arXiv:2301.00409v1 [cs.CV] 1 Jan 2023

基于扩散模型的脑出血图像半监督学习，用于高效的中线移位量化

Shizhan Gong[1], Cheng Chen[1], YuqiGong[1], Nga Yan Chan[2], WenaoMa[1], Calvin Hoi-Kwan Mak[3], Jill Abrigo[2], Qi Dou[1]

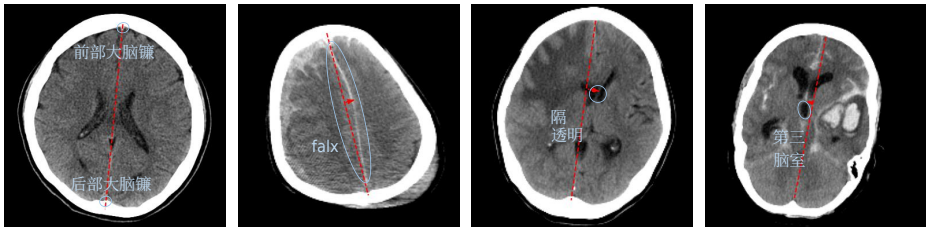
[1]香港中文大学计算机科学与工程系，香港，中国[2]香港中文大学影像及介入放射学系，香港，中国[3]伊利沙伯医院，香港，中国

摘要。 脑中线移位（MLS）是颅内出血临床诊断和治疗决策中最需考虑的关键因素之一。现有的中线移位量化计算方法不仅需要大量标注，进行毫米级测量，还因依赖特定标志点或简化的解剖学假设而表现不佳。本文提出一种新颖的半监督框架，用于从头部CT扫描中准确测量中线移位程度。我们将中线移位测量任务建模为形变估计问题，并利用少量带有稀疏标签的中线移位切片进行求解。同时，借助扩散模型，我们能够利用大量未标注中线移位数据和2793例无中线移位病例进行表征学习和正则化。提取的表征反映了图像与无中线移位图像之间的差异，而正则化在形变场由稀疏到稠密的细化过程中发挥着重要作用。我们在真实临床脑出血数据集上进行的实验取得了最先进的性能，并能够生成可解释的形变场。

关键词： 计算机辅助诊断 · 半监督学习 · 扩散模型 · 颅内出血

1 引言

颅内出血（ICH）是指颅骨内发生的脑出血，是一种严重的医疗急症，可能导致严重残疾甚至死亡 [1]。严重颅内出血的一个典型症状是脑中线移位（MLS），即脑结构中线向侧方移位（见图 1）。MLS 是衡量占位效应严重程度和干预紧迫性的重要且可定量指标 [2,3,9]。例如，通常使用 5 毫米（mm）的 MLS 阈值来判断是否需要立即干预和密切监测 [4]。MLS 定量需要很高的准确性和



(a) 无中线移位 (b) 大脑镰处中线移位 (c) 透明隔处中线移位 (d) 处于第三脑室

透明隔

图1：用于说明放射科医生如何测量MLS的头部CT扫描示例。连接前部大脑镰和后部大脑镰的红色虚线表示假想的正常中线。蓝色圆圈表示移位标志点。从移位标志点向正常中线作垂直红线，其长度即为中线移位尺度。

效率，而手动定量很难达到这一要求，尤其是在紧急情况下，因为移位区域存在差异、标志点边界不清晰，且扫描姿态不规范。一种能够立即且准确地进行MLS 定量的自动中线移位定量算法，对于及时识别紧急患者并进行治疗而言十分理想。

测量MLS时，临床医生通常会先找出几张移位明显的CT切片，然后测量并确定透明隔、第三脑室或大脑镰等解剖标志点相对于其正常对应位置的最大偏移量，作为最终的MLS距离（示例见图1）。这种临床方式的MLS定量难以转化为定义明确的自动化流程。目前，关于自动MLS定量的研究有限，且采用了不同策略和各异的标注要求。Nguyen等人提出了一种基于标志点的方法，依靠解剖标志来确定变形中线的位置 [9]。然而，该方法仅适用于MLS出现在这些特定标志区域的病例。Liao等人采用基于对称性的方法，试图寻找一条连接所有变形结构的曲线 [10], ；由于其解剖假设过于简化，且容易受患者扫描体位影响，因此难以推广。近期有少数研究尝试通过采用更强监督和密集标注来克服这些局限。一些研究将MLS定量表述为中线分割任务 [5,6,7], ，通过描绘完整中线作为标签，监督分割模型的训练。另一项研究设计了半球分割任务来量化 MLS [8], ，这需要对每张切片进行逐像素标注。然而，获取此类密集标注的成本很高、耗时很长，而且对于MLS定量而言可能并无必要。

