

学校代号 10532

学 号 S161000926

分 类 号 TP301

密 级 普通



湖南大学  
HUNAN UNIVERSITY

## 硕士学位论文

# 远程心电系统中的智能降噪及疾病检测 分类

学位申请人姓名 关俊杰  
培 养 单 位 信息科学与工程学院  
导师姓名及职称 李仁发教授  
学 科 专 业 计算机科学与技术  
研 究 方 向 人工智能及其应用  
论文提交日期 2019年3月5日

学校代号: 10532  
学 号: S161000926  
密 级: 普通

## 湖南大学硕士学位论文

# 远程心电系统中的智能降噪及疾病检测分类

学位申请人姓名: 关俊杰  
导师姓名及职称: 李仁发教授  
培 养 单 位: 信息科学与工程学院  
专 业 名 称: 计算机科学与技术  
论 文 提 交 日 期: 2019年3月5日  
论 文 答 辩 日 期: 2019年3月15日  
答 辩 委 员 会 主 席: 彭蔓蔓教授

An intelligent method for ECG noise reduction and disease detection  
classification in remote heart monitoring system

by

Guan Junjie

B.E. (Hubei University of technology) 2016

A thesis submitted in partial satisfaction of the

Requirements for the degree of

Master of engineering

in

Computer science and technology

in the

Graduate School

Of

Hunan University

Supervisor

Professor Li Renfa

March, 2019

# 湖南大学

## 学位论文原创性声明

本人郑重声明：所提交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写的成果作品。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律后果由本人承担。

作者签名：

日期： 年 月 日

## 学位论文版权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权湖南大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

本学位论文属于

- 1、保密 ，在\_\_\_\_\_年解密后适用本授权书。
- 2、不保密 。

(请在以上相应方框内打“√”)

作者签名：

日期： 年 月 日

导师签名：

日期： 年 月 日

## 摘 要

本文受启发于和企业的智慧医疗合作项目，围绕心脏病的发病特性和心脏病监控中的数据处理问题展开，伴随着云计算、边缘计算等新的计算模型的出现，重新思考现有心脏病监控方式的缺陷，依赖云计算模型提出了新的心脏病监控方式，并针对这一新型心脏病监控方式中的数据处理问题，重点关注了动态心电图的降噪问题以及动态心电图的心律失常检测问题，主要内容介绍如下：

(1) 远程心电监控系统；首先综述了国内外关于远程心脏病监控的发展历程，并对比了传统心脏病监控方式和远程心脏病监控方式中数据流向的区别以及数据的差异，进而详细论述了远程心电监控系统中的近年主要研究方向，将本文的关注点落在远程心电监控的系统结构上。从一种企业级的远程心电系统出发，详细论述了这种新型远程心电监控系统中的心电图采集设备、移动终端、云服务中心以及数据分析站。在这种新型远程心电监控系统中，不仅能将和心脏病患者息息相关的医院、保险、医生、病友等单位和个人均可通过云平台与心脏病患者联系起来，还可以充分利用中心医院的专家资源和医疗设备资源，整个一体化的新型医患模式构成了一个典型的物联网系统。在此基础上，详细论述了物联网结构的远程心电监控系统中的计算模式和数据处理模式。

(2) 动态心电图的智能降噪；首先介绍了动态心电图常见的三种噪声 BW、EM 以及 MA 噪声，并综述了动态心电图降噪的现有研究基础，将心电图视为一种信号数据，现有的降噪方法有滤波器、小波变换以及 EMD 方法，为了避免信号处理中不得不面对的阈值选取问题，通过提取心电图中的有用成分重构心电图的方法被提出，如 PCA、ICA。针对物联网环境下的心电图降噪问题，心电信号可能会同时包含多种类型的噪声，而且无法预知信号中的噪声类型的特殊场景，基于深度学习模型提出了一种新的心电图降噪方法，这种方法将动态心电图看作数据间存在强依赖关系的时间序列数据，利用 LSTM 网络的记忆单元保留心电信号间的依赖关系，同时抛弃心电信号与噪声信号间的依赖关系，通过多个 LSTM 层提取信号的深层次特征，高质量的还原心电信号。突破了现有心电图降噪方法的限制，取得了较小的 RMSE 和较大的信噪比提升，为动态心电图的降噪提供了新思路。

(3) 心电图的心律失常检测分类；首先介绍了一个完整心电周期中的特征波以及特征点，并综述了基于特征的各类动态心电图心律失常检测方法，如人工神经网络、支持向量机、决策树和随机森林、K 近邻算法以及常见的深度学习模型，在这里引入了 1-D CNN 分类模型对动态心电图自动检测分类，模型在数据

预处理部分设计了两个提取心跳 Beat 的算法，从连续的动态心电图中提取出不同的心跳 Beat，最终提取出等长的八类心跳 Beat。在模型的分类部分，将心电图作为 1 维信号数据考虑，并只考虑 1 维的卷积核和池化层，同时多次使用了 Dropout 层。最终取得了 99.45% 的 Accuracy，99.45% 的 Precision，99.45% 的 Recall，99.45% 的 F1-score，以及 0.99 的 AUC，这一实验数据均要优于现有的心律失常检测方法。除此之外，对带噪的心跳 Beat 也进行了实验，经过约 4000 个 step 的训练后，分类模型取得了 93.96% 的 Accuracy，94.01% 的 Precision，93.93% 的 Recall，93.97% 的 F1-score，以及 0.98 的 AUC。

综合以上研究和实验，本文涵盖了远程心电监控的系统结构、以及特定系统结构下的动态心电图降噪和疾病自动检测分类。

**关键词：** 动态心电图；物联网；云计算；LSTM；1-D CNN；噪声

## Abstract

This article is inspired by the company's smart medical cooperation project, focusing on the pathogenesis of heart disease and data processing problems in heart disease monitoring, rethinking the shortcomings of existing heart disease monitoring way with the emergence of new computing models such as cloud computing and edge computing. Proposing a new way of monitoring heart disease depending on cloud computing. Towards the data processing problem in this new kind of heart disease monitoring way, focusing on the noise reduction problem of dynamic electrocardiogram and the arrhythmia detection problem of dynamic electrocardiogram. The main contents are as follows:

(1) Remote ECG monitoring system; At first, it reviewed the development history of remote heart disease monitoring, and compared the difference of the traditional heart disease monitoring mode and remote heart disease monitoring mode. Furthermore, the main research scope in the remote ECG monitoring system in recent years are discussed in detail. And the focus of this paper falls on the system structure of remote ECG monitoring. Starting from an enterprise-level remote ECG system, the ECG acquisition equipment, mobile device, cloud service center and data analysis station in this new remote ECG monitoring system are discussed in detail. In this kind of remote ECG monitoring system, not only hospitals, insurance, doctors, patients and etc. can connect with heart patients through the cloud platform, but also make full use of the expert resources and medical equipment resources in central hospital. The entire system constitutes a typical Internet of Things system. Then the calculation mode and data processing mode in the IoT-driven ECG-based heart monitoring system are discussed in detail.

(2) Intelligent noise reduction of dynamic ECG; At first, three typical kind of noise, including BW, EM and MA, were introduced, and then reviewed the research basis of dynamic electrocardiogram de-noising. While considering ECG as a kind of signal data, existing noise reduction methods include filter, wavelet transform and EMD method. In order to avoid the threshold selection problem in signal processing, another method for

reconstructing the electrocardiogram by extracting useful components in the electrocardiogram is proposed, such as PCA and ICA. For the ECG noise reduction problem in the IoT environment, the ECG signal may contain multiple types of noise at the same time, and it is impossible to predict the type of noise. Based on deep learning model, a new ECG noise reduction method is proposed. This method regards the dynamic ECG as time series data with strong dependence between data, and uses the memory unit of the LSTM network to preserve the dependence between the ECG signals, while discarding the dependence between the ECG signal and the noise signal. The LSTM layer extracts the deep features of the signal and restores the ECG signal with high quality. It breaks through the limitations of the existing ECG noise reduction method, and achieves a smaller RMSE and a larger signal-to-noise ratio improvement, which provides a new idea for the noise reduction of dynamic ECG.

(3) ECG arrhythmia detection; Firstly, the characteristic waves and feature points in a complete ECG cycle are introduced, and give a survey to dynamic ECG arrhythmia detection methods, such as artificial neural network, support vector machine, decision tree and random forest, K-nearest neighbor algorithm and deep learning model, the 1-D CNN classification model is introduced to automatically classify dynamic ECG. Two algorithms for extracting heartbeat were proposed in the data pre-processing part. Eight types of heartbeat are extracted from the continuous dynamic ECG signals. In the classification part of the model, the ECG is considered as 1-D signal data, and only the 1-D convolution kernel and the pooling layer are considered, and the Dropout layer is used multiple times. Finally, 99.45% Accuracy, 99.45% Precision, 99.45% Recall, 99.45% F1-score, and 0.99 AUC were obtained. This result is superior to the existing arrhythmia detection method. In addition, another experiment about the noisy heartbeat was also performed. After about 4000 steps of training, the model achieved 93.96% Accuracy, 94.01% Precision, 93.93% Recall, 93.97% F1-score and an AUC of 0.98.

Based on the above research and experiments, this article covers the system structure of remote ECG monitoring, the noise reduction of dynamic ECG and the common disease detection classification.

**Key Words: D-ECG; IoT; Cloud-computing; LSTM; 1-D CNN; Noise**



## 目 录

学位论文原创性声明.....	I
摘    要.....	II
<b>Abstract</b> .....	IV
目    录.....	VI
插图索引.....	VIII
附表索引.....	X
<b>第 1 章 绪论</b> .....	1
1.1 研究背景与意义.....	1
1.1.1 研究背景.....	1
1.1.2 研究意义.....	3
1.2 国内外研究现状.....	3
1.3 研究问题.....	6
1.3.1 远程心电监控系统.....	6
1.3.2 动态心电图的降噪问题.....	7
1.3.3 心律失常的自动检测分类.....	8
1.4 本文内容及贡献.....	9
1.5 本文组织结构.....	10
<b>第 2 章 相关研究基础及进展</b> .....	12
2.1 引言.....	12
2.2 远程心电监控系统综述.....	12
2.3 心电图的降噪研究现状.....	15
2.4 心律失常检测研究进展.....	16
2.5 小结.....	19
<b>第 3 章 远程心电监控系统</b> .....	20
3.1 引言.....	20
3.2 心电图采集设备.....	21
3.3 远程心电图系统.....	24
3.3.1 数据处理模式.....	26
3.3.2 计算模式.....	28
3.4 小结.....	30

第 4 章 动态心电图的智能降噪 .....	31
4.1 引言 .....	31
4.2 多层 LSTM 降噪模型 .....	31
4.2.1 数据预处理 .....	32
4.2.2 降噪模型 .....	33
4.3 实验和评价 .....	36
4.3.1 评价指标 .....	36
4.3.2 实验结果 .....	37
4.4 对比分析 .....	39
4.5 小结 .....	41
第 5 章 动态心电图的心律失常检测分类 .....	42
5.1 引言 .....	42
5.2 1-D CNN 分类模型 .....	42
5.2.1 数据预处理 .....	44
5.2.2 多层 CNN 分类模型 .....	48
5.3 实验和评价 .....	52
5.3.1 评价指标 .....	53
5.3.2 实验结果 .....	54
5.4 对比分析 .....	57
5.4.1 降噪前后对比实验 .....	57
5.4.2 现有方法对比实验 .....	59
5.5 小结 .....	60
结    论 .....	61
参考文献 .....	63
附录 A 攻读硕士学位期间发表的学术论文 .....	73
附录 B 攻读硕士学位期间所参与的项目 .....	74
致    谢 .....	75

## 插图索引

图 1.1 全球前十位死亡原因.....	1
图 1.2 静态心电图对比动态心电图 .....	2
图 1.3 现有心脏病监控方式对比远程心电监控系统.....	4
图 1.4 智能降噪模型.....	5
图 1.5 分类问题的一般流程.....	6
图 2.1 数据流向对比图 .....	11
图 2.2 心电图的 P-QRS-T 特征波 .....	12
图 2.3 远程心电监控系统中的三种常见噪声 .....	13
图 2.4 单周期心电图详解图.....	15
图 3.1 远程心电监控系统的企业级实现.....	18
图 3.2 两种主流的心电图采集设备.....	20
图 3.3 心电图采集设备的特点 .....	22
图 3.4 云平台服务体系 .....	22
图 3.5 智慧医疗体系 .....	23
图 3.6 云、雾计算为中心的物联网框架 .....	24
图 3.7 云计算三种服务模式间的层次关系 .....	27
图 4.1 多层 LSTM 心电图降噪模型.....	30
图 4.2 多层 LSTM 模型.....	31
图 4.3 单层 LSTM 结构图 .....	32
图 4.4 LSTM 网络的记忆单元结构图 .....	32
图 4.5 类别 1~类别 7 的实验结果.....	36
图 4.6 RMSE 结果对比 .....	37
图 4.7 SNR 提升结果对比 .....	38
图 5.1 提取心跳 Beat 和 ECG 段 .....	41
图 5.2 1-D CNN 心跳 Beat 分类模型.....	41
图 5.3 不等长的心跳 Beat .....	44
图 5.4 三次采样插值后的心跳 Beat.....	44
图 5.5 八类心跳 Beat .....	46
图 5.6 训练过程.....	53
图 5.7 平均 ROC 曲线 .....	54
图 5.8 八类 ROC 曲线.....	54
图 5.9 带噪数据集训练过程.....	55
图 5.10 带噪数据集的 ROC 曲线.....	56

图 5.11 曲线带噪数据集八类 ROC 曲线 ..... 57

## 附表索引

表 3.1 商用心电图采集设备 .....	21
表 4.1 噪声混合类型划分 .....	31
表 4.2 不同噪声类别下的 RMSE 和 SNR .....	35
表 5.1 MIT-BIH 数据集标记说明 .....	42
表 5.2 八类心跳 Beat 数 .....	46
表 5.3 几种主流 DNN 模型对比 .....	47
表 5.4 1-D CNN 心律失常检测模型 .....	47
表 5.5 混合矩阵 .....	51
表 5.6 实验结果 .....	53
表 5.7 混合矩阵 .....	53
表 5.8 带噪数据集实验结果 .....	55
表 5.9 带噪数据集混合矩阵 .....	55
表 5.10 现有方法评价指标对比 .....	57

# 第1章 绪论

## 1.1 研究背景与意义

### 1.1.1 研究背景

心血管疾病属于慢性疾病的一种，给人类的生命健康带来了极大的威胁，其引起的死亡人数一直居高不下。世界卫生组织关于全球前十位死亡原因及死亡人数的数据<sup>[1]</sup>如图 1.1。




图 1.1 全球前十位死亡原因

从图一给出的数据来看，从 2000 到 2016 年，心脏病一直位于影响人类生命健康的十大疾病之首。在 2000 年，仅仅由心脏病引起的死亡人数就达到了将近 7 百万，这一数据在 2016 年更是超过了 9 百万。不管是在中低等收入国家还是在高收入国家，心脏病引起的死亡人数都位于前十位死亡原因的首位，而且越是在高收入国家，心脏病引起的死亡人数越高。在低收入国家，每 10 万人中有 75 人死于心脏病，而在高收入国家，每 10 万人中有 148 人死于心脏病。

造成如此高死亡率的主要原因是心脏病的发病特性，相比其他疾病，心脏病具有高危险性，病情隐蔽，强突发性<sup>[2]</sup>等特性，这使得心脏病成为了威胁人类生命健康的最大隐患。在现有的心脏病监控方式下，大部分的心脏病患者在感到身体不适之后才到医院挂号就诊，这种监控方式是造就心脏病的发病特性的主要原因，这主要体现在现有的心脏病监控方式下，以下三个方面的矛盾难以协调：

- (1) 患者得不到及时的治疗；
- (2) 难以准确采集到患者发病时的心电图；
- (3) 增加额外的医疗支出，据世界卫生组织报道<sup>[3]</sup>美国在医疗上的支出占美国国内生产总值约占 17.6%。

随着身体传感器和云计算等技术的兴起，近年来身体传感器等技术开始应用到人类生命健康保健中<sup>[4]</sup>。针对心脏病的发病特性，通过身体传感器和云计算等

技术构建物联网结构的远程心电监控系统，成为了工业界和学术界的一个共同话题。在这种新型的心脏病监控方式下，心脏病患者可以在家中自主采集心电图，通过手机 APP 将心电图上传到医院数据存储中心，随后对该心电图的分析和诊断结果将反馈到患者手机。与现有的心脏病监控方式相比，远程心电监控系统有着心电图采集简单、减少医疗支出、全天候的持续监控等无法比拟的优点。但是，在这种远程心电监控方式下，由于心电图采集方式的改变和新增了数据传输过程，使得只能采集到动态心电图，而动态心电图与目前临床诊断中使用的静态心电图相比存在较大的噪声干扰，噪声源主要来自如下几个方面：

