HARDC：一种新型心电图心搏分类方法，采用具有扩张卷积神经网络的层次注意力双结构循环神经网络检测心律失常

Md Shofiqul Islam[a, b], Khondokar Fida Hasan[c], Sunjida Sultana[d], Shahadat Uddin[e], Pietro Lio'[f], JulianM.W. Quinn[g] 和Mohammad Ali Moni[h, *]

[a]马来西亚彭亨大学计算学院，Gambang-26300，Kuantan，Pahang，马来西亚。[b]马来西亚彭亨大学（UMP）IBM 卓越中心、软件开发与集成计算中心，Lebuhraya Tun Razak，Gambang-26300，Kuantan，Pahang，马来西亚。[c]澳大利亚布里斯班 4000，乔治街 2 号，昆士兰科技大学（QUT）计算机科学学院。[d]孟加拉国库什蒂亚 7600，伊斯兰大学计算机与工程系。[e]澳大利亚悉尼，悉尼大学工程学院项目管理学院。[f]英国剑桥，剑桥大学计算机科学与技术系。[g]澳大利亚新南威尔士州达令赫斯特，加文医学研究所骨骼研究组。[h]澳大利亚昆士兰州圣卢西亚 4072，昆士兰大学健康与行为科学学院健康与康复科学学院人工智能与数据科学。

arXiv:2303.06020v1 [eess.SP] 6 Mar 2023

文章信息

关键词：扩张卷积神经网络 预处理 层次注意力 双向门控循环单元-双向长短期记忆网络 心电图 心律失常

摘要

基于深度学习的模型通过分析心电图信号对患者心搏进行分类，在检测心律失常方面取得了显著成功。为提升此类模型的性能，我们开发了一种新型混合式层次注意力双向循环神经网络与扩张卷积神经网络（HARDC）方法，用于心律失常分类。该方法解决了传统扩张卷积神经网络（CNN）模型忽视上下文相关性和梯度分散所引发的问题。所提出的 HARDC 充分利用扩张卷积神经网络和双向循环神经网络单元（双向门控循环单元-双向长短期记忆网络）架构生成融合特征。通过整合局部和全局特征信息及注意力机制，模型的预测性能得以提升。在 PhysioNet 2017 挑战赛数据集上，将融合特征与扩张卷积神经网络和分层注意力机制相结合后，训练出的 HARDC 模型在分类结果和特征提取的可解释性方面均显著改善。采用序列 Z 分数归一化、滤波、去噪和分割来准备原始数据以供分析。随后使用条件生成对抗网络（CGAN）从处理后的数据中生成合成信号。实验结果表明，所提出的 HARDC 模型显著优于其他现有模型；使用 MIT-BIH 生成的心电图时，其准确率达到 99.60%，F1 分数为 98.21%，精确率为 97.66%，召回率为 99.60%。此外，与常规卷积相比，该方法在使用扩张卷积神经网络时大幅缩短了运行时间。总体而言，这种混合模型为心电图信号压缩和高性能心电图识别提供了一种创新且经济高效的策略。结果表明，采用自动化且计算能力强的方法对多种心律失常信号进行分类，具有广阔的应用前景。

1. 引言

心电图（ECG）记录是一种常用的诊断方法，用于监测心脏活动。心电图记录中的信息可以显示心脏异常，并有助于诊断心脏病变，例如心律失常、缺血性心脏病以及心肌梗死的发生 [53]。心律失常是指由于电传导问题导致心搏频率异常，而心房颤动（AF）则是一种持续性且特别危险的心律失常类型，其心脏收缩速度极快。心房颤动及其他类型的心律失常可以通过心电图信号进行监测 [38]。目前，医疗专业人员通过对患者及其心电图信号进行临床评估，来识别心律失常及其严重程度。不过，自动化分析解决方案正开始涌现[8]。

一种基于机器学习的心电图信号自动检测方法，需要进行特征检测和

通讯作者：
*Mohammad Ali Moni m.moni@uq.edu.au (A.Moni) orcid(s): 0000-0003-0756-1006 (M.A. Moni)

提取，然后进行分类。然而，许多自动分类技术在实现足够准确的检测方面仍面临挑战[14] [10]。这也包括心电信号分类与标签标注方面的问题 [25], 数据标注 [21] , 可解释性 [56][13] [29], 效率 [19], 正确标注类别，以及处理多模态数据 [21] [17]。心电信号预处理过程中还会遇到其他具体挑战，包括标准化、处理各种心电信号模式、心电图信号中的波形变异性，以及长时程心电信号处理。

目前，心电信号的识别需要专家意见 -
来检测和诊断心律失常，但针对这一检测问题，已有多种混合方法被提出 [49][14] [10]。然而，基于深度学习的方法总体上优于传统机器学习技术
[42] [10] [38] [54] [22] [18] ，并在精确率和性能方面取得了出色的结果。深度学习方法在模型构建中使用多个算法阶段，并根据底层数据属性进行训练。深度学习技术，尤其是卷积神经网络（CNN）和循环神经网络（RNN），后者主要包含长短期记忆网络（ LSTM）和双向长短期记忆网络（Bi-LSTM），在心电信号处理中取得了显著成功 [49]。

卷积神经网络是深度学习研究中的常见技术
[53] [11] [51] [33] [45] [35] [23] [6] ，因为它在传统训练阶段同时执行特征提取和分类过程。卷积神经网络模型中串联了多个卷积层和池化层，形成能够提取内在输入特征的深度网络。由于卷积神经网络结构已被证明适用于计算量大的研究，因此非常适合用于心电信号识别机制[11][51][33]。Acharya 等人 [16] 构建了一种包含 11 层的卷积神经网络架构，可自动识别分段心电图信号中能够揭示可电击和不可电击室性心律失常的特征。卷积神经网络还被用于在不同心搏心电图片段间期内自动检测心律失常[48]。Yildirim 等人 [53] 采用一个 16 层深度卷积神经网络模型对长时程心电图数据进行分类。另一种广泛应用的重要方法是近期基于深度学习的研究中的长短期记忆网络 [38]。长短期记忆网络也用于心电图信号分类，并且已经开发出多种提高长短期记忆网络效率的方法。近期研究还将长短期记忆网络与卷积神经网络结合，采用混合方法，利用可变长度心搏识别心律失常[38]。Tan 等人 [51]使用一种采用卷积神经网络的长短期记忆网络，可自动从心电信号记录中检测冠状动脉疾病，且准确率令人满意。仅使用小波序列化作为网络输入，可显著提升基于长短期记忆网络的算法的性能 [53]。

循环神经网络（RNN）会遇到梯度消失问题，并且难以处理特征之间的长序列依赖 [2][20]。然而，先前的长短期记忆网络只能以一种方式对这类序列建模，因此开发了双向长短期记忆网络（Bi-LSTM），以同时沿正向和反向分析模式。尽管双向长短期记忆网络通常在各种设置下优于长短期记忆网络，但多项研究表明，它存在与数据重复相关的问题。Schuster等人 [42] 指出，尽管双向长短期记忆网络在某些应用中表现良好，但这项工作并未说明如何有效利用和结合正向与反向的特征表示，并且网络存在信息冗余问题。根据Pascanu等人[43], 的研究，双向长短期记忆网络容易出现信息冗余和梯度爆炸问题，因此不适用于轻量级设备。

我们采用一种基于混合深度学习的心律失常诊断方法，从心电图数据集中自动检测心房颤动。我们提出的方法包括数据处理、合成信号生成、特征提取和分类。该方法结合了四个主要阶段：预处理后，利用条件生成对抗网络（CGAN）生成合成心电图；双向循环神经网络；扩张卷积神经网络；以及用于提取特征和分类心电图的分层注意力层。预处理的第一阶段需要进行峰值检测和数据分割，以收集输入数据。随后将这些数据输入第二阶段，该阶段采用扩张卷积层和两个双向长短期记忆网络（BiLSTM）-双向

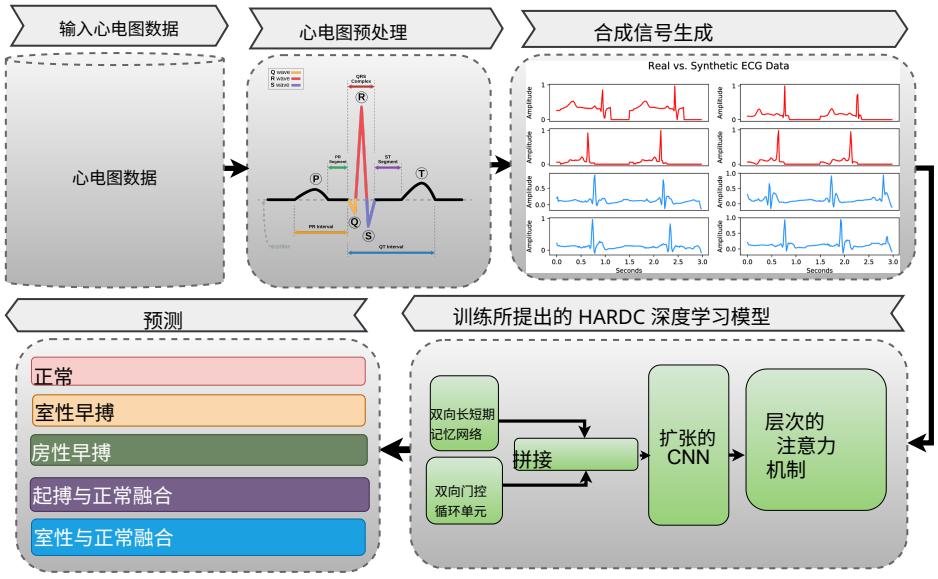


图1：HARDC模型的整体基本流程图。

门控循环单元（BiGRU）（双向长短期记忆网络-双向门控循环单元）模块，以完成自动特征提取。随后，将心电信号片段输入一个膨胀卷积网络，该网络包含两个全连接层和一个SoftMax层。生成的输出随后在扩张卷积神经网络层运算完成后，传递至分层注意力层进行最终分类。我们提出的方法论的基本步骤通过图中的流程图展示。1。

最后，我们对所提出方法的性能进行了测试评估。利用广泛的
从双向长短期记忆网络-双向门控循环单元中提取的特征，以及从扩张卷积神经网络层中快速提取的相关特征，这种层次注意力方法提高了特征提取的可解释性。这提升了心电信号分类的预测准确率。

总而言之，本文的主要贡献如下：首先，提出一种改进的双向长短期记忆网络-双向门控循环单元方法，能够捕捉对心电信号分析至关重要的不同尺寸及长程特征。其次，开发了一种改进的层次注意力方法，用于优化特征权重，从而提升心电特征选择的可解释性，并改善心电信号分类结果。最后，我们提出一种新颖的扩张卷积神经网络，能够以更少的网络参数处理更复杂的特征，以更低的复杂度提升分类性能。我们的方法无需传统的手工特征提取方法，同时能够提供准确的结果并提高可解释性，因此为心电信号分类提供了一种新颖的方法。

2. 相关研究

心律不齐会增加罹患心血管疾病的风险。此外，心房颤动、肥胖、高血压、心房期前收缩或三尖瓣疾病、阻塞性睡眠呼吸暂停、甲状腺功能亢进和酒精依赖也会降低生活质量，并增加死于心血管疾病的风险。心房颤动是一种已知的心律失常疾病，需要进行诊断和管理，以避免相关后果 [14]。近年来，一些现有的传统机器学习方法 [54][1]已被证明在心电图分类方面表现良好。支持向量机分类器是机器学习方法中常用的一种。Ye 和 Coimbra [51]提出了一种支持向量机分类器，使用小波系数和 RR 间期（在心电图中，指 QRS信号中两个连续 R波之间的时间），对时长为 0.83 秒、样本数可变的心电信号进行分类。Chen等人 [11]开发了另一种支持向量机分类器，利用 RR 间期和心电图投影矩阵对变长心电信号进行分类。LDA-P

