arXiv:2602.00956v1 [cs.CV] 1 Feb 2026

用于准确磁共振成像阿尔茨海默病严重程度分类的拓扑与深度特征融合混合方法

Faisal Ahmed[1*]

[1*]数据科学与数学系，安柏瑞德航空航天大学，美国亚利桑那州普雷斯科特市 WillowCreek 路 3700 号，邮编 86301。

通讯作者。电子邮箱：ahmedf9@erau.edu；

摘要

在基于神经影像的临床决策支持系统中，阿尔茨海默病（AD）的早期准确诊断仍是一项关键挑战。本文提出一种新颖的混合深度学习框架，将拓扑数据分析（TDA）与 DenseNet121 主干网络相结合，利用 OASIS 数据集中的结构磁共振成像数据进行四分类阿尔茨海默病分类。TDA 用于捕捉常规神经网络往往忽略的脑结构互补拓扑特征，而 DenseNet121 则能从磁共振成像切片中高效学习分层空间特征。通过融合提取的深度特征与拓扑特征，增强了阿尔茨海默病四个阶段之间的类别可分性。在 OASIS-1 Kaggle 磁共振成像数据集上进行的大量实验表明，所提出的 TDA+DenseNet121 模型显著优于现有最先进方法。该模型的准确率达到 99.93%，曲线下面积达到 100%，优于近期发表的基于卷积神经网络的方法、迁移学习、集成学习及多尺度架构。这些结果证实了将拓扑信息融入深度学习流程的有效性，并凸显了所提框架作为一种稳健且高度准确的阿尔茨海默病自动诊断工具的潜力。

关键词： 阿尔茨海默病、基于磁共振成像的诊断、拓扑数据分析、混合深度学习、疾病严重程度分类

1 引言

阿尔茨海默病（AD）是一种进行性神经退行性疾病，也是全球最常见的痴呆病因之一。其特征是不可逆的认知能力下降，并伴随脑结构逐渐退化。准确识别阿尔茨海默病严重程度阶段对于早期诊断、治疗规划和监测疾病进展至关重要。磁共振成像（MRI）已成为阿尔茨海默病评估的基石性成像方式，这得益于其无创性以及捕捉海马萎缩、皮质变薄和脑室扩大等结构变化的能力 [1, 2]。

尽管具有重要的临床意义，基于磁共振成像的阿尔茨海默病自动分类仍是一项艰巨任务。疾病不同阶段的结构变化通常较为细微、呈非线性，且个体差异显著。此外，经过充分标注的神经影像数据集有限，以及类别不平衡问题，进一步增加了可靠模型训练的难度 [3]。传统机器学习方法依赖手工特征，可能无法捕捉脑部磁共振成像数据中固有的复杂空间和结构关系。

深度学习，尤其是卷积神经网络（CNN），近期取得了显著进展，在基于磁共振成像的阿尔茨海默病分类任务中展现出良好前景 [4]。研究人员已在 OASIS 及其衍生数据集上探索 AlexNet、孪生网络、多尺度卷积神经网络和基于集成的深度模型等架构，并取得了较高的分类准确率 [5–8]。然而，如表2所总结，这些模型通常依赖强力的数据增强、大规模训练集或复杂的集成策略，并且主要学习局部的基于强度的特征。这些方法的计算成本可能较高，对数据不平衡较为敏感，也难以解释，从而限制了其临床适用性 [9]。

拓扑数据分析 (TDA) 最近已发展成为一种互补的数学框架，能够捕捉复杂数据的全局属性和形状感知属性 [10]。通过利用持久同调，TDA 对稳定的拓扑特征进行编码，在有效抵抗噪声和微小扰动的同时，总结数据内在的结构模式 [11]。在医学成像领域，TDA 已展现出强大的潜力，能够以可解释且数据高效的方式对解剖结构和疾病相关变化进行建模 [12]。然而，纯粹由拓扑驱动的模型可能难以捕捉高维磁共振成像数据中存在的细粒度局部纹理。

受上述观察启发，我们提出了一种新型混合框架，将 **拓扑数据分析与 DenseNet121** 相结合，融合全局拓扑描述符和深度卷积特征学习的优势。DenseNet121 是一种高效的深度架构，通过密集连接促进特征复用，从而以更少的参数实现强大的表征学习 [13]。在所提出的模型中，基于 TDA 的特征捕捉脑部磁共振成像的全局结构和几何特征，而 DenseNet121 学习分层空间表征，从而增强特征互补性。

我们在**OASIS-1（Kaggle）磁共振成像数据集** 上评估所提出的**拓扑数据分析+ DenseNet121** 框架，用于四分类阿尔茨海默病严重程度分类。如表2所示，所提出的模型准确率达到**99.93%**，曲线下面积达到**100%**，优于近期发表的基于深度学习和集成学习的

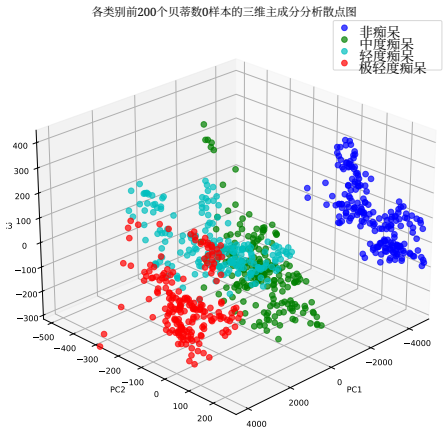

(a)基于贝蒂-0 特征的三维主成分分析投影，显示了阿尔茨海默病四种类别之间的明显区分。

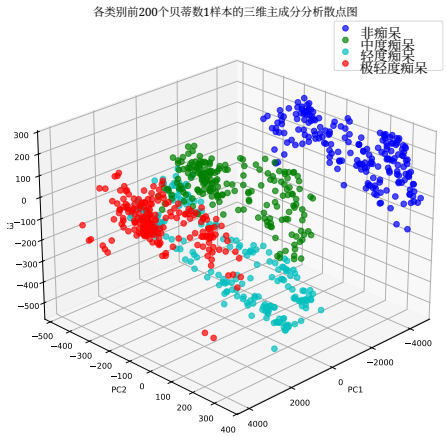

(b)基于贝蒂数1 特征的三维主成分分析投影，展示了阿尔茨海默病各类别的独特聚类。

图 1：使用前三个主成分对拓扑特征进行可视化分析。(a) 贝蒂-0 特征和 (b) 贝蒂-1 特征呈现出清晰且相互区分的聚类，分别对应四个阿尔茨海默病严重程度阶段，凸显了拓扑描述符的判别能力。