- (1) 患者身体与传感器之间的摩擦；
- (2) 患者的呼吸和走动；
- (3) 患者身体与传感器之间接触不良；
- (4) 肌肉等其他部分的收缩；
- (5) 数据传输过程中的噪声干扰。

在动态心电图的采集过程中，可能同时存在多种噪声污染，而且噪声类型无法提前确定并且会随着患者所处的外部环境而改变，这使得心电图的外型发生了很大的变化，静态心电图和动态心电图的对比如图 1.2。




图 1.2 静态心电图对比动态心电图

心脏病辅助诊断系统<sup>[5]</sup>是一个人工智能系统，旨在辅助医生完成对常见心脏病疾病的分析和诊断。对于没有噪声污染或者噪声干扰较小的静态心电图<sup>[6]</sup>，辅助诊断系统的准确率能够达到 95%，但是在临床应用中，由于噪声的存在，辅助诊断系统对动态心电图的分类准确率<sup>[7]</sup>只有 58.7%，这一准确率极大的限制了心脏病辅助诊断系统的临床应用。而降噪作为一种最为经典的信号质量增强技术，在心电图降噪中也有着广泛的应用。降噪旨在从被噪声污染的心电图中重建高质量的心电图，因此，降噪方法应该在滤除噪声的同时保留心电图的特征波形和心脏病的病理特征。但是由于心电图信号本身比较微弱，其中一些特征点很容易被噪音淹没，使现有降噪算法无法辨别是噪音还是心电图特征波形，而且心电

图因人而异，千变万化，所以现阶段心电图自动分析算法对于有噪音的心电图的分析准确性达不到完全不用人工核对的要求。人工智能借助大数据，可以模仿专业心电图人员判读心电图的过程，突破甚至解决有噪音的心电图自动分析的准确性和可靠性，是一个非常有价值和挑战的研究领域。立足于此，本文从以下三个方面展开：

- (1) 远程心电监控系统；
- (2) 动态心电图的智能降噪；
- (3) 心律失常检测分类。

### 1.1.2 研究意义

随着人工智能的迅猛发展，人工智能产品开始进入各行各业，成为日常生活中常见的消费品，给人们的生活带来了便利。但目前人工智能主要应用在消费类领域，在安全相关领域的研究和应用是远远不够的。因此在这篇文章中，从心脏病的发病特性出发，希望结合身体传感器和云计算等技术提出物联网结构的心脏病监控系统，而这种新型的心脏病监控系统有能力为心脏病患者提供全天候的监控方式，这种监控方式确实弥补了现有心脏病监控方式上的不足，而同时也带来了新的挑战。因此在这篇文章中，企图应用人工智能的方法来解决这种新型心脏病监控系统中遇到的噪声问题和分类问题。如果能够取得突破或者从根本上解决其中的噪声问题和分类问题，那对于广大的心脏病患者来说，无疑是最大的福音，同时也将大幅度削减由心脏病引起的死亡人数。

## 1.2 国内外研究现状

人工智能技术在世界范围内均有迅猛发展，将人工智能技术应用到心脏病的监控和诊断中在产业界和学术界均处于蓬勃发展阶段，本文围绕心脏病的远程监控和智能数据处理问题展开，同时也是目前国内外研究的着落点和需要重点突破的方向：

### 1、国外研究现状

在心脏病的远程监控方式中，国外的起步约早于国内二三十年，较早期的研究可以追溯到上个世纪七十年代 D. E. Lewis 提出的远程生理活动信息监控系统<sup>[8]</sup>，这一系统中主要涵盖了远程系统中的传感器和数据传输这两个方面，其后 D. Franchi 等人<sup>[9]</sup>在 1998 年提出了依靠个人 PC 以及电话线来实现动态心电信号和其它生理信号的远程监控方法。近年来，关于心脏病远程监控的系统研究较少，国外的研究重点落在远程心电监控系统下的身体传感器的研发、数据处理以及疾病检测分类上，首先在身体传感器的研发上，如 F. Giroud 等人<sup>[10]</sup>在 Soc 上开发了一个低功耗的心电图采集前端，并实现了 3 导联的心电监控。针对无线心电



图系统, R. Fensli 等人<sup>[11]</sup>开发了一种穿戴式的身体传感器, 利用这种传感器可以持续监控和记录心脏病患者的心脏病状况, 并通过无线网络传输数据。

在远程心电监控系统中的数据处理问题上, 以心电图的波群检测、信号压缩以及心电图降噪三个方向为例, 心电图的波形检测以 QRS 波群检测为例, 如 F. Avcu 等人<sup>[12]</sup>在 IOS 智能手机平台上实现了实时的心电图 QRS 波群检测, 以及 N. Vemishetty 等人<sup>[13]</sup>在远程个性化监护系统中提出了一种低复杂度的 QRS 波群检测和识别架构。在信号压缩方面, 如 H. Mamaghanian 等人<sup>[14]</sup>基于最新的压缩感知算法在无线人体传感器网络中实现了低复杂度的心电图压缩, 在 ECG 压缩能效方面优于目前最好的数字小波变换 (DWT) 方法, 以及 R. Mahajan 等人<sup>[15]</sup>提出的压缩算法能在较小失真的压缩 ECG 的前提下减少传输过程中的能耗、提高传输效率。最后在心电图的降噪方法上, 国外应用较多的方法是滤波器、小波变换、EMD (Empirical Mode Decomposition) 以及主成分分析方法。如 H. Hesar 等人<sup>[16]</sup>利用卡尔曼滤波器处理存在基线漂移的心电图, 能够以较高的准确率滤除心电图中的基线漂移, N. Küçüköz 等人<sup>[17]</sup>利用离散小波变换的粗略估计来滤除心电图中的基线漂移, 并在真实数据上检测了算法的有效性, U. Satija 等人<sup>[18]</sup>使用 EMD 方法将心电图分解成有限个 IMFs, 其中低阶的 IMFs 包含了心电图的高频成分, 而高阶 IMFs 中包含了心电图的低频成分, 分解之后的信号在结构上简单了很多, 通过处理 IMFs 来滤除心电图中的低频和高频噪声, D. Mandic 等人<sup>[19]</sup>利用主成分分析 (PCA) 分离心电图中的有效信号和噪声, 通过协方差矩阵区分心电图中的不同成份, 选择低阶主成分重构心电图。

关于心电图的自动疾病检测分类, 检测方法主要在数据预处理方式、特征提取工程以及分类器上存在差异, 单单就分类器而言, 应用在心电图自动疾病检测分类的常见分类器有: 人工神经网络、支持向量机、决策树和随机森林、K 近邻算法以及常见的深度学习模型, 如卷积神经网络、受限玻尔兹曼机、自编码器以及深度信念网络。如 S. Osowski 等人<sup>[20]</sup>应用高阶统计量特征, 以模糊神经网络为分类器对心电图分类, 完成了对不同类型心跳节拍的识别和分类。在此研究基础上, 作者利用 SVM 分类器、高阶统计量以及 QRS 波群的 Hermite 特征等特征提取方法, 融合构成了一个专家系统<sup>[21]</sup>, 该专家系统可以为 13 种类型的心跳节拍提供可靠的识别。而 G. R. Kumar 等人<sup>[22]</sup>通过离散余弦变换提取 ECG 中的 RR 间隔作为分类的特征, 并使用随机森林作为分类器, 在 MIT-BIH 数据集<sup>[23]</sup>上对不同类型的心跳节拍分类, 取得了不错的分类准确率。同样在 MIT-BIH 数据集上, J. Park 等人<sup>[24]</sup>利用 Pan-Tompkins 算法提取 ECG 中的 QRS 波群以及 P 波等特征, 在 MIT-BIH 心律失常数据集上对 17 种类型的心跳节拍分类, KNN 分类器的灵敏性和特征性均达到了 97% 左右。采用深度学习模型的方法如

Rahhal 等人<sup>[25]</sup>搭建了一个深度自编码器网络，并且在三个 ECG 数据集上检验了模型对心律失常的检测准确率，检测结果表明模型能够在更少专家干预的前提下达到比较高的检测准确率。

## 2、国内研究现状

在心脏病的远程监控方式中，国内的起步较晚，较早期的研究可以追溯到上个世纪九十年代清华大学研究团队提出的基于个人 PC 的远程心脏病控系统<sup>[26]</sup>，随后北京大学研究团队提出 WE CARE 项目<sup>[27]</sup>，北京中科院以及深圳中科院在便携式远程医疗体系<sup>[28]</sup>中的研究贡献，以及位于台湾的国立交通大学<sup>[29]</sup>和台湾大学<sup>[30]</sup>在这一研究领域也有较为突出的贡献，其中台湾大学附属医院远程监控中心<sup>[31]</sup>已经部署有一整套完整的心电信号实时监控系统，并且已经投入使用开始服务于一些台湾市民。其后在远程心脏病监控系统结构上的研究较少，较多的研究还是在远程心电监控系统中的身体传感器研发、数据处理问题<sup>[31]</sup>以及常见疾病检测分类<sup>[32]</sup>上，首先在远程心电监控系统中的身体传感器研发上，如 J. Dong 等人在文献[33]中提出了便携式智能心电监护仪，并已经投入到临床环境中，经临床认可，该设备具有测量准确，移动性强，易于使用，耐用，重量轻等优点。朱洁在文献[34]中提出了基于无线传感器网络的心电监护系统，钱垚同样在文献[35]中研究和设计了远程心电监护系统，以及刘斌在文献[36]中设计与实现了远程心电监护平台，同样基于无线传感器网络在心电监护系统在文献[37]中由李汉玲设计与实现。

在远程心电监控系统中的数据处理问题上，波群检测、信号压缩以及心电图降噪仍是研究较多的三个方向，在心电图的波形检测上仍然以 QRS 波群检测居多，如 C. Liu 等人<sup>[38]</sup>利用可穿戴身体传感器实现了实时和连续的个体心电图监控，在这种实时远程心电监控系统中，QRS 波群检测准确率能够达到 99.5%，以及杨思军等人在文献[39]中对心电信号先滤波滤除心电图中的噪声，对无噪声心电图进行 QRS 波群检测。在信号压缩方面，如赵安等人<sup>[40]</sup>在移动式远程心电监护系统中，对心电图的压缩方法进行研究，以近乎无损的精度实现了心电数据的压缩，以及张增芳等人在文献[41]中利用小波神经网络对心电信号进行压缩。心电图的降噪是远程心电监控系统中特有的问题，心电图的噪声伴随着心电图的采集方式和传输过程而产生，心电图的降噪对于心电图的自动诊断分类起着关键作用，国内研究心电图降噪中使用较多的方法是滤波器、小波变换、神经网络、EMD (Empirical Mode Decomposition) 以及主成分分析方法。如田絮资等人在文献[42]中利用数学形态滤波器对心电信号降噪，滤波器作为一种选频装置，可以使信号中特定的频率成分通过，而极大地衰减其他频率成分，王佳文等人在文献[43]中利用小波变换方法对心电图降噪，通过伸缩平移运算对心电信号逐步进行多尺度细化，从而可聚焦到心电信号的任意细节，而王太勇等人<sup>[44]</sup>利用模

糊神经网络对心电信号进行降噪，该方法摆脱了信号处理中不得不面对的阈值选取问题，而是通过线性或非线性变换，提取心电图中的有用特征。然而，利用深度神经网络对心电信号进行降噪成为了近年来的趋势，如金林鹏等人在文献[45]中对临床诊断上的深度学习进行了阐述，指出了深度神经网络的可能应用场景，其中心电信号的降噪是很重要的一环。

在远程心电监控系统中，伴随着人工智能方法出来的还有心电图的自动诊断，目前在国内的心电图的临床诊断上，心电图的自动分析算法应用较少，而且不允许自动诊断算法对心脏病的自主诊断，只能扮演辅助诊断的角色。目前在学术界，心电图分类常使用公开数据集，而公开数据集大部分来自心脏病患者在医院就诊时采集的心电图，此时心电图数据的噪声较小，因此现有的心电图自动检测算法均能达到 90%左右的准确率，如冯俊在文献[46]中通过结合特征提取方法和神经网络对心电图分类，结合射线拟合方法提取特征，其分类准确率为 78.2%，而通过小波变换方法提取特征时，其分类正确率达到 86.6%。而基于深度学习模型的心电图自动检测算法能够达到 95%以上的准确率，常见的深度学习模型如导联卷积神经网络<sup>[47]</sup>、深度信念网络<sup>[48]</sup>等，但是在实际动态心电图的自动检测分类上，检测准确率却只能达到 60%~70%。

## 1.3 研究问题

心脏病为人类生命健康带来了极大的威胁，同时也是造成死亡的最主要原因。为了改善这种现状，除了医学上需要做出相应的努力之外，计算机科学也扮演着重要角色，如早期发展起来的专家系统<sup>[49]</sup>以及目前正火热发展的人工智能系统<sup>[50]</sup>。近年来，关于心电图分类的研究很多，而且其分类准确率均能达到 90%以上，但是这种心脏病辅助诊断系统却没有普及，因为其在临床诊断中的准确率停留在 60%左右。因此，本文从心脏病的发病特性和现有的心脏病监控方式之间的矛盾出发，引出了本文的第一个研究问题，一种新型的心脏病监控系统，即物联网结构的远程心电监控系统。与现有心脏病监控方式相比，这种物联网结构的远程心脏病监控方式在多个方面表现出不可比拟的优势，但同时却被较大的噪声问题困扰，为了处理心电图中的噪声问题，增强心电信号质量，引出了本文的第二个研究点，即心电图的降噪问题。最后一个研究点落到论文的出发点，即提高带噪心电图的心律失常检测分类准确率。

### 1.3.1 远程心电监控系统

远程心电监控系统与现有心脏病监控方式相比，在心电图的采集和数据的处理上存在较大差异，现有心脏病监控方式与远程心电监控系统简略对比如图 1.3。

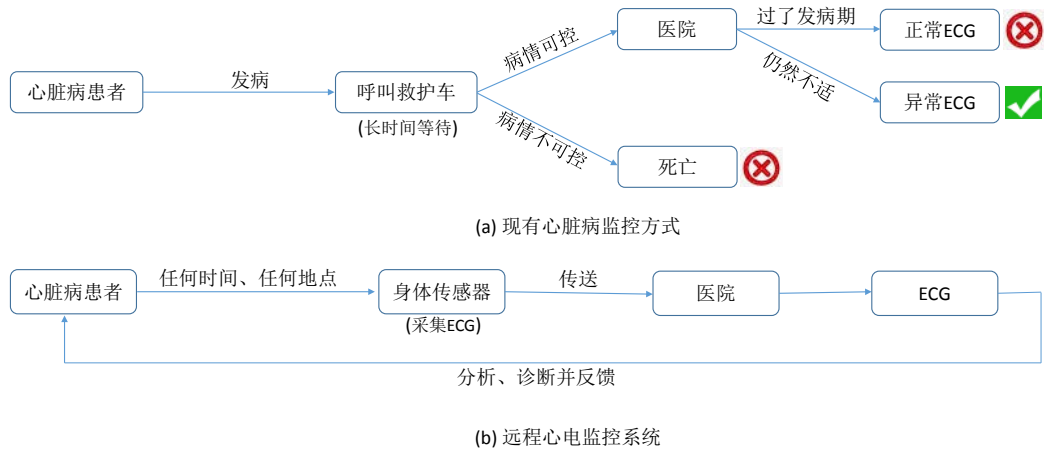


图 1.3 现有心脏病监控方式对比远程心电监控系统

在图 1.3 中，(a)图对应现有的心脏病监控方式，在这种方式下，虽然采集到的心电图都是静态心电图(ECG)，但是却很难能够采集到心脏病患者发病时的心电图，这不仅为诊断带来了麻烦，同时也为进一步的治疗造成了阻碍。而在图(b)这种远程心电监控系统中，心脏病患者可以在任何时间、任何地点使用身体传感器采集自身心电图，然后通过网络等方式将数据传送到医院数据中心，此时，无论是正常心电图还是发病时的心电图都能够很轻松的记录下来并且在最短的时间内收到专业医师的分析和诊断结果。

物联网结构的心电监控系统最大的优势在于心脏病患者能够在任何时间、任何地点采集自身心电，这种实现的技术支撑主要来自身体传感器的发展、新兴数据处理模式的出现以及采用新的计算架构。虽然物联网结构的心电监控系统为心电图采集带来了便利，同时也为心电图的进一步分析和诊断带来了挑战，尤其是心电图中的噪声问题。

### 1.3.2 动态心电图的降噪问题

在图 1.2 中，静态心电图和动态心电图呈现出巨大的形态差异，在静态心电图中，心电图的特征点和特征波形很清晰，并且在结构上呈现出规律性。而在动态心电图中，心电图的特征点被噪声掩盖，而且心电图的特征波形和周期性均被破坏，这为心电图的分析和诊断带来了很大的麻烦。因此，信号质量增强成为了一个必然趋势，而信号降噪又是信号质量增强的最常见方法。

信号降噪是一个很经典的研究课题，但是在物联网结构的远程心电监控系统中，又为信号降噪这一课题带来了新的挑战。在物联网结构的远程心电监控系统中，动态心电图中可能同时存在多种噪声，而且动态心电图中具体会包含哪些噪声是无法提前预知的。这同时为降噪算法带来了新的挑战：