多层感知机（线性判别分析（LDA）-多层感知机）[33] 方法使用时间和形态学特征，XGBoost 使用手工特征 [45],也已用于心电图分类。基于支持向量机的心电图分类也采用了 RR间期、小波系数和形态学描述符 [36]。Martis 等人开发了结合主成分分析（ PCA ）、离散小波变换（DWT）、高阶谱（HOS）和独立成分分析（ICA）特征的最小二乘支持向量机分类器，用于心电图信号分类。这项工作使用了更复杂的特征，因此计算成本更高。 [34]。本节将深入探讨与本文直接相关的方法，即利用心电图信号检测心房颤动的机器学习和深度学习方法。需要注意的是，篇幅所限，我们无法在此描述所有采用的方法。

2.1. 传统机器学习

目前已有一些传统机器学习方法。SVM [51] [11] [34] [33] [36][16] [50], XGBoost[45], 随机森林 [30] 和 LDA-MLP [33] 是近期在心电图分类中表现有所提升的方法。这些方法的训练时间较长，且准确率低于其他深度学习方法。支持向量机分类器是机器学习方法中常用的一种。某种使用支持向量机分类器的方法采用小波系数和 RR间期对时长为 0.83 秒的心电信号进行分类 [51]。该方法的准确率为 89.02%，精确率为 62.2%，召回率为 56.27%，但它非常依赖特征工程。另一种采用 RR间期和投影矩阵的支持向量机算法用于变长度心电图信号分类 [11]。该方法对时长为 0.83 秒的心电图进行分类，可识别 15 个不同类别，准确率达到 98.46%，但时间和空间复杂度略高。另一种方法采用 XGBoost 算法，利用人工设计的特征 [45] 对心电图进行分类，但在异常类别预测方面表现不佳。还有一种简单的支持向量机方法，利用 RR间期、小波系数和形态学特征检测心律失常 [36]。大多数用于心电图信号分类的支持向量机分类器 [38][36][51] 准确率在 91% 到 97% 之间，但大多非常依赖特征工程。SVM [16] 算法使用主成分分析、离散小波变换、高阶谱和独立成分分析特征对心电信号进行分类，准确率最高可达 98.91%。由于特征处理量较大，该方法的计算复杂度相对较高。

2.2. 深度学习

传统机器学习方法速度可能更快，但无法处理大型数据集 [38][36][51]。最常见的深度学习方法是卷积神经网络。与其他机器学习 [38][36][51]和深度学习方法 [52][14]相比，它在分类 [58][27] 方面表现出更高的准确率。我们列举了一些用于从 MIT-BIH（麻省理工学院-贝斯以色列医院）数据库中检测心律失常的基本深度学习技术。另一种卷积神经网络方法 [27]利用患者特异性特征检测心律失常。这种技术预测心律失常的精确率为 99%。该方法的主要局限在于对关键异常心搏的表征。另一种卷积神经网络方法 [58] 在对长度为 0.5 秒、包含 200 个采样点的心电图信号进行分类时，准确率达到 92.70%。集成算法和偏置损失过滤是该方法的主要局限。Yildirim 等人 [54]开发了一种较新且广受欢迎的基于卷积神经网络的方法，通过生成合成数据并对原始数据进行重缩放，对包含 260 个采样点的心电信号进行分类。该方法在对时长为 1 秒、包含 360 个采样点的信号进行分类时，准确率达到 94.03%。另一种卷积神经网络方法结合 RR间期 [44] 使用随机投影对心搏进行分类。该方法对可变长度的心搏信号进行分类时，准确率为 88.33%，精确率为 64.20%，召回率为 57%。

2.3. 混合深度学习

混合深度学习方法因其性能和适应性优于传统方法而应运而生。基于混合深度学习的方法是不同通用深度学习技术的组合

另一种混合方法结合卷积神经网络与循环神经网络，并使用基于患者的特征检测心律失常。该方法在可变长度的心电图数据上取得了98.10%的准确率 [38]。其准确率略低于常规支持向量机 [16]。Yıldırım等人 [53] 开发了一种使用深度卷积神经网络并对信号进行重缩放以检测心律失常的方法。该方法可对长度较短的

（0.015秒）心电图进行分类，精确率为91.33%。此外，同一批作者还开发了一种使用基于注意力机制的长短期记忆网络来处理基于编码的信号的方法[52], ，该方法的准确率为99.11%，但仅适用于长度较短的心电图数据。另一种混合模型结合卷积神经网络与双向长短期记忆网络，并利用四个RR间期信息 [10]对心电图信号进行分类。该方法的准确率、精确率和召回率分别为96.77%、77.8%和81.2%。其性能应能更好地适应不同的数据。Ma等人开发了扩张卷积神经网络 [32]。该方法使用去噪和归一化后的数据检测心律失常。这项技术的精确率达到98.65%。该技术缩短了运行时间，但需要进行更多归一化和预处理工作，有时会导致预测错误。Dang等人 [14] 开发了一种深度卷积神经网络与双向长短期记忆网络相结合的方法，通过分析RR间期、PR间期和QRS波群的特征对心电信号进行分类（QRS表示心室去极化，由“Q”波、“R”波和“S”波构成）。该方法将100条心电图信号分为五类。该方法对五类心电图数据的分类准确率达到96.59%。其主要局限在于执行耗时较长，且不具备实时应用能力。Jin等人 [26]开发了一种将注意力机制与卷积神经网络-长短期记忆网络结合、用于分析多域特征的技术。该方法预测五种不同心电图信号的准确率达到98.51%，但适应性较弱。一种采用卷积神经网络-双向长短期记忆网络的新技术 [49] 侧重于360个样本的原始数据特征。该方法取得了高达99.11%的准确率，但其泛化能力仍有提升空间。

基于残差通道注意力网络 [47] 和双向门控循环单元的多变量心电图分类方法，对长、短心电信号的准确率分别达到 96.7% 和 97.7%。该方法充分利用了导联注意力、形态特征和时域特征。其局限性在于未展示实时数据分析结果，且准确率略低于某些相关方法 [38] [27]。

2.4. 研究动机

现有方法及其局限性促使我们开发一种更新、更准确的心电图分类方法。传统机器学习 [51] [11] [34] [16] [50] [33]算法在使用时域特征时，准确率比传统深度学习（卷积神经网络）方法高出近 1%，达到 99%。[38] [36] [51] 使用小波特征时，基于支持向量机（SVM）的方法[16]在准确率方面的表现也几乎相似。合成信号生成也能充分平衡信号 [38]]。根据近期的一项综述，我们发现，基于注意力机制的模型[47]能够捕捉最相关的特征，而扩张卷积神经网络 [10] [52] [14][14] 能够以更快的速度提取特征 [32]。这进一步促使我们开发一种将注意力机制、扩张卷积神经网络与双向循环神经网络结合起来的心电图分类新方法。此外，我们重新处理了利用小波和 QRS 波群特征生成合成信号的任务，也略微提升了性能。

我们认为，现有的心电图分类通用机器学习（ML）方法速度更快，但其准确性和可重复性不如深度学习和混合深度学习方法。然而，所有方法都存在一些问题，例如特征提取的可解释性不足、运行时间长、内存需求较高、适应性或泛化能力不足、准确率较低，以及预测损失较高。我们针对这些问题提出了下文所述的方法。

3. 数据信息

本研究开发了一种新型的基于注意力的双向门控循环单元-双向长短期记忆网络与扩张卷积神经网络技术，用于检测心律失常心搏。所提出的系统采用HARDC方法对心电图心搏进行压缩和合成。首先，将每条心电图轨迹转换为低维编码信号。双向门控循环单元-双向长短期记忆网络模型提取特征，随后由扩张卷积神经网络接收循环神经网络层的输出。最后，采用层次注意力对合成信号进行分类。之后，完成心律失常心搏检测和合成信号识别。实验使用了来自五种不同心电图心搏类型的109446条分段信号。

表1 心律失常类型

数据信息		
心电图类别	样本 Size	百分比
’正常’	90589	82.8%
’起搏与正常融合’	8039	07.3%
’室性早搏’	7236	06.6%
’房性早搏’	2779	02.5%
’室性与正常融合’	803	00.7%
总计	109446	100%

3.1. 数据集

我们使用的数据取自 PhyoNet 网站，且可公开获取。心脏病学家对心电图心搏进行了标注，诊断结果则通过协商达成一致。MIT-BIH数据库中的心电图记录[37] 构成了我们方法的基础。MIT-BIH心律失常数据用于预测心律失常。对于心电图分类技术而言，这被视为金标准评估数据 [37]。该数据库包含48条半小时的心电图记录，采集对象为在 BIH心律失常实验室接受检查的患者。每条记录均包含两路心电图导联信号，时长各为30分钟，采样率为每秒360个样本。研究人员通过人工方式，对用于心搏分类方法的数据进行了标注和核查，并记录时间信息。总计标注了109,492个心搏。本研究考察了五种心电图信号，以检测心律失常。表1 展示了不同的心律失常类型及各类别的数量。表1列出了每个类别的信号数量。该表清楚地显示，“正常”类别占比最高，为82.8%；心电图类别“起搏与正常融合”的占比较低。为展示数据集中187个特征所对应的信号，图2呈现了各类别的心电信号。每条信号对应一个类别，长度为175毫秒，包含一个心搏。

3.2. 使用不同预处理方法提升性能的动机

为了降低噪声，使心电图更清晰、更易于解读，心电图预处理是一项艰巨的任务。

心电信号预处理中采用滤波，以实现高速、低延迟且计算开销更小的设计。由于该信号处理方法是为远程医疗系统设计的，因此噪声消除是首要目标。采用低、高截止频率分别为 0.5 Hz 和 48 Hz 的切比雪夫II型带通滤波，可去除基线漂移噪声以及心电信号中的干扰[4]。

心电信号去噪是一项重要的预处理步骤，可降低噪声，并突出心电图数据中的特征波形[9]。在我们的方法中，Daubechies小波去噪工具有助于压缩心电图数据并去除其中的噪声 [46]。

对心电信号进行分割的目的是检测其中的波形和片段（包括间期），并根据其时间特征和形态特征与已知模式进行比较 [3]。适当的分割过程有助于了解实际的类别标签。在我们的方法中，近期的一种方法采用LPD [28] 分割过程，以提升分类任务中的信号幅值。

心电图归一化可以减少干扰，是心电图信号处理中的关键步骤。归一化方法不仅能生成一致的信号，以供后续自动化处理，还能提供清晰的视觉解读 [24]。归一化过程能够妥善处理过拟合和欠拟合问题，使心电信号更具意义 [57][12]。

心电图信号可能受到各种噪声和失真的影响。因此，在输入深度学习算法之前提高信噪比（SNR）至关重要。为预处理心电图信号，我们执行了附录8.1节中概述的步骤。首先，对心电图心搏进行预处理，并利用条件生成对抗网络模型生成合成信号。

3.2.1. 合成数据的生成

生成对抗网络模型在合成信号生成中非常流行 [15]。合成数据用于弥补五个类别中心电搏动数量的不平衡。经过序列预处理（Z分数归一化、滤波、去噪和分割）后，通过处理原始归一化心电图信号生成合成数据样本。由于N类的数量最多，其片段保持不变。将N类片段与增加的片段关联起来。数据增强后，总数

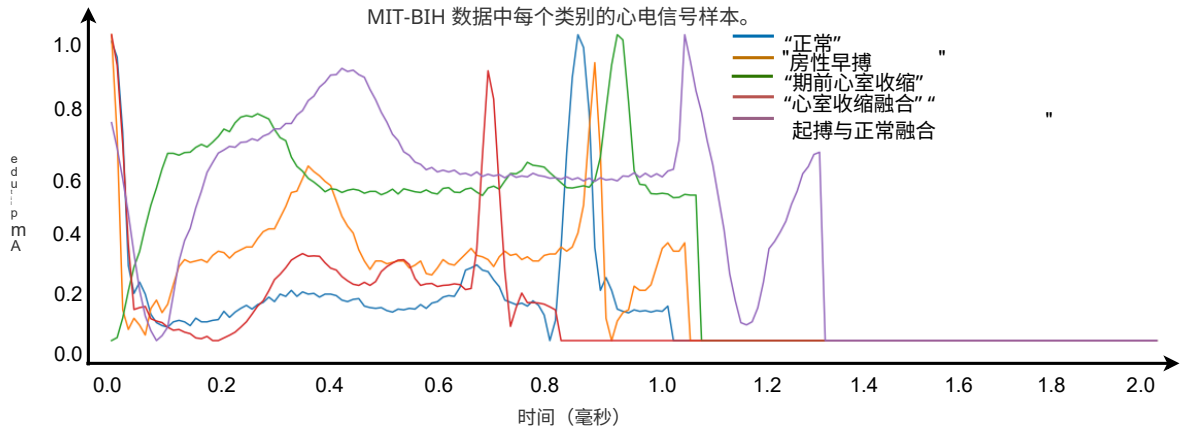


图2：带样本的心律失常类型。

包括五个类别的片段数量有所增加。合成心电信号生成的整体流程如图3所示。在该条件生成对抗网络模型中，我们将原始信号输入条件生成对抗网络模型的判别器部分，并将带有潜变量的噪声输入生成器部分。在生成器部分，编码后的卷积运算输出被送入编码双向长短期记忆层。全连接层用于判断样本是真实还是伪造，并根据判断结果将输出转发至条件生成对抗网络模型的判别器部分。条件生成对抗网络模型在判别器阶段经过激活函数运算后生成合成信号。图4展示了原始心电信号和生成的心电信号。