在 OASIS 及源自 OASIS 的数据集上的方法。这些结果凸显了拓扑表示在阿尔茨海默病严重程度评估中的价值，并表明所提出的**拓扑数据分析+DenseNet121** 框架为传统基于深度学习的磁共振成像分类方法提供了一种计算高效、数据高效且可解释的替代方案（见图 1 和 5）。此外，将拓扑信息与深度学习相结合，可显著增强模型的鲁棒性、泛化能力以及整体分类性能。

我们的贡献

- 我们提出了一种新颖、可解释的混合 **拓扑数据分析+DenseNet121** 框架，用于基于结构磁共振成像进行四分类阿尔茨海默病严重程度分类。
- 我们将**基于持久同调得出的拓扑描述符**与深度卷积特征相结合，以捕捉脑部磁共振成像的全局结构模式和局部空间特征。
- 我们在 OASIS-1 MRI 数据集上展现了**最先进的性能**，准确率达到**99.93%**，**曲线下面积达到 100%**，超越了现有的深度学习和集成学习方法。
- 我们证明，所提出的模型在保持计算效率的同时，具有更强的**鲁棒性和泛化能力**，适用于临床场景和数据有限的场景。
- 我们强调，**拓扑感知深度学习**有望成为一种有效且可解释的神经影像阿尔茨海默病诊断范式。



(a) 未患痴呆磁共振成像样本。 (b) 中度痴呆 MRI 样本。 (c)轻度痴呆磁共振成像样本。 (d) Very mild 痴呆 MRI 样本。

图 2: 本研究所考虑的四种阿尔茨海默病类别对应的 OASIS-1 数据集典型脑部磁共振成像示例。

2 相关研究

基于脑磁共振成像（MRI）的自动化分析已被广泛用于阿尔茨海默病（AD）的计算机辅助诊断。早期研究主要依赖从基于体素的形态测量学（VBM）、皮质厚度和区域体积测量中提取的手工特征，并结合传统机器学习分类器。支持向量机（SVM）利用脑结构改变，在区分阿尔茨海默病患者与认知正常者方面取得了令人鼓舞的结果 [14]。后续研究将 VBM 特征与卷积神经网络（CNN）相结合，以增强判别能力，但这些方法仍易受预处理流程和数据集特定差异的影响 [15]。

深度学习的快速发展显著推动了基于磁共振成像的阿尔茨海默病分类。由于能够自动从神经影像数据中学习层次化表征，二维和三维卷积神经网络架构均得到了广泛应用 [16]。密集型和多尺度卷积神经网络架构通过捕捉互补的局部信息与上下文信息，进一步提高了分类准确率 [17]。结合多个卷积神经网络模型的集成学习策略也已得到探索，以增强鲁棒性和泛化能力 [18]。尽管这些方法表现出色，但通常依赖大量标注数据集、大规模数据增强以及高昂的计算成本，这限制了它们在小型或中等规模临床数据集中的适用性。

为缓解纯深度学习模型的局限性，研究者提出了融合结构先验与特征选择技术的混合方法。拓扑保持分割框架（如 TOADS）在脑组织分割过程中确保解剖结构的一致性 [19]。包括最小冗余最大相关（mRMR）在内的特征选择方法，已被应用于降低特征维度，并提高基于磁共振成像的阿尔茨海默病研究中的分类稳定性 [20, 21]。尽管这些技术增强了可解释性和鲁棒性，但它们在很大程度上依赖基于强度或特定区域的特征，可能无法充分捕捉与疾病进展相关的全局结构变化。

近年来，拓扑数据分析（TDA）已成为一种强大的框架，可从复杂的医学成像数据中提取全局且感知形状的表示。借助持久同调，TDA 能够编码内在的拓扑特征，这些特征在噪声和微小扰动下仍保持稳定 [10, 11]。越来越多的研究已证明，TDA 在医学图像分析中行之有效，

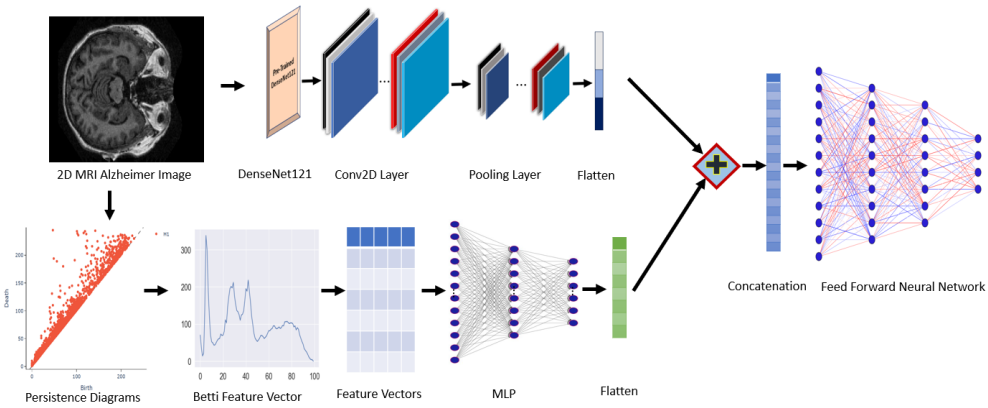

图 3： **所提出的拓扑数据分析（TDA）+DenseNet121 阿尔茨海默病分类框架**。该架构由两个互补的特征提取分支组成。在第一个分支中，将二维脑部磁共振成像切片输入基于 DenseNet121 的卷积网络，以学习层次化深度特征，随后进行卷积、池化和展平操作。与此同时，第二个分支对相同的磁共振成像输入应用拓扑数据分析（TDA），利用立方次水平过滤计算持久图，以捕获拓扑特征的诞生与消亡。这些图被转换为定长的贝蒂特征向量，并通过多层感知机（MLP）进一步优化。随后，将深度卷积特征与拓扑特征拼接，形成统一表示，最终输入前馈神经网络，以进行阿尔茨海默病严重程度四分类。

包括应用于脑部磁共振成像、组织病理学和体积成像 [12, 22–28]。这些研究凸显了拓扑描述符的稳健性、可解释性和数据效率，尤其是在数据有限的场景中。

与此同时，视觉Transformer（ViT）通过利用自注意力机制建模长程依赖关系，作为卷积神经网络的替代方案而受到关注 [29,30]。基于ViT的模型在医学成像任务（包括脑部MRI分析）中展现出良好的性能 [31, 32]。然而，由于计算需求高、依赖大规模预训练，以及需要进行通道复制等适配，其在灰度磁共振成像数据上的应用仍面临挑战；这些方法可能无法充分利用MRI特有的结构信息。近期研究探索了将迁移学习和基于Transformer的架构应用于医学图像分析，但在小型或类别不平衡的数据集中，性能往往会下降 [33–42]。