为解决这些局限性，我们提出利用仅包含有限标注的半监督学习（SSL），将 MLS 定量拟合为一个形变预测问题。我们的框架避免了对特定

标志点或以往方法中过度简化的假设的强依赖，同时不会增加标注工作量。我们的目标是仅使用稀疏且弱标签作为真值监督，这些监督仅包括放射科医生在数量有限的切片上提供的一个移位标志点及其对应的正常标志点，同时充分利用未标注切片和非中线移位数据，为从稀疏标注到稠密预测的扩展施加额外正则化。现有的半监督学习方法通常使用基于有标签数据部分训练的模型，为无标签数据生成伪标签，并假设有标签数据与无标签数据总体相似。在我们的场景中，这些方法可能并非最优，因为带有 MLS 的标注切片通常呈现最大的形变，而未标注切片仅包含轻微形变或不含形变。为此，我们提出了相应的半监督学习策略：利用生成模型为每个未标注的 MLS 切片生成对应的非中线移位图像，并对形变场进行正则化，使其能够将生成的非中线移位图像扭曲为原始的 MLS 图像。然而，由于我们仅拥有 MLS 和非中线移位分类的体积级标签，因此难以按照许多生成模型（如生成对抗网络） [12]的要求训练切片级判别器。幸运的是，近期提出的扩散模型 [15], 在分布学习和图像生成方面都展现出强大能力，且无需依赖判别器，因此可能是一个很好的解决方案。

在本研究中，我们提出一种基于扩散模型的新型半监督学习框架，通过形变预测从头部CT图像中量化脑中线移位。我们的方法有效利用所有类型的可用数据所提供的监督和正则化，包括带有稀疏真值标签的中线移位图像、无标签的中线移位图像以及非中线移位图像。我们在真实的临床头部CT数据集上验证了该方法，结果表明所提出的各个组件均有效。我们的贡献包括：(1) 为脑中线移位量化创新性地设计了一种有效的形变策略；(2) 将扩散模型用作表征学习器，提取能够反映中线移位图像与非中线移位图像在何处及如何存在差异的特征；(3) 提出一种基于扩散模型的半监督框架，能够有效利用海量未标注数据来提升模型性能。

2 方法

图2展示了我们提出的通过形变预测进行MLS定量的基于扩散模型的半监督学习框架。在第2.1节中，我们介绍仅使用稀疏监督进行的形变预测。在第2.2节中，我们提出利用非中线移位数据进行表征学习。在第2.3节中，我们描述如何利用无标签的中线移位图像进行稀疏到稠密正则化。

