

# 跨域光纤聚集体形状分析用于语言表现认知分数预测

Yui Lo<sup>1,2,4</sup>, Yuqian Chen<sup>1,2</sup>, Dongnan Liu<sup>4</sup>, Wan Liu<sup>5</sup>, Leo Zekelman<sup>2,7</sup>,  
Fan Zhang<sup>6</sup>, Yogesh Rathi<sup>1,2</sup>, Nikos Makris<sup>1,3</sup>, Alexandra J. Golby<sup>1,2</sup>,  
Weidong Cai<sup>4</sup>, and Lauren J. O' Donnell<sup>1,2</sup>

<sup>1</sup> Harvard Medical School, Boston, USA

<sup>2</sup> Brigham and Women's Hospital, Boston, USA

<sup>3</sup> Massachusetts General Hospital, Boston, USA

<sup>4</sup> The University of Sydney, Sydney, Australia

<sup>5</sup> Beijing Institute of Technology, Beijing, China

<sup>6</sup> University of Electronic Science and Technology of China, Chengdu, China

<sup>7</sup> Harvard University, Boston, USA

[odonnell@bwh.harvard.edu](mailto:odonnell@bwh.harvard.edu)

**摘要** 形状在计算机图形学中起着重要作用，提供有关对象形态和功能的有用特征。大脑成像中的形状分析可以帮助解释人类大脑的结构与功能性相关性。在这项工作中，我们研究了大脑 3D 白质连接的形状及其对人类认知功能潜在预测关系的可能性。我们使用扩散磁共振成像 (dMRI) 追踪技术将纤维簇重建为一系列 3D 点。为了描述每个连接，除了传统的 dMRI 连通性和组织微结构特征外，我们还提取了 12 个形状描述符。我们引入了一个新的框架形状融合纤维簇变换器 (SFFormer)，该框架利用多头交叉注意力特征融合模块基于 dMRI 追踪技术预测特定个体的语言表现能力。我们在包括 1065 名健康年轻成年人的大型数据集上评估了该方法的表现。结果显示，基于变换器的 SFFormer 模型及其与形状、微结构和连通性的内部/外部特征融合是有信息量的，并且共同提高了对特定个体语言表现得分的预测能力相比传统模型。总体而言，我们的结果表明大脑连接的形状可以预测人类的语言功能。

**Keywords:** 形状分析 · 轨迹追踪 · 扩散 MRI · 深度嵌入 · 域融合。

## 1 介绍

3D 形状的研究长期以来被认为对计算机图形学和医学图像分析至关重要 [35]。在磁共振成像 (MRI) 领域，形状研究使得能够详细分析大脑皮层的折叠以及皮下灰质结构的形态 [8]。然而，传递信息贯穿整个大脑的大脑白质连接的形状则研究得少得多。

扩散 MRI (dMRI) 轨迹追踪是一种独特的方法，能够基于脑组织中的水分扩散实现大脑白质连接的三维重建 [2]。dMRI 轨迹追踪产生一系列 3D 点，称为流线，可以将这些流线分组以定义个体的大脑连接或具有不同解剖形状的纤维簇（图 1）。纤维簇的定量分析包括组织微观结构（使用组织中的水分扩散）、大脑连通性（每个连接的力量）和形态分析。形态测量捕捉白质在个体间的变异 [33] 以及随年龄变化的情况 [23]。然而，白质连接形状的功能重要性尚不明确。为了评估纤维簇的形状是否与语言表现相关，在这项工作中我们使用了预测个体语言表现的测试任务。我们评估形态、微观结构和连通性特征域之间的信息整合能否增强对个体语言表现的预测能力。

