

DOI:10.3969/j.issn.1005-202X.2025.09.017

医学人工智能

## 三维深度网络结合迁移学习的房颤患者冠脉CTA术前分类

陈炜<sup>1,2,3,4</sup>, 辛梓睿<sup>1,3,4</sup>, 陈砾<sup>1,4</sup>, 刘振江<sup>1,4</sup>, 罗爱静<sup>1,2,3,4</sup>

1. 中南大学湘雅二医院, 湖南长沙 410011; 2. 中南大学生命科学学院, 湖南长沙 410013; 3. 医学信息研究湖南省普通高等学校重点实验室(中南大学), 湖南长沙 410013; 4. 湖南省心血管智能医疗临床医学研究中心, 湖南长沙 410011

**【摘要】目的:**基于三维深度网络构建房颤患者冠脉CTA术前分类模型,探讨迁移学习技术对医学影像分类模型性能的影响,为导管消融提供术前决策支持,推动房颤治疗向精确化、个性化转变。**方法:**分别以3D ConvNet和3D-ResNet作为骨干网络,提取冠脉CTA序列的三维分类特征;利用公开预训练权重进行迁移学习,并通过混淆矩阵、准确率、AUC等指标评估模型分类效果,对比分析迁移学习模型与初始化训练模型之间的性能差异。**结果:**迁移学习显著改善了模型性能,与初始化训练模型相比,各个迁移学习模型的分类AUC提升9.1%~16.7%,准确率提高6.2%~23.5%,其中结合MedicalNet预训练权重的3D-ResNet18模型表现最佳,AUC达0.77,准确率为0.71。**结论:**结合迁移学习的三维深度网络能通过术前冠脉CTA有效识别需在肺静脉隔离基础上附加额外消融的房颤患者,这将有助于引导临床医生优化手术策略并改善治疗效果,从而降低术后远期复发率。

**【关键词】**心房颤动;冠脉CTA;三维深度网络;迁移学习;导管消融;手术策略

**【中图分类号】**R318;R541.75

**【文献标志码】**A

**【文章编号】**1005-202X(2025)09-1245-10

## Three-dimensional deep neural network integrating transfer learning for preoperative coronary CTA classification in atrial fibrillation patients

CHEN Wei<sup>1,2,3,4</sup>, XIN Zirui<sup>1,3,4</sup>, CHEN Xi<sup>1,4</sup>, LIU Zhenjiang<sup>1,4</sup>, LUO Aijing<sup>1,2,3,4</sup>

1. The Second Xiangya Hospital of Central South University, Changsha 410011, China; 2. School of Life Sciences, Central South University, Changsha 410013, China; 3. Key Laboratory of Medical Information Research in Hunan Province (Central South University), Changsha 410013, China; 4. Clinical Medical Research Center for Cardiovascular Intelligent Medicine in Hunan Province, Changsha 410011, China

**Abstract: Objective** To develop a three-dimensional (3D) deep neural network based preoperative classification model for coronary computed tomography angiography (CTA) in atrial fibrillation patients, and to explore the effects of transfer learning on the performance of medical image classification models, thereby providing preoperative decision support for catheter ablation to advance atrial fibrillation treatment toward precision and personalization. **Methods** Utilizing 3D ConvNet and 3D ResNet as backbone network, the three-dimensional classification features were extracted from coronary CTA sequences. The publicly available pre-trained weights were used for transfer learning. The model performance was evaluated through metrics such as confusion matrix, classification accuracy, and area under the curve (AUC). A comparative analysis was also conducted to evaluate the performance differences between the transfer learning model and the initialized training model. **Results** Transfer learning yielded significant performance improvements over the initialized training models, attaining AUC improvement of 9.1%-16.7% and accuracy enhancement of 6.2%-23.5%. Among all models, 3D-ResNet18 model with MedicalNet pre-training weights performed the best, achieving an AUC of 0.77 and an accuracy of 0.71. **Conclusion** The proposed three-dimensional deep network enhanced by transfer learning can effectively identify atrial fibrillation patients requiring additional ablation besides pulmonary vein isolation through preoperative coronary CTA, which will assist clinicians in optimizing surgical strategies and improving treatment outcomes, thereby reducing long-term postoperative recurrence rates.

**Keywords:** atrial fibrillation; coronary computed tomography angiography; three-dimensional deep neural network; transfer learning; catheter ablation; surgical strategy

**【收稿日期】**2025-02-25

**【基金项目】**湖南省科技厅项目(2024SK4005)

**【作者简介】**陈炜, 硕士研究生, 研究方向: 医学人工智能, E-mail: cg2024@csu.edu.cn

**【通信作者】**罗爱静, 博士, 教授, 博士生导师, 研究方向: 医学信息学, E-mail: luoj@csu.edu.cn

## 前言

心房颤动(简称房颤)是最常见的心律失常类型,其发病率随社会人口老龄化不断上升,对我国公共健康持续构成威胁<sup>[1-2]</sup>。房颤不仅严重影响患者的生活质量,还增加了脑卒中、心衰等严重并发症的患病风险<sup>[3-4]</sup>,进而带来更高的相关死亡率和医疗费用<sup>[5]</sup>。目前治疗房颤最有效的临床手段是以肺静脉电隔离术(Pulmonary Vein Isolation, PVI)为基石的导管消融<sup>[6]</sup>,多数患者在接受PVI治疗后即可恢复窦性心律。然而,单纯PVI的术后远期复发率较高,在3~5年后接近40%<sup>[7-8]</sup>,其中一个重要原因是患者存在未被消融的非肺静脉房颤触发灶<sup>[9]</sup>。为此,医生需在术中通过电生理标测系统,经验性地定位潜在的非肺静脉触发灶或其他合并心律失常病灶,进而在PVI基础上附加额外消融。该过程增加了医生的精力负担,并将显著提高医患双方的术中辐射暴露时长。因此,借助患者术前临床资料、医学影像等无创检查数据来构建精确的人工智能分类模型,对帮助医务人员提早识别需要附加额外消融的房颤患者,并引导其选择恰当的导管消融策略,具有重要意义。

