割; 域转移; 生成对抗网络; 图像级域自适应; 特征级域自适应

A generative adversarial network-based unsupervised domain adaptation method for magnetic resonance image segmentation

SUN Yubo^{1,2}, LIU Jianan^{1,2}, SUN Zewen³, HAN Jianda^{1,2,4}, YU Ningbo^{1,2,4}

1. College of Artificial Intelligence, Nankai University, Tianjin 300350, P. R. China
2. Tianjin Key Laboratory of Intelligent Robotics, Nankai University, Tianjin 300350, P. R. China
3. Institute of Sports Medicine, Peking University Third Hospital, Beijing 100083, P. R. China
4. Institute of Intelligence Technology and Robotic Systems, Shenzhen Research Institute of Nankai University, Shenzhen, Guangdong 518083, P. R. China

Corresponding author: YU Ningbo, Email: nyu@nankai.edu.cn

【Abstract】 Intelligent medical image segmentation methods have been rapidly developed and applied, while a significant challenge is domain shift. That is, the segmentation performance degrades due to distribution differences between the source domain and the target domain. This paper proposed an unsupervised end-to-end domain adaptation medical image segmentation method based on the generative adversarial network (GAN). A network training and adjustment model was designed, including segmentation and discriminant networks. In the segmentation network, the residual module was used as the basic module to increase feature reusability and reduce model optimization difficulty. Further, it learned cross-domain features at the image feature level with the help of the discriminant network and a combination of segmentation loss with adversarial loss. The discriminant network took the convolutional neural network and used the labels from the source domain, to distinguish whether the segmentation result of the generated network is from the source domain or the target domain. The whole training process was unsupervised. The proposed method was tested with experiments on a public dataset of knee magnetic resonance (MR) images and the clinical dataset from our cooperative hospital. With our method, the mean Dice similarity coefficient (DSC) of segmentation results increased by 2.52% and 6.10% to the classical feature level and image level domain adaptive method. The proposed method effectively

DOI: 10.7507/1001-5515.202203009

基金项目: 国家自然科学基金(U1913208, 61873135, 61720106012); 国家重点研发计划(2018YFB1307803)

通信作者: 于宁波, Email: nyu@nankai.edu.cn

improves the domain adaptive ability of the segmentation method, significantly improves the segmentation accuracy of the tibia and femur, and can better solve the domain transfer problem in MR image segmentation.

【Key words】 Medical image segmentation; Domain shift; Generative adversarial networks; Image level domain adaptation; Feature level domain adaptation

引言

医学图像分割是决定医学图像在临床诊疗中能否提供可靠依据的关键手段^[1-2]。随着人工智能技术的发展,基于神经网络的医学图像智能分割得到广泛应用^[3-4],已经成为人工智能辅助诊疗的重要技术^[5-6]。

通过人工智能方法进行医学图像分割的过程中,域转移成为一个重要挑战^[7]。这主要是由于通过源域训练好的分割模型是针对某种特定类型序列图像的,在其他类型序列图像上分割相同组织时会不匹配,从而导致精度下降。精度误差通常与源域和目标域之间的分布差异成比例。因此,通过源域数据训练的模型,在对目标域数据分割时常常不能达到期望的效果。但研究者们希望无论数据来自哪个域,都可以使用一个通用模型获得有效的分割结果。解决域转移问题,成为医学图像分析中的迫切需求。

为了应对域转移挑战,研究者提出了域自适应方法^[8],较为常见的为图像级域自适应和特征级域自适应。要使分割网络适应目标域图像,可以通过使用有标签的目标域数据对分割网络进行调整来实现,但这需要对目标域数据进行注释。而图像分割需要进行像素级注释,与其他任务(如图像分类)相比,为分割任务注释数据要困难得多,从而导致分割任务图像通常缺乏人工标签。因此,无监督的域自适应方法受到越来越多的关注。

从图像层面进行的域自适应称为图像级域自适应,经常使用生成对抗网络(generative adversarial network, GAN)作为框架^[9-11],尤其是 Zhu 等^[12]提出的 CycleGAN,它可以将一个图像转换成另一种图像风格,而不需要成对的训练样本。Wollmann 等^[13]提出了一种基于 CycleGAN 的乳腺癌分类方法,首先使用 CycleGAN 将淋巴结的全切片图像从源域转换到目标域,然后将 DenseNet 用于乳腺癌分类。Hiasa 等^[14]基于 CycleGAN 并结合边缘损失将全髌关节磁共振(magnetic resonance, MR)图像转化为电子计算机断层扫描(computed tomography, CT)图像,并使用 U-Net 对生成的 CT 图像进行分割。但他们使用的非端到端的分割方法,不仅推理

时间长,而且相对来说训练也更加复杂。此外, Liu 等^[15]同样使用 CycleGAN 将不同类型的膝关节 MR 图像序列进行转化和分割,但他们使用的 2 维卷积神经网络结构会限制单个切片内的图像特征,并且当图像之间的对比度不一致时,可能会导致分割偏差。