(1) 滤除噪声；同其他降噪算法一样，滤除噪声仍然是降噪算法的主要任务。

(2) 保留心脏病的病理特征；由于心电图的特征点往往和噪声混合在一起，如何在滤除噪声的同时保留心电图中的病理特征成为了一大难题。

(3) 对噪声不敏感；由于动态心电图中可能同时存在多种噪声，而且动态心电图中具体会包含哪些噪声是无法提前预知的，因此降噪算法的性能不能随着噪声的变化而变化。

(4) 能够处理时间序列数据；动态心电图是一种特殊的时间序列数据，不同时刻的数据间存在依赖关系，甚至是长依赖关系，最直观的体现在某一时刻的幅值和之前时刻的幅值紧密相关。

综合考虑了降噪算法面临的挑战以及动态心电图的数据特性，本文总结了现有降噪方式在动态心电图降噪上可能遇到的问题，并将长短期记忆网络这种深度神经网络模型应用到动态心电图降噪中，智能降噪模型如图 1.4。




图 1.4 智能降噪模型

降噪旨在从动态心电图中恢复出静态心电图，因此降噪模型应该从数据中学习的能力不是区分噪声信号和心电信号而是学习如何重建静态心电图。

### 1.3.3 心律失常的自动检测分类

心电图的心律失常检测分类是心脏病辅助诊断系统中最重要的一环，分类的准确率直接决定了辅助诊断系统能否投入临床诊断服务于医生和心脏病患者，但是动态心电图的心律失常检测分类准确率只有 58.7%，极大的限制了辅助诊断系统在临床上的应用。通过心电图降噪，从动态心电图中恢复出静态心电图，有望提高动态心电图的分类准确率。在过去十年里，很多方法被应用到心电图自动心律失常检测分类中，而心律失常检测分类归根结底是一个分类问题，其一般流程<sup>[22]</sup>如图 1.5。

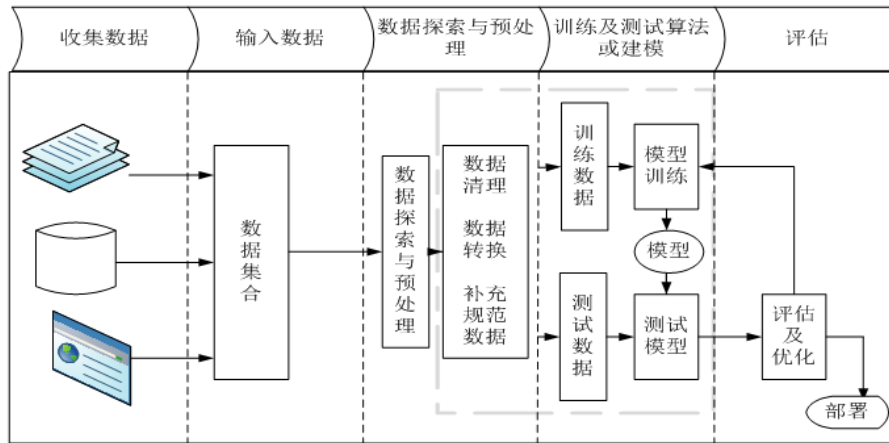


图 1.5 分类问题的一般流程

本文以卷积神经网络<sup>[51]</sup>模型为基础分类器，动态心电图的分类流程分为以下几步：

(1) 数据获取；由于对动态心电图的直接分类准确率较低，因此需要从降噪后的心电图中重建静态心电图，将静态心电图作为分类器的数据来源。

(2) 获取 R-R 间隔；由于重建后的静态心电图中往往包含了多个心率节拍，每一个心率节拍在结构上呈现出周期性，而 R-R 间隔反映了两个相邻心率节拍之间的距离，对于提取节拍起着至关重要的作用。

(3) 心电图节拍提取；由于心电图中的每一个心率节拍在结构上完全相同，重复周期性的数据对于训练分类器帮助不大，但是却会极大的增加模型中的参数。因此提取完整的心率节拍不仅能简化模型的结构，减少需要训练的参数，加快卷积神经网络模型的训练速度，同时也赋予了分类器意义，毕竟对不完整的心率节拍的分类是没有意义的。

(4) 心电图分类；在心电图节拍提取中，共提取了八类心率节拍：正常搏动、房性早搏、室性早搏、起搏节拍、左束支传导阻滞、右束支传导阻滞、室扑以及室性逸搏，因此需要训练一个八分类卷积神经网络分类器。

## 1.4 本文内容及贡献

本文从心脏病的发病特性和现有心脏病监控方式之间的矛盾出发，将矛盾归结于心电图的采集方式，因此，从心电图的采集方式和心电图数据处理两个角度探究了远程心电监控系统下的智能降噪及心律失常检测分类问题。主要包括以下内容：

(1) 远程心电监控系统；在现有心脏病监控方式下，虽然能够采集到噪声较小甚至无噪的静态心电图，但是由于心脏病的种种发病特性导致很难采集到心脏病发病时的心电图，从而耽误了进一步的诊断和治疗。便携式、易操作的身体传感器的出现，并结合智能移动终端和云计算这种新型的计算模式，有望为心脏

病患者提供全天候的监控方式，心脏病患者能够在任何时间、任何地点采集自身心电图，并通过移动终端将数据上传到医院数据中心，并在最短时间内得到专业医师的分析和诊断结果反馈。本文从远程心电监控系统的一种企业级实现方式出发，分析了该远程心电监控系统中的主要组成部分，同时深入分析了远程心电监控系统中的身体传感器、数据处理模式以及计算模式，最终将整个远程心电监控系统归结为一个典型的物联网系统。

(2) 动态心电图的智能降噪；动态心电图相比静态心电图，心电图中的特征点被噪声掩盖，而且心电图的特征波形和周期性均被破坏，心电图降噪旨在滤除噪声的同时保留心电图中的特征点并恢复心电图的特征波形。考虑到心电图属于时间序列数据的一种，而且动态心电图可能同时包含多种无法提前预知的噪声，这意味着降噪方法除了要在除噪声的同时保留心电图中的特征点并恢复心电图的特征波形，更应该是对噪声不敏感的，即降噪方法的性能不会随着噪声的改变而下降。利用深度学习模型的自学习、自调整的特性，本文提出了多层长短期记忆 (LSTM) 网络降噪模型，训练降噪模型从动态心电图重建静态心电图的能力，并将 Back Propagation Through Time (BPTT) 算法和 Adam 优化器用到模型的训练中，训练好的模型将直接应用于包含不同噪声的动态心电图。

(3) 心电图的心律失常检测分类；对动态心电图的自动心律失常检测分类准确率决定了自动分析算法能否直接应用到临床诊断中，但是由于噪声的存在以及心电图因人而异，千变万化等原因，为动态心电图的自动分类带来了极大的挑战。本文将动态心电图的分类分为两个步骤，第一步是从动态心电图恢复出静态心电图，滤除噪声的同时保留心电图的特征点和特征波形；第二步是对恢复出的静态心电图分类，在这一步中，又有两个非常重要的子步骤，其一是从静态心电图提取心率节拍，其二是训练深度卷积神经网络分类器，分类器的主要任务是识别每一种心率节拍的类型。

## 1.5 本文组织结构

本文的组织结构如下：

第一章为绪论。分别介绍了课题的研究背景及意义、研究问题以及主要内容和贡献。在这一章中介绍了心脏病对人类生命健康的威胁主要来自其发病特征，针对心脏病的发病特征，从现有的心脏病监控方式介绍到一种新型的心脏病监控方式，引出了本文的第一个研究点，即物联网结构的远程心电监控系统。这种新型的心脏病监控方式为心电图采集带来了便利，同时其中的噪声问题也为心电图自动分析和诊断带来了挑战，由此引出本文的第二个研究点，即动态心电图的智能降噪。而最终决定心脏病辅助诊断系统能否应用到临床诊断上的是心电图的自动分类准确率，因此心电图的自动分类作为本文的第三个研究点。

第二章是相关研究基础及进展。针对绪论中提出的三个研究点，即物联网结构的远程心电监控系统、动态心电图的智能降噪以及心电图的自动分类，分别给出了相关的研究基础、发展历程以及最新研究进展。其中，远程心电监控系统的研究进展主要围绕其发展历程展开；心电图降噪的研究进展主要围绕几类常见的降噪方法展开，如滤波器、小波变换、EMD、PCA、ICA、神经网络等；最后，心电图分类的相关研究以机器学习分类器、深度神经网络分类器为主。

第三章主要讲述了本文的第一个研究点，即物联网结构的远程心电监控系统。在远程心电监控系统中，物联网结构的心电图系统是一个比较新颖的提法，同时也是企业力图实现的心脏病远程监控方式。在这种监控方式中，身体传感器、新的数据处理模式以及新的计算模式是最重要的三个方面。身体传感器的发展，能够为患者提供便携式的、易操作的心电图采集方式；数据处理模式将心电图数据的采集与计算分离，决定心电图数据的处理方式是批数据还是流数据；而计算模式决定了对心电图数据的计算将会发生在何处。在这一章的最后给出了一种物联网结构的远程心电监控系统的实现方式。

第四章主要讲述了本文的第二个研究点，即动态心电图的智能降噪。首先介绍了动态心电图和静态心电图的区别，动态心电图在结构上的特点以及应用背景上的特殊性为现有降噪算法带来了挑战。然后重点介绍了本文提出的多层长短期记忆网络降噪模型，从模型的整体结构到每一层的结构再到每一个神经元的结构。在这一章的最后，给出了相应的评价指标和实验结果。

第五章主要讲述了本文的第三个研究点，即心电图的自动分类。这一部分内容紧接上一章的内容，和上一章内容加在一起完整表述了本文对动态心电图的分类策略，即首先对动态心电图降噪，从动态心电图中恢复出静态心电图，然后再对恢复出的静态心电图自动分类。在这一章中，重点介绍了提取心率节拍的过程以及深度卷积神经网络模型，并在最后给出了相应的评价指标和实验结果。

最后是结论和展望，针对本文的工作以及相应的创新点进行最后的总结，并对未来的研究工作进行展望。



## 第2章 相关研究基础及进展

### 2.1 引言

为了抑制心脏病的高死亡率，远程心脏病监控系统被提出，近年来，随着心脏病死亡率的持续上升，远程心脏病监控获得了更多的关注。相比现有的心脏病监控方式，在远程心脏病监控系统中，心脏病监控走向系统化、网络化，致使其结构和数据变得复杂化。

在这一章中，先介绍了远程心脏病监控系统的发展历程，从国内的研究现状到国外的研究现状，并总结关于远程心电监控系统的几个主要研究点。然后针对远程心电监控系统中的心电图数据处理问题，本文认为心电图数据处理中的基础问题是心电图的降噪和心电图的分类，同时这两个问题也是数据处理中的核心问题，因此详细介绍了心电图降噪和心电图分类这两个问题的研究现状及其发展趋势。

### 2.2 远程心电监控系统综述

为了应对心脏病与现有心脏病监控方式之间的不适应性，同时抑制心脏病的高死亡率，其中一个值得努力的方向是赋予患者更多自主权，而不仅仅是等待发病时才采取措施，让患者进行自我监控而医生仍然扮演诊断分析的角色，这无疑是最有效、最经济的一种解决方案。远程心电监控系统作为这一解决方案的实践，旨在将心电图数据的采集与诊断分离。在第一章中，针对现有心脏病监控方式与心脏病的发病特性之间的矛盾，在远程心电监控系统中患者可以居家采集心电图，得益于身体传感器的发展，心脏病患者可以在任何时间、任何地点采集自身心电图，这极大的方便了心电图的采集，同时也可以减少心脏病患者外出就医、住院观察引起的额外医疗开销，进而提高心脏病患者的生活质量。

从国内研究状况来看，较早涉足远程医疗的是清华大学的研究团队在 1996 年提出的一种基于个人 PC 的远程心脏病和血压监控系统<sup>[26]</sup>，这个系统的初衷是为心血管疾病患者提供居家可用的心电信号和血压采集装置，但是由于传感器设备、移动设备的缺乏以及通讯方式的单一，使得整个远程疾病监控系统笨重且难操作，同时其成本偏高。虽然这种基于个人 PC 和家庭电话线的远程生理信号监控系统存在一些不足之处，但是这种系统结构却奠定了远程生理信号监控的结构基础，同时给出了一种新型的数据处理模型。与现有心脏病监控方式下的采集即处理模型不同，这种新型数据处理模型分为数据的采集、数据的传送以及数据

的存储。两种监控方式下的数据流向对比图见图 2.1。

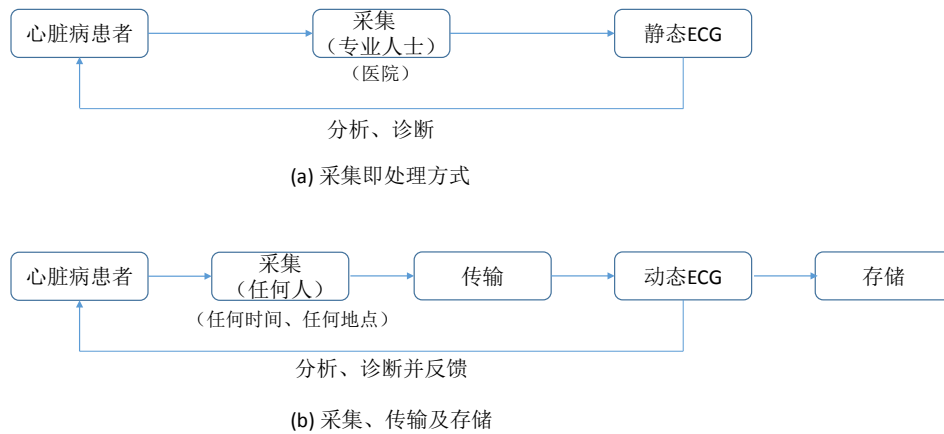


图 2.1 数据流向对比图

在之后的发展中，国内在远程心电监控这一领域研究较为突出的还有北京大学研究团队提出的 WE CARE 项目<sup>[27,52]</sup>，北京中科院以及深圳中科院在远程医疗体系中所做的特征检测<sup>[53]</sup>、基于移动互联网的便携式远程医疗监护系统<sup>[28]</sup>以及分类<sup>[54]</sup>等研究，位于台湾的国立交通大学<sup>[29,55]</sup>以及台湾大学<sup>[30,56]</sup>在这一研究领域也有较为突出的贡献，其中台湾大学附属医院远程监控中心<sup>[31]</sup>已经部署有一整套完整的心电信号实时监控系统，并且已经投入使用开始服务于一些台湾市民，市民只需要在家中采集心电信号，然后通过互联网将采集到的心电信号发送到医院监控中心，就能够得到及时的服务。

而在国外，远程监控人的生理活动信息早在 1971 年就由 T. H. Corbin 等人提出<sup>[8]</sup>，对于心脏病的监控，D. E. Lewis 在 1976 年正式提出远程心脏病监控系统<sup>[58]</sup>，在这一系统中主要涵盖了传感器和数据的传输这两个方面。在随后的发展中，R. Bedini 在 1994 年将远程医疗应用到心电信号的分析<sup>[59]</sup>中，D. Franchi 等人在 1998 年提出了依靠个人 PC 以及电话线来实现动态心电信号和其它生理信号的远程监控方法<sup>[9]</sup>。就近几年来看，在远程心脏病监控系统这一研究领域中的研究仍然较多，但是在远程心脏病监控系统结构方面的研究较少，较多的研究分布在以下几个方面：

(1) 远程心脏病监控系统中的身体传感器。如 F. Giroud 等人<sup>[10]</sup>在 Soc 上开发了一个低功耗的心电图采集前端，并实现了 3 导联的心电监控。针对无线心电图系统，R. Fensli 等人<sup>[11]</sup>开发了一种穿戴式的身体传感器，利用这种传感器可以持续监控和记录心脏病患者的心脏病状况，并通过无线网络传输数据。J. Dong 等人在<sup>[34]</sup>中提出了便携式智能心电监护仪，并已经投入到临床环境中，经临床认可，该设备具有测量准确，移动性强，易于使用，耐用，重量轻等优点。根据应用场景的不同，不同的身体传感器被用于获取心脏病患者的心电图，主要落脚点在身体传感器的能耗以及易用性。

(2) 针对不同身体传感器的心电图 QRS 检测，一个单心跳节拍见图 2.2。




图 2.2 心电图的 P-QRS-T 特征波

QRS 波群指的是由 Q 波、R 波及 S 波组成的波群，在远程心脏病监控系统中，由于采用了不同的身体传感器，采集到的心电图也存在较大差异，因此心电图中的 QRS 检测成为了一个较热的研究领域。如 F. Avcu 等人<sup>[12]</sup>在 IOS 智能手机平台上实现了实时的心电图 QRS 波群检测，C. Liu 等人<sup>[39]</sup>利用可穿戴身体传感器实现了实时和连续的个体心电图监控，这是一种 12 导联的心脏病监控系统，对于无噪心电图，其 QRS 波群检测准确率能够达到 99.5%，对于带噪心电图，其 QRS 波群检测准确率也有较大提升。QRS 波群中包含了心电图中的大部分信息，其识别准确率对于很多心脏疾病的检测有重大意义，因此几年来对于 QRS 波群的检测算法层出不穷。

