基于卷积神经网络的心脏射血分数评估研究

高媛^{1,2},宋金超²

¹上海理工大学健康科学与工程学院,上海 ²上海理工大学附属市东医院麻醉科,上海

收稿日期: 2025年3月21日; 录用日期: 2025年4月14日; 发布日期: 2025年4月21日

摘要

心血管疾病是全球范围内的重要死亡原因,涵盖了一系列涉及心脏和血管的疾病。射血分数作为临床检 查中的关键指标,其变化与心力衰竭、心肌梗死和心脏纤维化等常见心血管疾病密切相关。本研究旨在 通过开发一种高效准确的计算方法,协助临床医生及时诊断这些疾病。为此,本文基于EchoNet-Dynamic 数据集,提出了一种新的半监督深度学习网络EF-Net。该网络结合了U-Net架构、深度监督和注意力模块, 通过半监督学习增加训练样本,从而增强了模型的图像分割能力。与现有方法相比,EF-Net在数据集的 大多数评估标准上均表现出显著提升。研究结果表明,该方法显著提高了心脏超声成像中射血分数的计 算精度,展示了其在临床诊断中的潜在应用价值。

关键词

半监督学习,射血分数,超声图像,图像分割

Research on the Evaluation of Cardiac Ejection Fraction Based on Convolutional Neural Network

Yuan Gao^{1,2}, Jinchao Song²

¹School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai ²Department of Anesthesiology, Shidong Hospital Affiliated to the University of Shanghai for Science and Technology, Shanghai

Received: Mar. 21st, 2025; accepted: Apr. 14th, 2025; published: Apr. 21st, 2025

Abstract

Cardiovascular diseases are a leading cause of death globally, encompassing a range of conditions

文章引用: 高媛, 宋金超. 基于卷积神经网络的心脏射血分数评估研究[J]. 建模与仿真, 2025, 14(4): 649-655. DOI: 10.12677/mos.2025.144317

that affect the heart and blood vessels. Ejection fraction, a key metric in clinical examinations, is closely associated with common cardiovascular diseases such as heart failure, myocardial infarction, and cardiac fibrosis. This study aims to assist clinicians in timely diagnosis by developing an efficient and accurate computational method. To this end, we propose a novel semi-supervised deep learning network, EF-Net, based on the EchoNet-Dynamic dataset. This network integrates the U-Net architecture, deep supervision, and attention mechanisms, enhancing the model's image segmentation capabilities through semi-supervised learning with additional training samples. Compared to existing methods, EF-Net demonstrates significant improvements across most evaluation metrics on the dataset. The results indicate that this approach significantly enhances the accuracy of ejection fraction calculation in cardiac ultrasound imaging, underscoring its potential clinical diagnostic value.to the Hans standard, which illustrates all the formats.

Keywords

Semi-Supervised Learning, Ejection Fraction, Ultrasound Images, Image Segmentation

Copyright © 2025 by author(s) and Hans Publishers Inc. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). http://creativecommons.org/licenses/by/4.0/

1. 引言

心血管疾病涵盖了一系列与心脏和血管系统密切相关的病症,是全球范围内导致死亡的主要原因之一。众多研究显示,心血管疾病引发的死亡率与致残率处于持续攀升的态势,这对全球的医疗体系以及 经济系统均造成了极为沉重的负担[1]。据预测,到 2035 年,与心血管疾病相关的医疗费用以及因心血管 疾病导致的生产力损失将会急剧增加。相较于 2015 年的 5550 亿美元,这个数字预计会翻倍,达到 1.1 万 亿美元之多[2]。而且,不健康的生活方式和行为习惯正促使心血管疾病的发病率不断上升,这使得具有 心血管疾病风险因素的人群数量日益增多。在这样的背景下,早期对心血管疾病进行检测、准确的诊断 以及及时有效的治疗,对于心血管疾病的预防和控制而言,无疑是极为关键的举措。

左心室射血分数定义为每搏输出量与心室舒张末期容积的百分比。在心室收缩期间,并非所有心室中的血液都被射入动脉。正常成人静息时,左心室舒张末期容积约为125 mL,右心室约为137 mL,每搏输出量为 60~80 mL。每搏输出量与舒张末期容积的百分比称为射血分数,通常认为超过 50%为正常[3]。射血分数与心肌的收缩能力有关,收缩能力越强,射血分数越高。射血分数的变化与心力衰竭、心肌梗死和心脏纤维化等常见心血管疾病密切相关。