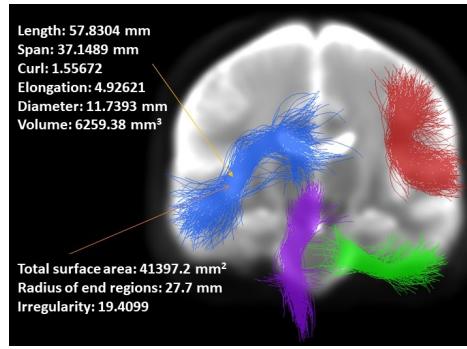


图 1. 四个示例个体白质连接（纤维簇）通过纤维聚类方法从整个人脑的白质中提取出来 [37]。为蓝色纤维簇提取了示例形状描述符。

## 1.1 相关工作

在本节中，我们首先概述了使用 dMRI 纤维追踪数据预测个体语言功能的方法，然后简要描述了构建我们当前框架所依据的深度学习技术。

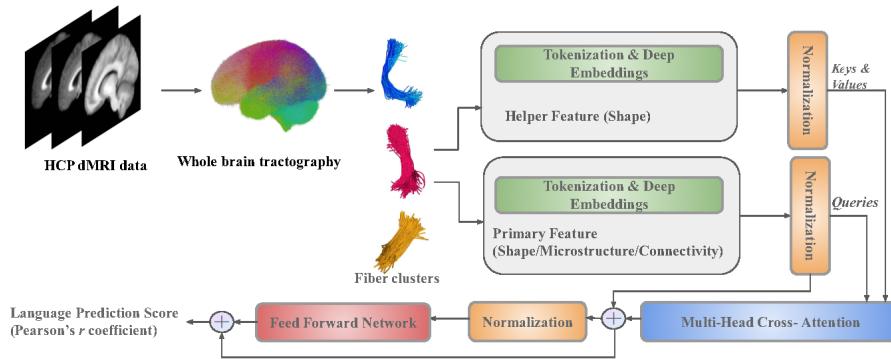
在文献中，提出了一些方法使用 dMRI 束成像数据来预测个体的认知和/或语言功能表现 [5, 10, 14, 18]。从 dMRI 导出的组织微观结构测量指标已被证明可以通过传统（非深度学习）回归分析与语言功能相关联 [34]。研究的测量指标包括分数各向异性 (FA)，描述了脑组织中水扩散的各向异性，以及平均扩散率 (MD)，描述了水扩散的整体幅度 [20]，还包括流线数量 (NoS)，被认为与大脑的连接性相关 [36]。相比之下，这些传统特征，纤维簇可以通过形状测量指标来描述，如表面积和体积，以及最近提出的、特定于纤维束

的测量指标，例如该束插入灰质区域的表面积 [33]。其他形状度量已被提出用于束道追踪，包括曲率和扭率 [3]、纤维弥散 [22] 以及体积 [17]。

最近的深度学习方法已经研究了使用 dMRI 追踪技术预测个体语言表现。一种基于卷积神经网络 (CNN) 的深度学习方法表明，在患有癫痫的儿童中，连接性可以预测语言能力 [14]。一种几何深度学习方法显示，在健康的年轻成年人中，微观结构和连通性可以预测语言功能 [5]。一个多层次网络方法被应用于预测人类衰老过程中的语言表现 [7]。与这些方法不同，我们专注于一种基于变压器的新型网络设计。

近年来，变压器模型 [11] 在计算机视觉任务中越来越受欢迎，例如目标检测 [40]、分类 [6] 和分割 [25]。与 CNN 相比，变换器的优势在于使用多头自注意力 [30] 来增强模型解释复杂语义和结构特征关系的能力。变换器还已被证明在许多医学图像应用中取得成功，包括 dMRI[27, 4, 32, 38]。关于使用变换器模型预测组织微结构的文献相当丰富，包括 SwinDTI[27]、基于稀疏编码的微观结构估计变换器 [39]、混合图变换器 (HGT) [4] 和 3D HGT[32]。变换器在束跟踪分析中的应用相对有限，例如用于全脑束跟踪分析的 TractoFormer[38]。因此，探讨变换器在束跟踪数据分析中的应用是有意义的。

## 2 方法论



**图2.** SFFormer 框架概述。HCP dMRI 数据经过全脑纤维追踪以获得 953 个纤维簇。计算纤维簇的微观结构、连接性和形状特征，并将其用作输入到 SFFormer 框架中，该框架利用多头交叉注意力模块中的辅助特性和主要特性输出语言预测分数。

## 2.1 追踪成像与纤维聚类

在这项工作中，我们研究了来自人类连接组计划青年成人（HCP-YA）数据集的 1065 名健康年轻成年人（575 名女性和 490 名男性，平均年龄 28.7 岁）的纤维簇形状 [28, 29]。对每位受试者的 dMRI 数据使用一种双张量无迹卡尔曼滤波方法 [19] 进行全脑追踪图生成，该方法可以表示多束交叉纤维，使纤维簇路径和连接性的解剖敏感估计成为可能 [12]。然后使用一个经过解剖学整理的追踪图大脑图谱 [37] 将追踪图划分为 953 个纤维簇。每个纤维簇包含数百条流线，代表人类大脑中的特定连接（参见图 1）。

