

EchoGPK:基于先验知识引导的超声心动图轻量级图卷积分析方法

王博荣^{1,2}, 叶剑^{1,3*}

(1. 中国科学院计算技术研究所, 北京 100190; 2. 中国科学院大学, 北京 101408;
3. 移动计算与新型终端北京市重点实验室, 北京 100190)

摘要: 根据超声心动图准确分析左心室轮廓和射血分数对于心血管疾病诊断意义重大. 但现有方法存在左心室分割和射血分数预测之间缺乏关联性、左心室分割关键点易于出现离群点和突变点、方法存储和计算开销大、解释性不佳等问题, 为此提出一种基于先验知识引导的轻量级图卷积方法 EchoGPK (Echo Guided by Prior Knowledge), 以心脏的结构和运动特性、相邻心肌的相似性等先验知识为引导, 设计了计算高效的螺旋聚合函数和深度压缩的多头偏心聚合解码器, 实现了图卷积结构的轻量化. 方法基于临床医生的普遍经验提出了适度利用左心室轮廓的多任务射血分数预测网络, 建立了左心室分割和射血分数预测之间的关联性, 增强了推理的可解释性; 基于图卷积神经网络的传递特性约束邻居点的行为, 减少了边界离群点和突变点的产生. EchoGPK 在大型公开数据集 EchoNet-Dynamic 上的实验结果表明, 左心室分割的 Dice 分数达 92.13%, 射血分数预测的 MAE 达 3.92%; 方法表现出准确率高、参数量和算力需求低等特点, 证明了先验知识在超声医学图像分析中的有效性.

关键词: 关键超声心动图; 左心室分割; 射血分数预测; 图卷积神经网络

基金项目: 国家自然科学基金 (No.82374299); 国家重点研发计划 (No.2022YFB3904700)

中图分类号: TP391.41

文献标识码: A

文章编号: 0372-2112(2024)04-1296-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20231065

EchoGPK: A Lightweight Graph Convolutional Analysis Method for Echocardiography Based on Prior Knowledge Guidance

WANG Bo-rong^{1,2}, YE Jian^{1,3*}

(1. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China;

2. University of Chinese Academy of Sciences, Beijing 101408, China;

3. Beijing Key Laboratory of Mobile Computing and Pervasive Device, Beijing 100190, China)

Abstract: Accurate analysis of the left ventricular outline and ejection fraction through echocardiography holds significant diagnostic implications in cardiovascular diseases. However, current methodologies exhibit deficiencies such as a lack of correlation between left ventricular segmentation and ejection fraction prediction, susceptibility to outliers and abrupt variations in key points of left ventricular segmentation, substantial storage and computational overhead, and poor interpretability. In addressing these issues, this study proposes a lightweight graph convolutional method termed EchoGPK (Echo Guided by Prior Knowledge). Guided by prior knowledge encompassing cardiac structure, motion characteristics, and the similarity among adjacent myocardial regions, the approach incorporates a computationally efficient spiral aggregation function and a deeply compressed multi-head eccentric aggregation decoder, achieving the lightweighting of the graph convolutional structure. Leveraging the common experiences of clinical practitioners, the method introduces a multi task ejection fraction prediction network that moderately utilizes left ventricular contours, establishing a correlation between left ventricular segmentation and ejection fraction prediction to enhance interpretability. By employing the graph convolutional neural network transmission characteristics to constrain the behavior of neighboring points, the generation of boundary outliers and abrupt variations is reduced. Experimental results on the large-scale public dataset EchoNet-Dynamic demonstrate

that EchoGPK achieves a Dice score of 92.13% for left ventricular segmentation and a mean absolute error (MAE) of 3.92% for ejection fraction prediction. Furthermore, the method exhibits higher accuracy, superior parameter count and computational efficiency compared to relevant approaches, affirming the effectiveness of prior knowledge in ultrasound medical image analysis.

Key words: echocardiography; left ventricular segmentation; ejection fractions prediction; graph convolutional neural network

Foundation Item(s): National Natural Science Foundation of China (No.82374299); National Key Research and Development Program of China (No.2022YFB3904700)

1 引言

左心室分割和射血分数预测是现代超声心动图分析中的核心任务^[1]。射血分数是诊断心力衰竭的关键指标,左心室边界既可以用于估算射血分数,也可用于缩短检测和应变分析等其他下游任务。开发对应的自动化工具将有助于超声诊断的客观化和智能化^[2],提升医生的工作效率。

基于卷积神经网络(Convolutional Neural Network, CNN)和Transformer的变种方法是当前超声心动图分析领域的主流思路,Ronneberger等^[3]提出的U-Net利用长距离的跳跃连接来弥补下采样的信息损失,启发了众多后续工作探索深浅层特征融合方法。Isensee等^[4]提出的nnU-net引入了大量预处理方法,拓宽了U-Net的适用范围,证明了数据预处理对方法性能的重要影响。Ouyang等^[5]提出的视频级框架EchoNet充分评估多个心跳周期,实现了专家级的分割和预测精度,为后续超声心动图研究奠定了基础。Rand等^[6]将CNN和ViTs(Vision Transformers)结合起来,有效平衡了全局视野和局部视野,实现了无需位置帧标注和分割掩码通道的高精度射血分数预测方法EchoCoTr。Zhang等^[7]将CNN和Transformer作为两个并行分支,在保留低层次细节的基础上,提高了全局上下文建模的效率,实现了二、三维通用的医学影像分割方法TransFuse。