相比之下，拓扑感知方法为基于磁共振成像的阿尔茨海默病分类提供了一种计算效率高且易于解释的替代方案。通过捕捉全局结构模式，弥补基于局部强度表示的不足，基于拓扑数据分析的方法解决了深度学习模型和基于 Transformer 的模型的关键局限。受这些优势启发，本研究将拓扑描述符与深度卷积特征相结合，在不过度依赖数据增强或大规模训练的情况下，实现准确、稳健的阿尔茨海默病四阶段严重程度分类。

3 方法论

3.1 通过持久同调进行拓扑特征提取

采用拓扑数据分析（TDA），利用持久同调（PH）从二维磁共振成像切片中提取稳健的结构描述符（见图 2）。给定一幅灰度磁共振成像图像 $\mathcal{X} \in \mathbb{R}^{H\times W}$，通过逐步对像素强度进行阈值处理，构建立方子水平过滤（见图 4）。对于一系列递增的阈值 $\{t_1, t_2, \ldots, t_N\}$，将过滤构建为一系列嵌套的立方复形，可将其解释为连续的二值图像：

$$\mathcal{X}_{t_1} \subseteq \mathcal{X}_{t_2} \subseteq \cdots \subseteq \mathcal{X}_{t_N}, \quad \mathcal{X}_{t_k} = \{(i,j) \mid \mathcal{X}_{i,j} \le t_k\}.$$

对于每个过滤层级，计算同调群 $H_k(\mathcal{X}_{t_k})$，其中 $k = 0$ 表示连通分量，$k = 1$ 表示环或空腔。这些拓扑特征的出生与死亡时间通过持久图进行汇总：

$$\mathrm{PD}_k = \{(b_\ell, d_\ell) \mid \ell \in H_k\},$$

其中，b_ℓ 和 d_ℓ 分别表示特征出现和消失时的阈值。

为了将持久图转换为适用于学习的定长表示，计算贝蒂曲线。贝蒂数 $\beta_k(t)$ 表示阈值 t 处活跃的 k 维拓扑特征数量：

$$\beta_k(t) = \left|\{(b_\ell, d_\ell) \in \mathrm{PD}_k \mid b_\ell \le t < d_\ell\}\right|.$$

为提高计算效率，将贝蒂曲线离散为 100 个分箱，每个同调维度各一组。每个磁共振成像切片的最终拓扑特征向量通过拼接贝蒂数0和贝蒂数1向量获得：

$$\mathbf{T} = [\boldsymbol{\beta}_0, \boldsymbol{\beta}_1] \in \mathbb{R}^{200}.$$

这些向量编码了脑结构的全局形态特征，并且对平移和旋转等几何变换具有不变性。

3.2 基于DenseNet121的图像特征提取

为了直接从磁共振成像中学习具有判别性的空间特征，本文采用了基于 DenseNet121 的深度卷积神经网络。首先，将每张磁共振成像切片归一化并重塑为张量 $\mathbf{I} \in \mathbb{R}^{248\times 248\times 1}$。由于 DenseNet121 专为三通道输入而设计，因此首先应用一个卷积层，将灰度图像投影为三通道表示：

$$\mathbf{I}' = \sigma(\mathbf{W}_{\mathrm{conv}} * \mathbf{I} + \mathbf{b}_{\mathrm{conv}}), \quad \mathbf{I}' \in \mathbb{R}^{248\times 248\times 3},$$

其中，$*$表示卷积，$\sigma(\cdot)$表示 ReLU 激活。

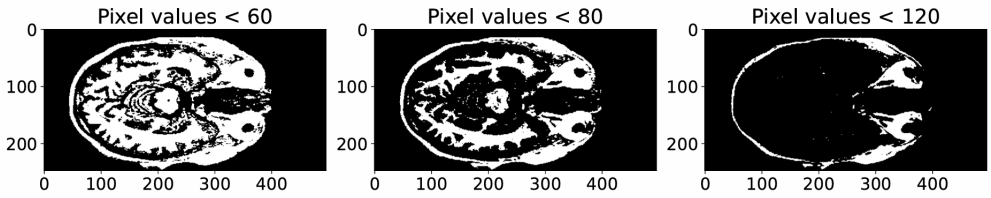

图 4：**MRI图像的子水平集过滤**。立方（子水平集）过滤过程示意图，其中像素根据其灰度强度值逐步激活。二值图像 $\mathcal{X}_{60}$、 $\mathcal{X}_{80}$ 和 $\mathcal{X}_{120}$ 分别对应阈值 60、80 和 120，展示了随着强度等级升高，连通分量和拓扑结构逐渐形成与演变的过程。

变换后的图像 $\mathbf{I}'$ 输入移除了分类头的 DenseNet121 主干网络。DenseNet121 由密集连接的卷积块组成，每一层都会接收所有前序层的特征图，从而促进特征复用并改善梯度流。令 $\Phi(\cdot)$ 表示卷积骨干网络学习到的映射：

$$\mathbf{F}_{\text{Dense}} = \Phi(\mathbf{I}'), \quad \mathbf{F}_{\text{Dense}} \in \mathbb{R}^{h \times w \times c}.$$

采用全局平均池化来汇总空间信息：

$$\mathbf{f}_{\text{GAP}} = \frac{1}{hw} \sum_{i=1}^{h} \sum_{j=1}^{w} \mathbf{F}_{\text{Dense}}(i, j), \quad \mathbf{f}_{\text{GAP}} \in \mathbb{R}^{c}.$$

随后，通过带 ReLU 激活的全连接层进一步优化该向量，以生成图像特征嵌入：

$$\mathbf{F}_{\text{CNN}} = \text{ReLU}(\mathbf{W}_{\text{cnn}} \mathbf{f}_{\text{GAP}} + \mathbf{b}_{\text{cnn}}), \quad \mathbf{F}_{\text{CNN}} \in \mathbb{R}^{64}.$$

这些特征捕捉了与阿尔茨海默病进展相关的局部纹理模式和空间变化。

3.3 特征融合与分类

所提出的框架通过后期融合策略整合拓扑特征和深层图像特征。拓扑嵌入$\mathbf{F}_{\text{TDA}} \in \mathbb{R}^{128}$ 和 CNN嵌入$\mathbf{F}_{\text{CNN}} \in \mathbb{R}^{64}$ 拼接后形成联合特征表示：

$$\mathbf{F}_{\text{fusion}} = [\mathbf{F}_{\text{TDA}}, \mathbf{F}_{\text{CNN}}] \in \mathbb{R}^{192}.$$