条件生成对抗网络模型的置信度通过损失来衡量，损失为 $Loss = E_x.[log(Dis(x))]+E_z[log(1-Dis(Gen(z))]$. 生成器从原始数据中获取真实输入，并向其中注入额外噪声。Dis(x) 会识别假信号，而 E_x 或 E_z 会给出信号真实性的评分。在损失函数的第二部分中，Dis(x) 被 Gen(z) 替代。实际上，判别器的输入是生成器 G 遇到随机源张量 z 时的输出。生成器会最大化或最小化损失，而判别器则会降低损失。

最后，信号经过预处理后，生成合成信号。下一步，我们使用 HARDC 模型对合成信号进行分类。随后，双向长短期记忆网络-双向门控循环单元层使用合成信号进行特征提取，然后将其传递到下一层。

4. 方法论

本节通过介绍多标签心电信号分类方法、流程图、深度卷积神经网络学习模型、双结构循环神经网络、层次注意力层及其他实验因素，讨论这些相互关联的方法。此处的图1展示了 HARDC 模型的整体流程图。首先，对序列进行预处理（Z 分数归一化、滤波、去噪和分割），然后使用条件生成对抗网络生成合成数据样本。

多标签分类是一种包含两个以上类别的方法。在这种分类中，各标签并非互斥。分类过程只为每个样本确定一个等级。现实中，将心电信号标注为一种或多种类型，是心搏多标签分类的一种应用。我们专注于心电信号多标签分类。对于 D 个数据集，我们执行了一个多分类任务，如公式（1）所示。有关此数据收集的更多详情，请参见本技术部分的 I 节。数据中包含心电信号特征，以及向量阶段的每个声明集。

$$D = (F, E)|F \in Documents, E \in (0, 1)^L \quad (1)$$

其中，F 表示基于心电图的特征，数据集 E 包含 N 个（心电图类别标签数量）目标类别，而所示心电图类别为递增级别 L。

4.1. 主要分类模型

我们的 HARDC 方法是一种混合深度学习方法。我们提出了一种新的层次注意力网络，

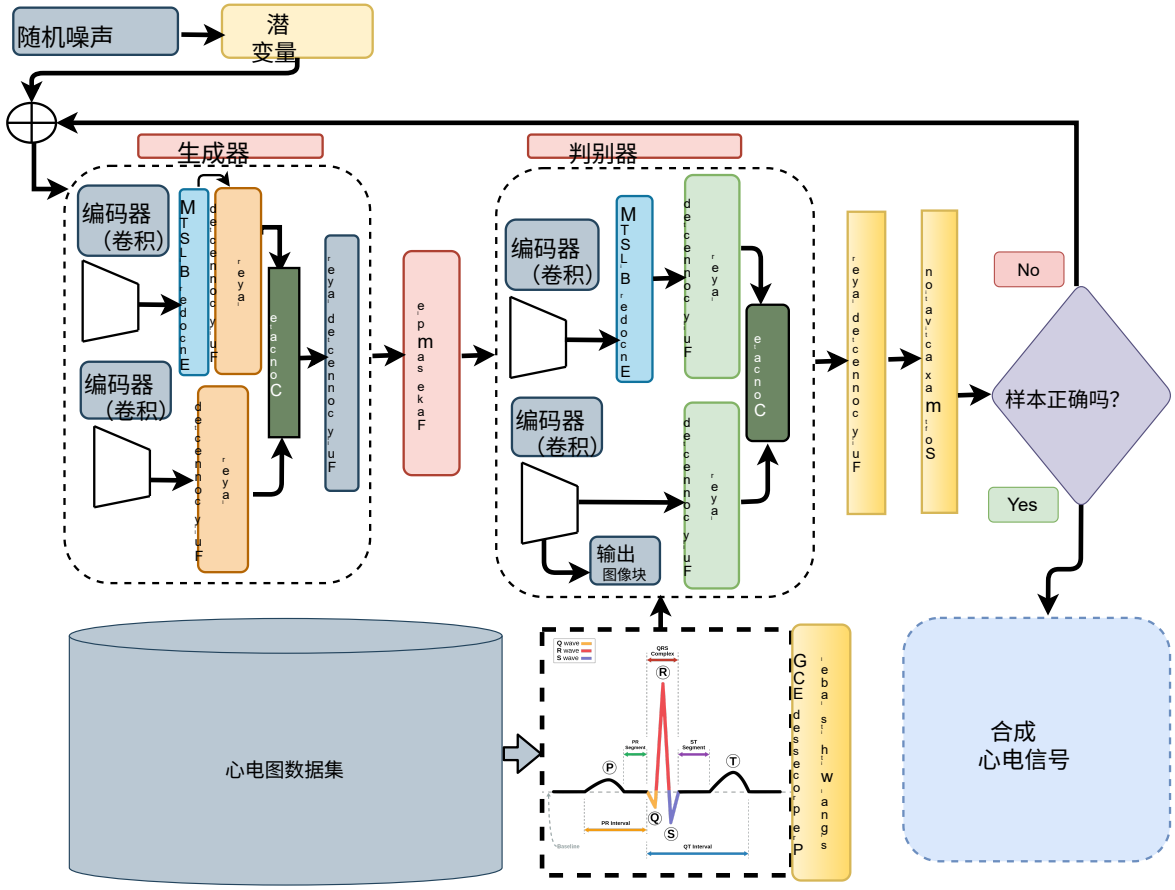


图3：用于生成合成信号的条件生成对抗网络模型。

在我们的心电信号分类方法中，采用了具有多层级结构的双向循环神经网络和扩张卷积神经网络（卷积神经网络）。该方法按以下步骤运行。

1. 首先收集基准数据，然后对原始数据进行预处理（Z 标准化、滤波、去噪和分割）。

2. 完成所有预处理任务后，生成合成信号以平衡信号。随后将合成信号输入双向门控循环单元-双向长短期记忆网络层进行特征提取。

3. 双向门控循环单元-双向长短期记忆网络为扩张卷积神经网络的深层创建一种向量路由算法，以提取长距离特征信息。

4. 扩张卷积神经网络执行更快速的特征提取操作，以获取相关特征。

5. 注意力层随后接收扩张卷积神经网络特征，以处理最相关的心电图信息，并将结果传递到下一层进行预测。

6. 使用不同指标分数对模型在测试数据上的表现进行评估。

我们提出的模型采用分类交叉熵、Adam 优化器和 ROC 评估方法。多标签心电图识别模块包含这些层。模型的整体顺序处理流程图如图 6所示。

4.1.1. 双向门控循环单元-双向长短期记忆网络层

下文将简要讨论我们模型中的 BIGRU-BiSTM 层。在我们的方法中，我们使用双向 GRU 和 LSTM。这使 GRU 能够处理较长时间段的信息，并通过少量受限的非线性变换进行反向传播，从而降低梯度消失的可能性。双向结构可以改变“左侧”和“右侧”上下文的

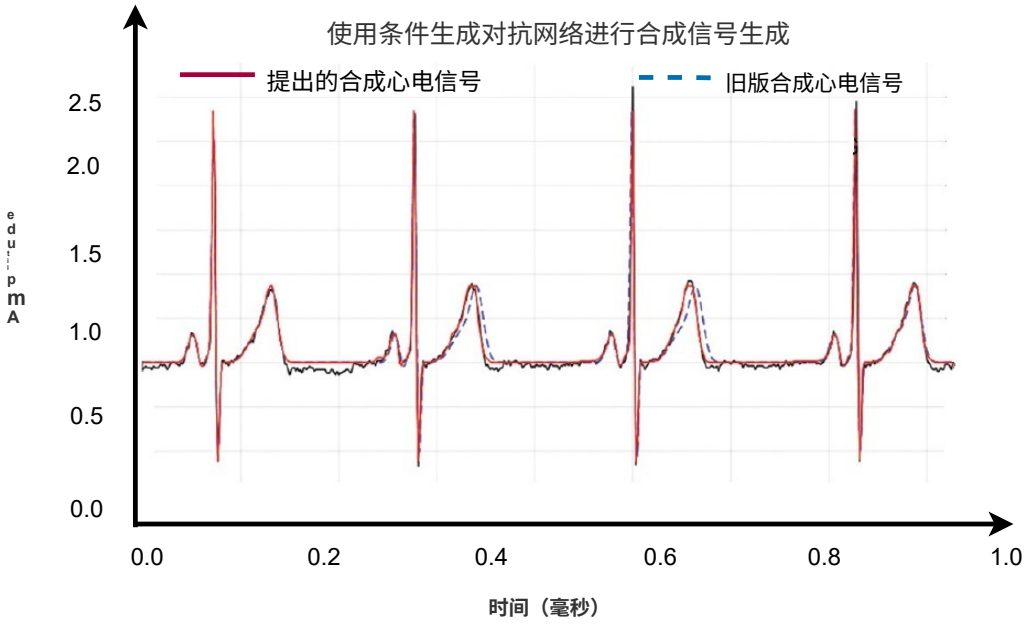


图 4：所提出的合成心电图生成示例

频繁模式。该双向门控循环单元包含两个模块，分别有 64 个和 128 个单元。在这一层中，我们将常规丢弃率降至 0.5，并将序列作为真值返回。双向长短期记忆网络-门控循环单元常用于 ECG 信号分类。对于单向长短期记忆网络-门控循环单元，数据从后向前传递。在双向长短期记忆网络-门控循环单元中，得益于两个隐藏状态，数据会自动双向流动。因此，双向长短期记忆网络似乎更能理解情境 [14]。双向长短期记忆网络 [52] 用于对网络可用的数据片段进行缩放。双向循环神经网络的基本运行序列如图所示 5(a)。