从特征层面进行的域自适应称为特征级域自适应,其主要目的是将源域数据和目标域数据映射到同一个特征空间,促使生成器学习跨域特征。Javanmardi 等^[16]提出了基于 GAN 的域自适应方法,并在公开的眼血管数据集和电子显微镜神经元图像分割数据集中进行了实验,将 U-Net 作为生成器用于图像的分割,使用另一个卷积神经网络作为鉴别器对分割结果进行分类,使用 0 或者 1 进行标记。Panfilov 等^[17]同样基于 GAN 对膝关节软骨进行了分割,不仅如此,实验中使用了两个鉴别器对不同阶段的特征进行分类,以在高维特征层面进行特征自适应学习,并且在三个数据集上进行了实验,在股骨软骨和胫骨软骨上最好的分割准确度结果提高了 3.0% 和 6.8%。但此工作只对软骨进行了分割,且使用的源域与目标域数据均来自同一公司生产的设备,MR 图像间差异较小。

为了更加有效地解决域转移问题,提高分割网络自适应性,本文提出了一种基于 GAN 的无监督端到端特征级域自适应医学图像分割方法。同时对比分析了本文提出的特征级域自适应方法与三种经典方法:① 直接使用由源域数据训练的分割网络对目标域图像进行分割;② Zhu 等^[12]于 2017 年提出的图像级域自适应方法;③ Panfilov 等^[17]于 2019 年提出的特征级域自适应方法。进一步的,使用来自不同 MR 设备且灰度值存在显著差异的膝关节 MR 图像数据集进行域自适应实验,对所提域自适应方法进行了有效性验证。

1 特征级域自适应图像分割方法设计

本文设计了一种无监督端到端特征级域自适应图像分割方法,整体流程如图 1 所示(x^s : 源域数据, y^s : 源域分割标签, x^t : 目标域数据, y^t : 目标域分割标签)。针对医学图像分割中人工标注工作繁琐、主观性强等问题,我们采用 GAN 针对目

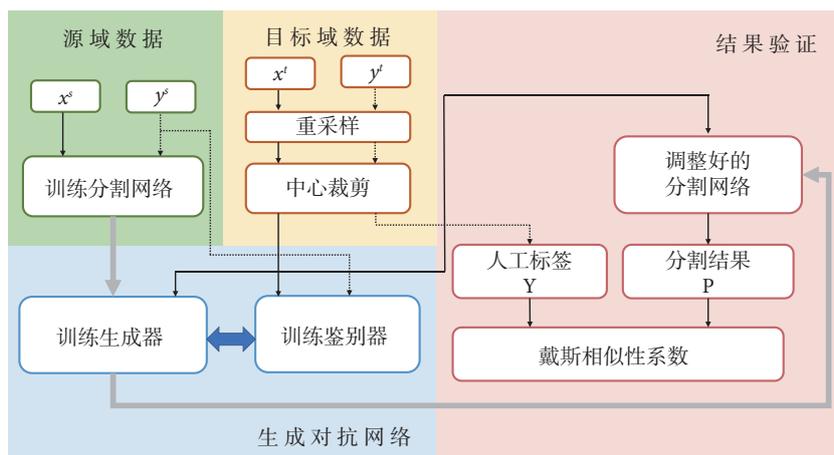


图1 本文提出的域自适应方法流程图

Fig.1 Flow chart of the proposed domain adaptation method

标域数据进行无监督学习训练。我们所提的无监督训练是指在解决域转移问题过程中，只使用目标域数据而未使用目标域标签。GAN 中生成器的梯度更新信息来自鉴别器，而不是来自数据样本，同时我们将源域标签作为鉴别器输入，使其更加适合针对目标域数据的无监督训练。本文采用了以残差模块为基本模块的分割网络，增强了对特征的复用能力。通过源域数据进行分割网络预训练，获得适合源域数据的参数作为 GAN 中生成器即分割网络的参数初值。鉴别器结构为卷积神经网络，其中目标域数据通过重采样与中心裁剪匹配源域数据格式，与源域分割标签的独热编码一起作为鉴别器的输入。再通过 GAN 对分割网络参数进行学习和调整，获得适合目标域的分割网络参数。随后通过戴斯相似性系数 (Dice similarity coefficient, DSC) 进行分割精度检验。本文所设计无监督域自适应方法基于 Pytorch^[18] 实现。

生成器G使用之前在我们的工作中提出的分割网络^[5]，具体如图2所示。分割网络的基本模块为残差模块，这样设计既增加了网络对特征的复用能力，又起到了降低优化难度的作用。利用并行的扩张卷积模块获取不同的感受野，克服了 U-Net 模型中单一感受野的局限性，有效提高分割能力的鲁棒性。使用空洞空间金字塔池化模块 (atrous spatial pyramid pooling, ASPP)，利用具有不同感受野的卷积操作，获取丰富的上下文信息。同时多输出融合模块能直接利用不同层次的特征，实现多尺度特征信息互补，最终提高了分割区域的连贯性和准确性。