随着深度学习在生物医学研究中得到了与日俱增的青睐,该技术已成为推动房颤诊疗迈向精准化、高效化的有力工具<sup>[10]</sup>,可通过分析复杂多变的数据来识别高危患病个体,揭示与房颤病程发展有关的风险因素或生物标志物,并指导个性化预后干预。然而,受房颤医学影像数据集的稀缺性、疾病复杂性及数据隐私等问题的制约,深度学习模型的训练往往并不充分。引入迁移学习是应对这一问题的潜在可行思路<sup>[11]</sup>,借助已在其他领域大型公共数据集进行足量训练及参数优化的预训练模型,通过特征映射或微调训练的方式将模型已学习到的知识迁移到小型房颤患者数据集中,最终构建面向特定医学任务的模型。

本文旨在基于深度网络和迁移学习技术构建房颤患者分类模型,利用房颤患者的冠状动脉CT血管成像(Coronary Computed Tomography Angiography, CCTA)序列数据为医生提供导管消融术前决策支持,预测房颤患者是否需要在PVI基础上附加额外消融,从而制定精准、个性化的消融手术策略,在提高患者治疗效果的同时促进医疗资源配置优化。

## 1 相关研究现状

单中心私有数据集因样本规模过小,易导致深度学习模型训练不佳或无法泛化,因此常采用迁移学习技术开发AI模型以实现心血管疾病诊断、病灶分割等下游任务。Holste等<sup>[12]</sup>在同样模型结构下通

过内外部验证对比发现,基于Kinetics-400预训练的模型在左心室肥厚分类任务中表现较随机初始化模型性能提升超20%;Yagi等<sup>[13]</sup>通过模型微调,将用于评估左心室射血分数的AI-EF模型迁移开发了AI-CTRCD模型,实现癌症治疗相关心功能障碍的稳健分层;Chen等<sup>[14]</sup>基于小型颈动脉MRI数据集对YOLO V3等多个预训练模型进行训练,识别颈动脉斑块用于中风风险评估,最高准确率达94.81%。

房颤导管消融术的高远期复发率一直困扰着医患双方,针对消融策略本身进行改进将利于从根本上降低复发率。Liu等<sup>[15]</sup>利用肺静脉CT及ResNet34预训练模型预测房颤肺静脉外触发灶,从而为手术提供额外信息支持;Muiznicce等<sup>[16]</sup>结合卷积神经网络和晚期钆增强心脏MRI,提出一种个性化消融策略制定方法,并在后续研究中,先基于心脏MRI创建患者左心房模型,而后利用强化学习Q-Learning算法开发智能体,在制定个性化消融策略的任务中取得71%的测试集成功率<sup>[17]</sup>。

综上所述,迁移学习能有效弥补因医学数据集规模过小导致的深度学习模型性能缺陷,在房颤导管消融策略优化方面,现有研究的结论证明深度学习能够利用患者的影像资料为手术医生提供有价值的决策信息。然而有关研究多聚焦于2D深度学习模型,忽视了医学影像的空间连贯性,无法全面呈现心脏解剖结构和病变特征。因此,本研究结合3D深度神经网络与迁移学习技术,利用房颤患者的CCTA序列数据构建分类模型,探索其在导管消融策略优化上的应用价值,为精准治疗和模型临床应用提供新的思路和参考。

## 2 资料与方法

### 2.1 研究队列与数据选取

回顾性收集2019年至2023年在中南大学湘雅二医院行房颤导管消融术的心血管内科住院患者。纳入标准为:(1)年龄大于18岁;(2)经门/急诊住院,确诊为心房颤动(包括阵发性房颤和持续性房颤);(3)接受房颤导管消融治疗,包括心房颤动射频消融术、冷冻消融术、脉冲消融术、Marshall静脉酒精消融术等;(4)在接受导管消融治疗前行CCTA检查。排除标准为患者CCTA影像有严重伪影或其他因素导致评估受阻。经过上述标准筛选得到房颤导管消融患者259例,其中139例患者仅接受PVI,其余120例患者在PVI的基础上附加复合术式,包括后壁顶部线或顶部加底部线等线性消融,以及上腔静脉、界嵴、Marshall静脉等处的非肺静脉触发灶消融。本研究

已获得中南大学湘雅二医院临床研究伦理委员会审查同意(审批号LYEC2024-0400)。

所有房颤患者均采用西门子 SOMATOM Force 达尔文双源 CT 设备进行 CCTA 检查,检查结果用于导管消融术前评估。本研究选取的 CCTA 成像均来自患者心脏舒张末期对应阶段,该阶段具有最大的左心房容量可供评估。用于构建深度学习数据集的影像切片起止区间为左心房上边界至左心房底部,每个切片间隔 0.75 mm,每例患者具有 80~150 张切片不等,最终获得共 259 例房颤患者的 29 456 张术前 CCTA 切片影像。

## 2.2 数据处理

**2.2.1 影像后处理** 首先对原始空间分辨率为 512×512 的 CCTA 影像进行标准化重建,根据从 DICOM 文件标签中提取的影像缩放截距和斜率完成重缩放,并将影像值标准化为 Hounsfield Units(HU)值。初始 HU 值在十进制无符号整数存储状态下的范围为 0~4 096,超出这一范围的 HU 值分别被 0 和 4 096 替换,以校正 CCTA 扫描或重建期间产生的偶然伪

影。在这一基础上,参考 Liu 等<sup>[15]</sup>调窗策略,将窗口宽度设置为 1 400,将窗口水平设置为 500,以清楚地呈现完整的心脏轮廓。

**2.2.2 数据增强** 为提升模型的泛化能力和鲁棒性,本研究采用仿射变换的方式增加训练样本的数量及多样性。由于患者间心脏大小存在差异,各患者可供分析的影像数量也不同,而 3D 深度网络需确保每个样本在输入时的各维度大小一致,因此需要将各样本的影像序列高度、宽度、深度对齐。首先对各患者的影像切片在原序列中按 2% 的间隔有序抽帧,取 50 张影像切片组成第一部分数据;而后在剩余部分中再次使用同一方法有序获得 50 张影像(若剩余数量小于 50,则通过随机复制将数量补齐),并将影像在水平及垂直两个方向均进行镜像翻转后组成第二部分数据;最后,每例患者的原始序列被拆分成两个各包含 50 张影像的子部分用于模型输入,且子部分之间的影像切片互不重复,可被视为一个独立样本进行训练。本研究所用的数据处理方法如图 1 所示,经数据增强后共得到 518 个深度学习样本。