2.1 通过形变估计进行中线移位定量

我们提出的脑中线移位定量形变策略旨在找到最优形变场 ϕ ，使中线移位图像可被视为一幅

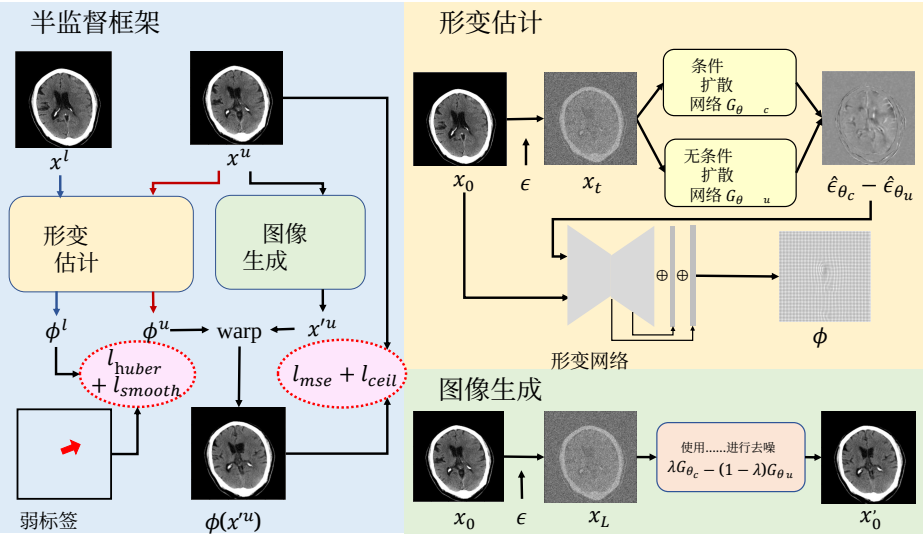


图 2：我们提出的用于 MLS 定量的半监督形变策略流程。标注图像 x^l 由稀疏标签监督，未标注图像 x^u 则通过生成的负样本图像进行自监督。

假想的无中线移位图像经该形变场扭曲后的结果。形变场可由高复杂度函数参数化，因此无需明确依赖单个标志点或过度简化的对称性假设，从而自然克服现有方法的局限。我们采用基于学习的框架，通过 U-Net 结构的神经网络对形变场进行参数化。网络的输出为稳态速度场 v。随后，通过对速度场积分得到微分同胚变形场 ϕ，其方式与用于图像配准的 VoxelMorph [11] 类似。学习过程由稀疏变形真值监督。对于每个有标签切片，我们拥有真值 $\mathbf{y} = (y_1, y_2)$，这是一个二维向量，方向从偏移标志点指向其推测的正常位置（图 2 中的红色箭头）。预测的形变 $\hat{\mathbf{y}}$ 在偏移标志点处通过形变场进行双线性插值，同样是一个二维向量。为减轻少数极大形变点的影响并提高模型的鲁棒性，我们采用 Huber损失衡量预测形变与标签之间的相似度：

$$l_{\text{huber}}(y_d, \hat{y}_d) = \begin{cases} |y_d - \hat{y}_d|, & |y_d - \hat{y}_d| \geq c, \\ \dfrac{(y_d - \hat{y}_d)^2 + c^2}{2c}, & |y_d - \hat{y}_d| < c. \end{cases} \tag{1}$$

其中 $d \in \{1, 2\}$。超参数 c 定义了绝对误差或平方误差的范围。我们还通过对形变 ϕ 的空间梯度施加扩散正则项，来促进平滑的形变场，从而避免不连续的

形变场：

$$l_{\text{smooth}} = \sum_j \sum_k \|\phi_{jk} - \phi_{(j-1)k}\|^2 + \|\phi_{jk} - \phi_{j(k-1)}\|^2, \tag{2}$$

由于在我们的案例中形变可能非常大，同时为了强制形变峰值与其相邻像素之间平滑过渡，我们采用由粗到细的方式，通过上采样生成速度场，并结合跳跃连接逐步聚合不同尺度的特征。

2.2 从非中线移位图像中学习负模式

为了学习形变场，将无中线移位图像扭曲为中线移位图像，理想情况下，我们需要一对无中线移位图像和中线移位图像来训练网络，但实际上并不存在这样的图像对。缺少此类信息会使网络难以学习。一种简单的解决方案是生成对应的无中线移位图像。然而，生成图像带有一定的随机性，而且往往缺少重要细节。过度依赖此类伪造输入会导致鲁棒性较差。受扩散模型的分数匹配解释启发 [17], ，我们提出从大量负样本中学习非中线移位分布。给定一幅中线移位图像，我们可以评估图像中的哪些部分使其区别于无中线移位图像。这种偏差可作为潜在特征，帮助形变网络进行形变预测。

扩散模型，尤其是 DDPM [14], ，将前向扩散过程定义为一个马尔可夫过程：逐步向给定图像添加随机高斯噪声，然后尝试用高斯分布近似逆向过程。前向过程可以通过单步采样简化： $x_t = \sqrt{\alpha_t} x_0 + \sqrt{1-\alpha_t}\epsilon$，其中 α_t： $= \prod_{s=0}^{t} 1 - \beta_t$，而 β_t 是预定义的方差调度。ϵ 从 $\mathcal{N}(0, I)$ 中采样。逆向过程的均值 $\mu_\theta(x_t, t)$ 和方差 $\Sigma_\theta(x_t, t)$ 可以通过神经网络参数化。一种常见的做法是对 $\mu_\theta(x_t, t)$ 进行重新参数化，使神经网络估计 $\hat{\epsilon}_\theta(x_t, t)$，而不是 $\mu_\theta(x_t, t)$，以近似噪声 ϵ。此外，扩散网络 $\epsilon(x_t, t)$ 的输出实际上是一个缩放后的分数函数 $\nabla \log p(x_t)$，因为它会将受扰图像推向与扰动相反的方向。 [18]。

