

## 基于教师督导的磁共振图像联合重建与分割

张宇<sup>1,2</sup>, 李浩然<sup>1,2</sup>, 李程<sup>1</sup>, 李飞<sup>1</sup>, 王珊珊<sup>1\*</sup><sup>1</sup>中国科学院深圳先进技术研究院劳特伯生物医学成像研究中心, 广东 深圳 518055;<sup>2</sup>中国科学院大学, 北京 100049

**摘要** 现有的深度学习方法倾向于将磁共振图像重建与分割作为两个单独的任务来处理, 而没有考虑到两个任务之间的相关性。如果简单地对重建网络与分割网络进行拼接训练, 则可能会由于任务之间的优化难度差异而影响重建与分割的最终效果。基于改进后的教师督导网络训练策略, 开发了一种磁共振图像联合重建与分割的多任务深度学习方法。新设计的教师督导策略迭代地以中间重建输出和全采样数据来指导多任务网络训练, 缓解误差积累。在一个公开数据集和一个内部数据集上对所提方法进行评估, 并与 6 种现有方法进行了比较。实验结果表明, 与对比方法相比, 所提方法在实现重建与分割协同优化的同时提升了重建图像质量和分割精度。

**关键词** 计算机视觉; 磁共振图像重建与分割; 多任务网络; 任务驱动成像; 教师督导

中图分类号 TP391.41

文献标志码 A

DOI: 10.3788/LOP202259.1415024

## Combinatorial Reconstruction and Segmentation of Magnetic Resonance Image Using Teacher Forcing

Zhang Yu<sup>1,2</sup>, Li Haoran<sup>1,2</sup>, Li Cheng<sup>1</sup>, Li Fei<sup>1</sup>, Wang Shanshan<sup>1\*</sup><sup>1</sup>Paul C. Lauterbur Research Center for Biomedical Imaging, Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, Guangdong, China;<sup>2</sup>University of Chinese Academy of Sciences, Beijing 100049, China

**Abstract** Existing deep learning methods handle magnetic resonance (MR) image reconstruction and segmentation as individual task instead of considering their correlations. However, the simple concatenation of the reconstruction and segmentation networks can compromise the performances on both tasks due to the differences in optimization. This paper develops a multi-task deep learning method for the combinatorial reconstruction and segmentation of MR images using an improved teacher forcing network training strategy. The newly designed teacher forcing scheme guides multi-task network training by iteratively using intermediate reconstruction outputs and fully sampled data to avoid error accumulation. We compared the effectiveness of the proposed method with six state-of-the-art methods on an open dataset and an *in vivo* in-house dataset. The experimental results show that compared to other methods, the proposed method possesses encouraging capabilities to achieve better image reconstruction quality and segmentation accuracy while co-optimizing MR image reconstruction and segmentation simultaneously.

**Key words** computer vision; magnetic resonance image reconstruction and segmentation; multi-task network; task-driven imaging; teacher forcing

## 1 引言

磁共振成像(MRI)具有对人体无电离辐射伤害、成像信息丰富、软组织对比度高等特点,在医学

诊断<sup>[1-3]</sup>、疾病分期<sup>[4-5]</sup>和临床研究<sup>[6-7]</sup>等应用中具有重要的价值。医学图像分割是在采集到的图像中分离感兴趣区域的过程,是为临床诊疗提供可靠依据以及辅助医生做出更为准确诊断的关键一步。近年

收稿日期: 2021-12-15; 修回日期: 2022-01-09; 录用日期: 2022-02-21

基金项目: 国家自然科学基金(61871371, 81830056)、科技创新 2030——“新一代人工智能”项目(2020AAA0104100, 2020AAA0104105)、广东省重点领域研发计划(2018B010109009)、广东省科技计划(2020B1212060051)、深圳市基础研究项目(JCYJ20180507182400762)、中国科学院青年创新促进会项目(2019351)