鉴别器D的结构如图3所示，本结构中鉴别器共由5个卷积层组成，初始卷积核数量设置为64，

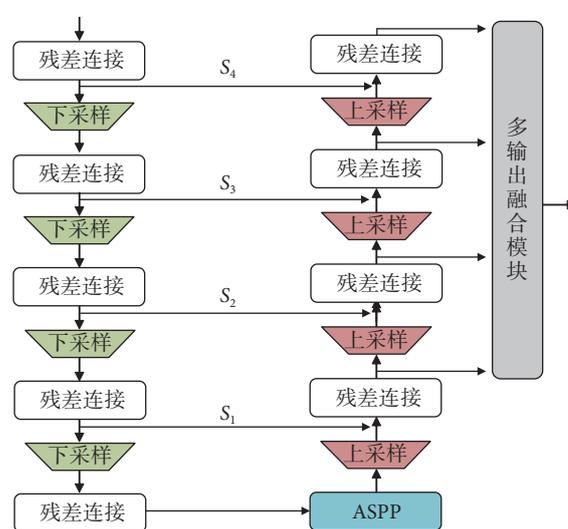


图2 生成器结构

Fig.2 Structure of the generator

第二层卷积核个数为128，随后逐层加倍，最后一层输出通道被设置为1，再通过双线性插值将最后一层的输出还原至384×384，即原始图像的分辨率大小。所使用的激活函数采用 Leaky ReLU。

生成器的具体训练流程如图4a所示，源域图像 x^s 与目标域图像 x^t 作为生成器输入，生成器输出图像分割结果。损失函数设置如公式(1)所示，由分割损失与对抗损失两部分组成。 f 使用softmax函数， p_n^s 为分割结果的概率值。

$$\begin{aligned} \mathcal{L}_g &= l_{seg} + \lambda l_{gan} \\ l_{seg} &= -\frac{1}{N} \sum_{n=1}^N y_n^s \log(p_n^s) \\ l_{gan} &= -\frac{1}{N} \log(1 - D(f(G(x_n^t)))) \end{aligned} \quad (1)$$

鉴别器的具体训练流程如图4b所示，本文将

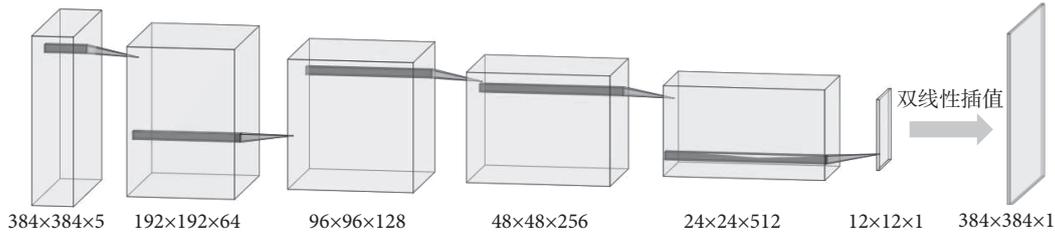


图3 鉴别器结构

Fig.3 Structure of the discriminator

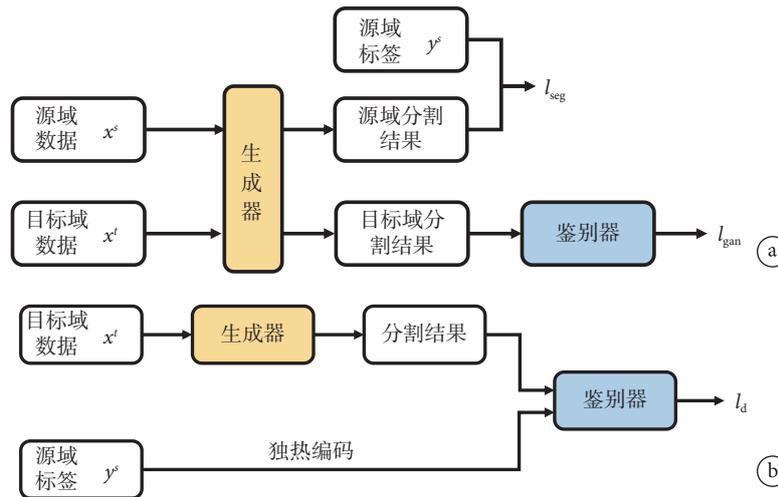


图4 生成对抗网络训练过程 a. 生成器训练流程； b. 鉴别器训练流程

Fig.4 Training process of the GAN a. the generator training process; b. the discriminator training process

源域数据分割标签的独热编码作为鉴别器输入之一，选取二分类交叉熵作为其损失函数，鉴别器的输出是与图像分辨率一致的矩阵。二分类交叉熵损失为：

$$l = -y \log(D(f(G(x)))) - (1 - y) \log(1 - D(f(G(x)))) \quad (2)$$

对于源域数据，本文中将其标签设定为矩阵 0，对于本地数据其标签为矩阵 1。将 $x = x^s, y = 0$ 和 $x = x^t, y = 1$ 分别代入交叉熵损失后相加，可得鉴别器损失函数。且式中 $f(G(x^s))$ 为由生成器得到的源域图像分割标签概率图，我们将此替换为源域标签 y^s 的独热编码，设计了如式 (3) 所示的鉴别器损失函数，以增加鉴别器精度。

$$l_d = -\log(D(f(G(x^t)))) - \log(1 - D(y^s)) \quad (3)$$

2 实验数据与实验设计

膝骨关节炎是一种慢性退行性关节疾病，会导致患者关节疼痛和运动障碍。关节软骨的体积和厚度是膝骨关节炎检测和分级的重要指标之一^[19]。MR 成像长期以来被认为是最强大的膝关节检查工

