

中国科学技术大学

University of Science and Technology of China

硕士学位论文



论文题目 基于深度学习的心电信号挖掘算法研究

作者姓名 张涛

学科专业 软件工程

导师姓名 汪炆 副教授

完成时间 二〇二二年五月

中国科学技术大学

硕士学位论文



基于深度学习的心电信号挖掘算法研究

作者姓名: 张涛
学科专业: 软件工程
导师姓名: 汪炆副教授
完成时间: 二〇二二年五月十四日

University of Science and Technology of China
A dissertation for master's degree



Research on ECG Signal Mining Algorithm Based on Deep Learning

Author: Tao Zhang

Speciality: Software Engineering

Supervisors: Associate Prof. Yang Wang

Finished time: May 14, 2022

摘要

心血管疾病是威胁人类生命健康的头号杀手，而心律失常则是心血管疾病中危害最大的一种，心律失常被定义为正常心律的任何不规则变化，严重情况下会导致心脏骤停甚至死亡。专业的心脏科医生可以通过观察心电图来了解心脏健康状况，然而单纯依靠肉眼识别心电图，准确率、实时性均难以保证。因此，心电图的自动分类一直以来都是医学和生物信息学上最有价值的研究课题之一。

心电信号是非平稳、幅值较小的连续信号，采集过程中会不可避免地受到噪声的干扰，导致信号失真。信号中存在的噪声可能会被误检为正常或异常的心拍，以至于直接影响分类的精度。针对该问题，本文以 Daubechies 小波作为基本小波将原始心电信号进行八层小波分解，并利用小波阈值降噪算法去除其中存在的低频的基线漂移、高频的肌电干扰和固定的工频干扰，维持了心电信号完整性的同时并突出了信号中重要的特征。然后利用 R 峰正好对应着小波变换后的模极大值的过零点的性质定位到 R 峰，并根据 R 峰位置将连续的心电记录分割成单个的心拍。最后对每个心拍进行 Z-Score 标准化处理，为后续的心电信号增强和心电信号分析提供数据支撑。

目前的公开心律失常数据库都普遍存在着严重的不平衡问题，然而，该领域大多数的分类算法更关注模型在整体上的准确性，却忽略了不平衡数据分布所导致的模型在异常类别上的糟糕表现。尽管可以通过传统数据增强的方式来缓解这种不平衡现象，但这些方法面临着形态信息变更或过拟合的问题。针对该挑战，本文提出了一种融合 VAE 和 Wasserstein-DCGAN 的心电信号生成式算法，其思想在于通过学习真实数据的分布来生成高质量的异常心拍，通过这种生成式算法可以使得增强后的数据分布更均衡。而基于高质量的分布平衡的大量训练数据，模型能够学习到更深层次的无偏语义特征，因此能实现更精确的分类效果。该心电信号生成算法的贡献在于：一，使用 Wasserstein 距离和梯度惩罚的损失函数，解决了传统心电信号生成模型训练不稳定、模式坍塌的问题；二，针对以随机采样噪声为输入的心电信号生成模型训练过程中存在的损失动荡以及难以正常收敛的问题，本文将 VAE 编码器输出的潜在特征作为 GAN 生成器的有监督输入，该潜在特征里包含心电信号的原始信息，可以帮助模型更快更稳定地收敛；三，能够拟合质量更高更丰富的波形，对于 VAE 训练目标，使用 GAN 判别器中表示的高维特征误差替换典型的元素重建误差，即将原本固定的相似性度量变为可学习的任务。

在均衡分布的数据集的基础上，本文还设计了基于注意力机制的心电信号分类模型。针对心电信号中长距离依赖问题以及特征无区分度的挑战，本文提

出将特征空间划分为多个子空间，在每个子空间独立的计算全局特征之间的关联关系并为不同时间段的特征赋予不同的注意力权重，因此能够有效地捕捉信号长时序上的依赖关系并量化各个时间段特征对于信号分类的贡献。由于在心律失常这样的医学数据集中对异常类别错误分类的成本通常远高于对正常类别错误分类的成本，因此本文使用了一种成本敏感的损失函数即焦点损失，以此来增加分类模型对于稀疏的异常类别的学习能力，从而能够在降低错误分类成本的同时提高模型的整体性能。最后，通过设计合理的评价指标和对比实验，验证了本文提出的算法明显地优于其他几种心电图分类算法。

关键词：类别不平衡；生成式算法；注意力；成本敏感；心电图分类

ABSTRACT

Cardiovascular disease is the number one killer that threatens human life and health, and arrhythmia is the most harmful type of cardiovascular disease. Arrhythmia is defined as any irregular change in normal heart rhythm, which can lead to cardiac arrest or even death in severe cases. Professional cardiologists can understand the health of the heart by observing the electrocardiogram. However, it is difficult to guarantee the accuracy and real-time performance of the electrocardiogram simply by relying on the naked eye. Therefore, automatic classification of electrocardiograms has always been one of the most valuable research topics in medicine and bioinformatics.

The ECG signal is a non-stationary continuous signal with small amplitude, which will inevitably be interfered by noise during the acquisition process, resulting in signal distortion. The noise present in the signal may be falsely detected as normal or abnormal heartbeat, so that it directly affects the accuracy of classification. In order to solve this problem, this dissertation uses the Daubechies wavelet as the basic wavelet to decompose the original ECG signal with eight layers of wavelet, and uses the wavelet threshold noise reduction algorithm to remove the low-frequency baseline drift, high-frequency electromyographic interference and fixed power frequency interference, maintain the ECG signal integrity and highlight important features in the signal. Then, the R peak is located by the property that the R peak corresponds to the zero-crossing point of the wavelet-transformed mode extreme value pair, and the continuous ECG recording is divided into single heart beats according to the position of the R peak. Finally, Z-Score normalization processing is performed on each heartbeat to provide data support for subsequent ECG signal enhancement and ECG signal analysis.

The current public arrhythmia databases generally have serious imbalances. However, most classification algorithms in this field currently pay more attention to the overall accuracy of the model, but ignore the poor performance of the model on anomalous categories caused by imbalanced data distribution. Although this imbalance can be alleviated by means of traditional data augmentation, these methods face the problem of changing morphological information or overfitting. In response to this challenge, this dissertation proposes an ECG signal generation algorithm that combines VAE and Wasserstein-DCGAN. The idea is to generate high-quality abnormal heartbeats by learning the distribution of real data, and this generative algorithm can make the enhanced data distribution more balanced. Based on a large amount of training data with high-quality distribution and balance, the model can learn deeper unbiased semantic features, so it can achieve more accurate classification results. The contributions of the ECG signal generation algorithm are: First, the loss function of Wasserstein distance and gradient penalty is used to solve the problems of unstable training and mode collapse of the traditional ECG signal generation model; second, in

view of the loss turbulence and slow convergence speed in the training process of the ECG signal generation model with random sampling noise as input, this dissertation proposes to use the latent features output by the VAE encoder as the supervised input of the GAN generator. The potential feature contains the original information of the ECG signal, which can help the model to converge faster and more stably; thirdly, it can fit higher quality and richer waveforms, for the VAE training target, the high-dimensional feature error represented in the GAN discriminator is used to replace the typical element reconstruction error, that is, the original fixed similarity measure becomes a learnable task.

On the basis of a well-distributed dataset, this dissertation also designs an ECG signal classification model based on the attention mechanism. In response to the long-distance dependence problem in ECG signals and the challenge of feature indiscrimination, proposes to divide the feature space into multiple subspaces, independently calculate the correlation between global features in each subspace, and assign different attention weights to the features of different time periods. Therefore, it can effectively capture the long-term dependence of the signal and quantify the contribution of the characteristics of each time period to the signal classification. Since the cost of misclassifying abnormal categories in medical datasets such as arrhythmia is usually much higher than the cost of misclassifying normal categories, this dissertation uses a cost-sensitive loss function, the focal loss, to increase the learning ability of the classification model for sparse anomaly categories, which can improve the overall performance of the model while reducing the cost of error. Finally, through the design of reasonable evaluation indicators and comparative experiments, it is verified that the algorithm proposed in this dissertation is significantly better than other ECG classification algorithms.

Key Words: Class Imbalance; Generative Algorithm; Attention; Cost Sensitive; ECG Classification

目录

第 1 章 绪论.....	1
1.1 选题背景及研究意义.....	1
1.2 国内外研究现状.....	2
1.2.1 心电智能诊断算法研究现状.....	2
1.2.2 心电信号生成研究现状.....	4
1.2.3 心电信号分类挑战.....	4
1.3 本论文的主要内容和章节安排.....	5
1.3.1 本论文的主要内容.....	5
1.3.2 本论文的章节安排.....	7
第 2 章 基础知识.....	8
2.1 心电图以及心律失常数据库.....	8
2.1.1 心电图.....	8
2.1.2 MIT-BIH 心律失常数据库.....	9
2.2 深度学习基础知识.....	9
2.2.1 激活函数.....	10
2.2.2 优化器.....	12
2.3 神经网络模型.....	12
2.3.1 卷积神经网络.....	13
2.3.2 循环神经网络及其变体.....	13
2.3.3 生成对抗网络.....	15
2.3.4 变分自编码器.....	16
2.4 注意力机制.....	17
2.4.1 自注意力机制.....	17
2.4.2 多头自注意力机制.....	18
2.5 小波变换和小波阈值去噪.....	18
2.5.1 小波变换.....	18
2.5.2 小波阈值去噪.....	20
2.6 本章小结.....	21

第 3 章 心电信号预处理算法.....	22
3.1 心电信号去噪.....	22
3.1.1 心电信号干扰.....	22
3.1.2 心电信号去噪与分析.....	23
3.2 R 峰定位.....	24
3.2.1 小波变换模极值与奇异点关系.....	24
3.2.2 基于小波变换的 R 波波峰检测.....	25
3.3 心拍分割和标准化.....	26
3.3.1 心拍分割.....	26
3.3.2 心拍标准化.....	27
3.4 本章小结.....	28
第 4 章 心电信号生成算法.....	29
4.1 数据不平衡问题.....	29
4.2 基于 DCGAN 的心电信号生成算法.....	30
4.2.1 DCGAN 基本原理.....	30
4.2.2 生成模型.....	30
4.2.3 判别模型.....	31
4.2.4 损失函数.....	32
4.3 基于 Wasserstein-DCGAN 的心电信号生成算法.....	33
4.3.1 Wasserstein 距离的定义.....	33
4.3.2 损失函数.....	34
4.4 融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法.....	34
4.4.1 模型总体框架.....	35
4.4.2 模型结构.....	35
4.4.3 损失函数.....	36
4.5 实验验证.....	38
4.5.1 评价指标.....	38
4.5.2 实验设计.....	38
4.5.3 基于 DCGAN 的心电信号生成实验.....	39

4.5.4 基于 Wasserstein-DCGAN 的心电信号生成实验	41
4.5.5 融合 VAE 和 Wasserstein-DCGAN 的心电信号生成实验	43
4.6 对比分析	45
4.6.1 生成样本相似度对比	45
4.7 本章小结	46
第 5 章 心电信号分类算法	47
5.1 引言	47
5.2 基于 CNN 和 LSTM_Attention 的心电信号分类算法	47
5.2.1 模型总体框架	47
5.2.2 网络结构	48
5.2.3 数据增强	49
5.2.4 损失函数	50
5.3 实验设置与分析	51
5.3.1 评价指标	51
5.3.2 实验设计	52
5.3.3 实验结果	52
5.4 消融实验	54
5.4.1 损失函数对比	54
5.4.2 数据增强对比	55
5.4.3 网络结构对比	56
5.5 本章小结	57
第 6 章 总结和展望	58
6.1 总结	58
6.2 展望	58
参考文献	60
致 谢	66
在读期间发表的学术论文与取得的其他研究成果	67

第1章 绪论

1.1 选题背景及研究意义

根据世界卫生组织的统计,心血管疾病已经成为威胁人类生命健康的头号杀手,而心律失常是心血管疾病中最普遍也是危害最大的一种。心律失常指正常心律的任何不规则变化,具有突发性和间歇性的特点,严重情况可能导致心脏骤停甚至死亡。心电图(Electrocardiography, ECG)作为一种无创的诊断技术,被广泛用于监测心跳活动,为心血管疾病的诊断和治疗提供了丰富的信息。传统的心电分析诊断技术主要依靠人工,医生需要通过肉眼去观察心电图,显然分析的时效性和准确率都是个很大的问题。

过去对心电图的研究主要分为以下几个方面:一,通过检测心电RR间隔变化和波形形态的特征^[1],此类方法简单直接,但容易受到噪声的干扰,会产生较大的误差,并且对于动态心电适用性不强;二,利用模板匹配^[2],可以有效地发现心律异常事件,但是该方法对噪声的包容性不强,会将心电图中的噪声片段诊断为异常,因此容易造成大量阴性误检为阳性的情况,这反而会大大地增加了医生的工作负担;三,利用机器学习算法^[3],这类算法需要人工提取特征,由于特征提取具有针对性,其能够发挥较好的作用,但分类精度在面对大量未知测试数据时却不能够被保证。后来随着大数据的不断发展,深度学习重新引起了关注,通过神经网络的拟合可以避免人工提取特征这一复杂过程,最大化实现数据的完整表达,可以在保证时效性和准确率的基础上实现对心电信号的有效分析。

虽然深度学习方法在心电信号分类方面已经取得了突破性的成就,但是它需要大量的数据才能表现出优秀的性能。然而诸如心电图、脑电图、肌电图这样的医学数据集通常非常有限且价格昂贵,除此之外,该类数据集一般还存在着严重的数据不平衡问题,正常类别占绝大多数,而数十种异常类别只占很少一部分。由于这种不平衡的特性使得训练后的模型很容易偏向具有大量训练数据的正常类,而在数据有限的异常类上表现不佳。因为它们的目的是优化整体准确率,而没有适当考虑每个类别的相对准确率。然而,在心律失常这样的医学数据集中对异常类别错误分类的成本通常远高于对正常类别错误分类的成本。因此,迫切需要一种适用于心律失常数据集的良好数据增强技术。克服这种不平衡的常见方法是通过使用平移、翻转和旋转等经典数据增强方法来人工创建合成数据,这些方法已成为计算机视觉任务中必不可少的步骤。但是这种方法并不适用于心电信号,因为心电信号有着明显的时序和形态特征。因此,如何从稀疏的异常心拍中生成高质量的数据以缓解数据不平衡和数据稀疏问题,是

提高心电信号分类模型整体性能的关键所在。

尽管已有一系列心电信号分类的相关研究，但由于心电信号的复杂性和标注的稀疏性，其在分类任务上仍然面临噪声干扰、数据不平衡、特征提取不精准等挑战。而随着深度学习和数据增强技术的发展，通过设计损失函数、合成新数据、构建一系列新颖的网络结构等方法可以有效地提高心电信号分类模型的表现能力。

1.2 国内外研究现状

1.2.1 心电智能诊断算法研究现状

心电图是反映心脏活动的影像，专业的医生可以通过观察心电图判定心脏的健康状况，但是对于不具备专业知识的普通人来说没办法做到这点。因此，越来越多的国内外科研人员投入到对心电图的研究中来，使得心电图的智能诊断分析技术迅速发展，取得了很不错的成果。综合这些研究，心电智能诊断算法包括三个方面：心电信号预处理、特征提取、心电信号分类。

1. 心电信号预处理研究现状

心电信号是非平稳、幅值较小的连续信号，采集过程中会不可避免地被噪声干扰，导致信号失真。一直以来，研究者们做了大量的关于心电信号去噪方面的研究。常见的去噪方法有：传统的形态滤波^[4]、有限脉冲响应滤波^[5]、中值滤波^[6]、新兴的小波阈值去噪^[7]、自适应滤波^[8]等。基于数字滤波器的去噪方法，根据心电信号的频域特征来设计截止频率，滤波器会将截止频率之外的信号剔除掉，这样粗粒度的去噪方法会影响信号的完整性造成失真。而自适应滤波器通过动态的调节滤波参数而能保证最低程度的信号失真，使输出信号不断逼近干净信号。另一种适用于 ECG 信号实时降噪的技术是经验模式分解（Empirical Mode Decomposition, EMD）^[9]，在 EMD 中，信号首先被分解为一组幅度和频率调制的分量，通常称为固有模式函数，然后根据频谱分析去除噪声对应的分量，最后通过模式函数和残差的总和来重构信号，但是该方法重构过程中会丢弃一些低频信号。Qiu 等人^[10]提出了利用循环神经网络的特性来过滤心电信号中最常见的工频干扰，但是该方法去除噪声不彻底且计算复杂度大。Liu 等人^[11]提出了基于相似段的协同滤波方法，首先将一个信号分成等长的片段，然后根据相似度找到每个片段的相似片段，并排列成一个二维数组，通过多项式拟合方法在两个方向上分别进行滤波，最后，将所有过滤后的段放回原来的位置恢复原信号。

