用于电影心脏磁共振成像左心室自动分割的两种深度学习方法

Wenhui Chu
wchu@uh.edu 休斯敦大学磁共振成像实验室 美国得克萨斯州休斯敦

Nikolaos V. Tsekos
nvtsekos@central.uh.edu 休斯敦大学磁共振成像实验室 美国得克萨斯州休斯敦

arXiv:2601.00794v1 [cs.CV] 2 Jan 2026

摘要

左心室（LV）分割对于心脏图像的临床定量分析和诊断至关重要。在本研究中，我们提出了两种新颖的深度学习架构，称为 LNU-Net 和 IBU-Net，用于从短轴电影磁共振图像中分割左心室。LNU-Net 源自层归一化（LN）U-Net 架构，而 IBU-Net 源自用于医学图像分割的实例-批归一化（IB）U-Net。LNU-Net 和 IBU-Net 的架构均包含用于特征提取的下采样路径和用于精确定位的上采样路径。我们采用原始 U-Net 作为基础分割方法，并将其与所提出的架构进行比较。LNU-Net 和 IBU-Net 都采用了左心室分割方法：LNU-Net 在每个卷积块中应用层归一化，而 IBU-Net 在第一个卷积块中结合实例归一化和批归一化，并将其结果传递到下一层。我们在图像数据处理中采用仿射变换和弹性变形。我们使用包含来自 45 名患者的 805 张左心室 MRI 图像的数据集进行评估。实验结果表明，与其他最先进的方法相比，所提出的方法在 Dice 系数和平均垂直距离方面表现更优。

CCS 概念

• **计算方法** → **神经网络**。

关键词

磁共振成像；左心室；心脏外科；卷积神经网络

ACM 引用格式：
Wenhui Chu和Nikolaos V. Tsekos。2022年。电影心脏磁共振成像中左心室自动分割的两种深度学习方法。载于*2022*年第*12*届生物科学、生物化学与生物信息学国际会议（*ICBBB '22*），*2022*年*1*月7日至*10*日，日本东京。ACM，纽约，纽约州，美国，6页。https://doi.org/10.1145/3510427.3510429

允许免费制作本作品全部或部分内容的数字或纸质副本，供个人或课堂使用，但不得为营利或商业利益制作或分发副本，且副本首页必须附有本声明和完整引文。本作品中由 ACM 以外各方拥有版权的组件必须予以尊重。注明出处后可进行摘要引用。若需以其他方式复制、再版、发布至服务器或向列表重新分发，须事先获得明确许可和/或支付费用。请通过 permissions@acm.org 申请许可。*ICBBB '22*，日本东京 © 2022年 ACM。ACM ISBN 978-1-4503-8738-5/22/01 https://doi.org/10.1145/3510427.3510429

1 引言

心脏疾病始终威胁着世界各地人们的生命。在美国，这是导致自然死亡的最主要原因，每年造成数百万人丧生 [3]。在U-Net中，它能够为边界检测提供精确的分割，这对于临床应用尤为重要。此外，U-Net在GPU内存使用方面效率很高。与其计算能力相比，GPU内存是一个瓶颈，因此节省GPU内存对于卷积神经网络而言是一个相当显著的优势。U-Net的表现也优于相关研究成果，因为它所需的标注训练样本更少。众所周知，获取标注样本的成本相当高，因此U-Net能够以更少的训练数据实现较高的准确率，表现十分出色。

心脏疾病的MRI图像是诊断心脏疾病的重要参考。手动分割MRI图像需要耗费大量时间，还需额外支付聘请专家的费用，而这些资源本可用于帮助更多患者。此外，这种分割方式的准确性无法得到充分保证。随着计算单元的发展，神经网络扫描已能应用于日常生活的几乎各个方面。医疗保健也是一项重要应用，尤其是在图像分类、图像分割和目标检测方面。人们相信，在神经网络的帮助下，图像处理将更加高效、准确。具体而言，对于左心室心脏图像，我们认为，更准确的分割有助于心脏疾病的诊断，并将在未来挽救更多生命。由于准确分割是评估心脏功能的首要步骤，过去几十年来，已有一些关于左心室心脏图像分割的重要研究 [14]。本文重点研究采用 U-Net [17], 的像素分类方法。U-Net 是一种广泛应用于医学应用的神经网络。我们将通过采用不同的归一化方法改进 U-Net，并比较这些方法对结果的影响。