通信作者: \*ss.wang@siat.ac.cn

来,随着深度学习在机器视觉领域的蓬勃发展,磁共振图像重建和图像分割等视觉任务有了全新的解决方案<sup>[8-11]</sup>。

在磁共振成像欠采样重建研究领域,文献[12]使用卷积神经网络来学习欠采样K空间数据经傅里叶变换得到的低质量图像到高质量图像的映射关系,由此实现高质量磁共振图像重建。文献[13]通过流形近似自动变换方法学习采样空间到图像空间的映射关系,实现了端到端的图像重建。文献[14]提出了一种双域并行编解码网络,该网络通过同时处理K空间数据和图像数据并融合双域信息,显著提升了磁共振图像重建质量。文献[15]提出了一种基于交替方向乘子法求解的Lp范数联合全变分正则项局部K空间邻域建模算法,该算法在加快成像速度的同时有效提高了重建图像的质量。在磁共振图像分割研究领域,文献[16]提出了一种基于改进U-Net<sup>[17]</sup>的脑肿瘤磁共振图像分割算法,用残差模块替代原有卷积层,设计了密集跳跃连接,提升了分割网络的性能。文献[18]提出了一种改进的三维双路径脑肿瘤图像分割网络,在网络参数量较少的情况下保证了分割精度。文献[19]使用端到端的方法,利用SynNet和LI-Net直接从欠采样K空间数据预测分割结果。文献[20]通过一个任务驱动的注意力模块,重复利用模型的中间分割结果,从原始K空间数据中提取图像域特征,以此提升分割效果。此外,文献[21]提出了一种具有两个模块的联合深度神经网络SegNetMRI,通过共享重建编码器的权重,合并训练多个分割模块得到最终的分割结果,该方法在探索磁共振图像联合重建与分割任务上做出了一定的贡献,但忽视了重建网络训练过程中图像信息丢失造成的误差累积,算法性能仍有提升空间。

大多数现有的深度学习方法通常把磁共振图像重建与分割看作两个独立的任务来处理。单一任务下的重建算法仅以均方误差(MSE)或L1范数等损失函数来驱动重建优化过程,由于缺乏下游分割任务的约束,难以保证重建后的图像在分割任务感兴趣区域的质量,这可能会影响最终分割算法的性能。因此,本文开发了一种基于改进教师督导<sup>[22]</sup>网络训练策略的磁共振图像联合重建与分割的深度学习方法。教师督导方法被广泛地用于训练循环神经网络,处理文本数据。本文修改了原有教师督导体系的工作流,使之适用于多任务磁共振成像。具体来说,全采样数据和重建流程的中间输出都被用于服务分割任务,从而缓解上游任务误差积累的影响,降低多任务网络的训练难度,进而提升多任务系统的整体性能。

## 2 基本原理

### 2.1 概述

提出的多任务磁共振成像框架如图1所示,由重建子模块和分割子模块组成。选择D5C5<sup>[23]</sup>作为重建网络模块,U-Net作为分割网络模块。D5C5是一个深度级联神经网络,以端到端的训练方式对数据一致性层和卷积层集成进行重建。基于编解码器结构的全卷积网络U-Net是医学图像分割的一个流行网络架构。编码器和解码器分别用于获取高级语义信息和恢复空间信息,编码层和相应的解码层之间引入的跳跃连接可以恢复降采样引起的信息丢失。重建模块和分割模块之所以选用现有的经典网络,是因为本课题更关注开发一个多任务成像框架,而不是设计新的网络结构。所提多任务磁共振成像方法以欠采样K空间数据作为输入,同时输出图像重建和分割结果。

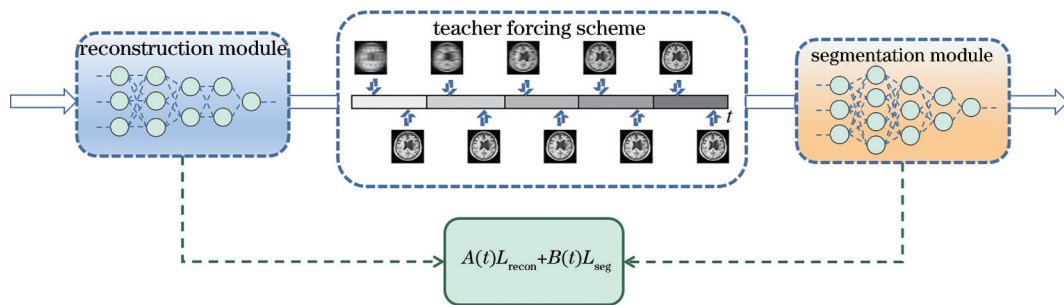


图1 所提多任务磁共振成像方法框架

Fig. 1 Framework of the proposed multi-task MRI method

### 2.2 教师督导体系

教师督导体系最先应用于训练循环神经网络,是一种依赖于标签数据的语言模型训练方法。在训练阶段,对于一个T步的序列化任务,设 $x_t, y_t, \hat{y}_t$ 分别表示第t步的输入、标签和输出。对一般的自回归模式来说,第t步的输入 $x_t$ 通常是上一步的输出,即 $\hat{y}_{t-1}$ ,该模式的局限性在于低层次模型的误差会逐渐累积,可能导致网络不收敛。教师督导模式则以 $y_{t-1}$ 代替 $\hat{y}_{t-1}$ 作