BiGRU sequences are as below in equation (2) to (4):

$$\overrightarrow{bg_t} = (\overrightarrow{GRU_t} * \overrightarrow{h_{t-1}}).x_t \tag{2}$$

$$\overleftarrow{bg_t} = (\overleftarrow{GRU_t} * \overleftarrow{h_{t-1}}).x_t \tag{3}$$

$$bg_t = (\overrightarrow{h_t} * \overleftarrow{h_t}) \tag{4}$$

双向长短期记忆网络序列按如下公式进行运算（5）至（7）：

$$\overrightarrow{bl_t} = (\overrightarrow{LSTM_t} * \overrightarrow{h_{t-1}}).x_t \tag{5}$$

$$\overleftarrow{bl_t} = (\overleftarrow{LSTM_t} * \overleftarrow{h_{t-1}}).x_t \tag{6}$$

$$bl_t = (\overrightarrow{h_t} * \overleftarrow{h_t}) \tag{7}$$

因此，BiGRU和BiLSTM层编码器会生成如下公式所示的变量序列

(8) 至 (9)::

$$BG = bg_1, bg_2, ..., bg_n \in R^{n*d^{\sim}} \tag{8}$$

$$BL = bl_1, bl_2, ..., bl_n \in R^{n*d^{\sim}} \tag{9}$$

并行执行得到的BiGRU和BiLSTM输出会合并后传入膨胀卷积运算

该层通过双向长短期记忆网络-双向门控循环单元的双向运算，处理心电信号的长程特征。

4.1.2. 深度卷积神经网络层

这是 HARDC 模型中最重要的层级之一。卷积层的深层结构旨在提取层次化细粒度特征，作为架构内容描述。本层从膨胀卷积神经网络层获得的特征中快速提取相关特征。与直接对预训练权重执行卷积运算的普通卷积神经网络不同，我们的深度卷积神经网络接收包含空间信息的双向门控循环单元层和双向长短期记忆网络层的输出。实际上，双向门控循环单元和双向长短期记忆网络经过拼接后被送入该膨胀卷积神经网络层，以获得 RV 输出。图 5(b) 展示了少量卷积块，如下所述。膨胀卷积神经网络层获取双向长短期记忆网络和双向门控循环单元拼接后的特征，如公式 (10) 至 (12)：

$$RV_{BiGRU} = BG = bg_1, bg_2, ..., bg_n \in R^{n*d^{\sim}} \tag{10}$$

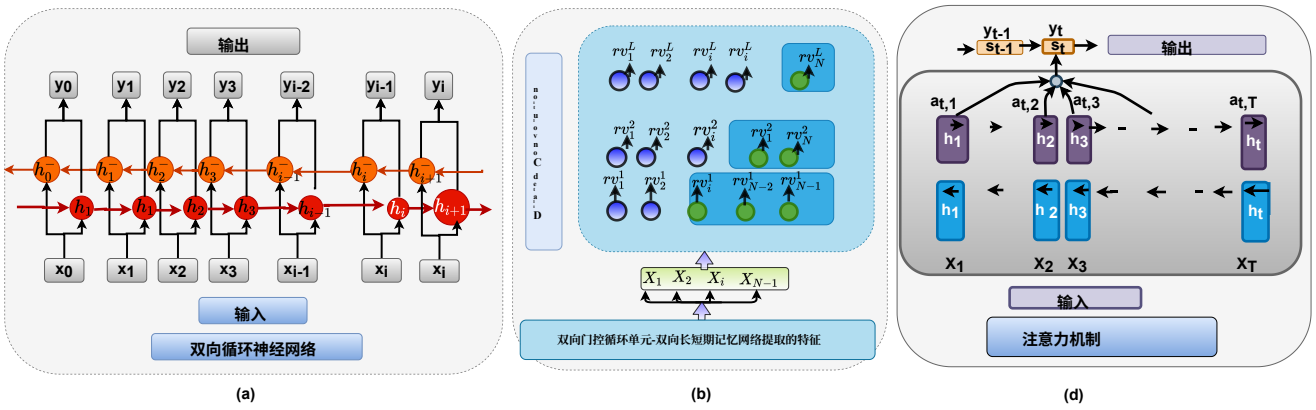


图5：层概览 (a) 双向循环神经网络 (b) 分层注意力机制，以及 (c) 扩张卷积神经网络。

$$RV_{BiLSTM} = BL = bl_1, bl_2, .., bl_n \in R^{n*d^{\sim}} \quad (11)$$

$$RV_l = concatenation(RV_{BiGRU}, RV_{BiLSTM}) \quad (12)$$

输入的输入序列的标量分量 d。因此，输出可以视为每个中间架构的最终部分。

$$RV^1 = [rv_1^l, rv_2^l, ..., rv_n^l] \in R^{n*d^{\sim}}, l \in (1, L) \quad (13)$$

卷积块的总数为 L，块滤波器的阶数为 k。我们只看第 l 个块的数量。

$$W^l \in R^{k*w*k}, W^l \in R^{k*w*d^{\sim}} \quad (14)$$

此滤波矩阵中仅使用一个 k 阶滤波器核和 w 个向量。下面介绍如何调整两个相邻块。

$$RV = F(W^1, RV^{l-1}) \quad (15)$$

它基本上是将滑动滤波器应用于长度为 w 的输入序列，并以其作为窗口，其中 f 表示代数函数。形式上，$rv_1^l \in RV^l$ 的计算如下：

$$rv_t^l = ReLU(W^l \oplus [rv_{t+1r}^{l-1}]_{t=0}^{w-1} \quad (16)$$

⊕符号表示卷积过程。对于卷积神经网络，r 用于描述深层的数量。激活函数修正线性单元（ReLU）本质上是一种修正函数。双向门控循环单元—双向长短期记忆网络技术是一种深层技术，其中每个块最多增加 2^{L-2} 层，且所有块字段的最大宽度为 $(w-1)2^{L-1}$。这一深层就是我们使用的特征。典型的深度学习模型层会使其权重呈指数级增长，而不是随网络深度增加而使相应的感受野权重线性增长。公式 $(w-1)*2^{L-1}$ 可以计算感受野。最后，得到 RV^1、RV^2、……、RV^l 的分层映射。卷积神经网络的结果通过向量路由生成，卷积过程为 rv_l^N。动态方法将扩张卷积输出预测为值 V_io，即经常变化的连接系数。上游层和下游层的卷积均使用一组耦合系数。SoftMax 用于通过零偏置集计算它。较大的 CV_{io}有助于正确分类。目前 $RV^1 = [rv_1^l, rv_2^l, ..., rv_n^l] \in R^{n*k^{\sim}}$，$l \in (1, L)$ 第 l 个卷积块的输出表示为 $R^{n*k^{\sim}}$，$l \in (1, L)$。每个 rv 表示由 k 个滤波器映射生成的一个 n元语法特征，随后我们将其用作输入卷积。现在取 $CV^1 = [CV_1^l, CV_2^l, ..., CV_n^l] \in R^{M*d_V}$。卷积的目标是 dv，其中 M 表示目标卷积的数量，dv 表示输出卷积尺寸。目标是将 RV^l 路由到 CV^l，以提高特征提取可解释性和信息分类能力。预测向量 $\tilde{rv}_{J|l}$ 用于检查待传递的原始向量，它由 rv_i 与变换矩阵 W_j相乘得到。

$$\tilde{rv}_{J|l} = rv_i * W_j \quad (17)$$

该策略通过扩展小向量并将大向量压缩为单位向量，提高了复杂路由方法的管理和信息交换效率。我们采用迭代式分层路由方案，在两个卷积层上计算中间状态。这种分层注意力机制提高了基于双向长短期记忆网络-双向门控循环单元的长程独立特征以及从空洞卷积神经网络层快速提取的相关特征的特征提取可解释性，

从而有助于提高预测中心电信号分类的准确率。在 Softmax 路由函数中，b_{ij} 被设为零，并通过 a_{ij} 缩放收缩进行修正，如公式（18）至（19）所示。样本的大小决定了其 a_{ij} 一致性。

$$a_{ij} = cv_i * \widetilde{rv}_{J|l} \tag{18}$$

$$b_{ij} = b_{ij} + a_{ij} \tag{19}$$

通常，目标卷积 M 表示包含孤立类别的文本类别数量。其系统或许能够区分“背景”数据（如停用词），但无法区分与任务相关的词语。孤立类别方法消除了类别重叠，并实现了更高效、更具可扩展性的卷积路由。算法1描述了分层路由方案。每个自主目标卷积层都会为功能的第 l 个协同进化块生成 $CV^1 = [CV_1^l, CV_2^l, ..., CV_n^l] \in R^{M*d_V}$。在统一 CV 中，我们结合目标卷积的结果。

$$CV^1 = [CV^l, CV^l, ..., CV^l] \tag{20}$$

操作完成后，结果将传递至分层注意力层。

4.1.3. 分层注意力层

通过将每个目标卷积的输出作为输入，该层旨在生成指定的聚合实际变量。对于每个目标卷积 $cv_i \in R^{dv}$ 在 CV 中，我们计算注意力 I，以反映其与分类目标的相关性及其贡献。图 5（c）展示了注意力机制的基本工作原理。注意力任务按公式（21）至（22）计算

$$e_i = a(q, cv_i) \tag{21}$$

$$a_{ij} = \frac{exp(e_i)}{\sum_k exp(e_k)} \tag{22}$$

卷积池 CV 在整个池中的可能性如图所示，其中 q 是一个训练程序模式向量，k 是卷积池 CV 在整个池中的概率。随后，将加权总和传递至整体目标卷积的下游分类，从而生成一个定长的注意力聚合变量。图 5（c）展示了基本工作示意图展示了注意力机制。

$$o = \sum_i a_{ij} * cv_i) \tag{23}$$

4.1.4. 预测层

该层的作用是通过 p(y|S) 计算概率分布，其中 y 是分类目标。向量 o 通过 Softmax函数输入多层分类器，用于处理定长且面向护理的聚合数据。

$$o = \sum_i a_k cvo_i) \tag{24}$$

图 6展示了我们模型的运行阶段，说明了从输入部分到预测层各层的运作机制。生成的输出会沿单一方向传递至后续处理层的输入端。我们使用心电图数据在真实环境中测试模型的性能。首先，心电信号经过预处理后，利用我们的条件生成对抗网络模型将原始信号转换为合成信号。经过滤波、去噪和 Z 标准化后，信号被输入深度学习模型并依次执行。最后，模型预测心电图的目标类别。

4.2. HARDC模型分类心电信号的主要伪代码。

本节介绍心电信号数据的核心算法运作过程。该算法接收原始数据作为输入，并根据数据预测心电图目标类别。首先记录并预处理心电信号。双向门控循环单元-双向长短期记忆网络层接收预处理后的信号，并提取有用特征。扩张卷积神经网络的输出会传递至层次化注意力机制。在最后一层，使用 SoftMax 预测心电图信号。此处，伪代码4.2是用于采用 HARDC 模型进行心电图类别分类的主要算法

伪代码1()：数据：心电图数据集 D 的输入，特征列表 Fi 结果：心律失常预测 输入来自 D_s 的合成信号 从心电图数据的合成信号中提取输入特征 (F1,F2,. . . ., FN)

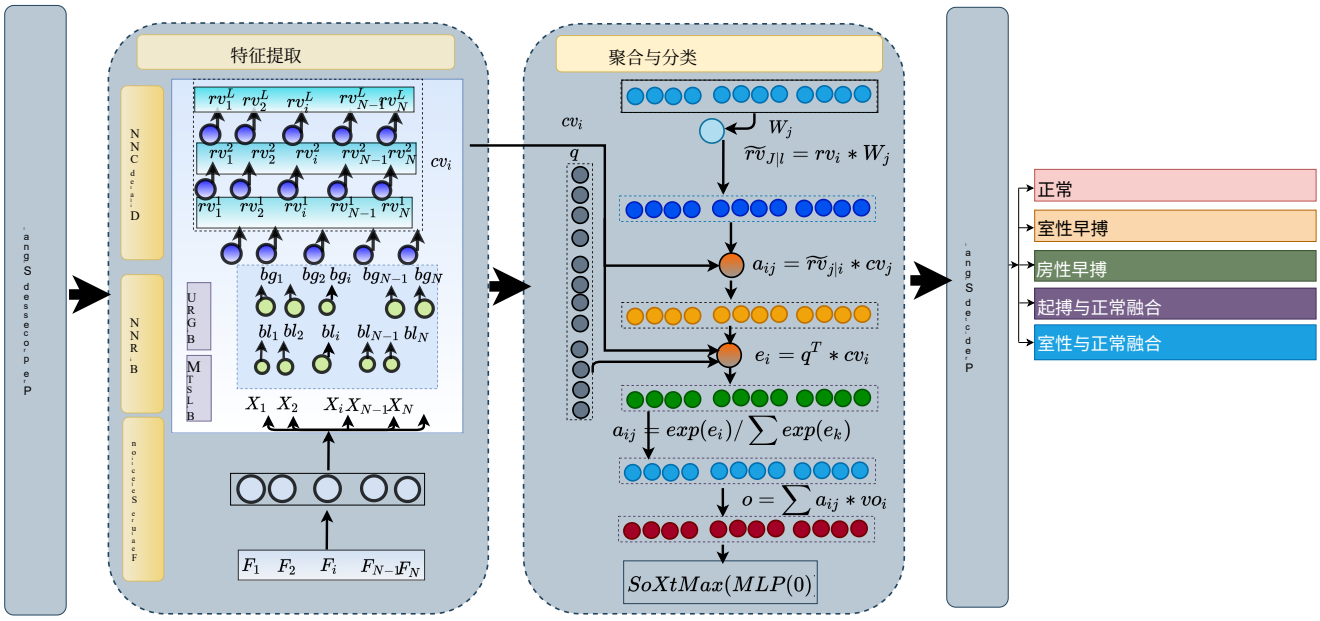


图6：HARDC模型的整体流程。

预处理特征生成为 $X = x_1, x_2, \ldots\ldots, x_n$处理输入的心电图特征：$X = x_1, x_2, \ldots\ldots, x_n \in R^{n*d}$，其中 d 是维度

