

基于 T1 加权图像的白质纤维束分割方法

焦瑞柯¹, 张小凤², 叶初阳¹

(1. 北京理工大学集成电路与电子学院, 北京 100081; 2. 北京理工大学(珠海)大湾区创新研究院, 珠海 519088)

摘要: 白质纤维束分割方法通过识别连接不同脑区的白质通路, 为脑连接分析提供了重要的神经通路参考信息。然而, 传统的白质纤维束分割方法主要依赖于弥散磁共振图像 (Diffusion magnetic resonance imaging, dMRI), 由于获取弥散磁共振图像比较耗时, 这极大地限制了其在临床中的应用。为解决此问题, 提出了一种基于 T1 加权图像的白质纤维束分割方法, 通过计算 T1 加权图像的结构张量来提示可能的纤维走向, 进而提高白质纤维束的分割精度。此外, 本文在模型训练期间引入弥散磁共振图像的特权信息来指导模型学习, 从而提升白质束分割模型性能, 具有挑战性的束分割效果提升明显, 其中左穹窿 (Left fornix, FX_left) 的 Dice 得分提高了 5%, 右穹窿 (Right fornix, FX_right) 的 Dice 得分提高了 6%。本研究弥补了在缺少弥散磁共振图像的场景下无法进行神经通路分析的不足, 扩展了神经通路分析的应用场景。

关键词: 医学图像分割; 白质纤维束; 特权信息; T1 加权图像; 弥散磁共振图像

中图分类号: TP391 **文献标志码:** A

White Matter Fiber Tract Segmentation Method Based on T1-Weighted Imaging

JIAO Ruike¹, ZHANG Xiaofeng², YE Chuyang¹

(1. School of Integrated Circuits and Electronics, Beijing Institute of Technology, Beijing 100081, China; 2. Greater Bay Area Innovation Research Institute, Beijing Institute of Technology (Zhuhai), Zhuhai 519088, China)

Abstract: White matter fiber tract segmentation methods provide crucial neural pathway reference information for brain connectivity analysis by identifying white matter tracts connecting distinct brain regions. Traditional segmentation methods predominantly depend on diffusion magnetic resonance imaging (dMRI), but the lengthy acquisition time of dMRI severely restricts its clinical applicability. To address this limitation, this paper introduces a white matter fiber tract segmentation approach based on T1-weighted imaging. This method leverages the structural tensor of T1-weighted images to infer potential fiber orientations, thereby enhancing the segmentation accuracy of white matter tracts. Moreover, the proposed method incorporates privileged information from dMRI during model training to guide the learning process, thus improving the performance of the white matter tract segmentation model, and the segmentation of challenging tracts is improved significantly, with a 5% improvement in Dice score for the left fornix (FX_left) and a 6% improvement in Dice score for the right fornix (FX_right). This approach mitigates the limitations of conducting neural pathway analysis in the absence of dMRI, broadening the

基金项目: 北京市自然科学基金 (7242273); 中央高校基本科研业务费专项资金 (2024CX06040); 广东省“天临空地海”复杂环境智能探测重点实验室研究基金 (2022KSYS016)。

收稿日期: 2024-06-09; **修订日期:** 2024-07-01

application scope of neural pathway analysis.

Key words: medical image segmentation; white matter fiber tracts; privileged information; T1-weighted imaging; diffusion magnetic resonance imaging (dMRI)

引言

大脑是人体神经系统的核心,了解其结构和功能有助于揭示认知、感知和情感等方面的基本机制,能够更全面、深入地理解人类思维和行为的本质^[1-3]。在大脑内部结构中,每一侧大脑半球均由外层的灰质和深层的白质所构成。灰质主要包含神经元胞体,而白质则是由轴突集结而成的束状结构。为实现正常的大脑功能,各特定灰质区域之间需要通过白质纤维通道进行精密而复杂的连接。脑白质神经束承载着神经冲动和信息传递的重要任务,连接了大脑的不同部分,促进了神经元之间的通信。总体而言,脑白质神经束对于支持大脑各部分之间的协调和通信至关重要,是神经系统正常功能的关键组成部分。临床实践中,准确了解白质神经通路受病变影响的情况,对于理解患者脑功能障碍以及脑疾病患者术后功能恢复的过程具有重要的学术和临床价值,从而推进脑疾病的防治。

在传统工作中,由神经解剖学专家手工识别是提取纤维束最常用的方法^[4]。这需要具备丰富解剖经验的专家对基于纤维追踪技术得到的代表神经纤维的三维流线进行人工筛选,从流线图中手动提取与解剖学上定义良好的白质纤维束相对应的流线,实现白质纤维束手动分割。虽然这个过程产生了精确的感兴趣区域,但高分辨率图像的手动描绘是非常密集型的劳动,手工标注工作量繁重。因此,在过去10年里,已经开发了各种自动化白质纤维束区域识别的方法来替代人工分割,减轻人工分割的局限性。

基于聚类的传统分割方法是一种尝试将纤维追踪生成的流线分组为相干聚类的策略。基于聚类的白质纤维束分割方法主要是应用聚类算法对流线特征进行分组,此类算法根据特征之间的相似性将数据点划分为不同的簇,即将纤维流线划分为不同的束簇,基于纤维之间距离度量的纤维聚类可用于寻找跨对象的稳定束^[5]。在无监督模式下,纤维聚类需要首先得到每条流线的几何信息,计算其与其他流线的相似性或距离,不依赖于任何标记数据来获得纤维束类别。例如,QB(Quick bundles)^[6]是一种简单、紧凑且定制的聚类算法,它克服了大型数据集复杂性高的问题,可以在几秒钟内提供信息丰富的聚类。每个QB簇可以用单个质心流线来表示,这些质心流线可以被视为纤维束成像的有效表示。另一方面,有监督纤维聚类需要使用白质图谱、专家制作的样本束或解剖学的预定义信息来指导聚类任务,依赖先验信息。Cabeen等^[7]通过在纤维束追踪数据集中提取稀疏且具有代表性的标记点,使用最近点变换方法相对于标记点进行变换曲线,提高白质纤维聚类准确性。