EchoNet-Dynamic 数据集[4]提供了超声心动图视频、左心室收缩末期和舒张末期的标签以及射血分数,允许通过深度学习对这些标签进行分割。这使得可以使用公式1估算射血分数(EF),其中 EDV 表示舒张末期容积,ESV 表示收缩末期容积。

$$EF = \frac{(EDV - ES) \times 100\%}{EDV}$$
(1)

本研究基于公开的 EchoNet-Dynamic 数据集的超声心动图视频进行模型训练和优化,以图像分割 为技术基础,并通过半监督学习扩展数据集[5]。旨在准确高效地计算射血分数,协助临床医生及时诊 断,从而提高患者的生存质量和生活质量,最终减轻全球医疗和经济系统的负担。图 1 展示了研究的 流程。



Figure 1. Workflow of this article 图 1. 本文工作流程

2. 材料与方法

2.1. 数据预处理

本研究从斯坦福大学医学院所公开的 EchoNet-Dynamic 数据集收集到了 10,024 个带有舒张末期和收缩末期标签的超声心动图视频,其余帧均无标签。将该数据集按照 5:2:2 的比例划分训练集、验证集和测试集。具体划分情况如下:训练集包含 5568 组数据,这一集在后续的研究中主要用于模型的训练,通过大量的训练数据让模型学习到数据中的特征和规律;验证集有 2228 组数据,它在模型训练过程中起着重要的验证作用,有助于评估模型在训练过程中的表现并调整模型参数,防止模型过拟合;测试集同样有 2228 组数据,其主要功能是在模型训练完成后对其进行最终的测试,从而全面评估模型对新数据的泛化能力。此外,为了使数据格式统一以便于模型处理,将图像数据统一调整为 112×112 像素的形式。图 2 呈现了左心室收缩末期和舒张末期图像及其各自对应标签的具有代表性的示例,这些示例能够帮助读者更好地理解本研究中数据的特征和标注方式。



 Figure 2. Examples of left ventricular images and their labels for end-systolic and end-diastolic phases

 图 2. 左心室图像及其收缩末期和舒张末期标签示例

2.2. 实验模型

本研究以 U-Net [6]架构为基础框架,提出了名为 EF-Net 的分割模型。U-Net 架构是专门为图像分割 任务而设计的,其结构呈现出一种对称的形式,由编码器和解码器这两大部分构成。其中,解码器里集 成了跳跃连接这一重要机制,它的作用在于融合各个层级的特征信息,进而提升图像分割的精度。U-Net 的编码器部分是由卷积层与池化层组合而成的。卷积层通过卷积核在图像上滑动进行卷积操作,能够自 动学习图像中的局部特征,而池化层则对卷积层输出的特征图进行下采样操作,在减少数据量的同时保 留主要特征信息,两者协同工作,从而从输入图像中有效地提取出高级特征表示。与之相对应的是,解 码器部分主要依靠上采样操作和卷积层来发挥作用。上采样操作能够增加特征图的尺寸,逐步将经过编 码器处理后得到的低分辨率特征图恢复到与原始输入图像相同的分辨率大小,卷积层在这个过程中则进 一步对特征进行处理和优化。在 U-Net 架构的每一层都运用了跳跃连接。这种跳跃连接方式巧妙地将来 自编码器和解码器的特征进行合并,使得模型在重建图像特征的过程中能够保留更多的复杂细节信息, 这对于精确的图像分割任务来说是非常关键的。本研究提出的 EF-Net 的总体架构如图 3 所示。



Figure 3. The network structure of the EF-Net 图 3. EF-Net 的网络结构

本研究模型采用多尺度深度监督策略[7],以实现对各类特征的高效学习。在模型的不同深度层次中, 较深层次的神经元能够有效提取包含有形状与结构信息的全局特征,这些全局特征对于理解整体图像的 语义信息至关重要;相对而言,较浅层次的网络层则侧重于对局部特征的捕捉,而局部特征在描述图像 中物体的表面特性方面起着不可或缺的作用。通过在多个分辨率级别设置深度监督层,能够从不同层次 与角度获取特征信息,使模型能够更好地适应各种复杂的图像数据情况,进而全面提升模型的性能并增 强其泛化能力。

另外,本模型引入了病理特征注意力(PFA)块[8],该模块融合了 CBAM [9]和 CA [10]这两种注意力 机制。这种融合方式使得 PFA 块在捕捉图像细节信息方面表现出色,同时在计算特征层的权重方面也具 备卓越的性能。将 PFA 块集成到跳跃连接部分之后,能够有效强化网络的分割能力,从而在处理如医学 图像分割这类对细节要求较高的任务时,能够取得更好的效果。