对每次重复生成的输出使用双向门控循环单元和双向长短期记忆网络进行处理，i 的取值范围为 0 到 N

$RV_{BiGRU} = BG = bg_1, bg_2, ..., bg_n \in R^{n*d^{\sim}}$

$RV_{BiLSTM} = BL = bl_1, bl_2, .., bl_n \in R^{n*d^{\sim}}$

其中，RV 是路由处理的双向长短期记忆网络-双向门控循环单元层-器：$RV_l = concatenation(RV_{BiGRU}, RV_{BiLSTM})$

$RV^l = [rv^l_1 rv^l_2 ..., rv^l_n] \in R^{n*d^{\sim}}, l \in (1, L)$

$rv^l_t = ReLU(W^l \oplus [rv^{l-1}_{t+1r}]^{w-1}_{t=0}$

其中 L 为层数 $W^l \in R^{k*w*k}$，$W^l \in R^{k*w*d^{\sim}}$

end

执行扩张卷积神经网络

对于 l 从 0 到 l 的每次重复，执行

对于 r 从 0 到 N 的每次迭代，执行

$RV^1 = [rv^l_1 rhv^l_2 ..., rv^l_n] \in R^{n*d^{\sim}}, l \in (1, L)$

对于范围 (0,w) 内的 w，执行

$rv^l_t = ReLU(W^l \oplus [rv^{l-1}_{t+1r}]^{w-1}_{t=0}$

end

end

end

对深度卷积神经网络输出执行动态卷积网络处理：

对于 i 从 0 到 N 的每次迭代，执行对于 j 从 0 到 N 的每次迭代$cv_j = \sum_{i=1}^{m} C_{ij} * \widetilde{rv}_{J|l}$

$\widetilde{rv}_{J|l} = rv_i * W_j$ $a_{ij} = cvo_i * rhv_{J|l}$结束 结束

执行层次注意力机制 对于 i 从 0 到 N 的每次迭代，执行对于 j 从 0 到 N 的每次迭代，执行对于 k 从 0 到 N 的每次迭代$e_i = a(q, cv_i)$

$a_{ij} = \frac{exp(e_i)}{\sum exp(e_k)_k} a(q, cv_i) = q^T cv_i$结束 结束 结束

执行预测函数 对于 i 从 0 到 N 的每次迭代，执行对于 k 从 0 到 N 的每次迭代$o = \sum a_k cv_i$结束

结束 执行预测函数
$p(y|S) = p(y|o) = SoftMax(MLP(o))$

4.3. 评估指标

使用多种广泛采用的性能指标来评估性能。下面列出了一些评估指标及其计算公式。在计算中，P 表示正类，T 表示真，F 表示假，N 表示负类。在损失函数中，y 是预测值y_i。它们的计算方法如下列公式所示（25）至（30）。

$$Accuracy = \frac{(TP + TN)}{TP + TN + FP + FN} \tag{25}$$

$$Precision = \frac{(TP)}{TP + FP} \tag{26}$$

$$Recall/Sensitivity = \frac{(TP)}{TP + FN} \tag{27}$$

$$Specificity = \frac{(TN)}{TN + FP} \tag{28}$$

$$F1 = 2 * \frac{(precision * Recall)}{precision + Recall} \tag{29}$$

$$Loss(y) = y_i log(\bar{y}_i) + (1 - y_i) + log(1 - \bar{y}_i) \tag{30}$$

4.3.1. 实验设置

所提出的方法采用了结合层次注意力网络的 BiLSTM-BiGRU 膨胀卷积神经网络。为评估该模型的有效性，我们在实验中对模型进行了微调，并采用分类交叉验证方法评估模型。在分析中，我们将数据集划分为 80% 的训练集和 20% 的验证集。请注意，我们使用了来自同一数据集的 20% 未标记数据进行测试。在每轮训练中，模型训练时均采用分类交叉验证。其余 20% 用于验证模型。最后，我们汇总了所有评估结果。模型最多训练 100 轮，批量大小为 32。我们使用学习率为 $1e^{-3}$ 的 Adam 优化器来最小化损失 L。为减轻训练过程中过拟合的影响，我们采用了系数为 $1e^{-3}$ 的 L2 正则化，并使用丢弃概率为 0.5 的丢弃方法。层数逐步配置双向循环神经网络、扩张卷积神经网络和注意力层，以分析 MIT-BIH 心律失常数据库中的心电图信号。我们使用 Python 编程语言和 Google TensorFlow 深度学习框架来实现该模型。我们使用一台配备 5 个中央处理器（Intel(R) 3.60 GHz）、32 GB 随机存取存储器且运行 Windows 10 操作系统的计算机执行分类交叉验证。所有实验的最佳结果均在结果部分给出。所提出模型的概述见第7节的8.2。

5. 结果分析

本节对结果进行定性和比较分析。与预期一致，训练集的表现略优于验证集，且算法逐渐趋于稳定值，表明用于训练模型的设置并不过度。在验证模型中，所提出的方法获得了稳定的分类性能和良好的准确率。

5.1. 定性分析

本节中的“相关矩阵”展示了输入变量或目标变量之间的相关系数。表格中的每个单元格都显示了相关系数。相关矩阵可汇总数据，以便进行更全面的分析或提供更先进的诊断工具。图7 (a) 展示了心电信号所有训练特征的心电图数据相关矩阵。图7 (b) 展示了心电信号目标类别的心电图数据相关矩阵。在图7b 中，心电图目标类别中的“正常”、“起搏与正常融合”、“室性早搏”、“房性早搏”和“心室与正常融合”分别记为 N、FN、PVC、AP 和 FVN。为了检验模型在训练和验证中的性能，我们为模型设置了合适的参数。为所提出的 HARDC 模型设置的批量大小为 32、学习率为 1e-3、训练轮数为 100。我们的方法在学习过程中，训练准确率达到 99.60%，验证准确率达到 99.40%。模型的训练精确率也达到 97.66%，验证精确率为 95.69%；训练 F1 值为 98.21%，验证 F1 值为 96.56 %，如表5所示。该 HARDC 模型需要 P

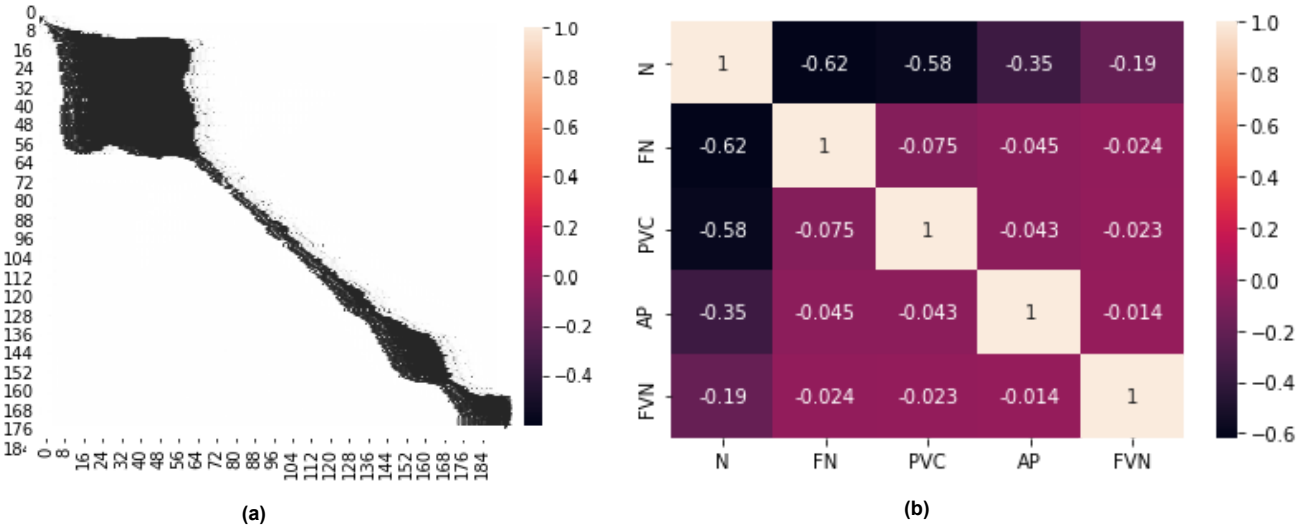


图7：（a）输入特征之间的相关矩阵，（b）心电信号目标类别之间的相关矩阵

表2 HARDC模型的性能

HARDC模型的性能		
HARDC metrics and parameters	训练准确率	99.60%
	验证准确率	99.40%
	训练F1分数	98.21%
	验证 F1	96.56%
	训练集召回率	99.60%
	验证召回率	98.99%
	训练集精确率	97.66%
	验证集精确率	95.69%
	训练损失	0.0150
	验证损失	0.0440
	训练时间	2 小时
	验证时间	2 小时
	批量大小	32
	学习率	$1e^{-3}$

两小时进行训练。训练损失函数值为 0.0.0150，验证损失函数值为 0.0.0440。

为了检验所提出的HARDC模型在测试数据上的性能，我们使用20%的未标记数据进行评估。模型在测试集上的表现与训练和验证阶段一样出色。我们的HARDC模型在测试数据上的准确率达到99.01%。调优模型时，设置卷积核大小为5、RNN输入大小为64、RNN神经元单元数为128、扩张CNN卷积为3*3、全局丢弃率为0.5。在测试性能分析中，测试数据样本数为21,886, 187。表3展示了所提出的HARDC模型的测试性能。

这里，图 8 展示了我们的 HARDC 模型对心电图信号进行分类时的整体测试性能。

表3 HARDC模型在测试数据上的性能

HARDC模型的测试性能		
Performance	测试准确率	99.01%
	测试 F1 值	97.51%
	测试召回率	98.02%
	测试精确率	97.01%
	测试时间	20 秒
	测试数据大小	21886*187

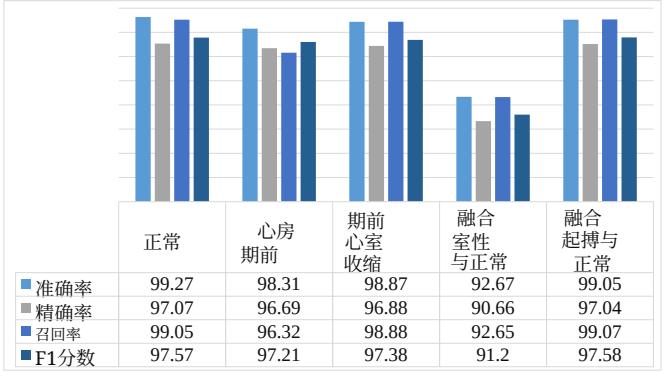


图8：HARDC 在测试中的性能

在性能评估中，我们考察准确率、F1分数、精确率和召回率。这些图中的不同颜色分别表示各项评估指标，每个子图中的每个柱形表示相应心电图类别的性能。

根据训练、验证和测试数据的表现，我们实现的 HARDC 模型程序在心电图数据上生成了如下曲线结果。图 9展示了训练期间的表现

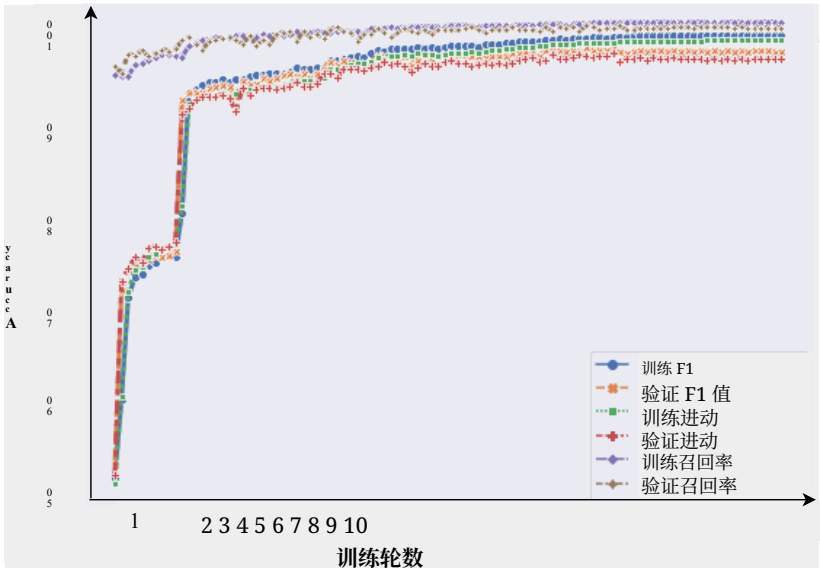


图9：HARDC模型在心电图训练数据上的F1分数、精确率和召回率

和验证期间的表现。在图 9 中，横轴表示训练轮次，纵轴表示性能百分比。每条曲线都展示了我们的 HARDC 模型的性能。

此处展示了我们的HARDC模型在训练和验证期间的分类交叉熵损失函数值。训练损失为0.015，验证损失为0.0440。

5.2. 与先进技术的比较

本节将介绍所有先进方法，以及我们提出的方法在对MIT-BIH数据库中的心电图数据进行分类时的性能。表中列出的所有对比方法4 分为三类：传统机器学习（ML）、深度学习（DL）和混合深度学习（HDL）。心电信号分类中最常用的传统机器学习算法是支持向量机： [51][11] [34][33][36] [16] [50]。XGBoost [45],随机森林 [30], 和LDA-MLP [33] 等方法近年来也展现了其在心电图分类中的性能。基于小波系数和RR间期进行心电信号分类的支持向量机 [51] 准确率为89.02%，精确率为62.2%，召回率为56.27%。