近年来,随着深度学习技术在图像处理任务中的广泛应用,研究者们提出了基于深度网络的白质纤维束分割方法,极大地提升了分割的准确性。基于深度学习技术的白质纤维束自动分割方法可以根据输入数据分为基于纤维流线型和基于体素型。基于纤维流线的白质纤维束分割方法利用预先指定的纤维特征进行神经网络训练,从而实现白质纤维束自动分割。因此,首先要进行纤维追踪获得纤维流线信息,据纤维流线的几何形态和空间位置等信息计算流线特征图,然后将特征图输入深度网络实现纤维流线的分类,得到白质纤维束分割结果。基于体素的白质纤维束分割方法是直接从原始图像中提取白质纤维束,判断体素中是否包含白质纤维束或方向信息。Wasserthal等^[8]提出了一种对体素进行直接标记的白质纤维束自动分割方法 Tractseg,该方法将从弥散磁共振图像(Diffusion magnetic resonance image, dMRI)计算得到的纤维方向信息输入神经网络,得到白质纤维束分割结果。

基于扩散加权磁共振的纤维束成像方法是研究白质的主要工具,但此类方法依赖于采集耗时的弥

散磁共振图像^[9-10],使其并不总是可用的,特别是对于遗留或时间有限的研究。为解决此问题,Yang 等^[11]提出了一种多重空间局部卷积神经网络,从结构磁共振图像标准模板的固定空间块中学习上下文信息,获得与基于纤维束标注方法一致的白质纤维束分割结果。这证明了从 T1 加权图像(T1-weighted imaging, T1w)中实现鲁棒性白质纤维束分割的可行性,即使在缺乏弥散磁共振图像时,通过使用结构磁共振图像也能够可视化神经通路,为在临床应用和神经科学研究中更广泛地应用白质纤维束分割提供了一种更便捷的替代方法。但是,该方法将 T1 加权图像配准至蒙特利尔神经学研究所的脑成像国际联盟 152 不对称模板空间,其结果不是每个受试者的特异性分割结果。

为实现精确、高效的白质神经束分割,基于深度学习的方法被广泛应用于白质纤维束分割问题中,并获得了具有前景的结果^[12-14]。脑神经通路的重建需要弥散磁共振图像,而该成像方式极为耗时,通常无法在成像时间有限的场景下进行采集。现有的白质束分割方法大多数都是基于弥散磁共振图像,但是临床场景下缺少该图像,则无法进行神经通路分析,限制了白质纤维束分析的应用场景。因此,本文旨在研究临床场景下基于 T1 加权图像的白质纤维束分割,进一步提高分割准确率,以推动白质纤维束分割在脑疾病研究中的广泛应用。

1 本文方法

如图 1 所示,本文提出了一种基于 T1 加权图像的白质纤维束分割算法,在弥散磁共振图像质量差或缺失的临床场景进行神经通路定位分析。通过计算 T1 加权图像的结构张量来提供可能的白质纤维走向信息,从而提升白质纤维束的分割精度。此外,在模型训练期间引入弥散磁共振图像的特权信息,在测试期间提升基于 T1 加权图像的白质束分割模型性能,扩展神经通路分析场景。

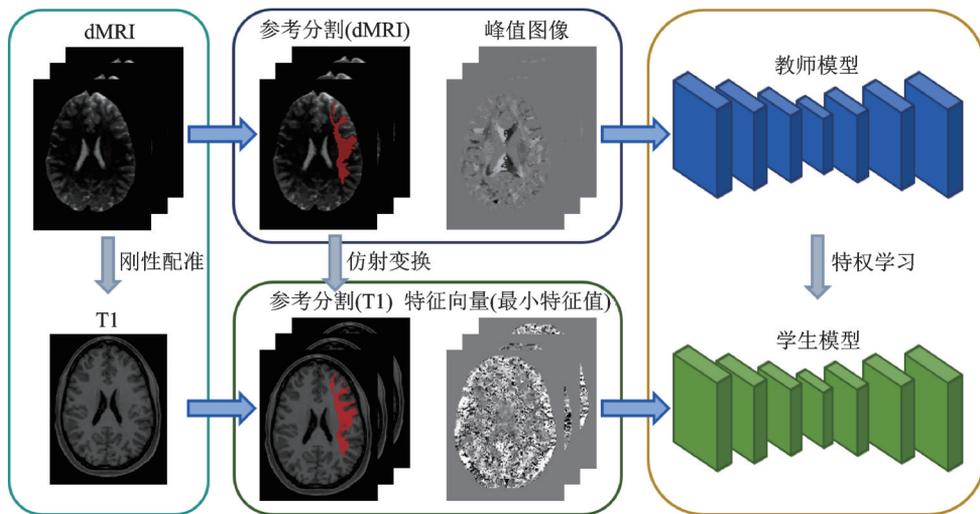


图1 本文方法整体框架

Fig.1 Overall framework of the proposed method

1.1 参考分割生成及数据预处理

本文使用来自人类连接组项目中 100 位受试者高分辨率的 T1 加权图像和弥散磁共振图像进行模型训练和测试。为了使弥散磁共振图像适合于纤维束造影,需要多个梯度方向和高梯度值,这在临床环境中并不常见,而且成像需要较长的扫描时间。T1 加权成像是一种结构磁共振成像技术,通常用于获取生物组织的高分辨率图像,以显示解剖结构和组织类型的详细信息。结构磁共振图像获取简单而