(3) 远程心电监控系统中的信号传输。相比现有心脏病监控方式，远程心电系统中需要将心电图从患者端传输到医院端，传输过程中的心电信号压缩成为了远程心电监控系统中的一大研究点。如 H. Mamaghanian 等人<sup>[14]</sup>基于最新的压缩感知算法在无线人体传感器网络中实现了低复杂度的心电图压缩，在 ECG 压缩能效方面优于目前最好的数字小波变换 (DWT) 方法。压缩率和重建 ECG 质量是评价信号压缩算法的两个最主要指标，为了改进压缩感知算法的压缩率以及信号重建质量，F. L. Polania 等人<sup>[60]</sup>通过结合先验知识和信号重建算法获得了压缩率和重建质量方面的显著性能增益。针对远程心电监控系统中的信号传输问题，不同的压缩算法均旨在较小失真的压缩 ECG 的前提下减少传输过程中的能耗、提高传输效率。

综合国内外的研究现状来看，在早期时候，由于移动设备在计算能力和可扩展方面的限制以及数据的传输方式很单一，所以这种远程监控系统结构提出之后，在这一领域中学者的关注点更多在于身体传感器、QRS 波群检测以及 ECG 传输等。远程心电监控系统中的身体传感器旨在为心脏病患者提供持续的、便携的心电监控，而 QRS 波群包含了 ECG 中的大部分信息，对于心脏病疾病的检测具有重要意义，ECG 传输只存在于远程心电监控系统中，减少传输过

程中的能耗、提高传输效率将会是一个永恒的课题。近年来身体传感器、智能手机以及云计算等技术的发展，为远程心电系统的结构实现提供了新的实现思路。

## 2.3 心电图的降噪研究现状

在远程心电监控系统中，心电图中最常见的噪声有基线漂移（BW）、电极运动（EM）以及肌电干扰（MA），三种噪声信号见图 2.3。




图 2.3 远程心电监控系统中的三种常见噪声

其中基线漂移主要产生于患者的呼吸和走动，电极运动主要产生于患者与传感器之间不恰当的接触，肌电干扰则来自肌肉等部位的收缩。当心电图中同时存在这些噪声时，使得心电图的形态与静态心电图相比存在较大差异（图 1.2）。

将心电图作为一种信号数据，最具代表性降噪方法有滤波器、小波变换以及 EMD。文献[16]中利用卡尔曼滤波器处理存在基线漂移的心电图，能够以较高的准确率滤除心电图中的基线漂移，为了处理心电图中的不同类型的噪声，文献[61]中使用多种自适应滤波器高质量的提取心电信号的特征波，文献[62]中在微处理器上级联多个数字滤波器以近乎实时的速度处理心电图中的多种噪声，但是当心电图同时包含多种噪声时，滤波器很难滤除与心电图频率相近的噪声，同时多个滤波器的级联增大了计算上的复杂性，以及通常需要外部参考来估计噪声极大的限制了其在大规模数据上的应用。小波变换作为一种更普遍的方法，在心电图降噪上有着广泛的应用，文献[17]中利用离散小波变换的粗略估计来滤除心电图中的基线漂移，并在真实数据上检测了算法的有效性，对于弱信号的检测，在文献[63]中基于子带编码理论提出了阈值自适应小波变换，可在低信噪比情形下检测心电信号的特征波，文献[64]中通过平稳小波变换从噪声中恢复有效心电图，并以最小的失真显示信号，虽然可以通过选取更合适的阈值、多层变换等方式提升算法性能，使算法适用于噪声较大的情形，但是适用于较大噪声情形的算

法却无法推广到噪声较小的情形<sup>[65]</sup>，算法的有效性仍然十分依赖母波，这无疑是特征提取的瓶颈。文献[18]中使用EMD方法将心电图分解成有限个IMFs，其中低阶的IMFs包含了心电图的高频成分，而高阶IMFs中包含了心电图的低频成分，分解之后的信号在结构上简单了很多，通过处理IMFs来滤除心电图中的低频和高频噪声，但是IMFs之间存在混频现象，可能会将心电图中的P波、T波滤除。虽然EEMD（Ensemble EMD）<sup>[66]</sup>解决了EMD方法中的混频现象，但是却增大了计算复杂性。

另外一种趋势是通过提取心电图中的有用成分重构心电图。这类方法摆脱了信号处理中不得不面对的阈值选取问题，而是通过线性或非线性变换，提取心电图中的有用特征。文献[19]中利用主成分分析（PCA）分离心电图中的有效信号和噪声，通过协方差矩阵区分心电图中的不同成份，选择低阶主成分重构心电图，其问题在于动态心电图中的主要成分和次要成分很难界定。文献[67]中利用独立成分分析（ICA）处理频率与心电信号相近的噪声，通过矩阵的逆变换将信号分解为心电信号和各种噪声的线性组合，并假设心电信号和噪声在独立子空间，但是噪声并不总是以线性、平稳的方式和心电图混在一起<sup>[68]</sup>，这使得信号的线性可分性成为一个问题。文献[69]中将神经网络应用到心电图降噪，通过一系列的非线性变换自动提取心电信号中最有用的信息。为了提取心电图的深层次特征，文献[70]以及[71]中将深度神经网络模型应用到心电图降噪中，通过大量数据自动学习心电图中最具代表性的特征，可以在不依赖阈值和波形的前提下高质量还原心电图。

现有降噪方法通常是针对某种特定类型的噪声，提出相应降噪算法，噪声类型改变之后需要重新调整参数，而实际上无法提前确定动态心电图中的噪声类型，而且动态心电图中往往同时包含多种类型的噪声。针对这些问题，现有降噪算法均表现出不适应性，人工智能结合大数据，使降噪模型能够用于包含不同类型噪声甚至多种噪声同时存在的心电信号的降噪。

## 2.4 心律失常检测研究进展

ECG 以时间为单位记录心脏的电生理活动，广泛应用在心脏病的临床诊断中，详细的一个心电图周期见图 2.4。




图 2.4 单周期心电图详解图

在图 2.4 中，ECG 中包含了丰富的特征，从时间的先后顺序上，依次是 P 波、PR 间隔、PR 段、Q 波、R 波、S 波、J 点、ST 段、T 波、ST 间隔、QT 间隔以及 RR 间隔，其中 Q 波、R 波和 S 波组成 QRS 波群间隔。除此之外，ECG 的特征还包括波形上的特征、时域特征以及频域等特征，特征点和特征波对于心电图的判读起着至关重要的作用。因此，在心电图的自动分类中，这些特征广泛应用在心脏病的自动诊断中。连续的 ECG 可以记录心脏病患者 24 小时的所有心脏活动，但是在心脏病诊断过程中，通常以单个心跳节拍为单位，因此本文中提到的心电图分类均指对心跳节拍的自动分类。

在心电图自动分类上的研究很广，但是这些方法或者采用了不同的数据预处理方式，或者采用不同的特征提取工程或者采用了不同的分类器，这意味着数据预处理、特征工程以及分类器是心电图自动分类的最主要部分。其中，分类器通常是心电图自动分类的最后一步，应用在心电图自动分类中的常见分类器有：人工神经网络、支持向量机、决策树和随机森林、K 近邻算法以及常见的深度学习模型，如卷积神经网络、受限玻尔兹曼机、自编码器以及深度信念网络。

(1) 以人工神经网络 (NN) 为分类器；S. Osowski 等人<sup>[20]</sup>应用高阶统计量特征，以模糊神经网络为分类器对心电图分类，完成了对不同类型心跳节拍的识别和分类。和这篇文献类似，H. T. Linh 等人<sup>[72]</sup>也以模糊神经网络为分类器，但是采用 Hermite 因子作为特征提取方法，也取得了不错的实验效果。同样采用神经网络作为分类器，但是采用了不同的特征提取方法，便形成了不同的方法，如文献[73]中采用小波变换作为特征提取方法，而文献[74]中采用小波变换结合主成分分析作为特征提取方法。除此之外，常用的特征提取方法还有线性判别分析、混合 C 均值、连续小波变换以及离散余弦变换等，通过结合不同的特征提取方法，均取得了 90% 以上的分类准确率。

(2) 以支持向量机 (SVM) 为分类器；C. Ye 等人<sup>[75]</sup>通过小波变换和独立组件分析提取 ECG 的 RR 间隔、形态学等特征，以 SVM 为分类器实现了二导联 ECG 的分类，并且取得了较高的分类准确率。而 S. Osowski 等人<sup>[21]</sup>利用

SVM 分类器、高阶统计量以及 QRS 波群的 Hermite 特征等特征提取方法，融合构成了一个专家系统，该专家系统可以为 13 种类型的心跳节拍提供可靠的识别。N. Sultana 等人在文献[76]中提出了一个五分类 SVM 分类器，提取了心电图中的 QRS 波群，RR 间隔，R 波，S 波和 T 波等特征，对 5 种类型的心跳节拍实现了 95% 的识别准确率。通过使用离散余弦变换提取 ECG 在时频域的特征，并结合主成分分析减少特征的维度，S. Raj 等人<sup>[77]</sup>通过结合 SVM 分类器和粒子群优化算法（PSO）对 16 种类型的心跳节拍分类准确率达到 98.82%。同样利用 PSO 优化 SVM 分类器的还有 M. Moavenian 等人<sup>[78]</sup>，虽然采用了不同的特征提取方法，但是也取得了 97.21% 的心跳节拍分类准确率。可见通过结合 SVM 分类器和不同的特征提取方法均取得了不错的分类准确率。

(3) 以决策树和随机森林为分类器；G. R. Kumar 等人<sup>[22]</sup>通过离散余弦变换提取 ECG 中的 RR 间隔作为分类的特征，并使用随机森林作为分类器，在 MIT-BIH 数据集上对不同类型的心跳节拍分类，取得了不错的分类准确率。同样使用随机森林作为分类器，但是 E. Alickovic 等人<sup>[79]</sup>使用离散小波变换将 ECG 分解成不同的连续频带来提取心电图中的波形特征，最终在 5 种不同类型的心跳节拍上实现了 99.95% 的分类准确率。ID3 算法是决策树的一种经典实现，T. A. Sadiq 等人<sup>[80]</sup>利用 ID3 决策树和离散小波变换等特征提取方法在 MIT-BIH 数据集上取得了 94% 的分类准确率。

(4) 以 K 近邻算法（KNN）为分类器；J. Park 等人<sup>[24]</sup>利用 Pan-Tompkins 算法提取 ECG 中的 QRS 波群以及 P 波等特征，在 MIT-BIH 心律失常数据集上对 17 种类型的心跳节拍分类，KNN 分类器的灵敏性和特征性均达到了 97% 左右。I. Christov 等人<sup>[81]</sup>利用 KNN 分类器，对室性早搏（PVC）和正常心跳节拍（NOR）的特异性和灵敏性同样超过了 96%。为了实现高性能的异常心律检测，J. T. Jun 等人<sup>[82]</sup>在云服务器上的虚拟 GPU 上执行其检测算法，检测时间是 CPU 检测算法的 2.5 倍。并且实现了 93.5% 的准确率。

(5) 以深度学习模型（DNN）为分类器；与传统机器学习算法不同，深度学习模型分类器没有复杂的特征提取工程。如 Y. Yan 等人<sup>[83]</sup>针对两导联的心律检测问题，构建了一个深度信念网络（DBN），将受限制的玻尔兹曼机器学习算法应用于心律异常检测分类中，实现了 98.829% 的分类准确率。同样采用深度信念网络的还有文献[84]和文献[85]，不同的是，D. Wang 等人在[84]中使用 DBN 作为心律失常检测分类器，而 M. Huanhuan 等人在文献[85]中使用 DBN 作为 ECG 特征提取器，使用 SVM 作为心律失常检测分类器。同样采用深度学习模型，Rahhal 等人<sup>[25]</sup>搭建了一个深度自编码器网络，并且在三个 ECG 数据集上检验了模型对心律失常的检测准确率，检测结果表明模型能够在更少专家干预的前提下达到比较高的检测准确率。除此之外，一种更加普遍的深度学习模型

是卷积神经网络（CNN），不同层数的卷积神经网络形成了不同的分类器<sup>[86]</sup>，这些 CNN 模型在网络结构和数据处理上采用了不同的方式，CNN 模型的层数从 3 层到 11 层不等，甚至更深的网络结构。在数据处理上，一些 CNN 模型将 ECG 视为信号数据，采用 1-D CNN 模型，还有一些 CNN 模型将 ECG 视为图片数据，采用 2-D CNN 模型。

以上五类方法是 ECG 心律失常检测分类中研究较多的，除了以上方法，还有贝叶斯方法、循环神经网络等应用在 ECG 心律失常检测中。虽然在很多文献中指出了 ECG 心律失常检测分类准确率达到 98%，有的文献甚至超过了 99%，但是在动态心电图上其检测准确率只有 58.7%，其背后的原因主要来自科研中考虑问题的片面性往往与真实场景的复杂性相冲突，将复杂场景步骤化，再结合深度神经网络模型在数据处理上的优势，有望进一步提高动态心电图的心律失常检测分类准确率。

## 2.5 小结

本章首先介绍了远程心电监控系统的系统结构，并从时间线和国内外研究两个方面，详细介绍了远程心电监控系统在系统结构上的发展、不同时间段内针对远程心电监控系统的研究侧重点以及近年来在远程心电监控系统方面的代表性作品。然后针对远程心电监控系统中的噪声问题，分别介绍了现有的不同降噪方法，如滤波器、小波变换、EMD、PCA、ICA 以及神经网络等，针对噪声较大、噪声类型会发生改变以及噪声类型无法确定等实际场景，指出了现有降噪方法存在的不足和挑战，并希望通过结合人工智能和大数据为 ECG 降噪提供新思路。最后回顾了 ECG 心律失常检测分类中的最常见的五类方法，包括人工神经网络、支持向量机、决策树和随机森林、K 近邻算法以及深度学习模型，其中前四种方法主要出现在早期的 ECG 分类检测中，而深度学习模型，如深度信念网络、自编码器、卷积神经网络以及循环神经网络，成为了近年来的主流方法，而且其心律检测分类准确率均达到了 90% 以上，但是临床上对于动态心电图的检测分类准确率却很低，主要是噪声问题以及不同人 ECG 之间的巨大差异引起的，因此，本文希望将动态心电图的检测分为多个步骤，再结合深度学习方法进一步提高动态心电图的检测分类准确率。



## 第3章 远程心电监控系统

### 3.1 引言

相比较于现有的心脏病监控方式，远程心电监控系统提供了一种完全不同的心脏病监控方式，虽然近年来关系远程心电监控系统的研究仍然很多，但是主要是关于心电图采集工具、QRS 波群检测方法、远程心电传输等方面的，反而远程心电系统结构方面的研究较少。目前，远程心电监控系统未能普及的一个重要原因是缺少成熟的方法来处理动态心电图，除此之外，另一个重要原因是远程心电监控系统的系统结构还不够完善。因此，在这一章中，本文将从远程心电监控系统的一种企业级实现方式出发，重新思考远程心电监控系统在系统结构上的实现以及系统中的数据处理问题和计算问题。

早在 2016 年，全球心脏病患者就已经超过了 9 百万，更严峻的一个趋势是青少年的心脏病发病率也越来越高，可见远程心电监控系统有着非常广大的市场，在图 3.1 中给出了一种远程心电监控系统的企业级实现。



图 3.1 远程心电监控系统的企业级实现

在图 3.1 中给出的是北京生息握持公司和医院合作实现的一种远程心电监控系统。在这种远程心电监控系统中，主要由四部分构成，分别是心电图采集设备、移动终端、云服务中心以及分析工作站。对每一部分的功能介绍如下：

(1) 心电图采集设备：整个心电图采集设备只有一张名片大小，却集心电图的采集和传输功能于一体，并且符合 2014AHA/ACCF/HRS 指南精神，采用白金标准的 DXL 算法，因此可以避免假阴性事件发生。除了便于携带之外，这种心电图采集设备也是易操作的，心脏病患者使用该设备获取自身心电图的整个过程只需要一个按钮就能完成采集和传输。在具体使用中，患者使用该设备采集心电图时可以选择使用双手测量法或者胸部 V5 测量法，其中双手测量法只需要

心脏病患者用双手握持该心电图采集设备 30 秒即可完成心电图的采集，即使是心脏病患者的主要群体——老年人也能够很轻松的使用该设备。出于能耗方面的考虑，这种心电图采集设备并没有提供网络接口和蓝牙接口，取而代之的是以声波方式传送心电图数据，因此该设备一次完全充电后可持续使用 2 年。