## 2.2 传统和形状特征

对于每个聚类，我们计算传统的组织微结构特征，包括分数各向异性（FA）和平均扩散系数（MD），以及传统的连通性特征——流线数量（NoS）[36]。这些特征用于比较和评估形状特征。

我们研究了 12 个纤维簇形状特征，这些特征被认为可以全面分析束状成像的形状 [33]。这些特征包括长度、直径、伸长率、跨度、卷曲度、体积、主干体积、分支体积、总面积、末端区域的总半径、末端区域的总面积和不规则性。通过应用软件 DSISTudio[33]，计算了所有受试者的所有纤维簇的这些形状特征。形状测量的完整定义和计算方法在 DSISTudio[33] 中进行了介绍。

## 2.3 形状融合纤维簇变换器（SFFormer）

在本节中，我们介绍了用于预测特定主题语言分数的提议 SFFormer。如图 2 所示，SFFormer 模型包括一个分词模块和一个仅编码器的变压器架构，特别针对预测任务进行了设计。这种仅编码器的设计符合专注于学习纤维簇特征以获得语言分数预测结果的任务。SFFormer 编码器由 1-4 个相同的层堆栈组成。每一层都包含一个多头注意力模块和一个前馈网络。

分词模块 [11] 对特定特征（例如，FA 或长度）进行深度嵌入，该特征的维度为  $1 \times 953$ 。为了创建嵌入，我们将输入数据 ( $x$ ) 与随机初始化的权重相乘，然后加上随机初始化的偏置。此过程为深度学习管道中的多头交叉注意力模块准备数据。

我们扩展了从基础变压器 [11] 的设计。我们将纤维簇特征自然地视为一个标记，以利用所有簇特征的长距离依赖性来提升预测效果。我们采用了一

种适合处理长序列（如 953 个纤维簇特征）的多头机制 [30]，因为每个头部独立关注输入序列的不同部分。

我们设计了一个多头交叉注意力模块来融合形状、微观结构和连通性特征域的特征。与使用变压器的自注意力机制不同，我们的多头交叉注意力模块可以将不同领域的特征对称地组合到两个相同维度的嵌入序列中，其中一个序列用作查询 (Q) 输入。另一个序列则作为键 (K) 和值 (V) 输入在 SFFormer 中提供特征融合。由于需要两个嵌入，SFFormer 能够同时捕捉并关注来自不同特征的信息。动机是通过利用双流输入框架更有效地确定变化的注意力权重。该方法强调交叉注意力以并发地训练主要特征，并试图整合两条数据流中的关键信息。

#### 2.4 实现细节

我们的模型通过 Optuna 超参数 [1] 进行训练和调整，设置为 20 次试验。该模型配置了 ReGLU 激活函数和 He 初始化 [13]，带有 8 个注意力头。该模型使用批量大小为 8 进行了 1000 个时期的训练和评估，并且具有 50 个时期的耐心等待时间。所有实验都分为三折交叉验证。训练通过 Adam[16] 进行优化，学习率设置在  $1e-5$  和  $1e-3$  之间，权重衰减为对数均匀分布，在  $1e-6$  和  $1e-3$  之间。标记数量设置在 64 到 512 之间，较大的嵌入捕获更多信息。注意力和前馈模块的丢弃率分别设置在 0 到 0.5，以及残差连接的 0 到 0.2。所有实验都在 NVIDIA RTX A5000 GPU 上使用 PyTorch 1.7.1[21] 进行。

### 3 实验与结果

首先，我们进行实验以基于个体特征执行特定主题的语言分数预测。我们将最先进的 1DCNN 模型 [18] 和基线变压器模型在训练单个微观结构、连通性或形状特征时的性能进行了比较。接下来，我们将每个特征与选定的帮助形状特征融合，并应用 SFFormer 模型。帮助形状特征被选为使用基线变压器模型时表现最佳的形状特征。我们选择直径作为 TPVT 分数预测的帮助形状特征，并将不规则性作为 TORRT 分数预测的帮助形状特征。

#### 3.1 语言评估分数

我们预测了 HCP-YA 提供的两项语言评估的特定主题表现，包括 NIH 工具箱图片词汇测试 (TPVT) 和 NIH 工具箱口语阅读识别测试 (TORRT)