具^[20]，临床上通常用于研究膝关节，特别是关节软组织的内部结构变化。对于需要进行膝关节置换术的晚期膝骨关节炎患者，利用分割后的 MR 图像进行三维重建可以构建患者的膝关节模型，用于个性化假体设计和术前规划^[21]。但是由于成像设备差异、同一设备扫描参数差异等原因，域转移问题在膝骨关节炎 MR 图像的分割中经常出现，并仍未得到有效解决。因此，本文选取了来自不同 MR 设备且灰度值存在显著差异的膝关节 MR 图像数据集进行了域自适应方法验证实验。

设计实验，对比分析本文所提特征级域自适应方法和三种经典方法：① 直接使用由源域数据训练的分割网络对目标域图像进行分割；② Zhu 等^[12]于 2017 年提出的图像级域自适应方法；③ Panfilov 等^[17]于 2019 年提出的特征级域自适应方法。

2.1 实验数据

本文使用膝关节 MR 图像公开数据集 OAI-ZIB^[22]作为源域数据，使用由北京大学第三医院运动医学研究所提供并授权使用的膝骨关节炎患者的膝关节 MR 图像数据集^[5]作为目标域数据，进行域自适应方法验证实验，对所提方法的有效性进行验证。

OAI-ZIB 数据集来自美国国家卫生研究院，数据集的手工分割由柏林 Zuse 研究机构进行。手工分割区域包括股骨、股骨软骨、胫骨和胫骨软骨。合作医院提供的本地 MR 图像数据集，由影像科医师进行了标注，并使用 ITK SNAP 软件进行分割^[23]。具体参数如表 1 所示，两个数据集的 MR 图像之间存在明显的域转移问题。

公开数据集中的 MR 图像和合作医院提供的临床数据集 MR 图像对比如图 5 所示。由于 MR 图像的具体类型不同，公开数据集图像中骨性区域一般为黑色，软骨区域为白色，而本地数据集则相反，两个数据集中的图像灰度值存在明显差异。

2.2 实验设备与数据预处理

实验中使用的计算机 CPU 为 E5-2 678 v3，内存为 128 GB，显卡为 2080Ti。

本文使用了 OAI-ZIB 公开数据集中的 1 840 张图像以及本地数据集中的 1 694 张图像，为避免同一病例的 MR 图像层间相关性对实验造成影响，数据均以每个病例为整体进行划分。实验设计具体为：取 OAI-ZIB 数据集中的 1 840 张图像作为源域数据，随机选取本地数据集中 2 例患者共 225 张图像作为测试集，1 例患者 110 张图像作为验证集，其余 12 例患者共 1 359 张图像作为训练集。由于公开数据集图像与本地数据集图像的像素间距不同，我们对本地数据集图像进行了重采样，采用规范化像素间距方法使本地数据集图像分辨率变为 444×444，随后进行中心裁剪使分辨率为 384×384，与公开数据集图像分辨率相同。

2.3 对比实验设计

首先使用源域数据与标签对本文所提出的分割网络进行训练，得到适用于源域数据的分割网络参数。进而使用训练所得参数配置分割网络，进行目标域图像分割，以此作为基线。

其次使用 Zhu 等^[12]提出的 CycleGAN 图像级域自适应网络，将不同类型的 MR 图像相互转换。具体为使用通过 CycleGAN 训练好的生成器，将目标域图像转换为源域图像风格，并输入使用源域数据训练的分割网络。本文遵循之前研究中 CycleGAN 的实验参数设置，训练生成器和鉴别器。

最后设计与 Panfilov 等^[17]提出的特征级域自适应方法进行对比。为了控制影响分割结果的因素，对比实验中的参数设定与本文提出的方法相同。批处理大小设置为 1，学习率设置为 0.001，动量设置为 0.9，权重衰减设置为 0.000 5，损失函数中 λ 设置为 0.1。其中使用公开数据库数据预训练模

表 1 存在域转移问题的源域与目标域数据集对比

Tab.1 Comparison of the source domain dataset and the target domain dataset with domain shift

指标	OAI-ZIB数据集	本地数据集
MR类型	DESS	PD
采集面	矢状面	矢状面
像素间距/mm	0.36×0.36×0.7	0.312 5×0.312 5×1
分辨率/像素	384×384	512×512
数量/张	1 840	1 694
性别(男:女)	262:245	10:5
年龄/岁	61.87±9.33	/
骨关节炎分级 (0:1:2:3:4)	60:77:61:151:158	/