2.3. 评估指标

豪斯多夫距离(Hausdorff Distance)是衡量两组点之间相似性的指标,定义如下:给定两组点 $A = \{a_1, \dots, a_q\}$ 和 $B = \{b_1, \dots, b_q\}$,这两组点之间的豪斯多夫距离定义为公式 2。公式 3 和 4 中的 h(A,B) 和 h(B,A)分别是从集合 A 到集合 B 和从集合 B 到集合 A 的单向豪斯多夫距离。豪斯多夫距离分割的边界敏感。

$$H(A,B) = \max[h(A,B),H(B,A)]$$
(2)

$$h(A,B) = \max_{a \in A} \min_{b \in B} \left\| a - b \right\|$$
(3)

$$h(B,A) = \max_{b\in B} \min_{a\in A} \left\| a - b \right\|$$
(4)

Dice 系数(Dice Coefficient)能够量化预测分割结果与真实标签之间的重叠程度,范围从0到1。Dice 系数越高,越接近1,表示预测结果与真实标签的对齐程度越高,从而表明模型性能越好。与其他指标相比,Dice 系数在在许多语义分割任务中得到广泛应用。

$$Dice = \frac{2 \times Intersection}{Ground truth + predicted}$$
(5)

EF-MAE: 平均绝对误差(MAE)是评估预测模型误差的指标,常用于回归问题。它计算模型预测值与 真实值之间的平均绝对差异,反映了差异的平均幅度。本研究计算了不同方法获得的射血分数值与数据 集中提供的标准射血分数值之间的 MAE,并将其命名为 EF-MAE。EF-MAE 越小,表示预测越准确。

2.4. 实现细节

为了便于模型的可重复性,在表1中列出了模型训练过程中的超参数设置和环境配置。这些配置可 以提高模型的准确性和效率,促进其在射血分数估计中的应用,并协助临床诊断。

名称	值	
学习率	0.001	
轮数	50	
图像尺寸	$112 \times 112 \times 3$	
Batchsize	32	
CPU	Intel Xeon Silver 4210 CPU	
GPU	NVIDIA RTX 3090	
优化器	Adam	

 Table 1. Model hyperparameter configuration and running environment

 表 1. 模型超参数配置和运行环境

3. 结果

3.1. 评估指标结果

为了验证方法的有效性,本研究将其与 U-Net 和 SegResNet [11]进行了比较分析。所有网络均在一致的实验条件下采用相同的训练策略运行。表 2 中的评估结果表明,EF-Net 在所有指标上均优于其他模型。此外,半监督训练的使用显著提高了结果的准确性。

Table	2. Model evaluation metrics
表 2.	模型评估指标

方法	Dice 系数↑	豪斯多夫距离↓	EF-MAE↓
U-Net	0.865 ± 0.049	8.650 ± 2.204	0.157 ± 0.085
SegResNet	0.865 ± 0.049	8.693 ± 2.393	0.158 ± 0.084
U-Net+PFA	0.865 ± 0.044	8.630 ± 2.365	0.150 ± 0.086
EF-Net	0.866 ± 0.050	8.606 ± 2.314	0.153 ± 0.088
EF-Net + semi-supervised	0.868 ± 0.049	8.082 ± 2.412	0.147 ± 0.087

3.2. 分割结果的可视化比较

尽管所有模型在 Dice 指标上的平均差异不显著,但可视化比较清楚地显示了 EF-Net 的优势。如图 4 所示, SegResNet 的分割结果存在明显的噪声,而 U-Net 的伪影相对较少。射血分数-Net 的分割输出是所 比较方法中最清晰、最准确的,从而证实了其优于其他方法的分割性能。



Figure 4. Visual comparison of results using different methods 图 4. 不同方法结果的视觉比较

3.3. EF-MAE 统计分析

为了全面评估不同方法的性能,本文绘制了所有方法 EF-MAE 结果的箱线图,如图 5 所示。X 轴表示每种方法,Y 轴表示绝对误差。箱线图内的黑线表示平均值。评估表明,EF-Net 在第一四分位数和平均值方面均表现出优于其他方法的性能。



图 5. EF-MAE 的统计结果

4. 讨论

本研究提出的 EF-Net 通过整合 U-Net 架构、深度监督机制与病理特征注意力模块,在超声心动图左 心室分割任务中展现出稳定的性能优势。实验结果显示,相较于传统 U-Net 和 SegResNet, EF-Net 在 Dice 系数、豪斯多夫距离和 EF-MAE 等关键指标上均取得改进。这种提升源于两个核心设计:多尺度深度监督策略通过同步学习全局结构特征与局部纹理信息,改善了超声图像分辨率不足导致的边界辨识问题; 病理特征注意力模块通过空间与通道注意力协同机制,增强了心肌 - 心室腔交界区域的特征聚焦能力,