**表 1.** 预测性能对于 TPVT ( $r$ )。斜体显示的形状特征优于最佳的传统特征表现。加粗的特征显示了在三种不同学习模型中的最优表现。

Features	CNN [18]	Vanilla Transformer	SFFormer (helper: diameter)
<b>Microstructure</b>			
FA	0.293±0.063	<b>0.418±0.077</b>	0.404±0.079
MD	0.260±0.041	0.337±0.098	<b>0.338±0.098</b>
<b>Connectivity</b>			
NoS	0.395±0.054	0.410±0.103	<b>0.417±0.007</b>
<b>Shape</b>			
Length	0.133±0.039	0.330±0.079	<b>0.414±0.080</b>
Span	0.119±0.044	0.355±0.094	<b>0.417±0.098</b>
Curl	0.203±0.092	0.310±0.070	<b>0.407±0.081</b>
Volume	0.381±0.063	0.410±0.102	<b>0.423±0.071</b>
Trunk Volume	0.156±0.083	0.275±0.041	<b>0.414±0.084</b>
Branch Volume	0.376±0.064	0.414±0.096	<b>0.430±0.079</b>
Diameter	0.406±0.082	<b>0.419±0.083</b>	
Elongation	0.313±0.070	0.392±0.074	<b>0.419±0.083</b>
Total surface area	0.395±0.060	<b>0.418±0.098</b>	0.406±0.092
Radius of end regions	0.235±0.045	0.347±0.125	<b>0.429±0.084</b>
Surface area of end regions	0.406±0.080	0.414±0.100	<b>0.418±0.092</b>
Irregularity	0.322±0.041	0.391±0.092	<b>0.416±0.071</b>

[9, 31]。TPVT 衡量词汇理解能力，并是一项接受性语言评估 [9]。TORRT 衡量阅读解码能力，并是一项口语语言评估 [9]。

### 3.2 评估指标

皮尔逊相关系数 ( $r$ ) [24] 被用于评估语言表现预测，因为它是在神经认知表现预测中常用的度量标准 [10, 15, 26]。Pearson 的  $r$  衡量两个变量之间线性关联的强度和方向（正或负）。

### 3.3 结果与讨论

表 1 和表 2 分别显示了三个比较模型在预测特定科目词汇理解 (TPVT) 分数和特定科目口语阅读 (TORRT) 分数的表现。

**表 2.** 预测性能对于 TORRT ( $r$ )。斜体显示的形状特征优于最佳的传统特征。加粗的特征显示了在三种不同学习模型中的最佳性能。

Features	CNN [18]	Vanilla Transformer	SFFormer (helper: irregularity)
<b>Microstructure</b>			
FA	0.332±0.055	0.382±0.059	<b>0.383±0.06</b>
MD	0.315±0.004	0.344±0.021	<b>0.374±0.06</b>
<b>Connectivity</b>			
NoS	0.349±0.024	0.345±0.061	<b>0.372±0.05</b>
<b>Shape</b>			
Length	0.103±0.002	0.301±0.056	<b>0.376±0.053</b>
Span	0.126±0.017	0.318±0.071	<b>0.377±0.072</b>
Curl	0.241±0.014	0.285±0.061	<b>0.377±0.075</b>
Volume	0.324±0.016	<b>0.392±0.083</b>	0.379±0.066
Trunk Volume	0.184±0.035	0.260±0.039	<b>0.384±0.123</b>
Branch Volume	0.357±0.021	<b>0.377±0.075</b>	0.362±0.073
Diameter	0.315±0.038	0.390±0.071	<b>0.398±0.050</b>
Elongation	0.275±0.005	0.363±0.045	<b>0.376±0.049</b>
Total surface area	0.368±0.046	<b>0.391±0.079</b>	0.369±0.056
Radius of end regions	0.3196±0.063	0.341±0.087	<b>0.374±0.053</b>
Surface area of end regions	0.330±0.001	<b>0.374±0.085</b>	0.371±0.062
Irregularity	0.341±0.021	<b>0.439±0.062</b>	

如表 1 和表 2 的第二列所示, CNN 模型 [18] 成功预测了语言表现, 尽管它被基线变压器模型和 SFFormer 模型所超越。在使用 CNN 模型时, NoS 特征是最具信息量的传统特征, 而几个形状特征 (以斜体显示) 的表现超过了 NoS。