此外,研究者还试图从预处理和后处理入手提升算法性能。薛武峰等^[8]利用光流网络提取心脏运动信息,用于指导和改进左心室分割的结果,使得方法具有更好的解释性。刘晓鸣等^[9]使用3D全连接条件随机场来对全卷积神经网络输出的概率图做后处理,通过像素级的密度预测和3D心室重建来精准地预测射血分数。

近年来,基于图卷积的关键点回归方法逐步受到关注,Sarina等^[1]首次将螺旋卷积引入到了超声心动图的左心室分割任务中,利用螺旋卷积^[10]来建模左心室的形状特征,为方法的轻量化和解释性提供了新的思路。

但是,基于CNN和Transformer方法通常具有复杂

的推理网络,对参数量和算力的需求相对较高;依赖于预处理和后处理的方法需要手工设计特征,方法的准确率和泛化性往往低于深度学习方法;基于关键点坐标回归的分割方法则容易产生突变点或离群点。此外,大部分方法倾向于直接从图片中回归式地生成射血分数预测值,忽视了左心室分割与射血分数预测之间的关联性,加剧了网络的黑盒性质。

针对这些问题,本文提出了一种以先验知识为引导的兼顾轻量、准确和解释性的超声心动图分析方法EchoGPK(Echo Guided by Prior Knowledge),方法使用图卷积神经网络(Graph Convolutional Neural Network, GCNN)以提升对非欧几里得结构的适应性^[11],提出了多种图卷积结构以建模有关心脏的先验特性,以帮助网络以更小的代价学习到更好的表达。方法在大型公开数据集EchoNet-Dynamic上进行实验。实验表明,与其他方法相比,EchoGPK具有更高的分割和预测精度、更少的参数量需求和更快的推理速度。EchoGPK使用简单的网络结构达成了先进性能,证明了先验知识对超声医学图像分析任务的重要性,同时也说明图卷积神经网络在超声医学图像分析领域中所具有的潜力。

2 本文方法

本文的EchoGPK方法围绕先验知识展开建模,共包含三个部分:特征编码器、多头偏心聚合解码器、带辅助任务的射血分数预测器。方法的整体结构如图1所示。其中,螺旋聚合函数利用自身的排序敏感性来建模左心室的螺旋形状先验,同时捕捉心肌的邻近相似性;偏心聚合扩大低层感受野,缓解过平滑问题;多头解码结构利用偏心率的组合来拟合正态状的心肌牵引力分布。这些先验建模为网络提供了学习的方向和捷径,帮助模型以更轻的结构实现更好的性能。同时,方法参考医生的临床经验,将左心室分割分支作为射血分数预测任务中的辅助分支,通过共同学习和反向传播来引导网络关注轮廓特征,避免了过度依赖问题,提高了射血分数预测的精度。

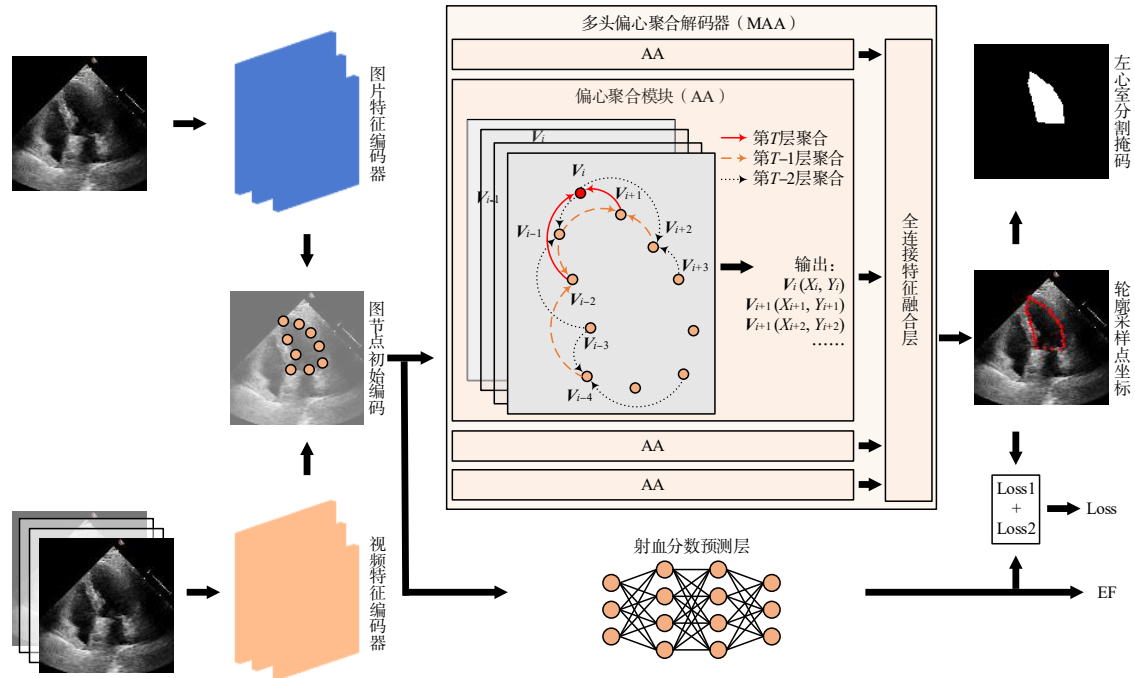


图1 EchoGPK整体结构图

2.1 特征编码器

特征编码器的职责是从图片中抽取高级的语义特征,并将其分配给各个图节点以完成节点特征表示的初始化.经典的CNN网络都可以作为特征编码器,本文选择的网络基于对速度和准确性的权衡,需要能输出足够长度的特征向量以供分配,并且在性能上尽量强大和高效,除此之外并没有其他的限制.