过去几年，人们一直在探索将神经网络应用于图像分割。R. Poudel 等人[15] 使用循环全卷积神经网络进行心脏磁共振成像的心脏图像分割。全卷积神经网络被用于心脏分割 [20]。结合水平集方法与深度置信网络，对心脏磁共振成像中的左心室进行分割 [12]。使用深度学习网络时，充足的训练数据是提高准确率的必要条件 [16]。在此之前，高斯混合模型 [5], 、基于图像的方法 [6], 、分层时空森林 [10], 以及动态方法 [9] 等机器学习方法已被应用于这项任务。

在本研究中，我们希望比较不同归一化方法与 U-Net 在左心室

心脏图像分割中的应用效果。本文结构安排如下。在方法部分，我们将讨论采用 U-Net 的原因，并简要比较所使用的归一化方法，包括批归一化、层归一化和批实例归一化。我们将展示所用神经网络的结构以及数据。在第三节中，我们将讨论数据预处理方法和实验结果。本文最后一节将进行讨论并得出结论。

2 方法

2.1 网络结构

U-Net 是一种专为生物医学图像分割而设计的卷积神经网络（CNN） [17]。U-Net 采用 U 形架构，我们将在本节中对其进行讨论。基于 U-Net 发展出了许多变体，包括 UNet++ [24]、Attention UNet [13] 和 BNU-Net [4]。

本研究使用了三种归一化方法，分别是批归一化 [7], 、层归一化 [1], 和实例归一化 [21]。它们通常可以被视为一种数据预处理技术。深度学习中应用归一化，是为了实现更准确、更高效的训练。为了提高准确率，当特征分布范围较广时，归一化尤其有效，因为它会将所有特征限制在相近的范围内。归一化还有助于减小内部协变量偏移，即减弱训练过程中网络参数的变化。特征范围差异越大，数据归一化方法就越能有效地将权重限制在特定范围内，并防止其发生爆炸。因此，优化过程将会加快。

批归一化 [7] 是我们测试的第一种方法。它会在网络中对一个批次内前序激活的输出进行归一化。可以将其视为在神经网络的每一层进行数据预处理。使用批归一化时，我们会在 U-Net 中插入一个批归一化层。见图 1。

批归一化因能加快卷积神经网络（CNN）[7]的训练并提升其泛化能力而广受认可。然而，对于循环架构，这项技术的效果很差，因为它仅适用于 RNN 堆叠结构；在这种结构中，归一化沿垂直方向进行，以避免反复缩放的问题。

批归一化存在一些缺陷，限制了它作为降低深度神经网络模型中内部协变量偏移（ICS）的最重要技术的地位 [7]。在对前序模型的输出进行归一化时，会将批次除以经验标准差，再从结果中减去后续的经验均值。批归一化通常不适用于在线学习的流水线处理，因此会导致训练数据的泛化能力较差；这是由于每次迭代时批量大小发生变化所致。由此产生的偏移最终会影响输入数据的性能。为解决这一问题，人们提出了其他归一化方法。

层归一化 [1] 会对输入的各个特征进行归一化，这与批归一化中跨批次归一化的方式截然不同。均值和标准差的计算方法与批归一化类似。对于输入中的每个元素，都会计算其各个特征的均值和方差。我们在每个卷积块中应用了层归一化，并以指数线性单元（ELU）为基础。参见图2。

在批归一化中，每个批次使用相同的统计量；而在层归一化中，统计量是针对每个特征计算的，并且不依赖于其他样本。样本之间相互独立，因此将其应用于循环神经网络时很简单。“用于多切片 MRI 心脏分割的循环全卷积神经网络” [15] 一文的作者发现，在循环神经网络的应用中，这种方法的表现优于其他归一化方法。

批实例归一化 [11] 是批归一化和实例归一化 [21]的插值。采用实例归一化时，会针对每个输入组的每个通道计算均值和标准差。实例归一化与层归一化有些相似，但有一个明显的区别：层归一化会针对训练样本中的每个特征计算统计量，而实例归一化则针对每个通道计算。近年来，人们还发现实例归一化对生成对抗网络（GAN）有效。不过，实例归一化也存在一些问题：它适用于风格迁移，但无法处理对比度问题。因此，它不适用于图像分割任务。为解决这一问题，我们在第一个卷积块中同时使用实例归一化和批归一化，应用 ELU，并将其结果传递给下一层。参见图3。它兼顾了批归一化和实例归一化，模型可以通过梯度下降学习采用不同比例的组合。根据先前的研究 [11], , 在 CIFAR-10/100、ImageNet、迁移、风格迁移和图像分类任务中，批实例归一化的表现优于批归一化。