另一种结合 RR 间期和心电图投影矩阵的支持向量机 [11] 分类器，以 98.46% 的准确率对变长心电信号进行分类。采用时序和形态特征的 LDA-MLP [33] 方法对心电信号进行分类准确率为 89.02%；使用手工提取特征 [45]进行心电图分类的 XGBoost 准确率为 91.87%。基于支持向量机的心电图分类 [36]使用了 RR 间期、小波系数和形态学描述符。其他所有基于支持向量机的分类器 [50] [36] [51] 对心电图信号进行分类的准确率均在 91% 至 97% 之间。可以看出，在传统机器学习方法中，采用多种特征对心电图信号进行分类的支持向量机 [16]分类器准确率最高，达到 98.91%。最常见的深度学习方法是卷积神经网络，与其他方法相比，该方法明显表现出更优越的性能，且使用更加便捷。

一种近期开发的方法采用卷积神经网络 [27]确定患者特异性特征，准确率高达99.00%。另一种使用卷积神经网络 [58] 的方法，在对时长为0.5秒、包含200个采样点的心电信号进行分类时，准确率达到92.70%。大多数研究采用基于卷积神经网络的方法，通过生成合成数据并对原始数据进行重缩放，以94.03%的准确率对心电图信号进行分类。一种使用随机投影、提取RR间期特征，并采用卷积神经网络 [44] 处理不同长度心电信号的方法，准确率为88.33%，精确率为64.2%，召回率为57.0%。一种结合卷积神经网络与循环神经网络的混合方法，精确率达到98.10% [38]。Yıldırım等人 [53] 提出了一种基于卷积神经网络-长短期记忆网络的方法。该方法使用重缩放工具对心电图信号进行预处理，在心电图分类中取得了91.33%的准确率。

Table 4
Compared Performance.

Type	Author	Method	Input	Class	Samples	Signal length	Performance
ML	[33]	LDA-MLP	Temporal,Morphological	5	NA	NA	Accuracy 89.02% F1 62.20% precision 56.27%
	[51]	SVM	Temporal,Morphological	5-15	Various	.083s	Accuracy 86.55% F1 55.90% precision 53.40%
	[11]	SVM	RR interval, projection matrix	5-15	Various	.083s	Accuracy 98.46% F1 98.46% precision 98.46%
	[45]	XGBoost	168 handcrafted	6	NA	.08s	Accuracy 91.87% F1 67.80% precision 61.80%
	[36]	SVM	RR, Wavelet, Morphological	5	260	NA	Accuracy 94.4% F1 67.00% precision 66.30%
	[34]	LS-SVM	Statistical PCA	5	200	0.56s	Accuracy 98.11% precision 90.60%
	[16]	SVM	PCA,DWT,HOS,ICA	5	200	0.56s	Accuracy 98.91%
	[50]	Linear SVM	Wavelet coefficient	5	300	0.83s	Accuracy 97.94% Precision 98.05% Sensitivity 99.56% Specificity 89.33%
	[30]	Random Forest	Wavelet coefficient	5	143	0.39s	Accuracy 98.30% Precision 79.30% Sensitivity 99.05%
DL	[27]	CNN	Patient-Specific	5	64/128	Variable	Accuracy 99.00% Sensitivity 79.30% Specificity 99.05%
	[58]	CNN	Patient-Specific	5	200	0.56s	Accuracy 92.70%
	[54]	CNN	synthetic signal, Re-scaling	5	360	1s	Accuracy 94.03%
	[44]	CNN	Random projections, RR-interval	5	260	Variable	Accuracy 94.03% F1 64.20% Precision 57.00%
HDL	[48]	CNN-LSTM	Patient-Specific	5	Various	Variable	Accuracy 98.10% Sensitivity 97.50% Specificity 98.70%
	[53]	DCNN	Re scaling Raw data	17	Various	0.015s	Accuracy 91.33%
	[52]	CAE-LSTM	Coded signals	5	260	0.72s	Accuracy 99.10% Sensitivity 99.00% Specificity 99.00%
	[10]	CNN-BiLSTM	RR intervals	5	224/325	1.53s	Accuracy 96.77% F1 77.80% Precision 81.20%
	[32]	Dilated CNN	Denoising, normalization	5	260	NA	Accuracy 98.65% Sensitivity 97.98.97% Specificity 99.03%
	[47]	Deep Attention BiLSTM	Attention,morphological, temporal	5	360	Various	precision 96.7% Recall 96.4% F1 96.5%
	[14]	Deep CNN-BiLSTM	RR, PR intervals, QRS	5	100	0.8s	Accuracy 96.59% Sensitivity 99.93% Specificity 97.03%
	[26]	CNN-LSTM Attention	Multi domain features	5	360	NA	Accuracy 98.51% Sensitivity 98.14% Specificity 98.76%
	[49]	CNN-BiLSTM Attention	Raw data	5	360	NA	Accuracy 99.10% Precision 98.16% Sensitivity 98.40% Specificity 98.70%
	HARDC (Our)	Attention BiGRUBiLSTM Dilated CNN	Wavelet, QRS, Synthetic	5	360	1.5s	Accuracy 99.60% F1 98.21% precision 97.66% Recall 99.60%

该作者还开发了一种结合注意力机制与长短期记忆网络的方法，获得了 99.11% 的精确率 [52]。另一种采用卷积神经网络和双向长短期记忆网络的新方法 [10] 通过该方法获得了 96.77% 的准确率、77.8% 的精确率和 81.2% 的召回率。Ma等人开发了一种基于扩张卷积神经网络的方法[32] ，通过利用数据去噪和归一化，以 98.65% 的准确率检测心律失常。Dang等人 [14]提出了一种结合卷积神经网络和双向长短期记忆网络的方法，对心电图信号进行分类，获得了 69.59% 的精确率。Jin等人 [26] 提出了一种结合卷积神经网络-长短期记忆网络与注意力机制的技术，该技术利用领域知识，在对五种心电图信号进行分类时获得了 98.51% 的准确率。另一种采用卷积神经网络-双向长短期记忆网络的技术 [49] 在心电图分类中获得了 99.11% 的准确率。比较结果见表4。基于残差通道注意力网络的多变量心电图分类方法 [47] 以及双向门控循环单元，针对长、短时长的心电图信号分别获得了 96.7% 和 97.7% 的准确率。该方法很好地利用了导联注意力、形态特征和时域特征。本文提出的 HARDC 方法使用了合成及预处理后的心电图信号，每条信号包含 360 个采样点，时长为 1.5 秒。相比之下，我们的混合HARDC模型取得了最高的 99.60% 准确率、98.21% 的 F1 值和 97.66% 的精确率。

5.3. 讨论

文献部分概述了现有方法存在的问题，而我们设计新的 HARDC 模型正是为了解决这些问题。我们对提出的 HARDC 模型进行了评估，并将其与若干当前模型基准进行了比较。在 MIT-BIH 提供的心电图数据上，我们的 HARDC 模型准确率为 99.60%，F1 值为 98.21%，精确率为 97.66%，召回率为 99.60%。在应用预处理操作后使用 HARDC 模型之前，我们先利用条件生成对抗网络模型合成原始心电信号。

基于 MIT-BIH 心电图数据，我们进行了五种分类实验。实验结果表明，我们的策略优于若干竞争性基线方法，并取得了多项先进成果。

通过对原始正常心电图信号完成一系列预处理，我们的方法中的条件生成对抗网络模型显著提升了合成数据样本的生成质量。这有助于解决误分类问题并提升性能。

基于注意力的网络采用双重结构的双向门控循环单元和双向长短期记忆网络，并结合混合扩张卷积神经网络方法，这是我们提出的 HARDC模型的关键。我们提出了一种新型混合模型，通过动态地将其层级系统转变为注意力卷积，改进学习结构、提取特征并分析心电信号分类。双向门控循环单元-双向长短期记忆网络与扩张卷积神经网络的处理，以及层级自注意力系统，能够自动提取心电图特征的层级表示，从而充分利用这些特征。我们提出的混合神经网络卷积模型成功获取了隐式特征信息。该模型充分利用了双向门控循环单元-双向长短期记忆网络之间的差异与相互依赖关系。

为提升性能，扩张卷积神经网络能够处理丰富的特征。我们的混合模型采用基于注意力机制的范式，并纳入分层自处理方法；其中的扩张卷积神经网络能够缩短训练时间、简化网络结构，从而提升性能。改进后的卷积网络结合动态路由算法，可提高提取更多相关特征的效率。

我们还采用相同的参数调优和输入尺寸实现了一些传统方法，以评估所提出模型的有效性。表格5 展示了性能对比。根据表格5，HARDC方法的表现优于迄今为止所有其他可比较的方法。

表格展示了HARDC模型与最常用且相关模型的整体性能对比，传统模型的对比结果表明，在采用相同参数调优的情况下，我们的方法能够获得比其他方法更高的准确率。

5.4. 复杂度分析

我们开发了一种混合深度学习模型 HARDC，该模型结合了双向循环神经网络和扩张卷积神经网络，并采用层次注意力机制，以兼顾方法的有效性与运行时间。模型记录的运行时间比其他任何深度学习方法在测试集上的运行时间都短。由于训练卷积神经网络（CNN）需要更多时间，所提出的方法没有采用

表5 HARDC模型与传统模型的性能比较。

模型	批量大小	学习函数	激活	优化函数	Drop out	输入大小	准确率
CNN	32	$1e^{-3}$	Re-Lu	Adam	0.5	300.128.5	96.00%
LSTM	32	$1e^{-3}$	Re-Lu	Adam	0.5	300.128.5	96.50%
GRU	32	$1e^{-3}$	Re-Lu	Adam	0.5	300.128.5	97.84%
注意力卷积神经网络-双向门控循环单元	32	$1e^{-3}$	Re-Lu	Adam	0.5	300.128.5	98.43%
注意力卷积神经网络-双向长短期记忆网络	32	$1e^{-3}$	Re-Lu	Adam	0.5	300.128.5	98.87%
注意力深度卷积神经网络-双向门控循环单元	32	$1e^{-3}$	Re-Lu	Adam	0.5	300.128.5	98.93%
HARDC（我们的方法）	32	$1e^{-3}$	ReLu	Adam	0.5	300.128.5	99.60%

表6 对比测试时间。

模型	样本量	时间（秒）
CNN	21,886	15
LSTM	21,886	18.5
GRU	21,886	19
注意力卷积神经网络双向门控循环单元	21,886	26
注意力卷积神经网络双向长短期记忆网络	21,886	23
注意力深度卷积神经网络双向门控循环单元	21,886	22
HARDC（我们的方法）	21,886	20