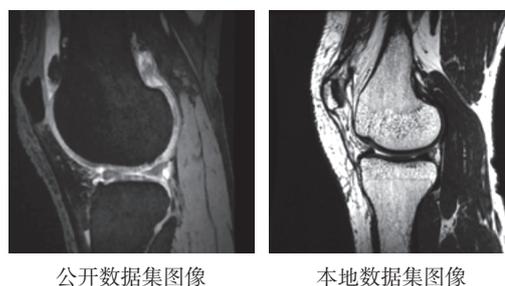


图 5 不同数据集图像对比

Fig.5 Image comparison of different data sets

型，优化器为随机梯度下降 (stochastic gradient descent, SGD)^[24]。参数随机初始化后训练鉴别器，并在其中使用了谱标准化^[25]，选用 Adam 优化器^[26]，学习率设置为 0.001。学习率使用 Poly 更新，次方数 0.9，训练次数设定为 100 000 次。

3 模型训练与结果分析

本文将所提特征级域自适应方法与三种经典方法分别进行了训练与分割实验，同时也对 CycleGAN 在本文所用数据集中图像风格转化的有效性进行了验证。为了直观地展示各种方法在图像分割结果上的差异，随机选取了两幅目标域图像进行不同方法的分割结果定性对比。最后采用戴斯相似性系数对各分割方法在测试集中的分割精度进行了量化评估与对比分析。

3.1 定性分析

我们在测试集中随机选取两张图像进行对比分析，所提方法与三种已有方法的分割结果如图 6 所示。由于存在域转移问题，直接使用由源域数据训练的分割网络对目标域图像进行分割，无法对股骨和胫骨进行有效分割，分割区域不完整。Zhu 等^[12]提出的图像级域自适应方法使用 CycleGAN 将目标域图像转换为源域图像风格，如图 7 所示，再使用

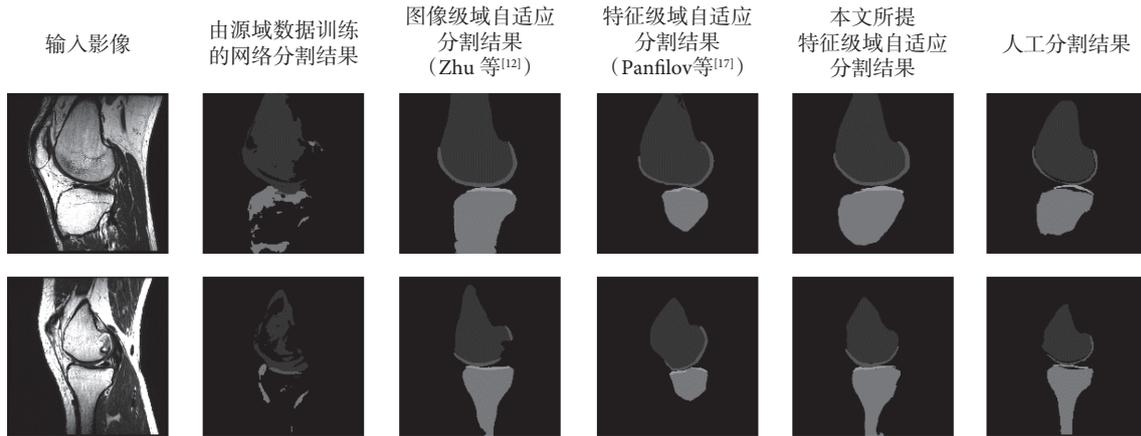


图6 不同分割方法对比

Fig.6 Qualitative segmentation results comparison of different methods

由源域数据训练的分割网络进行分割,能有效改善分割结果,但假阳性区域过多。使用 Panfilov 等^[17]提出的特征级域自适应方法后,分割区域存在较多缺失。而本文所提的特征级域自适应方法的分割结果与手工分割结果最为接近。

3.2 定量评估

由于每个病例的 MR 图像常由多个存在前后关系的二维图像切片组成,故评估分割精度时,本文选择将每个病例的数据作为整体进行评估而不是逐张进行评估,是一种符合数据情况的评估方法。分割精度评估大多采用戴斯相似性系数,其通常用于计算两个集合间的相似度,适合本研究中的相似度量评估需求,且最近有研究表明戴斯相似性系数在医学图像分割任务中更为合适^[27],故本研究中采用戴斯相似性系数进行定量评估。戴斯相似性系数的计算结果范围为 0%~100%,数值越小表示相似度越差,反之则越好。

实验中的待分割部分包括股骨、胫骨、股骨软骨和胫骨软骨。本文采用戴斯相似性系数对每一个分割区域分别进行评估,随后取平均值。戴斯相似性系数的计算过程如公式(4)所示。

$$DSC = \frac{2\|Y \cap P\|_1}{\|Y\|_1 + \|P\|_1} \times 100 \quad (4)$$

其中, Y 代表真值,即目标域的人工分割结果, P 为分割网络预测的结果。

图像分割对比实验结果如表 2 所示,相对于经典域自适应方法,本文提出的无监督特征级域自适应方法在股骨和胫骨区域分割中戴斯相似性系数分别可以达到 92.06% 和 89.34%;同时股骨软骨的分割精度也得到了较大提升,戴斯相似性系数可达到 48.03%;另外,本文所提方法可以获得最高的平