且广泛应用于神经成像研究和临床环境。高分辨率的 T1 加权图像是用于揭示人类大脑皮层功能连接和结构连接的主要方式,提供卓越的解剖细节,实现了对皮层区域的准确描绘,这使得从结构磁共振图像中分割出白质束成为可能。

利用 Tractseg 方法^[8]中半自动方法生成的 72 个白质纤维束区域的高质量分割结果和配准流程生成本文方法的参考分割(T1 空间)。通过半自动化方法获得的参考分割处于弥散磁共振图像空间,不能直接使用。因此,首先提取每位受试者弥散磁共振图像中场强大小(B 值)为 0 s/mm^2 的图像;然后使用 FMRIB 软件库将每个受试者 B 值为 0 s/mm^2 图像的体积刚性配准到同一受试者的 T1 加权图像空间;最后通过配准步骤获得仿射矩阵,将白质纤维束标注(dMRI 空间)仿射重定向配准到同一受试者的 T1 加权图像空间中,作为本文方法的参考分割(T1 空间)。

1.2 结构张量

T1 加权图像是脑结构图像,缺乏纤维束方向的有效信息,而结构张量通过考虑局部邻域来描述图像中的特征^[15],因此本文通过使用结构张量分析数据,提供可能的纤维方向信息。结构张量分析是对图像梯度向量形成的局部张量特征进行分析,估计预定义邻域内强度值变化最小的局部三维方向。对于包含神经纤维的体素,该方向是沿着纤维的主轴线指向。

图像中体素的方向可以根据强度梯度的局部向量场来估计,梯度向量的外积是一个 3×3 的结构张量,用来避免比邻域更小元素的抵消效应。通过在体素附近集成数据(平滑处理),可以在图像中存在噪音的情况下增强方向估计的稳健性。为了对白质边界平面的局部方向进行鲁棒估计,采用了数据自适应结构张量。对于这种结构张量,平滑优先发生在纤维束的方向上,同时限制了纤维束之间边缘上的平滑。

结构张量 J 是通过梯度构造的三阶张量,即

$$J = \begin{bmatrix} I_a^2 & I_{ab} & I_{ac} \\ I_{ba} & I_b^2 & I_{bc} \\ I_{ca} & I_{cb} & I_c^2 \end{bmatrix} \quad (1)$$

式中: I 表示图像; a, b, c 表示3个方向; I_a 为图像在 a 方向的梯度。

为了过滤 T1 加权图像,通过实验确定的参数值,以保持目标纤维束之间的边缘,从而保持白质纤维束的准确定位,同时给出平滑的结构张量场,不被数据中的小伪影(如静脉)和噪声破坏。对每个体素的平滑张量矩阵进行特征分解,提取特征值和特征向量。特征值表示图像强度的局部梯度,纤维轴方向的梯度最小,纤维的方向对应最小特征值的特征向量。分数各向异性图像(Fractional anisotropy, FA)是一种用于评估大脑白质纤维束结构完整性的图像,三维结构张量最小特征值对应的特征向量以短线的形式叠加在分数各向异性图像上,如图 2 所示。

1.3 基于特权信息的白质束分割方法

在临床脑疾病研究中,T1 加权图像等脑结构图像数量丰富且应用广泛,但是在白质纤维束分割方面,脑结构图像提供的纤维信息有一定局限性。特权信息是指训练时可用的额外信息来帮助学习一个特定的目标模式,而特权模态不需要在测试阶段执行预测。受蒸馏和特权信息统一框架的启发,特权

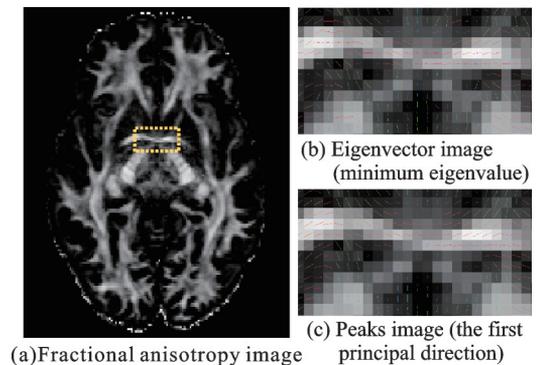


图 2 纤维方向对比

Fig.2 Comparison of fiber directions

知识学习可以表述为广义知识蒸馏过程,采用特权知识学习的师生架构,使用具有丰富分割知识的教师模型为基于目标模态的学生模型提供特权信息监督,从而提升目标任务的分割效果。因此,本文方法使用基于弥散磁共振图像的特权信息来指导 T1 加权图像的白质束分割,训练时使用两种模态信息,测试时仅需要 T1 加权图像就可以得到高质量白质纤维束分割结果。

1.3.1 特权知识

本文方法使用一组由成对模态组成的训练数据 $\{X, X^*\}$ 和标签 Y , 目标模态的数据 $X = \{x_i\}_{i=1}^N$ 在训练和测试阶段都是可用的, 而特权模态的数据 $X^* = \{x_i^*\}_{i=1}^N$ 只在训练数据中可用, 在测试期间无法访问。本文提出的特权知识学习框架旨在训练阶段利用特权模态 X^* , 使测试阶段的分割模型优于仅建立在目标模式 X 上的模型。