为第t步的输入,相当于以标签为教师,及时纠正低层次模型的错误,降低了网络训练难度。然而,传统教师督导模式采用标签来完全代替上一步的输出,这可能会导致曝光偏差,即训练阶段和测试阶段的性能差距。这是由于网络在训练和测试过程中第t步的输入是从不同的分布中推断而来的,分别来自真实数据分布和模型预测数据分布,因此网络在训练和测试阶段的解码结果会有所差异。

通过同时利用标签数据和中间重建输出设计了新的教师督导体系。如图 2 所示,新的教师督导体系依次以第  $t-1$  步的输出和标签数据作为第  $t$  步的输入,而不是固定的以第  $t-1$  步的标签作为下一步的输入。具体来说,可以将多任务磁共振成像看作一个从重建到分割的两步序列化任务。在训练阶段,对于输入的

一个小批量数据,将欠采样 K 空间数据作为重建子模块的输入  $\mathbf{x}_1$ ,重建子模块的输出  $\hat{\mathbf{y}}_1$  作为分割子模块的输入  $\mathbf{x}_2$ ,完成第一次对两个模块的梯度更新;之后,在同一个大批量数据上将标签数据  $\mathbf{y}_1$  作为分割子模块的输入  $\mathbf{x}_2$ ,重复一次此过程,进行另一次对两个模块的梯度更新。

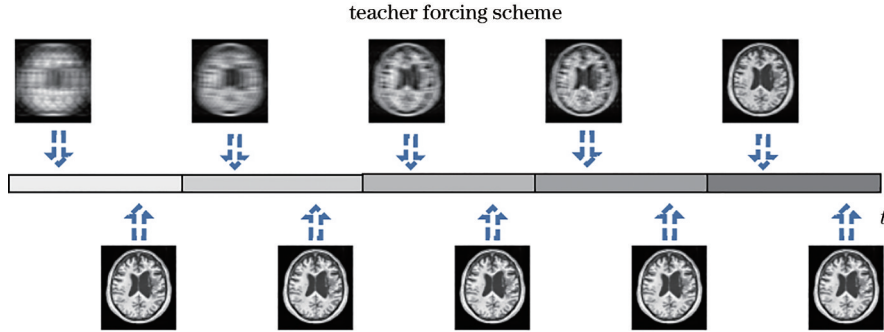


图 2 所提教师督导体系  
Fig. 2 The proposed improved teacher forcing scheme (TFS)

### 2.3 损失函数设计

对于多任务磁共振成像工作,下游任务的性能受上游任务输出的影响很大。当下游任务是分割任务时,将分割模块与重建模块设计为一个协同的双任务网络,可以加强两个任务之间的联系。通常,这类网络可以采用端到端的方式进行训练,其损失函数是两个任务的损失函数的加权求和:

$$L = A(t)L_{\text{recon}} + B(t)L_{\text{seg}}, \quad (1)$$

式中:  $L_{\text{recon}}$  和  $L_{\text{seg}}$  分别指重建任务和分割任务的损失函数;  $A(t)$  和  $B(t)$  为相应的权重。

$$\begin{cases} A(t) = \max \{ \exp(-t) - 0.2, 0.05 \} \\ B(t) = 1 - A(t) \end{cases}, \quad (2)$$

式中:  $t \geq 0$ , 表示 epoch 序号。这样的加权设计是由于重建子模块参数数量较小,收敛速度快,因此需要在前期训练时增加重建模块的损失权重  $A(t)$ ,在后期重建网络趋于稳定时再增加分割模块的权重  $B(t)$ 。式(2)中的数值依据经验设置。重建任务中,采用 L1 范数作为损失函数,分割任务中,采用二元交叉熵作为损失函数。重建任务的损失函数为

$$L_{\text{recon}} = \|C(\mathbf{K}_{\text{US}}) - \mathbf{I}_{\text{FS}}\|_1, \quad (3)$$