该融合向量经过一系列全连接层，以对模态之间的高阶交互进行建模：

$$\mathbf{z}_1 = \text{ReLU}(\mathbf{W}_1 \mathbf{F}_{\text{fusion}} + \mathbf{b}_1), \quad \mathbf{z}_2 = \text{ReLU}(\mathbf{W}_2 \mathbf{z}_1 + \mathbf{b}_2).$$

应用丢弃率为 $p = 0.2$ 的丢弃操作以减少过拟合。最终分类层使用 Softmax 激活来预测四个阿尔茨海默病阶段的概率分布：

$$\hat{\mathbf{y}} = \mathrm{Softmax}(\mathbf{W}_{\mathrm{out}}\mathbf{z}_2 + \mathbf{b}_{\mathrm{out}}), \quad \hat{\mathbf{y}} \in \mathbb{R}^4.$$

模型通过最小化分类交叉熵损失进行训练：

$$\mathcal{L} = -\sum_{c=1}^{4} y_c \log(\hat{y}_c),$$

其中 y_c 表示真实标签。该融合策略使模型能够联合利用全局拓扑结构和局部空间模式，从而提升分类性能。所提出模型的完整工作流程如图3所示。所提出方法的算法框架见算法1。

3.4 超参数调优

所提出的 TDA+DenseNet121 融合模型的超参数通过经验确定，并在所有实验中保持固定，以确保可复现性。模型使用 TensorFlow/Keras 实现，并采用端到端方式训练。数据集按照 90:10 的比例划分为训练集和测试集，并使用固定的随机种子。类别标签采用独热编码，以用于四分类。训练前，MRI 图像调整为 248×248 像素，并归一化至范围 $[0, 1]$ 。DenseNet121 分支使用 ImageNet 预训练权重初始化，并设置为不包含分类头。对卷积特征图进行全局平均池化，随后接入一个带 ReLU 激活的全连接层。与此同时，拓扑特征分支采用多层感知机处理提取出的 TDA 向量。

通过拼接 DenseNet121 和拓扑数据分析分支的输出进行特征级融合，随后使用全连接层和丢弃来缓解过拟合。最终预测层采用 Softmax 激活进行四分类。模型使用 Adam 优化器和分类交叉熵损失进行训练。训练共进行 50 个轮次，批次大小为 32。根据验证准确率进行模型检查点保存，并保留性能最佳的模型用于评估。未使用数据增强或学习率调度。完整的超参数值汇总于表 1。

4 实验

4.1 数据集

OASIS-1 数据集 [43]

OASIS-1 数据集是一个广泛使用的横断面结构 MRI 数据库，包含 416 名年龄介于 18 至 96 岁的成年人的 T1 加权脑部扫描

算法 1：TDA+DenseNet121：基于融合的四分类阿尔茨海默病分类 输入：MRI 数据集 $\mathcal{D} = \{(\mathbf{I}_i, y_i)\}_{i=1}^{N}$、同调维数 $k \in \{0, 1\}$、贝蒂分箱数量 $B = 100$、训练 – 测试集划分比例、DenseNet121 主干网络 输出：训练好的融合模型和评估指标 步骤 1：MRI 预处理 对于 $i \leftarrow 1$ 至 N，执行以下操作：将磁共振成像切片 $\mathbf{I}_i$ 调整大小至 248×248将像素强度归一化至 $[0, 1]$扩展通道维度：$\mathbf{I}_i \in \mathbb{R}^{248\times248\times1}$指定类别标签 $y_i \in \{0, 1, 2, 3\}$ 步骤 2：通过持久同调进行拓扑特征提取 对于 $i \leftarrow 1$ 至 N，执行以下操作：根据 $\mathbf{I}_i$ 构建立方子水平过滤 对于 $homology\ dimension\ k \in \{0, 1\}$，执行以下操作：计算持久图 $\mathrm{PD}_k(\mathbf{I}_i) = \{(b_\sigma, d_\sigma)\}$计算贝蒂曲线 拼接贝蒂特征：步骤 3：数据集构建与划分 构建 MRI 张量数据集 $\mathbf{X}_{\mathrm{MRI}}$ 和拓扑数据分析特征矩阵 $\mathbf{X}_{\mathrm{TDA}}$按 90:10 的比例将数据划分为训练集和测试集 对类别标签应用独热编码 步骤 4：通过双分支网络进行特征学习 (a) 拓扑数据分析分支（多层感知机）：通过全连接层处理 $\mathbf{T}_i$：

$$\vec{\beta}_k(\mathbf{I}_i) = [\beta_k(t_1), \ldots, \beta_k(t_B)]$$

$$\mathbf{T}_i = [\vec{\beta}_0(\mathbf{I}_i), \vec{\beta}_1(\mathbf{I}_i)] \in \mathbb{R}^{200}$$

$$198 \to 800 \to 256 \to 128$$

使用 ReLU 激活以获得拓扑嵌入 $\mathbf{F}_{\mathrm{TDA}}$
（b）卷积分支（DenseNet121）：将灰度 MRI 转换为 3 通道输入
使用 DenseNet121（ImageNet 权重，无分类头）提取深度特征，应用全局平均池化及 64 单元全连接层，以获得图像嵌入$\mathbf{F}_{\mathrm{CNN}}$

步骤 5：特征融合与分类拼接特征嵌入：通过全连接层 $256 \to 128$ 并应用 ReLU 激活以 $p = 0.2$ 的比例进行丢弃使用 Softmax 预测类别概率：**步骤 6：模型训练**使用 Adam 优化器优化分类交叉熵损失训练 50 个轮次，批次大小为 32使用检查点保存验证准确率最高的模型 **步骤 7：评估** 9在测试集上生成预测结果计算准确率、精确率、召回率和 F1 分数计算多分类曲线下面积（OvR）生成混淆矩阵**返回** 训练完成的融合模型和性能指标

$$\mathbf{F}_{\mathrm{fusion}} = [\mathbf{F}_{\mathrm{TDA}}, \mathbf{F}_{\mathrm{CNN}}]$$

$$\mathbf{y} = \mathrm{softmax}(\mathbf{W}\mathbf{F}_{\mathrm{fusion}} + \mathbf{b})$$