为此,受广义蒸馏框架的启发,首先使用特权模态数据集 $\{X^*, Y\}$ 来学习一个教师模型 f^T 。通过利用特权模态中的信息,教师模型获得了关于分割领域的丰富知识。然后,从教师模型中提取学习到的知识,表示为变量 $K = \{k_i\}_{i=1}^N$, 从而改进只使用目标模态 X 作为输入的学生模型 f^S 的学习过程。利用训练数据对 $\{x_i, y_i\}$ 和 $\{x_i, k_i\}$ 学习学生模型 f^S , 对应于以下优化问题

$$f^S = \arg \min_f \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\sigma(f(x_i)), y_i) + \mathcal{L}(g(f(x_i)), k_i) \quad (2)$$

式中: σ 表示激活函数; g 表示将 $f(x_i)$ 转换为编码知识形式的函数。通过这种方式,学生模型的学习得到了真相标签和来自教师的额外监督的支持,没有直接使用特权模态。

1.3.2 像素级蒸馏

弥散磁共振图像可以提供准确的白质纤维束方向信息,在本文方法中使用弥散磁共振图像作为特权模态。利用 MRtrix 软件中的多壳多组织约束球面反卷积从原始弥散磁共振图像中提取纤维方向图,教师模型接收每个体素的 3 个主要纤维方向,即峰值图像作为输入,所以需要 9 个不同的输入通道(每个主方向 3 个)。其中,白质纤维第一主方向如图 2(c) 所示。

T1 加权图像缺乏纤维方向信息,不适合直接进行纤维分割,因此本文使用 T1 加权图像计算结构张量作为学生模型的输入。使用结构张量来估计局部方向的过程中有两个重要参数的设定: d_σ 参数用于控制构建每个体素的结构张量的高斯导数滤波器的宽度; d_ρ 参数用于定义局部邻域并控制噪声的高斯滤波器的宽度。这两个参数共同影响局部方向的估计,可以用来适应不同的数据和结构尺度。选择适当的 d_σ 和 d_ρ 得到 T1 加权图像的结构张量,并计算最小特征值对应的特征向量作为分割网络的输入。

在本文方法中,教师模型和学生模型使用相同的 U-Net 网络架构和默认的 U-Net 网络参数,即具备相同数量的参数。此外,教师网络和学生网络只有输入数据不同,教师网络的输入是弥散磁共振图像的峰值图像和对应 dMRI 空间的参考分割,为 9 个输入通道,学生网络的输入是 T1 加权图像的结构张量最小特征值对应的特征向量和 T1 空间的参考分割,为 3 个输入通道。U-Net 网络的编码器-解码器将其输入空间总结为一个潜在的表示,以捕获分割的重要信息。教师和学生处理不同的输入,但目的是提取相同的信息,因此模型的第一层是不同的,而最后一层,特别是潜在的表示是相似的。通过强迫学生模型的潜在空间与教师的潜在空间相似,使得学生模型从教师模型的额外信息中学习像素级分割。

首先,使用弥散磁共振图像的峰值图像和参考分割(dMRI 空间)训练教师模型。然后,使用像素级知识蒸馏项和参考分割(T1 空间)损失来训练学生模型。在对学生模型的训练期间,教师模型的权重会被冻结,并且学生模型的错误也不会反向传播给教师模型。像素级知识蒸馏允许学生模型通过使用教师模型的预测作为目标,并通过强迫学生模型的编码信息与教师模型的编码信息相似来向教师模型学习。同时,参考分割损失约束学生模型的预测分割类似于参考分割(T1 空间)。

白质纤维束分割是一个二分类多标签任务。在各种损失函数中,最常用的是二进制交叉熵(Binary

cross-entropy, BCE) 损失。对于给定一批例子 $\{(x_i, y_i)\}_{i=1}^N$ 和预测概率 \hat{y} , BCE 损失为

$$\mathcal{L}_{\text{BCE}} = -\frac{1}{N} \sum_{i=1}^N y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (3)$$

在传统的知识蒸馏中, 基于 logits 的蒸馏通常最小化教师模型和学生模型经过 softmax 函数处理后的预测概率之间的差异。然而, 由于该方法依赖于所有类的预测概率总和为 1 的基本假设, 而多标签分割允许一个像素或区域同时被多个类别标签所标记, 因此上述假设不成立, 所以该方法不能直接应用于多标签分割场景。采用广义知识蒸馏策略, 本文直接利用弥散磁共振图像的分割模型得到预测概率, 将有用的知识传递给 T1 加权图像的白质束分割模型。像素级知识蒸馏 (Pixel knowledge distillation, PKD) 损失为

$$\mathcal{L}_{\text{PKD}} = \sum \mathcal{L}_{\text{BCE}} \left(\sigma \left(f^T(x_i^*) \right), \sigma \left(f^S(x_i) \right) \right) \quad (4)$$

式中 σ 为 sigmoid 函数。求取 PKD 损失的目的是通过充分利用教师预测中的信息知识来提高学生模型的性能。T1 加权图像分割模型的学习过程由真实标签和弥散磁共振分割模型的预测概率共同支持, 总目标损失为

$$L = \lambda \mathcal{L}_{\text{BCE}} + (1 - \lambda) \mathcal{L}_{\text{PKD}} \quad (5)$$

式中 $\lambda \in [0, 1]$, 用于平衡参考分割与教师预测分割的影响。本文取 $\lambda = 0.5$ 。

2 实验设置与分析

2.1 实验参数

本文使用 100 例公开的人类连接组项目数据来评估所提出的方法, 其中 60 例为训练集, 20 例为验证集, 20 例为测试集。实验在 NVIDIA GeForce GTX 2080 Ti GPU 的基础上, 基于 Python 3.7 和 pytorch 1.12.1 搭建深度学习框架, 在验证集上选择与分割精度最好的 epoch 对应的模型为最优模型。使用 Adamax 最小化损失函数, 批次大小设置为 56, epoch 次数为 500, 初始学习率为 0.001。