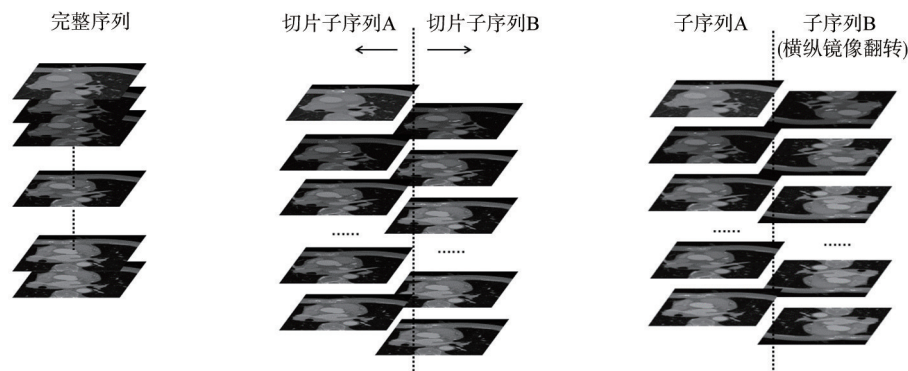


图1 影像样本集数据增强方法

Figure 1 Image dataset augmentation method

## 2.3 三维深度神经网络分类模型构建

**2.3.1 三维卷积网络(3D ConvNets)** 本文构建 3D ConvNets 作为基础模型,提取房颤患者 CCTA 影像序列中的特征并实现导管消融术前分类。相比于传统的二维卷积神经网络(2D-CNN),3D ConvNets 能够在时间和空间维度上捕捉信息,因此在应用于具备时间维度(例如视频)或空间维度(例如医学影像)的数据特征提取上更具优势。与 2D-CNN 不同,3D ConvNets 的输入涵盖一系列连续帧或切片,借助 3D 卷积核在高度、宽度和深度 3 个维度上展开,生成具有空间连贯性的特征表示,各卷积层与 3D 卷积核在通过滑动操作后提取得到特征模块,使模型有效捕捉序列内的深层信息,学习到数据的连贯性与上下

文依赖关系。2D-CNN 和 3D ConvNets 中用于特征提取的卷积核对比如图 2 所示。

为了进一步提升模型性能,本文结合迁移学习技术,使用 Tran 等<sup>[18]</sup>在 ICCV2015 中发布的预训练权重进行训练,该预训练权重提取自大型视频数据集 UCF101(包含从 Youtube 中搜集的 101 个动作类别的 13 320 个短视频),能够为分类模型提供有效的初始参数,从而加速模型收敛,提升模型的泛化能力。本文构建的 3D ConvNets 模型以像素尺寸为 112×112 的 CCTA 图像作为输入,共有 8 个卷积层、5 个最大池化层和 2 个全连接层,最后选择 softmax 函数作为输出层,所有 3D 卷积核的维度大小均为 3×3×3,步幅为 1,架构如图 3 所示。为对抗训练过程中出现的过拟合

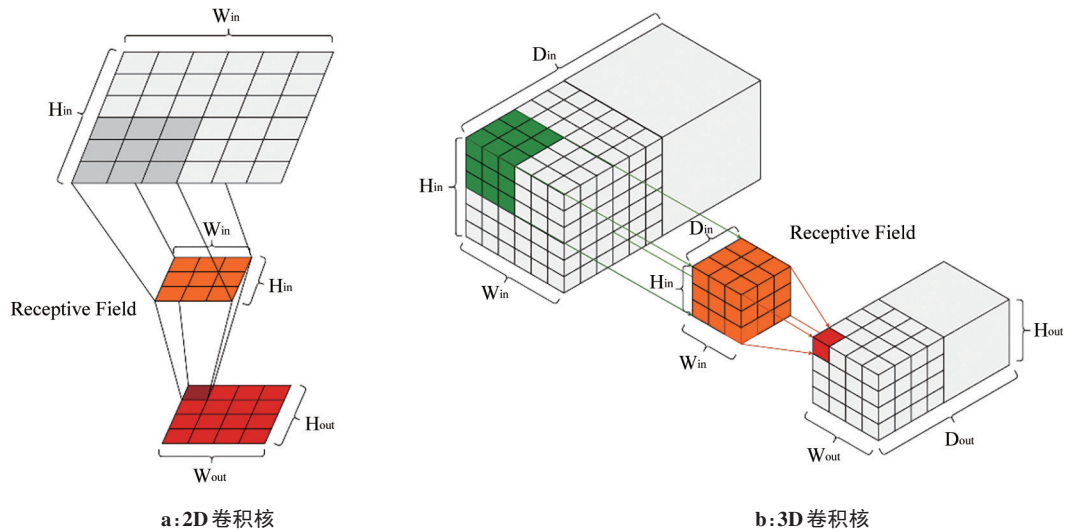


图2 卷积核特征提取对比(2D卷积核作用于单张图像,而3D卷积核作用于多张图像)

Figure 2 Comparison of convolutional kernel feature extraction (2D convolution kernel is applied to a single image, while 3D convolution kernel is applied to multiple images)