通用 CNN。不过，我们采用具有多级膨胀率机制的扩张卷积操作来执行特征提取所需的卷积，从而降低整体计算复杂度。测试集的运行时间为 20 秒。在典型的卷积层中，卷积核之间也紧密耦合。不过，在所提出的方法中，加入扩张组件降低了卷积层的处理复杂度。因此，如表 6 所示，我们的模型空间复杂度较低，且运行时间短于一些采用注意力机制、结合普通 CNN 卷积与 RNN 的模型。通过使用扩张卷积神经网络，我们的模型减少了计算时间，但运行时间仍长于 CNN、GRU 和 LSTM 等一些传统模型。在未来的开发中，我们将着重通过采用不同的优化器、归一化和正则化方法来降低时间复杂度。

5.5. 本研究的局限性

该方法确实存在一些局限性。首先，所提出的技术仅关注五种信号来检测心律失常。其次，对数据驱动的深度模型的需求是，我们未来的目标是分析大型多标签数据集，以检验所提出的方法并提升模型的泛化能力。未来的项目中，我们将进一步改进模型复杂度和适应性。

6. 结论

自动分类，尤其是心律失常检测，是最关键的临床问题之一，也是人工智能驱动的生物信息学领域公认的挑战。我们提出了一种新方法，利用基于注意力机制的扩张卷积神经网络-双向长短期记忆网络，对五类心电信号进行心律失常诊断。该模型结合了特征提取方法，并利用基于注意力机制的扩张卷积神经网络、双向长短期记忆网络和双向门控循环单元，提升了可解释性。由两个双向长短期记忆网络模块和两个双向门控循环单元模块组成的双向循环神经网络，可提取相关的长程独立特征。扩张卷积神经网络层是一种因果卷积层，用于提取心电图信号的特征。最终，我们提出的方法在训练、验证和测试阶段的准确率分别达到99.60%、99.40%和99.01%。该方法还获得了98.21%的F1 值、97.66%的精确率以及99.60%的召回率，适用于训练

数据集。根据实验结果，我们提出的方法在心房颤动（心房颤动）检测方面也表现出色，尤其是实现了较高的检测准确率和灵敏度。与生物医学信号处理中常见的既有特征学习方法不同，所提出的HARDC模型无需预先输入知识或生物学信息，也不需要采用经典机器学习中的手工特征提取流程，这些都可视为其额外优势。因此，该网络能够以极低的计算开销检测心房颤动，并具备理论上的实时性能。未来的研究将结合本项工作，重点开发一种基于云的自动化方法，用于分类多类型心律失常信号。我们计划提升模型的泛化能力、优化神经网络的学术表现、改善临床效益，并计划通过采用不同的优化器、归一化和正则化方法，降低模型的时间复杂度。

7. 致谢

本研究未获得任何基金或资助。

8. 附录

8.1. 心电图数据预处理

多种噪声和伪迹都会影响心电图信号。因此，在将信号输入深度学习模型之前，提高信噪比（SNR）至关重要。为预处理心电图信号，我们执行了以下步骤。首先，对心电图心搏进行预处理，并利用条件生成对抗网络模型生成合成信号。

8.1.1. 归一化

使用 Pan-Tompkins 算法进行 R 波峰检测 ins [39] 算法。所有心电图数据均被划分为以检测到的 R 波峰为中心、长度为 360 个采样点的片段。随后，在输入学习模型之前，使用 Z 分数归一化对每个片段进行归一化，以处理幅值缩放并减小偏移效应。Pan-Tompkins Z 归一化的基本运算公式如下：化公式如下，见公式（31）：

$$ZN(z) = \frac{(x-\mu)}{\sigma} \tag{31}$$

其中，ZN(z) 表示使用高通滤波器进行 Z 归一化。本节通过执行方程（31）和图10展示各层的顺序操作。

8.1.2. 滤波

由于心电图研究中的信号幅值通常很低，因此采用滤波方法去除噪声至关重要，可以清除大量噪声 [55]。我们采用“切比雪夫II型”通带，将频带范围保留在 0.5 至 48 Hz。选择该滤波器是因为其截止频率陡峭且没有波纹。该滤波器的主要运算方程见方程（32）：

$$|CH_n(j\omega)| = [\frac{1}{\sqrt{1+(\in)^2 T_n^2(\frac{\omega}{\omega_0})}}] \tag{32}$$

其中，$\in$ 为波纹因子，ω_0 为截止频率，而 T_n 为 n 阶切比雪夫多项式。切比雪夫滤波的应用如图10所示。

8.1.3. 去噪

归一化后，进行了去噪处理。首先使用 Daubechies 小波滤波器对心电图数据进行去噪并去除基线 [46]。其次，将信号分割为心搏，并根据心脏病学家的标注进行排序。Daubechies 小波滤波器的基本计算 [41]如下方程（33）所示:

$$P_N(y) = \sum_{k=0}^{(N=1)} [\frac{N-1+k}{k}] y^k \tag{33}$$

其中，y 是经过归一化的去噪输出，k 表示具有特定范围的分段值。应用 Daubechies 去噪的结果如图10所示。

8.1.4. 分割

正常心律会产生四种不同的波形 [7][31][40]：P波、QRS波群、T波和U波，各自具有独特的形态。P波表示心房去极化。QRS波群表示心室去极化。心室复极化

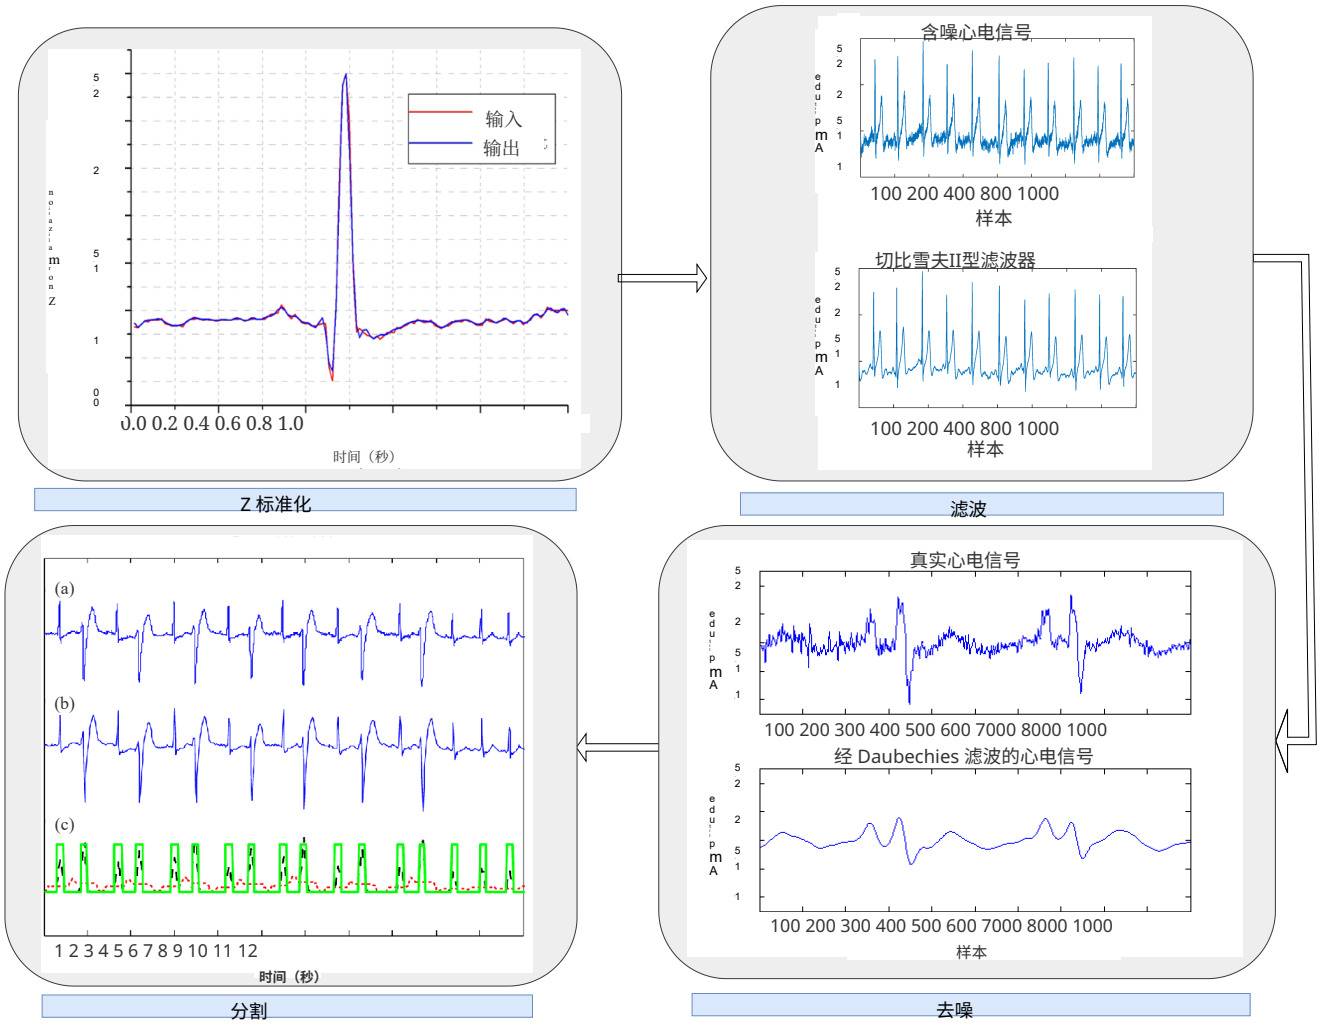


图 10：心电信号预处理

由T波表示。乳头肌复极化由U波表示。PR间期是P波起始点与QRS波群起始点之间的时间间隔。识别QRS波群、P波和T波及其形态、振幅和相对位置，都是心电图分析的一部分。识别QRS波群、P波和T波的起始点与终止点，称为心电信号分段或波形界定 [5]。

在我们的任务中，我们采用低通微分（LPD）进行心电图分割。LPD [28] 用于一种近期方法，以改善分类任务中的信号幅值。低通微分器会产生包含斜率信息的滤波信号。通过自适应阈值识别每个信号中的 QRS 信息。信号的一阶导数用于识别原始心电信号的波峰，具体如下

零交叉点。在正向偏转与负向偏转之间，零交叉点对应于初始心电信号中的一个极大值。通过从修正信号中检测到的波峰向后和向前扫描，确定原始信号的波形边界（起始点和终止点）。该过程按以下步骤执行：I. 首先，检测 QRS(i)，并对每个导联进行预处理 $QRS_j(i)$；II. 然后查找漏检情况：如果被剔除的部分是极大值，则可能导致漏检，并可将该最大值设为下一个心搏。因此，若将最大值设为导联 j，则赋值为 $QRS(l) = QRS(l-1)(l >= i+1)$，其中 l 表示心电图的导联。所采用的 LPD分割技术如图所示10。

根据数据集提供的标注，所有单条记录都被划分为 75 秒的片段。每个片段包含 360*75 = 27000 个采样点及相应的标签，因为信号是采-

表7 HARDC模型中使用的参数。

层类型	层数	层信息	滤波器*卷积核尺寸	输入尺寸
膨胀卷积	0	二维卷积 (64,64,膨胀率=1,步幅=1)	64*8	360*128*5
	1	批归一化 (64)	64*8	360*128*5
	2	ReLU(64)	64*8	360*128*5
	3	二维卷积 (64,64,膨胀率=1,步幅=1)	64*8	360*128*5
	4	批归一化 (64)	64*8	360*128*5
	5	ReLU (64)	64*8	360*128*5
	6	二维卷积 (64,64,膨胀率=1,步幅=1)	64*8	360*128*5
	7	批归一化 (64)	64*8	360*128*5
双向长短期记忆网络-双向门控循环单元	8	最大池化	64*8	360*128*5
	9	双向长短期记忆网络(64)	64*128	360*128*5
	10	双向门控循环单元 (64)	64*128	360*128*5
注意力机制	11	注意力机制 (64)	64*128	360*128*5
	12	全连接层 (64*128)	64*128	360*128*5
	13	双曲正切函数 (64)	64*128	360*128*5
预测	14	ReLU（64）	64*128	360*128*5
	15	最大池化（54）	64*128	360*128*5
	16	全局平均池化 (64)	64*128	360*128*5
	17	丢弃 (0.5)	丢弃 = 0.5	360*128*5
	18	全连接层 (5)	-	5