2.2 评价指标

本文研究的内容是 T1 加权图像领域的白质纤维束分割, 实验部分所有提及的参考分割均限定于该图像空间内, 以确保评估过程的有效性。为了验证本文提出方法的准确性, 将分割结果与参考分割进行比较。为了量化分割结果和真实结果之间的一致性, 使用 Dice 得分进行度量, 其表达式为

$$\text{Dice} = \frac{2|y \cap \hat{y}|}{|y| + |\hat{y}|} \quad (6)$$

式中 Dice 用于计算标签 y 与分割结果 \hat{y} 的重叠率。 \hat{y} 由阈值对分割支路的结果进行二值化获得, 即当预测值大于阈值时取值为 1, 小于阈值时取值为 0, 本文使用的阈值为 0.5。如果平均 Dice 高于已有的最大值, 则将当前参数保存为最优模型, 最终的最优模型用于网络测试。

在本文实验中, 分割生成的目标白质纤维束共有 72 种。其中, 一些白质纤维束交叉重叠的区域分割可能比其他区域更具挑战性。因此, Liu 等^[16]在评价分割结果时将 72 种白质纤维束分为不同的分割差异组, 选择了 Dice 得分最低的 5 个白质纤维束区域作为具有挑战性的区域。由于其中一些束在大脑中是双侧的, 如果一对双侧束的一侧具有挑战性, 其对侧束也被认为是具有挑战性的。由此, 划分成一组具有显著挑战性的束区域, 包括 7 种白质纤维束 (约占总体 72 种白质纤维束的 10%), 包括左穹窿 (Left fornix, FX_left)、右穹窿 (Right fornix, FX_right)、前连合 (Commissure anterior, CA)、左下纵束 (Left inferior longitudinal fascicle, ILF_left)、右下纵束 (Right inferior longitudinal fascicle, ILF_right)、左

钩束(Left uncinat fascicle, UF_left)和右钩束(Right uncinat fascicle, UF_right),其余的白质纤维束区域(约90%)被认为是较为容易分割的白质纤维束。其中,由于前连合、左穹窿和右穹窿的分割质量显著低于上述其他具有挑战性的纤维束,因此将前连合、左穹窿和右穹窿(约4%)进一步归类为最具挑战性的束。本文重点研究具有挑战性的白质纤维束区域的分割结果。

2.3 实验结果与分析

2.3.1 实验设置

本文通过计算 T1 加权图像的结构张量来提供纤维方向信息,纤维的方向对应最小特征值的特征向量,因此本文的基线方法是以结构张量最小特征值的特征向量为输入,使用 U-Net 网络架构进行白质纤维束分割。在 T1 加权图像结构张量的计算中,高斯导数滤波器的宽度 d_σ 根据感兴趣结构的宽度来进行调整,通常设为比感兴趣结构的宽度小。 d_σ 足够小以捕获感兴趣结构的细节,而 d_ρ 可以帮助平滑和去除噪声,以获取更稳定的纤维方向估计。

通过选取不同的滤波器宽度值,寻找最佳的纤维方向估计。表 1 为定量实验结果,通过调整结构张量滤波器的宽度,获得验证集的 72 组白质纤维束分割结果的平均 Dice 得分。T1 加权图像的结构张量能提供可能的纤维走向估计,因此可获得更好的纤维分割结果。最终,通过实验确定选取滤波器宽度 $d_\sigma=0.5, d_\rho=0.5$, 此时白质纤维束分割结果最优。

2.3.2 实验结果

首先,对实验所获得的结果进行定性分析。本文主要关注具有显著挑战性的束区域,这些区域往往更加考验分割方法的精确性和稳定性。为了更直观地展示本文方法在白质区域分割上的表现,选取了一组具有代表性的测试对象,并对其白质区域进行了三维渲染图的构建和横截面视图的呈现。由于双侧束在结构上具有对称性,因此在实际分析时,仅需关注一侧的束结构即可。图 3 呈现了本文方法与基线方法在白质纤维束分割任务上的对比结果,并附以白质纤维束的标准参考分割作为参照。在横截面视图中,将白质束分割结果叠加在 T1 加权图像上,为了更好地进行比较,突出显示了区域的放大视图。对于每个白质纤维束区域,三维效果图显示在第一行,横截面视图和放大的视图分别显示在第二行的左右两侧。三维渲染图表明,在束形状方面,本文方法的结果比基线方法的结果更接近参考分割。例如,在 FX_left 的分割上,基线方法的结果出现了断裂现象,而本文方法则能够产生连续且完整的分割结果,与参考分割高度一致。此外,从横截面视图及其放大视图来看,本文方法在白质纤维束区域的空间覆盖上也展现出了更高的准确性。与基线方法相比,本文方法的分割结果更贴近于标准参考分割,能够更准确地覆盖白质纤维束的实际分布区域。

然后,通过计算测试集上分割结果的 Dice 得分,将本文方法与基线方法进行了定量比较。本文关注了 7 个具有显著挑战性的白质束区域,并计算了每个区域的平均 Dice 得分,结果如表 2 所示。由表 2 可见,在所有情况下,本文方法都获得了更高的 Dice 得分。特别是在 3 个最具挑战性的区域,CA、FX_left 和 FX_right 上,本文方法展现出了更为明显的优势。与基线方法相比,FX_left 的 Dice 得分提高了 5%,FX_right 的 Dice 得分提高了 6%。这进一步证明了本文方法在处理复杂白质束区域中的优越性和有效性。