2.2 数据集

实验使用了 Sunnybrook 数据集 [2] 。该数据集由 Sunnybrook 健康科学中心心血管介入影像研究中心提供，专为 MICCAI 2009 的左心室自动分割任务而制作。真实标注掩膜由专家手动分割后提供。Sunnybrook 数据集收集了 45 名患者的医学影像（共 805 张），涵盖不同类型的心脏疾病：伴心肌梗死的心力衰竭（12 例）、不伴心肌梗死的心力衰竭（12 例）、肥大（12 例）和健康患者（9 例）。每位患者有 12 至 28 张影像。每个时间序列由 6 至 12 个二维电影序列图像堆栈组成，层厚为 8 mm，面内分辨率为 1.3 mm 至 1.4 mm。该数据集按 15:15:15 的比例划分为训练集、验证集和测试集。实验使用 NVIDIA GeForce Titan X Pascal GPU 进行。在比较每个训练轮次的计算速度时，也应考虑计算资源的性能。

2.3 模型

在本研究中，我们用于图像分割的模型是基于全卷积网络改进的 U-Net。我们使用指数线性单元（ELU）作为激活函数，

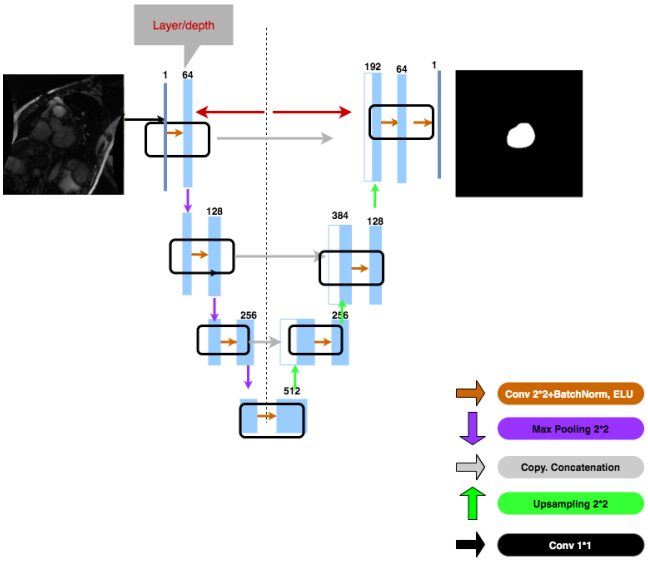

图1：BNU-Net卷积网络的架构。(a) 收缩路径负责特征提取。(b) 卷积层中的每次卷积后都会进行批归一化。

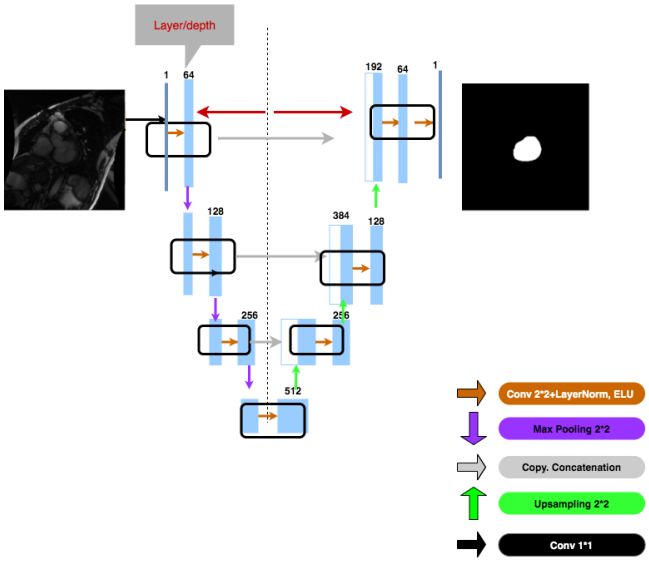

图2：所提出的全卷积网络 LNU-Net 架构。在卷积层中的每次卷积之后都会进行层归一化。

取代原始版本中的 ReLU。此外，我们还在模型中加入了归一化层，而原始 U-Net 并未考虑这一层。模型架构请参见图 1–3。

- Conv2*2 是一个使用 2*2 卷积核的卷积层。
- 为加快训练过程，使用 ELU 替代 ReLU。由于当 x 为负数时，函数值不再为 0，因此也避免了梯度消失问题。