因此，通过预训练一个使用全部数据训练的无条件扩散模型（记为 $\mathcal{U}$）和一个仅使用非中线移位数据训练的条件扩散模型（记为 $\mathcal{C}$），对两个输出进行相减

$$\hat{\epsilon}_{\theta_\mathcal{U}}(x_t, t) - \hat{\epsilon}_{\theta_\mathcal{C}}(x_t, t) \propto \nabla \log p(x_t|n) - \nabla \log p(x_t) = \nabla \log p(n|x_t), \tag{3}$$

可视为类别预测（$n = 1$ 非中线移位时，否则为 0）相对于输入图像的梯度，反映输入图像与无中线移位图像的偏差。该潜在表示包含了如何将中线移位阳性图像转换为无中线移位图像的信息，因此有助于训练形变网络。此外，这种特征表示受加性噪声随机性的影响较小，因为减法消除了随机部分。它比

预测噪声或生成的 MLS 负样本图像更加稳定。训练时，我们从 0 到扩散步数 T_{train} 中随机采样 t ；推理时则将其固定为某个值。我们在第 3.4 节考察了该值的影响。

2.3 半监督形变正则化

形变估计是一个密集预测问题，而我们只有稀疏监督。如果形变缺少适当的正则化，就可能出现闪烁现象，且泛化能力较差。另一方面，我们拥有大量来自 MLS 体积的无标签数据，这些数据可能会有所帮助。因此，我们提出在训练过程中以半监督的方式纳入这些无标签数据，使其能够为训练提供额外的正则化，或基于带噪声的伪标签生成更多训练样本。许多现有的半监督方法会将同一网络或孪生网络对无标签数据的预测用作伪标签，并据此监督模型或施加某种正则化。然而，这些方法强烈假设有标签数据和无标签数据来自同一分布，而这并不适用于我们的情况，因为大多数有标签数据都具有较大形变，而无标签数据的形变较小或不存在形变。因此，我们希望寻找另一类伪标签，以绕开分布假设。由于假设形变场会将假想的正常图像扭曲为中线移位图像，我们通过无分类器引导，利用预训练扩散模型生成假想的无中线移位图像 x_0' [16]:

$$\hat{\epsilon}(x_t, t) = \gamma \hat{\epsilon}_{\theta_{\mathcal{C}}}(x_t, t) + (1-\gamma)\hat{\epsilon}_{\theta_{\mathcal{U}}}(x_t, t), \tag{4}$$

其中， γ 是用于控制条件强度的超参数。我们将 x_0' 扭曲后的图像与形变场 ϕ(x_0')进行比较，并通过均方误差损失计算其与原始 x_0 的相似度。由于生成过程涉及大量随机采样，生成的图像可能难以完全忠实于原始图像，因此这种 l_{mse} 只能作为噪声监督。因此，我们不在形变网络训练前预先生成 x_0' ，而是按需生成，以抵消噪声影响。

最终的 MLS 测量值通过计算预测形变场中的最大位移向量的长度来估计，因此对高估更为敏感。我们的结果也表明，大多数误差都来自高估。对于无标签切片，我们仍有先验认知：其 MLS 不会大于该特定体积 δ的 MLS。为此，我们提出加入一个额外的上限损失，以惩罚高估：

$$l_{\text{ceil}} = \sum_j \sum_k \max(0, ||\phi_{jk}|| - \delta). \tag{5}$$

总体而言，损失项由监督损失和无监督损失组合而成，并通过权重项控制各损失项的相对重要性：

$$l = l_{\text{huber}} + w_1 l_{\text{smooth}} + u(i)(l_{\text{mse}} + w_2 l_{\text{ceil}}), \tag{6}$$