表 1 不同滤波器宽度的分割结果的 Dice 得分

Table 1 Dice scores of segmentation results with different filter widths

滤波器宽度	Dice 得分
$d_\sigma=1.0, d_\rho=1.0$	0.794
$d_\sigma=0.5, d_\rho=1.0$	0.794
$d_\sigma=0.5, d_\rho=0.5$	0.800
T1 加权图像(无滤波器)	0.786

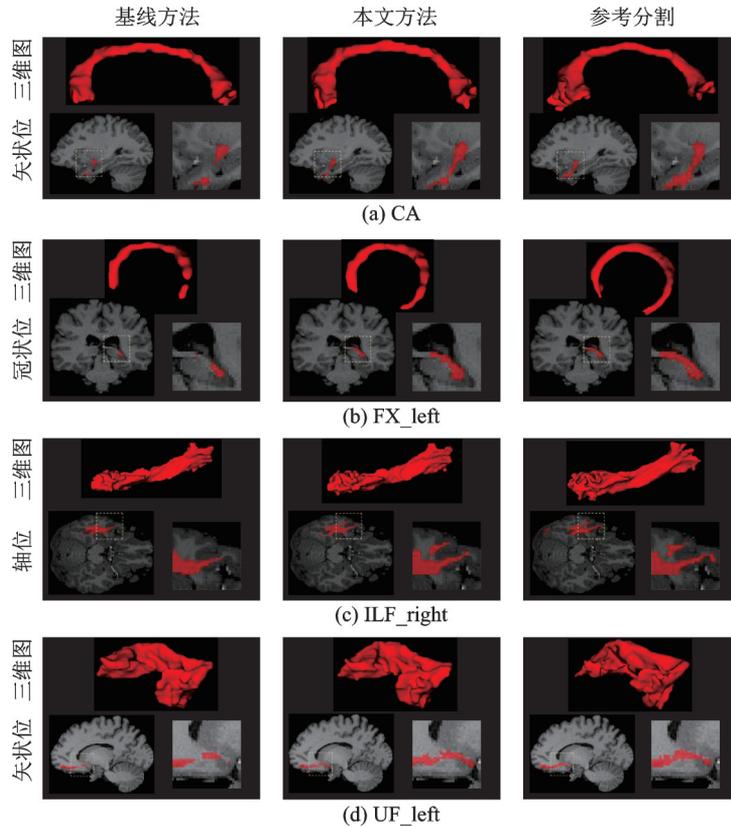


图3 白质纤维束分割结果

Fig.3 White matter tract segmentation results

表2 具有挑战性的白质束的Dice得分

Table 2 Dice scores of challenging white matter tracts

方法	Dice得分						
	CA	FX_left	FX_right	ILF_left	ILF_right	UF_left	UF_right
基线方法	0.624	0.597	0.553	0.754	0.733	0.720	0.753
本文方法	0.636	0.626	0.586	0.762	0.741	0.732	0.756

表3 不同挑战性区域的Dice得分

Table 3 Dice scores of different challenging regions

方法	平均Dice得分		
	最具挑战性束区域	显著挑战性束区域	全体评估束区域
基线方法	0.591	0.676	0.800
本文方法	0.616	0.691	0.806

在评估了本文方法与基线方法在白质纤维束分割任务上的性能后,进一步对结果进行了总结和分析。具体来说,计算了最具挑战性的束区域(约占全体评估束区域4%)、具有显著挑战性的束区域(约占全体评估束区域的10%)以及全体评估束区域的平均Dice得分,结果如表3所示。表3与表2的结果保持了一致,对于挑战性的区域,本文方法获得了更高的平均Dice得分,优于基线方法。无论是针对挑战性区域的分割任务,还是对于整体白质纤维束的分割,本文提出的白质束分割方法都展现出了优异的性能。

在评估了本文方法与基线方法在白质纤维束分割任务上的性能后,进一步对结果进行了总结和分析。具体来说,计算了最具挑战性的束区域(约占全体评估束区域4%)、具有显著挑战性的束区域(约占全体评估束区域的10%)以及全体评估束区域的平均Dice得分,结果如表3所示。表3与表2的结果保持了一致,对于挑战性的区域,本文方法获得了更高的平均Dice得分,优于基线方法。无论是针对挑战性区域的分割任务,还是对于整体白质纤维束的分割,本文提出的白质束分割方法都展现出了优异的性能。

2.4 蒸馏方法对实验结果的影响

2.4.1 蒸馏方法实验设置

本文探讨了其他4类蒸馏方法对实验结果的影响,所有实验方法均采用对应原文代码。

(1)教师模型和学生模型瓶颈之间的知识蒸馏^[17]。该方法假设编码器-解码器网络的中间潜在空间,即瓶颈部分,编码了正确分割输入图像的信息,通过使用KL(Kullback-leibler)散度作为教师和学生瓶颈之间的损失函数来约束学生模型学习教师模型编码的额外信息。

(2)预测图蒸馏(Prediction maps distillation,PM)^[18]。该方法构建了一个预测图蒸馏模块,将分割任务视为一个像素级分类问题的集合,然后计算2个网络中相同空间位置的所有像素对的损失值,并将这些值集合为该模块的蒸馏损失。

(3)正则化知识蒸馏(Regularized knowledge distillation,RKD)^[19]。该方法在正则化因子和教师与学生软化输出的交叉熵损失之间进行像素级的乘法,形成一个正则化的知识蒸馏损失。只有当教师在不同的位置做出正确的预测时,才允许知识转移。