2. 心电信号特征提取研究现状

特征提取是十分重要的一步，提取的特征越准确，最终分类识别的精度也越高。一般来说，心电信号主要由 P 波、QRS 波群、T 波等组成，其他特征由这几个特征扩展而来，通过分析这些特征可以判断心脏的健康状况，例如通过分析 QRS 波群的宽度可以判断是否有室早搏，通过分析 P 波可以判断是否有房颤。小波变换模极值法^[12]广泛用于 QRS 波群的检测，该方法利用原始心电信号小波变换后的极值点和过零点的组合来检测 QRS 波群。Kim J^[13]提出了通过能量水平、能量变化率的幅度和持续时间阈值来检测 QRS 复合波。S.Z. Mahmoodabadi^[14]等人采用多分辨率小波变换的方法来对心电信号特征进行提取。相比较于 QRS 波群，P 波和 T 波的检测难度要高得多。近些年来，一些科研工作者提出将马尔科夫算法^[15]与贝叶斯融合来提取信号 P、T 波。Kresimir^[16]等人提出先寻找心电图中的 R 波波峰，然后确定 R-R 间期，最后在该范围内根据 P 波和 T 波的波峰特征来检索。Panigrahy D^[17]提出的差分进化优化策略在 P 波检测中显示出良好的准确率，然而，这种方法计算量大，并且文中描述的相位分配方法依赖于 R 峰的准确检测。不同心律失常的特征复杂多变，仅提取单个特征或简单融合多个特征不足以区分心律失常，上述方法必须根据先验知识构建和选择信号特征，实现效率低。

3. 心电信号分类算法研究现状

心电信号的分析要求丰富的经验，并且内容枯燥。因此，如果能够设计出心电信号自动分类的方法就能大大降低医生的负担。传统的机器学习方法广泛应用于检测心律失常。它显著的特点是特征提取和分类器的分类是相互独立的，如支持向量机（Support Vector Machines, SVM）^[18]、人工神经网络（Artificial Neural Networks, ANN）^[19]、随机森林（Random Forest, RF）^[20]等方法。这些方法都有一个共同的缺点，需要手动提取特征，过程较为复杂且繁琐，并且对于信号的突变较为敏感。相比之下，深度学习自动提取特征的能力非常适合于心律失常的自动检测^[21]。Wang 等人^[22]提出了一种端到端的深度学习方法，用于多阶段特征融合的多类心律失常检测。文献^[23]将心电信号分解成不同尺度的频率子带，这些频率子带用作双向长短期记忆网络的输入序列，实现心电信号的分类。Lih 等人^[24]提出了一种结合卷积神经网络和长短期记忆网络的自动化系统，这项工作的新颖之处在于使用了来自 MIT-BIT 心律失常数据库的可变长度的 ECG 片段。Rajpurkar P 等人^[25]提出了一种 34 层 ResNet 的深度学习模型，他们使用该模型将心电图样本序列映射到节律序列，无需采用任何复杂的预处理和特征工程步骤，他们声称该模型的心电图辨别能力方面超过了普通心脏病专家的表现。Gao 等人^[26]提出了使用具有焦点损失的长短期记忆网络模型对不平衡的心律失常数据进行分类。Essa E 等人^[27]将集成学习用于心电信号分类，提

出了一种基于深度学习的多模型系统，并将它们的分类结果组合成最终预测。一些研究人员使用短期傅里叶变换和小波变换将 ECG 数据转换为二维（频率、时间）数据，并将其用作深度神经网络的输入。Salem^[28]等人使用 MIT-BIH 数据集将一维 ECG 信号转换为“频谱图”来制作 2D 图像，他们还使用了一个 161 层的 DenseNet，在数百万张图像上进行了预训练，以提取抽象信息，然后应用 SVM 进行四类分类，他们的模型准确率和 F1 分数分别为 97.23% 和 97.35%，但是这种方法计算复杂度很高，而且还需要占用大量的磁盘空间来存储 2D 图像。尽管深度学习方法在心电图分类方面显示出不错的结果，但其需要每个类别的大量训练样本才能表现出优秀的性能，而大多数危及生命的心律失常极为罕见并且蕴含着大量重要的信息，深度学习方法一直面临着对此类稀疏异常心拍分类精度不够高的问题。

1.2.2 心电信号生成研究现状

关于心电信号生成方面的研究很少，大部分都是采用数学方法为每个波形单独建模。McSharry 等人^[29]提出了一种两阶段动态模型来生成人工心电图信号。首先，他们通过指定真实 RR 间隔的频谱参数和时间参数（平均心率和标准偏差）来生成内部时间序列。其次，他们构建了运动方程、三维轨迹模型，并指定每次心跳峰值的位置和高度，以生成 ECG 的平均形态，信号中的每个波形分别用该轨迹模型内的一组高斯方程表示，心电信号可视为这些波形的高斯方程之和。Li 等人^[30]提出了一种基于分段曲线的数据流图方法对心电信号进行建模，该算法需要分别对心电图中的每个波形单独建模，然后将它们组合成一个完整的心拍。Clifford 等人^[31]提出将每个心跳视作一种状态，使用一阶马尔可夫链实现正常和异常节拍类型之间的切换，其中的概率转换矩阵从真实数据中学习。Roonizi 等人^[32]提出了一种基于信号分解的方法来对 ECG 信号进行建模，因为单个 ECG 心跳可以看作是基函数的总和。Zhu 等人^[33]提出了使用生成对抗网络生成心电信号，其中双向长短期记忆网络用作生成器，卷积神经网络用作判别器，生成与现有临床数据一致的合成心电图数据，以便保留心脏病患者的特征。

1.2.3 心电信号分类挑战

现有心电信号分析的相关工作主要是通过设计网络的结构、提高特征抽取质量来提高模型的性能。然而，要实现更精准地分类、更好的医疗辅助价值，仍然面临以下的挑战：

1. 心电信号中的噪声干扰。心电信号是非平稳、幅值较小的连续信号，采集过程中会不可避免地被噪声干扰。信号中存在的噪声可能会被错误地检测为正常心跳或异常心跳，严重地影响模型的分类效果。现有的方法大都采用滤波

策略，然而仍然面临着噪声去除不干净、信号完整性和连续性被破坏、算法复杂度高等问题，预处理方案仍有待提升。

2. 数据不平衡问题。在心律失常数据集中，正常类别的心拍占绝大多数，而大多数危及生命的异常心拍却只占很少一部分。由于这种不平衡的特性使得训练后的模型很容易偏向具有大量训练数据的正常类，导致模型在数据有限的异常类上表现不佳。然而，在心律失常这样的医学数据集中对异常类别错误分类的成本通常远高于对正常类别错误分类的成本。克服这种不平衡的常见方法是通过使用平移、翻转和旋转等经典数据增强方法来人工创建合成数据，这些方法已成为计算机视觉任务中必不可少的步骤。尽管这些修改可能会产生一些其他的边际收益，但它们也可能会破坏相关的形态特征和原始数据集的分布，导致分类模型产生严重的性能问题。因此，如何从小样本中学习真实心电信号的分布并生成高度逼真的样本是解决不平衡分类的重要挑战。

3. 数据多样性问题。在数据不平衡问题中，一些研究只关注生成数据的质量，而没有考虑到生成数据的多样性。在实际情况下，每种类型的心电信号通常呈现出不止一种形式的波形。但是传统的心电信号生成模型只倾向于生成某一种或几种类型的样本，这就是我们所说的“模式崩溃”问题，即生成样本缺乏多样性。单一的样本容易造成模型的过拟合，并且在面对大量未知测试数据时，模型的表现能力往往不尽如人意。因此，如何从小样本中生成具有多样性的的心拍是提高心电信号分类模型泛化能力和拟合能力的重要挑战。

4. 特征提取不精准且无区分度。医生在分析心电图时，不仅需要了解全局的信息，还需要注意波形之间的前后联系并重点关注几个关键的部分，不同的心电图重点关注的部分也不相同。在心电图的自动分类中，传统的机器学习方法必须根据先验知识构建和选择信号特征，然而不同类别心拍的特征复杂多变，仅提取单个特征或简单融合多个特征不足以区分各个类别。而现有的深度学习方法可以自动提取需要的特征，其主要是通过卷积神经网络提取形态特征或是使用循环神经网络提取时序特征，但是心电信号时间序列较长，传统的深度学习方法难以捕捉长距离的依赖关系并且无法区分不同时序上的特征对于心电信号隐藏信息的表示。因此，如何更精准地提取连续心电信号上的特征并关注更重要的特征是心电信号分类所面临的一个挑战。

1.3 本论文的主要内容和章节安排

1.3.1 本论文的主要内容

本文致力于将先进的深度学习技术应用到心电诊断算法并解决非平衡学习问题，主要研究内容包括以下几个方面：

1. 由于心电信号中存在的噪声可能会被错误的检测为心拍,影响分类模型的性能,因此本文首先分析了心电信号采集过程中常见的三种噪声及其性质,然后根据心电信号的采样频率以及噪声的频率分布范围,以 Daubechies 小波作为基本小波将原始心电信号进行八层小波分解,并利用小波阈值去噪方法去除了 MIT-BIH 数据集中低频的基线漂移、高频的肌电干扰和固定的工频干扰,突出心电信号中的重要特征,维持了心电信号完整性的同时并减少噪声对后续心电信号分类的消极影响。接着利用 R 峰正好对应着小波变换后的模极大值的过零点的性质定位到 R 峰,并根据 R 峰位置将连续的心电记录分割成单个的心拍。最后对每个心拍进行 Z-Score 标准化处理,为后续的心电信号增强和心电信号分析提供数据支撑。

2. 针对传统数据增强方法容易产生过拟合和修改形态特征的问题,本文提出了一种融合 VAE 和 Wasserstein-DCGAN 的心电信号生成式算法,其思想在于通过学习真实数据的分布来生成高质量且多样性的异常心拍,通过这种生成式算法可以使得增强后的数据分布更均衡。基于高质量的分布平衡的大量训练数据,模型能够学习到更深层次的无偏语义特征,因此能实现更精确的分类效果。该心电信号生成算法的贡献在于:一,使用 Wasserstein 距离和梯度惩罚的损失函数,解决了传统心电信号生成模型训练不稳定、模式坍塌的问题;二,针对以随机采样噪声为输入的心电信号生成模型训练过程中存在的损失动荡以及难以正常收敛的问题,本文将 VAE 编码器输出的潜在特征作为 GAN 生成器的有监督输入,该潜在特征里包含心电信号的原始信息,可以帮助模型更快更稳定地收敛;三,能够拟合质量更高更丰富的波形,对于 VAE 训练目标,使用 GAN 判别器中表示的高维特征误差替换典型的元素重建误差,即将原本固定的相似性度量变为可学习的任务。实验证明,相比较于其他生成模型,该算法生成的心电信号质量更高,多样性更明显。

3. 设计了心电信号分类算法。首先使用本文提出的心电信号生成算法对训练集补充以平衡数据的分布,然后针对常见方法无法捕捉到心电信号中长距离的依赖关系且信号时序特征无区分的问题,本文引入了多头自注意力机制,提出了基于 CNN 和 LSTM_Attention 的心电信号分类模型,该模型将特征空间划分为多个子空间,在每个子空间独立的计算全局特征之间的关联关系并为不同时间段的特征赋予不同的注意力权重,因此能够有效地捕捉信号长时序上的依赖关系并量化各个时间段特征对于信号分类的贡献。在心律失常这样的医学数据集中对异常类别错误分类的成本通常远高于对正常类别错误分类的成本,由于数据集的不平衡性,无区分度的交叉熵会进一步增加模型的分类错误成本。针对该问题,本文使用了一种成本敏感的损失函数即焦点损失,以此来增加分

类模型对于稀疏的异常类别的学习能力，从而能够在降低错误分类成本的同时提高模型的整体性能。最后对比分析本论文提出的心电信号分类算法与其他方法，验证本文提出算法的有效性。

1.3.2 本论文的章节安排

本论文共分为六章，主要内容如下：

第一章：绪论。首先介绍了心电信号分类算法的研究背景及意义，然后具体阐述了心电信号智能诊断算法和心电信号生成算法的国内外研究状况，并对其存在的不足之处做了分析，最后交代了本文的主要内容和章节安排。

第二章：基础知识。首先介绍了心电图的基本概念以及所分析的 MIT-BIH 心律失常数据库，接着引入了心电信号分类和心电信号生成所用到的深度学习相关算法和网络模型，最后描述了注意力机制和小波变换算法。

第三章：心电信号预处理算法。本章首先介绍了心电信号中最常见的三种噪声，然后利用小波阈值降噪算法去除这三种噪声，接着利用 R 峰位置正好对应着小波变换后的模极值对的过零点的性质定位到 R 峰，最后根据 R 峰位置完成心拍的分割和标准化，为心电信号增强和分类提供数据支撑。

第四章：心电信号生成算法。阐述了数据不平衡问题，并且针对 MIT-BIH 数据集中存在的该问题，提出了利用 GAN 拟合真实数据的分布以生成高质量的心电信号并对训练集补充，使得增强后的数据分布更均衡。本章在 ECG-DCGAN 的基础上，设计了两种算法，分别是基于 Wasserstein-DCGAN 的心电信号生成算法以及融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法，并在 PRD 和 RMSE 两个衡量生成样本质量的指标上，将本文提出的心电信号生成算法同其他生成算法进行比较。

第五章：心电信号分类算法。使用前一章提出的生成模型对训练集进行补充，并设计心电信号分类模型。针对普通模型难以捕捉长距离依赖以及特征之间无区分度的问题，引入多头自注意力机制来捕捉心电信号中全局特征的关联关系，并学习不同时序上特征对于信号分类的影响。同时针对普通交叉熵对各个类别惩罚力度相同的情况，提出使用焦点损失，增加对异常心拍分类错误的惩罚力度，以提高模型对于该类别的识别准确率，最后将本文提出的方法与其他方法进行对比分析。

第六章：总结与展望。就本文提出的心电信号生成和分类算法做了简单的总结，同时也针对该论文存在的一些不足之处进行了讨论，并明确了下一步的研究内容和改进措施。

第 2 章 基础知识

本章首先介绍了心电图中的几种常见波形和本文所分析的心律失常数据库 MIT-BIH，然后对本文所使用的神经网络模型以及深度学习相关知识做了简单的阐述，接着描述了注意力机制的原理及其适用场景，并同时延伸出了注意力机制的两个变种：自注意力机制和多头自注意力机制，最后介绍了小波变换和小波阈值去噪的相关概念和具体流程。

2.1 心电图以及心律失常数据库

心电图记录了人体心脏的电活动，已成为诊断心脏病最重要的工具之一，专业的心脏科医生通过监测心电图的微小变化，可以对人体的心脏状况做出准确的判断。下面将介绍心电图中的常见波形以及本论文将要分析的心律失常数据库 MIT-BIH。

2.1.1 心电图

心电图主要由 P 波、QRS 复合波、T 波等组成，研究这些复杂的波形及其所代表的心脏活动对于诊断各种心律失常至关重要。如图 2.1 是一个完整周期的正常心电图，下面对心电图的基本概念做简单的介绍^[34]。




图 2.1 心电图

1. P 波：P 波是心电图中的第一个波形，持续时间在 0.08-0.11 秒，幅值一般小于 0.25mV，P 波在波形形态上小且圆钝，反映的是左心室和右心室的除极过程。
2. P-R 间隔：指电刺激从 P 波开始到 QRS 波群结束的时间间隔，持续时间一般在 0.12-0.2 秒，P-R 间隔的变化反映了心脏的健康状况，P-R 间隔过短表示存在预激综合征，而过长则表示存在房室传导阻滞。
3. R-R 间隔：指相邻 R 波波峰之间的距离，反映了人体心房产生兴奋然后传达到心室总共花费的时间，在心电图上显示为一个平直段。R-R 间隔是心电

图中一个完整的心拍周期。

4. QRS波群: QRS波群蕴含着很多重要的信息,是整个心电信号中能量最集中的波形,其振幅较P波更高。QRS波群,由三个连续的波构成,第一个波是Q波,方向向下,接着便是QRS复合波中最高的R波,方向向上,最后是S波,方向向下。QRS波群时间一般持续在0.06-0.10s。

5. S-T段: S-T段连接QRS波群和T波,该段较平滑,正常的时长一般在0.08-0.12秒。

6. T波: T波在S-T段之后,持续时间一般为0.05-0.25秒,反映了心室复极中的电活动情况,波幅较大,在心电图中,表现为圆润光滑的弧形,临床上,常被用作判断心室早搏的依据。

7. Q-T间隔: 从QRS复合波开始到T波结束的时间,持续时间一般为0.32-0.44秒。Q-T间隔异常延长与室性心律失常风险增加有关,严重情况可能会导致猝死。

2.1.2 MIT-BIH 心律失常数据库

MIT-BIH^[35]是一个用于研究心律失常的权威数据库,心律失常指正常心律的任何不规则变化,具有突发性和间歇性的特点,严重情况可能导致心脏骤停甚至死亡。该数据库由麻省理工学院研发并开源,数据全部来自于真实的用户。它包含了48条不同性别和年龄的个人测量记录,每条记录持续时间是30分钟,采样频率为360Hz,心跳和R峰位置已由专家注释并与数据集相关联。该数据库几乎包括了所有的心拍类型,其中的左束支传导阻滞(Left Bundle Branch Block Beat, LBBB)、右束支传导阻滞(Right Bundle Branch Block Beat, RBBB)、房性早搏(Atrial Premature Beat, APB)和室性早搏(Premature Ventricular Contraction, PVC)是临床中最常见的传导异常和心律失常类型,也是本文的主要研究对象。数据库中每条心电测量记录都是由头文件、数据文件和注释文件共同描述。具体说明如下:

1. 头文件: 具体说明了采样频率、数据存储格式等信息。
2. 数据文件: 记录了心电信号每个采样点的幅值大小。
3. 注释文件: 描述了心脏病医学专家对患者心电信号的分析结果。