其中， w_1 和 w_2 是两个固定权重项， $u(i)$ 是一个随时间变化的权重项，预计会随着训练迭代 i 的推进而逐渐增大，使训练能够先通过强监督快速收敛，再借助无监督损失进行细化并增强泛化能力。

3 实验与结果

3.1 数据采集与预处理

我们回顾性收集了2019年7月至2019年12月期间，在香港医院管理局辖下公立医院威尔士亲王医院因头部创伤或卒中症状入院，并被诊断为各种亚型颅内出血的患者的匿名厚层无增强头颅CT影像，包括硬膜外出血、硬膜下出血、蛛网膜下腔出血、脑室内出血和脑实质内出血。研究获得香港中文大学—新界东医院联网联合临床研究伦理委员会的伦理批准。符合条件的患者共计2793组CT体积数据，其中124例为MLS阳性病例。MLS范围为 $2.24mm$ 至 $20.12mm$，平均值为 $8.34mm$ ，中位数为 $8.73mm$。标注由两名受训医生完成，并由一名经验丰富的放射科医师（具有超过10年的脑内出血临床经验）审核。标注过程遵循真实的临床测量流程：标出移位标志点、大脑镰前点和大脑镰后点，并将从标志点到连接大脑镰前点与大脑镰后点的直线之间的垂线长度作为测得的MLS值。对于每组体积数据，分别测量并标注若干形变较大的切片，并将移位最大的切片所对应的数值作为病例级标签。平均而言，每组体积数据的30张切片中有4张带有标签。我们舍弃了前8张和后5张切片，因为其中主要是与MLS无关的结构。预处理时，我们将所有图像的像素尺寸调整为 $0.86mm$ ，然后将生成的图像裁剪或填充至 256×256 像素的分辨率。HU窗设为0和80。我们对每张图像进行了强度裁剪（第0.5和第99.5百分位数）以及最小—最大归一化（范围为-1至1）。采用 $-15°$至 $15°$ 之间的随机旋转进行数据增强。

3.2 实施细节

对于扩散网络，我们采用 DDPM [15]中设计的网络架构，并通过使用$T_{\text{train}} = 1000$ 进行线性调度，将噪声水平从 10^{-4} 设置为 2×10^{-2} 。对于无中线移位图像生成，我们使用 50 步的去噪扩散隐式模型（DDIM） [13]，并将噪声尺度设为 15，以缩短生成时间。我们将超参数设为 $\alpha = 1$、 $\beta = 1$、 $c = 3$和 $\gamma = 2$。 $u(i)$ 通过线性调度从 1 设置为 10。扩散模型使用 AdamW优化器进行训练，初始学习率为 1×10^{-4},

表1：使用5折交叉验证对不同方法进行比较。

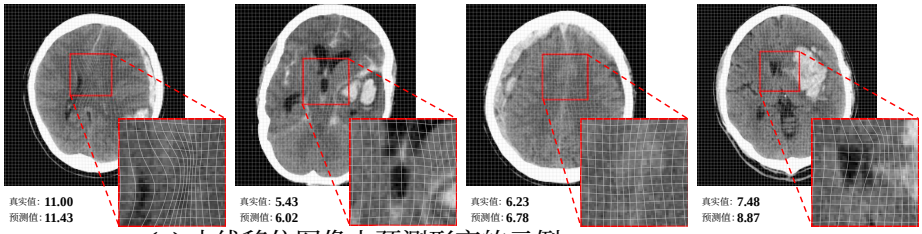
方法	训练数据		体积级		切片级	
	有标签	无标签	MAE↓ (mm)	均方根误差↓ (mm)	MAE↓ (mm)	均方根误差↓ (mm)
回归	✓		3.91	4.90	3.56	4.16
形变	✓		3.80	4.47	2.51	3.17
Mean-Teacher [19]	✓	✓	2.89	3.67	2.43	3.22
CPS [20]	✓	✓	2.72	3.42	2.38	3.15
Ours	✓	✓	**2.43**	**3.17**	**2.25**	**3.09**

批次大小为 4，迭代 2×10^5 次。训练无条件扩散模型时，我们通过 10×对中线移位阳性数据进行上采样。形变网络使用 AdamW优化器进行训练，初始学习率为 1×10^{-4}，批次大小为 16，训练 100 个周期。所有模型均使用 PyTorch 1.12.1 实现，并在一块 Nvidia GeForce RTX 3090 图形处理器上运行。