基线变压器模型（表 1 和表 2 的第三列）在所有输入特征上都优于 CNN 模型。这表明变换器提升了语言分数预测任务的表现。FA 特征是最具信息量的传统特征。多种形状特征（以斜体显示）优于 FA，包括直径（表 1）、体积、直径、总面积和不规则性（表 2）。

SFFormer（表 1 和表 2 的第四列）成功预测了语言表现，其大多数特征都优于基线模型以及最先进的 CNN 模型。这表明领域融合技术有效地促进了特定主题的语言分数预测，在包含辅助特征信息以帮助整体训练时，性能得到提升。在表 1 中，形状特征的表现与 FA 和 MD 相当或更好，各种形状特征（斜体显示），包括末端区域的表面面积、延伸度、体积、末端区域的半径以及分支体积，都超过了传统上表现最好的特征 NoS，在预测语言表现方面更胜一筹。此外，表 2 还表明 FA 是最具信息量的传统特征，并且 FA 优于几个形状特征，如树干体积和直径（斜体显示）。

总结来说，表 1 和表 2 中展示的评估表明，在 SFFormer 模型中形状特征和领域融合具有更强的预测能力，这比传统特征有了改进，并且超过了 CNN 模型和自注意力基础变压器模型的最新方法。未来的工作可能会探索包含多种输入特征的模型。

## 4 结论

在本文中，我们提出了 SFFormer，该模型利用多头交叉注意力模块融合来自不同领域的特征以提高预测结果。我们的 SFFormer 结果显示，纤维簇连接形状的测量对于个体特定的语言表现预测是有信息量的。对 HCP-YA 数据集的评估表明，跨/域内特征融合有利于更好的预测。这表明与形状相关的特征对于预测和评估各种认知能力是有用的，在某些情况下可能优于微观结构和连通性特征。总体而言，这表明白质纤维簇的形状与人类大脑的重要功能有关。

## 5 遵守道德标准

本研究使用公开的 HCP 成像数据；无需伦理审批。

## 6 致谢

本工作部分得到了国家重点研发计划（编号 2023YFE0118600）和国家自然科学基金（编号 62371107）的支持。本工作得到了悉尼大学国际奖学金的支持。

## 参考文献

1. Akiba, T., Sano, S., Yanase, T., Ohta, T., Koyama, M.: Optuna: A next-generation hyperparameter optimization framework. In: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. pp. 2623–2631. KDD ’19, Association for Computing Machinery, New York, NY, USA (Jul 2019)
2. Bassier, P., Pajevic, S., Pierpaoli, C., Duda, J., Aldroubi, A.: In vivo fiber tractography using DT-MRI data. *Magn. Reson. Med.* **44**(4), 625–632 (2000)
3. Batchelor, P.G., Calamante, F., Tournier, J.D., Atkinson, D., Hill, D.L.G., Connelly, A.: Quantification of the shape of fiber tracts. *Magn. Reson. Med.* **55**(4), 894–903 (Apr 2006)
4. Chen, G., Jiang, H., Liu, J., Ma, J., Cui, H., Xia, Y., Yap, P.T.: Hybrid graph transformer for tissue microstructure estimation with undersampled diffusion MRI data. In: Medical Image Computing and Computer Assisted Intervention – MICCAI 2022. pp. 113–122. Springer Nature Switzerland (2022)
5. Chen, Y., Zekelman, L., Zhang, C., Xue, T., Song, Y., Makris, N., Rathi, Y., Golby, A., Cai, W., Zhang, F., O’Donnell, L.: TractGeoNet: A geometric deep learning framework for pointwise analysis of tract microstructure to predict language assessment performance. arXiv preprint arXiv:2307.03982 (2023)
6. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., Houlsby, N.: An image is worth 16x16 words: Transformers for image recognition at scale. arXiv preprint arXiv:2010.11929 (Oct 2020)
7. Feng, G., Wang, Y., Huang, W., Chen, H., Dai, Z., Ma, G., Li, X., Zhang, Z., Shu, N.: Methodological evaluation of individual cognitive prediction based on the brain white matter structural connectome. *Hum. Brain Mapp.* **43**(12), 3775–3791 (Aug 2022)
8. Fischl, B.: FreeSurfer. *Neuroimage* **62**(2), 774–781 (Aug 2012)