表 1：所提出的 TDA+DenseNet121 融合模型的超参数设置

组件	超参数设置
输入数据	图像尺寸： $248 \times 248 \times 1$ （灰度） 像素归一化： $[0, 1]$ 缩放 TDA 特征维度：198 训练集–测试集划分：90:10（随机种子 $= 3$）
DenseNet121 分支	骨干网络：DenseNet121 预训练权重：ImageNet 包含顶层：否 全连接层：64 个神经元（ReLU）
TDA-MLP分支	全连接层：800–256–128 激活函数：ReLU 输入维度：200 输出嵌入维度：128
融合网络	融合方法：特征拼接 全连接层：256、128（ReLU） Dropout率：0.2 输出层：4 个神经元（Softmax）
训练设置	优化器：Adam（默认参数） 损失函数：分类交叉熵 批次大小：32 训练轮次：50 模型检查点：最佳验证准确率

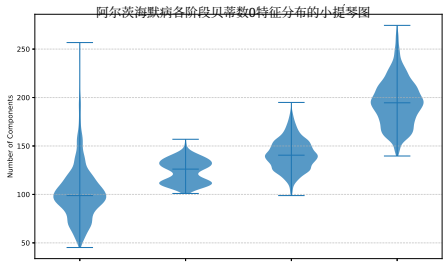

(a)四个阿尔茨海默病阶段中贝蒂数0（连通分量）特征的小提琴图，揭示了清晰分离且具有类别特异性的分布模式。

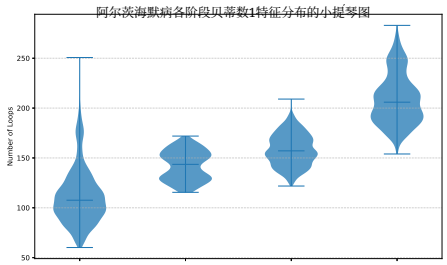

(b)贝蒂数1（拓扑环）特征的小提琴图，展示了各阿尔茨海默病类别之间明显且结构良好的分布。

图 5： 基于持久同调得出的拓扑特征分布的可解释可视化。小提琴图展示了所有 MRI 样本中汇总的贝蒂数0和贝蒂数1特征在各类别中的分布。四个阿尔茨海默病严重程度分期之间呈现出明显且互不重叠的模式，表明脑结构存在渐进且具有判别性的拓扑变化。这些清晰的区分凸显了所提出的基于拓扑数据分析的描述符具有很强的可解释性和类别判别能力。

年。每位受试者在单次成像会话期间采集了三或四次 T1加权MRI扫描，从而能够生成信噪比较高的平均图像，并有助于开展稳健的形态计量分析。在整个队列中，

100名60岁以上受试者经临床诊断患有极轻度至中度阿尔茨海默病（AD），其余316名受试者则被归类为认知正常对照。由于每名受试者有多次扫描，该数据集包含约300–400次AD扫描和950–1300次非痴呆对照扫描。

该数据集还包含一个可靠性子集，其中20名非痴呆受试者在约90天内接受了复扫，可用于评估重测再现性。除原始T1加权图像外，OASIS-1还提供经运动校正和平均处理的体积数据、图谱配准图像、增益场校正扫描以及去颅骨脑体积。另有分割结果可用于区分灰质、白质和脑脊液。此外，每名受试者均附有全面的元数据，包括人口统计信息（年龄、性别、惯用手）、临床痴呆评定以及体积测量指标，例如估算的总颅内容积、标准化全脑体积和图谱缩放因子。凭借标准化的采集方案、高质量数据，以及同时纳入健康受试者和阿尔茨海默病受试者，OASIS-1已成为衰老、神经退行性疾病研究和算法验证的基准数据集。

本研究将 OASIS-1 磁共振成像数据整理为四个诊断类别：无痴呆、极轻度痴呆、轻度痴呆和中度痴呆。为确保模型训练和评估的稳健性，我们根据可用扫描数据构建了各类别的专属子集。用于模型开发的最终数据集包含 5000 个无痴呆样本、5000 个极轻度痴呆样本、5002 个轻度痴呆样本和 488 个中度痴呆样本。这一分布反映了原始队列中固有的类别不平衡，尤其是中度痴呆病例数量有限。无痴呆和早期痴呆类别的样本量较大，使模型能够有效学习与阿尔茨海默病早期进展相关的细微结构变化，同时保留四个阶段在临床诊断上的重要多样性。

4.2 实验设置

训练集–测试集划分：按照文献中针对基于 OASIS 的阿尔茨海默病分类所采用的常见做法，将数据集按 90:10 的比例划分为训练集和测试集。

无需数据增强：与严重依赖大量数据增强策略来缓解训练数据有限或不平衡问题的传统卷积神经网络和深度学习方法相比，[44]，该**拓扑数据分析+DenseNet121**框架无需任何形式的数据增强。提取的拓扑描述符本身对几何变换（如旋转和翻转）以及轻微的强度变化具有不变性，因此模型能够抵御磁共振成像扫描中的噪声和细微扰动。这样便无需进行数据增强，大幅降低了计算开销，并提升了训练效率，同时保持了强大的泛化性能。

运行效率与平台：所有实验均在一台个人笔记本电脑上进行，该电脑配备 Apple M1 片上系统、8 核中央处理器（4 个性能核心和 4 个能效核心）以及 16 GB 统一内存。实现使用 Python 和 TensorFlow/Keras 框架完成，所有

模型均在 macOS 上训练和评估。源代码将公开发布，以支持研究结果的复现。

5 结果

表 2 对近期发表的、使用 OASIS 和基于 OASIS 的 MRI 数据集进行四分类阿尔茨海默病分类的方法进行了比较分析。所报告的方法涵盖了多种深度学习范式，包括采用大量数据增强的传统卷积神经网络、迁移学习、集成架构、孪生网络以及多尺度卷积模型。性能主要通过分类准确率以及（如有报告）ROC 曲线下面积（曲线下面积）进行评估。

早期的迁移学习和集成方法在 OASIS 数据集上取得了中等性能。基于 AlexNet 的迁移学习模型在 80:20 的训练—测试划分下报告了 92.85% 的准确率 [5], , 而深度神经网络集成在 90:10 的划分下达到了 93.18% 的准确率 [6]。尽管这些方法证明了多类别阿尔茨海默病分类的可行性，但其性能仍然有限，这可能是因为未能充分建模类别间细微的结构差异。

较新的架构引入了专门的网络设计，以提升判别能力。四路孪生卷积神经网络在 OASIS-3 数据集上取得了 93.85% 的准确率和 95.10% 的曲线下面积 [7], , 凸显了度量学习在多类别判别方面的优势。类似地，深度多尺度卷积神经网络模型也报告了性能提升，在采用 90:10 划分时，准确率达到 98.00%，曲线下面积达到 99.33% [8]。这些结果表明，多尺度特征提取能够增强对疾病相关模式的捕捉；然而，此类模型通常依赖复杂的架构，且计算成本较高。