现象,在模型的全连接层设置了0.5的Dropout率,即在每次训练中随即丢弃50%的神经元,避免模型过

度依赖某些特定神经元组合,从而增强模型的特征学习能力。

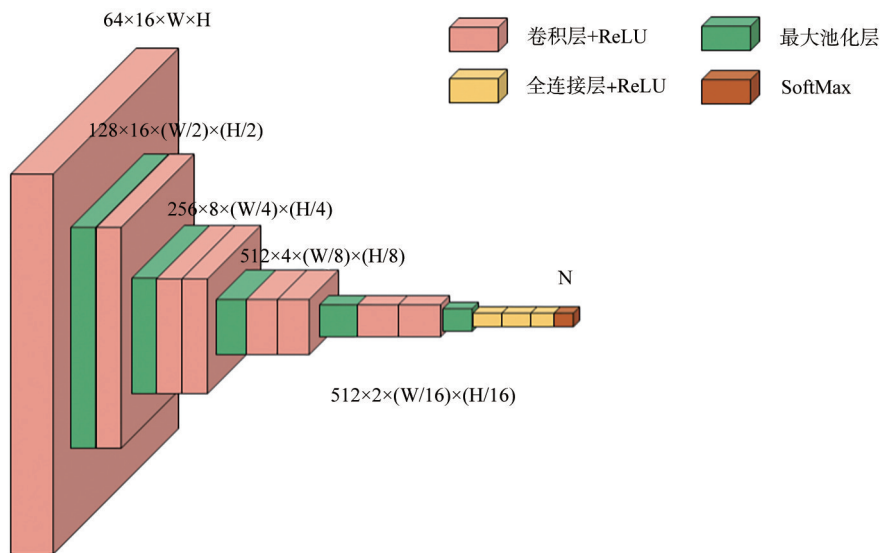


图3 3D ConvNets的模型架构

Figure 3 Model architecture of 3D ConvNets

2.3.2 三维残差卷积神经网络(ResNet) 由He等<sup>[19]</sup>提出的ResNet网络框架在2015年ImageNet大规模视觉识别挑战赛中脱颖而出,被视作计算机视觉领域的一座里程碑,其对比经典CNN架构的最大优势在于利用残差表示(Residual Representations)和批归一化(Batch Normalization)解决网络堆叠过深时出现的梯度消失、梯度爆炸以及模型退化的问题。多项研究已证明,ResNet框架可以扩展至三维结构,其中Chen等<sup>[20]</sup>推出的三维医学成像项目MedicalNet,构

建并提供一系列基于3D-ResNet的医学图像预训练模型。与ResNet的原始版本类似,该项目中提供多个不同深度的3D-ResNet版本。本研究选择MedicalNet中的部分3D-ResNet(包括18、34和50层版本)作为预训练模型进行比较,提取房颤导管消融患者的CCTA影像序列特征并进行术前分类。不同深度版本的ResNet网络结构类似,区别在于每个残差块中包含的卷积层数量。

3D-ResNet18的网络结构如图4所示,其提取关

键特征的过程为:(1)以像素尺寸为256×256的连续影像作为输入,首先通过7×7×7的三维卷积核(步长为2)的卷积操作提取低级特征;(2)低级特征依次通过4个残差块,每个残差块包含4个3×3×3的卷积层,在每个卷积层之后,均使用ReLU(Rectified Linear Unit)作为激活函数。经激活函数处理后,各残差块

输出的特征通道数分别为64、128、256和512。每个残差块利用残差链接机制,有效避免梯度消失和模型退化问题。通过这些层级结构,模型能够逐步捕获从低级到高级的图像特征,从而实现有效的特征表达和模型训练。




图4 3D-ResNet18网络结构(每种颜色代表一个残差卷积块,残差卷积块中又包含多个残差卷积层)

Figure 4 3D-ResNet18 structure (Each color represents a residual convolution block which contains multiple residual convolution layers)

### 2.4 实验设置与模型评估

本研究将接受单纯PVI的房颤患者定义为负样本(共139例,占比53.7%),将其余120例在PVI基础上附加额外消融术式的患者定义为正样本(占比46.3%),据此构建医学二分类深度网络模型。正负样本集均按7:1.5:1.5的比例划分为训练集、验证集和测试集。所有模型的训练、验证和测试流程都在配备了两张NVIDIA RTX A6000显卡、操作系统为Ubuntu20.04的戴尔Precision 7920塔式工作站中进行,模型代码基于Python3.8和Pytorch1.10框架环境运行。经过多次实验对模型的优化器及训练超参数进行调整,最终3D-ResNet模型采用Adam优化器,而3D ConvNet模型则使用SGD优化器,在损失函数方面,所有模型均选择交叉熵损失函数(Cross Entropy Loss)。为对抗深度网络在训练中出现的过拟合现象,结合验证集上的模型表现引入Dropout、L2正则化、学习率衰减等策略,具体参数设置如表1所示。

模型评估方面,使用混淆矩阵直观反映深度网络的二分类性能,混淆矩阵的主对角线上的元素表示模型正确分类的样本数,即真正例(True Positive, TP)和真负例(True Negative, TN),其余的元素表示模型分类错误的样本数,即假正例(False Positive, FP)和假负例(False Negative, FN)。除此之外,本文还引入准确率、灵敏度、特异度、F1分数等指标进一步评估模型性能。准确率代表模型对样本正确分类的整体能力;灵敏度可反映模型对正样本的识别能力,在医学分类模型中,灵敏度越高代表模型更能避免患者漏诊的情况出现;特异度则反映模型对负样本的识别能力,代表模型避免误诊的能力;F1分数综合反映模型精确率和召回率。在混淆矩阵已知的基础上,4个评价指标的计算公式如下所示:

$$\text{Accuracy} = \frac{(\text{TP} + \text{TN})}{(\text{TP} + \text{TN} + \text{FP} + \text{FN})} \tag{1}$$

$$\text{Sensitivity} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \tag{2}$$

$$\text{Specificity} = \frac{\text{TN}}{(\text{TN} + \text{FP})} \tag{3}$$

$$\text{F1 Score} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}} \tag{4}$$

最后,使用受试者工作特征曲线(Receiver Operating Characteristic, ROC)来对比不同模型的分​​类效果。ROC以灵敏度为纵轴、以1-特异度为横轴,直观地反映模型在不同阈值下的整体性能。曲线越接近左上角,表明模型的分​​类效果越佳,对应的量化