2.2 深度学习基础知识

深度学习是机器学习的一个重要分支,相比较于机器学习,深度学习取消了人工提取特征这样繁琐的一步,而是由神经网络自动提取特征。神经网络由多个神经元组成,每个神经元仅独立地执行简单的计算,神经网络的强大拟合能力来自于这些神经元可以形成复杂的连接。下面将介绍深度学习中几种常用

的激活函数和优化器。

2.2.1 激活函数

我们知道，神经网络中的每一个网络层实际上是对输入的数据做线性变换。如果没有使用任何激活函数^[36]的话，无论怎样设计网络层的结构，最终得到的输出也只是上一层输入的某种线性组合，这样会严重地限制神经网络拟合函数的能力，而当引入激活函数后，可以对输入数据做非线性拟合，从而可以去逼近任意函数。激活函数具有以下特点：一，非线性；二，单调性，容易进行凸优化；三，连续且可微。在本小节中，将介绍几个常见的激活函数。

1. *Sigmoid*^[37]激活函数：

$$Sigmoid(x) = \frac{1}{1 + e^{-x}} \tag{2.1}$$

它的导数计算公式如下：

$$Sigmoid'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} \tag{2.2}$$

图 2.2 是*Sigmoid*激活函数在坐标轴上的函数曲线以及导函数的函数曲线。观察曲线我们可以分析出，在*x*趋向于无穷小或者趋向于无穷大时候（饱和情况），*Sigmoid*的斜率很小，即*Sigmoid*导函数的函数值很小，这种情况就会导致神经网络的训练非常缓慢。




图 2.2 *Sigmoid*激活函数

2. *Tanh*^[38]激活函数：

$$Tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{2.3}$$

它的导数计算公式如下：

$$Tanh'(x) = 1 - \left(\frac{e^x - e^{-x}}{e^x + e^{-x}}\right)^2 \tag{2.4}$$

图 2.3 是 $Tanh$ 激活函数在坐标轴上的函数曲线以及导函数的函数曲线。观察曲线我们可以分析出, $Tanh$ 导函数在坐标轴上呈现出对称的规律, 而 $Tanh(x)$ 的取值范围在 $[-1,1]$ 之间, 并且均值为 0。




图 2.3 $Tanh$ 激活函数

3. $ReLU^{[39]}$ 激活函数:

$$ReLU(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases} \quad (2.5)$$

它的导数计算公式如下:

$$ReLU'(x) = \begin{cases} 0 & x \leq 0 \\ 1 & x > 0 \end{cases} \quad (2.6)$$

图 2.4 是 $ReLU$ 激活函数在坐标轴上的函数曲线以及导函数的函数曲线。观察曲线我们可以分析出, 当 $x \leq 0$ 时, $ReLU'(x) = 0$; 而当 $x > 0$ 时 $ReLU'(x) = 1$, 函数值为常数, 因此当网络层数加深的时候, 可以有效的避免“梯度消失问题”。另外, $ReLU$ 相较于 $Sigmoid$ 和 $Tanh$ 来说运算量也减少了很多。




图 2.4 $ReLU$ 激活函数

2.2.2 优化器

一般人们都认为偏差越小的模型拟合的效果越好，在神经网络中根据场景的不同设计出不同的损失函数来量化模型预测结果与真实结果之间的偏差。优化器通过最小化损失函数来使得网络中的参数朝着正确的方向更新合适的大小，从而不断提升模型的能力，减少预测结果的误差。下面介绍几种典型的深度学习优化器算法：标准梯度下降法（Gradient Descent, GD）^[40]、随机梯度下降法（Stochastic Gradient Descent, SGD）^[41]、Momentum 优化算法^[42]、Adam 优化算法^[43]。

GD 的思路可以理解为从山顶寻找最快下山的路径，每走一步都会计算当前位置最陡的方向（梯度），并作为下一步。GD 优化算法的具体公式为：

$$\theta_{t+1} = \theta_t - \alpha \cdot \nabla_{\theta} J(\theta) \quad (2.7)$$

α 是学习率，学习率决定了朝着最佳权重移动的速度大小。标准梯度下降算法的缺点很明显，每走一步都要重新计算下一步的方向。而在面对大规模的数据集时，每当神经网络中输入一个样本，都需要重新计算并更新参数，这将会导致训练过程十分缓慢，神经网络得到收敛解需要消耗大量的计算资源。

SGD 是梯度下降的变体，不用每输入一个样本就更新一次参数，而是每一部分数据更新一下模型参数，因此更适用于大规模数据集。SGD 优化算法的具体公式如下：

$$\begin{cases} g_{t+1} = \nabla_{\theta_t} J(\theta_t) \\ \Delta \theta_{t+1} = -\eta * g_{t+1} \end{cases} \quad (2.8)$$

SGD 优化算法中考虑到了随机性和噪声，其期望与梯度下降相同，并且在噪声不是特别大的情况下也能很好的收敛。但是 SGD 的学习率和批量大小需要不断调试，否则可能一直在最小值附近震荡。

Momentum 优化算法的思想是记录历史梯度信息的动量来加快 SGD 的速度。具体公式如下：

$$\begin{cases} m_t = \mu * m_{t-1} + g_t \\ \Delta \theta_t = -\eta * m_t \end{cases} \quad (2.9)$$

Adam 优化算法，是目前最流行的梯度下降优化算法之一，旨在加速优化过程，减少达到最优值所需的函数评估次数，提高优化算法的能力。它结合了 SGD 和 Momentum 二者的优点，具体的公式如下：

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (2.10)$$

$$V_t = \beta_2 \cdot V_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (2.11)$$

其中 β_1 控制一阶动量， β_2 控制二阶动量。

2.3 神经网络模型

深度学习发展至今，衍生出了各种各样的神经网络模型，每种类型的神经

网络模型都是为了执行某些任务而量身定制的，下面介绍本文使用的几种神经网络模型。

2.3.1 卷积神经网络

卷积神经网络（Convolution Neural Network，CNN）^[44]是目前最流行的神经网络结构之一。随着计算能力的提升、训练数据量的增加、神经网络的优化和层数的加深，使得卷积神经网络在图像分类、交通流量预测、人脸识别和姿态估计等复杂领域都有着非常出色的表现。卷积神经网络独特的非全连接结构和权重共享的特点，彻底突破了全连接网络结构的局限，使得网络模型的参数量和计算复杂度进一步的下降。图 2.5 展示了一个经典的卷积神经网络结构。




图 2.5 卷积神经网络结构图

卷积层是网络结构的核心层，通过卷积核在输入数据上的不断滑动扫描和点积，卷积层可以自动提取想要的特征，卷积核大小不同，提取的特征粒度也不同，并且随着网络的加深，卷积层提取的特征也会变得更加抽象。在卷积层后通常连接池化层，池化是一种下采样的操作，可以逐渐压缩特征的空间尺寸并提取数据卷积核范围内关键信息，使得特征更加具有代表性，池化层有最大池化和平均池化两种实现方式。在卷积和池化层之后，通常连接全连接层，全连接层的输入是每个子区域特征展平的一维向量。多个全连接层不断压缩特征的维度得到最终的输出。

2.3.2 循环神经网络及其变体

循环神经网络（Recurrent Neural Network，RNN）^[45]是一种特殊的神经网络，在处理时序数据时具有独特的优势。传统的神经网络通常会忽视时序上的关联，但是这是不合理的。举个例子，我们平时阅读文献的时候，在思考当前单词所代表的含义时，会需要借助之前读到的一些内容来帮助推理出当前单词的意思。RNN 会存储先前输入的状态或信息，以生成序列的下一个输出，每一时刻神经元的隐藏层信息不仅取决于当前的输入值，还取决于上一时刻的信息。图 2.6 展示了一个经典的循环神经网络结构。




图 2.6 循环神经网络

其中 W 表示网络可学习的参数，每一时刻 W 都是共享的， O_t 表示 t 时刻的输出。 t 时刻的输入 X_t 和前一时刻的隐藏层状态 S_{t-1} 共同影响 t 时刻隐藏层的状态 S_t 。具体公式表示如下：

$$O_t = g(V \cdot S_t) \tag{2.12}$$

$$S_t = f(U \cdot X_t + W \cdot S_{t-1}) \tag{2.13}$$

但是循环神经网络只能处理短时序的影响，在面对神经元之间长期的时序依赖关系时，会因为时间序列过长以及反向传播过程中梯度的连乘效应出现严重的梯度消失以及梯度爆炸。在梯度消失问题中，误差梯度的范数随着每个时间步长呈指数下降，使得网络难以正常的收敛。而在梯度爆炸问题中，网络权重产生剧烈的改变，造成损失函数的动荡，使得网络难以训练。并且 RNN 处理时间数据时没有侧重点，这将导致其不可避免地会受到噪声的影响。因此为了解决上述问题，长短期记忆网络（Long Short-Term Memory，LSTM）模型^[46]被提出了，该模型目前广泛地应用于科研界和工业界。LSTM 一个单元的内部结构如图 2.7 所示。




图 2.7 LSTM 内部结构

相比较于 RNN，LSTM 引入了三个门控单元，分别是输入门、遗忘门和输出门。LSTM 的具体公式如下：

$$\begin{cases} i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ \tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \\ h_t = o_t * \tanh(c_t) \end{cases} \quad (2.14)$$

其中 σ 为 logistic 函数，其输出区间为 $[0,1]$ 。 i_t 是输入门，它决定是否会在每一时刻输入信息到记忆单元中； f_t 是遗忘门，它是用来让模型忘记对当前的输出没有用的信息； o_t 是输出门，它决定每一时刻是否有信息从记忆单元输出。通过控制这些门，LSTM 可以选择保留有用的信息丢弃无用的信息，并且可以避免梯度消失和梯度爆炸问题。

2.3.3 生成对抗网络

生成对抗网络（Generate Adversarial Networks，GAN）^[47]于 2014 年被提出，它是一种典型的无监督算法，其核心思想是通过生成模型和判别模型的不断对抗来提高生成数据的质量。图 2.8 是一个经典的 GAN 网络结构，由生成模型 G 和判别模型 D 共同组成。




图 2.8 GAN 网络结构

生成模型通过学习训练数据的潜在分布从而生成与训练数据相似的样本，而判别模型负责对输入样本的真实性进行分析。两者通过对抗，不断提升彼此的能力，从博弈论的角度来看，两者最终会达到纳什均衡（Nash equilibrium）。此时生成模型已经掌握了真实数据的分布，而判别模型对于输入的数据无法分辨出来到底是真实数据还是生成数据。上述的对抗过程用公式表示如下：

$$\text{Min}_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (2.15)$$

其中 x 表示真实样本， z 表示输入 G 网络的噪声， $G(z)$ 表示生成的样本， $D(x)$ 表示判别模型对样本的真实性评价。上述公式表示复杂，可以将其拆为两

部分，分别是生成模型 G 和判别模型 D 。

判别模型 D 的输入分为真实样本和生成样本两部分，它会对给定的样本输出一个 $[0,1]$ 之间的分数，对于真实样本， D 应该给出较高的分数，而对于由网络生成的样本， D 应该给出较低的分数，因此判别模型 D 的目标函数可以改写成：

$$\text{Max}_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (2.16)$$

生成模型 G 会尽可能生成接近真实的样本来骗过判别模型 D ，即 $D(G(z))$ 的值尽可能的高， $1 - D(G(z))$ 的值尽可能的小，因此生成模型 G 的目标函数可以改写成：

$$\text{Min}_G = \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (2.17)$$

训练过程中遵循“单独交替迭代训练”的原则，即训练判别模型的时候，固定 G ，使得 $D(x)$ 最大；而训练生成模型的时候，固定 D ，使得 $1 - D(G(z))$ 最小。通过上述对抗，可以不断地提高生成模型和判别模型的能力。通常在训练的每个循环中，首先对判别模型 D 优化 k 步，然后对生成模型 G 优化一步。之所以这样做是因为在数据集数量有限的情况下，“一步到位”的激进优化方式容易引起“模式坍塌”的问题，即生成的样本单一不具备多样性。但是，如果我们保持生成模型缓慢更新的频率，可以控制判别模型动态地维持在最优解附近。

2.3.4 变分自编码器

变分自编码器 (Variational AutoEncoder, VAE)^[48]是自编码器的一种变体，它结合贝叶斯推理解决了自编码器中非正则化潜在空间的问题，并为整个空间提供了生成能力。图 2.9 是一个典型的 VAE 网络。




图 2.9 VAE 示意图

与传统编码器不同的是，VAE 的编码器不是在潜在空间中输出向量，而是在每个输入的潜在空间中输出预定义分布的参数。然后 VAE 对该潜在分布施加约束，使其成为标准正态分布。VAE 构建两个网络，分别用来表示样本均值 μ_i 和样本方差 σ_i ，然后利用 μ_i 和 σ_i 采样得到隐含向量 z_i ，并迫使 z_i 能够大致地服从一个标准正态分布。在这样的限制条件下，既防止噪声为零，又保证了模型具

有生成能力，最后经过解码器就可以重构得到生成的样本 $\hat{x}_i$ 。VAE 的训练损失定义为重建损失和相似性损失的总和，重建损失表示为解码器生成的数据与输入数据的相似程度，使用元素误差衡量，相似性损失则是潜在空间分布和标准正态分布之间的 KL 散度，KL 散度始终大于等于 0，KL 散度越小，潜在空间分布与标准正态分布越接近。VAE 的损失函数定义如下

$$\mathcal{L} = D_{KL}(\mathcal{N}(\mu, \sigma^2) \parallel \mathcal{N}(0, 1)) + \frac{1}{n} \sum_{i=1}^n \|x_i - \hat{x}_i\|^2 \tag{2.18}$$

其中 x_i 表示输入编码器的第 i 个真实样本， $\hat{x}_i$ 表示解码器重构得到的第 i 个生成样本。

2.4 注意力机制

注意力机制^[49]（Attention Mechanism）由人类的注意力思维方式启发而来，当人类快速观察某个图像时，会把更多的注意力资源投入到感兴趣的区域，而对周围不感兴趣的区域，只给予很少的注意力资源，从而快速筛选出有价值的信息，这是人类在长期进化中形成的一种特殊的处理机制。注意力机制在处理时间信息方面具有独特的优势，它通过为不同时序上的特征向量分配不同的概率权重，来更好地学习特征之间的关联，提高特征抽取的质量，并且能够使得模型关注更重要的信息，因此可以取得更优秀的分类效果。

2.4.1 自注意力机制

自注意力机制是注意力机制的一种，其结构如图 2.10 所示。




图 2.10 自注意力结构

自注意力机制实际上是一个函数，输入是两个序列，分别为查询序列 Q 和键序列 K ，通过相似度计算，为查询序列 Q 的每个元素生成一个注意力分数，然后利用 Softmax 将注意力分数映射到 $[0,1]$ 之间，得到注意力权重。最后，将值序列和权重加权求和就可以获得量化后的输出。具体计算公式如下：

$$Q = W_Q * X \tag{2.19}$$

$$K = W_K * X \quad (2.20)$$

$$V = W_V * X \quad (2.21)$$

$$\text{Attn}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2.22)$$

其中 X 表示输入数据， W_Q 、 W_K 、 W_V 是网络可学习的参数， Q 、 K 、 V 分别表示查询序列、键序列和值序列， Attn 表示信息的加权平均， $\sqrt{d_k}$ 指的是键序列维度的平方根，用于调节内积的大小，防止某个值过大而出现严重的倾斜问题，同时也可以加快网络收敛速度。

2.4.2 多头自注意力机制

多头自注意力^[50]是自注意力机制的改进，主要是为了解决自注意力过度关注于自身位置的问题。多头自注意力机制实际上是多个独立 Attention 的并行计算，同时获得 h 个 (Q, K, V) 的不同表示，并计算每个表示的缩放点积注意力，最后将各个子空间抽取的特征拼接起来得到加权平均后的输出。多头自注意力机制的计算公式如下：

$$\text{Head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (2.23)$$

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W^O \quad (2.24)$$

其中 W_i^Q 、 W_i^K 、 W_i^V 是网络待学习的参数，而 h 表示子空间的数目。通过将自注意力机制拆分为多个头可以形成多个子空间，而在每个子空间独立计算、互不干扰，可以让模型去关注不同方面的信息。

2.5 小波变换和小波阈值去噪

2.5.1 小波变换

小波变换 (Wavelet Transform, WT)^[51]的提出主要是为了解决傅里叶变换处理非平稳信号有天生缺陷的问题。相比较于傅里叶变换，小波变换使用位于实空间和傅里叶空间中的函数，可以对信号同时在时域和频域内进行联合分析。小波变换通过将基本小波进行伸缩、平移等操作得到不同支撑域的小波基，然后和原始信号做内积运算，能够尽可能的突出信号局部特征，非常适用于突变非平稳的心电信号。基本小波在坐标轴上表现为长度有限且均值为 0 的曲线。从数学角度上，基本小波函数 $\psi(t)$ 性质满足如下公式：

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (2.25)$$

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\psi(t)|^2}{t} dt < \infty \quad (2.26)$$

通过控制尺度因子 a ， b 的大小，可以将基本小波转换为不同的小波函数 $\psi_{a,b}(t)$ ：

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.27)$$

尺度因子 a ， b 均为实数， a 控制函数的伸缩， b 控制函数的平移。连续小波变换

(Continuous Wavelet Transform, CWT) 的实质是原始信号 $f(t)$ 与被缩放和平移的连续小波基函数 $\psi_{a,b}(t)$ 内积，并在信号存在的整个期间里求和的结果：

$$W_f(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = \int_{-\infty}^{\infty} f(t) \cdot \psi_{a,b}(t) dt = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \cdot \psi_{a,b}\left(\frac{t-b}{a}\right) dt \quad (2.28)$$