式中:  $\mathbf{K}_{\text{US}}$  表示欠采样 K 空间数据;  $\mathbf{I}_{\text{FS}}$  表示标签图像数据;  $C(\cdot)$  表示重建任务使用的模型;  $\|\cdot\|_1$  表示 L1 范数。分割任务的损失函数为

$$L_{\text{seg}} = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log_{10} p(x_i) + (1 - y_i) \cdot \log_{10} [1 - p(x_i)], \quad (4)$$

式中:  $N$  表示样本个数;  $i$  表示样本编号;  $x_i$  表示分割结果,  $y_i$  表示分割标签,正类为 1,负类为 0;  $p(\cdot)$  表示样本预测为正类的概率。

## 3 分析与讨论

### 3.1 实验设置

使用公开数据集 ATLAS<sup>[24]</sup> 测试所提方法。该数据集包括来自全球 11 个中心 229 个病例的 T1 加权磁共振图像,由专业医生手动标注脑卒中病变区。每个病例包含 189 张切片图像,每张图像被裁剪为  $224 \times 192$  像素大小。其中,随机选取 120 个病例用作训练集,40 个病例用作验证集,69 个病例用作测试集。

此外,还在一个内部数据集上进行了试验。该数据集由贵州省人民医院收集,包含从西门子 1.5T 扫描仪得到的 40 个病例的图像,共 485 张 FLAIR 序列切片图像。脑卒中病变区由经验丰富的临床医生用 ITK-SNAP 标记得到的,所有切片被裁剪为  $224 \times 224$  像素大小,并在训练时采用随机翻转、旋转和仿射变换作为数据增强方法。其中,20 个病例(247 张切片)用于训练,剩余的 20 个病例(238 张切片)用于测试。

实验中使用的欠采样 K 空间数据由全采样的图像域数据经傅里叶变换后,再经如图 3 所示的不同加




图 3 不同加速倍数下的 K 空间掩模。(a) 4 倍加速下的掩模;  
(b) 8 倍加速下的掩模  
Fig. 3 Examples of 1D random K-space mask with different acceleration factors. (a) Mask under  $4 \times$  acceleration; (b) mask under  $8 \times$  acceleration



速倍数下的一维掩模处理所得。在两个数据集上分别完成了 4 倍加速下的实验,并在 ATLAS 数据集上完成了 8 倍加速下的实验,以验证所提方法的泛化性。

实验基于 Pytorch 深度学习框架实现,编译环境为 Python3.7,采用英伟达 2080 Ti 和特斯拉 V100 作为硬件支持。实验过程中采用了 Adam (adaptive moment estimation) 优化器来加速收敛,重建任务的损失函数采用 L1 范数,分割任务的损失函数采用二元交叉熵函数,初始学习率设置为  $1 \times 10^{-4}$ ,每隔 10 个 epoch,学习率以 0.2 进行衰减。其中,在 ATLAS 数据集上批量大小设置为 16,模型训练了 50 个 epoch,在内部数据集上批量大小设置为 4,模型训练了 100 个 epoch。

### 3.2 量化评估指标

使用 5 个评价指标来评估所提方法在两个数据集上的性能,包括 Dice 系数、精确度 (precision)、召回率

(recall)、峰值信噪比 (PSNR) 和结构相似性 (SSIM)。整体实验是在加速因子设置为 4 时完成的。

### 3.3 ATLAS 数据集上的比较与评估

为了验证所提方法的有效性,在公开数据集 ATLAS 上进行了对比实验。需要注意的是,所提方法和 SegNetMRI 可以同时提供重建和分割结果,而 SynNet、LI-Net 和 SERANet 只能得到分割结果。表 1 和图 4 展示了 4 倍加速下 ATLAS 数据集上不同方法的重建与病灶分割性能的指标结果和视觉效果对比。从表 1 可以看出,相比于对比算法,所提方法在 Dice 分数、峰值信噪比、结构相似度上均有一定的提升。此外,选择了两个切片来展示不同算法的重建性能,如图 4 所示。从图 4 可以看出,参与实验对比的算法都能够得到较为清晰的重建图像,但重建结果在细节上仍存在一些差异。所提方法重建误差更小,能够更有效地去除混叠伪影。

表 1 不同方法在 ATLAS 数据集上的实验结果 (4 倍加速),粗体表示每个指标最好的结果

Table 1 Experimental results of different methods on the ATLAS dataset (acceleration factor is 4), bold letters indicate the best result