在以往的研究中，采用大量数据增强的卷积神经网络模型取得了最高性能：使用 70:30 划分时，在 OASIS Kaggle 磁共振成像数据集上准确率最高达到 99.68% [45]。尽管这些方法效果显著，但它们高度依赖激进的数据增强策略来缓解数据匮乏并提升泛化能力，这可能会引入冗余，并限制不同数据集间的可复现性。

相比之下，所提出的 **拓扑数据分析+DenseNet121** 框架取得了最佳的整体性能，在 OASIS-1 Kaggle磁共振成像数据集上采用 90:10 的训练集–测试集划分时，准确率达到 **99.93%** ，曲线下面积达到 **100%**。这一提升并非依赖过度的数据增强或复杂的集成机制，而是通过互补融合拓扑描述符（用于捕捉脑部磁共振成像的全局结构与几何属性）和 DenseNet121 学得的深度卷积特征实现的。这种混合表示增强了阿尔茨海默病所有四个阶段之间的类别可分性。

总体而言，结果表明，将拓扑数据分析融入深度学习流程，可为阿尔茨海默病严重程度分类提供稳健且具有高度判别力的特征表示。与现有最先进的卷积神经网络、孪生网络和集成方法相比，所提出的方法

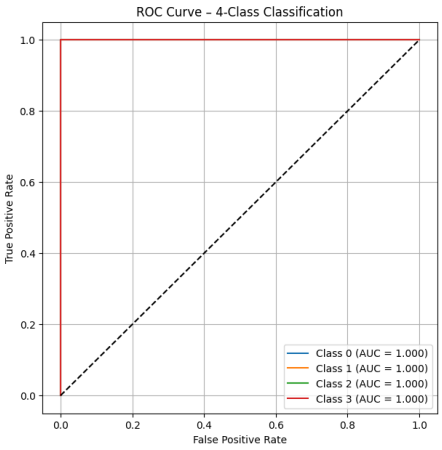

(a)各类别对应的 一对多ROC曲线及曲线下面积分数。

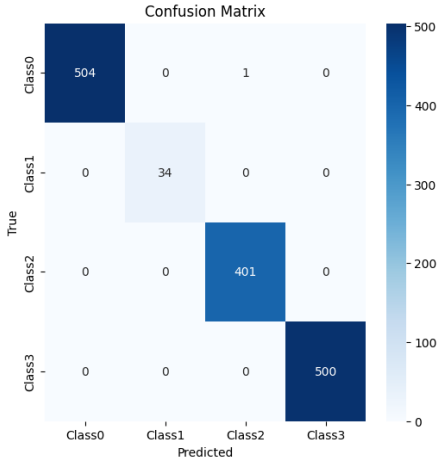

(b)显示各类别预测性能的 四分类 for 模型阿尔茨海默病分类。

图 6: **拓扑数据分析+DenseNet121** 在 OASIS-1 数据集上的评估。(a) 一对多ROC曲线，展示四种阿尔茨海默病类别的区分性能。(b) 混淆矩阵，展示各类别中分类正确和错误的样本。

具有更高的准确率、优异的曲线下面积表现和更强的稳健性，彰显了其在可靠且具有临床意义的基于磁共振成像的阿尔茨海默病诊断中的潜力。

表 2: 已发表的基于 OASIS 或 OASIS 衍生磁共振成像数据集进行四分类阿尔茨海默病分类的准确率结果。

OASIS / OASIS 衍生磁共振成像数据集：四分类结果

方法	# 个类别	数据集	训练集:测试集	准确率	AUC
卷积神经网络（数据增强 +数据增强） [45]	4	OASIS（Kaggle 磁共振成像）	70:30	99.68	–
使用 AlexNet 进行迁移学习 [5]	4	OASIS 磁共振成像	80:20	92.85	–
深度神经网络集成学习 [6]	4	OASIS 磁共振成像	90:10	93.18	–
四路孪生卷积神经网络 [7]	4	OASIS-3 磁共振成像	80:20	93.85	95.10
深度多尺度卷积神经网络 [8]	4	OASIS（磁共振成像）	90:10	98.00	99.33
卷积神经网络（数据增强 +数据增强） [45]	4	OASIS（Kaggle 磁共振成像）	70:30	99.68%	–
拓扑数据分析+DenseNet121（我们的方法）	4	OASIS-1（Kaggle 磁共振成像）	90:10	**99.93**	**100**

6 讨论

本研究的结果表明，将拓扑数据分析（TDA）与深度卷积特征学习相结合，可显著提升基于结构磁共振成像的四分类阿尔茨海默病分类性能。

所提出的 TDA+DenseNet121 框架在 OASIS 及其衍生数据集上的表现始终优于此前报道的基于卷积神经网络、基于集成学习以及多尺度架构的模型。这些发现证实，拓扑感知表征能够为传统深度学习特征提供互补信息，并增强模型区分阿尔茨海默病严重程度分期之间细微结构差异的能力。

比较分析的一项关键发现是，许多性能优异的深度学习方法严重依赖激进的数据增强、复杂的集成模型或专门设计的架构。尽管这些策略有效，但会增加计算成本，并可能降低模型在不同数据集上的可复现性。相比之下，所提出的框架无需过度依赖数据增强或多模型融合，即可实现更高的准确率和曲线下面积。引入拓扑描述符后，模型能够捕捉脑部磁共振成像中在噪声和受试者间变异性影响下仍保持稳定的全局几何与结构特征，从而提升鲁棒性和泛化能力。

所提出方法出色的曲线下面积表现表明，其在全部四种诊断类别中均具有优异的类别可分性。这对于阿尔茨海默病早期阶段尤为重要，因为此时结构变化较为细微，往往难以仅凭基于强度的特征检测出来。通过持久同调对全局结构模式进行编码，拓扑数据分析补充了 DenseNet121 学得的层次化空间表征，从而提升了对相邻疾病阶段（如极轻度痴呆与轻度痴呆）的区分能力。

尽管表现出色，仍需注意若干问题。实验仅使用了一个数据集（OASIS-1）；虽然结果与多项基于 OASIS 及其衍生数据集的研究进行了比较，但并未明确评估跨数据集泛化能力。此外，中度痴呆病例数量较少，反映了该数据集固有的类别不平衡，这可能会影响模型对疾病后期阶段的敏感度。未来的工作将探索在 ADNI 等独立队列上进行验证，并研究领域自适应策略，以进一步提升泛化能力。