(2) 移动终端；移动设备的发展也是该远程心电监控系统得以实现的一个关键，而移动 APP 更是丰富了移动设备的功能。移动终端在整个系统中主要充当数据中转的作用，即心脏病患者自主采集的心电图数据会先从心电图采集设备传输到移动终端，然后再由移动终端传送到云服务中心，最终心电图数据会存储在云服务器上。数据从心电图采集设备传输到移动终端采用的是声波传送，具体的操作流程也只需要将心电图采集设备的放音孔靠近移动终端的放音孔。而移动终端归根结底只是一个计算能力受限、存储空间受限的设备，因此心电图数据还需要从移动终端传送到远程云服务器上，此时采用的是网络传输的方式。

(3) 云服务中心；云计算是一种新兴的网络计算模式，美国国家标准与计算研究院（NIST）将云计算定义<sup>[87]</sup>如下：云计算这个模型可以方便地按需访问一个可配置的计算资源的公共集，如网络资源、服务器资源、存储资源、应用程序以及服务等。这些资源可以被迅速提供并发布，同时最小化管理成本或服务提供商的干涉。在远程心电监控系统中，利用云计算技术可以将医院、药店、保险企业、监管机构、患病用户、健康用户以及其他所有相关单位或个体关联起来，为其提供数据存储管理、数据分析、网络安全保障等服务。医院可以从云服务中心获取到心脏病患者上传的心电图数据，而心脏病患者可以从云服务中心获取到自身的诊断报告。

(4) 分析工作站；分析工作站主要指分析患者心电图的站点，其中分析既可以是人工分析，也可以是自动算法辅助分析；而站点主要指中大型的医院，一般的社区医院或小型医院，在人力资源、设备资源等方面匮乏。在实际使用中，通常是心电图自动分析和人工分析相结合，心电图自动分析可以不经心电专家判读，用户在较短时间内即可得到系统自动分析的心电诊断结果，而人工分析主要依靠心电专家复核心电图自动分析结果，确保事件诊断结果准确性。同时，针对诊断结果，与患者电话沟通，消除患者的不安与疑虑。

针对这种新型的远程心电监控系统，在这一章中将分别介绍身体传感器，即心电图采集设备的发展历程、远程心电图系统中的数据处理模式以及计算模式。

## 3.2 心电图采集设备

心电图采集设备在远程心电监控系统中扮演着十分重要的角色，可以说是整个系统便携性、易操作性的主要体现。根据使用方式的不同，主流的心电图采集设备主要分为两个类别：粘合性电极片和金属触点电极片，这两种心电图采集设

备在形状和使用方式上相差甚远，其形状见图 3.2。




图 3.2 两种主流的心电图采集设备

(1) 粘合性电极片<sup>[88]</sup>；在图 3.2 的(a)图中给出了粘合性电极片的形状结构图，粘合性电极片是目前使用最广的一种心电图采集设备，在现有的心脏病监控方式中，心脏病患者在医院采集心电图时使用的就是粘合性电极片。这种粘合性电极片的优势在于能够采集到静态心电图，静态心电图的波形结构见图 1.2，静态心电图中噪声干扰较小，保留了心电图中的特征波形以及特征点，这有利于心电图的分析和诊断。除此之外，在远程心电监控系统中，粘合性电极片通常被包装成可穿戴设备，可以为心脏病患者提供 48 小时全天候的监控方式，患者任何的异常心律活动都能够记录下来。因此，目前很多商用心电图采集设备都使用的是粘合性电极片。如 V-Patch、Lifecare、Lifestar ACT 等商用设备均采用的是粘合性电极片，心脏病患者只需要将设备贴在心脏部位即可完成全天候的心电图采集，通过专属无线网络可将心电数据传送到数据分析站点。doc@home 这种商用心电图采集设备也采用粘合性电极片，但是使用的是有线电话连接传输心电数据，而 ECGnano、PMP4 SelfCheck ECG 这两种心电图采集设备使用的是蓝牙传输心电数据。

(2) 金属触点电极片<sup>[89]</sup>；在图 3.2 中的图(b)中给出了金属触点电极片的形状结构，相比较于粘合性电极片，金属触点电极片的外观更加多样化，更大的区别在于使用方式上的截然不同，心脏病患者在金属触点电极片采集自身心电图时，通常只需要身体的某个部位接触设备上的金属触点即可，最常使用的身体部位如手指、手掌等。金属触点电极片的优势在于心脏病患者不需要穿戴使用，可以按照自身习惯使用，心脏病患者可以在任何时间、任何地点按照自身习惯采集心电图，是一种非侵入性的心电图采集设备，对于患者来说更加友好，考虑到心电图采集设备的使用群体主要是老年人，因此用户友好型设备十分重要。然而，由于使用的是接触金属的方式采集心电图，使得采集到的心电图通常如图 1.2 中所示的动态心电图，动态心电图中有较大的噪声干扰，这也为心电图的诊断和分析带来了巨大的挑战。金属触点电极片在目前商用心电图采集设备中也占有一席之地，如 REKA 私人有限公司开发的 E100 心电图采集设备，这种心电记

记录仪使用手指接触金属触点的方式采集患者心电图，可以配合市场上的大部分手机以及笔记本电脑使用，而且在 E100 心电记录仪中还内置了存储器以及数据加密功能，可以将部分数据存储在本地，同时可以保障数据传输过程中的安全性。同样使用金属触点电极片的商用心电记录仪还有 HeartCheck ECG PEN、DiCare m1C 等，其中 HeartCheck ECG PEN 是一款笔状的心电图采集设备，同样使用手指接触金属触点的方式采集患者心电图，DiCare m1C 一款智能，多功能，无创，可靠且易于操作的心电图记录仪，采用指尖触摸的方式即可清晰的记录心电图，并完整地显示 ECG 波形，适用于从静止到剧烈运动的状态持续进行心电图监测。

金属触点电极片除了在商业上有着广泛的用途之外，在科研中也有着大量的研究。A.Benini 等人在文献[90]中引入了一种单导联心电图采集设备，通过大量的走访心脏病患者，调查心脏病患者最青睐的心电图采集方式，最终采用手掌接触金属触点的方式，开发了一种书本大小的心电图记录仪，使用这种记录仪采集到的心电图和心脏病患者在医院采集的静态心电图几乎一致。再如图 3.2 中的图(b)中给出了一款手指接触金属触点的心电图记录仪，同时将心电图记录仪和一个 ARM 处理器集成在一起实现心电图的实时处理，在 ARM 处理器上训练了一个 SVM 分类器，通过该分类器将采集到的心电图在本地识别为正常心跳或心房颤动或心肌缺血这三类。类似的研究还有很多，在考虑了不同的应用背景的前提下，在文献中提出的心电图记录仪在形状和使用上均存在较大的区别，这是与商用心电图采集设备最大的区别之一，商用心电图记录仪在形状和使用上差别不大，总是旨在为心脏病患者提供便捷的、易操作的心电图采集方式。将主流心电图采集设备汇总见表 3.1。

表 3.1 商用心电图采集设备

ECG 设备	V-Patch	Lifecare	REKA-E100	Lifestar-ACT	ECG-PEN	ECG-nano
电极片类型	粘合性	粘合性	金属触点	粘合性	金属触点	粘合性
ECG 设备	doc@home	DiCare-m1C	PMP4-ECG	iPhone-ECG	Cardio-Defender	Smart-heart
电极片类型	粘合性	金属触点	粘合性	金属触点	金属触点	粘合性
ECG 设备	ME-80	ELI-10 mobile	MD-100E	EKG/ECG -80A	PC-80	ECG-Check
电极片类型	金属触点	粘合性	粘合性	粘合性	粘合性	金属触点

在图 3.1 中给出的远程心电监控系统的企业级实现方案中，心电图采集设备使用的是手掌与金属触点接触的方式采集心电图，因此属于金属触点电极片的一种。除了具备一般金属触点电极片的特性外，这种心电图采集设备的特点见图 3.3。

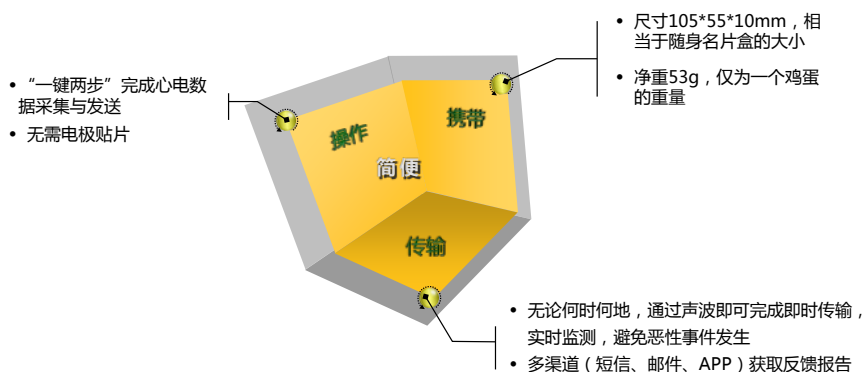


图 3.3 心电图采集设备的特点

心脏病患者在使用这种便携式、易操作的心电图采集设备时，只需要一个按键即可完成心电数据的采集和发送，而且省去了繁琐的电极贴片，让心脏病患者可以在不具备任何专业知识的前提下采集自身的心电信号，这对于老年人群体来说是极其友好的。目前，心电图采集设备得到了极大的发展，这些心电图采集设备旨在为心脏病患者提供简单易操作的使用环境，同时便携性、提供持续的监控方式等也是心电图设备的设计宗旨。

### 3.3 远程心电图系统

在图 3.1 中给出的远程心电监控系统的企业级实现中，引入了云服务中心作为数据存储管理、数据分析以及网络安全保障的节点，可以将医院、药店、患者等相关单位和个体关联起来，见图 3.4。



图 3.4 云平台服务体系

通过借助图 3.4 中的云平台，可以建立以患者为中心的新型医患模式。以心

脏病为例，和心脏病患者息息相关的医院、保险、医生、病友等单位和个人均可通过云平台与心脏病患者联系起来，与现有医患模式最大的区别在于可以为患者提供成体系的服务，而不是单方面的某一种服务。同时，医生可以建立自己的患者群体，提升个人形象和口碑，通过远程的手段加大对患者的关注，减少医患纠纷的隐患，而且每一位医生都可以和业界专家无缝对接，如课题参与、学术交流等。

在上一节中介绍的心电图采集设备是这种新型远程心电监控系统中的另一个核心部分，这种智能传感器除了能为心脏病患者省时、省钱、省事的同时，通过结合云服务中心还可以构建图 3.5 所示的智慧医疗体系。




图 3.5 智慧医疗体系

在图 3.5 中的一体化医疗体系中，能够将专家资源和设备资源缺乏的社区医院和中心医院联系起来，充分利用中心医院的专家资源和医疗设备资源。整个一体化的医疗体系构成了一个典型的物联网（IoT）系统<sup>[91]</sup>。在物联网系统中，旨在为所有事物提供一个 IP 地址使其能够通过互联网与外界交换数据，让人与人之间、人与物之间、物与物之间都能够相互交换数据以满足某些智能需求。在可以预见的未来，我们可以看到物联网在衣食住行等各方面带来的改变，在“衣”这一方面，各种可穿戴设备的发展实现了人的生理数据与外界的交换，如嵌入在汽车驾驶员座椅上传感器能够实现对驾驶员状态的监控，可用于检测驾驶员是否疲劳驾驶，这也是智慧交通的一部分；在“食”这一方面，对于食品的开始加工时间、食物加工过程的监控等都可以实现联网，如早上的咖啡机在起床之后定点开启、面包加工过程的监控等都可以给我们的生活带来便利，这也是智慧生活的一部分；在“住”这一方面，各种家电设备的网络化方便了我们远程控制家电设备，如空调的开启可以在户主到家前的几十分钟，户主还可以远程的调节空调的温度以及风速，这也是智能家居的一部分；最后在“行”这一方面，无人驾驶以

及辅助驾驶等概念不再是新名词，车与车之间的数据交换能够给汽车提供一条最少拥堵，路况最好的道路，甚至路口红绿灯能够通过当前路况智能调节持续时间，这些也是智慧城市的一部分。如图 3.6 所示的以云计算和雾计算为中心的物联网框架。

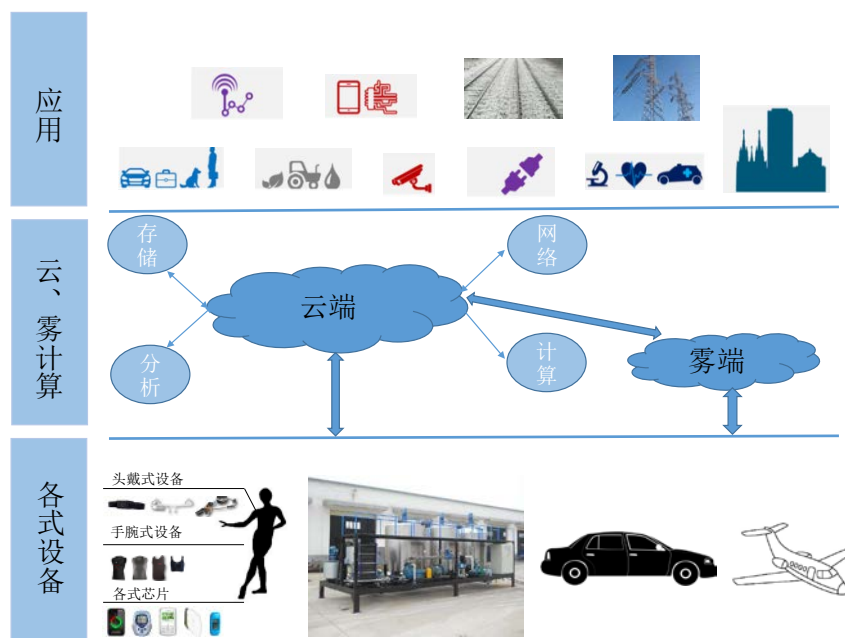


图 3.6 云、雾计算为中心的物联网框架

在物联网系统中，数据处理模式和计算模式是不可回避的两个问题，因此，本节将聚焦于这种物联网结构的远程心电监控系统中的数据处理模式以及计算模式。

### 3.3.1 数据处理模式

数据处理是对数据进行分析 and 加工的过程，通过对数据的采集、存储、检索、加工、变换和传输，将数据变为信息的过程。在物联网系统中，各类穿戴式设备、机床、汽车以及飞机等产生了大量的数据，每一类数据在结构特点上存在巨大差异，或是结构化数据、半结构化数据，甚至非结构化数据。更具体地，在物联网结构的远程心电监控系统中，通过传感器采集并传输数以亿计的心脏病患者的心电数据，针对如此大量的数据，最常见的数据处理模式有两种，分别是批处理模式和流处理模式。

批处理模式主要操作大容量静态数据集，数据集一般具有大量、持久以及有界等特性，通常需要遍历整个数据集才能完成计算。Apache Hadoop 是首个在开源社区获得极大关注的大数据处理框架，专用于批处理的大数据处理框架，其批处理功能主要来自 Hadoop 的原生批处理引擎——MapReduce。MapReduce<sup>[92]</sup>是谷歌公司在 2004 年公开的一种编程范式，这种编程范式通过计算机集群并行处理大规模的数据集，并且在谷歌公司内部已经有了很多成功的

应用。首先 MapReduce 是易用的，MapReduce 隐藏了分布式系统中并行化的细节、优化、负载均衡以及容错等，这使得即使不了解分布式编程或并行编程的程序员也能很轻易的使用 MapReduce。其次，MapReduce 非常灵活，能够同时处理结构化数据、半结构化数据甚至非结构化数据，而且 MapReduce 的可扩展性很强，既能够工作在单机模式下，同时也能在成千上万个节点上正常工作。从 MapReduce 的一般工作流程中，可以总结出批处理模式的一般过程如下：

(1) 读取数据；从类似于 Hadoop Distributed File System (HDFS) 这种分布式文件系统中读取数据集；

(2) 数据分片；将较大的数据集拆分成小块，将每一小块数据分配给所有可用的节点；

(3) 每个节点对本节点上的数据子集进行计算，中间结果可以保存在本地文件系统中；

(4) 重新分配中间结果，按照键值进行分组；

(5) 对每个节点上的中间结果进行汇总；

(6) 将汇总结果写入分布式文件系统，如 HDFS。

从 MapReduce 的一般执行流程可以看出 MapReduce 的最大缺陷在于效率低，由于 MapReduce 主要以容错和可扩展为设计目标，并没有对 I/O 效率进行优化，因此在执行过程中存在多次读写 HDFS。同时，从其执行流程中还可以看出需要遍历整个数据集才能完成最终的计算，通常情况下需要几小时或者几天才能将结果返回，因此采用批处理方式在实时性上的效率较差。

对于流数据的一个最直观理解是流入系统中的数据是持续不断的，数据可能来自成千上万个数据源，但是每一个数据源的数据量不大，产生的数据以数据记录的形式流入系统中。流数据处理与批数据处理不同，流数据处理通常只针对单条数据记录计算，而且在实时性上的要求较高，通常应用在实时性要求较高的场景，如社交网站信息、金融交易、线上交易等。在图 3.5 所示的智慧医疗体系中，数以亿计的心脏病患者都是一个数据源，虽然每个心脏病患者均只产生很小的数据量，但是数据分析站必须在较短时间内返回计算结果，可见图 3.1 所示的远程心电监控系统中的数据处理的属于典型的流处理方式。