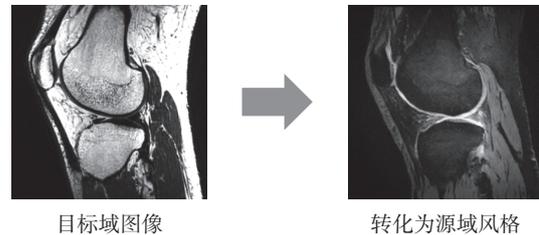


图7 图像级域自适应中,目标域图像转化为源域风格

Fig.7 In image-level domain adaptation, the target domain image is converted to the source domain state

表 2 不同域自适应分割方法戴斯相似性系数对比

Tab.2 The DSC comparison of different domain adaptation methods

方法	股骨	股骨软骨	胫骨	胫骨软骨	平均
使用源域数据训练模型	40.61%	0.00%	22.43%	0.00%	15.76%
图像级域自适应 (Zhu等 ^[12])	88.82%	40.9%	80.86%	36.07%	61.66%
特征级域自适应 (Panfilov等 ^[17])	90.42%	36.34%	78.89%	26.68%	58.08%
本文所提特征级域自适应	92.06%	48.03%	89.34%	27.27%	64.18%

注:粗体字为几种方法中的最好结果

均戴斯相似性系数 64.18%,相对于直接使用由源域数据训练、图像级域自适应方法^[12]和特征级域自适应方法^[17]分别提升了 48.42%、2.52% 和 6.10%。直接使用源域数据训练分割模型参数对本地临床图像进行分割,戴斯相似性系数最低,甚至无法分割软骨。使用经典图像级域自适应和经典特征级域自适应后,平均戴斯相似性系数有所提高。使用本文所提方法在胫骨软骨分割中戴斯相似性系数低于经典图像级域自适应方法,但股骨、股骨软骨和胫骨的分割中,戴斯相似性系数均高于经典方法。

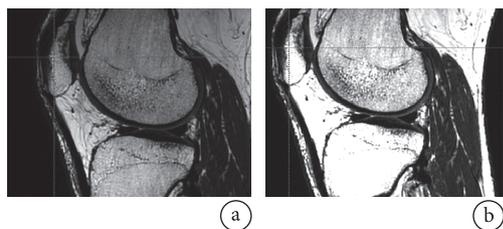


图8 不同对比度的本地数据集图像 a. 原始图像; b. 调整对比度后的图像

Fig.8 MR images with different contrasts in our dataset a. original image; b. contrast adjusted image

经典图像级域自适应对胫骨软骨分割精度高于特征级域自适应方法,但不论是经典方法还是本文所提方法,对胫骨软骨区域进行分割的戴斯相似性系数普遍偏低。进行图像对比后发现,如图8a所示,目标域数据集中胫骨软骨部分的对比度较低,胫骨软骨与胫骨骨性区域界限不明显。通过调整窗位、窗宽增加对比度后可以使其界限较为清晰,但这种做法会造成图像中胫骨部分与旁边的肌肉组织部分相似,如图8b所示,影响胫骨骨骼部分的分割,故本文在实验中未对目标域数据进行对比度处理。同时本地数据集均来自膝关节炎患者,胫骨软骨区域均存在一定的病理问题,且胫骨软骨区域在每张MR图像中占比较小,约为1.7%,特征级域自适应方法在特征学习过程中会受到模糊边界与软骨区域病理问题的影响,从而损失一定的分割精度。

相对于对比方法中的经典域自适应方法,本文所提方法的戴斯相似性系数有一定的提升,骨骼区域由于面积较大几乎在每一张MR图像上都存在,在实际的人工标注中耗时较多,本文所提的域自适应方法可以较好地解决在骨骼区域的域转移问题。

4 结论

本文针对医学图像智能化分割面临的域转移挑战,提出了一种基于GAN的无监督端到端特征级域自适应图像分割方法。在膝关节MR图像公开数据集和我们合作医院的膝关节MR图像临床数据集上进行了域自适应实验,结果表明所提方法能有效提高分割模型的域自适应能力,显著提高了对胫骨和股骨的分割精度。本文使用膝关节MR图像进行方法验证,此方法还可推广至其他部位的医学图像分割,如髋关节等。未来将开发结合图像级域自适应与特征级域自适应的方法,结合两者优势,同步提高骨性区域与软骨区域的分割精度,从而更好地在临床中为假体设计与术前规划等

提供帮助。同时,MR图像是由多个存在前后关系的二维图像切片组成,这些切片包含丰富的结构信息,在以后的工作中,将会基于GAN在无监督训练上的优势,研发基于图像切片间相关性的域自适应图像分割方法,进一步提高分割精度。

重要声明:

利益冲突声明:本文全体作者均声明不存在利益冲突。

作者贡献声明:孙玉波主要负责研究框架设计、方法设计与实现、数据处理与分析、文稿写作以及最后定稿。刘嘉男主要负责方法设计与实现、对比方法代码设计与实现、数据集处理与分析以及文稿写作。孙泽文主要负责数据集整理、打标、分析与解释。韩建达教授与于宁波教授主要负责课题构思与设计、资料的分析与解释、对文稿关键方法与学术内容的修改以及最后定稿。