小波变换基本流程如图 2.11 所示。




图 2.11 小波变换流程

经连续小波变换后，原来的一维信号转换为二维信号，实现了在时间和频率两个方面的分析。同时也可以根据小波逆变换公式将二维信号转换为原始的一维信号，小波逆变换公式如下所示：

$$f(t) = \frac{1}{C_\psi} \iint W_f(a,b) \psi_{a,b}(t) db \frac{da}{a^2} \quad (2.29)$$

在连续小波变换中， a 、 b 是连续变化的，这样会导致分解过程产生大量冗余信息并极大地增加了计算的复杂度。在实际应用中，为了保证原始信号信息完整性的同时并减少计算量，通常会将尺度因子 a 、 b 按幂级数离散化处理。离散小波变换公式如下：

$$W_f(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = \frac{1}{\sqrt{a}} \int f(t) \cdot \psi\left(\frac{t-b}{a}\right) dt \quad (2.30)$$

对原始信号离散小波分解后，重构公式如下：

$$f(t) = \frac{1}{C_\psi} \int_0^\infty \frac{1}{a^2} W_f(a,b) \cdot \psi\left(\frac{t-b}{a}\right) da db \quad (2.31)$$

2.5.2 小波阈值去噪

1. 小波阈值去噪

小波阈值去噪算法^[52]是基于小波变换理论提出的一种优秀的去噪算法，在处理过程中既可以保持信号的完整性又可以去除噪声，十分适合处理心电这种非平稳信号。假设有一组需要处理的信号：

$$f(t) = s(t) + n(t) \quad (2.32)$$

其中 $f(t)$ 代表含噪信号， $s(t)$ 表示不含噪声的真实信号， $n(t)$ 则是需要过滤掉的噪声。通过对原始心电信号 $f(t)$ 进行多尺度小波变换后，能够得到各尺度下的小波系数。在实际情况下，噪声信号通常表现为高频信号，而心电信号则一般表现为低频或更平滑的信号，经小波变换分解后，噪声的小波系数幅值远小于有效信号的小波系数幅值，因此可以设置一个合理的阈值分离出噪声和真实信号。小波阈值去噪的具体步骤如下：

(1) 根据噪声和心电信号的性质，选择合适的基本小波和分解尺度对原始信号进行小波分解。

(2) 选择合适的阈值和阈值函数，将分解后的小波系数幅值大于阈值的视作为有用的心电信号并保持不变，而将小波系数小于阈值的利用阈值函数抑制或直接去除。

(3) 将第二步处理后的小波系数进行自底向上的小波逆变换，就能获得需要的干净的心电信号。

2. 常用的阈值

在小波阈值去噪算法中，阈值的大小会直接影响到去噪的效果，阈值过大容易丢失有效信号，阈值过小容易导致噪声的残留。阈值^[53]的选择一般有这几种方法。

(1) 固定阈值。其公式如下所示：

$$\lambda = \sigma \sqrt{2 \ln(N)} \quad (2.33)$$

其中 N 为该尺度变化下频率较高的小波系数的数量， σ 是输入信号的噪声方差。

(2) 极大极小阈值。其公式如下所示：

$$\lambda = \begin{cases} \sigma \left[0.3936 + 0.1829 \left(\frac{\ln N}{\ln 2} \right) \right] & , N > 32 \\ 0 & , N \leq 32 \end{cases} \quad (2.34)$$

3. 阈值函数

一个合适的阈值函数能够有效地提高信号的信噪比，常用的阈值函数有软阈值和硬阈值^[54]两种。

(1) 硬阈值函数

当小波系数的绝对值小于阈值时，直接设置为 0；否则，保持不变。数学表示形式如下：

$$Y = \begin{cases} X, & |X| \geq \lambda \\ 0, & |X| < \lambda \end{cases} \quad (2.35)$$

(2) 软阈值函数

当小波系数的绝对值小于阈值时，处理方式与硬阈值相同；否则，令其减去阈值。相比较于硬阈值函数，软阈值得到的小波系数整体连续性较好。数学表示形式如下：

$$Y = \begin{cases} \text{sign}(X) (|X| - \lambda) & , |X| \geq \lambda \\ 0 & , |X| < \lambda \end{cases} \quad (2.36)$$

2.6 本章小结

本章首先介绍了心电图中的常见波形以及 MIT-BIH 数据集，然后引入了深度学习的相关知识，包括激活函数、优化器以及一些常见的深度学习模型，接着介绍了注意力机制及其变种，最后描述了小波变换的相关概念，包括连续小波变换、离散小波变换以及小波阈值去噪。

第 3 章 心电信号预处理算法

MIT-BIH 数据集中每条记录包含的心拍种类繁多，因此必须将连续的记录划分为标准长度的单个心拍才能用于后续的数据增强和数据分析。在该数据集中，存在着严重的噪声干扰，容易被误检为正常或异常的心拍，以至于直接降低分类模型的精度。针对上述情况，本章首先分析了心电信号采集过程中常见的噪声，接着利用小波阈值去噪算法去除心电信号中的噪声，最后根据定位到的 R 峰位置对心电记录进行分割和 Z-Score 标准化处理。

3.1 心电信号去噪

人体心肌细胞在体表的的活动产生了心电信号，而心电信号在采集过程中容易受到外界噪声的干扰，导致波形产生形变或者偏移，这严重阻碍了心电信号的分析，因此心电信号的去噪格外重要。

3.1.1 心电信号干扰

心电信号是心脏病诊断的重要分析依据，其具有频率小、幅度低（幅度： $10\mu\text{V}\sim 5\text{mV}$ ，频率： $0.05\sim 100.00\text{Hz}$ ）的特点，因此采集到的信号会不可避免地携带噪声。表 3.1 总结了心电信号中常见的三种噪声^[5]及其特性。

表 3.1 心电信号中的常见噪声

噪声种类	原因	频率范围
肌电干扰	环境和心理影响下的收缩舒张运动	5~2000Hz
工频干扰	电路系统的干扰	50Hz
基线漂移	肢体运动和呼吸	0.05~1Hz

下面具体介绍这三种噪声：

1. 肌电干扰：心电信号采集过程中普遍面临的一种噪声，主要是由于人体表皮肌肉收缩而造成的干扰，其频率在 5~2000Hz 之间，并且主要集中在 30~300Hz，类似于高频的高斯白噪声，在心电图上通常表现为变化迅速且不规则的波浪状。

2. 工频干扰：心电信号采集过程中很常见且不可避免，频率一般固定为 50Hz，干扰的幅度大小不等，主要是由于设备电路系统的电磁辐射。具体表现为以正弦波的形式叠加在原始心电信号上。

3. 基线漂移：一种常见的心电信号噪声，其频率一般低于 1Hz，并集中在

0.1Hz 左右，主要是由于受测者的肢体运动和呼吸引起的。具体表现为信号基线偏离正常位置，整体信号上下波动。由于基线漂移的影响，T 峰的峰值将高于 R 峰的峰值。

3. 1. 2 心电信号去噪与分析

小波变换方法具有十分优秀的时频分析表现，特别适合心电这种非平稳信号，它可以将含噪信号按照频段的不同分成高频信号和低频信号，因此，能够在保证信号完整性和连续性的同时有效地去除噪声。目前小波变换发展已经较为成熟，相比较于传统的去噪方法有着良好的表现。因此本文通过对原始信号进行小波分解来去除 MIT-BIH 数据集中的三种常见噪声，以降低其对于后续心电信号生成和分类的消极影响。

小波变换的分解尺度直接影响到心电信号的去噪效果，考虑到本文使用的 MIT-BIH 数据集信号采样频率为 360Hz 以及基线漂移的频率分布范围 (0.05~1Hz)，可以确定原始心电信号的小波分解尺度为 8 层。离散小波变换一般以正交小波为基函数，小波基函数的选择对于降噪的效果至关重要，一般从支撑长度、正交性、对称性、消失矩阶数等几个方面考虑。在本论文中，综合考量后选择 Daubechies 小波^[56]作为基本小波，其拥有正交、连续且紧支撑的优秀性质。原始心电信号经小波分解后各尺度近似信号与细节信号的频率带宽如表 3.2 所示。

表 3.2 各分解尺度下的频率带宽

分解尺度	近似信号频率带宽 (Hz)	细节信号频率带宽 (Hz)
1	0~90Hz	90~180Hz
2	0~45Hz	45~90Hz
3	0~22.5Hz	22.5~45Hz
4	0~11.25Hz	11.25~22.5Hz
5	0~5.625Hz	5.625~11.25Hz
6	0~2.8125Hz	2.8125~5.625Hz
7	0~1.40625Hz	1.40625~2.8125Hz
8	0~0.73125Hz	0.73125~1.40625Hz

根据工频干扰以及肌电干扰的频率分布范围，可以判断第一和第二尺度是其集中的主要地方。因此可以通过抑制第一和第二尺度的细节分量达到去除的目的，这里直接将小波系数置 0。然后对于第三到第八尺度的小波系数，将其绝对值和固定阈值比较，若小于固定阈值，则视作噪声并置 0，若大于固定阈值，则减去固定阈值。处理完成后，借助小波逆变换公式自底向上重构信号，就可以获得需要的干净心电信号。从图 3.1 对比分析可以看出，经小波阈值去噪后，信号中的毛刺已经消失，波形变得更加平滑。因此小波阈值去噪方法可以有效地消除心电信号中常见的三种噪声。




图 3.1 去噪前后信号对比

3.2 R 峰定位

一个合适的心拍划分有助于帮助深度学习模型更准确地提取心电信号中的关键特征，进而增强分类模型的整体性能。而心拍的划分依赖于 R 峰的准确定位，在本小节将利用 R 峰位置正好对应着小波变换后的模极值对的过零点的性质定位到 R 峰。

3.2.1 小波变换模极值与奇异点关系

通常利用 Lipschitz 指数表示信号奇异性的大小，Lipschitz 指数^[57]定义如下：设 n 是非负整数， $n < \alpha \leq n + 1$ ，如果存在两个常数 A 和 $h_0 > 0$ ，以及 n 次多项式 $P_n(h)$ ，使得任意的 $h \leq h_0$ ，均有 $|f(x_0 + h) - P_n(h)| \leq A|h|^\alpha$ ，则称 $f(x)$ 在点 x_0 的李氏指数为 α 。由 Lipschitz 指数的定义可知， α 可以表示信号的光滑程度： α 越大，表明该点越光滑，奇异性越小； α 越小，表明该点越尖锐，奇异性越大。并且随着分解尺度的变化，信号奇异点对应的小波变换模极大值有如下规律：当 $\alpha > 0$ ，小波变换极大值随着尺度的增加而增加，当 $\alpha < 0$ ，小波变换极大值随着尺度的增加而减小。当 $\alpha = 0$ ，小波变换极大值不会随大小而变化。因此根据上述变化规律，可以通过检测小波变换后各层上的模极值点来得到信号的奇异点。

3.2.2 基于小波变换的 R 波波峰检测

在一个完整的心电信号周期中，R 波的幅度最大，且其波峰位置正好对应着小波变换后的模极值对的过零点^[58]。而双正交二次样条小波可以有效地检测出奇异点^[59]，因此在本文中，选择其作为小波分解的基本小波。双正交二次样条小波是平滑函数的一阶导数，其表达式为：

$$Y = \begin{cases} h_0 = \frac{1}{4}, h_1 = \frac{3}{4}, h_2 = \frac{3}{4}, h_3 = \frac{1}{4} \\ g_0 = -\frac{1}{4}, g_1 = -\frac{3}{4}, g_2 = \frac{3}{4}, g_3 = \frac{1}{4} \end{cases}$$

(3.1)

考虑到 MIT-BIH 数据库的心电信号采样频率为 360Hz 以及 QRS 波群的频率主要集中在 0-45Hz 区间，因此选择将原信号进行四层小波变换，各尺度的小波系数如图 3.2 所示：




图 3.2 不同尺度下的小波系数

原始心电信号经分解后，各尺度的频带分布如表 3.3 所示：

表 3.3 各分解尺度下的频率带宽

分解尺度	近似信号频率带宽 (Hz)	细节信号频率带宽 (Hz)
1	0~90Hz	90~180Hz
2	0~45Hz	45~90Hz
3	0~22.5Hz	22.5~45Hz
4	0~11.25Hz	11.25~22.5Hz

QRS 波群的能量主要集中在第三和第四尺度上，而在第四尺度上容易受到高大的 T 波干扰，因此选择第三尺度更合适，且在该尺度下细节系数与噪声区

别最大。在第三尺度找到相邻的且不超过 120 毫秒的正负极值对^[12]，并选择正极大值大于阈值 $th1$ 且负极小值小于阈值 $th2$ 的作为有效的正负极值对。阈值的大小会直接影响最终 R 波波峰的识别效果，在本文中，将每个输入的 ECG 信号划分为四段，单独求出每段最大值的平均值的三分之一作为 $th1$ ，每段最小值的平均值的三分之一作为 $th2$ 。在确定第三尺度上细节系数的正负极值对后，就可以根据其过零点的位置确定 R 波波峰。图 3.3 是利用小波变换定位 R 波波峰的实例：




图 3.3 R 峰定位

根据实验结果可以发现，利用 R 峰位置正好对应着小波变换后的模极值对的过零点的性质能够准确定位到 R 峰。将该算法应用到 MIT-BIH 数据集中所有记录中，并把检测到的 R 峰位置保存到文件中。

3.3 心拍分割和标准化

通过 3.1 节和 3.2 节完成了心电信号的去噪和 R 波波峰的定位，本小节将实现心拍和分割和标准化处理。

3.3.1 心拍分割

根据 3.2 节定位到的 R 峰位置，截取 R 峰前 100 个点，R 峰后 199 个点，共

300 个点，作为一个完整的心拍。之所以设置截取 300 个点，是因为 MIT-BIH 数据集的采样频率是 360Hz，这样的截取方式可以有效地表示为一个完整的心跳周期。由于数据集中 102 和 104 号记录没有 MLII 导联信息故去除，另外，心拍类型种类繁多，这里只针对五种最常见的类型进行预测，分别是正常搏动（Normal）、房性早搏（APB）、室性早搏（PC）、左束支传导阻滞（LBBBB）、右束支传导阻滞（RBBBB）。其他心拍均为不常见类型或数量太少无法用于信号的分类。具体的心拍截取步骤如下：

- 1. 读取 R 峰位置和注释文件中对应的心拍类型，保存到列表中；
- 2. 根据 R 峰位置，取包括 R 峰在内的 300 个点作为一个完整的心拍周期；
- 3. 将每次取到的 300 个点保存到 csv 文件中，文件最后一列标注心拍类型；
- 4. 重复上述三个步骤，遍历所有记录；

经上述步骤处理后得到的数据集样本分布如表 3.4 所示，可以发现该数据集存在着严重的不平衡问题，Normal 类型的心拍占绝大多数，而其他类型的异常心拍只占很少一部分。

表 3.4 心拍划分结果

心拍类型	数量
Normal	71762
APB	1972
PVC	6981
LBBBB	6588
RBBBB	4979

3.3.2 心拍标准化

在神经网络的训练中，标准化是至关重要的一步，标准化操作通过将预处理的数据映射到限定的范围内，可以有效地缩放特征，避免样本的特征大小出现两极分化，不仅可以使得训练过程更加稳定还能加快网络收敛速度。本文采用 Z-Score 标准化方法处理心电信号，假设心电信号原数据集样本为 $X = \{x_1, x_2, \dots, x_n\}$ ，经标准化处理后的心电信号数据集样本为 $Y = \{y_1, y_2, \dots, y_n\}$ ，处理过程如以下公式所示：

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n (x_i) \tag{3.2}$$

$$x_{std} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \tag{3.3}$$

$$y_i = \frac{x_i - \bar{x}}{x_{std}} \tag{3.4}$$

其中 $\bar{x}$ 为样本均值， x_{std} 为样本方差，经过处理后，心电信号数据集样本 Y

符合均值为 0，方差为 1 的标准正态分布。

3.4 本章小结

本章首先介绍了心电信号中常见的三种噪声，然后利用小波阈值去噪算法去除了这三种噪声。接着利用 R 峰位置正好对应着小波变换后的模极大值的过零点的性质定位到 R 峰，并根据 R 峰位置将连续的记录划分成单个的心拍，每一个心拍长度为 300。最后对样本中的心电信号进行 Z-Score 标准化处理。

第 4 章 心电信号生成算法

在 MIT-BIH 数据集中存在着严重的数据不平衡问题^[60]，正常类别占绝大多数，而数十种异常类别只占很少一部分，数据集的不平衡会导致深度学习模型的训练偏向于包含大量样本的正常类，而在稀疏的异常类别上表现却很糟糕。克服这种不平衡的常见方法是通过使用平移、翻转、过采样等经典数据增强方法来人工创建合成数据。但是，此类方法会修改心电信号的时序特征、形态特征以及原始数据集的分布。针对这个问题，本章提出了通过 GAN 学习数据集的真实分布来生成高质量的心电信号，并将生成的数据用作额外的训练数据，以缓解数据不平衡和数据稀疏问题，从而提高分类模型对稀疏的异常心拍的识别能力。