目前流处理框架以 Spark Streaming、Storm、Flink 等为代表，其中 Spark 是一种通用的集群计算框架，也是 Apache 的一款开源框架，Spark 通过将数据集计算任务分配到多个计算节点上，提供高效内存计算，Apache Spark 开源项目包含多个紧密集成的组件，其中 Spark Streaming 这个组件提供了对实时数据的流式计算。Storm 是一款分布式实时计算系统，其使用十分高效，能够可靠的处理无界数据流，因此在分布式 RPC、实时分析、连续计算、在线机器学习等领域有着广泛的应用。而且 Storm 的处理速度很快，每个节点每秒钟能够处理



百万级的数据记录，在 Twitter 这种大型社交平台上使用的数据处理模式就是基于 Storm 的流处理方式。Flink 同样是 Apache 的一款开源框架，Flink 主要应用在流数据处理场景中，但是 Flink 能够同时支持流数据处理和批数据处理，基于 Flink 的流式执行模型，将批处理作为一种特殊的流数据处理。数据的流处理模型每次只需要处理很少的数据量，而且通常是基于内存的计算，因此能够在很短的时间内给出计算结果，在实时性上有很好的保障。

综合对比批数据处理和流数据处理这两种数据处理模式，在物联网结构的远程心电监控系统中，由于必须在较短时间内将心电图分析诊断结果反馈给心脏病患者，而且每次处理的数据量很小，因此属于典型的流数据处理。

### 3.3.2 计算模式

在上一小节中综合对比了两种典型的数据处理模式，即批数据处理和流数据处理，并确定了物联网结构的远程心电监控系统中的数据处理模式属于典型的流处理方式。随之而来的一个不可避免的问题是，在何处处理心脏病患者自主采集的心电图数据，即采用何种计算模式。目前在处理物联网数据时，主要有三种计算模式，分别是云计算、雾计算以及云-雾混合计算模式。

云计算的概念最早由 Google 首席执行官在 2006 年提出，通俗的讲，云指的是互联网，而计算是一类服务的总称，云计算即通过互联网按需提供计算能力、数据库存储、数据库、网络、应用程序和其他 IT 资源，而且云平台上提供的服务是弹性的，通常是按需购买，从而降低运营成本，使闲置的基础设施更有效地运行，并能根据业务需求的变化动态调整对服务的使用。目前云计算有三种基本服务模式，分别是基础架构即服务（IaaS）、平台即服务（PaaS）以及软件即服务（SaaS）。其中，在基础架构即服务这种服务模式中，供应商为用户提供服务器、存储器和网络等计算资源，用户可以在这些基础架构上使用自己的平台和应用，而且 IaaS 是种弹性服务，用户只需要对自己租用的那部分服务付费，而不需要为整套基础架构付费，同时还可以根据业务需求灵活扩展，既不会出现数据的单点故障，也不需要花大量人力物力在基础架构上，从而将更多的时间和精力放在其他业务上，这一点为初创企业、中小型企业带来了极大的便利。平台即服务这种服务模式中，除了可以提供给用户基础架构之外，还为用户提供了操作系统、数据库管理系统、开发工具和分析工具等服务，利用 PaaS 用户可以预构建工具套件，在相同的环境中开发、定制和测试自己的应用，同时可以将企业的精力集中在开发上，而不需要担心底层基础架构，即使在远程协同开发中也可以无缝连接各个开发小组。软件即服务是最上层的一种服务模式，在这种服务模式中，用户无需在本地设备上安装应用，且无需对软件进行维护，应用部署在远程云服务器上，软件的管理和维护由服务提供商全权负责，用户可以通过

API 或者网页等方式使用远程的应用软件。

通过云计算的这三种不同的服务模式，可以为用户带来极大的便利，用户可以根据自己的实际需求选择不同的服务模式，这三种服务模式之间的层次关系见图 3.7。

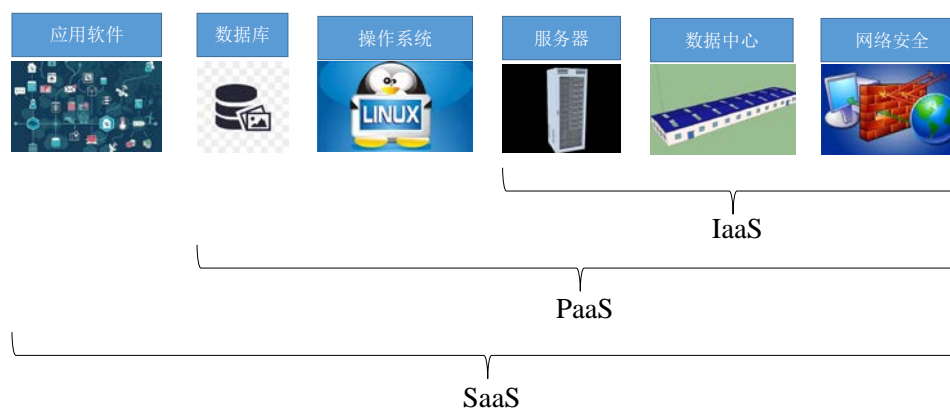


图 3.7 云计算三种服务模式间的层次关系

云计算使得用户就能随时随获得高出现有设备几十倍甚至几百倍的计算能力和存储空间。但是相应地，这种计算模式会因为网络的拥塞造成较大的时间开销，同时用户的隐私数据也需要一并上传到云端参与计算，导致数据的安全性得不到保证。而雾计算<sup>[93]</sup>作为云计算在网络边缘的扩展，丰富和完善了云计算在网络边缘上呈现出的不足，同时也是一种保护用户隐私数据的计算模式。雾计算在 2011 年由哥伦比亚大学的教授提出，在 2012 年由思科正式提出，并且定义了雾计算在物联网系统中所扮演的角色。雾计算将云计算范例扩展到网络边缘，从而实现新的服务模式，其最本质的特征是低延迟和位置感知，雾计算中的节点常常通过无线接入到系统中，因此节点数量多、分布广、节点之间的结构异构且具有流动性，而且实时性是雾计算中的重要考虑指标。雾计算相比云计算更加靠近物联网系统所说的“物”，因此它能够有效的较少数据传输过程中的延时，而且不必将隐私数据上传到云端，让数据在最合适的地方进行处理。相应地，雾计算相比云计算在计算资源、网络资源以及存储资源上会受限，无法像云计算模式一样提供高带宽和强大的计算能力。

由于雾计算在实时性上有较好的保障，雾计算在联网汽车、智能电网、智慧城市等应用中扮演着重要角色。对于更加复杂的动态系统，可能需要采用云-雾混合计算模式让数据在最合适的地方进行处理。如自动驾驶中，汽车在行驶过程中车与车之间，车与基础设施之间的局部信息交换在实时性上的要求较高，因此采用雾计算这种计算模式可能更合适，但是在行驶过程中的三维场景构图等需要高性能计算的任务，其计算量很大，对计算设备有较高的要求，可能就需要借助云计算这种计算模式来实现。

在物联网结构的远程心电系统中，虽然心脏病患者的心电数据属于隐私数

据，但是却更加适合云计算这种计算模式，在文献[89]中，T. Jeon 等人为了实现心脏病患者的隐私数据保护，通过将每个心电图记录仪和 ARM 处理器集成在一起实现心电图的实时处理，让计算在本地即可完成。为了达成保护用户隐私数据的目的，却大大增加了成本。通过借助云计算这种计算模式，图 3.1 所示的企业级远程心电系统得以实现，不仅能为心脏病患者提供便携、易操作的心电图采集方式，而且对于心脏病患者来说，所有的心电图诊断分析过程都是透明的。

### 3.4 小结

在这一章中，从一种企业级的远程心电系统出发，详细论述了这种新型远程心电监控系统中的四个主要部分，即心电图采集设备、移动终端、云服务中心以及数据分析站，并在此基础上，列举了目前两类主要的心电图记录仪，分别是粘性电极片和金属触点电极片。在这种新型远程心电监控系统中，综合考虑心电图采集设备和云平台后，可以建立以患者为中心的新型医患模式。不仅能将和心脏病患者息息相关的医院、保险、医生、病友等单位和个人均可通过云平台与心脏病患者联系起来，还可以充分利用中心医院的专家资源和医疗设备资源，整个一体化的新型医患模式构成了一个典型的物联网系统。在物联网结构的远程心电系统中，每次只需要处理极小量的数据，但是在实时性上的要求较高，因此本文将系统中的数据处理归结为一种典型的流处理方式。虽然系统对于实时性的要求较高，但是相比于延迟较小的雾计算模式，采用云计算能够极大的缩减成本，而且对于心脏病患者来说，所有的心电图诊断分析过程都是透明的，因此本文认为将系统中的计算放在云端更合适。

## 第4章 动态心电图的智能降噪

### 4.1 引言

心脏病的主要诊断工具是心脏病患者的心电图，目前临床上使用的心电图主要是静态心电图，但是在上一章中提及的远程心电监控系统中，只能采集到患者的动态心电图。远程心电监控系统中心电图的采集方式克服了现有心电采集方式下的很多缺点，如高成本、缺乏及时的诊断、病情不可控等，但同时动态心电图相比静态心电图（见图 1.2）存在很大的差异，多种噪声可能同时存在于动态心电图中，而且噪声类型会随着外界环境的变化而改变。动态心电图中噪声的存在为疾病的自动诊断带来了极大的困扰，同时由于在远程心电监控系统中，噪声类型无法提前预知，这为现有的心电图降噪方法带来了挑战。

动态心电图属于信号数据的一种，但是企业实际应用中，发现传统的信号降噪方法并不能较好的滤除心电图中的噪声，致使临床诊断中动态心电图的自动诊断准确率一直停留在 60%左右。近年来，人工智能方法开始展现其异常强大的数据处理能力，同时动态心电图可以看作一种特殊的时间序列数据，而时间序列数据最大的一个特点是不同时刻数据间存在相互依赖关系。传统神经网络模型假设所有的输入和输出数据在时间上是独立的，这种假设在处理序列数据时是不恰当的。循环神经网络作为神经网络模型的一个发展，在每个神经元中增加了多个非线性变换，使得这种模型能够处理存在依赖关系的时间序列数据，如文本数据、信号数据、语音数据等。但是循环神经网络在处理长依赖关系的数据时，会出现梯度消失或者梯度爆炸问题，一旦出现这类问题，对于模型来说是致命的，直接结果是模型输出 NaN（不是一个数值）。而心电图恰恰属于具备长依赖关系的时间序列数据，最直观的一个体现是某一时刻的幅值和之前时刻的幅值存在依赖关系，为了处理长依赖关系的时间序列数据，长短期记忆网络<sup>[94]</sup>（LSTM）在 1997 年被提出。

### 4.2 多层 LSTM 降噪模型

心电图属于信号数据的一种，但可以将其视为一种特殊的时间序列数据，其不同时刻数据间存在依赖，甚至存在长依赖，这种依赖性主要体现在当前时刻的幅值受之前多个时刻的幅值的影响。而 LSTM 网络具有记忆功能，能够有效提取时间序列上特征，可以用于处理心电图数据间的依赖性。LSTM 模型能够自动提取特征，通过适当增加状态层有助于提取更丰富的特征和增强学习能力，模型

依赖学习到的知识自适应的调整权值，提升心电信号间的依赖性，同时降低与噪声信号间的相关性。基于此，本章提出了采用多层 LSTM 网络的动态心电图降噪方法（图 4.1）。

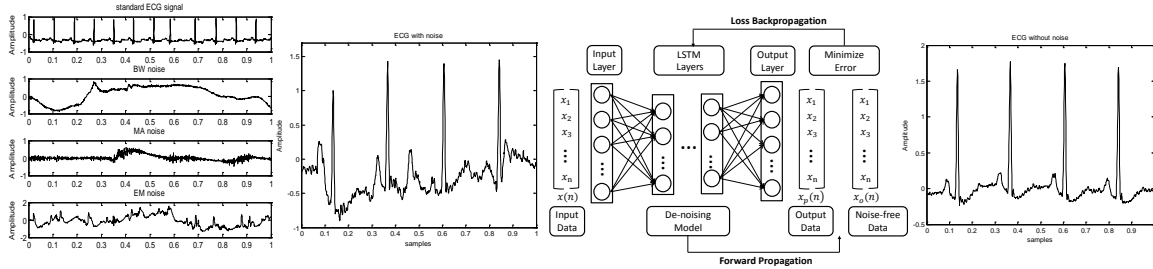


图 4.1 多层 LSTM 心电图降噪模型

多层 LSTM 降噪模型（图 4.1）的整体结构包括一个输入层、多个 LSTM 层、一个 TimeDistributed 层以及一个输出层。输入层输入的是带噪声的动态心电信号，其详细生成过程参见 4.2.1。LSTM 层是模型学习和预测的关键，每个 LSTM 层都包含一个循环结构用于处理动态心电图数据间的依赖性，其中心电信号间的依赖关系会被记忆在每个神经元中，而心电信号与噪声信号间的依赖关系会被舍弃。LSTM 模型的权值采用随机的方式进行初始化，通过前向计算逐层产生模型的预测结果，最终结果通过输出层输出。输出层的结果与对应的静态心电信号之间的误差会通过 Back-propagation through time(BPTT)算法反向传播到每个 LSTM 层，并使用 Adam 算法更新模型的权值直至算法收敛。

#### 4.2.1 数据预处理

动态心电图中可能同时存在多种类型的噪声，通过混合静态心电信号和各种噪声信号来模拟产生动态心电信号，产生方式如下：

$$x(n) = x_o(n) + a \cdot x_{bw\_noise}(n) + b \cdot x_{ma\_noise}(n) + c \cdot x_{em\_noise}(n) \quad (4.1)$$

上式中  $x(n)$  表示动态心电信号， $x_o(n)$  表示对应的静态心电信号，而  $x_{bw\_noise}(n)$ 、 $x_{ma\_noise}(n)$  及  $x_{em\_noise}(n)$  分别表示 BW 噪声、MA 噪声及 EM 噪声， $a$ ， $b$ ， $c$  作为比例因子控制各种噪声在心电信号中的比重，用于模拟多种噪声同时存在以及噪声类型发生改变等复杂应用背景。

实验数据来源于 MIT-BIH 数据集中的心律失常数据库和噪声数据库<sup>[95]</sup>。MIT-BIH 数据集中包含了 48 条半小时的心电信号，每个记录包括双通道心电信号记录：II 导联和 V1 导联。在本章实验中选取 II 导联数据作为样本，其中包含了 650000 个点，依次截取连续的 300 个点作为样本数据。在噪声数据集中包含了 3 条半小时的噪声信号，分别对应上述的三种噪声，为了使动态心电信号中的噪声尽可能具有随机性，随机选取连续的 300 个点作为噪声样本，由公式（1）模拟产生动态心电信号。

动态心电图中噪声类型会随着外界环境而改变，当噪声类型发生改变时，降噪模型仍然能够自动提取最有价值的特征对高质量的还原心电信号有着至关重要的作用。通过调整公式（1）中的比例因子  $a$ ,  $b$ ,  $c$ ，可将噪声混合类型分成七个类别（表 4.1）。

表 4.1 噪声混合类型划分

噪声类别	类别 1	类别 2	类别 3	类别 4	类别 5	类别 6	类别 7
噪声	BW	MA	EM	BW+MA	BW+EM	MA+EM	ALL

表 1 中 BW 表示模拟产生动态心电图时仅保留基线漂移噪声，将  $b$  和  $c$  设置为 0，依此类推，ALL 表示同时保留三种噪声。其中前三个类别对应仅考虑某种特定噪声的情形，后四个类别对应多种噪声同时存在的情形，根据混合噪声类别的不同可以模拟产生不同情况下的动态心电信号。

实验中将生成的  $x(n)$  作为降噪模型的输入，而将  $x_o(n)$  作为  $x(n)$  对应的降噪后信号用于模型的训练和验证。

### 4.2.2 降噪模型

为了处理心电信号在时间上的长依赖关系，本章采用多层 LSTM 模型对动态心电信号进行降噪。相比单层 LSTM 模型，多层 LSTM 模型有着更加复杂的结构，其结构图在图 4.2 中给出。