表1 模型训练优化超参数设置

Table 1 Model training hyperparameter optimization settings

模型	Dropout率	初始学习率	学习率衰减率及步长	L2正则化系数
3D ConvNet	0.5	5e-6	0.95, step=5	5e-3
3D-ResNet18	未使用	1e-3	0.5, step=5	5e-3
3D-ResNet34	未使用	5e-4	0.5, step=5	5e-3
3D-ResNet50	未使用	1e-3	0.5, step=5	8e-3

指标为曲线下面积(Area Under the Curve, AUC),即AUC值越接近1,代表模型的综合分类性能越好。

### 2.5 统计学方法

采用SPSS 27.0软件对患者基线临床特征数据进行统计分析,符合正态分布的计量资料用均数±标准差表示,采用*t*检验;计数资料以频数及百分率(%)表示,采用 $\chi^2$ 检验。 $P<0.05$ 为差异有统计学意义。

## 3 结果

### 3.1 患者基线临床特征

本研究共纳入259例房颤导管消融患者,其中仅接受PVI的有139例(53.7%),其余120例患者(46.3%)在PVI的基础上附加复合术式。表2总结了患者的基线临床特征。

表2 房颤患者基线临床特征

Table 2 Baseline clinical characteristics of atrial fibrillation patients

特征	复合术式组( <i>n</i> =120)	PVI组( <i>n</i> =139)	<i>t</i> / $\chi^2$ 值	<i>P</i> 值
年龄/岁	59.17±10.13	59.74±10.81	0.439	0.661
性别[例(%)]			4.539	0.033
男	86(71.7)	82(59.0)		
女	34(28.3)	57(41.0)		
高血压[例(%)]	61(50.8)	66(47.5)	0.289	0.591
房颤类型[例(%)]			61.275	<0.001
持续性房颤	80(66.7)	26(18.7)		
阵发性房颤	40(33.3)	113(81.3)		
左室内径/mm	48.45±4.91	48.28±4.40	-0.293	0.770
左房内径/mm	40.80±5.11	37.32±4.88	-5.594	<0.001
右室内径/mm	31.95±3.24	30.85±3.35	-2.677	0.008
右房内径/mm	36.30±5.03	33.22±4.13	-5.242	<0.001
室间隔厚度/mm	9.85±1.35	9.67±1.41	-1.051	0.294
左室后壁厚度/mm	9.60±3.49	9.37±1.92	-0.678	0.498
主动脉内径/mm	32.26±3.72	31.80±3.43	-1.035	0.302
肺动脉内径/mm	23.12±2.15	22.42±2.16	-2.577	0.011
主动脉瓣口流速/cm·s <sup>-1</sup>	113.91±19.34	122.45±22.12	3.274	0.001
肺动脉瓣口流速/cm·s <sup>-1</sup>	80.61±17.22	87.37±17.83	3.082	0.002
左心室射血分数/%	57.84±7.00	60.17±5.54	2.930	0.004
左心室缩短分数/%	30.44±4.60	32.44±6.76	2.735	0.007

### 3.2 初始化训练的三维深度网络模型的房颤导管消融患者分类效果

构建上述几种不同结构的三维深度网络模型,在未使用预训练权重的情况下使用CCTA增强数据集进行初始化训练,并在测试集中评估模型性能。测试结果的混淆矩阵如图5所示,各模型分类表现如表3所示。结果显示,ResNet框架下的各个深度网络的分类性能均优于3D ConvNet,这表明残差连接机制明显提升模型捕捉影像序列切片间连贯特征的能力。而对比不同深度的3D-ResNet模型,发现3D-ResNet50和3D-ResNet18在AUC上表现相当,尽管3D-ResNet50的准确率更高,但图5中混淆矩阵显示其灵敏度和特异度失衡,进而导致F1分数略低于

3D-ResNet18。相比之下,后者的整体性能更加均衡,表现出更优的模型稳定性。

### 3.3 结合迁移学习的三维深度网络模型性能

在本研究中,3D ConvNet模型采用Tran等<sup>[18]</sup>在ICCV2015中发布的C3D模型权重,对于3D-ResNet模型,则采用MedicalNet项目<sup>[20]</sup>中提供的多个权重,这些权重由模型在具有不同模式、靶器官和病理的医学图像数据集3D Seg-8上训练产生。然后,使用房颤患者术前CCTA影像序列数据对这些预训练模型进行迁移学习,表4列出了经过迁移学习后各模型性能表现,图6显示了测试集中各个模型分类结果的混淆矩阵。表4中各项评估指标显示,结合MedicalNet预训练权重进行迁移训练的3D-ResNet18取得最




图5 初始化训练的各三维深度网络测试结果混淆矩阵

Figure 5 Confusion matrices of the test results of 3D deep neural network models after initialized training

表3 初始化训练的各三维深度网络模型分类效果

Table 3 Classification performance of 3D deep neural network models after initialized training

模型	AUC	准确率	灵敏度	特异度	F1分数
3D ConvNet	0.53	0.51	0.31	0.68	0.36
3D-ResNet18	0.66	0.61	0.64	0.59	0.60
3D-ResNet34	0.55	0.55	0.53	0.57	0.51
3D-ResNet50	0.66	0.65	0.53	0.75	0.58

表4 结合迁移学习的各三维深度网络模型分类效果

Table 4 Classification performance of 3D deep neural network model integrating transfer learning

模型	AUC	准确率	灵敏度	特异度	F1分数
3D ConvNet	0.61	0.63	0.67	0.59	0.62
3D-ResNet18	0.77	0.71	0.69	0.73	0.68
3D-ResNet34	0.62	0.59	0.61	0.57	0.57
3D-ResNet50	0.72	0.69	0.69	0.68	0.67

优的分类性能, AUC为0.77, 准确率为0.71; 其次是3D-ResNet50, AUC为0.72, 准确率为0.69。从混淆矩阵来看, 相比于初始化训练模型, 迁移学习模型在主对角线元素与非对角线元素(即假阳性FP和假阴性FN)之间展现出了更明显的区分度, 分类性能更好。