- 归一化：对特征图进行归一化，以解决内部协变量偏移问题。
- Cropping2D 是一种用于裁剪特征图的裁剪层。它还用于减少拼接，以避免过拟合。
- 拼接是将来自下采样的两个不同特征图连接起来。• 上采样层用于增大特征的尺寸。

如我们所见，用于自动分割左心室的新型 U-Net 基于全卷积神经网络（FCN）架构的基本结构 [18]。我们所做的第一项改进是采用编码器架构。由于图像处理中需要大量乘加运算，训练用于医学图像分割的 FCN 是一个计算开销很大的过程。编码器架构有助于减轻计算负担并加快训练过程，尤其是在 Titan X 的计算能力有限时。

第二个问题是如何改进归一化。如前所述，我们尝试了三种归一化方法来改进模型，分别是批归一化、层归一化和批实例归一化。我们发现，对于医学图像分割，使用 FCN 进行训练时，内部协变量偏移是一个问题。这一问题受到输入特征分布变化 [23] 的影响，也会导致训练速度减慢。由于训练过程独立于初始数据分布，我们认为在研究中引入数据归一化是一个值得尝试的做法。

第三个问题是 FCN 中的跳跃连接。我们发现，使用 FCN 进行分割时，边缘定义不够清晰。使用原始版本的 FCN 时，图像之间的边界不够明确。

3 结果

3.1 实验研究

为了取得良好的学习效果，我们需要大量带标注的数据集。然而，在当前的医学领域，训练样本有限。因此，医学图像数据集采用了数据增强方法。Patrice 等人 [19] 于 2003 年首次提出弹性变形。我们对现有训练图像进行弹性变形，以扩大训练数据集的规模并提高模型的适应性。在本研究中，我们采用以下数据增强策略：仿射变换、弹性变形和旋转。

U-Net 的原始版本是处理左心室心脏图像的典型方法，因此我们首先使用 NVIDIA GeForce Titan X Pascal GPU 测试其性能。我们发现，U-Net 的 Dice均值仅为 0.87。训练时，如果将批次