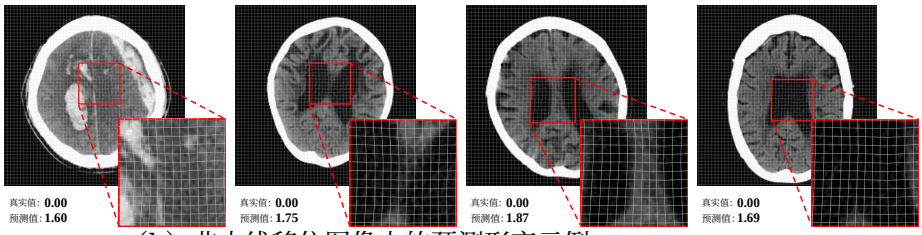
3.3 定量准确性与形变质量

我们通过平均绝对误差（MAE）和均方根误差（RMSE）评估所提出定量策略的性能。对于体积级评估，我们测量整个体积中每个切片的最大形变，并选取其中最大的值作为最终结果。我们还报告了基于标注切片计算的切片级评估结果。该误差能够反映模型在形变相对较大的切片上的表现。由于现有的 MLS 估计方法所需的标签类型与我们不同，因此难以与这些方法直接比较。因此，我们首先将基于形变的策略与基于回归的策略进行比较，后者使用 DenseNet-121 [21] 直接预测切片级 MLS。我们还将提出的半监督学习方法与两种流行的半监督学习方法进行比较，即 Mean-Teacher [19] 和交叉伪监督（CPS）[20], ，并将它们应用于我们的形变框架中。结果见表1，结果基于五折交叉验证。

从结果可以看出，仅使用有标签的 MLS 切片进行模型学习时，我们的形变策略已经优于回归模型。这可能是因为我们的形变模型学习了 MLS 数值及其位置的信息，而回归模型仅获取 MLS 数值信息。如果考虑切片级表现，这种差异还会进一步扩大。此外，三种半监督学习方法，即 Mean-Teacher、CPS 和我们的方法，均能持续提升形变预测的表现，显示出



(a) 中线移位图像上预测形变的示例



（b）非中线移位图像上的预测形变示例

图3：在（a）中线移位图像和（b）非中线移位图像上的预测形变。形变量最大的区域已突出显示。同时提供了切片级预测中线移位和真值。

将无标签数据纳入模型学习的益处和重要性。我们基于扩散模型的半监督学习方法取得了优于 Mean-Teacher 和 CPS 的定量结果，将体积级平均绝对误差从 3.80mm 显著降低至 2.43mm。一个有趣的发现是，无标签数据对体积级评估的贡献大于对切片级评估的贡献。通过检查预测结果，我们发现，使用有标签数据训练的形变预测模型往往会高估几乎没有形变或完全没有形变的切片的形变量，从而导致体积级预测容易出错。由于大多数无标签数据都是移位较小的切片，将这些数据用于半监督学习可以施加约束，避免出现较大的形变，从而显著提升模型的鲁棒性。

我们还对几个样本病例的预测形变场进行了可视化。从图 3(a) 可以看出，该模型能够准确定位最大移位出现的位置，并将其推向假设的正常对应位置。最大形变恰好发生在最大移位所在部位。为了验证模型的鲁棒性，我们还选取了几名诊断为无中线移位的患者，并绘制了这些样本的预测形变。如图 3(b) 所示，我们的方法能够通过对无中线移位图像输出远小于中线移位图像的数值，为无中线移位图像提供合理的预测。模型对无中线移位图像的预测并不完全为零，一方面是因为即使对于完全健康的人，由于扫描体位等多种因素，中线也不可能实现完美对齐；另一方面，我们的

方法	MAE↓ (mm)	均方根误差↓ (mm)
全监督	3.61	4.47
+ 表征	3.22	3.69
半监督	2.61	3.24
+ 表征	2.45	3.05