### 3.4 三维深度网络初始化训练与迁移学习测试结果对比

图7和图8分别显示所有模型在房颤患者导管消融术前CCTA影像上的分类测试AUC和准确率, 直观对比了预训练权重迁移学习和初始化训练的

性能差异。结果表明, 采用预训练权重进行迁移学习的三维深度网络模型在房颤患者CCTA影像序列中的分类性能显著更优, 对比初始化训练模型, AUC提高9.1%~16.7%, 准确率提高6.2%~23.5%。在所有模型中, 3D-ResNet18的测试AUC和准确率均为最优, 随着残差卷积层数的加深, 尽管模型分类性能并未显著提升, 但从AUC来看, 3D-ResNet34和3D-ResNet50仍优于结构相对简单的3D ConvNet模型。

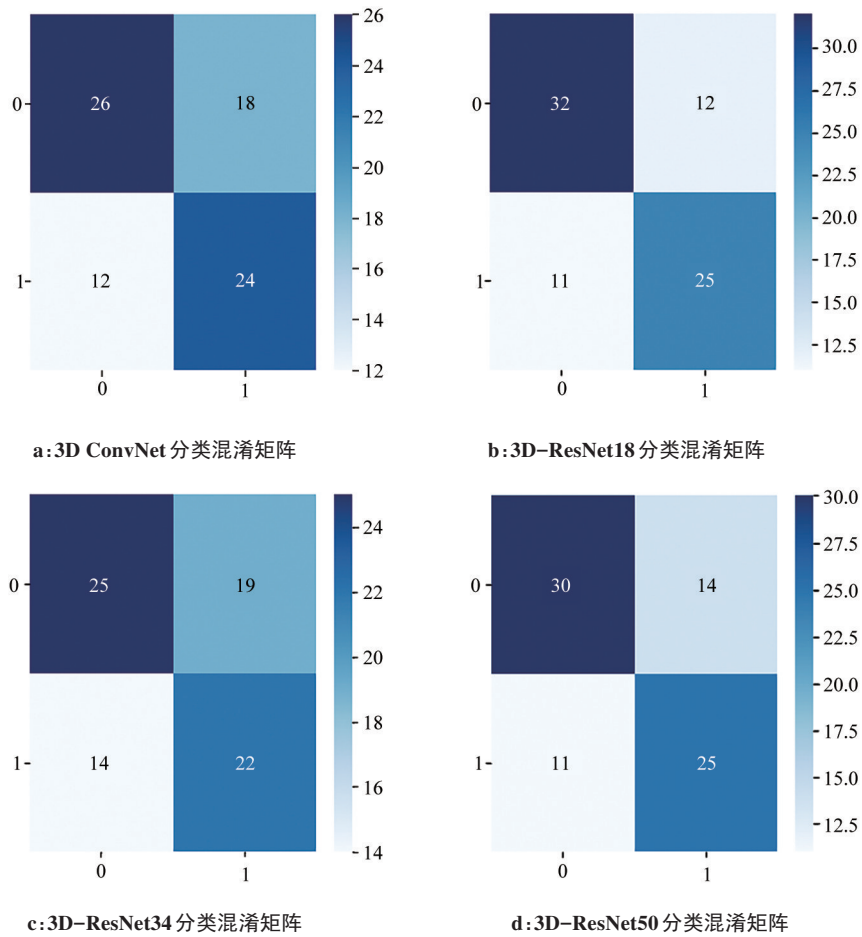


图6 结合迁移学习的三维深度网络测试结果混淆矩阵

Figure 6 Confusion matrices of the test results of 3D deep neural network models integrating transfer learning

### 4 讨论

本研究基于 3D ConvNet 和 3D ResNet 两种三维深度网络框架,构建房颤患者的 CCTA 分类模型,可用于优化房颤导管消融手术策略,在术前向手术医生提供决策支持。研究表明,结合迁移学习技术的 3D-ResNet18 模型在分类任务中表现最优,能够通过 CCTA 有效区分出需要在 PVI 基础上附加额外消融术式的房颤患者,这将为临床电生理学家提供术前患者分流及术中策略优化的重要依据,促使个性化和精细化的房颤导管消融成为可能。长期以来,房颤导管消融治疗建立在 PVI 这一基础术式上,尽管 PVI 在很大程度上有效实现房颤患者的节律控制,但其术后远期复发率高仍是医患双方需要面临的重大问题<sup>[21-22]</sup>。导致该问题的一个重要原因是消融策略不精细、治疗不彻底,未对肺静脉以外的心律失常触发灶或其驱动机制实施消融<sup>[9]</sup>。为解决这一问题,Liu 等<sup>[15]</sup>尝试使用患者肺静脉 CT 图像,构建针对非肺静脉房颤触发灶的二维深度学习预测模型。在心脏结构方面,已有研究发现,相比于无房颤对照

组,肺静脉外触发的房颤患者在上肺静脉口处存在显著扩张<sup>[23]</sup>。而 Allamsetty 等<sup>[24]</sup>研究发现,房颤患者左心房前壁的压缩或拉伸与主动脉侵袭区域的非肺静脉触发有关。这些研究揭示心脏结构与房颤触发灶的分布存在一定关联。与以往类似研究不同,本文构建的深度网络模型从患者连续的 CCTA 序列中提取三维特征,而非将影像视作独立的二维图像样本进行处理,因此模型得以捕捉到医学影像数据中的空间连贯性和上下文依赖关系,这对于模型理解蕴含在房颤患者心脏结构内的深层信息尤为重要。

此外,本研究的另一项重要工作是探讨迁移学习技术对深度网络模型带来的性能改变。在对比实验中,尽管 3D ConvNet 使用的预训练权重产生自医学领域以外的数据集<sup>[18]</sup>,模型在小规模样本集中的训练结果仍然得到有效改善,这与 Holste 等<sup>[12]</sup>在使用迁移学习的左心室肥厚分类任务内外部验证结论相似。同时发现,使用大型医学数据集进行预训练的 3D-ResNet 架构迁移到房颤患者 CCTA 分类任务中保持了较高性能,对比初始化训练模型的 AUC 最高提