9. Gershon, R., Cook, K., Mungas, D., Manly, J., Slotkin, J., Beaumont, J., Weintraub, S.: Language measures of the NIH toolbox cognition battery. *J. Int. Neuropsychol. Soc.* **20**(6), 642–651 (Jul 2014)
10. Gong, W., Beckmann, C., Smith, S.: Phenotype discovery from population brain imaging. *Med. Image Anal.* **71**, 102050 (Jul 2021)
11. Gorishniy, Y., Rubachev, I., Khrulkov, V., Babenko, A.: Revisiting deep learning models for tabular data. *Advances in Neural Information Processing Systems* **34**, 18932–18943 (2021)
12. He, J., Zhang, F., Pan, Y., Feng, Y., Rushmore, J., Torio, E., Rathi, Y., Makris, N., Kikinis, R., Golby, A., O'Donnell, L.: Reconstructing the somatotopic organization of the corticospinal tract remains a challenge for modern tractography methods. *Hum. Brain Mapp.* **44**(17), 6055–6073 (Dec 2023)
13. He, K., Zhang, X., Ren, S., Sun, J.: Delving deep into rectifiers: Surpassing Human-Level performance on ImageNet classification. In: 2015 IEEE International Conference on Computer Vision (ICCV). pp. 1026–1034. IEEE (Dec 2015)
14. Jeong, J., Lee, M., O'Hara, N., Juhász, C., Asano, E.: Prediction of baseline expressive and receptive language function in children with focal epilepsy using diffusion tractography-based deep learning network. *Epilepsy Behav.* **117**, 107909 (Apr 2021)
15. Kim, M., Bao, J., Liu, K., Park, B., Park, H., Baik, J., Shen, L.: A structural enriched functional network: An application to predict brain cognitive performance. *Med. Image Anal.* **71**, 102026 (Jul 2021)
16. Kingma, D., Ba, J.: Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980 (2014)
17. Lebel, C., Gee, M., Camicioli, R., Wieler, M., Martin, W., Beaulieu, C.: Diffusion tensor imaging of white matter tract evolution over the lifespan. *Neuroimage* **60**(1), 340–352 (Mar 2012)
18. Liu, W., Chen, Y., Ye, C., Makris, N., Rathi, Y., Cai, W., Zhang, F., O'Donnell, L.: Fiber tract shape measures inform prediction of Non-Imaging phenotypes. arXiv preprint arXiv:2303.09124 (2023)
19. Malcolm, J., Shenton, M., Rathi, Y.: Filtered multitensor tractography. *IEEE Trans. Med. Imaging* **29**(9), 1664–1675 (Sep 2010)
20. O'Donnell, L., Westin, C.: An introduction to diffusion tensor image analysis. *Neurosurg. Clin. N. Am.* **22**(2), 185–96, viii (Apr 2011)
21. Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., DeVito, Z.,

- Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., Chintala, S.: PyTorch: an imperative style, high-performance deep learning library. In: Proceedings of the 33rd International Conference on Neural Information Processing Systems, pp. 8026–8037. Curran Associates Inc., Red Hook, NY, USA (Dec 2019)
22. Savadjiev, P., Kindlmann, G.L., Bouix, S., Shenton, M.E., Westin, C.F.: Local white matter geometry from diffusion tensor gradients. *Neuroimage* **49**(4), 3175–3186 (Feb 2010)
  23. Schilling, K.G., Archer, D., Yeh, F.C., Rheault, F., Cai, L.Y., Hansen, C., Yang, Q., Ramdass, K., Shafer, A.T., Resnick, S.M., Pechman, K.R., Gifford, K.A., Hohman, T.J., Jefferson, A., Anderson, A.W., Kang, H., Landman, B.A.: Aging and white matter microstructure and macrostructure: a longitudinal multi-site diffusion MRI study of 1218 participants. *Brain Struct. Funct.* **227**(6), 2111–2125 (Jul 2022)
  24. Sedgwick, P.: Pearson’s correlation coefficient. *British Medical Journal* **345** (Jul 2012)
  25. Strudel, R., Garcia, R., Laptev, I., Schmid, C.: Segmenter: Transformer for semantic segmentation. In: 2021 IEEE/CVF International Conference on Computer Vision (ICCV). pp. 7262–7272. IEEE (Oct 2021)
  26. Tian, Y., Zalesky, A.: Machine learning prediction of cognition from functional connectivity: Are feature weights reliable? *Neuroimage* **245**, 118648 (Dec 2021)
  27. Tiwari, A., Singh, R., Shigwan, S.: SwinDTI: swin transformer-based generalized fast estimation of diffusion tensor parameters from sparse data. *Neural Comput. Appl.* (Dec 2023)
  28. Van Essen, D., Smith, S., Barch, D., Behrens, T., Yacoub, E., Ugurbil, K., WU-Minn HCP Consortium: The WU-Minn human connectome project: an overview. *Neuroimage* **80**, 62–79 (Oct 2013)
  29. Van Essen, D., Ugurbil, K., Auerbach, E., Barch, D., Behrens, T., Bucholz, R., Chang, A., Chen, L., Corbetta, M., Curtiss, S., Della Penna, S., Feinberg, D., Glasser, M., Harel, N., Heath, A., Larson-Prior, L., Marcus, D., Michalareas, G., Moeller, S., Oostenveld, R., Petersen, S., Prior, F., Schlaggar, B., Smith, S., Snyder, A., Xu, J., Yacoub, E., WU-Minn HCP Consortium: The human connectome project: a data acquisition perspective. *Neuroimage* **62**(4), 2222–2231 (Oct 2012)
  30. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A., Kaiser, Ł., Polosukhin, I.: Attention is all you need. *Adv. Neural Inf. Process. Syst.* **30** (2017)
  31. Weintraub, S., Dikmen, S.S., Heaton, R.K., Tulsky, D.S., Zelazo, P.D., Bauer, P.J., Carlucci, N.E., Slotkin, J., Blitz, D., Wallner-Allen, K., Fox, N.A., Beaumont, J.L.,