Method	Dice	Precision	Recall	PSNR /dB	SSIM
SynNet	0.331±0.055	0.473±0.090	0.318±0.065		
LI-Net	0.338±0.060	0.494±0.095	0.303±0.060		
SERANet	0.353±0.072	<b>0.682±0.126</b>	0.280±0.060		
SegNetMRI	0.224±0.067	0.618±0.164	0.156±0.034	28.22±0.746	0.950±0.00600
U-Net	0.451±0.070	0.641±0.085	0.409±0.075		
D5C5				28.78±0.689	0.958±0.00005
Ours	<b>0.515±0.067</b>	0.665±0.079	<b>0.490±0.077</b>	<b>28.88±0.763</b>	<b>0.959±0.00005</b>

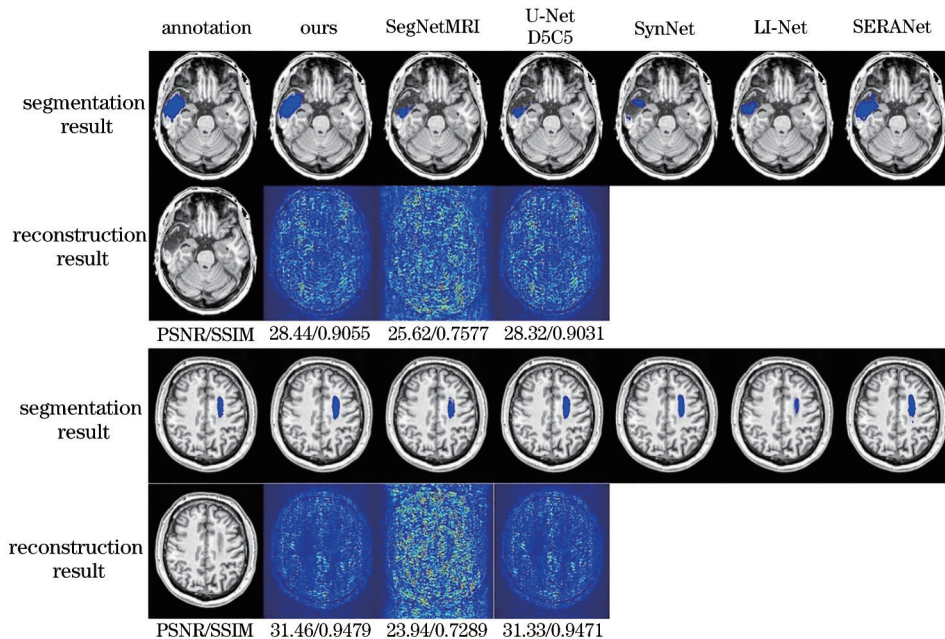


图 4 ATLAS 数据集上病变区域分割结果和重建误差 (4 倍加速),从左到右依次是 annotation,ours,SegNetMRI,U-Net (上半图)和 D5C5 (下半图),SynNet,LI-Net,SERANet

Fig. 4 Examples of lesion segmentation results and image reconstruction error maps of samples on the ATLAS dataset (acceleration factor is 4), from left to right is annotation, ours, SegNetMRI, U-Net (top) and D5C5 (bottom), SynNet, LI-Net, SERANet

对不同算法在 ATLAS 数据集上的分割 Dice 分数进行了可视化,如图 5 所示。从琴形图中可以看出,所提方法的 Dice 分数中位数最大,分割性能稳定地优于其他对比算法。为了与现有的分割算法进行全面比较,展示了不同病灶大小下各对比算法的 Dice 分数箱线图,如图 6 所示。为了便于比较,将病灶区按大小分为 5 类,由此可以测试不同分割算法对病灶大小的敏感度。分类依据是单个病例下分割标签的像素个数总