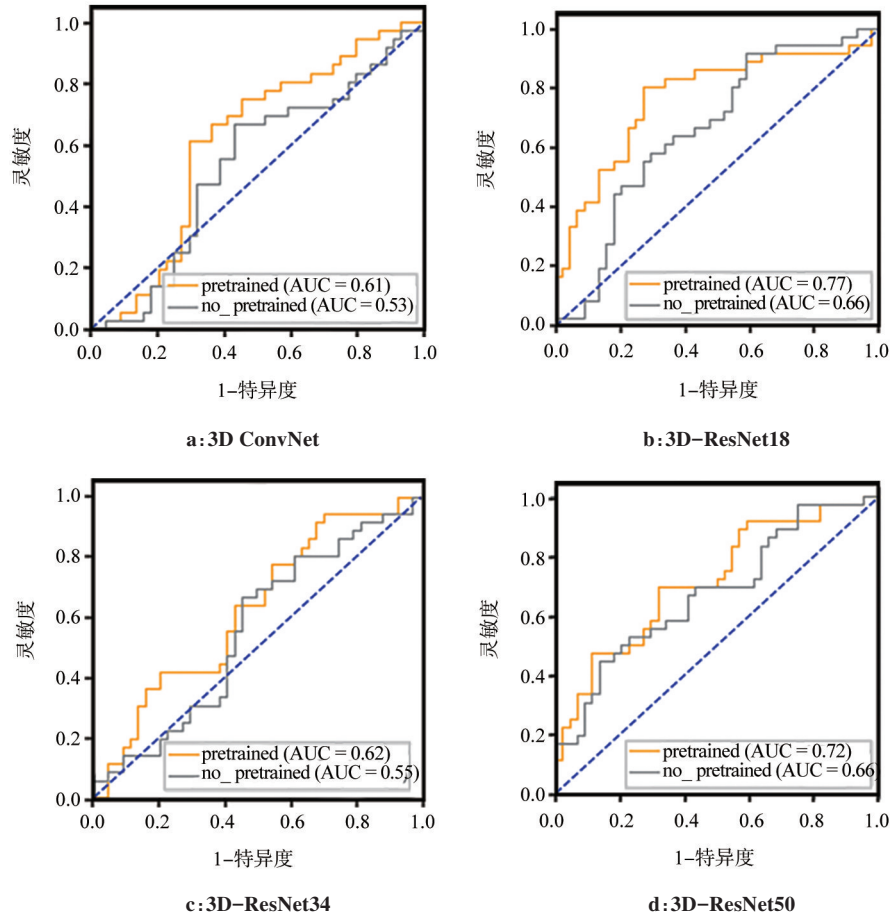


图7 三维深度学习网络在房颤患者 CCTA 的分类 ROC 曲线(灰色为初始化训练模型,黄色为迁移学习模型)

Figure 7 ROC curve of 3D deep neural network classification for CCTA in atrial fibrillation patients (with gray indicating the initialized training model and yellow indicating the transfer learning model)

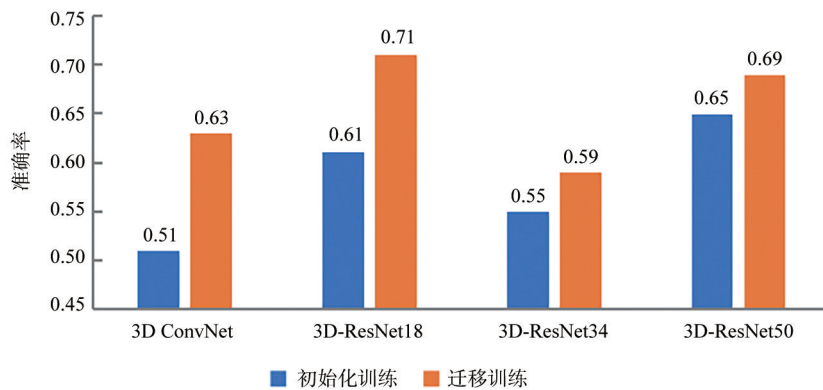


图8 三维深度学习网络模型在房颤患者导管消融术前 CCTA 影像上的分类测试准确率

Figure 8 Classification accuracies of 3D deep neural network model on CCTA images of atrial fibrillation patients before catheter ablation

升 16.7%<sup>[20]</sup>。这反映了数据对于模型训练效果的重要影响,MedicalNet 预训练使用的大型数据集与本研究数据集相近,均为人体生理结构与器官轮廓的相关内容,使得预训练权重中包含的特征信息可以更好地迁移至房颤患者的 CCTA 分类任务,帮助模型快速捕捉关键特征,提升分类性能<sup>[25]</sup>。但在数据规模

和训练超参数不变的情况下,3D-ResNet 模型的深度堆叠并未优化其分类效果,反而更容易出现过拟合导致性能减弱。

本研究的一个潜在局限性是未充分考虑患者队列的随访结果,虽然在队列纳入标准中定义了以患者是否仅行 PVI 作为分类标签,但不排除可能存在极

少部分应附加额外消融术式的患者在仅接受PVI后终止消融治疗。此外,本研究侧重于验证三维深度网络模型在房颤患者CCTA分类的方法学可行性研究,未对模型的可解释性深入探讨,因此未来还将在模型决策过程可视化、临床解释等方面做进一步研究。

## 5 结论

三维深度网络模型可以借助房颤患者的术前冠状动脉CT血管成像有效区分患者是否需要在肺静脉隔离的基础上附加额外术式,该模型的应用将有助于优化导管消融策略,改善患者治疗效果并降低术后远期复发率。通过实验对比发现,具有残差表示的3D-ResNet模型在分类性能上明显优于一般的三维卷积网络,尤其在结合预训练权重进行迁移学习后,模型的表现得到进一步提升。本文将为利用深度学习优化房颤导管消融策略提供重要的实践参考。

## 【参考文献】

[1] 中国心血管健康与疾病报告编写组. 中国心血管健康与疾病报告2022概要[J]. 中国循环杂志, 2023, 38(6): 583-612.  
The Writing Committee of the Report on Cardiovascular Health and Diseases in China. Report on cardiovascular health and diseases in China 2022: an updated summary[J]. Chinese Circulation Journal, 2023, 38(6): 583-612.