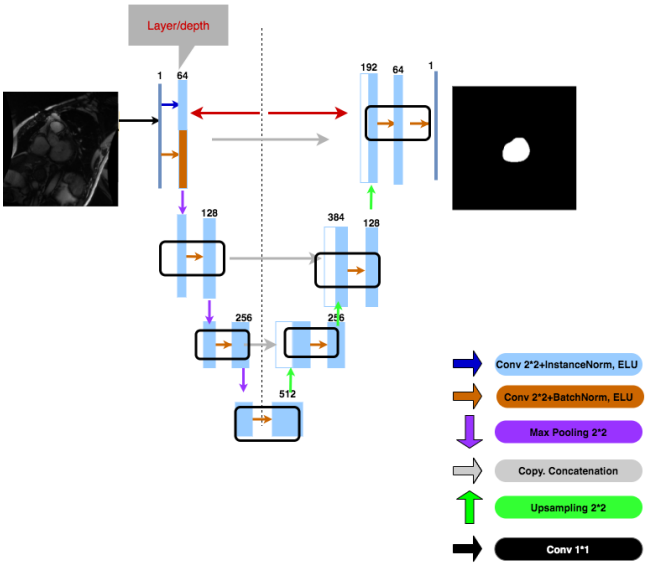

图3：IBU-Net 卷积网络的架构。第一个卷积层采用实例归一化。卷积层中的每次卷积之后都进行批归一化。

表1：不同归一化方法的Dice均值

	使用 ELU	使用 ReLU
实例-批归一化	0.94	0.93
批归一化	0.91	0.90
层归一化	0.89	0.88

尺寸为16。本研究提出了一种新颖的分割方案，其中包含批归一化和实例归一化，以提高分割性能。我们希望提升Dice均值并加快训练过程。

3.2 实验结果

我们使用带批归一化的 U-Net、带层归一化的 U-Net，以及带批实例归一化的 U-Net 来处理图像分割任务。Dice均值列于表 1。与 ReLU 相比，ELU 可能会引入更多计算。但当 x 为负数时，ELU 可以避免 ReLU 导致的梯度消失。表 1 展示了六种实验的 Dice均值：使用 ELU 和 ReLU 的批归一化、层归一化以及批实例归一化。我们希望测试不同激活函数对图像分割的影响，包括对 Dice均值和训练速度的影响。同时，我们也想了解归一化方法是否能带来更好的性能，以及在本例中哪种归一化方法最优。

从实验结果可以看出，新的激活函数 ELU 能有效提高训练过程中的 Dice均值。在每组比较中，采用 ELU 的模型性能均优于采用 ReLU 的模型。可以认为，ELU 更适用于心脏磁共振成像图像分割。

LNU-Net（图2）和IBU-Net（图3）的性能如表2所示。该表展示了LNU-Net和IBU-Net在使用和未使用数据增强时的表现差异。比较表2中的三种归一化方法后，我们发现批实例归一化是图像分割的最佳选择。正如我们在第二节中所述，批实例归一化结合了批归一化和实例归一化的优点，因此在图像分割任务中表现更佳。

与原版U-Net相比，ELU与批实例归一化的组合使Dice均值提高了8%，从0.87升至0.96，这是一项显著且可靠的改进。上表未展示训练速度方面的提升。原版U-Net每个训练轮次耗时11秒；而采用编码器架构、批实例归一化和丢弃连接后，每个训练轮次仅需8秒。训练速度提高了27%，这意味着在相同时间内几乎可以多处理三分之一的图像。加速得益于编码器架构和丢弃连接。它们能够减少训练过程中的计算量，同时也能避免过拟合。

图4和图5展示了三种不同心脏状况下输出分割结果的示例：伴心肌梗死的心力衰竭、肥大和健康患者。为评估所提出结构的性能，我们使用相同的Sunnybrook数据集和相同的数据划分，将我们的方法与其他团队在45例患者病例上报告的性能进行比较。不同归一化方法带来的性能提升幅度各不相同。表3显示，与其他团队提出的结构相比，使用带数据增强的IBU-Net可获得最佳的Dice均值、Dice标准差和平均垂直距离。

上述算法的实验结果表明，我们提出的方法提高了效率和有效性，并且由于所得Dice系数的提升，其性能优于卷积深度网络。

4 讨论与结论

在本研究中，我们通过改进U-Net，提升了左心室心脏图像分割任务的性能。数据预处理采用了批归一化、层归一化和批实例归一化。此外，还采用编码器架构和丢弃连接来加快训练并减少过拟合。本研究通过修改U-Net所作出的主要贡献如下。

首先，归一化方法有效提升了图像分割任务中的 Dice系数。在广泛使用的归一化方法中，我们发现批实例归一化更适合进行分割。结合批实例归一化和 ELU，我们取得了最先进的分割效果，Dice均值达到 0.96。其次，我们目前的方法提升了训练速度。每个训练轮次的训练时间

表2：模型输出与效率指标结果

	Dice均值	Dice标准差	灵敏度	平均垂直距离
使用数据增强的 IBU-Net	**0.96**	**0.02**	**0.98**	**1.91**
不使用数据增强的 IBU-Net	0.94	0.03	0.96	2.02
使用数据增强的 LNU-Net	0.90	0.11	0.96	2.29
不使用数据增强的 LNU-Net	0.89	0.14	0.95	2.46
BNU-Net [4] 使用数据增强	0.93	0.03	0.97	1.94
BNU-Net [4] 未使用数据增强	0.91	0.04	0.96	2.06
使用数据增强的 U-Net	0.88	0.09	0.96	2.48
未使用数据增强的 U-Net	0.87	0.11	0.95	2.51