从临床角度来看，所提出的混合方法在性能、效率和可解释性之间实现了良好的平衡。拓扑特征能够提供有意义且稳定的脑结构表征，并可与已知的神经退行性模式相联系，从而有望提升临床医生对自动化决策支持系统的信任。将 TDA 与紧凑而强大的深度架构相结合，为在真实临床环境中部署稳健的阿尔茨海默病分类模型提供了一条可扩展的路径。

最后，本研究凸显了拓扑感知深度学习在神经影像分析中的价值，并证明将全局结构描述符与卷积表示相结合，能够显著推动基于磁共振成像的阿尔茨海默病严重程度分类达到新的先进水平。

7 消融研究

研究人员在 OASIS-1（Kaggle 磁共振成像）数据集上进行了消融研究，以评估所提出框架中各组成部分的贡献。如表 3 所示，仅使用TDA的模型表现出色，说明拓扑描述符能够有效捕捉全局结构信息。独立的 DenseNet121 模型通过从磁共振成像数据中学习分层空间特征，进一步提升了召回率和曲线下面积。所提出的混合 DenseNet121 + TDA 模型始终优于两种单独配置，在精确率、召回率和准确率方面均达到最高水平，曲线下面积更是达到 100%。这些结果证实，结合拓扑特征与深度卷积特征，能够为四分类阿尔茨海默病分类提供互补且具有高度判别力的表示。

表3：不同模型配置与数据集上的消融研究结果

数据集	模型	精确率	召回率	准确率	AUC
OASIS-1	TDA特征（多层感知机）	98.42	92.80	97.99	99.75
	DenseNet121	98.44	98.35	97.78	99.98
	DenseNet121 + TDA	**99.94**	**99.95**	**99.93**	**100.00**

8 结论

本研究提出了一种新颖的混合框架，将拓扑数据分析（TDA）与 DenseNet121 相结合，利用结构磁共振成像对阿尔茨海默病严重程度进行四分类。该方法将基于持久同调提取的全局拓扑描述符与深度卷积特征表示相结合，从而有效捕捉与阿尔茨海默病进展相关的结构几何特征和局部空间模式。

在 OASIS-1 磁共振成像数据集上的实验评估表明，所提出的 TDA+ DenseNet121 模型达到了最先进的性能，准确率为 99.93%，曲线下面积为 100%。与现有基于卷积神经网络、集成学习和多尺度方法的模型进行比较后发现，融入拓扑感知表示具有明显优势，尤其能够提升类别可分性和稳健性，同时无需过度依赖数据增强或复杂的集成模型。除了出色的定量表现外，所提出的框架在计算效率和可解释性方面也具有实用优势。拓扑特征能够为脑结构提供稳定且有意义的表示，受噪声和受试者间变异性的影响较小，从而支持更可靠且更具临床相关性的预测。这些特性使该方法尤其适用于数据和计算资源可能有限的真实临床场景。

未来的工作将重点在多个独立数据集上验证所提出的框架，研究跨域泛化，并将

具备拓扑感知能力的深度学习范式拓展至纵向分析和多模态神经影像数据。总体而言，本研究证明了将拓扑洞见与深度学习相结合，有助于稳健、准确地进行阿尔茨海默病诊断和严重程度评估。

声明

资助
作者未获得任何用于本研究、论文撰写或发表的资金支持。

作者贡献
Faisal Ahmed 构思了本研究，下载了数据，编写了代码，进行了数据分析并撰写了论文。Faisal Ahmed 审阅并批准了论文的最终版本。

致谢
作者使用在线平台检查并纠正语法错误，以提高句子的可读性。

利益冲突/竞争性利益作者声明不存在利益冲突。

伦理审批和参与知情同意
不适用。本研究未涉及人类参与者或动物，并使用了公开可用数据集。

发表知情同意不适用。

数据可用性
本研究使用的数据集可在网上公开获取。

材料可用性不适用。

代码可用性
本研究使用的源代码可在 GitHub 上公开获取。

参考文献

[1] Jack, C.R., Bernstein, M.A., Fox, N.C., 等：阿尔茨海默病神经影像学计划（ADNI）：磁共振成像方法。磁共振成像杂志 27(4), 685–691 (2008)[2] Mosconi, L.：使用磁共振成像和 FDG-PET 早期检测阿尔茨海默病。Journal of Alzheimer's Disease 8(3), 237–252 (2005)[3]Liu, S., Li, Y., 等：阿尔茨海默病中的深度学习：诊断与预后应用。生物学与医学中的计算机 136, 104709 (2021)[4] Zhang, X., Shen, D.：使用磁共振成像和正电子发射断层扫描进行阿尔茨海默病诊断的多模态深度学习。IEEE医学成像汇刊 40(5), 1445–1456 (2021)[5] Maqsood, M., Nazir, F., Khan, U., Aadil, F., Jamal, H., Mehmood, I., Song, O.- y.：借助迁移学习，利用三维MRI扫描对阿尔茨海默病阶段进行分类和检测。Sensors 19(11), 2645 (2019)[6] Islam, J., Zhang, Y.：利用深度卷积神经网络集成系统进行阿尔茨海默病诊断的脑部MRI分析。脑信息学 5(2), 2 (2018)[7] Adil, M., 等：采用带三元组损失函数的深度孪生卷积神经网络对阿尔茨海默病进行四分类。脑信息学 10, 45 (2023) https://doi.org/10.1186/s40708-023-00184-w[8] Femmam, M., Femmam, S., Fareh, M.E., Senni, O.A., Ferhani, A.：基于深度学习的阿尔茨海默病与痴呆分类和诊断：从基线磁共振成像扫描中进行多尺度特征提取。Journal of Image and Graphics 12(4), 427–436 (2024)[9] Hernandez, M., 等：用于阿尔茨海默病诊断的集成深度学习。生物医学计算机方法与程序 175, 33–42 (2019)[10] Carlsson, G.：拓扑与数据。美国数学会通报 46(2), 255–308 (2009)[11] Edelsbrunner, H., Harer, J., 等：持久同调综述。当代数学 453(26), 257–282 (2008)[12] Ahmed,F.,Nuwagira, B., Torlak, F., Coskunuzer, B.：Topo-CXR：利用拓扑机器学习筛查胸部X光中的结核病和肺炎。载于：IEEE/CVF国际计算机视觉会议论文集，第 2326–2336 页 (2023)[13] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q.：密集连接