[2] Shi SB, Tang YH, Zhao QY, et al. Prevalence and risk of atrial fibrillation in China: a national cross-sectional epidemiological study [J]. Lancet Reg Health West Pac, 2022, 23: 100439.

[3] Elliott AD, Middeldorp ME, Van Gelder IC, et al. Epidemiology and modifiable risk factors for atrial fibrillation[J]. Nat Rev Cardiol, 2023, 20(6): 404-417.

[4] Pabel S, Knierim M, Stehle T, et al. Effects of atrial fibrillation on the human ventricle[J]. Circ Res, 2022, 130(7): 994-1010.

[5] Burdett P, Lip GY. Atrial fibrillation in the UK: predicting costs of an emerging epidemic recognizing and forecasting the cost drivers of atrial fibrillation-related costs [J]. Eur Heart J Qual Care Clin Outcomes, 2022, 8(2): 187-194.

[6] 中华医学会心血管病学分会, 中国生物医学工程学会心律分会. 心房颤动诊断和治疗中国指南[J]. 中华心血管病杂志, 2023, 51(6): 572-618.  
Chinese Society of Cardiology, Chinese Medical Association, Heart Rhythm Committee of Chinese Society of Biomedical Engineering. Chinese guidelines on diagnosis and management of atrial fibrillation [J]. Chinese Journal of Cardiology, 2023, 51(6): 572-618.

[7] Ouyang FF, Tilz R, Chun JL, et al. Long-term results of catheter ablation in paroxysmal atrial fibrillation: lessons from a 5-year follow-up[J]. Circulation, 2010, 122(23): 2368-2377.

[8] Gaita F, Caponi D, Scaglione M, et al. Long-term clinical results of 2 different ablation strategies in patients with paroxysmal and persistent atrial fibrillation [J]. Circ Arrhythm Electrophysiol, 2008, 1(4): 269-275.

[9] 中华医学会心电生理和起搏分会, 中国医师协会心律学专业委员会,

会, 中国房颤中心联盟心房颤动防治专家工作委员会. 心房颤动: 目前的认识和治疗建议(2021)[J]. 中华心律失常学杂志, 2022, 26(1): 15-88.

Chinese Society of Pacing and Electrophysiology, Chinese Society of Arrhythmias, Atrial Fibrillation Center Union of China. Current knowledge and management of atrial fibrillation: consensus of Chinese experts 2021 [J]. Chinese Journal of Cardiac Arrhythmias, 2022, 26(1): 15-88.

[10] 朱晓庆, 陈韬, 沈娟, 等. 心房颤动预测: 从传统回归模型分析到人工智能模型[J]. 中国循环杂志, 2023, 38(12): 1305-1310.  
Zhu XQ, Chen T, Shen J, et al. Prediction of atrial fibrillation: from traditional regression analysis towards artificial intelligence [J]. Chinese Circulation Journal, 2023, 38(12): 1305-1310.

[11] 黎英, 宋佩华. 迁移学习在医学图像分类中的研究进展[J]. 中国图象图形学报, 2022, 27(3): 672-686.  
Li Y, Song PH. Review of transfer learning in medical image classification [J]. Journal of Image and Graphics, 2022, 27(3): 672-686.

[12] Holste G, Oikonomou EK, Mortazavi BJ, et al. Efficient deep learning-based automated diagnosis from echocardiography with contrastive self-supervised learning [J]. Commun Med (London), 2024, 4(1): 133.

[13] Yagi R, Goto S, Himeno Y, et al. Artificial intelligence-enabled prediction of chemotherapy-induced cardiotoxicity from baseline electrocardiograms [J]. Nat Commun, 2024, 15(1): 2536.

[14] Chen YF, Chen ZJ, Lin YY, et al. Stroke risk study based on deep learning-based magnetic resonance imaging carotid plaque automatic segmentation algorithm [J]. Front Cardiovasc Med, 2023, 10: 1101765.

[15] Liu CM, Chang SL, Chen HH, et al. The clinical application of the deep learning technique for predicting trigger origins in patients with paroxysmal atrial fibrillation with catheter ablation [J]. Circ Arrhythm Electrophysiol, 2020, 13(11): e008518.

[16] Muizniece L, Bertagnoli A, Qureshi A, et al. Reinforcement learning to improve image-guidance of ablation therapy for atrial fibrillation [J]. Front Physiol, 2021, 12: 733139.

[17] Muffoletto M, Qureshi A, Zeidan A, et al. Toward patient-specific prediction of ablation strategies for atrial fibrillation using deep learning [J]. Front Physiol, 2021, 12: 674106.

[18] Tran D, Bourdev L, Fergus R, et al. Learning spatiotemporal features with 3D convolutional networks [C]//2015 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2015: 4489-4497.

[19] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 770-778.

[20] Chen SH, Ma K, Zheng YF. Med3D: transfer learning for 3D medical image analysis [EB/OL]. (2019-07-17). <https://arxiv.org/abs/1904.00625>.

[21] Crowley R, Chieng D, Sugumar H, et al. Catheter ablation for persistent atrial fibrillation: patterns of recurrence and impact on quality of life and health care utilization [J]. Eur Heart J, 2024, 45(29): 2604-2616.

[22] Tang SY, Razeghi O, Kapoor R, et al. Machine learning-enabled multimodal fusion of intra-atrial and body surface signals in prediction of atrial fibrillation ablation outcomes [J]. Circ Arrhythm Electrophysiol, 2022, 15(8): e010850.

[23] Lin WS, Prakash VS, Tai CT, et al. Pulmonary vein morphology in patients with paroxysmal atrial fibrillation initiated by ectopic beats originating from the pulmonary veins: implications for catheter ablation [J]. Circulation, 2000, 101(11): 1274-1281.

[24] Allamsetty S, Lo LW, Lin YJ, et al. Impact of aortic encroachment to left atrium on non-pulmonary vein triggers of atrial fibrillation [J]. Int J Cardiol, 2017, 227: 650-655.

[25] Iman M, Arabnia HR, Rasheed K. A review of deep transfer learning and recent advancements [J]. Technologies, 2023, 11(2): 40.

(编辑:陈丽霞)