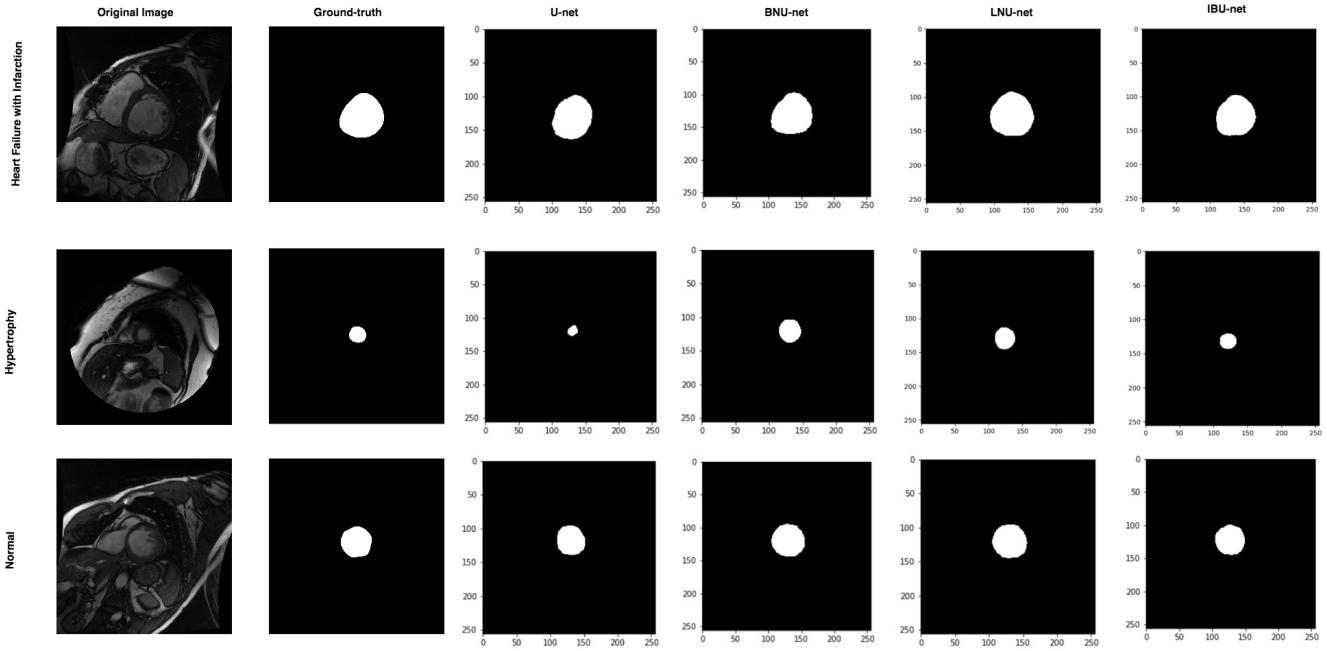

图4：分割示例 来自 Sunnybrook 数据集三种状况的原始输入结果。第一行包含 ns 伴心肌梗死的心力衰竭，第二行表示肥大，第三行显示健康患者。

表3：Sunnybrook 数据集分割的 Dice 系数和平均垂直距离（平均垂直距离），以及与当前最先进方法性能的比较

	Dice均值	Dice标准差	平均垂直距离（mm）
IBU-Net	**0.96**	**0.02**	**1.91**
X-Y Zhou [23]	0.92	-	-
Zhou [22]	0.93	0.06	-
Ngo 和 Carneiro [12]	0.90	0.03	2.08
Hu 等人 [5]	0.89	0.03	2.24
Huang 等人 [6]	0.89	0.04	2.16
Liu 等人 [9]	0.88	0.03	2.36

从 12 秒缩短至 9 秒。第三，与原版 U-Net 相比，我们的版本获得了更高的 Dice 系数，并且速度更快速度更快，这意味着我们以更少的计算资源取得了更好的结果。心脏电影磁共振成像是评估心脏功能的金标准 [8]。我们希望这项工作能够为医学应用中的实际图像分割工作提供帮助。我们希望这项工作能帮助经验丰富的医生和康复中的患者共同对抗心脏疾病。

参考文献

[1] Jimmy Lei Ba, Jamie Ryan Kiros 和 Geoffrey E. Hinton。2016年。层归一化。*arXiv* 预印本 *arXiv:1607.06450*（2016年）。[2] 心脏图谱项目。[无日期]。Sunnybrook心脏数据集。https://www.cardiacatlas.org/studies/sunnybrook-cardiac-data/。访问于：2021年。[3] 美国疾病控制与预防中心。[无日期]。心脏病统计数据与地图。https://www.cdc.gov/heartdisease/statistics_maps.htm。访问于：2021年。[4] Wenhui Chu 等。2019年。BNU-Net：一种用于短轴磁共振成像左心室分析的新型深度学习方法。载于*2019*年*IEEE*第*19*届国际生物信息学与生物工程会议（*BIBE*）。IEEE，731–736。