EchoGPK采用模块化设计,因此可以根据使用需求轻易地替换不同的编码器.第3节中的实验证明,EchoGPK能够适应多种^[12-14]复杂度的编码器,且相比于其他同复杂度的方法,EchoGPK都能取得领先的性能.

2.2 多头偏心聚合解码器

2.2.1 螺旋聚合函数

对于心脏而言,邻近的轮廓点通常被同一块心肌平滑相连,因而具有形态、位置和运动上的天然相似性,图卷积神经网络可以利用自身邻域聚合的结构特性,为解码器显式地建模这种邻近相似性先验.首先定义一张无向图 $G=(V, E)$,其中,图顶点 $V=\{v_i|i=1, \dots, N\}$ 代表左心室轮廓上的采样点,边 $E=\{e_i|i=1, \dots, N\}$ 代表相邻两个图顶点之间的轮廓线,则当采样点数量足够多时, G 可以看作是左心室实际轮廓的充分拟合.基于图 G ,本文使用编码器分配图节点的初始特征,利用式(1)所示的螺旋聚合函数对图节点进行8层聚合解码,从而得到高级特征表示.

$$h_i^k = \sigma(W^k \parallel_{j \in S(i, \text{len}(\delta(i, n)))} h_j^{k-1}) \quad (1)$$

其中, h_i^k 代表第 k 层中 i 号节点的特征向量; W^k 表示第 k 层的权重矩阵; σ 则表示激活函数; $\delta(i, n)$ 表示距离图节点 v_i 不超过 n 跳的邻域点集合,其中 $n=1$ 为超参数;“ \parallel ”表示串联操作; $S(i, l)$ 表示以图节点 v_i 为中心、以逆时针为螺旋方向、长度为 l 的螺旋序列^[10].螺旋序列的作用是将邻域范围内的图节点序列化,并为类似左心室这样的结构添加螺旋状的归纳偏置^[1].

2.2.2 偏心聚合

图卷积神经网络不仅为网络带来了有力的先验建模,同时也带来了过平滑问题.为克服过平滑现象,本文重新将与图顶点 v_i 相距为 n 的邻域集定义为如下形式:

$$f(v_i, 0) = \{i\} \quad (2)$$

$$f(v_i, n) = ((f(v_i, n-1) + N + \alpha) \% N) \cup (f(v_i, n-1) + N - \beta) \% N) \quad (3)$$

$$F(v_i, n) = \{v_j | j \in f(v_i, n)\} \quad (4)$$

其中, $F(v_i, n)$ 表示距离等于 n 的领域顶点集合; N 表示图顶点的最大编号; $\alpha=1$ 和 $\beta=2$ 是可以调节的偏心率超参数.基于以上定义,邻域聚合过程如图2所示,聚合中心点 v_i 的两侧被引入大小不等的空隙,使得聚合中心可以在更低层的网络中取得更多的邻域信息,从而有效地压缩网络的深度,缓解过平滑现象.需要注意, α 和 β 不能相等,否则聚合时 v_i 可能永远只能看见无向环形图的一个下采样子图.由于 $\alpha \neq \beta$ 时, v_i 两侧的聚合速率不再相等,故本文称其为“偏心聚合(Acentric Aggregation)”.

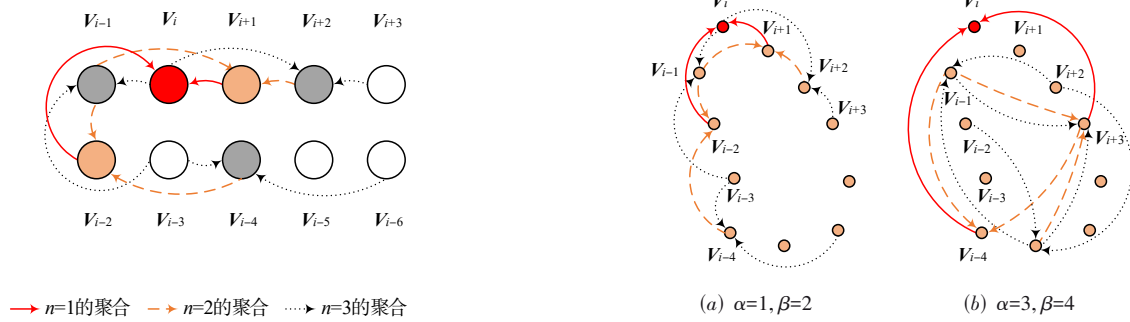


图2 $\alpha=1, \beta=2$ 时, v_i 的邻域聚合过程

2.2.3 偏心聚合的多头扩展

心脏的形态性状在不同个体之间具有较大的差异性,为获得更强的适应性,本文提出可以从多个角度进行解码的多头解码机制.多头偏心聚合解码器由图3中所示的4种不同偏心率的偏心聚合解码器组成,各个聚合模块关注不同的聚合重点,以便适应不同的心脏性状.最终预测结果由各聚合加权融合得出.

4种偏心聚合结构的偏心率分别设置成 $\alpha=(1, 2, 3, 4), \beta=(2, 1, 4, 3)$.这种偏心率设计能够使各个子结构互相弥补感受野不足以及节点对聚合中心的影响力违背先验分布的问题(如图4(a)~(d)所示),最终使得多头聚合结构的总感受野覆盖全图,且聚合范围内全部图节点参与聚合传播的次数基本符合正态分布(如图

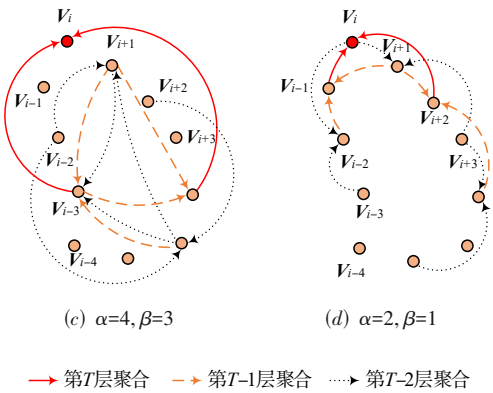


图3 四种偏心聚合结构示意图

4(e)所示),此时图节点对聚合中心的影响力与节点间距离呈负相关,与心肌的运动牵引规律相符.