(4)多标签日志蒸馏(Multi-label logits distillation,MLD)^[20]。该方法将原始的多标签任务分解为多个二值分类问题,并使2个模型的二值预测概率之间的差异最小化。多标签日志蒸馏损失的目的是通过充分利用日志中的信息知识来提高学生模型的性能。

2.4.2 不同蒸馏方法实验结果与讨论

所有实验结果均采用相同的20例测试数据的平均值,定性结果如图4所示,定量结果如表4所示,其中每个具有挑战性的白质纤维束区域分解的最优结果以粗体突出显示。由实验结果可知:

(1)在师生模型瓶颈之间的知识蒸馏结果中,在某些特定的束区域,模型所实现的分割精度甚至未

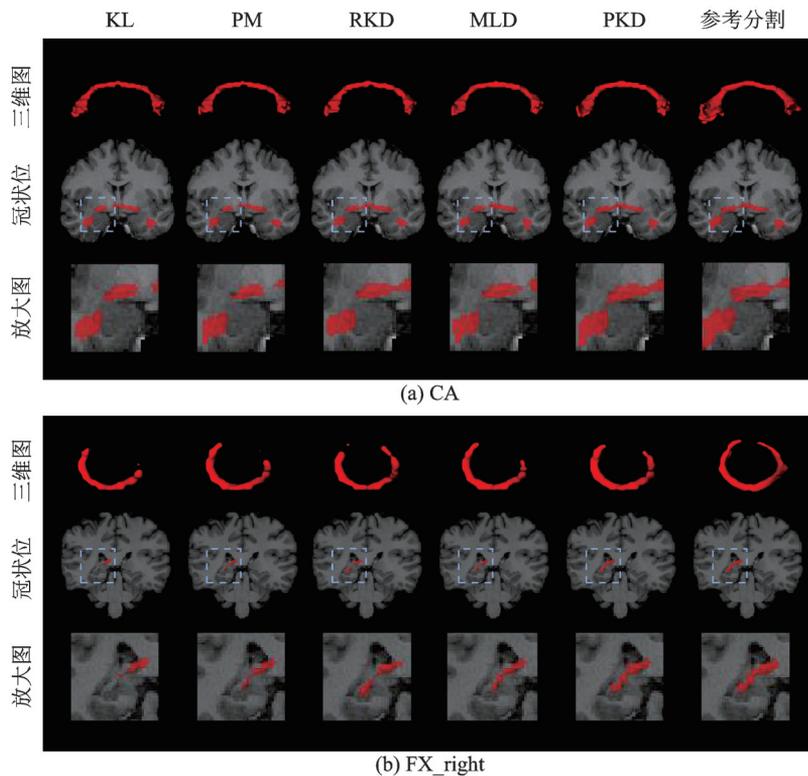


图4 不同蒸馏方法分割结果

Fig.4 Segmentation results of different distillation methods

表4 不同蒸馏方法实验结果

Table 4 Experimental results of different distillation methods

方法	平均Dice得分						
	CA	FX_left	FX_right	ILF_left	ILF_right	UF_left	UF_right
KL	0.619	0.601	0.555	0.741	0.723	0.713	0.744
PM	0.626	0.623	0.575	0.761	0.741	0.720	0.754
RKD	0.626	0.598	0.546	0.749	0.731	0.715	0.748
MLD	0.625	0.622	0.584	0.755	0.737	0.723	0.753
PKD	0.636	0.626	0.586	0.762	0.741	0.732	0.756

达到预期的基线水平,这主要源于师生模型之间信息输入的差异性导致信息编码处理的不匹配。具体来说,教师模型在处理数据时,是以弥散磁共振图像生成的峰值图像为输入,当学生模型以T1加权图像生成的结构张量作为输入时,两者在数据结构和信息密度上存在显著差异。这导致在瓶颈部位(即编码器-解码器的中间层),某些关键的纤维方向特权信息没有得到准确的编码和传递,甚至引入了错误的冗余。这种信息编码的不匹配,直接影响了学生模型在后续解码过程中的性能,进而导致了分割精度的下降。在模型结构最后一层的潜在空间,基于弥散磁共振图像的束分割模型能够进行准确的预测,从而有效地编码方向信息并转移给基于T1加权图像的束分割模型,从而在一定程度上提高了白质束分割的效果。

(2)预测图蒸馏、正则化知识蒸馏及多标签日志蒸馏均聚焦于最后一层潜在空间的知识提取,此类方法相较于基线方法在性能上均有所提升,证明了最后一层中纤维方向编码信息学习的准确性和有效性,但本文方法的结果均优于其他所有方法。这是因为白质纤维束分割任务是一个多标签图像分割任务,每个像素点可能同时属于多个束类别,这要求模型能够准确地捕捉和区分不同类别之间的细微差异。在特权知识学习的框架下,本文采用了二进制交叉熵损失函数来约束学生模型的学习过程,使其能够尽可能地模仿教师模型的分割结果。BCE损失函数在处理多标签问题时能够充分考虑到不同标签之间的独立性和相关性,因此它能够更好地引导学生模型进行学习,从而在白质纤维束分割任务中取得了更优异的性能。