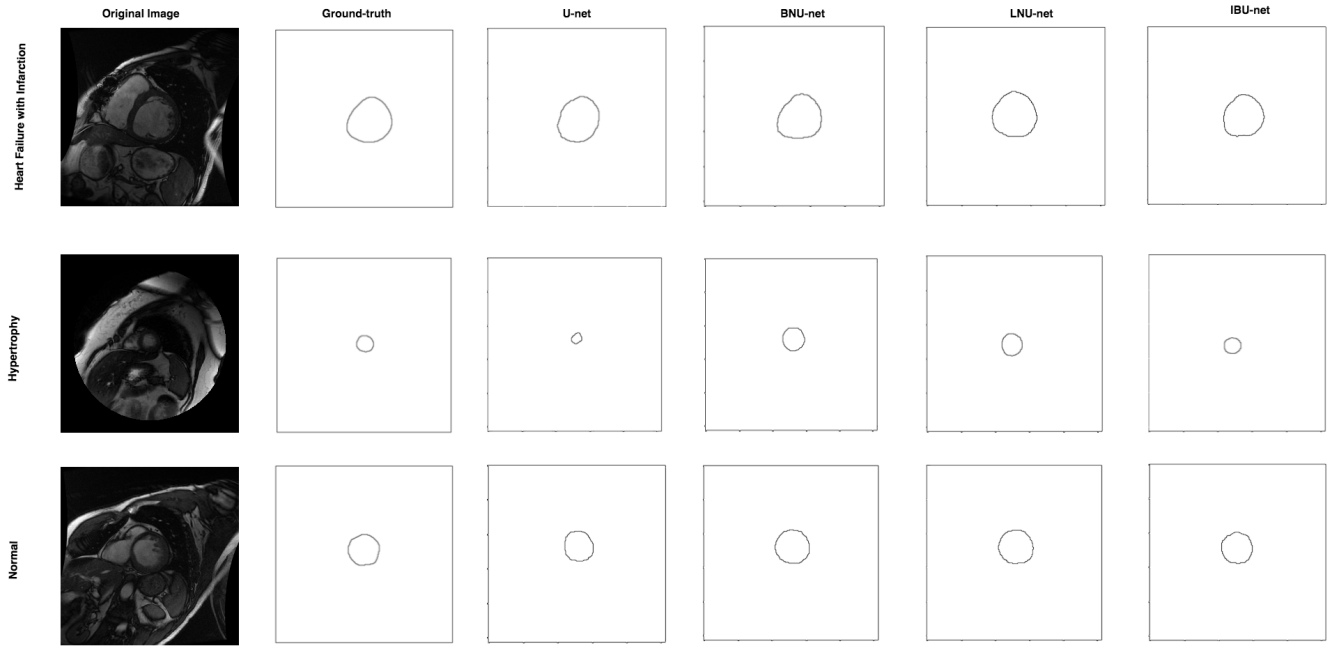

图5：我们的方法生成的一些分割结果。实线表示 Sunnybrook 数据集中的分割示例。我们比较了四种不同的网络方法，分别为 U-Net、BNU-Net、LNU-Net 和 IBU-Net。