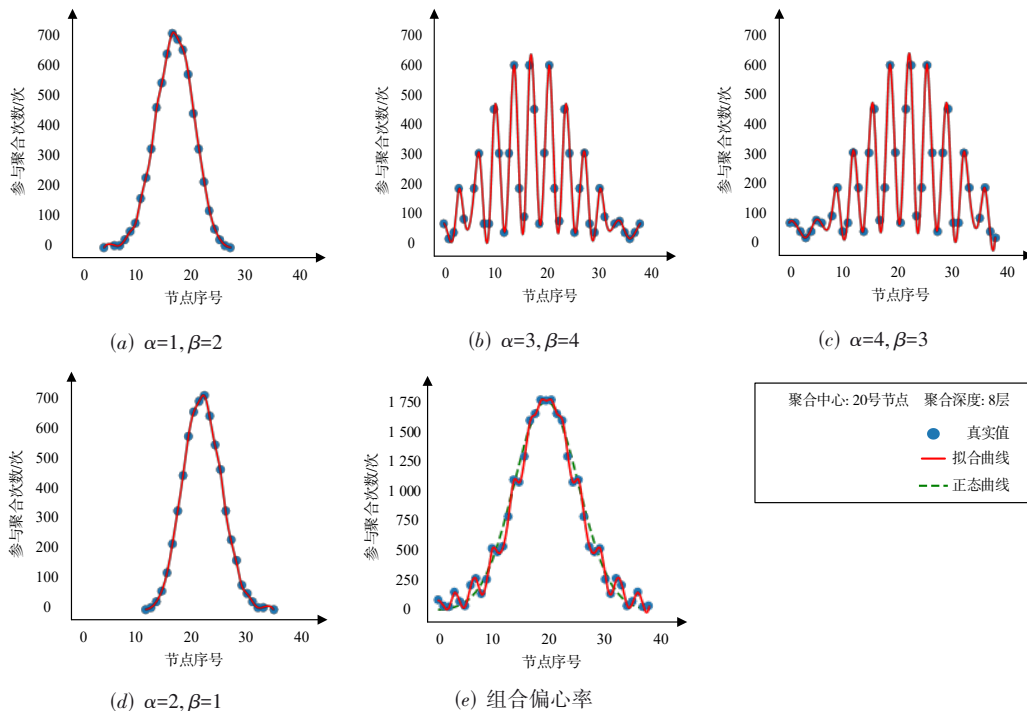


图4 偏心组合后的节点聚合次数分布

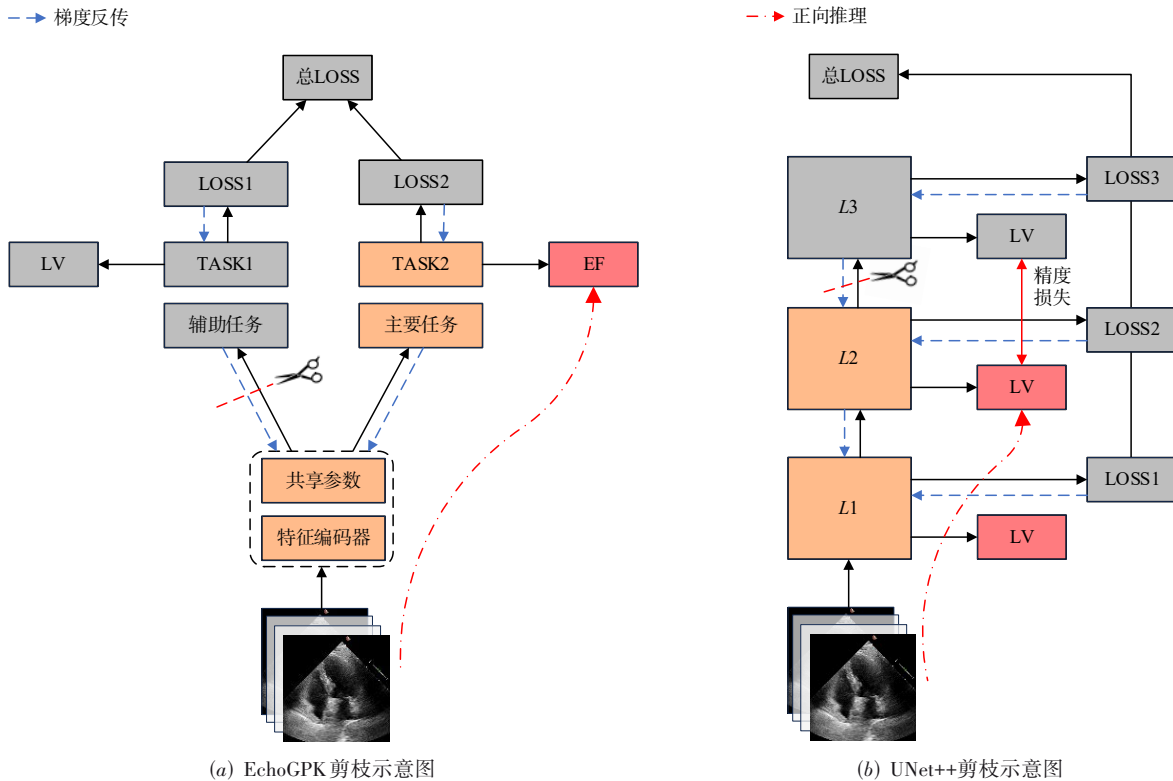
2.3 带辅助任务的射血分数预测器

在临床诊断过程中,人类专家通常先勾勒左心室轮廓,而后使用辛普森双平面法估算出左心室的收缩末期容积和舒张末期容积,最后计算得出射血分数.根据这一临床经验,可知左心室轮廓中应该包含对射血分数预测有益的信息,但许多工作^[5,15,16]更倾向于从原始图像中使用直接回归方法生成射血分数估计值,因为完全依赖于左心室轮廓的方法效果不佳.由此推测,过度依赖左心室轮廓信息可能会损害方法性能.

为融合左心室轮廓中的有效信息,本文设计了如图5所示的带辅助任务的射血分数预测网络.其中,特征编码器需要使用视频级编码器,例如Res3D18^[14],编码器连接着两个分支:多头偏心聚合解码器(左心室分割分支)和射血分数预测层(射血分数预测分支),三者共同组成了一个多任务学习网络.射血分数预测分支是一个简单的6层多层感知机,它对编码器的输出做直

接回归,得出射血分数的预测值.而左心室分割分支作为提示性任务分支将网络的注意力更多地集中到左心室轮廓这一关键信息上,帮助网络的其他部分学习出更好的特征表示.

方法没有将左心室分割结果展示给射血分数预测分支,而是通过共同训练和反向传播,将有益的先验信息内化到编码器和射血分数预测分支的权重中,以此防止网络对左心室轮廓信息产生过度依赖.由于两个分支在前向传播时互不干扰,所以在网络权重固定之后,可以将左心室分割分支剪去,以加快推理速度.这一过程与UNet++^[17]的剪枝过程类似,如图5所示,但不同之处在于,UNet++使用基于同一任务的深监督机制,深层网络建立在浅层网络的基础之上,因此剪去更深的嵌套层会带来精度损失,而本文使用基于不同任务的多任务机制,各任务在推理时相互独立,因此剪去其一不会损害另一任务的精度.



(a) EchoGPK剪枝示意图

(b) UNet++剪枝示意图

图5 EchoGPK与UNet++剪枝示意图

2.4 损失函数

2.4.1 左心室分割损失函数

使用轮廓匹配损失函数^[18]来对方法进行训练.选取所有匹配方式中的最小损失作为最终的损失值.记边界点的金标准为 $T=\{t_0, t_1, \dots, t_{N-1}\}$,预测值为 $P=\{p_0, p_1, \dots, p_{N-1}\}$,则定义损失函数 L_{kpts} 如下:

$$L_{\text{kpts}}(P, T) = \min_{j \in \{0, \dots, N-1\}} \sum_{i=0}^{N-1} \|p_i - t_{(i+j)\%N}\|_2 \quad (5)$$

2.4.2 射血分数预测损失函数

多任务学习网络的损失是所有分支损失的融合.射血分数预测分支采用损失;左心室分割分支采用2.4.1中所述的 L_{kpts} 损失.记射血分数金标准为 x_t ,预测值为 x_p ,则定义总损失如下:

$$L_1(x_p, x_t) = \|x_p - x_t\|_1 \quad (6)$$

$$L_{cf} = L_1(x_p, x_t) + \gamma \times L_{kpts}(P, T) \quad (7)$$

其中, γ 是超参数, 本文取 $\gamma=0.1$.

3 实验结果及分析

3.1 数据集

本文使用 EchoNet-Dynamic^[5] 作为实验数据集. 数据集由 10 030 个真实患者的超声心动图视频组成, 每个视频标注有射血分数、左心室收缩末期(End-Systole, ES)和舒张末期(End-Diastole, ED)位置、ES 帧和 ED 帧上的左心室轮廓和容积. 左心室轮廓由 40 个关键标记点围成, 另附两个额外的关键标记点表示左心室长轴. 实验中数据集的划分为: 训练集 75%、验证集 12.5%、测试集 12.5%.

3.2 评价指标

3.2.1 左心室分割评价指标

本文使用戴斯系数(Dice Coefficient, DC)和关键点误差作为左心室分割的评估指标. 记 P_{TP} 为分类正确的前景像素数量; P_{FN} 为分类错误的前景像素数量; P_{TN} 为分类正确的背景像素数量; P_{FP} 为分类错误的背景像素数量, 则 DC 的计算方式如下:

$$DC = \frac{2P_{TP}}{P_{FP} + 2P_{TP} + P_{FN}} \times 100\% \quad (8)$$

使用与 2.4.1 节中相同的预测值 P 和金标准 T , 则关键点误差 MKE (Mean Keypoints Error) 的计算方式如下:

$$MKE = \frac{\sum_{i=0}^{M-1} \|p_i - t_i\|_2}{M} \div 112 \times 100\% \quad (9)$$

3.2.2 射血分数预测评价指标

本文使用所有测试样本的平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE) 和相关性 (R^2) 作为平均射血分数预测结果的指标.