4.1 数据不平衡问题

在分类任务中，很多数据集都存在着不平衡的现象，即少量的类别拥有大部分的样本，而大量的类别仅拥有小部分的样本。数据不平衡的存在对模型的学习过程有重要影响，通常产生的分类器对样本数目多的类别识别准确率很高，但对样本数目少的类别识别准确率却很低，因为它们的目的优化整体准确率，而没有适当考虑每个类别的相对准确率。数据不平衡问题越严重，各个类别上的识别效果越是两极分化。假设在一个二分类任务中，A 类与 B 类的比例为 99:1，模型的目标是提高整体的准确率，训练完成后，整体准确率为 99%，对 A 类都能完全识别，但是对于 B 类识别准确率却为 0，这样的模型并没有实际意义。在本文中所用的心律失常数据集 MIT-BIH 中也存在着严重的不平衡问题，样本的分布如图 4.1 所示：




图 4.1 MIT-BIH 数据集样本分布

可以看出，在该数据集中存在着严重的不平衡问题，N 类心拍的数目远超过其他四种类型的心拍，最少的是 A 类和 R 类，数据不平衡问题将严重影响分类模

型的性能。

常见的缓解不平衡问题的方法有过采样^[61]和欠采样^[62]两种，但是这两种方法很明显改变了原始数据的分布并且会引入额外的噪声。通过对数据不平衡问题的研究，本文提出通过 GAN 来学习真实心电信号的分布，以生成 MIT-BIH 数据集中样本数量较少的 A、V、L、R 四种异常心拍并添加到训练集中，通过这种生成式算法可以使得增强后的数据分布更均衡。而基于高质量的分布平衡的大量训练数据，模型能够学习到更深层次的无偏语义特征，因此能实现更精确的分类效果。

4.2 基于 DCGAN 的心电信号生成算法

4.2.1 DCGAN 基本原理

DCGAN^[63]全称是 Deep Convolutional Generative Adversarial Networks，是众多 GAN 变体中的一种。相比较于原始的 GAN，DCGAN 的改进如下：

1. 取消全连接和池化。相比较于传统的 GAN，DCGAN 放弃了模型中原来使用的全连接转而使用卷积和转置卷积，并使用步幅卷积和微步幅卷积来替代生成器和判别器中的池化层。

2. 激活函数的改进。判别器中使用 LeakyReLU，和 ReLU 不同的是，对于 x 小于 0 的情况不是直接输出 0，而是乘上一个斜率，因此可以避免训练过程中 ReLU 的神经元死亡问题。

3. 批量归一化。几乎每层卷积或转置卷积层后都连接着批量归一化层，使得每批量的输入都满足均值为 0，方差为 1 的标准正态分布，可以加速网络的训练并提升其稳定性。

4.2.2 生成模型

图 4.2 是基于 DCGAN 的心电信号生成算法的生成模型，该模型由模型^[68]改进而来，从左到右依次是输入层、连续七个转置卷积层、输出层。生成模型的输入是从标准正态分布采样的长度为 100 的随机噪声。输入层后连接转置卷积层，转置卷积是实现上采样的一种方式，被认为是卷积的反向过程，转置卷积可以根据卷积核大小和输出的大小，恢复卷积前的尺寸。输入每经过一层转置卷积，通道数就会缩减，而特征图的尺寸则会增大。每个转置卷积层后都连接批量归一化层，可以加快网络收敛速度，避免出现过拟合问题，并且每经过一层批量归一化都使用 ReLU 激活函数进行激活。输入的随机噪声经过连续七个

转置卷积层上采样后，尺寸最终变为 $1 \times 1 \times 300$ ，即心电图中心拍的长度。




图 4.2 生成模型网络结构

生成模型中的转置卷积层网络参数如表 4.1 所示：

表 4.1 转置卷积层参数设置

Layer	Input_size	in_channel	out_channel	kernel	stride	padding	Out_size
DeC	1*100*1	100	2048	4	1	0	1*2048*
onv1							4
DeC	1*2048*4	2048	1024	4	2	1	1*1024*
onv2							8
DeC	1*1024*8	1024	512	4	2	0	1*512*1
onv3							8
DeC	1*512*18	512	256	4	2	0	1*256*3
onv4							8
DeC	1*256*38	256	128	3	2	1	1*128*7
onv5							5
DeC	1*128*75	128	64	4	2	1	1*64*15
onv6							0
DeC	1*64*150	64	1	4	2	1	1*1*300
onv7							

4. 2. 3 判别模型

图 4.3 是基于 DCGAN 的心电信号生成算法的判别模型^[68]，由输入层、连续七个一维卷积层、输出层组成。判别器的输入由两部分组成，分别是真实的心电信号和生成模型合成的心电信号，长度均为 300。与二维卷积不同，一维卷积只在一个方向上进行卷积操作。每经过一层一维卷积，通道数就会增大，而特征图的尺寸则会缩减。每个卷积层后都连接批量归一化层，并采用 LeakyReLU 激活函数对神经元激活。经过连续七个一维卷积后，输入的尺寸变

为 1*1*1，然后经过 Sigmoid 激活函数将值映射到[0,1]之间，表示为对输入的心电信号的真实性评价。




图 4.3 判别模型网络结构

判别模型中的卷积层网络参数如表 4.2 所示：

表 4.2 卷积层参数设置

Layer	Input_size	in_channel	out_channel	kernel	stride	padding	Out_size
Con v1	1*1*300	1	64	4	2	1	1*64*15 0
Con v2	1*64*150	64	128	4	2	1	1*128*7 5
Con v3	1*128*75	128	256	4	2	1	1*256*3 7
Con v4	1*256*37	256	512	4	2	1	1*512*1 8
Con v5	1*512*18	512	1024	4	2	1	1*1024* 9
Con v6	1*1024*9	1024	2048	4	2	1	1*2048* 4
Con v7	1*2048*4	2048	1	4	1	0	1*1*1

4. 2. 4 损失函数

根据前面的介绍我们知道，生成器的目标是生成尽可能接近于真实心电信号的样本，而判别器的目标是正确区分出真实的心电信号和生成的心电信号，两者相互对抗不断提升彼此能力。其损失函数定义如下：

$$\text{Min}_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_{\text{prior}}(z)} [\log (1 - D(G(z)))] \quad (4.1)$$

其中 p_{data} 表示真实数据的分布， x 表示真实的心电信号， z 表示已知分布采样的

噪声， D 表示判别器的映射， G 表示生成器的映射。具体的训练过程如算法 4.1 所示：

算法 4.1 基于 DCGAN 的心电信号生成算法

Input: 训练集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$

Output: 基于 DCGAN 的心电信号生成模型

- 1 初始化生成器、判别器的参数分别为 θ_{Gen} 、 θ_{Dis}
- 2 设置学习率 η ，训练最大轮数 $epochs$ ，每批数据量的大小 n
- 3 **repeat**
- 4 从训练集 D 的分布 $P_{\text{data}}(x)$ 中随机采样 n 个 $\{x^1, x^2, \dots, x^n\}$
- 5 从已知分布 $P_{\text{prior}}(z)$ 中随机采样 n 个 $\{z^1, z^2, \dots, z^n\}$
- 6 使用 $\tilde{x}^i = G(z^i)$ 获得生成数据 $\{\tilde{x}^1, \tilde{x}^2, \dots, \tilde{x}^n\}$
- 7 更新 D 的参数 θ_{Dis} 来最大化：
$$\tilde{V} = \frac{1}{n} \sum_{i=1}^n \log D(x^i) + \frac{1}{n} \sum_{i=1}^n \log (1 - D(\tilde{x}^i))$$
- 9 $\theta_{\text{Dis}} \leftarrow \theta_{\text{Dis}} + \eta \nabla \tilde{V}(\theta_{\text{Dis}})$
- 10 更新 G 的参数 θ_{Gen} 来最小化：
$$\tilde{V} = \frac{1}{n} \sum_{i=1}^n \log D(x^i) + \frac{1}{n} \sum_{i=1}^n \log (1 - D(\tilde{x}^i))$$
- 12 $\theta_{\text{Gen}} \leftarrow \theta_{\text{Gen}} + \eta \nabla \tilde{V}(\theta_{\text{Gen}})$
- 13 **until** 设定的最大训练轮数 $epochs$

4.3 基于 Wasserstein-DCGAN 的心电信号生成算法

在实践中，普通的 GAN 相比较于生成器模型更容易优化判别器模型，而在最优判别器的形式下，生成器的损失等价变换为真实分布与生成分布之间的 JS 散度。当两个分布之间没有重叠或重叠部分可忽略时，无论二者距离多远，JS 散度始终是一个常数。因此，最终导致了生成器上的梯度消失，生成器无法再生成新的心电信号，样本始终单一，但是在真实的心电信号中，同一个类别的心拍有多种不同形状的波形。因此为了解决这个问题，在本小节引入了基于 Wasserstein 距离的损失函数替代了原先的 JS 散度，使得网络更容易收敛，避免出现“模式坍塌”现象。该模型的整体网络结构与 4.2 节大致相同，只是取消了判别器模型最后一层的 Sigmoid，即不再将输出映射到[0,1]之间。

4.3.1 Wasserstein 距离的定义

Wasserstein 距离^[64]用来衡量两个分布之间的重合度，它表示从一个分布移动到与另一个分布重合的最小能量耗损。相比较于 JS 散度，Wasserstein 距离对于即使完全不重叠的分布，也能提供有效的梯度。Wasserstein 距离的数学公式

如下:

$$W(P_{\text{data}}, P_g) = \inf_{\gamma \sim \Pi(P_{\text{data}}, P_g)} E_{(x,y) \sim \gamma} [\|x - y\|] \quad (4.2)$$

其中 P_g 表示生成数据分布, P_{data} 表示真实数据分布, $\Pi(P_{\text{data}}, P_g)$ 是 P_{data} 和 P_g 的联合分布, γ 表示从联合分布中的采样, $\|x - y\|$ 表示真实样本和生成样本之间的距离。Wasserstein 距离是连续的并且几乎处处可微, 这使得我们能够将模型训练到最优, 从而避免出现“模式坍塌现象”。

4.3.2 损失函数

Wasserstein 距离的计算是一个 NP-hard 问题, 无法直接求解, 需要进一步地转换才能用于生成对抗网络的损失函数。Arjovsky 等人^[64]提出通过李氏指数连续定理将 Wasserstein 距离的求解问题转化为公式:

$$W(P_{\text{data}}, P_g) = \frac{1}{K} \sup_{\|f\|_L \leq K} E_{x \sim P_{\text{data}}} [f(x)] - E_{x \sim P_g} [f(x)] \quad (4.3)$$

其中 $\sup$ 是最小上限, f 是遵循此约束的 1-Lipschitz 函数, 上述公式也就是为连续函数 f 添加一个限制, 使得 f 满足 $|f(x) - f(y)| \leq K|x - y|$, K 是 Lipschitz 常数。公式 4.2 可近似变换为下式进行求解:

$$K \cdot W(P_{\text{data}}, P_g) \approx \max_{w: \|f_w\|_L \leq K} E_{x \sim P_{\text{data}}} [f_w(x)] - E_{x \sim P_g} [f_w(x)] \quad (4.4)$$

对于满足 K -Lipschitz 限制的函数集合 f_w , 生成对抗网络的优化目标可以转换为:

$$L = E_{x \sim P_{\text{data}}} [f_w(x)] - E_{x \sim P_g} [f_w(x)] \quad (4.5)$$

对函数 f_w 添加 K -Lipschitz 约束的方式有多种, 本文采用基于梯度惩罚^[65]的方法。最终, 生成对抗网络的损失函数如下:

$$L = E_{x \sim P_{\text{data}}} [f_w(x)] - E_{x \sim P_g} [f_w(x)] + \lambda E_x \left[(\|\nabla_x \hat{D}(x)\|_2 - 1)^2 \right] \quad (4.6)$$

$\hat{x}$ 代表沿真实心电信号分布和生成心电信号分布的直线上均匀采样得到的数据, λ 是梯度惩罚的加权系数。判别器的目标是使得 L 最大, 而生成器的目标是使得 L 最小。基于 Wasserstein-DCGAN 的心电信号生成算法训练过程与算法 4.1 类似, 只是更换了损失函数。

4.4 融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法

在基于 Wasserstein-DCGAN 的心电信号生成算法中, 从标准正态分布随机采样作为生成器的输入, 并输出心电信号, 但是生成器事先并没有看过真正的心电信号, 因此在训练过程中必须经常调整网络参数, 这样容易导致网络出现剧烈动荡并减缓了收敛速度, 以至于直接影响生成数据的质量。针对这个挑战, 本文结合 VAE 的稳定性, 提出了融合 VAE 和 Wasserstein-DCGAN 的心电信号生

成模型。在该模型中，生成器的输入不单单是随机采样的噪声，还包括通过 VAE 编码器得到的有监督的潜在特征。基于该种策略得到的输入将更易于生成模型的训练和收敛，因为潜在特征里包含着心电信号的原始信息。同时为了拟合更丰富的波形，对于 VAE 的训练目标，其重建损失不再是固定的元素误差，而是判别器中表示的可学习的更高维度的特征误差^[66]。这是因为元素误差没有特殊针对的场景也不具备学习能力，并且其对于单个点的变化过于敏感，因此只倾向于生成固定不变的或者变化十分微小的样本，这与心拍的多样性不符。而判别器可以从更高的维度来更好地反映真实心电信号和生成心电信号的差异。

4.4.1 模型总体框架

本文提出的心电信号生成模型的总体框架如图 4.4 所示。它由三个子网络组成，分别是编码器网络、生成器网络和判别器网络，其中 VAE 网络的解码器与 Wasserstein-DCGAN 的生成器为同一部分。




图 4.4 模型总体框架

首先，编码器将每个输入的真实心电信号转换为低维的潜在特征表示，并添加到生成模型中，作为该模型的额外有监督输入，帮助模型更好的收敛。然后，生成器（解码器）将得到的潜在特征重构为心电信号，并使得重构后的信号在高维的特征上尽可能地接近于输入的心电信号，这里使用判别器的隐藏层计算输入信号和重构信号的特征相似度。最后，判别器对输入的真实心电信号和重构的心电信号的真实性做出评价，并将产生的损失分别传播到生成模型和判别模型中，更新网络的参数。通过三个网络的共同协作，生成数据的分布会稳定地逼近于真实数据的分布，因此能够生成高质量且多样性的心电信号。

4.4.2 模型结构

图 4.5 是构建的融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法的

VAE 网络，用于为每个输入的心电信号构建专属的隐含向量并重构得到合成的心电信号。




图 4.5 VAE 网络

输入数据是真实的心电信号，经过连续七层的一维卷积和批量归一化后，尺寸变为 $1 \times 2048 \times 4$ ，并且每经过一层归一化，都使用 LeakyReLU 激活函数进行非线性映射。然后经过两个一维卷积网络，输入通道是 2048，输出通道是 100，卷积核大小为 4，分别得到尺寸为 $1 \times 100 \times 1$ 的均值和方差的对数，之所以选择方差的对数，是因为方差总是大于等于 0，而选择生成方差的对数，可以避免使用激活函数处理。由于均值 μ 和方差的对数 σ 是采样得到的，而采样过程是离散的，因此不可导也无法利用梯度下降方法更新网络参数。这里借助重参数化技巧，从标准正态分布采样得到 ϵ ，然后让 $Z = \mu + \epsilon \times \sigma$ ，使得 Z 服从 $N(\mu, \sigma)$ 的分布，而从 ϵ 到 Z 只涉及了线性操作，这是可导的，并且 ϵ 的分布已知。接着将隐含向量 Z 作为解码器（生成器）的输入，经过连续七个转置一维卷积和批量归一化后，就可以从潜在空间得到解码后的数据，即生成的心电信号。判别器网络延续 4.3 节的判别器网络结构。

4.4.3 损失函数

为了实现 VAE 和 Wasserstein-DCGAN 联合训练的目的，需要结合 VAE 和判别器的损失来共同提高网络的能力^[66]，整个网络的损失函数分为三部分：编码器损失、生成器损失和判别器损失。编码器的损失函数分为两部分：1. 输入心电信号和重构心电信号之间的特征差异，使用判别器的隐藏层来衡量；2. 编码后的特征向量和标准正态分布之间的差异，使用 KL 散度衡量。编码器网络的损失函数定义如下：

$$L_{\text{encoder}} = \mathbb{E}_{q(Z|X)}[(D_l(X||G(Z)))] + D_{KL}(q(Z|X)||p(Z)) \tag{4.7}$$

其中 D_l 表示在判别器网络第 l 层隐藏层中生成信号和真实信号之间的特征差异，相比较于固定的元素误差，可学习的特征误差能够更好的反映真实信号和生成信号之间的相似度，这里选用判别器网络的倒数第二层隐藏层来衡量二者特征之间的差异。对于判别器而言，应尽可能地区分高斯噪声产生的心电信号 $G(Z_p)$ 、潜在特征产生的心电信号 $G(E(X))$ 和真实心电信号 X 。而对于生成器而言，则应尽可能使得重构后的心电信号与原信号在高维的特征上接近，并且保证生成器生成的心电信号会尽量被判别器认为是真实信号。生成器和判别器的损失函数设置如下：

$$L_{\text{generator}} = \lambda_1 \mathbb{E}_{q(Z|X)}[(D_l(X||G(Z)))] - \mathbb{E}_Z[D(G(Z_p))] - \mathbb{E}_X[D(G(E(X)))] \quad (4.8)$$

$$L_{\text{gan}} = -2 * \mathbb{E}_X[D(X)] + \mathbb{E}_Z[D(G(Z_p))] + \mathbb{E}_X[D(G(E(X)))] \quad (4.9)$$

$$L_{\text{discriminator}} = L_{\text{gan}} + \lambda_2 \mathbb{E}_X[(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2] \quad (4.10)$$