表 2：表征的影响。

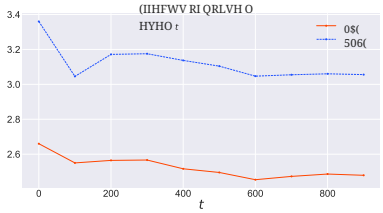


图 4：噪声水平的影响。

模型往往会高估移位，这是因为我们将最大形变作为最终测量值。

3.4 消融研究

我们进行了若干消融实验，以研究所提出框架中的多个组件对模型性能的影响。报告的逐体积结果是在四个文件夹上训练、在一个文件夹上测试得到的。

表征学习的影响。我们首先进行消融研究，以验证从两个扩散模型中提取的潜在特征是否确实有助于形变预测。为此，我们选取两个形变模型进行比较：一个仅使用有标签数据训练，另一个使用半监督学习训练；并比较它们在有无提取的表征作为输入时的性能。结果见表 2。正如预期，加入表征可以提升两种情况下的模型性能。

噪声水平是扩散模型的重要组成部分。只有设置合适的噪声水平，模型才能准确估计图像向负样本空间偏移的程度。因此，我们使用多个噪声水平进行推理，并比较其对模型性能的影响。结果如图 4 所示。我们的模型对这一超参数非常稳健。只要 t 不太小，模型的性能就非常相似。最佳性能出现在中间位置，此时 $t = 600$。这是合理的，因为噪声过小无法充分破坏原始图像，从而降低分数估计的性能；而噪声过大则可能掩盖原始图像中的过多细节。

无标签图像的数量。 为验证无标签图像的有效性，我们针对所使用的无标签图像数量开展了消融研究。在每项实验中，我们随机抽取 20%、40%、60% 和 80% 的体积，并将这些体积中的无标签切片纳入半监督训练。对于其余体积，我们仅使用带标签切片。我们还进行了一项完全不使用无标签图像的实验。各项实验使用的预训练扩散模型均相同，且该模型使用了全部数据。换言之，这些无标签图像在某种程度上仍然有助于模型训练。结果如图 5(a) 所示。可以看出，随着纳入的无标签图像增多，模型的性能和鲁棒性均有所提升。这

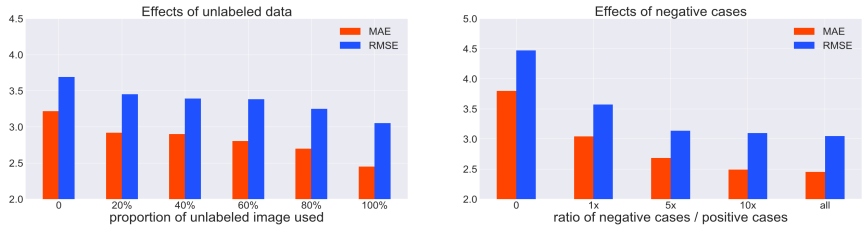


图5：消融实验结果，包括：(a) 未标注数据的使用比例；(b) 负样本数据的使用比例。

为我们的主张提供了有力证据：我们的模型确实从无标签数据中学习到了有价值的信息。

非中线移位图像的数量。为了进一步衡量纳入非中线移位病例的益处，我们针对非中线移位病例的比例开展了另一项消融研究。非中线移位病例用于训练扩散模型。目前，非中线移位病例的数量远多于中线移位病例，因此我们对中线移位病例进行上采样，使训练无条件扩散模型时两类病例的数量大致相同。在消融实验中，我们首先对非中线移位数据进行下采样，使其数量分别为中线移位病例数量的 $1\times$、 $5\times$和 $10\times$ ，随后对中线移位病例进行上采样，使两类病例数量均衡。从图5(b)的结果可以看出，纳入更多非中线移位病例后，模型性能有所提升。增加非中线移位病例有助于训练扩散模型，进而提升生成图像和提取的特征表示的质量。然而，由于中线移位病例的数量相对较少，这种效果很快就会达到饱和。这可能成为有效利用非中线移位病例的瓶颈，因为使用如此不平衡的数据集训练无条件扩散模型颇具挑战。

4 结论与未来工作

本文提出了一种基于形变场估计的新型框架，用于自动测量脑中线移位。我们使用的标签较为稀疏，可以大幅减轻标注工作量。此外，我们还提出了一种基于扩散模型的半监督学习策略，显著提升了模型性能。在临床数据集上的实验表明，我们的方法取得了令人满意的效果。我们还验证了使用无标签数据和非中线移位病例确实有助于提升模型性能。