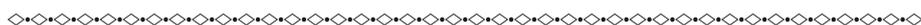
参考文献

- 1 Chowdhary C L, Acharjya D P. Segmentation and feature extraction in medical imaging: a systematic review. *Procedia Comput Sci*, 2020, 167: 26-36.
- 2 Hesamian M H, Jia W, He X, *et al*. Deep learning techniques for medical image segmentation: achievements and challenges. *J Digit Imaging*, 2019, 32(4): 582-596.
- 3 吴玉超, 林岚, 王婧璇, 等. 基于卷积神经网络的语义分割在医学图像中的应用. *生物医学工程学杂志*, 2020, 37(3): 533-540.
- 4 王玉丽, 赵子健. 基于深度学习的脑图像分割算法研究综述. *生物医学工程学杂志*, 2020, 37(4): 721-729.
- 5 于宁波, 刘嘉男, 高丽, 等. 基于深度学习的膝关节MR影像自动分割方法. *仪器仪表学报*, 2020, 41(6): 140-149.
- 6 Aslan M F, Unlarsen M F, Sabanci K, *et al*. CNN-based transfer learning-BiLSTM network: A novel approach for COVID-19 infection detection. *Appl Soft Comput*, 2021, 98: 106912.
- 7 Torralba A, Efros A A. *Unbiased look at dataset bias*// CVPR 2011. Colorado Springs: IEEE, 2011: 1521-1528.
- 8 Guan H, Liu M. Domain adaptation for medical image analysis: a survey. *IEEE Trans Biomed Eng*, 2021, 69(3): 1173-1185.
- 9 Yi X, Walia E, Babyn P. Generative adversarial network in medical imaging: A review. *Med Image Anal*, 2019, 58: 101552.
- 10 Patgiri R, Biswas A, Roy P. *Health informatics: A computational perspective in healthcare*. Berlin: Springer, 2021: 77-96.
- 11 Goodfellow I, Pouget-Abadie J, Mirza M, *et al*. Generative adversarial networks. *Commun ACM*, 2020, 63(11): 139-144.
- 12 Zhu J Y, Park T, Isola P, *et al*. Unpaired image-to-image translation using cycle-consistent adversarial networks// *Proceedings of the IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 2223-2232.
- 13 Wollmann T, Eijkman C S, Rohr K. Adversarial domain adaptation to improve automatic breast cancer grading in lymph nodes// 2018 IEEE 15th International Symposium on Biomedical Imaging. Washington: IEEE, 2018: 582-585.
- 14 Hiasa Y, Otake Y, Takao M, *et al*. Cross-modality image synthesis from unpaired data using CycleGAN// Gooya A, Goksel O, Oguz I, *et al*. *International workshop on simulation and synthesis in medical imaging*. Cham: Springer, 2018: 31-41.

- 15 Liu F. SUSAN: segment unannotated image structure using adversarial network. *Magn Reson Med*, 2019, 81(5): 3330-3345.
- 16 Javanmardi M, Tasdizen T. Domain adaptation for biomedical image segmentation using adversarial training// 2018 IEEE 15th International Symposium on Biomedical Imaging. Washington: IEEE, 2018: 554-558.
- 17 Panfilov E, Tiulpin A, Klein S, *et al.* Improving robustness of deep learning based knee MRI segmentation: Mixup and adversarial domain adaptation// Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops. Seoul: IEEE/CVF, 2019: 450-459.
- 18 Paszke A, Gross S, Massa F, *et al.* Pytorch: An imperative style, high-performance deep learning library. *Adv Neural Inf Process Syst*, 2019, 32: 1-12.
- 19 Razmjoo A, Caliva F, Lee J, *et al.* T2 analysis of the entire osteoarthritis initiative dataset. *J Orthop Res*, 2021, 39(1): 74-85.
- 20 Hayashi D, Roemer F W, Guermazi A. Magnetic resonance imaging assessment of knee osteoarthritis: current and developing new concepts and techniques. *Clin Exp Rheumatol*, 2019, 37(Suppl 120): 88-95.
- 21 Gao L, Ding K, Liu J, *et al.* Design and Development of A Knee Surgery Planning System// 2020 Chinese Control And Decision Conference (CCDC). Hefei: IEEE, 2020: 2053-2059.
- 22 Ambellan F, Tack A, Ehlke M, *et al.* Automated segmentation of knee bone and cartilage combining statistical shape knowledge and convolutional neural networks: Data from the Osteoarthritis Initiative. *Med Image Anal*, 2019, 52: 109-118.
- 23 Yushkevich P A, Gerig G. ITK-SNAP: an interactive medical image segmentation tool to meet the need for expert-guided segmentation of complex medical images. *IEEE Pulse*, 2017, 8(4): 54-57.
- 24 Cherry J M, Adler C, Ball C, *et al.* SGD: Saccharomyces genome database. *Nucleic Acids Res*, 1998, 26(1): 73-79.
- 25 Miyato T, Kataoka T, Koyama M, *et al.* Spectral normalization for generative adversarial networks. *arXiv preprint arXiv: 2018: 1802.05957*.
- 26 Kingma D P, Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv: 2014: 1412.6980*.
- 27 Ma J, Chen J, Ng M, *et al.* Loss odyssey in medical image segmentation. *Med Image Anal*, 2021, 71: 102035.