其中 E 表示编码器将输入转换为潜在特征的映射， λ_1 用于缩放特征差异的值，设置为0.1。 G 表示生成器的映射， D 表示判别器对于输入样本的真实度评价， λ_2 用于缩放梯度惩罚的值，设置为10。融合VAE和Wasserstein-DCGAN的心电信号生成算法的具体训练过程如算法4.2所示：

算法4.2 融合VAE和Wasserstein-DCGAN的心电信号生成算法

Input: 训练集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$

Output: 融合VAE和Wasserstein-DCGAN的心电信号生成模型

- 1 初始化编码器、解码器、判别器的参数分别为 θ_{Enc} 、 θ_{Gen} 、 θ_{Dis}
 - 2 设置学习率 η ，训练最大轮数 $epochs$ ，每批数据量的大小 n
 - 3 **repeat**
 - 4 $X \leftarrow$ 从心电信号训练集 D 随机 mini-batch 采样 n 个心拍
 - 5 $Z \leftarrow \text{Enc}(X)$ ，编码得到潜在特征
 - 6 计算分布的相似程度 $D_{KL}(q(Z|X)||p(Z))$
 - 7 $\tilde{X} \leftarrow \text{Gen}(Z)$ ，重构得到潜在特征产生的心电信号
 - 8 计算输入信号和重构信号之间的特征差异 $\mathbb{E}_{q(Z|X)}[(D_l(X||\tilde{X}))]$
 - 9 $Z_p \leftarrow$ 从先验分布 $N(0,1)$ 采样
 - 10 $X_p \leftarrow \text{Gen}(Z_p)$ ，解码得到高斯噪声产生的心电信号
 - 11 计算三个网络的损失： L_{encoder} 、 $L_{\text{generator}}$ 、 $L_{\text{discriminator}}$
 - 12 根据梯度来更新参数：

$\theta_{\text{Enc}} \leftarrow \theta_{\text{Enc}} + \nabla_{\theta_{\text{Enc}}}(L_{\text{encoder}})$
 $\theta_{\text{Gen}} \leftarrow \theta_{\text{Gen}} + \nabla_{\theta_{\text{Gen}}}(L_{\text{generator}})$
 $\theta_{\text{Dis}} \leftarrow \theta_{\text{Dis}} + \nabla_{\theta_{\text{Dis}}}(L_{\text{discriminator}})$
 - 14 **until** 设定的最大训练轮数 $epochs$
-

4.5 实验验证

4.5.1 评价指标

为了衡量生成心电信号和真实心电信号的相似性，本文使用常用的两种判断时间序列相似度的指标^[67]，分别是百分比均方根误差（The Percent Root Mean Square Difference，PRD）和均方根误差（Root Mean Square Error，RMSE），两种评价指标具体定义如下：

$$PRD = 100 \times \sqrt{\frac{\sum_{i=1}^N (x_i - r_i)^2}{\sum_{i=1}^N x_i^2}} \tag{4.11}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - r_i)^2} \tag{4.12}$$

其中 r_i 表示生成的时间序列第 i 个点， x_i 表示真实的时间序列第 i 个点， N 表示时间序列长度， PRD 、 $RMSE$ 值越小表明生成的信号和原始信号越相似，即生成的信号质量越高。

4.5.2 实验设计

根据文献^[68]建议，首先从标准差为 0.02、均值为 0 的高斯分布采样，并初始化编码器、生成器和判别器的权值。然后将第三章预处理后的 MIT-BIH 数据集按照 7：3 的比例，划分为训练集和测试集，同时将训练集作为心电信号生成算法的输入。训练完成后，在测试集上比较生成的心电信号与原信号的相似程度。三种心电信号生成算法的网络训练参数如表 4.3 所示。

表 4.3 网络训练参数

参数名	参数值
编码器学习率	0.0002
生成器学习率	0.0002
判别器学习率	0.0002
梯度下降方式	Adam(0.5, 0.999)
Batchsize	96
Epochs	3000
Negative_Slope	0.2

训练过程遵循单独交替迭代训练的方法，模型共训练 3000 个 epochs，批量大小为 96，LeakyReLU 的负斜率设置为 0.2。考虑到生成器和判别器的训练速度差异，因此两个模型的更新速度有所不同，设置为判别器每更新五次，生成器更新一次。

4.5.3 基于 DCGAN 的心电信号生成实验

图 4.6 展示了基于 DCGAN 的心电信号生成算法在 3000 个 epochs 的训练过程中生成器模型和判别器模型的损失变化。




图 4.6 生成器和判别器损失变化

可以发现随着训练轮数的增加，判别器的损失逐渐趋向于稳定，而生成器的损失逐渐趋向于 0，此时生成器不能产生有效的梯度，因此无法继续提高其能力也不能产生新的不同样本，这表明生成器生成的心电信号单一。这种情况发生的原因是 G 只要学会欺骗 D 就可以了，所以 G 其实可以只生成少量真实数据即可，极端情况下甚至可以只生成一个真实数据就可以欺骗 D。由于原始数据中 N 类的数量足够多，因此实验中只生成异常心拍（A、V、L、R）的数据。

APB 训练初期和训练完成时生成数据的变化如图 4.7 所示：




图 4.7 APB 训练初期和训练完成生成的数据

PVC 训练初期和训练完成时生成数据的变化如图 4.8 所示：




图 4.8 PVC 训练初期和训练完成生成的数据

LBBBB 训练初期和训练完成时生成数据的变化如图 4.9 所示：




图 4.9 LBBBB 训练初期和训练完成生成的数据

RBBBB 训练初期和训练完成时生成数据的变化如图 4.10 所示：




图 4.10 RBBBB 训练初期和训练完成生成的数据

表 4.4 展示了 DCGAN 模型生成的电信号和真实信号在 PRD 和 RMSE 两个指标上的相似度评估值。根据实验结果，可以发现其生成的样本单一、缺乏多样性且质量不高。出现这种现象，主要是因为在实践中，相比较于生成器模型，GAN 更容易优化判别器模型，而在最优判别器的形式下，生成器的损失等价变换为真实分布与生成分布之间的 JS 散度。当两个分布之间没有重叠或重叠

部分可忽略时，无论距离多远，JS 散度始终是一个常数。因此，最终导致了 G 上的梯度消失，G 无法再生成新的心电信号，样本始终单一。

表 4.4 生成数据相似度

模型类型\指标	PRD	RMSE
DCGAN	97.6	0.56

4.5.4 基于 Wasserstein-DCGAN 的心电信号生成实验

图 4.11 展示了基于 Wasserstein-DCGAN 的心电信号生成算法在 3000 个 epochs 的训练过程中生成器模型和判别器模型的损失变化。




图 4.11 生成器和判别器损失变化

可以发现在改进损失函数后，并未出现生成器梯度为 0 的情况。因此，生成器和判别器可以通过不断对抗提高彼此能力，训练完成后，生成器已经能拟合真实心电信号的分布，而判别器也无法正确的区分生成的心电信号和真实的心电信号。但是由于不合理的随机输入的噪声，判别器和生成器的损失在训练后期依然有严重的震荡。

APB 训练初期和训练完成时生成数据的变化如图 4.12 所示：




图 4.12 APB 训练初期和训练完成生成的数据

PVC 训练初期和训练完成时生成数据的变化如图 4.13 所示：




图 4.13 PVC 训练初期和训练完成生成的数据

LBBBB 训练初期和训练完成时生成数据的变化如图 4.14 所示：




图 4.14 LBBBB 训练初期和训练完成生成的数据

RBBBB 训练初期和训练完成时生成数据的变化如图 4.15 所示：




图 4.15 RBBBB 训练初期和训练完成生成的数据

表 4.5 展示了改进后的基于 Wasserstein-DCGAN 的心电信号生成模型在 PRD 和 RMSE 两个指标上的相似度评估值。根据实验结果，可以发现在使用 Wasserstein 距离和梯度惩罚的损失函数后，生成的心电信号与原信号更加接近

且呈现出更明显的多样性，这表明使用改进的损失函数后能够有效地避免模式坍塌问题。

表 4.5 生成数据相似度

模型类型\指标	PRD	RMSE
Wasserstein-DCGAN	67.3	0.45

4.5.5 融合 VAE 和 Wasserstein-DCGAN 的心电信号生成实验

图 4.16 展示了融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法在 3000 个 epochs 的训练过程中生成器模型和判别器模型的损失变化。




图 4.16 生成器和判别器损失变化

可以发现在融合 VAE 和 Wasserstein-DCGAN 后，该心电信号生成模型训练前期产生了轻微的震荡，但是随着训练轮数的增加，模型很快就趋向于稳定，并且没有出现严重的震荡。这表明在生成器的输入中添加 VAE 编码器得到的有监督的潜在特征能够帮助模型更快更稳定的收敛，从而可以取得更高质量的生成数据。

APB 训练初期和训练完成时生成数据的变化如图 4.17 所示：




图 4.17 APB 训练初期和训练完成生成的数据

PVC 训练初期和训练完成时生成数据的变化如图 4.18 所示：




图 4.18 PVC 训练初期和训练完成生成的数据

LBBBB 训练初期和训练完成时生成数据的变化如图 4.19 所示：




图 4.19 LBBBB 训练初期和训练完成生成的数据

RBBBB 训练初期和训练完成时生成数据的变化如图 4.20 所示：




图 4.20 RBBBB 训练初期和训练完成生成的数据

表 4.6 展示了融合 VAE 和 Wasserstein-DCGAN 的生成模型在 PRD 和 RMSE 两个指标上的相似度评估值。根据实验结果可以发现，在生成器的输入中添加 VAE 编码器得到的有监督的潜在特征后，由于生成器获得了原始信号的相关信息，因此相比较于输入只是随机采样噪声的 Wasserstein-DCGAN 的心电信号生成模型，该模型的 PRD 和 RMSE 值均有一定程度的下降，生成数据的质量有明

显的提高。并且由于使用判别器中表示的特征误差替换固定的元素重建误差，因此波形的多样性和连续性更好。

表 4.6 生成数据相似度对比

模型类型\指标	PRD	RMSE
VAE-Wasserstein-DCGAN	53.2	0.28

4. 6 对比分析

高质量的生成样本能够缓解数据不平衡问题，而低质量的生成样本则会修改数据的分布，进而影响分类模型的性能。本小节中，将在 PRD 和 RMSE 两个评价指标上，将本文提出的三种心电信号生成模型与其他传统的生成模型进行对比。

4. 6. 1 生成样本相似度对比

表 4.7 列出了本文提出的三种针对心电信号的生成模型与其他传统的生成模型的生成数据相似度对比：

表 4.7 生成数据相似度对比

模型类型\指标	PRD	RMSE
VAE-Wasserstein-DCGAN	53.2	0.28
Wasserstein-DCGAN	67.3	0.45
DCGAN	97.6	0.56
LSTM-CNN GAN	68.83	0.51
BILSTM-MLP	147.73	0.61
RNN-VAE	146.57	0.609
LSTM-VAE	145.97	0.607

VAE 通常易于训练，但由于元素误差等不完善的度量，生成的数据质量较低且样本单一。而普通的 GAN 虽然有很好的生成能力，但是由于其损失函数的不合理以及随机采样的输入，因此训练过程不稳定且难以正常收敛，从而导致最终生成的信号质量不高。针对这个问题，本文结合二者的优点提出了融合 VAE 和 Wasserstein-DCGAN 的心电信号生成模型，该模型将编码器得到的有监督的潜在特征作为生成器的额外输入，并使用始终能提供有效梯度的 Wasserstein 距离替代原先的 JS 散度，同时对于 VAE 训练目标，使用可学习的更高维度的特征误差替代固定的元素误差。因此模型并未出现梯度消失、模式坍

塌现象，并且能正常稳定地收敛。实验结果表明，该模型生成心电信号的 PRD 值和 RMSE 值均低于其他模型，即该模型生成的数据与原数据更相似，并且其表现出更明显的多样性。因此能够更加有效地缓解数据集的不平衡问题，从而提高分类模型对稀疏的异常心拍的识别能力。

4.7 本章小结

心律失常数据集中存在着严重的不平衡现象，针对传统数据增强方法容易产生过拟合和修改形态特征的问题，本文提出了使用 GAN 生成心电信号，分析了 DCGAN 心电信号生成模型训练不稳定、生成信号单一的原因，并使用 Wasserstein 距离和梯度惩罚的损失函数代替原损失函数，提高了训练过程的稳定性和生成信号的多样性。并在这个基础上，针对 Wasserstein-DCGAN 心电信号生成模型损失动荡收敛速度慢的问题，提出了使用 VAE 编码器得到的潜在特征表示作为 Wasserstein-DCGAN 生成模型的额外有监督输入，从而有效地提升了模型的收敛速度和稳定性。同时为了拟合更丰富的波形，对于 VAE 的训练目标，其重建损失不再是固定的元素误差，而是判别器中表示的可学习的更高维度的特征误差。最后，在 PRD 和 RMSE 两个指标上，将本文提出的心电信号生成模型与其他传统的生成模型进行对比。

第 5 章 心电信号分类算法

本章将结合多头自注意力机制设计心电信号分类算法，并使用前一章提出的融合 VAE 和 Wasserstein-DCGAN 的心电信号生成模型对训练集增强，以缓解数据不平衡和数据稀疏问题。同时，使用了一种成本敏感的损失函数即焦点损失，提高分类模型对稀疏的异常心拍的识别能力。最后，设计实验并对比其他心电信号分类模型。

5.1 引言

CNN 模型通过设置大小不同的卷积核来抽取心电信号的形态特征，然后借助池化层来压缩特征图提取主要特征，从而保存心电信号中的重要信息。本研究中使用的心电图是一维时序信号，执行分类任务时通常会考虑心电信号时序上的影响，而 CNN 在处理时间序列时无法有效地捕捉到数据之间存在的前后联系，深度学习模型 LSTM 的引入可以有效解决这个问题。CNN 和 LSTM 的叠加已被证明在多类心律失常检测中十分有效^[69]，但是，LSTM 只能捕捉心电信号短距离依赖的特征，而对于中远距离的相互依赖的特征，则需要长时间的信息积累才有可能捕捉得到，并且特征之间距离越远，获得有效信息的可能性更小。不仅如此，LSTM 处理心电信号时还忽略了这样一个事实，即从心电信号中提取的特征图的不同时间段对信号分类的贡献不同。因此为了解决这个问题，本文引入了多头自注意力机制来将特征空间划分为多个子空间，在每个子空间独立的计算心电信号全局特征之间的关联关系并为不同时间段的特征赋予不同的注意力权重，因此能够有效地捕捉信号长时序上的依赖关系并量化各个时间段特征对于信号分类的贡献，从而使得模型能够关注更重要的特征并提升整体的性能。

5.2 基于 CNN 和 LSTM_Attention 的心电信号分类算法

5.2.1 模型总体框架

本文设计的心电信号分类模型总体框架如图 5.1 所示。针对 MIT-BIH 数据集样本分布不平衡的问题，使用本文提出的融合 VAE 和 Wasserstein-DCGAN 的心电信号生成模型对异常心拍进行数据增强并补充到训练集中，以平衡该数据集中正常心拍和异常心拍的比例。将增强后的训练集输入到心电信号分类模型

中，经过 CNN 和 LSTM 抽取形态特征和时序特征后，利用多头自注意力机制捕捉心电信号全局特征的关联关系并区分不同时序上特征对于心拍分类的贡献，融合后的信息经过 Softmax 进行五分类，分别对应五种心拍。为了进一步降低不平衡分布带来的消极影响，增强模型对于异常心拍的识别能力，使用了焦点损失函数，增加对异常心拍分类错误的惩罚力度，使得模型能够学习到该类心拍更深层次的特征，从而提高模型对该类心拍的识别能力。




图 5.1 模型总体框架

5.2.2 网络结构

本文提出的基于 CNN 和 LSTM_Attention 的心电信号分类模型的网络结构如图 5.2 所示。




图 5.2 网络结构

该模型的整体结构从左到右依次为输入层、两层 ConNormPool、LSTM、Attention 层、全连接层、输出层。模型的输入是预处理后的心拍，长度为 300。然后经过连续两层的 ConNormPool 层提取心电信号中的形态信息并保留重要的特征。接着经过 LSTM 层捕捉信号之间的前后联系，LSTM 层后连接着多头自注意力层，多头自注意力层通过三个全连接网络分别得到 Q、K、V 的不同表示，并将 Q、K、V 都各自拆分成四个子空间，在每个子空间独立的计算缩放的点积

注意力，管理并量化相互依赖的特征。接着将各个子空间的计算结果拼接起来得到最终的状态，拼接完成后进行批量归一化，并采用 ReLU 激活函数进行非线性映射。融合后的特征展平为一维向量输入到全连接层，全连接层将 4800 维压缩成 5 维的实数向量。最后经过一层 Softmax 将 5 维实数向量映射为一个 5 维的概率分布，分别对应着 N、L、R、V、A 五个类别的概率值，各个维度的值都限定在[0,1]之间，并且总和为 1。标准的 Softmax 计算方法如下：

$$\sigma(\mathbf{Z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \tag{5.1}$$