3.3 左心室分割效果与分析

图 6 展示了以 ResNet50^[13] 为编码器的 EchoGPK 和 EchoGraphs^[1] 的左心室分割效果. 对比金标准图像, 图 6(a) 中 EchoGraphs 的分割轮廓底端存在较为明显的异常突起 (突变点), 而 EchoGPK 的分割轮廓则要更加平滑 (图 6(c)), 这是由于 EchoGPK 更显式地强调了聚合过程中的邻域约束, 而 EchoGraphs 则认为所有图节点地位同等, 未做特别的约束. EchoGPK 的分割边缘起伏更小, 更接近方法所建模的椭圆形先验. 这可能导致方法拟合棱角细节的能力变弱 (如图 6(f)), 但这也更符合左心室的形状共性, 有助于降低过拟合风险, 提高泛化性.

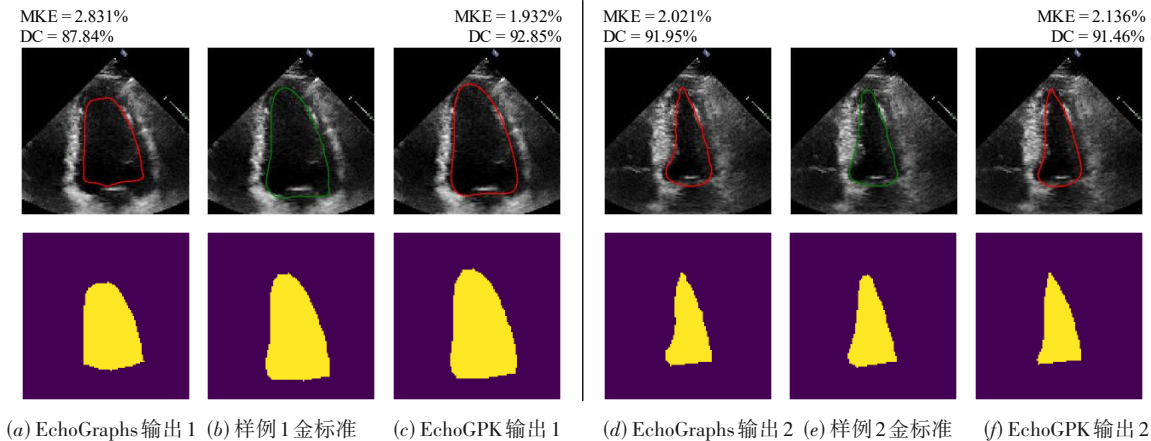


图 6 左心室分割典型样例

3.4 准确度对比评估结果

3.4.1 左心室分割准确度评估

本文选取了 EchoGraphs^[1]、U-Net^[3]、EchoNet^[5]、Transfuse^[7] 四种算法与 EchoGPK 进行对比. 评估结果如表 1 所示.

根据表 1, 在使用轻量级编码器时, 与准确率相近的 U-Net 和 EchoNet 相比, EchoGPK (MobileNetV2) 所需的参数量相对降低 84.60%、87.93%, 而与同尺寸的 EchoGraphs (MobileNetV2) 相比, EchoGPK (Mobile-

NetV2) 的准确率提升了 0.26%. 而在使用大型编码器时, EchoGPK (ResNet50) 取得了最高的准确率, 相比 25 M 参数以上的同尺寸方法, DC 分数平均提高 0.50%, 同时参数量平均相对下降 9.31%. 由此可见, EchoGPK 在使用各种复杂度的特征编码器时, 都能保证甚至提升准确率, 并实现参数量的下降, 说明了先验知识建模在超声心动图分析中有效性.

使用多任务网络训练得出的左心室分割结果较差, 这是因为从左心室轮廓到射血分数值之间的单值

表1 左心室分割准确度评估结果

方法名称	编码器	MKE/%	DC/%	参数量/M
U-Net ^[3]	U-Net		91.54	31.04
EchoNet ^[5]	DeepLabV3		91.70	39.60
Transfuse ^[7]	Transformer		91.31	26.25
EchoGraphs ^[11]	MobileNetV2	2.07	91.34	4.900
EchoGraphs ^[11]	ResNet18	1.99	91.69	12.40
EchoGraphs ^[11]	ResNet50	1.97	91.96	27.66
EchoGPK(多任务)	Res3D18	2.14	91.23	34.28
EchoGPK	MobileNetV2	2.02	91.60	4.780
EchoGPK	ResNet18	1.97	91.87	12.26
EchoGPK	ResNet50	1.91	92.13	27.54

注:粗体表示最优值,空白表示不适用。

映射函数(例如辛普森双平面法)不可逆. 给定的心室形态必然对应唯一的射血分数值,但相同的射血分数值却可能对应多种不同的心室形态. 因此射血分数预测分支反而可能为左心室分割分支引入噪声,损害其分割性能。

3.4.2 射血分数预测准确度评估

本文选取了EchoNet^[5]、UVT^[16]、EchoGraphs^[11]、EchoCoTr^[6]和AdaCon^[19]五种先进方法与以Res3D18^[14]为编码器的EchoGPK进行对比. 评估结果如表2所示。

表2 射血分数准确度评估结果

方法名称	输入帧数	MAE	RMSE	R ²
EchoNet ^[5]	32	4.21	5.50	0.800
UVT ^[16]	128	5.32	7.20	0.626
EchoGraphs ^[11]	16	4.01	5.36	0.814
EchoCoTr ^[6]	36	4.00	5.25	0.815
AdaCon ^[19]	32	3.86	5.07	0.828
EchoGPK	16	3.92	5.25	0.816