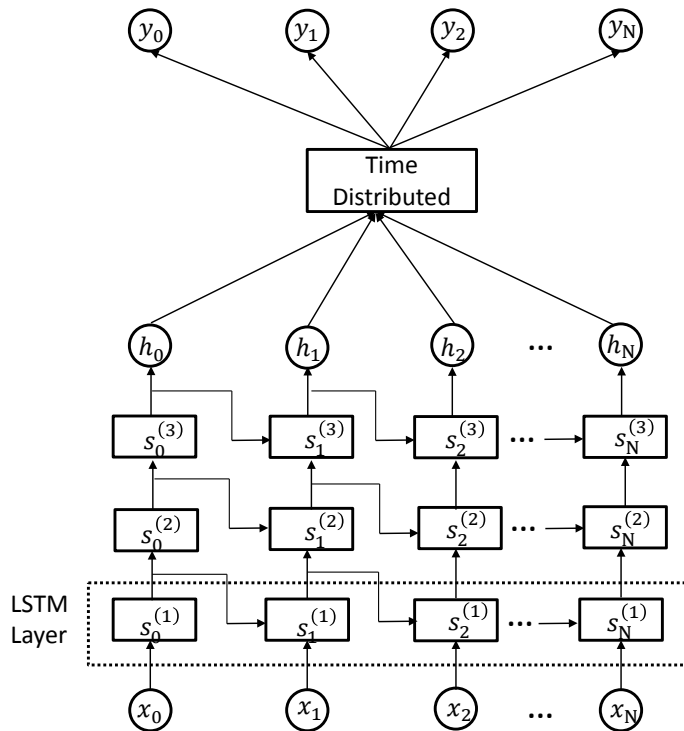


图 4.2 多层 LSTM 模型

通过在输入层和输出层之间引入多个 LSTM 层可以使模型的学习能力增

强，从而使动态心电信号在时间维度上的特性被不断提炼，最终能够在高层的记忆单元中准确地区分心电信号和噪声信号。

每个 LSTM 层中都是循环结构，这种循环结构可以处理动态心电信号数据间的依赖性，其中心电信号间的依赖关系会被记忆在每个神经元中，而心电信号与噪声信号间的依赖关系会被舍弃。单个 LSTM 层的结构见图 4.3。




图 4.3 单层 LSTM 结构图

由图 4.3 可知，单层 LSTM 中存在循环结构，每一时刻的状态单元均共享权重矩阵，这种特殊的神经元称为记忆单元，其中的  $s_{t-1}$ ， $s_t$  和  $s_{t+1}$  均表示一个记忆单元，它们之间共享权重矩阵  $U$ 、 $V$  及  $W$ ，将  $s_{t-1}$ ， $s_t$  和  $s_{t+1}$  进一步展开见图 4.4。记忆单元会先对前一时刻的状态和当前时刻的输入做 Sigmoid 变换，此时输入数据间的某些依赖会被舍弃，如心电信号和噪声信号之间的依赖。然后对前一时刻的状态和当前时刻的输入做 Sigmoid 变换计算当前时刻的输入对当前状态的贡献，其中当前状态通过对前一时刻的状态和当前时刻的输入做 tanh 变换得到，此时输入数据的某些依赖会被记忆，如心电信号数据间的依赖。最后通过前一时刻的状态、当前时刻的输入以及当前记忆得到神经元的输出。




图 4.4 LSTM 网络的记忆单元结构图

在前向计算过程中，在记忆单元中会具体的计算哪些依赖关系需要保存，哪些依赖关系又需要舍弃，这一过程可描述<sup>[94]</sup>如下：

$$f_t = S(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4.2)$$

$$C_t = f_t * C_{t-1} + S(W_i \cdot [h_{t-1}, x_t] + b_i) * \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4.3)$$

$$h_t = S(W_o \cdot [h_{t-1}, x_t] + b_o) * \tanh(C_t) \quad (4.4)$$

其中  $S$  函数和  $\tanh$  函数分别表示如下：

$$S(x) = \frac{1}{1 + e^{-x}} \quad (4.5)$$

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.6)$$

在公式 (4.2) 中通过权重矩阵  $W_f$  和偏置  $b_f$  计算得到一个值为 0 和 1 之间的比例因子  $f_t$ ， $f_t$  将作用于前一时刻状态  $C_{t-1}$  决定需要遗忘哪些记忆，进而在公式 (4.3) 中舍弃与噪声信号间的依赖关系，此外，权重矩阵  $W_i$ 、 $W_c$  以及偏置  $b_i$ 、 $b_c$  被用于计算当前时刻输入对当前神经元状态的贡献，通过结合这两项得到需要记忆的依赖关系  $C_t$ ，最终通过权重矩阵  $W_o$  及偏置  $b_o$  得到当前神经元的输出  $h_t$ 。当前神经元的输出会同时作为下一层的输入和下一时刻的输入，作为下一层的输入表示当前神经元的输出会被下一个 LSTM 层进一步提炼，而作为下一时刻的输入表示当前记忆会被传递。

在模型训练时，本节采用 (4.7) 式作为损失函数。

$$\min J(U, V, W) = \min \left( \sum_{n=1}^N (x_p(n) - x_o(n))^2 \right) + \lambda \left( \sum_{i,n} U_{i,n}^2 + \sum_{i,n} V_{i,n}^2 + \sum_{i,n} W_{i,n}^2 \right) \quad (4.7)$$

公式 (4.7) 由两部分组成，第一部分用于计算模型降噪结果与对应的静态心电信号之间的差别，第二部分表示惩罚项，防止模型过拟合。模型的训练过程旨在最小化损失函数，为此需要将梯度逐层向后传播，直至模型的第一个 LSTM 层。由于在每个 LSTM 层中设置了循环结构，因此无法直接使用梯度下降算法来优化权值，取而代之的是使用 BPTT 算法计算梯度，并使用 Adam 算法来优化最小化损失函数。

本节使用六层 LSTM 网络对心电图降噪，其整体结构包括一个输入层、三个 LSTM 层、一个 TimeDistributed 层及一个输出层，算法的整体流程在 Algorithm 4.1 中给出。

---

#### 算法 4.1: Six-Layer LSTM De-noise Algorithm

---

**Input:** The input signal  $\{x(n)\}_{i=1}^{Samples}$  and output signal  $\{x_o(n)\}_{i=1}^{Samples}$ ;

**Output:** The de-noised signal  $\{x_p(n)\}_{i=1}^{Samples}$ ;

1: Randomly initialize all the weights and bias;

2: **For** each iteration **do**:

3: Forward computing for first LSTM layer as:

4:  $h_t^{(1)} = \tanh(U^{(1)}x_t + W^{(1)}h_{t-1}^{(1)});$

5: Forward computing for second LSTM layer as:

6:  $h_t^{(2)} = \tanh(U^{(2)}h_t^{(1)} + W^{(2)}h_{t-1}^{(2)});$

7: Forward computing for last LSTM layer as:

8:  $h_t^{(3)} = \tanh(U^{(3)}h_t^{(2)} + W^{(3)}h_{t-1}^{(3)});$

9: Forward computing for output layer as:

---



---

```

10:       $o_t = \text{linear}(Vh_t^{(3)});$ 
11:  Calculate gradients for last LSTM layer through BPTT as:
12:      
$$\frac{\partial J}{\partial V} = \sum_{t=1}^T \left( \frac{\partial J_t}{\partial o_t} \cdot \frac{\partial o_t}{\partial (Vh_t^{(3)})} \cdot \frac{\partial (Vh_t^{(3)})}{\partial V} \right)$$

13:      
$$\frac{\partial J}{\partial U^{(3)}} = \sum_{t=1}^T \sum_{k=1}^t \frac{\partial h_k^{(3)}}{\partial U^{(3)}} \left( \prod_{i=k+1}^t U^{(3)^T} = \text{diag}[\tanh'(h_{i-1}^{(3)})] \right) \frac{\partial o_t}{\partial h_t^{(3)}} \cdot \frac{\partial (J_t)}{\partial o_t}$$

14:      
$$\frac{\partial J}{\partial W^{(3)}} = \sum_{t=1}^T \sum_{k=1}^t \frac{\partial h_k^{(3)}}{\partial W^{(3)}} \left( \prod_{i=k+1}^t U^{(3)^T} \text{diag}[\tanh'(h_{i-1}^{(3)})] \right) \frac{\partial o_t}{\partial h_t^{(3)}} \cdot \frac{\partial (J_t)}{\partial o_t}$$

15:  Update weights for last LSTM layer through Adam as:
16:      
$$W_t^{(3)} := W_{t-1}^{(3)} - \alpha \cdot \frac{\beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot \frac{\partial J}{\partial W^{(3)}}}{1 - \beta_1^t} \cdot \frac{\beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot \left( \frac{\partial J}{\partial W^{(3)}} \right)^2}{1 - \beta_2^t} + \varepsilon$$

17:      The same with  $V$  and  $U^{(3)}$ ;
18:  Update weights for remaining LSTM layer in the same way;
19: end for
20: Save model in h5;
21: /** Use the same model to de-noise for different category of noise. **/
22: For each category of noise do:
23:   Get dynamic ECG with the current category of noise;
24:   Denoising the dynamic ECG with model;
25: end for

```

---

## 4.3 实验和评价

在上一节中给出了降噪模型的整体结构、算法流程以及数据源。其中降噪模型的整体结构由两部分组成，第一部分是数据生成，第二部分是多层 LSTM 降噪网络，在数据生成过程中，通过数据融合的方式将静态心电图和噪声信号融合产生动态心电图，并将动态心电图作为多层 LSTM 降噪网络的输入，将动态心电图对应的静态心电图作为多层 LSTM 降噪网络的输出，根据 BPTT 算法的流程不断调整心电信号和噪声信号的权值来最小化损失函数。而且采用的数据源是真实的心电图数据，MIT-BIH 取自波士顿 Beth Israel 医院（现在的 Beth Israel Deaconess 医疗中心）和麻省理工学院的实验室的合作课题，这个课题旨在心律失常分析和相关课题的研究，这个数据集包含 48 个 30 分钟长的双通道心电图记录片段，采自于心脏病患者。因此，在这一节将验证降噪模型及算法在真实心电图数据上的有效性。

### 4.3.1 评价指标

评价降噪能力常用的指标包括根均方误差(RMSE)和信噪比(SNR)，其中 RMSE 是指模型预测值与真实值的相似程度，值越小表示模型的预测值越靠近

真实值，SNR 用于衡量信号中噪声大小，信噪比越高表示信号质量越好。分别定义如下：

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} [x_p(n) - x_o(n)]^2} \quad (4.8)$$

$$SNR = 10 \log \frac{\sum_{n=0}^{N-1} [x_o(n)]^2}{\sum_{n=0}^{N-1} [x_{noise}(n)]^2} \quad (4.9)$$

### 4.3.2 实验结果

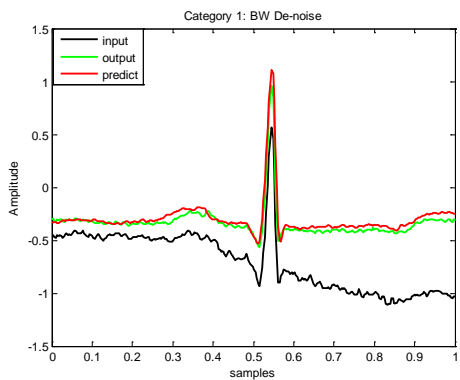
本章所提出的降噪模型在不同类别噪声下的 RMSE 和 SNR 情况见表 4.2.

表 4.2 不同噪声类别下的 RMSE 和 SNR

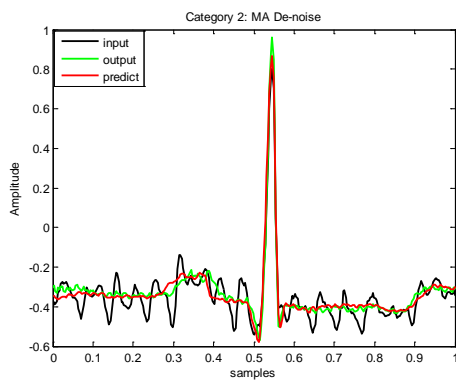
噪声类别	类别 1	类别 2	类别 3	类别 4	类别 5	类别 6	类别 7
RMSE	0.025	0.039	0.028	0.034	0.035	0.031	0.037
D-ECG SNR	-2.703	35.327	-7.427	-3.466	-17.845	-7.857	-18.121
R-ECG SNR	37.098	49.919	45.601	39.323	37.214	43.090	37.021
I-ECG SNR	39.801	14.592	53.028	42.789	55.059	50.947	55.142

由表 4.2 可知模型在类别 1~类别 7 下的 RMSE 在均 0.03 左右，这说明本章提出的降噪模型对噪声是不敏感的，不需要重新调整参数或者重新训练模型即可适用到不同类别噪声的降噪中。这一特点非常适合用于处理噪声类型无法提前确定的动态心电图，反观传统降噪方法却不具备这一特性，只能应用于某一特定类型噪声的降噪中。特别值得一提的是，降噪模型在多种噪声同时存在时，仍然能取得较小的 RMSE，而这一点又是传统降噪方法不曾具备的。

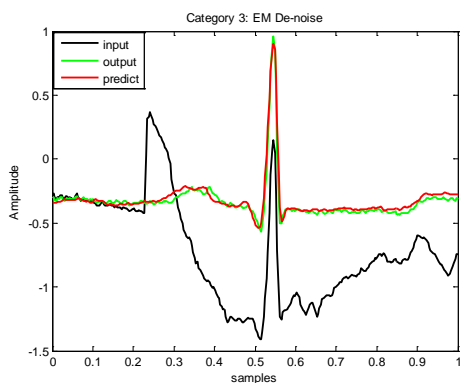
同时，表 4.2 的后三行反映了降噪模型在 SNR 上的实验结果，其中 D-ECG SNR 表示降噪前动态心电图的信噪比，R-ECG SNR 表示降噪模型从动态心电图中恢复出的静态心电图的信噪比，而最后一行 I-ECG SNR 表示模型在信噪比上取得的提升。降噪后心电信号的 SNR 在类别 1~类别 7 下也同样表现稳定，这也进一步说明了降噪模型对于噪声是不敏感的。从这一行的实验结果还可以看出降噪前的信噪比越低，模型能够取得的信噪比提升就越高。而且在类别 7 下，由于动态心电信号中同时包含了三种类型的噪声，使得信号降噪前的信噪比低至-18.121，经降噪后 SNR 提升高达 55db，这远远高于现有降噪方法。模型在七个类别下的具体降噪结果如图 4.5 所示。



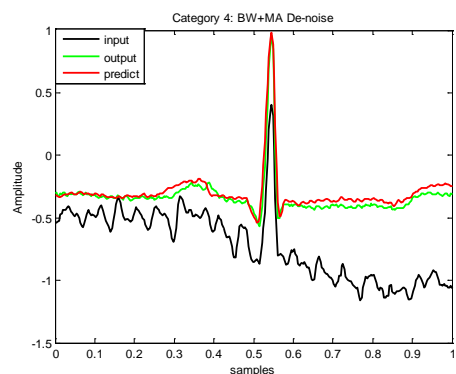
(a)



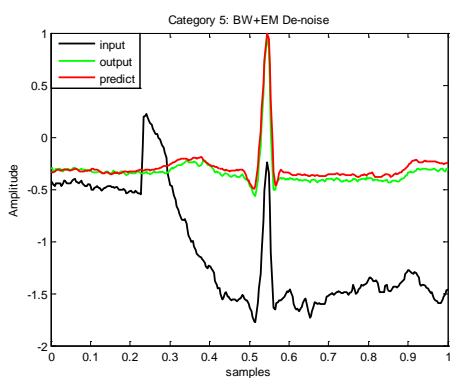
(b)



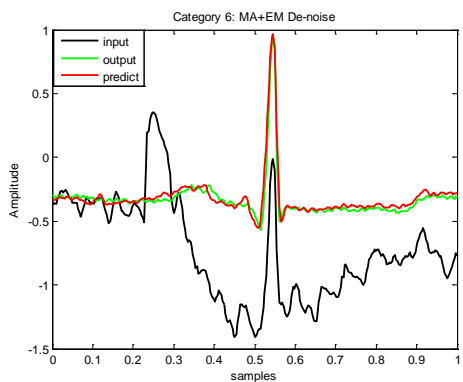
(c)



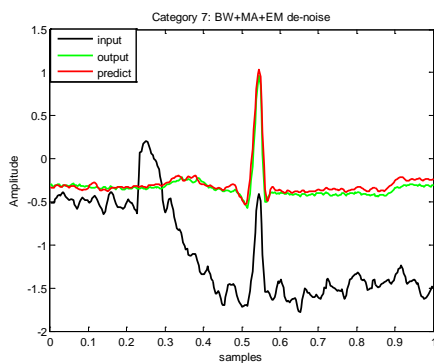
(d)



(e)



(f)



(g)

图 4.5 类别 1~类别 7 的实验结果

图 4.5(a)~(g)分别对应七个类别的噪声的降噪结果，图中黑色实线表示动态心电信号，绿色实线表示对应的无噪声信号，红色实线表示模型的降噪结果。可以看出降噪模型的预测结果和真实信号虽然在某些局部有细微的偏差，但是保留了静态心电信号的主要特征，与此形成鲜明对比的是，动态心电信号和原始心电信号存在很大差异。这说明模型依然可以从发生了较大形变的心电信号中高质量的还原心电信号。当噪声类型发生改变，或者多种噪声同时存在时，算法性能基本没有下降，这主要由于 LSTM 模型的记忆单元中保留了心电信号之间的依赖关系，并且舍弃了心电信号和噪声信号间的依赖关系，经过多个 LSTM 层不断提炼这种依赖关系，增强了模型高质量还原心电信号的能力。