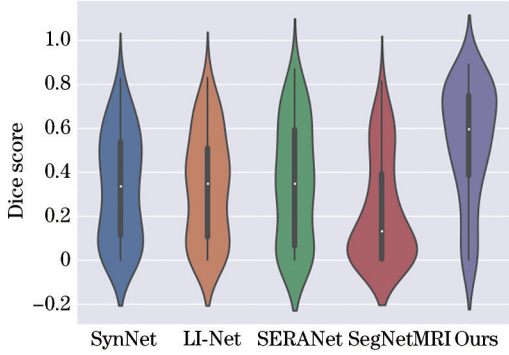


图 5 ATLAS 数据集上的分割结果的琴形图

Fig. 5 Violin-plot of the segmentation results on the ATLAS dataset

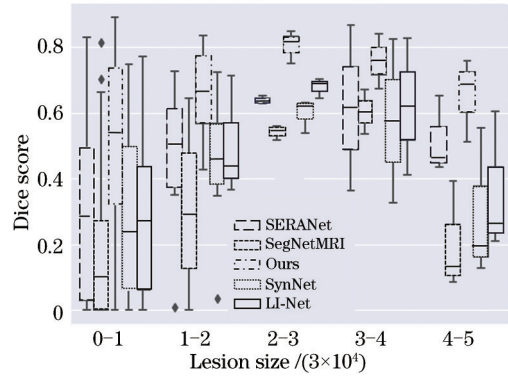


图 6 ATLAS 数据集上的分割结果的箱线图

Fig. 6 Boxplot of the segmentation results on the ATLAS dataset

和,数值结果被缩放 30000。如图 6 所示,所有算法对中等大小的病灶(横坐标为 2~3)的分割效果都很好。值得注意的是,相比于其他对比算法,所提方法在所有病灶大小区间上都取得了令人满意的结果,这进一步表明了所提方法的有效性和鲁棒性。此外,还在 ATLAS 数据集上进行了 8 倍加速的实验,表 2 的定量结果显示所提方法可以更好地适应更高的加速倍数。

表 2 不同方法在 ATLAS 数据集上的结果(8 倍加速)

Table 2 Experimental results of different methods on the ATLAS dataset (acceleration factor is 8)

Method	Dice	Precision	Recall	PSNR /dB	SSIM
SynNet	0.311±0.063	0.506±0.098	0.268±0.057		
LI-Net	0.312±0.056	0.458±0.095	0.288±0.059		
SERANet	0.303±0.080	0.582±0.151	0.245±0.065		
SegNetMRI	0.081±0.019	0.368±0.197	0.050±0.009	22.96±0.678	0.887±0.0001
U-Net	0.420±0.069	0.571±0.093	0.393±0.075		
D5C5				22.98±0.666	0.888±0.0002
Ours	<b>0.445±0.073</b>	<b>0.628±0.095</b>	<b>0.407±0.077</b>	<b>23.04±0.610</b>	<b>0.892±0.0002</b>

### 3.4 消融实验

主要评估所提教师督导体系的有效性。消融分析研究在加速因子设置为 4 的 ATLAS 数据集上完成,对比了有无教师督导策略时的模型性能表现。从表 3

表 3 ATLAS 数据集上教师督导体系有效性的消融分析(4 倍加速)

Table 3 Ablation study on the ATLAS dataset of effectiveness evaluation of the proposed teacher forcing scheme (acceleration factor is 4)

TFS	Dice	Precision	Recall	PSNR /dB	SSIM
	0.494±0.071	0.636±0.135	0.462±0.067	28.78±0.732	0.957±0.00005
✓	<b>0.515±0.067</b>	<b>0.665±0.079</b>	<b>0.490±0.077</b>	<b>28.88±0.763</b>	<b>0.959±0.00005</b>

### 3.5 内部数据集上的比较与评估

为了进一步验证所提方法的有效性,还设计了 4 倍加速下内部数据集上的实验。重建图像与病灶分割结果对比如表 4 和图 7 所示。在内部数据集上,所提方法在重建任务和分割任务上都取得了较好的性

展示的定量对比结果可以看出,在加入设计的教师督导训练方法之后,联合训练的网络模型在重建与分割上都获得了一定的性能提升。

能, Dice 分数为 0.864, PSNR 为 32.65 dB, SSIM 为 0.986。如图 7 所示,所提方法提取到的分割区域更接近医生手动标注的区域,重建出的图像误差更小。与对比算法的重建误差图和分割结果相比,所提方法在这两个任务中更有效。

表 4 不同方法在内部数据集上的实验结果(4倍加速)

Table 4 Experimental results of different methods on the in-house dataset (acceleration factor is 4)

Method	Dice	Precision	Recall	PSNR /dB	SSIM
SegNetMRI	0.841±0.004	0.814±0.024	0.859±0.033	32.52±0.057	0.983±0.006
U-Net	0.854±0.015	0.830±0.007	0.789±0.107		
D5C5				32.49±0.044	0.984±0.008
Ours	<b>0.864±0.001</b>	<b>0.880±0.011</b>	<b>0.868±0.031</b>	<b>32.65±0.013</b>	<b>0.986±0.001</b>