- Mungas, D., Nowinski, C.J., Richler, J., Deocampo, J.A., Anderson, J.E., Manly, J.J., Borosh, B., Havlik, R., Conway, K., Edwards, E., Freund, L., King, J.W., Moy, C., Witt, E., Gershon, R.C.: Cognition assessment using the NIH toolbox. *Neurology* **80**(11 Suppl 3), S54–64 (Mar 2013)
32. Yang, J., Jiang, H., Tassew, T., Sun, P., Ma, J., Xia, Y., Yap, P.T., Chen, G.: Towards accurate microstructure estimation via 3D hybrid graph transformer. In: Medical Image Computing and Computer Assisted Intervention – MICCAI 2023. pp. 25–34. Springer Nature Switzerland (2023)
  33. Yeh, F.: Shape analysis of the human association pathways. *Neuroimage* **223**, 117329 (Dec 2020)
  34. Zekelman, L., Zhang, F., Makris, N., He, J., Chen, Y., Xue, T., Liera, D., Drane, D., Rathi, Y., Golby, A., O'Donnell, L.: White matter association tracts underlying language and theory of mind: An investigation of 809 brains from the human connectome project. *Neuroimage* **246**, 118739 (Feb 2022)
  35. Zhang, D., Lu, G.: Review of shape representation and description techniques. *Pattern Recognit.* **37**(1), 1–19 (Jan 2004)
  36. Zhang, F., Daducci, A., He, Y., Schiavi, S., Seguin, C., Smith, R., Yeh, C., Zhao, T., O'Donnell, L.: Quantitative mapping of the brain's structural connectivity using diffusion MRI tractography: A review. *Neuroimage* **249**, 118870 (Apr 2022)
  37. Zhang, F., Wu, Y., Norton, I., Rigolo, L., Rathi, Y., Makris, N., O'Donnell, L.: An anatomically curated fiber clustering white matter atlas for consistent white matter tract parcellation across the lifespan. *Neuroimage* **179**, 429–447 (Oct 2018)
  38. Zhang, F., Xue, T., Cai, W., Rathi, Y., Westin, C.F., O'Donnell, L.J.: Tractoformer: A novel fiber-level whole brain tractography analysis framework using spectral embedding and vision transformers. In: Wang, L., Dou, Q., Fletcher, P.T., Speidel, S., Li, S. (eds.) *Medical Image Computing and Computer Assisted Intervention – MICCAI 2022*. pp. 196–206. Springer Nature Switzerland, Cham (2022)
  39. Zheng, T., Yan, G., Li, H., Zheng, W., Shi, W., Zhang, Y., Ye, C., Wu, D.: A microstructure estimation transformer inspired by sparse representation for diffusion MRI. *Med. Image Anal.* **86**, 102788 (May 2023)
  40. Zhu, X., Su, W., Lu, L., Li, B., Wang, X., Dai, J.: Deformable DETR: Deformable transformers for End-to-End object detection. arXiv preprint arXiv:2010.04159 (Oct 2020)