卷积网络。《IEEE计算机视觉与模式识别会议论文集》，第 4700–4708 页（2017）[14] Kl¨oppel, S., 等：阿尔茨海默病磁共振扫描的自动分类。《衰老神经生物学》（2008）[15] Zhang, e.a.：基于脑灰质变化，采用基于体素的形态测量和深度学习模型诊断早期阿尔茨海默病。《大脑皮层》（2022）[16] Ebrahimi, A., Luo, S., 疾病神经影像学倡议, f.t.A.：用于通过 MRI 图像检测阿尔茨海默病的卷积神经网络。《医学影像学杂志》**8**(2), 024503–024503（2021）[17] Wang, Q., Li, Y., Zheng, C., Xu, R.：Densecnn：一种基于海马磁共振数据进行阿尔茨海默病分类的密集连接卷积神经网络模型。《美国医学信息学协会年度研讨会论文集》，第 2020 卷，第 1277 页（2021）[18] Fathi, S., Ahmadi, A., Dehnad, A., Almasi-Dooghaee, M., Sadegh, M., Initiative, A.D.N.：一种基于深度学习的集成方法，利用 MRI 图像早期诊断阿尔茨海默病。《神经信息学》**22**(1), 89–105（2024）[19] Bazin, P.-L., Pham, D.L.：脑磁共振图像的保拓扑组织分类。IEEE医学成像汇刊**26**(4), 487–496（2007）[20] Alshamlan, H., Omar, S., Aljurayyad, R., Alabduljabbar, R.：利用机器学习识别适用于阿尔茨海默病生物标志物基因检测的有效特征选择方法。《诊断学》**13**(10), 1771（2023）[21] Alshamlan, H., Alwassel, A., Banafa, A., Alsaleem, L.：利用不同的机器学习方法和特征选择技术改进阿尔茨海默病预测。《诊断学》**14**(19), 2237（2024）[22] Ahmed, F.：通过拓扑特征提取、特征选择和集成学习，基于 MRI 实现阿尔茨海默病四阶段分类。arXiv预印本 arXiv:2601.00918（2026）[23] Ahmed, F., Bhuiyan, M.A.N., Coskunuzer, B.：Topo-CNN：利用拓扑深度学习进行视网膜图像分析。Journal of Imaging Informatics in Medicine, 1–17（2025）[24] Ahmed, F.：医学图像分析中的拓扑机器学习。博士论文，德克萨斯大学达拉斯分校（2023）[25] Ahmed, F., Coskunuzer, B.：Tofi-ML：利用拓扑机器学习进行视网膜图像筛查。载于：医学图像理解年度会议与

分析，第 281–297 页（2023 年）。施普林格

[26] Ahmed, F.：3D-TDA：从三维磁共振成像中提取拓扑特征以进行阿尔茨海默病分类。可见 SSRN 5882122（2025）[27] Yadav, A., Ahmed, F., Daescu, O., Gedik, R., Coskunuzer, B.：利用拓扑签名进行组织病理学癌症检测。载于：2023年IEEE生物信息学与生物医学国际会议（BIBM），第 1610–1619 页（2023）。IEEE[28]Ahmed, F., Bhuiyan, M.A.N.：拓扑签名与梯度直方图：医学图像分类的比较研究。arXiv预印本 arXiv:2507.03006（2025）[29] Dosovitskiy, A., Beyer, L.,等。：一张图像胜过 16×16 个词：用于大规模图像识别的变换器。载于：国际学习表征会议（ICLR）（2021）[30] Liu, Z., Lin, Y., 等。：Swin变换器：采用移位窗口的层次化视觉变换器。载于：IEEE计算机视觉国际会议（ICCV），第 10012–10022 页（2021）[31] Sankari, C., Jamuna, V., Kavitha, A.：用于在基于 MRI 的医学成像中准确检测和分类脑肿瘤的层次化多尺度视觉变换器模型。Scientific Reports 15(1), 38275（2025）[32] Dhinagar, N.J., Thomopoulos, S.I., Laltoo, E., Thompson, P.M.：在结构磁共振扫描上高效训练视觉Transformer以检测阿尔茨海默病。载于：2023年第45届IEEE医学与生物学工程学会国际年会（EMBC），第 1–6 页（2023）。IEEE[33] Ahmed, F.：用于基于 MRI 的多类别（4 类）阿尔茨海默病分类的颜色映射增强视觉变换器。arXiv预印本 arXiv:2512.16964（2025）[34]Ahmed, F.：HOG-CNN：将方向梯度直方图与卷积神经网络相结合，实现视网膜图像分类。arXiv预印本 arXiv:2507.22274（2025）[35] Ahmed, F., Uddin, M.J.：Ocuvit：一种基于视觉变换器的糖尿病视网膜病变和年龄相关性黄斑变性自动分类方法。Journal of Imaging Informatics in Medicine, 1–11（2025）[36] Ahmed, F., Alfrad Nobel Bhuiyan, M.：利用迁移学习和数据增强实现稳健的五分类及二分类糖尿病视网膜病变分类。arXiv电子预印本，2507（2025）

[37] Ahmed, F.：Histovit：用于准确、可扩展组织病理学癌症诊断的视觉Transformer。arXiv预印本 arXiv:2508.11181（2025）[38]Ahmed, F.：通过数据增强和迁移学习解决多类别糖尿病视网膜病变严重程度分级中的类别高度不平衡问题。arXiv预印本 arXiv:2507.17121（2025）[39]Ahmed, F.：Repvit-cxr：用于胸部X光结核病和肺炎分类的视觉Transformer通道复制策略。arXiv预印本 arXiv:2509.08234（2025）[40]Ahmed, F.：Pseudocolorvit-cxr：采用颜色映射增强视觉变换器，从灰度胸部X光图像中检测结核病和肺炎。可见于SSRN 5547319（2025）[41]Rawat, R., Ahmed, F.：通过基于ViT的预处理和迁移学习，实现高效的乳腺癌和卵巢癌分类。arXiv预印本 arXiv:2509.18553（2025）[42] Ahmed, F.：使用EfficientNet进行迁移学习，实现准确的白血病细胞分类。arXiv预印本 arXiv:2508.06535（2025）[43] Marcus, D.S., Wang, T.H., Parker, J., Csernansky, J.G., Morris, J.C., Buckner, R.L.：开放影像研究系列（OASIS）：年轻、中年、非痴呆及痴呆老年人的横断面磁共振成像数据。《认知神经科学杂志》**19**（9），1498–1507（2007）https://doi.org/10.1162/jocn.2007.19.9.1498[44] Goutam, B., Hashmi, M.F., Geem, Z.W., Bokde, N.D.：使用眼底图像进行视网膜疾病诊断的深度学习策略综述。IEEE Access（2022）[45] Dardouri, S.：一种基于磁共振成像图像并使用深度卷积神经网络检测早期阿尔茨海默病的高效方法。《人工智能前沿》**8**，1563016（2025）https://doi.org/10.3389/frai.2025.1563016