采样率为100赫兹。

8.2. 模型参数

在本小节中，我们已在表格中列出了模型参数7。该表展示了从特征提取到预测的层信息，包括卷积核、滤波器尺寸和输入尺寸。

参考文献

[1] Acharya, U.R., Fujita, H., Lih, O.S., Hagiwara, Y., Tan, J. H., Adam, M., 2017. 使用卷积神经网络，通过心动过速心电图片段的不同间期自动检测心律失常。Information Sciences 405, 81– 90.[2] Andersen, R.S., Peimankar, A., Puthusserypady, S., 2019. 一种用于实时检测心房颤动的深度学习方法。Expert Systems with Applications 115, 465– 473.[3] Aspuru, J., Ochoa-Brust, A., F´elix, R.A., Mata-L´opez, W., Mena, L.J., Ostos, R., Mart´ınez-Pel´aez, R., 2019. 通过线性回归算法对心电信号进行分段。Sensors 19, 775.[4] Ayashm, S., Chehel Amirani, M., Valizadeh, M., 2022. 使用全卷积网络对心电信号进行分析，以实现自动检测……

阻塞性睡眠呼吸暂停的诊断。Circuits, Systems, and Signal Processing，1–16。[5] Azami, H., Sanei, S., Mohammadi, K., 2011。一种基于标准差和可变阈值的新型信号分割方法。《国际计算机应用杂志》34，27–34。[6] Bala, M., Ali, M.H., Satu, M.S., Hasan, K.F., Moni, M.A., 2022。用于自闭症谱系障碍早期检测的高效机器学习模型。Algorithms 15，166。[7] Beraza, I., Romero, I., 2017。心电图分割算法的比较研究。《生物医学信号处理与控制》34，166–173。[8] Cano, ´O., Andr´es, A., Alonso, P., Osca, J., Sancho-Tello, M.J., Rueda, J., Osa, A., Mart´ınez-Dolz, L., 2017。先天性心脏病及心律失常患者心电图中的关键线索。Journal of electrocardiology 50，243–250。[9] Chatterjee, S., Thakur, R.S., Yadav, R.N., Gupta, L., Raghuvanshi, D.K., 2020。心电图信号去噪技术综述。IET Signal Processing 14，569–590。[10] Chen, A., Wang, F., Liu, W., Chang, S., Wang, H., He, J., Huang, Q., 2020。用于心律失常自动检测的多信息融合神经网络。《生物医学中的计算机方法与程序》193，105479。[11] Chen, S., Hua, W., Li, Z., Li, J., Gao, X., 2017。利用心电信号的投影特征和动态特征进行心搏分类。《生物医学信号处理与控制》31，165–173。

[12] Choi, G.H., Lim, K., Pan, S.B., 2020。面向智能车辆、基于自适应阈值滤波器和归一化心电图的驾驶员识别系统。Sensors 21, 202。[13] Chou, Y.h., Hong, S., Zhou, Y., Shang, J., Song, M., Li, H., 2020。知识少样本学习：一种用于类别不平衡心电图数据分类的可解释深度模型。《神经计算》417，64–73。[14] Dang, H., Sun, M., Zhang, G., Qi, X., Zhou, X., Chang, Q., 2019。一种利用心电图信号进行心房颤动分类的新型深度心律失常诊断网络。IEEE Access 7，75577–75590。[15] Delaney, A.M., Brophy, E., Ward, T.E., 2019。利用生成对抗网络合成逼真的心电图。arXiv预印本 arXiv:1909.09150。[16] Elhaj, F.A., Salim, N., Harris, A.R., Swee, T.T., Ahmed, T., 2016。结合心电图信号线性与非线性特征进行心律失常识别和分类。《生物医学中的计算机方法与程序》127，52–63。[17] Hammad, M., Liu, Y., Wang, K., 2018。基于卷积神经网络、通过心电图与指纹不同层级融合实现的多模态生物特征认证系统。IEEE Access 7，26527–26542。[18] Hasan, K.F., Overall, A., Ansari, K., Ramachandran, G., Jurdak, R., 2022。新兴智能交通的安全、隐私与信任：认知车联网，载于：《下一代企业安全与治理》。CRC出版社，第193–226页。[19] Hinton, G., Vinyals, O., Dean, J., 2015。提炼神经网络中的知识。arXiv预印本 arXiv:1503.02531。[20] Hochreiter, S., Schmidhuber, J., 1997。长短期记忆。《神经计算》9，1735–1780。[21] Hong, S., Zhou, Y., Shang, J., Xiao, C., Sun, J., 2020。深度学习方法在心电图数据中的机遇与挑战：系统综述。《生物学与医学中的计算机》122，103801。[22] Humayn Kabir, M., Fida Hasan, K., Kamrul Hasan, M., Ansari, K., 2021。面向智慧城市应用的可解释人工智能：安全可信平台。arXiv电子印本，arXiv–2111。[23] Islam, M.M., Hossain, M.B., Akhtar, M.N., Moni, M.A., Hasan, K.F., 2022。基于迁移学习模型、结合数据增强与变换的混凝土裂缝检测卷积神经网络。Algorithms 15，287。[24] Ji, T., Lu, Z., Wu, Q., Ji, Z., 2008。利用经验模态分解和数学形态学对心电图信号进行基线归一化。《电子学快报》44，1。[25] Jiang, J., Zhang, H., Pi, D., Dai, C., 2019。一种用于类别不平衡心搏分类的新型多模块神经网络系统。《应用专家系统：X》1，100003。[26] Jin, Y., Qin, C., Huang, Y., Zhao, W., Liu, C., 2020。利用双注意力卷积长短期记忆神经网络对心房颤动检测进行多域建模。《基于知识的系统》193，105460。[27]Kiranyaz, S., Ince, T., Gabbouj, M., 2015. 基于一维卷积神经网络的实时患者特异性心电图分类。《IEEE生物医学工程汇刊》63, 664–675。[28] Laguna, P., Jan´e, R., Caminal, P., 1994. 多导联心电信号波形边界的自动检测：使用CSE数据库进行验证。《计算机与生物医学研究》27, 45–60。[29] Li, R., Zhang, X., Dai, H., Zhou, B., Wang, Z., 2019. 基于心搏活动全局序列特征和双向长短期记忆网络—注意力神经网络的心搏分类可解释性分析。IEEE Access 7, 109870–109883。[30] Li, T., Zhou, M., 2016. 利用小波包熵和随机森林进行心电图分类。《熵》18, 285。[31] Lyakhov, P., Kiladze, M., Lyakhova, U., 2021. 一种采用基于小波的预处理、用于通过神经网络识别心电图信号中心房颤动的系统。《应用科学》11, 7213。[32] Ma, H., Chen, C., Zhu, Q., Yuan, H., Chen, L., Shu, M., 2021. 一种基于膨胀因果卷积的心电信号分类方法。《医学中的计算与数学方法》2021。[33] Mar, T., Zaunseder, S., Mart´ınez, J.P., Llamedo, M., Poll, R., 2011. 通过特征选择优化心电图分类。《IEEE生物医学工程汇刊》58, 2168–2177。[34] Martis, R.J., Acharya, U.R., Mandana, K., Ray, A.K., Chakraborty, C., 2012. 将主成分分析应用于心电图信号，以自动诊断心脏健康状况。Expert Systems with Applications 39, 11792–11800。[35] Mim, T.R., Amatullah, M., Afreen, S., Yousuf, M.A., Ud-din, S., Alyami, S.A., Hasan, K.F., Moni, M.A., 2023. GRU-Inc：一种基于Inception—注意力的方法，使用门控循环单元进行人体活动识别。Expert Systems with Applications 216, 119419。[36] Mond´ejar-Guerra, V., Novo, J., Rouco, J., Penedo, M.G., Ortega, M., 2019. 通过分类器集成融合心电图的时间信息和形态信息进行心搏分类。《生物医学信号处理与控制》47, 41–48。[37] Moody, G.B., Mark, R.G., Goldberger, A.L., 2001. Physionet：用于研究生理信号的网络资源。《IEEE医学与生物学杂志》20, 70–75。[38] Oh, S.L., Ng, E.Y., San Tan, R., Acharya, U.R., 2018. 结合卷积神经网络和长短期记忆网络技术及可变长度心搏的心律失常自动诊断。《生物学与医学中的计算机》102, 278–287。[39] Pan, J., Tompkins, W.J., 1985. 一种实时QRS检测算法。《IEEE生物医学工程汇刊》，230–236。[40] Randazzo, A., 2016. 终极12导联心电图电极放置指南（附插图）。Prime Medical Training (https://www. pri memedicaltraining. com/12-lead-ecg-placement/)。[41] Ro we, A.C., Abbott, P.C., 1995. Daubechies小波与

数学。《物理学中的计算机》9, 635–648。[42] Schuster, M., Paliwal, K.K., 1997a. 双向循环神经网络。《IEEE 信号处理汇刊》45, 2673–2681。[43] Schuster, M., Paliwal, K.K., 1997b. 双向循环神经网络。《IEEE 信号处理汇刊》45, 2673–2681。[44] Sellami, A., Hwang, H., 2019. 一种采用批次加权损失的稳健深度卷积神经网络，用于心搏分类。Expert Systems with Applications 122, 75–84。[45] Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., Liu, C., 2019. 一种基于加权极端梯度提升的心电图心搏分类分层方法。《生物医学中的计算机方法与程序》171, 1–10。[46] Singh, B.N., Tiwari, A.K., 2006. 用于心电信号去噪的小波基函数优化选择。Digital signal processing 16, 275–287。[47] Tao, Y., Li, Z., Gu, C., Jiang, B., Zhang, Y., 2022. 一种基于心电图的专家知识注意力网络，用于识别快速性心律失常。《生物医学信号处理与控制》76, 103649。[48] Waldo, A.L., Feld, G.K., 2008. 心房颤动与心房扑动的相互关系：机制及临床意义。《美国心脏病学会杂志》51, 779–786。[49] Wang, J., 2021. 一种用于心房颤动和心房扑动信号分类的智能计算机辅助方法，采用改进的双向长短期记忆网络。Information Sciences 574, 320–332。[50] Yang, W., Si, Y., Wang, D., Guo, B., 2018. 基于主成分分析网络和线性支持向量机的心律失常自动识别。《生物学与医学中的计算机》101, 22–32。[51] Ye, C., Kumar, B.V., Coimbra, M.T., 2012. 利用心电图信号的形态特征和动态特征进行心搏分类。《IEEE生物医学工程汇刊》59, 2930–2941。[52]Yildirim, O., Baloglu, U.B., Tan, R.S., Ciaccio, E.J., Acharya, U.R., 2019. 一种利用深度编码特征和长短期记忆网络进行心律失常分类的新方法。《生物医学中的计算机方法与程序》176, 121–133。[53] Yıldırım, ¨O., Pławiak, P., Tan, R.S., Acharya, U.R., 2018. 利用长时程心电图信号和深度卷积神经网络检测心律失常。《生物学与医学中的计算机》102, 411–420。[54] Yildirim, O., San Tan, R., Acharya, U.R., 2018. 利用深度卷积自编码器对心电图信号进行高效压缩。《认知系统研究》52, 198–211。[55] Zarei, A., Asl, B.M., 2020. 采用单导联心电信号自动检测睡眠呼吸暂停时谱自相关函数和自回归模型的性能评估。《生物医学中的计算机方法与程序》195, 105626。[56] Zhang, D., Yang, S., Yuan, X., Zhang, P., 2021a. 用于12导联心电图自动诊断的可解释深度学习

心电图。Iscience 24, 102373.[57] Zhang, X., Li, J., Cai, Z., Zhang, L., Chen, Z., Liu, C., 2021b. 基于深度学习的心房颤动检测中过拟合抑制训练策略。Medical & Bio- logical Engineering & Computing 59, 165–173.[58] Zubair, M., Kim, J., Yoon, C., 2016. 一种使用卷积神经网络的自动化心电图心搏分类系统，载于：2016 第六届IT融合与安全国际会议（ICITCS），IEEE。第 1–5 页。