其中K表示数据的维度， $\sigma(\mathbf{Z})_j$ 表示第j维的概率。

5.2.3 数据增强

数据采用第三章预处理后的 MIT-BIH 数据集，并按照 7:3 的比例，划分为训练集和测试集，并将训练集作为 5.2.2 节心电信号分类算法的输入，损失函数为交叉熵。同时使用本文提出的融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法对训练集进行补充，图 5.3 展示了在不同数目的补充样本的情况下，各类别的 F1 值变化，F1 值越大，分类的效果越好。




图 5.3 数据补充数目对于各个类别 F1 值的影响

从图 5.3 可以发现，在对原始数据集扩充后，模型在各个异常类别上的 F1 值均得到了显著地提升，尤其是原样本数目最少的 A 类。因此，本文提出的心

电信号生成式算法能够有效地学习到真实数据的分布，并可以通过数据增强的方式缓解数据集的不平衡问题。在均衡分布的数据集的基础上，模型能够学到不同心拍更深层次的特征。数据增强前后的训练集样本分布如图 5.4 所示。




图 5.4 数据增强前后样本分布

可以发现经过数据增强后，样本的分布变得更加均衡，虽然 N 类的数目仍是最多的，但是其所占的比例从之前的 77%降低到了 50%左右，而其他类别的心拍数目均有不同程度的提升，尤其是 A 类，从 2%提高到了 8.3%，N 类与 A 类的比例也从之前的 36:1 降到了现在的 6:1。这样更均衡的分布，使得模型在训练时候不会特殊地偏向于某一类，因此即使是在样本数目较少的异常心拍上，都有十分优秀的表现。

5.2.4 损失函数

在传统的心电信号的分类任务中，通常采用交叉熵作为损失函数，因为它们的目的是优化整体准确率，并不会考虑每个类别的相对准确率。交叉熵的数学公式如下：

$$H(p, q) = - \sum p_i \log q_i \tag{5.2}$$

其中 p_i 为输入样本真实的标签，而 q_i 是网络预测的结果， $H(p, q)$ 可以衡量 p, q 的相似性。可以发现交叉熵施加惩罚的时候没有任何区分，但是像心律失常这样的医学数据集，异常类别错误分类的成本通常远高于对正常类别错误分类的成本。由于数据集的不平衡性，这种不公平的损失函数会进一步增加模型的分类错误成本。因此在本小节中，针对该问题使用了焦点损失函数^[70]，焦点损失是交叉熵损失的改进版本，其数学公式如下：

$$L_f = - \sum p_i \alpha_i (1 - q_i)^{\gamma} \log (q_i) \tag{5.3}$$

$$\alpha_i = \begin{cases} \alpha & \text{if } p_i = 1 \\ 1 - \alpha & \text{otherwise} \end{cases} \tag{5.4}$$

其中 α_i 表示第 i 类样本的权重, 参数 γ 是一个固定的正值, 它调节样本被降低权重的速率。如果 $\gamma = 0$, 则焦点损失函数类似于交叉熵函数。当 γ 增加时, 调制因子的效率也会增加。此外, α 用作 0 和 1 之间的固定值, 以平衡正负标记样本。 γ 设置为 2, α 设置为 0.25。通过增加对样本数目较少的异常心拍的惩罚力度, 使得网络可以学到该类异常心拍的更深层次的特征, 从而能够在减少不平衡分布带来的消极影响的同时并提高模型的识别能力。该心电信号分类模型的训练过程如算法 5.1 所示:

算法 5.1 基于 CNN 和 LSTM_Attention 的心电信号分类算法

Input: 训练集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$

Output: 基于 CNN 和 LSTM_Attention 的心电信号分类模型

- 1 使用融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法生成四种异常心拍, 并提供补充数据集 $D_{augmentation} = \{(x_1, y_1), (x_2, y_2), \dots, (x_{m'}, y_{m'})\}$
- 2 合并原始数据集和补充数据集, 得到新的数据集 $D' \leftarrow D \cup D_{augmentation}$
- 3 初始化 CNN 和 LSTM_Attention 的心电信号分类模型网络参数 Θ
- 4 设置学习率 η , 训练最大轮数 $epochs$, 每批数据量的大小 n
- 5 **repeat**
- 6 从数据集 D' 中随机选择 n 个 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ 样本组成一批 D_{batch}
- 7 将 n 个数据 D_{batch} 输入到基于 CNN 和 LSTM_Attention 的心电信号分类模型中, 输出分类结果 $\{\hat{y}_1, \dots, \hat{y}_n\}$
- 8 使用焦点损失计算出每个样本的损失 $\{L_i(y_i, \hat{y}_i)\}_{i=1}^n$
- 9 使用 Adam 算法优化损失, 计算 n 个样本的平均梯度 $g \leftarrow \frac{1}{n} \Delta_{\Theta} \sum_{i=1}^n L_i(y_i, \hat{y}_i)$
- 10 更新网络参数 $\Theta \leftarrow \Theta - \eta g$
- 11 **until** 设定的最大训练轮数 $epochs$

5.3 实验设置与分析

5.3.1 评价指标

在心电信号分类任务中, 分类结果为正常的占了绝大多数, 因此针对这类样本分布不均衡的分类任务, 为了更好地评价模型的分类性能, 实验中设置了四个评价指标, 分别是准确率 (Accuracy, ACC)、精确率 (Precision, Pre)、召回率 (Recall, Rec)、F1 值 (F1-Score, F1)。具体计算公式如下:

$$Acc = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (5.5)$$

$$Pre = \frac{TP}{TP + FP} \times 100\% \quad (5.6)$$

$$\text{Rec} = \frac{TP}{TP + FN} \times 100\% \tag{5.7}$$

$$\text{F1} = \frac{2 \times \text{Pre} \times \text{Rec}}{\text{Pre} + \text{Rec}} \times 100\% \tag{5.8}$$

其中 TP 为真阳性，代表把正样本成功预测为正的数目；FN 为假阴性，代表把正样本错误的预测为负的数目；FP 为假阳性，代表把负样本错误的预测为正的数目；TN 为真阴性，代表把负样本成功预测为负的数目。

5.3.2 实验设计

网络的 Dropout 丢弃率设置为 0.2，表示随机将 20%的神经元的输出暂时从网络中丢弃。这样做可以有效地防止神经元在训练过程中相互依赖，避免出现过拟合问题。网络的具体参数如表 5.1 所示：

表 5.1 网络参数设置

参数名	参数值
学习速率初始值	0.0001
梯度下降方式	Adam(0.5,0.999)
BatchSize	96
Epochs	100
Dropout	0.2

5.3.3 实验结果

图 5.5 展示了训练期间该心电信号分类模型准确率的变化，可以发现随着训练轮数的增加，模型逐渐趋向于稳定，并且拥有较高的整体准确率。




图 5.5 不同 Epoch 的准确率变化

由于在心律失常这样的医学数据集中，异常类别错误分类的成本通常远高

于对正常类别错误分类的成本。因此与整体的准确率相比，我们更关注算法在异常心拍上的表现。传统的机器学习方法和深度学习方法，由于样本质量和数量的限制，一直面临着对稀疏的异常心拍识别精度不够高的情况。针对这个挑战，本文从四个方面给出了新的针对性解决方案，分别是：一，利用小波阈值降噪算法对心电信号预处理，突出信号中的重要特征；二，通过学习真实数据的分布生成四种异常心拍，以提供补充数据集并平衡样本分布；三，使用了成本敏感的损失函数，以增强分类模型对异常心拍的学习能力；四，根据心电信号时序上的关系，引入了多头自注意力机制捕捉全局特征之间的依赖关系并量化不同时间段特征对于心电信号分类的贡献。表 5.2 展示了本文提出的方法在各个类别上的具体表现，可以发现即使是在原本稀疏的异常心拍上，该算法也表现出了优秀的性能。

表 5.2 分类结果

类别/标准	精确率	召回率	F1
N	99.87%	99.85%	99.86%
A	95.72%	94.68%	95.19%
V	98.39%	98.51%	98.45%
L	98.29%	98.15%	98.22%
R	97.35%	97.64%	97.49%

表 5.3 展示了本文提出的方法与其他方法的对比结果：

表 5.3 MIT-BIH 数据库上本文方法和其他方法对比结果

模型	特征提取	准确率	精确率	召回率	F1
随机森林 ^[20]	小波包熵 + RR 区间	93.80%	93.84%	93.84%	93.84%
SVM ^[18]	小波包+独立分量相关	96.20%	96.30%	94.18%	95.11%
1D-CNN ^[71]	经验模态分解	98.60%	97.05%	94.12%	95.46%
BiLSTM ^[72]	端到端	97.70%	96.22%	94.94%	95.58%
CNN+Smote ^[73]	RR 区间	98.30%	-	-	-
2D-CNN ^[74]	小波变换	98.20%	-	-	-
Encoder+ SVM ^[75]	编码器	99.45%	-	-	-
本文方法	-	99.52%	97.92%	97.76%	97.84%

多年来，许多关于心电图的研究都使用了 MIT-BIH 心律失常数据库进行分

析，这些研究更多的考虑从模型结构、特征抽取、特征融合等方面来提高分类的准确率，却忽视了一个高质量的分布平衡的大量训练数据对于深度学习方法的重要性，并且其损失函数也并未考虑到错误分类的成本，虽然整体准确率较高，但是在异常心拍上表现并不突出。实验结果表明，相比较于其他的心电信号分类算法，本文提出的算法拥有更高的准确率、精确率、召回率和 F1 值，因此能够发挥更优秀的医疗辅助价值。

5.4 消融实验

为了观察本文提出方法的各个模块对于分类性能的影响，在本节将设计消融实验，分别比较损失函数改进前后、数据增强前后、模型结构修改前后该分类模型性能的变化。

5.4.1 损失函数对比

训练集采用经数据增强后的数据集，模型使用本文提出的基于 CNN 和 LSTM_Attention 的心电信号分类模型，其余网络参数均保持不变。如图 5.6 是交叉熵和焦点损失训练过程准确率对比，可以发现使用焦点损失后可以有效提高整体的准确率。




图 5.6 损失函数对比

但是与整体的准确率相比，我们更关注模型在异常心拍上的表现。表 5.4 展示了损失函数改进前后分类模型在各个心拍上的 F1 值对比。可以发现在使用焦点损失后，虽然对 N 类的惩罚力度下降了，但是由于 N 类有大量的样本加持，因此其 F1 值仅有极小幅度的下降，而其他类型心拍的 F1 值均有不同幅度的提升，特别是样本数目最少的 A 类。这表明焦点损失通过施加不同的惩罚力度可以让模型学习到异常心拍的更深层次的特征，从而能够有效地提升该类异常心

拍的 F1 值，并减少分类错误的成本。

表 5.4 损失函数改进前后在各个心拍上 F1 值对比

损失函数/心拍类型	N	A	V	L	R
交叉熵	99.89%	89.03%	93.07%	92.93%	91.74%
焦点损失	99.86%	95.19%	98.45%	98.22%	97.49%

5.4.2 数据增强对比

模型使用本文提出的基于 CNN 和 LSTM_Attention 的心电信号分类模型，损失函数采用焦点损失，其余网络的参数均保持一致。图 5.7 是数据增强前后训练过程准确率对比，可以发现在对数据增强后模型的整体准确率有了明显的提高。




图 5.7 数据增强对比

与整体的准确率相比，我们更关注模型在异常心拍上的表现。表 5.5 展示了数据增强前后分类模型在各个心拍上的 F1 值对比。

表 5.5 数据增强前后在各个心拍上 F1 值对比

数据变化/心拍类型	N	A	V	L	R
未数据增强	99.87%	80.46%	88.95%	87.21%	84.35%
数据增强	99.86%	95.19%	98.45%	98.22%	97.49%

可以发现，在数据增强后，异常心拍的 F1 值均有明显的提升，尤其是数量最少的 A 类。因此，本文提出的融合 VAE 和 Wasserstein-DCGAN 的心电信号生成算法能够有效地学习到真实数据的分布，并且可以通过生成式的方式使得数据的分布更均衡。而基于高质量的分布平衡的大量训练数据，模型能够学习到更深层次的无偏语义特征，因此能实现更精确的分类效果。

5.4.3 网络结构对比

训练集采用经数据增强后的数据集，损失函数采用焦点损失，模型分别为 CNN、CNN-LSTM 和引入多头自注意力机制后的模型，其余网络参数均保持一致。图 5.8 是三种模型训练过程准确率对比，可以发现 CNN 模型的分类效果不是很理想，而在引入 LSTM 和多头自注意力机制后，模型的整体准确率有了明显的提高。




图 5.8 不同网络结构对比

表 5.6 展示了 CNN、CNN-LSTM 和引入多头自注意力机制后的模型在各个心拍上的表现对比。

表 5.6 不同网络结构在各个心拍上 F1 值对比

网络结构/心拍类型	N	A	V	L	R
CNN	97.27%	85.63%	91.38%	90.59%	87.82%
CNN-LSTM	98.96%	90.69%	95.12%	95.34%	94.69%
Attention	99.86%	95.19%	98.45%	98.22%	97.49%

可以发现，只使用 CNN 的模型对于异常心拍的识别能力有着明显不足，A 类的 F1 值只有 85.63%，因为其并未考虑到时序上的关联，而心电信号是典型的一维时间序列，不同时序上的特征存在着相互依赖的关系。在加入了 LSTM 捕捉时序特征后，模型的性能有着一定程度的提升，但是由于心电信号时间序列较长，而 LSTM 难以捕捉到长时间的依赖并且其对于提取的特征没有区分，所以表现仍然不佳。而在引入了多头自注意力机制后，模型的性能达到了最佳，各个类别上的 F1 值均有不同程度的提升。这表明多头自注意力机制能够有效地学习到心电信号全局特征之间的依赖关系，并使得分类模型将更多的注意力投入在关键的特征上，从而获得了更优秀的分类效果。

5.5 本章小结

在本章首先设计了基于 CNN 和 LSTM_Attention 的心电信号分类模型，针对数据不平衡问题，使用本文提出的心电信号生成模型通过数据增强的方式使得数据集的样本分布更加均衡，同时为了降低分类错误的成本，增加分类模型对于异常心拍的学习能力，使用了焦点损失函数。实验结果表明，相比较于其他的心电信号分类算法，本文提出的算法拥有更高的准确率、精确率、召回率和 F1 值。最后，设置了消融实验，分别观察损失函数改进前后、数据增强前后、网络结构修改前后模型的性能变化。

第6章 总结和展望

6.1 总结

心律失常是迄今为止导致人类死亡的最严重的疾病。而心电图作为一种无创的诊断技术，被广泛应用于监测心跳活动中，为心血管疾病的诊断和治疗提供了丰富的信息。传统的心电分析诊断技术主要依靠人工，医生需要通过肉眼观察心电图，显然分析的时效性和准确率都是个很大的问题。因此，本文为了实现心电图的自动分类设计了多个算法：

1. 由于心电信号中存在的噪声可能会被错误的检测为心拍，影响分类模型的性能，因此本文首先分析了心电信号采集过程中常见的三种噪声及其性质，然后根据心电信号的采样频率以及噪声的频率分布范围，以 Daubechies 小波作为基本小波将原始心电信号进行八层小波分解，并利用小波阈值去噪方法去除了 MIT-BIH 数据集中低频的基线漂移、高频的肌电干扰和固定的工频干扰，突出心电信号中的重要特征，维持了心电信号完整性的同时并减少噪声对后续心电信号分类的消极影响。接着利用 R 峰正好对应着小波变换后的模极大值的过零点的性质定位到 R 峰，并根据 R 峰位置将连续的心电记录分割成单个的心拍。最后对每个心拍进行 Z-Score 标准化处理，为后续的心电信号增强和心电信号分析提供数据支撑。

2. 针对传统数据增强方法容易产生过拟合和修改形态特征的问题，本文提出了一种融合 VAE 和 Wasserstein-DCGAN 的心电信号生成式算法，其思想在于通过学习真实数据的分布来生成高质量且多样性的异常心拍，通过这种生成式算法可以使得增强后的数据分布更均衡。基于高质量的分布平衡的大量训练数据，模型能够学习到更深层次的无偏语义特征，因此能实现更精确的分类效果。该心电信号生成算法的贡献在于：一，使用 Wasserstein 距离和梯度惩罚的损失函数，解决了传统心电信号生成模型训练不稳定、模式坍塌的问题；二，针对以随机采样噪声为输入的心电信号生成模型训练过程中存在的损失动荡以及难以正常收敛的问题，本文将 VAE 编码器输出的潜在特征作为 GAN 生成器的有监督输入，该潜在特征里包含心电信号的原始信息，可以帮助模型更快更稳定地收敛；三，能够拟合质量更高更丰富的波形，对于 VAE 训练目标，使用 GAN 判别器中表示的高维特征误差替换典型的元素重建误差，即将原本固定的相似性度量变为可学习的任务。实验证明，相比较于其他生成模型，该算法生成的心电信号质量更高，多样性更明显。