收稿日期: 2022-03-06 修回日期: 2022-10-23

本文编辑: 李蓓兰

(上接第 1180 页; *Continued from Page 1180*)

- 9 Qi F F, Wu W, Yu Z L, *et al.* Spatio temporal-filtering-based channel selection for single-trial EEG classification. *IEEE T Cybernetics*, 2021, 51(2): 558-567.
- 10 Park Y, Chung W. Selective feature generation method based on time domain parameters and correlation coefficients for filter-bank- CSP BCI systems. *Sensors*, 2019, 19(17): 3769.
- 11 付荣荣, 田永胜, 鲍甜怡. 基于稀疏共空间模式和Fisher判别的单次运动想象脑电信号识别方法. *生物医学工程学杂志*, 2019, 36(6): 911-915, 923.
- 12 骆金晨, 姜月, 胡秀枋, 等. 基于多特征融合的多分类运动想象脑电信号识别研究. *生物信息学*, 2020, 18(3): 176-185.
- 13 郝东瑞, 周晖, 冯李道, 等. 基于特征融合和粒子群优化算法的运动想象脑电信号识别方法. *电子科技大学学报*, 2021, 50(3): 467-475.
- 14 汲继跃, 余青山, 张启中, 等. 最优区域共空间模式的运动想象脑电信号分类方法. *传感技术学报*, 2020, 33(1): 34-39.
- 15 Goldberger A L, Amaral L A N, Glass L, *et al.* PhysioBank, PhysioToolkit, and PhysioNet-components of a new research resource for complex physiologic signals. *Circulation*, 2000, 101(23): 215-220.
- 16 Schalk G, Mcfarland D J, Hinterberger T, *et al.* BCI2000: a general-purpose, brain-computer interface (BCI) system. *IEEE T Bio-Med Eng*, 2004, 51(6): 1034-1043.
- 17 Varsehi H, Firoozabadi S M P. An EEG channel selection method for motor imagery based brain-computer interface and neurofeedback using Granger causality. *Neural Networks*, 2021, 133: 193-206.
- 18 Lun Xiangmin, Yu Zhenglin, Chen Tao, *et al.* A simplified CNN classification method for MI-EEG via the electrode pairs signals. *Front Hum Neurosci*, 2020, 14: 338.
- 19 Hou Y M, Zhou L, Jia S Y, *et al.* A novel approach of decoding EEG four-class motor imagery tasks via scout ESI and CNN. *J Neural Eng*, 2020, 17(1): 016048.
- 20 徐欣, 王娜. 四类运动想象脑电信号的特征提取与分类. *南京邮电大学学报: 自然科学版*, 2017, 37(6): 18-22.
- 21 马满振, 郭理彬, 苏奎峰. 基于多类运动想象任务的EEG信号分类研究. *计算机测量与控制*, 2017, 25(10): 232-239.
- 22 Robnik-Sikonja M, Kononenko I. Theoretical and empirical analysis of ReliefF and RReliefF. *Mach Learn*, 2003, 53(1-2): 23-69.
- 23 张小内, 翟文鹏, 侯惠让, 等. 基于ReliefF-Pearson的嗅觉脑电通道选择. *电子信息学报*, 2021, 43(7): 2032-2037.
- 24 Mishuhina V, Jiang Xudong. Feature weighting and regularization of common spatial patterns in EEG-based motor imagery BCI. *IEEE Signal Proc Let*, 2018, 25(6): 783-787.
- 25 褚亚奇, 朱波, 赵新刚, 等. 基于时空特征学习卷积神经网络的运动想象脑电解码方法. *生物医学工程学杂志*, 2021, 38(1): 1-9.
- 26 Fu Rongrong, Han Mengmeng, Tian Yongsheng, *et al.* Improvement motor imagery EEG classification based on sparse common spatial pattern and regularized discriminant analysis. *J Neurosci Meth*, 2020, 343: 108833.
- 27 Luo Jing, Gao Xing, Zhu Xiaobei, *et al.* Motor imagery EEG classification based on ensemble support vector learning. *Comput Meth Prog Bio*, 2020, 193: 105464.
- 28 Tolic M, Jovic F. Classification of wavelet transformed EEG signals with neural network for imagined mental and motor tasks. *Kinesiology*, 2013, 45(1): 130-138.
- 29 Kim Y, Ryu J, Kim K K, *et al.* Motor imagery classification using mu and beta rhythms of EEG with strong uncorrelating transform based complex common spatial patterns. *Comput Intel Neurosc*. 2016, 2016: 1489692.
- 30 Dose H, Moller J S, Lversen H K, *et al.* An end-to-end deep learning approach to MI-EEG signal classification for BCIs. *Expert Syst Appl*, 2018, 114: 532-542.

收稿日期: 2021-12-11 修回日期: 2022-09-26

本文编辑: 陈咏竹