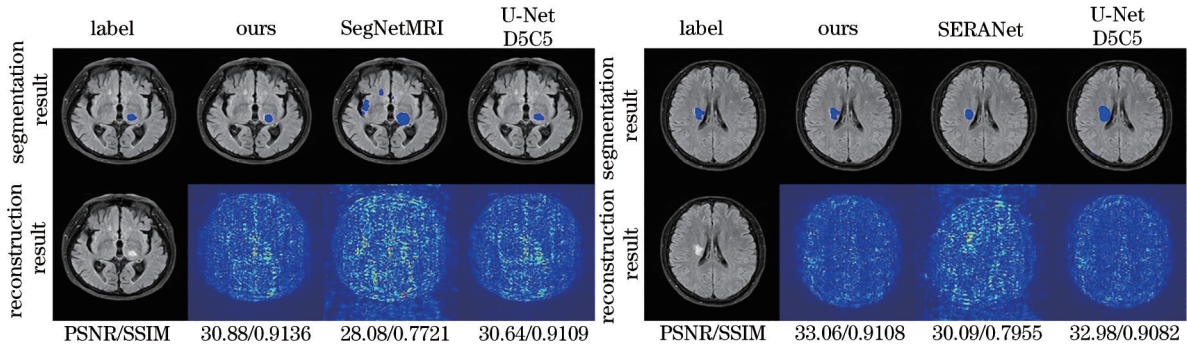


图 7 内部数据集上的病变区域分割结果和重建误差(4倍加速),从左到右依次是 label,ours,SegNetMRI,U-Net (上半图)和 D5C5 (下半图)

Fig. 7 Examples of lesion segmentation results and image reconstruction error maps of samples on the in-house dataset (acceleration factor is 4), from left to right is label, ours, SegNetMRI, U-Net (top) and D5C5 (bottom)

## 4 结 论

提出了一个基于教师督导网络训练的多任务磁共振成像框架。所提出的教师督导训练框架可以缓解上游图像重建任务的误差积累,减轻其对下游病灶分割任务的性能影响,具有降低协同多任务网络训练难度的作用。与对比算法相比,所提方法分别在重建和分割任务都得到了更好的结果,并且所提方法可以有效地分割小病灶区,这在临床应用中具有重要的意义。在研究中发现,重建和分割任务在整体框架中的权重占比对训练多任务网络有一定影响,因此对任务自适应权重的研究也是一个具有意义的研究方向。此外,目前所提教师督导体系在静态成像上取得了令人满意的性能,未来可以尝试用于难度更大的动态多任务成像场景,如心脏电影成像等。

## 参 考 文 献

- [1] Bruno F, Arrigoni F, Palumbo P, et al. New advances in MRI diagnosis of degenerative osteoarthropathy of the peripheral joints[J]. *La Radiologia Medica*, 2019, 124(11): 1121-1127.
- [2] Ebrahimzadeh E, Fayaz F, Ahmadi F, et al. A machine learning-based method in order to diagnose lumbar disc herniation disease by MR image processing[EB/OL]. [2021-05-03]. <http://www.medtextpublications.com/medlife/articles/MOA-0002.pdf>.
- [3] Cao P, Shan X F, Zhao D Z, et al. Sparse shared structure based multi-task learning for MRI based cognitive performance prediction of Alzheimer's disease [J]. *Pattern Recognition*, 2017, 72: 219-235.
- [4] Taylor S A, Mallett S, Ball S, et al. Diagnostic accuracy of whole-body MRI versus standard imaging pathways for metastatic disease in newly diagnosed non-small-cell lung cancer: the prospective Streamline L trial [J]. *The Lancet Respiratory Medicine*, 2019, 7(6): 523-532.
- [5] Beddy P, O'Neill A C, Yamamoto A K, et al. FIGO staging system for endometrial cancer: added benefits of MR imaging[J]. *Radiographics*, 2012, 32(1): 241-254.
- [6] Dettle S, Schilling S, Duperron M G, et al. Clinical significance of magnetic resonance imaging markers of vascular brain injury: a systematic review and meta-analysis[J]. *JAMA Neurology*, 2019, 76(1): 81-94.
- [7] 王选齐, 杨锋, 曹斌, 等. 卷积神经网络在甲状腺结节诊断中的应用[J]. *激光与光电子学进展*, 2022, 59(8): 0810005.
- [8] Wang X Q, Yang F, Cao B, et al. Application of convolution neural network in diagnosis of thyroid nodules [J]. *Laser & Optoelectronics Progress*, 2022, 59(8): 0810005.
- [9] Aggarwal H K, Mani M P, Jacob M. MoDL: model-based deep learning architecture for inverse problems[J]. *IEEE Transactions on Medical Imaging*, 2019, 38(2): 394-405.
- [10] Kabkab M, Samangouei P, Chellappa R. Task-aware compressed sensing with generative adversarial networks [EB/OL]. (2018-02-05)[2021-03-04]. <https://arxiv.org/abs/1802.01284>.
- [11] Wang S, Li C, Wang R, et al. Annotation-efficient deep learning for automatic medical image segmentation[J]. *Nature Communications*, 2021, 12: 5915.