[5] Huaifei Hu、Honghai Liu、Zhi Gao 和 Ling Huang。2013年。使用高斯混合模型和区域限制动态规划对心脏磁共振成像中的左心室进行混合分割。《磁共振成像》31卷4期（2013年），575–584。[6] Su Huang、Jimin Liu、Liang Choon Lee、Sudhakar Venkatesh、Lynette Teo、Christo- pher Au 和 Wieslaw L. Nowinski。2011年。一种基于图像的综合方法，用于从心脏短轴电影磁共振图像中自动分割左心室。《数字成像杂志》24卷4期（2011年），598–608。[7] Sergey Ioffe 和 Christian Szegedy。2015年。批归一化：通过减少内部协变量偏移加速深度网络训练。*arXiv* 预印本 *arXiv:1502.03167*（2015年）。[8] Thomas Küstner、Niccolo Fuin、Kerstin Hammernik 等。2020年。CINENet：基于深度学习的三维心脏电影磁共振成像重建，采用多线圈复值四维时空卷积。《科学报告》10卷1期（2020年），13710。[9] Honghai Liu、Huaifei Hu、Xianghua Xu 和 Enmin Song。2012年。使用拓扑稳定状态阈值处理和区域限制动态规划对心脏磁共振成像中的左心室进行自动分割。《学术放射学》19卷6期（2012年），723–731。[10] Jan Margeta、Ezequiel Geremia、Antonio Criminisi 和 Nicholas Ayache。2012年。用于从四维心脏磁共振成像数据中分割左心室的分层时空森林。载于*MICCAI*研讨会：心脏统计图谱与计算模型（*STACOM*）。[11] Hyeonseob Nam 和 Hyo-Eun Kim。2018年。用于自适应风格不变神经网络的批实例归一化。载于《神经信息处理系统进展》。2558–2567。[12] T. A. Ngo 和 G. Carneiro。2013年。结合水平集方法与深度置信网络对心脏磁共振成像中的左心室进行分割。载于*2013*年*IEEE*国际图像处理会议。IEEE，695–699。[13] Ozan Oktay、Jo Schlemper、Loic Le Folgoc、Matthew Lee、Mattias Heinrich、Kazu- nari Misawa、Kensaku Mori、Steven McDonagh、Nils Y. Hammerla、Bernhard Kainz 等。2018年。注意力U-Net：学习在哪里寻找胰腺。*arXiv* 预印本 *arXiv:1804.03999*（2018年）。[14] Caroline Petitjean 和 Jean-Nicolas Dacher。2011年。心脏短轴磁共振图像分割方法综述。《医学图像分析》15卷2期（2011年），169–184。[15] Rudra P. K. Poudel、Pablo La mata 和 Giovanni Montana。2016年。用于多层磁共振心脏分割的循环全卷积神经网络。*arXiv* 预印本 *arXiv:1608.03974*（2016年）。[16] Sandro Queirós、Daniel Barbosa、Brecht Heyde、Pedro Morais、João L. Vilaça、Denis Friboulet、Olivier Bernard 和 Jan D'hooge。2014年。四维电影心脏磁共振数据集中的快速自动心肌分割。《医学图像分析》18卷7期（2014年），1115–1131。[17] Olaf Ronneberger、Philipp Fischer 和 Thomas Brox。2015年。U-Net：用于生物医学图像分割的卷积网络。载于医学图像计算与计算机辅助干预国际会议。Springer，234–241。[18] Evan Shelhamer、Jonathan Long 和 Trevor Darrell。2017年。用于语义分割的全卷积网络。*IEEE*模式分析与机器智能汇刊39，4（2017年），640–651。[19] Patrice Y. Simard、David Steinkraus 和 John C. Platt。2003年。应用于视觉文档分析的卷积神经网络最佳实践。载于第七届文档分析与识别国际会议。IEEE，958–963。[20] Phi Vu Tran。2016年。一种用于短轴磁共振成像中心脏分割的全卷积神经网络。*arXiv*预印本 *arXiv:1604.00494*（2016年）。[21] Dmitry Ulyanov、Andrea Vedaldi 和 Victor Lempitsky。2016年。实例归一化：快速风格化所缺少的关键要素。*arXiv*预印本 *arXiv:1607.08022*（2016年）。[22] Xiao Zhou、Qiufu Li、Mali Shen、Peilin Li、Zeyu Wang 和 Guang Yang。2019年。采用实例层归一化的 U-Net 训练。*arXiv* 预印本 *arXiv:1908.08466*（2019年）。[23] Xi-Yao Zhou 和 Guang-Zhong Yang。2019年。用于二维生物医学语义分割的 U-Net 训练中的归一化。*IEEE*机器人与自动化快报（2019年），1792–1799。[24] Zongwei Zhou、Md Mahfuzur Rahman Siddiquee、Nima Tajbakhsh 和 Jianming Liang。2018年。UNet++：一种用于医学图像分割的嵌套式U-Net架构。载于医学图像分析中的深度学习与临床决策支持的多模态学习。Springer，3–11。