注:粗体表示最优值。

表2表明,EchoGPK仅需从心动周期中采样16帧,即可取得令人满意的效果. 采样帧的数量并非评价方法好坏的标准,但更少的采样帧意味着更小的存储需求,有利于降低方法的硬件要求. EchoGPK的准确率超越了EchoCoTr、EchoNet等使用经典回归思路的方法,说明了左心室分割分支确实可以为射血分数预测提供正向的助力,这与医疗专家估算射血分数的普遍经验相一致. AdaCon虽然准确率高于EchoGPK,但其对于计算量的需求达到了EchoGPK的约50倍(见3.5节),并且也没有对临床上重视的解释性问题和轻量化问题加以关注. AdaCon的强大性能来自于对比学习,在对轻量化需求较低的场景下,同样的思路也可以应用于EchoGPK,并可能进一步提升其性能。

3.5 轻量化程度对比评估结果

本文使用参数量和FLOPs(Floating Point Opera-

tions,浮点运算次数)来衡量方法的轻量化程度. FLOPs均在非并行条件下测试单个样本得出. 对于编码器可替换的方法,使用多种编码器分别测试. 左心室分割和射血分数预测的轻量化程度评估结果分如表3和表4所示。

表3 左心室分割轻量化程度评估结果

方法名称	编码器	参数量/M	FLOPs/GMac
EchoNet ^[5]	DeepLabV3	39.60	91.97
U-Net ^[3]	U-Net	31.04	10.47
Transfuse ^[7]	Transformer	26.25	8.630
EchoGraphs ^[11]	MobileNetV2	4.900	0.097
EchoGraphs ^[11]	ResNet18	12.40	0.497
EchoGraphs ^[11]	ResNet50	27.66	1.120
EchoGPK	MobileNetV2	4.780	0.092
EchoGPK	ResNet18	12.26	0.492
EchoGPK	ResNet50	27.54	1.090

注:粗体表示最优值。

表4 射血分数预测性能评估结果

方法名称	编码器	参数量/M	FLOPs/GMac
UVT ^[16]	Transformer	346.8	130.0
EchoNet ^[5]	DeepLabV3	39.60	91.97
AdaCon	Res3D18	31.63	81.54
EchoCoTr ^[6]	Transformer	21.20	15.59
EchoGraphs ^[11]	Res3D18	33.36	1.577
EchoGPK	Res3D18	33.19	1.565

注:粗体表示最优值。

表3表明,EchoGPK在计算量上更具有优势. EchoGPK(MobileNetV2)具有最少的参数量和最低的FLOPs,其所需的浮点计算量约为EchoNet的1/1 000,但准确率仅下降0.10%. 这得益于两个方面,一是MobileNetV2编码器本身的轻量化设计,二是EchoGPK所建立的先验捷径。

从表4中可以看到,EchoCoTr和AdaCon的总参数量虽然较低,但它们所需要的计算量却分别达到了EchoGPK的约10倍和50倍. 这是因为AdaCon使用了32帧的大尺寸输入序列,并在其上进行频繁的三维卷积;而EchoCoTr则较多地使用了注意力机制和插值嵌入操作,存在较多无可训练参数参与的计算. 而根据表5可知,EchoGPK的左心室分割分支和射血分数预测分支都非常轻量化,这是因为EchoGPK利用采样、小范围聚合等操作尽力避免了全连接层和大尺寸卷积,从而降低了参数量和计算量。

3.6 消融实验结果

为评估本文所提方法的各部分的有效性,设置以MobileNetV2+MPNN和Res3D18+MLP为基线的消融实验,依次将EchoGPK各结构加入到基线网络中,观察方

表5 EchoGPK各部分参数量及计算量

模块名称	参数量 /M	参数 占比/%	FLOPs /GMac	计算量 占比/%
Res3D18 编码器	33.16	96.73	1.565	99.683
左心室分割分支	1.090	3.180	4.946×10^{-3}	0.315
射血分数预测分支	0.028	0.081	2.766×10^{-5}	0.002

法的性能变化. 表6、表7分别列出了左心室分割和射血分数预测的消融实验结果.

从表6中可以观察到,螺旋聚合函数和偏心聚合均能同时降低MKE误差、提高DC分数,而多头偏心聚合解码器则是在提高DC分数上表现更佳. 这是因为多头偏心聚合解码器注重提高方法的适应性,降低预测的方差,而DC指标更能反映这一变化.

为更好地说明本文所提结构的有效性,表7对比了不同方法作为辅助任务时的效果. 数据表明,多头偏心

表6 左心室分割消融实验结果

模块名称	MKE/%	DC/%
MobileNetV2+MPNN	2.46	89.09
MobileNetV2+螺旋聚合函数	2.28	91.28
MobileNetV2+螺旋聚合函数+偏心聚合	2.06	91.41
MobileNetV2+螺旋聚合函数+多头偏心聚合解码器	2.02	91.60

注:粗体表示最优值.

聚合解码器取得了最好的效果,对比无分支网络MAE相对下降了7.33%. EchoGraphs解码器也取得了较好的效果,说明常规的左心室分割分支网络也能对射血分数预测提供帮助,结合左心室分割辅助射血分数预测的方法具有通用性. U-Net解码器在所有以Res3D18为编码器的网络中表现最差,原因可能是U-Net解码器难以解码时空信息. 将编码器换为U-Net编码器后,多任务网络的结果相比于同编码器的直接回归方法也有所改善.

表7 射血分数消融实验结果

基础编码器	射血分数预测分支解码器	左心室分割分支解码器	MAE	RMSE	R ²
Res3D18	MLP	无	4.23	5.75	0.779
Res3D18	MLP	EchoGraphs解码器 ^[1]	4.00	5.33	0.810
Res3D18	MLP	U-Net解码器 ^[3]	5.24	7.33	0.642
Res3D18	MLP	多头偏心聚合解码器	3.92	5.25	0.816
U-Net编码器 ^[3]	MLP	无	7.37	9.34	0.422
U-Net编码器 ^[3]	MLP	U-Net解码器 ^[3]	6.20	7.68	0.620

注:粗体表示最优值.