3 结束语

在神经科学研究领域,白质纤维束分割是分析脑连接网络的关键步骤。长期以来,该领域的研究主要依赖于弥散磁共振成像技术。尽管此类技术能够提供丰富的白质纤维束信息,但其数据采集过程比较耗时且对图像质量要求极高,使得此类技术在临床实践中的应用变得相当困难。为了突破这一瓶颈,本文提出了一种基于T1加权图像的白质纤维束分割方法。通过计算T1加权图像的结构张量,预测出潜在的纤维走向。在模型训练的过程中,引入了特权信息,通过教师模型提供的额外信息来指导学生模型的学习。在特权知识学习的框架下,训练期间充分利用弥散磁共振图像编码准确的白质纤维束方向信息,并将特权信息传递给基于T1加权图像的目标分割模型,在测试期间仅利用T1加权图像就可以进行实现高质量白质束分割。在已有的人类连接体项目数据集上的实验结果验证了本文方法能有效地提升具有挑战性的束以及其他白质束的分割效果。

参考文献:

- [1] PASTERNAK O, KELLY S, SYDNOR V J, et al. Advances in microstructural diffusion neuroimaging for psychiatric disorders[J]. *NeuroImage*, 2018, 182: 259-282.
- [2] 赵可, 王强, 邓伟, 等. 首发精神分裂症患者的前联合白质完整性对认知功能的影响[J]. *中国神经精神疾病杂志*, 2014, 40(1): 16-20.
ZHAO Ke, WANG Qiang, DENG Wei, et al. The role of the white matter integrity of the anterior commissure in cognitive

- functions in first-episode schizophrenia[J]. Chinese Journal of Nervous and Mental Diseases, 2014, 40 (1): 16-20.
- [3] TOESCU S M, HALES P W, KADEN E, et al. Tractsographic and microstructural analysis of the dentato-rubro-thalamo-cortical tracts in children using diffusion MRI[J]. Cerebral Cortex, 2021, 31(5): 2595-2609.
- [4] WAKANA S, CAPRIHAN A, PANZENBOECK M M, et al. Reproducibility of quantitative tractsography methods applied to cerebral white matter[J]. NeuroImage, 2007, 36(3): 630-644.
- [5] MOBERTS B, VILANOVA A, VAN WIJK J J. Evaluation of fiber clustering methods for diffusion tensor imaging[C]// Proceedings of the IEEE Conference on Visualization. Minneapolis, USA: IEEE, 2005: 65-72.
- [6] GARYFALLIDIS E, BRETT M, CORREIA M M, et al. Quick bundles, a method for tractsography simplification[J]. Frontiers in Neuroscience, 2012, 6: 175.
- [7] CABEEN R P, TOGA A W, LAIDLAW D H. Tractsography processing with the sparse closest point transform[J]. Neuroinformatics, 2021, 19(2): 367-378.
- [8] WASSERTHAL J, NEHER P, MAIER-HEIN K H. Tractseg-fast and accurate white matter tracts segmentation[J]. Neuroimage, 2018, 183: 239-253.
- [9] NIR T M, THOMOPOULOS S I, VILLALON-REINA J E, et al. Multi-shell diffusion MRI measures of brain aging: A preliminary comparison from ADNI3[C]//Proceedings of the IEEE International Symposium on Biomedical Imaging. Venice, Italy: IEEE, 2019: 173-177.
- [10] KOIRALA N, KLEINMAN D, PERDUE M V, et al. Widespread effects of dMRI data quality on diffusion measures in children[J]. Human Brain Mapping, 2022, 43(4): 1326-1341.
- [11] YANG Q, HANSEN C B, CAI L Y, et al. Learning white matter subject-specific segmentation from structural MRI[J]. Medical Physics, 2022, 49(4): 2502-2513.
- [12] ZHANG F, KARAYUMAK S C, HOFFMANN N, et al. Deep white matter analysis (DeepWMA): Fast and consistent tractsography segmentation[J]. Medical Image Analysis, 2020, 65: 101761.
- [13] LU Q, LIU W, ZHUO Z, et al. A transfer learning approach to few-shot segmentation of novel white matter tracts[J]. Medical Image Analysis, 2022, 79: 102454.
- [14] LIU W, ZHUO Z, LIU Y, et al. One-shot segmentation of novel white matter tracts via extensive data augmentation and adaptive knowledge transfer[J]. Medical Image Analysis, 2023, 90: 102968.
- [15] TRINKLE S, FOXLEY S, KASTHURI N, et al. Synchrotron X-ray micro-CT as a validation dataset for diffusion MRI in whole mouse brain[J]. Magnetic Resonance in Medicine, 2021, 86(2): 1067-1076.
- [16] LIU W, LU Q, ZHUO Z, et al. Volumetric segmentation of white matter tracts with label embedding[J]. Neuroimage, 2022, 250: 118934.
- [17] HU M, MAILLARD M, ZHANG Y, et al. Knowledge distillation from multi-modal to mono-modal segmentation networks [C]//Proceedings of the Medical Image Computing and Computer Assisted Intervention. Lima, Peru: Springer Cham, 2020: 772-781.
- [18] QIN D, BU J J, LIU Z, et al. Efficient medical image segmentation based on knowledge distillation[J]. IEEE Transactions on Medical Imaging, 2021, 40(12): 3820-3831.
- [19] CHEN C, DOU Q, JIN Y, et al. Learning with privileged multimodal knowledge for unimodal segmentation[J]. IEEE Transactions on Medical Imaging, 2022, 41(3): 621-632.
- [20] YANG P, XIE M K, ZONG C C, et al. Multi-label knowledge distillation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE, 2023: 17271-17280.

作者简介:



焦瑞柯(1999-),女,硕士研究生,研究方向:医学图像分割,E-mail: rkjiao@163.com。



张小凤(1982-),女,副教授,研究方向:模式识别与智能系统,E-mail: kar-en6886@163.com。



叶初阳(1985-),通信作者,男,副教授,研究方向:医学图像处理,E-mail: chuyang.ye@bit.edu.cn。

(编辑:张黄群,王婕)