这与射血分数计算依赖的解剖结构定位精度密切相关。半监督学习框架的引入使训练样本量扩展,在医学影像标注数据有限的场景中,通过伪标签迭代优化提升了模型对超声图像噪声的适应性。从临床应用 角度观察,EF-Net 的 EF-MAE 值表明其计算结果具备辅助诊断的实际可行性。在心力衰竭筛查场景中, 该方法可实现舒张末期与收缩末期容积的自动化测量,将传统人工测量耗时从分钟缩短至秒级,同时减 少主观评估差异。

当前研究存在两方面局限性:模型训练依赖单一机构的超声数据,未来需通过多中心异构数据验证 泛化能力;实时视频分析时的心脏搏动周期相位识别精度可能影响容积计算的时序一致性,后续计划结 合心电信号进行多模态优化。总体而言,EF-Net 为心血管疾病智能诊断提供了可推广的技术方案,其高 效率与精确度的平衡特性有助于提升基层医疗机构的心功能评估效率。

5. 结论

本研究证明了 EF-Net 在预测射血分数方面的有效性。该模型为心脏检查中的射血分数评估提供了更快、更便捷的方法。与传统预测模型相比, EF-Net 在各项指标上均表现出更优的性能。因此, EF-Net 在临床实践中具有实用价值,有助于医生加快诊断速度,从而提高患者的生存率和生活质量,同时减轻医疗和经济系统的负担。

参考文献

- Benjamin, E.J., Virani, S.S., Callaway, C.W., Chamberlain, A.M., Chang, A.R., Cheng, S., *et al.* (2018) Heart Disease and Stroke Statistics—2018 Update: A Report from the American Heart Association. *Circulation*, **137**, e67-e492. https://doi.org/10.1161/cir.0000000000558
- [2] Dunbar, S.B., Khavjou, O.A., Bakas, T., Hunt, G., Kirch, R.A., Leib, A.R., *et al.* (2018) Projected Costs of Informal Caregiving for Cardiovascular Disease: 2015 to 2035: A Policy Statement from the American Heart Association. *Circulation*, **137**, e558-e577. <u>https://doi.org/10.1161/cir.00000000000570</u>
- [3] Redfield, M.M. and Borlaug, B.A. (2023) Heart Failure with Preserved Ejection Fraction: A Review. *JAMA*, **329**, 827-838. <u>https://doi.org/10.1001/jama.2023.2020</u>
- [4] Ouyang, D., He, B., Ghorbani, A., et al. (2019) EchoNet-Dynamic: A Large New Cardiac Motion Video Data Resource for Medical Machine Learning. 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), Vancouver, 8-14 December 2019, 1-11.
- [5] Jiao, R., Zhang, Y., Ding, L., Xue, B., Zhang, J., Cai, R., et al. (2024) Learning with Limited Annotations: A Survey on Deep Semi-Supervised Learning for Medical Image Segmentation. *Computers in Biology and Medicine*, 169, Article 107840. <u>https://doi.org/10.1016/j.compbiomed.2023.107840</u>
- [6] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention—MICCAI* 2015, Munich, 5-9 October 2015, 234-241. <u>https://doi.org/10.1007/978-3-319-24574-4_28</u>
- [7] Lee, C.Y., Xie, S., Gallagher, P., et al. (2015) Deeply-Supervised Nets. Proceedings of the Eighteenth International Conference on Artificial Intelligence and Statistics, San Diego, 9-12 May 2015, 562-570.
- [8] Ma, Y., Zhang, Y., Wang, Z., Li, J., Miao, Y., Yang, F., et al. (2024) DSFF-GAN: A Novel Stain Transfer Network for Generating Immunohistochemical Image of Endometrial Cancer. Computers in Biology and Medicine, 170, Article 108046. <u>https://doi.org/10.1016/j.compbiomed.2024.108046</u>
- [9] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. Computer Vision— ECCV 2018, Munich, 8-14 September 2018, 3-19. <u>https://doi.org/10.1007/978-3-030-01234-2_1</u>
- [10] Hou, Q., Zhou, D. and Feng, J. (2021) Coordinate Attention for Efficient Mobile Network Design. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Nashville, 20-25 June 2021, 13708-13717. https://doi.org/10.1109/cvpr46437.2021.01350
- [11] Myronenko, A. (2019) 3D MRI Brain Tumor Segmentation Using Autoencoder Regularization. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries, Granada, 16 September 2018, 311-320. https://doi.org/10.1007/978-3-030-11726-9_28