- [11] 张欢, 仇大伟, 冯毅博, 等. U-Net模型改进及其在医学图像分割上的研究综述[J]. 激光与光电子学进展, 2022, 59(2): 0200005.  
Zhang H, Qiu D W, Feng Y B, et al. Improved U-Net models and its applications in medical image segmentation: a review[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0200005.
- [12] Wang S S, Su Z H, Ying L, et al. Accelerating magnetic resonance imaging via deep learning[J]. IEEE International Symposium on Biomedical Imaging, 2016, 2016: 514-517.
- [13] Zhu B, Liu J Z, Cauley S F, et al. Image reconstruction by domain-transform manifold learning[J]. Nature, 2018, 555(7697): 487-492.
- [14] 张登强, 庞彦伟, 刘霄汉. 基于双域并行编解码网络的磁共振图像重建[J]. 激光与光电子学进展, 2022, 59(12): 1210014.  
Zhang D Q, Pang Y W, Liu X H. Reconstruction of dual-domain crossed magnetic resonance images based on codec network[J]. Laser & Optoelectronics Progress, 2022, 59(12): 1210014.
- [15] 段继忠, 和晓珣, 刘畅, 等. 基于 $L_p$ 范数联合全变分的磁共振成像重构方法[J]. 激光与光电子学进展, 2021, 58(24): 2411001.  
Duan J Z, He X X, Liu C, et al. Method of magnetic resonance imaging reconstruction based on  $L_p$ -norm joint total variation[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2411001.
- [16] 牟海维, 郭颖, 全星慧, 等. 一种基于改进U-Net脑肿瘤MRI图像分割方法[J]. 激光与光电子学进展, 2021, 58(4): 041022.  
Mou H W, Guo Y, Quan X H, et al. Magnetic resonance imaging brain tumor image segmentation based on improved U-Net[J]. Laser & Optoelectronics Progress, 2021, 58(4): 041022.
- [17] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [18] 张恒良, 李镔, 关欣. 一种改进的三维双路径脑肿瘤图像分割网络[J]. 光学学报, 2021, 41(3): 0310002.  
Zhang H L, Li Q, Guan X. An improved three-dimensional dual-path brain tumor image segmentation network[J]. Acta Optica Sinica, 2021, 41(3): 0310002.
- [19] Schlemper J, Oktay O, Bai W J, et al. Cardiac MR segmentation from undersampled k-space using deep latent representation learning[M]//Frangi A F, Schnabel J A, Davatzikos C, et al. Medical image computing and computer assisted intervention-MICCAI 2018. Lecture notes in computer science. Cham: Springer, 2018, 11070: 259-267.
- [20] Huang Q Y, Chen X, Metaxas D, et al. Brain segmentation from k-space with end-to-end recurrent attention network[M]//Shen D G, Liu T M, Peters T M, et al. Medical image computing and computer assisted intervention-MICCAI 2019. Lecture notes in computer science. Cham: Springer, 2019, 11766: 275-283.
- [21] Sun L Y, Fan Z W, Ding X H, et al. Joint CS-MRI reconstruction and segmentation with a unified deep network[M]//Chung A C S, Gee J C, Yushkevich P A, et al. Information processing in medical imaging. Lecture notes in computer science. Cham: Springer, 2019, 11492: 492-504.
- [22] Williams R J, Zipser D. A learning algorithm for continually running fully recurrent neural networks[J]. Neural Computation, 1989, 1(2): 270-280.
- [23] Schlemper J, Caballero J, Hajnal J V, et al. A deep cascade of convolutional neural networks for dynamic MR image reconstruction[J]. IEEE Transactions on Medical Imaging, 2018, 37(2): 491-503.
- [24] Liew S L, Anglin J M, Banks N W, et al. A large, open source dataset of stroke anatomical brain images and manual lesion segmentations[J]. Scientific Data, 2018, 5: 180011.