4 结语

本文针对现有超声分析方法解释性弱、复杂度高等问题,提出了一种以先验知识为核心的轻量级图卷积分析方法. 实验结果表明,方法能够以更少的参数和计算量取得更高的分割与预测精确度,证明了先验知识对超声分析任务的重要性和潜在价值. 然而,目前的方法所包含的先验知识较为基础和有限,后续将重点考虑针对专业医学知识的先验建模方法.

参考文献

- [1] THOMAS S, GILBERT A, BEN-YOSEF G. Light-weight spatio-temporal graphs for segmentation and ejection fraction prediction in cardiac ultrasound[C]//Medical Image Computing and Computer Assisted Intervention—MICCAI 2022: 25th International Conference. Cham: Springer Nature Switzerland, 2022: 380-390.
- [2] 刘盛锋, 王毅, 杨鑫, 等. 深度学习在医学超声图像分析中的应用综述[J]. 工程(英文), 2019, 5(2): 261-275.
LIU S F, WANG Y, YANG X, et al. Deep learning in medical ultrasound analysis: A review[J]. Engineering, 2019, 5

(2): 261-275. (in Chinese)

- [3] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]//Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference. Cham: Springer International Publishing, 2015: 234-241.
- [4] ISENSEE F, JAEGER P F, KOHL S A A, et al. nnU-Net: A self-configuring method for deep learning-based biomedical image segmentation[J]. Nature Methods, 2021, 18(2): 203-211.
- [5] OUYANG D, HE B, GHORBANI A, et al. Video-based AI for beat-to-beat assessment of cardiac function[J]. Nature, 2020, 580(7802), 252-256.
- [6] MUHTASEB R, YAQUB M. EchoCoTr: Estimation of the left ventricular ejection fraction from spatiotemporal echocardiography[C]//Medical Image Computing and Computer Assisted Intervention—MICCAI 2022: 25th International Conference. Cham: Springer Nature Switzerland, 2022: 370-379.
- [7] ZHANG Y D, LIU H Y, HU Q. TransFuse: Fusing Trans-

- formers and CNNs for medical image segmentation[C]// Medical Image Computing and Computer Assisted Intervention—MICCAI 2021: 24th International Conference. Cham: Springer Nature Switzerland, 2021: 14-24.
- [8] XUE W F, CAO H, MA J Q, et al. Improved segmentation of echocardiography with orientation-congruency of optical flow and motion-enhanced segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26(12): 6105-6115.
- [9] 刘晓鸣, 雷震, 何刊, 等. 全卷积神经网络与全连接条件随机场中的左心室射血分数精准计算[J]. 计算机辅助设计与图形学学报, 2019, 31(3): 431-438.
- LIU X M, LEI Z, HE K, et al. Accurate estimation of left ventricle ejection fraction using fully convolutional networks and fully connected conditional random field[J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(3): 431-438. (in Chinese)
- [10] BOURITSAS G, BOKHNYAK S, PLOUMPIS S, et al. Neural 3D morphable models: Spiral convolutional networks for 3D shape representation learning and generation [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2019: 7212-7221.
- [11] 万升, 杨健, 宫辰. 基于图神经网络的高光谱图像分类研究进展[J]. 电子学报, 2023, 51(6): 1687-1709.
- WAN S, YANG J, GONG C. Advances of hyperspectral image classification based on graph neural networks[J]. Acta Electronica Sinica, 2023, 51(6): 1687-1709. (in Chinese)
- [12] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 4510-4520.
- [13] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 770-778.
- [14] TRAN D, WANG H, TORRESANI L, et al. A closer look at spatiotemporal convolutions for action recognition [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 6450-6459.
- [15] ESFEH M M K, LUONG C, BEHNAMI D, et al. A deep bayesian video analysis framework: Towards a more robust estimation of ejection fraction[C]//Medical Image Computing and Computer Assisted Intervention—MICCAI 2020: The 23rd International Conference, Part II. New York: ACM, 2020: 582-590.
- [16] REYNAUD H, VLONTZOS A, HOU B, et al. Ultrasound video Transformers for cardiac ejection fraction estimation[C]//Medical Image Computing and Computer Assisted Intervention—MICCAI 2021: The 24th International Conference. Cham: Springer Nature Switzerland, 2021: 495-505.
- [17] ZHOU Z W, RAHMAN SIDDIQUEE M M, TAJBAKHSH N. UNet++: A nested U-Net architecture for medical image segmentation[C]// Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support (DLMIA ML-CDS) 2018. Cham: Springer Nature Switzerland, 2018: 3-11.
- [18] TIAN Z Q, LI X J, ZHENG Y Y, et al. Graph-convolutional-network-based interactive prostate segmentation in MR images[J]. Medical Physics, 2020, 47(9): 4164-4176.
- [19] DAI W H, LI X M, CHIU W H K, et al. Adaptive contrast for image regression in computer-aided disease assessment[J]. IEEE Transactions on Medical Imaging, 2022, 41(5): 1255-1268.

作者简介



王博荣 男, 2002年1月出生于江西省赣州市. 现为中国科学院大学研究生, 培养单位为中国科学院计算技术研究所. 主要研究方向为智能医学影像.

E-mail: wangborong23@ucas.mails.ac.cn



叶剑 男, 1974年6月出生于山东省济南市. 现为中国科学院计算技术研究所高级工程师、硕士生导师. 主要研究方向为机器学习、数据挖掘.

E-mail: jye@ict.ac.cn