3. 设计了心电信号分类算法。首先使用本文提出的心电信号生成算法对训

练集补充以平衡数据的分布,然后针对常见方法无法捕捉到心电信号中长距离的依赖关系且信号时序特征无区分的问题,本文引入了多头自注意力机制,提出了基于 CNN 和 LSTM_Attention 的心电信号分类模型,该模型将特征空间划分为多个子空间,在每个子空间独立的计算全局特征之间的关联关系并为不同时间段的特征赋予不同的注意力权重,因此能够有效地捕捉信号长时序上的依赖关系并量化各个时间段特征对于信号分类的贡献。在心律失常这样的医学数据集中对异常类别错误分类的成本通常远高于对正常类别错误分类的成本,由于数据集的不平衡性,无区分度的交叉熵会进一步增加模型的分类错误成本。针对该问题,本文使用了一种成本敏感的损失函数即焦点损失,以此来增加分类模型对于稀疏的异常类别的学习能力,从而能够在降低错误分类成本的同时提高模型的整体性能。最后对比分析本论文提出的心电信号分类算法与其他方法,验证本文提出算法的有效性。

6.2 展望

本文实现的心电信号智能诊断算法能够有效地缓解心律失常数据集的不平衡问题,提升稀疏的异常心拍识别准确率,增强心电信号分类模型整体的性能。但是由于研究时间有限,仍然存在以下几个方面可以继续改进:

1. 本文采用的数据集是 MIT-BIH 心律失常数据库,该数据集标注清晰,在心电信号预处理和分类中普遍使用。但是该数据集存在着严重的数据不平衡问题,某些心律失常的心拍数量过少,无法使用数据增强方法扩充。因此,如果后续有更多的数据来训练算法模型,对模型的性能提升将有极大的帮助。但是,医疗数据的收集和标注是一个十分复杂的过程,需要专业的医生和科研人员的共同努力,在本文实现较为困难,希望在未来能够有更多心律失常的数据集开放出来。

2. 高质量的生成样本能够提高分类的准确率,而低质量的样本则会产生消极的作用,因此如何进一步改进生成模型、提高生成数据的质量和多样性是下一步工作的重点。

3. 本文提出的心电信号分类算法只是在分析心电图的基础上,但是患者的年纪、性别、其他生理特征参数等也应该是考虑的内容,后续考虑将这些信息融合到神经网络中做进一步的分析。

4. 心电图、脑电图、肌电图等一维生物医学信号都普遍面临着数据稀疏、样本分布不平衡、噪声干扰、序列过长引起的特征提取不精准等问题,因此后续可以考虑将本文提出的方法应用到其他生物医学领域,以便能够实现更全面的医疗辅助。

参考文献

- [1] Lin C C , Yang C M . Heartbeat Classification Using Normalized RR Intervals and Wavelet Features[J]. Mathematical Problems in Engineering, 2014, (2014-5-4), 2014.
- [2] Malek A S , Elnahrawy A , Anwar H , et al. Automated detection of premature ventricular contraction in ECG signals using enhanced template matching algorithm[J]. Biomedical Physics & Engineering Express, 2020, 6(1):015024.
- [3] Jambukia S H , Dabhi V K , Prajapati H B . Classification of ECG signals using machine learning techniques: A survey[C]// Computer Engineering & Applications. IEEE, 2015.
- [4] Khosravy M , Gupta N , Patel N , et al. Particle Swarm Optimization of Morphological Filters for Electrocardiogram Baseline Drift Estimation[M]. 2020.
- [5] Chouhan V S, Mehta S S. Total Removal of Baseline Drift from ECG Signal[C]. International Conference on Computing: Theory and Applications. 2007:512-515.
- [6] Kumar A , Tomar H , Mehla V K , et al. Stationary wavelet transform based ECG signal denoising method[J]. ISA Transactions, 2020, 114(24).
- [7] Jenkal W , Latif R , Toumanari A , et al. An efficient algorithm of ECG signal denoising using the adaptive dual threshold filter and the discrete wavelet transform[J]. Biocybernetics & Biomedical Engineering, 2016:499-508.
- [8] Saxena S , Jais R , Hota M K . Removal of Powerline Interference from ECG Signal using FIR, IIR, DWT and NLMS Adaptive Filter[C]// 2019 International Conference on Communication and Signal Processing (ICCSP). IEEE, 2019.
- [9] Zhang M , Wei G . An integrated EMD adaptive threshold denoising method for reduction of noise in ECG[J]. PLoS ONE, 2020, 15(7):e0235330.
- [10] Qiu Y, Xiao F, Shen H. Elimination of power line interference from ECG signals using recurrent neural networks[C]. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE, 2017, 2296-2299.
- [11] Liu B , Li Y . ECG signal denoising based on similar segments cooperative filtering[J]. Biomedical Signal Processing and Control, 2021, 68:102751.
- [12] Belkadi M A , Daamouche A . A robust QRS detection approach using stationary wavelet transform[J]. Multimedia Tools and Applications, 2021, 80(15):22843-22864.

- [13] Kim J , Shin H . Simple and Robust Realtime QRS Detection Algorithm Based on Spatiotemporal Characteristic of the QRS Complex[J]. Plos One, 2016, 11(3):e0150144.
- [14] Mahmoodabadi S Z , Ahmadian A , MD Abolhasani, et al. ECG Feature Extraction Based on Multiresolution Wavelet Transform[C]// Conference proceedings :. Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference. IEEE, 2005.
- [15] Lin C , Mailhes C , Tourneret J . Y . P- and T-Wave Delineation in ECG Signals Using a Bayesian Approach and a Partially Collapsed Gibbs Sampler[J]. IEEE transactions on bio-medical engineering, 2010, 57(12):2840-2849.
- [16] Kresimir F , Davor K , J Alan, et al. Optimizing the detection of characteristic waves in ECG based on processing methods combinations[J]. IEEE access 6, 2018:1-1.
- [17] Panigrahy D , Sahu P K . P and T wave detection and delineation of ECG signal using differential evolution (DE) optimization strategy[J]. Australasian Physical & Engineering Sciences in Medicine, 2018.
- [18] Fast multi-scale feature fusion for ECG heartbeat classification[J]. Eurasip Journal on Advances in Signal Processing, 2015, 2015(1):46.
- [19] Ma F , Z Ha Ng J , Liang W , et al. Automated Classification of Atrial Fibrillation Using Artificial Neural Network for Wearable Devices[J]. Mathematical Problems in Engineering, 2020, 2020.
- [20] Taiyong, Li, Min, et al. ECG Classification Using Wavelet Packet Entropy and Random Forests[J]. Entropy, 2016.
- [21] Litjens G , Kooi T , Bejnordi B E , et al. A Survey on Deep Learning in Medical Image Analysis[J]. Medical Image Analysis, 2017, 42(9):60-88.
- [22] Wang R , Yao Q , Fan X , et al. Multi-class Arrhythmia Detection based on Neural Network with Multi-stage Features Fusion[C]// 2019 IEEE International Conference on Systems, Man and Cybernetics (SMC). IEEE, 2019.
- [23] Zhang H , Zhao W , Liu S . SE-ECGNet: A Multi-scale Deep Residual Network with Squeeze-and-Excitation Module for ECG Signal Classification[J]. 2020.
- [24] Lih O S et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats[J]. Computers in Biology & Medicine, 2018.

- [25] Rajpurkar P , Hannun A Y , Haghpanahi M , et al. Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks. 2017.
- [26] Gao J , Zhang H , Lu P , et al. An Effective LSTM Recurrent Network to Detect Arrhythmia on Imbalanced ECG Dataset[J]. Journal of Healthcare Engineering, 2019, 2019:1-10.
- [27] Essa E , Xie X . Multi-model Deep Learning Ensemble for ECG Heartbeat Arrhythmia Classification[C]// 2020 28th European Signal Processing Conference 2021.
- [28] Salem M , Taheri S , Yuan J S . ECG Arrhythmia Classification Using Transfer Learning from 2-Dimensional Deep CNN Features[J]. IEEE, 2018.
- [29] McSharry, Patrick E , Clifford, et al. A Dynamical Model for Generating Synthetic Electrocardiogram Signals.[J]. IEEE Transactions on Biomedical Engineering, 2003.
- [30] Li Z , Ma M . ECG Modeling with DFG[J]. Conf Proc IEEE Eng Med Biol Soc, 2005.
- [31] Clifford G D , Nemati S , Sameni R . An artificial vector model for generating abnormal electrocardiographic rhythms[J]. Physiological Measurement, 2010, 31(5):595.
- [32] Roonizi E K , Sameni R . Morphological modeling of cardiac signals based on signal decomposition[J]. Computers in Biology & Medicine, 2013, 43(10):1453-1461.
- [33] Zhu F , Ye F , Fu Y , et al. Electrocardiogram generation with a bidirectional LSTM-CNN generative adversarial network[J]. Scientific Reports, 2019, 9(1).
- [34] Kaplan Berkaya S , Uysal A K , Sora Gunal E , et al. A survey on ECG analysis[J]. Biomedical Signal Processing and Control, 2018, 43:216-235.
- [35] Santiago T A , Juan F , Antonio P I J , et al. AMSOM: artificial metaplasticity in SOM neural networks—application to MIT-BIH arrhythmias database[J]. Neural Computing & Applications, 2018:1-8.
- [36] Leshno M , Lin V Y , Pinkus A , et al. Multilayer Feedforward Networks with a Non-Polynomial Activation Function Can Approximate Any Function[J]. Social Science Electronic Publishing.
- [37] Shao H , Qian S , Liu Y . Temporal Interlacing Network[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020.
- [38] V Sitzmann, Martel J , Bergman A W , et al. Implicit Neural Representations with Periodic Activation Functions[J]. 2020.

- [39] Agarap A . Deep Learning using Rectified Linear Units (ReLU)[J]. 2018.
- [40] Kivinen J , Warmuth M K . Exponentiated Gradient Versus Gradient Descent for Linear Predictors[J]. Information & Computation, 1997, 132(1):1-63.
- [41] Zhuo L , Zhang B , Chen C , et al. Calibrated Stochastic Gradient Descent for Convolutional Neural Networks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33:9348-9355.v
- [42] Zou F , Shen L , Jie Z , et al. A Sufficient Condition for Convergences of Adam and RMSProp[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2019.
- [43] Kingma D , Ba J . Adam: A Method for Stochastic Optimization[J]. Computer Science, 2014.
- [44] Kiranyaz S , Ince T , Gabbouj M . Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks[J]. IEEE Transactions on Biomedical Engineering, 2016, 63(3):664-675.
- [45] Graves A , Mohamed A R , Hinton G . Speech recognition with deep recurrent neural networks[C]// Acoustics, Speech, and Signal Processing, 1988. ICASSP-88. 1988International Conference on. IEEE, 2013.
- [46] Hochreiter, Sepp, Schmidhuber, et al. Long short-term memory.[J]. Neural Computation,1997.
- [47] Goodfellow I J , Pouget-Abadie J , Mirza M , et al. Generative Adversarial Networks[J]. 2014.
- [48] Walker J , Doersch C , Gupta A , et al. An Uncertain Future: Forecasting from Static Images using Variational Autoencoders[J]. Springer, Cham, 2016.
- [49] Firat O , Cho K , Bengio Y . Multi-Way, Multilingual Neural Machine Translation with a Shared Attention Mechanism[J]. 2016.
- [50] Vaswani A , Shazeer N , Parmar N , et al. Attention Is All You Need[J]. arXiv, 2017.
- [51] Hazarika N , Chen J Z , Tsoi A C , et al. Wavelet Transform[J]. Signal Processing,1997, 59(1):61-72.

- [52] Awal M A , Mostafa S S , Ahmad M , et al. An adaptive level dependent wavelet thresholding for ECG denoising[J]. Biocybernetics & Biomedical Engineering, 2014, 34(4):238-249.
- [53] Moortel I D , Munday S A , Hood A W . Wavelet Analysis: the effect of varying basic wavelet parameters[J]. Solar Physics, 2004, 222(2):203-228.
- [54] Zhou J , Chen Y P , Zhou C , et al. The Application of De-noise Based on Compromise Algorithm Between Soft-thresholding and Hard-thresholding of Wavelet Coefficient for Fault Location[J]. Automation of Electric Power Systems, 2005.
- [55] Chandrakar B , Yadav O P , Chandra V K . A survey of noise removal techniques for ecg signals. 2013.
- [56] Cédric Vonesch , Blu T , Unser M . Generalized Daubechies Wavelet Families[J]. IEEE Transactions on Signal Processing, 2007, 55(9):4415-4429.
- [57] Alsmeyer, Gerold. On the stationary tail index of iterated random Lipschitz functions[J]. Stochastic Processes & Their Applications, 2016, 126(1):209-233.
- [58] Mukhopadhyay S , Biswas S , Roy A B , et al. Wavelet Based QRS Complex Detection of ECG Signal[J]. Computer Science, 2012.
- [59] Shang Y , Lei S , Liu B . QRS Characteristic Waveform Extraction Based On Biorthogonal B-Spline Wavelet[J]. International Journal of Control & Automation, 2014, 7(1):95-106.
- [60] Ketu S , Mishra P K . Empirical Analysis of Machine Learning Algorithms on Imbalance Electrocardiogram Based Arrhythmia Dataset for Heart Disease Detection[J]. Arabian Journal for Science and Engineering:1-23.
- [61] Chawla N V , Bowyer K W , Hall L O , et al. SMOTE: Synthetic Minority Over-sampling Technique[J]. 2011.
- [62] Yan Y , Min C , Shyu M L , et al. Deep Learning for Imbalanced Multimedia Data Classification[C]// IEEE International Symposium on Multimedia. IEEE, 2016.
- [63] Radford A , Metz L , Chintala S . Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks[J]. Computer ence, 2015.
- [64] Arjovsky M , Chintala S , Bottou L . Wasserstein GAN[J]. 2017.

- [65] Gulrajani I , Ahmed F , Arjovsky M , et al. Improved Training of Wasserstein GANs[J]. 2017.
- [66] Larsen A B L, Sønderby S K, et al. Autoencoding beyond pixels using a learned similarity metric[C]//International conference on machine learning. PMLR, 2016: 1558-1566.
- [67] Almahamdy M , Riley H B . Performance Study of Different Denoising Methods for ECG Signals[J]. Procedia Computer Science, 2014, 37:325-332.
- [68] Golany T , Lavee G , Yarden S T , et al. Improving ECG Classification Using Generative Adversarial Networks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(8):13280-13285.
- [69] Fm A , Oy B , Mt C , et al. Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review[J]. Computers in Biology and Medicine, 120.
- [70] Lin T Y , Goyal P , Girshick R , et al. Focal Loss for Dense Object Detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, PP(99):2999-3007.
- [71] Hasan N I , Bhattacharjee A . Deep Learning Approach to Cardiovascular Disease Classification Employing Modified ECG Signal from Empirical Mode Decomposition[J].Biomedical Signal Processing and Control, 2019, 52(July 2019):128-140.
- [72] Saeed, Saadatnejad, Mohammadhosein, et al. LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices.[J]. IEEE Journal of Biomedical & Health Informatics, 2020.
- [73] Pandey S K , RR Jan gh el. Automatic detection of arrhythmia from imbalanced ECG database using CNN model with SMOTE[J]. Australasian physical & engineering sciences in medicine, 2019, 42(4):1129-1139.
- [74] Rajput K S , Wibowo S , Hao C , et al. On Arrhythmia Detection by Deep Learning and Multidimensional Representation[J]. 2019.
- [75] Hou B , Yang J , Wang P , et al. LSTM Based Auto-Encoder Model for ECG Arrhythmias Classification[J]. IEEE Transactions on Instrumentation and Measurement, 2020, PP(99):1-1.

致 谢

春风不解少年意，夏蝉方知离别情，在科大已经不知不觉已经度过了三年，我即将迈入新的人生阶段，到现在仍然清楚地记得刚收到录取通知书时候母亲的热泪和父亲的喜悦。在研究生期间我也从未敢忘记过自己当初定下的任务和目标，脚踏实地、努力学习，在成为更好的自己的时候也能够对社会有所贡献。在这毕业论文即将完成之际，往事一幕幕闪回，这一路走来经历了太多的挫折和不容易，但也受到了很多人的帮助和支持，我真心地向他们道一声感谢。

首先最应该感谢的人是我的导师汪扬老师，是汪老师给了我继续学习的机会，汪老师学识渊博、积极乐观，是良师也是益友，不仅在学术上指导我们，更在生活上积极地影响我们。每周一次的篮球比赛，既强健了身体也放松了心情，汪老师教会了我们如何平衡工作和生活。在此，再次衷心地感谢我的导师，是他的谆谆教导促使着我不断地成长，祝您桃李满天下，春晖遍四方。

还要感谢实验室的同学们，从刚开始的拘谨羞涩到现在的大方自然，都是受到了同学们积极健康的影响。对我来说，实验室不仅是学习的地方更是像家一样温暖的地方，同学们团结友爱、互帮互助、共同进步，是他们的陪伴和支持，让我度过了最珍贵的三年，祝他们前程似锦、不负韶华。其次还要感谢晚上十二点的快2路公交车司机，看到狂奔的我们总是会耐心的多等一会。

最后我想感谢我的父母，父母之爱子，则为之计深远。求学生涯二十年，是父母的臂膀替我挡住外面的风风雨雨，是父母的支持让我在挫折时仍然能有勇气奋起直追。我会加倍努力，成为你们的依靠和骄傲。

在读期间发表的学术论文与取得的其他研究成果

已发表论文:

- [1] T. Zhang, "Arrhythmias Classification Based on CNN and LSTM_ATTENTION Hybrid Model," 2021 3rd World Symposium on Artificial Intelligence (WSAI).第一作者