我们的方法存在若干局限性。首先，模型性能高度依赖预训练扩散模型。使用极度不平衡的数据训练扩散模型需要付出大量努力。其次，由于噪声扰动，测量结果具有随机性。最后，测量结果容易出现高估。我们未来的工作将探索解决这些局限性的方法。

参考文献

1. Caceres, J.A., Goldstein, J.N.: 颅内出血。《Emerg. Med. Clin. North Am.》30(3), 771 (2012) 2. Quattrocchi, K.B., 等：将中线移位定量作为头部损伤后不良结局的预测指标。载于：《外科神经病学》，第35卷(3)，第183–188页，(1991)。3. Yang, W., Li, Q., Li, R., Liu, Q., Wang, X., 等：确定预测幕上自发性脑出血患者不良结局的最佳中线移位阈值。载于：《神经重症护理》，第28卷(3)，第314–321页，(2018)。4. Liao, C., Chen, Y., and Xiao, F.: 脑中线移位测量及其自动化：技术与算法综述。载于：《国际生物医学成像杂志》，第4303161卷，(2018)。5. Pisov, M., 等：将任务特定结构知识融入卷积神经网络以检测脑中线移位。载于：Suzuki, K., 等 (编) ML-CDS/IMIMIC -2019。《计算机科学讲义》，第11797卷，第30–38页。Springer, Cham (2019)。6. Wang, S., Liang, K., Li, Y., 等：融合结构连接先验的上下文感知细化网络，用于脑中线勾画。载于：Martel, A.L., 等 (编) MICCAI 2020。《计算机科学讲义》，第12267卷，第208–217页。Springer, Cham (2020)。7. Wei, H., 等：用于勾画大幅变形脑中线的基于回归的线检测网络。载于：Shen, D., 等 (编) MICCAI 2019。《计算机科学讲义》，第11766卷，第839–847页。Springer, Cham (2019)。8. Qin, C., Li, H., Liu, Y., Shang, H., Pei, H., Wang, X., Chen, Y., Chang, J., Feng, M., 等：血肿患者的三维脑中线勾画。载于：Bruijne, M., 等 (编) MICCAI 2021。《计算机科学讲义》，第12905卷，第510–518页。Springer, Cham (2021)。9. Nguyen, N.P., Yoo, Y., Chekkoury, A., Eibenberger, E., 等：基于非增强计算机断层扫描的级联深度网络流程，用于脑中线移位检测与定量。载于：ICCVW 2021。10. Liao, C., Xiao, F., 等：脑部CT图像中中线移位的自动识别。载于：《生物学与医学中的计算机》，第40卷，第331–339页。(2010) 11. Balakrishnan, G., Zhao, A., Sabuncu, M.R., Guttag, J., Dalca, A.V.: VoxelMorph：用于可变形医学图像配准的学习框架。《IEEE医学成像汇刊》38(8), 1788–1800 (2019) 12. Goodfellow, I.J.,Pouget, J.A., Mirza, M., Xu, B., Farley, D.W., Ozair, S., Courville, A., Bengio, Y.: 生成对抗网络。载于：NeurIPS 2014。13. Song, J., Meng, C., Ermon, S.: 去噪扩散隐式模型。载于：ICLR 2020。14. Ho, J., 等：去噪扩散概率模型。载于：NeurIPS 2020。15. Dhariwal, 等：扩散模型在图像合成方面优于生成对抗网络。载于：NeurIPS 2021。16. Ho, J., and Salimans. T.: 无分类器扩散引导。载于：NeurIPS 2021深度生成模型与下游应用研讨会 (2021)。17. Song, Y., and Ermon, S.: 通过估计数据分布梯度进行生成建模。载于：NeurIPS 2019。18. Luo, C.: 理解扩散模型：统一视角。arXiv预印本 arXiv:2208.11970 (2022) 19. Tarvainen, A., Valpala, H.: 均值教师是更好的榜样：权重平均一致性目标提升半监督深度学习效果。载于：NeurIPS 2017。20. Chen, X., Yuan, Y., Zeng, G., Wang, J.: 基于交叉伪监督的半监督语义分割。载于：CVPR 2021。21. Huang, G., Liu, Z., van der Maaten, L., Weinberger, K.Q.: 密集连接卷积网络。载于：CVPR 2017。