#### 4.4 对比分析

本节选取了 S 变换<sup>[96]</sup>、改进阈值的小波变换<sup>[97]</sup>、BP 神经网络<sup>[98]</sup>以及自编码器<sup>[99]</sup>这四种方法，由于这些方法都仅仅考虑了存在某种特定噪声的情形，因此本节对比了算法在前三个噪声类别下的 RMSE 及信噪比的提升。在图 4.6 中给出了五种降噪算法取得的 RMSE。

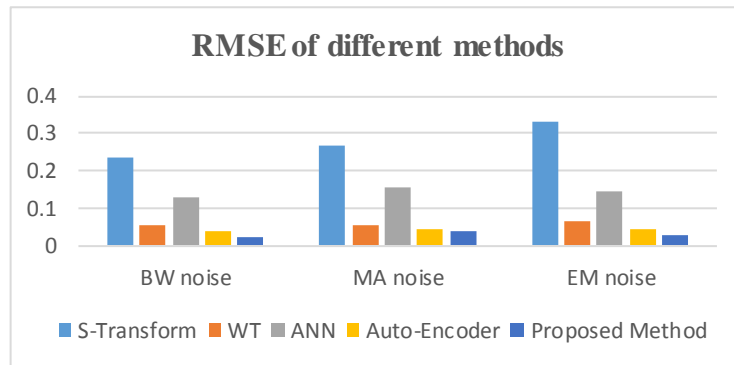


图 4.6 RMSE 结果对比

图 4.6 中的对比了五种降噪方法在 BW、MA 和 EM 这三类噪声下的 RMSE。S 变换将信号转换到时频域，然后借助滤波等方式滤除噪声，人为的特征提取过程和对阈值的依赖使得其 RMSE 较大，在 0.25 和 0.35 之间波动。改进阈值的小波变换在阈值选取上做了较大优化，并且对信号做了 5 层分解，这使得其 RMSE 能够维持在 0.06 左右。BP 神经网络和自编码器均可以自动提取特征，当噪声类型发生改变后，自编码器依靠重新训练模型取得了较小的 RMSE，在 0.03 和 0.04 之间波动，而 BP 神经网络由于结构相对简单，其 RMSE 维持在 0.15 左右。本章提出的多层 LSTM 降噪模型不依赖阈值和清晰的特征波，将心电信号和噪声信号一起作为序列数据的一部分，通过记忆单元保留心电信号间的依赖关系，同时舍弃心电信号和噪声信号间的依赖关系，并且这种

依赖关系会在多个 LSTM 层中不断被提炼，这使得本章提出的模型能够直接应用到不同类型噪声的降噪实验中，当噪声类型发生改变或者同时包含多种噪声时，在不重新调整阈值或重新训练模型的前提下均可以取得 0.03 左右的 RMSE。

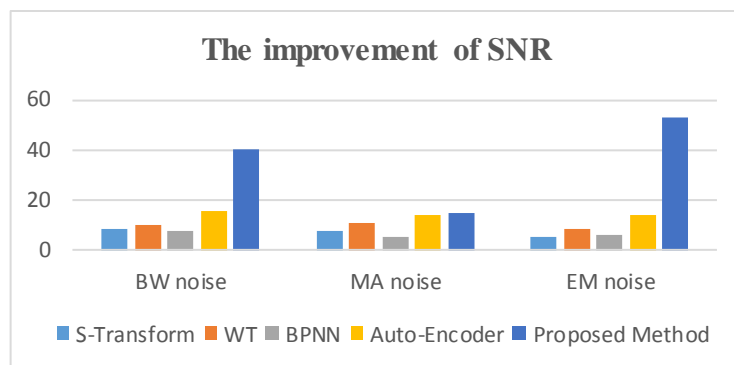


图 4.7 SNR 提升结果对比

在图 4.7 中给出了五种方法在 BW、MA 和 EM 这三类噪声下取得的信噪比提升。S 变换、改进阈值的小波变换、BP 神经网络以及自编码器这些方法均应用在噪声扰动较小的情形，当动态心电信号的信噪比在 0db 和 5db 之间时，能够取得的信噪比提升均在 10db 左右。而本章提出的多层 LSTM 降噪模型能够适用于信噪比更低的情形，且动态心电信号的信噪比越低，模型能够取得的信噪比提升越大，在类别 3 下模型取得的信噪比提升高达 53db，这远远高于现有的降噪方法。这同时也说明每个神经元中确实记忆了心电信号间的依赖关系，且舍弃了心电信号与噪声信号间的依赖关系，因此模型的预测结果中心电信号占了很大比重，而噪声信号在多个 LSTM 层中被不断压缩，随着噪声信号的较少，信号的信噪比得到了很大提升。

实验结果表明本章提出的多层 LSTM 降噪模型在主要指标上要优于现有的降噪方法，尤其是在信噪比的提升上。这可能是因为在信噪比的提升上。这可能是因为现有降噪方法存在如下限制：

- (1) 依赖准确的特征值，当心电信号结构变得复杂之后，很难找出准确的阈值区分噪声信号和心电信号。
- (2) 依赖清晰的波形，当波形变得杂乱之后，无法提取到有用的特征。
- (3) 当噪声类型发生改变之后，需要重新调整算法。

然而，在物联网结构的远程心脏监控方式下，心电信号可能会同时包含多种类型的噪声，而且无法预知信号中的噪声类型。但是现有的降噪方法大部分都仅针对某一特定类型噪声，当噪声类型改变后，需要重新调整阈值。本章所提出的模型通过多个 LSTM 层提取心电图的深层次特征，自适应的调整权值，避免了阈值的选取，同时将心电信号和噪声信号一起作为序列数据的一部分，通过记忆

单元保留心电信号间的依赖，舍弃心电信号和噪声信号间的依赖，摆脱了对波形的依赖。实验表明所提出的模型能够直接应用到多种类型的心电信号的降噪中，在不同类型下均取得了较小的均方根误差和较大的信噪比提升。

## 4.5 小结

本章基于深度学习模型提出了一种新的心电图降噪方法，这种方法将动态心电图看作数据间存在强依赖关系的时间序列数据，利用 LSTM 网络的记忆单元保留心电信号间的依赖关系，同时抛弃心电信号与噪声信号间的依赖关系，通过多个 LSTM 层提取信号的深层次特征，高质量的还原心电信号。基于这些特性，这一章中所提出的降噪方法不依赖于特征值的选取和清晰的波形，并且当心电图中噪声类型发生改变时，不需要重新调整算法，更不需要重新训练模型，可以直接应用到不同噪声环境中，除此之外，本章中所提出的降噪模型能够直接推广到多种噪声同时存在时的情形。

## 第5章 动态心电图的心律失常检测分类

### 5.1 引言

心律失常是种非常常见的疾病，产生于心脏电信号的产生和传导问题，进而导致心跳出现过快、过慢或无规律现象，严重时会造成猝死。根据产生原因的不同，心率失常引起的心跳节拍种类繁多，常见的心律失常心跳节拍有：房性早搏、室性早搏、起搏心跳、左束支传导阻滞、右束支传导阻滞、室扑、室性逸搏。目前，心律失常的分类检测主要依靠专业医师对心电图的判读经验，但是在远程心电监控系统中，为了提供工作效率并在较短时间内将心电图诊断分析结果反馈给心脏病患者，心电图的自动分析和人工分析相结合成为了一种发展趋势，自动分析可以不经心电专家判读，患者在较短时间内即可得到系统自动分析的诊断结果，而人工分析主要依靠心电专家复核心电图自动分析结果，确保事件诊断结果准确性。近年来关于心律失常自动检测分类的研究很多，但是 58.7% 的分类准确率极大的限制了心律失常自动检测分类算法在临床上的应用。

由于噪声的干扰，心电图中的特征点被噪音淹没，进而导致现有心电图算法无法辨别是噪音还是心电图特征波形，为了提高心律失常自动检测分类算法的准确率，本文将心律失常检测分类分两步走，先将心电图中的噪声滤除，然后在此基础上对降噪后的心电图做自动心律失常检测分类。在上一章中，通过借助多层 LSTM 降噪模型，取得了较小的 RMSE 和较大的信噪比提升，从动态心电图中恢复出了较高质量的静态心电图。因此，在这一章中，将以上一章中的多层 LSTM 模型的输出信号为实验数据，以卷积神经网络（CNN）为分类模型，对以上七类心律失常心跳节拍和正常心跳节拍做八分类。

### 5.2 1-D CNN 分类模型

心律失常自动检测分类的基本数据对象通常有两种，分别是以心跳节拍为基本对象和以 ECG 片段为基本对象，其中如果以心跳节拍为基本数据对象，需要首先从连续的 ECG 中提取出一个个心跳节拍，而提取心跳 Beat 通常需要精确的 R 波峰值，无论是提取心跳 Beat 还是找到准确的 R 波峰值对于波形结构完全被破坏的动态心电图而言，都是极具挑战的工作。如果以 ECG 片段为基本数据对象，则只需要每隔 2s 或者 5s 截取一段连续的 ECG 信号即可，虽然在提取基本数据上有了极大的简化，但是由此引起的一个问题是心跳 Beat 在不同段之间的分布极不均匀，有极大的可能出现一个信号段中一个心跳 Beat 都没有，而有的

信号段中出现多个心跳 Beat。这两种提取基本数据对象的方法见图 5.1。




图 5.1 提取心跳 Beat 和 ECG 段

从图 5.1 中可以看出，以心跳 Beat 为基本数据单位时，需要首先获取到心电图中的 R 波峰值，然后以 R 波峰值为中心，分别在左、右两个方向上截取部分 ECG 信号段，以此构成一个心跳 Beat。而以 ECG 段为基本数据单位时，总是在连续 ECG 信号上等间隔截取 ECG 信号段，每一段 ECG 信号作为一个基本数据对象。虽然提取心跳 Beat 的过程比较复杂，但是若能够提取到相对比较准确的心跳 Beat，对于卷积神经网络模型的训练来说无疑是巨大的帮助，反观提取 ECG 信号段的方法，虽然提取过程简单，但是标签的选取和数据的筛选需要复杂的手工过程。因此，在本章中，通过提取心跳 Beat 作为基本数据对象，构建如图 5.2 所示的 1-D CNN 分类模型。

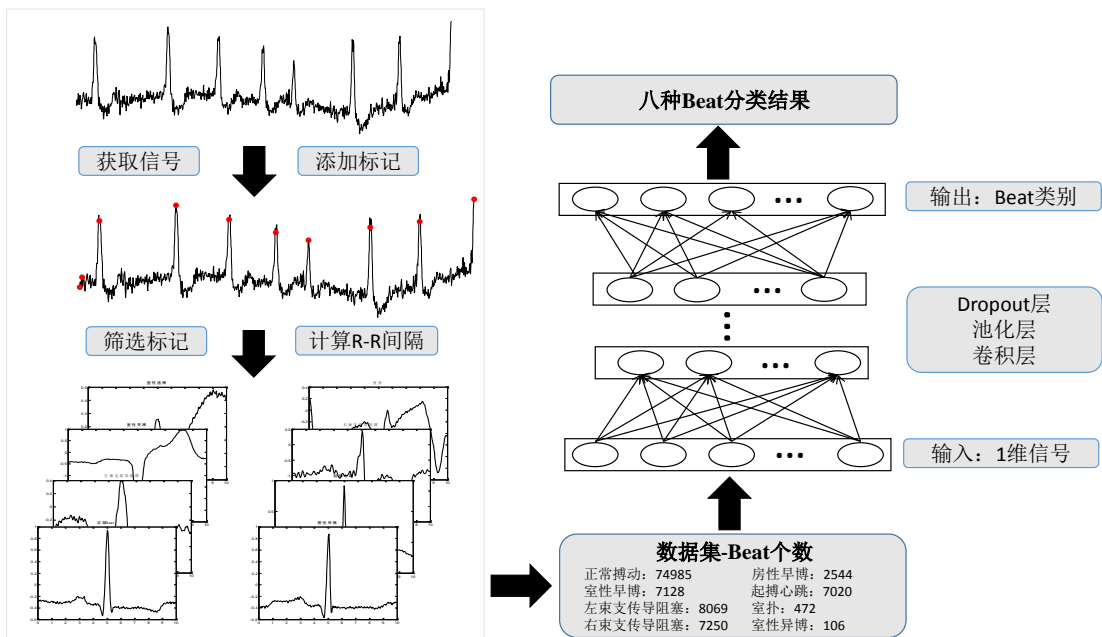


图 5.2 1-D CNN 心跳 Beat 分类模型

在图 5.2 所示的 1-D CNN 心跳 Beat 分类模型中的 1-D 主要指输入数据的维度，由于心跳 Beat 图像中只包含较少的有用信息，因此在这里使用的是心跳



Beat 的信号数据，1 维的信号数据决定了整个 CNN 模型是 1 维的。而整个心跳 Beat 分类模型主要由两部分组成，其中第一部分是数据预处理，数据预处理旨在从连续的 ECG 信号中提取出不同的心跳 Beat，详细的提取心跳 Beat 的过程将在 5.2.1 节中叙述。第二部分是多层 CNN 分类模型，CNN 分类器的输入是 1 维的心跳 Beat 信号数据，经过多个卷积层、池化层以及 Dropout 层后，通过 Flatten 函数将多维的输入一维化，最后通过一个三层全连接神经网络得到模型分类的结果，由于 CNN 模型最终需要对心跳 Beat 进行八分类，因此采用 softmax 作为分类结果的激活函数，其他层采用 Relu 作为激活函数。借助 Adam 优化器和 Back-Propagation 算法更新 CNN 分类模型的权值，以最小化多分类交叉熵函数为目标，迭代至算法收敛。

### 5.2.1 数据预处理

如前所述，心律失常自动检测分类的基本数据对象有两种，分别是以心跳 Beat 为基本对象和以 ECG 片段为基本对象，而在本节实验中采用的是心跳 Beat 作为检测分类对象。为了从连续的 ECG 信号中提取出完整的心跳 Beat，对于 R 波峰值的标记是非常重要的步骤，庆幸的是 MIT-BIH 数据集中已经包含了专业医师对心电图的标记。在上一章中已经对 MIT-BIH 数据集进行了描述，这个数据集中包含了 48 条数据记录，每条记录包含了  $2 \times 650000$  个数据点，共记录了二导联的心电图信息。MIT-BIH 数据集中的标记共有 23 类，其符号表示分别为：N A V ~ | Q / f + x F j L a J R [ ! ] E S “ e，共 23 个字符表示 23 类标记信息，每一类标记的具体含义见表 5.1。

表 5.1 MIT-BIH 数据集标记说明

标记	N	A	V	~		e	]
含义	正常搏动	房性早搏	室性早搏	信号质量改变	孤立 QRS 波群	房性逸搏	房颤结束标记
标记	/	f	+	x	F	j	E
含义	起搏心跳	混合心跳	心率改变	APB	心室融合心跳	交界性逸搏	室性逸搏
标记	L	a	J	R	[	!	S
含义	左束支传导阻滞	异常房性早搏	交界性早搏	右束支传导阻滞	房颤开始标记	室扑	室上性早搏

另外两种标记，“表示注释，而 Q 表示未分类 Beat。理清不同的标记类型对于提取准确的心跳 Beat 来说至关重要，这主要体现在 R-R 间隔的计算上，R-R

间隔指的是连续 ECG 信号中两个连续的 R 波峰值之间的距离。如果不区别对待每一种标记，而是将所有的标记都作为 R 波峰值的标记，那么一个很严重的问题是有些 R-R 间隔很小，而有些 R-R 间隔很大，这对于平均 R-R 间隔的计算是极其不利的，不仅需要人为的剔除不在合理范围内的 R-R 间隔，最终计算得到的平均 R-R 间隔也是不准确的。此时的算法流程见算法 5.1。

---

#### 算法 5.1: 心跳 Beat 提取算法

---

```

输入: 连续 ECG 信号;
输出: 心跳 Beat
1: 定义所有 48 条记录的集合 arr;
2: 对于集合 arr 中的每一条记录:
3:   载入连续 ECG 数据, 存入 signal 集合:
4:     load('ECG_path');
5:   载入这条记录的标记数据, 存入 peaks 集合:
6:     load('label_path');
7:   在集合 peaks 中找到所有标记为 N 的标记:
8:     Npeaks = peaks(find(label == 1));
9:   计算 R-R 间隔:
10:    rr_interval(j) = Npeaks(j+1) - Npeaks(j);
11:  筛选 R-R 间隔:
12:    剔除 R-R 间隔过大或者过小的数据;
13:  计算平均 R-R 间隔: avg;
14:  预定义八个空集合, 用于保存不同类型的心跳 Beat;
15:  对于 peaks 集合中的每个标记:
16:    IF label==1:
17:      获取 signal(peaks(j) - avg / 2 : peaks(j) + avg / 2), 作为 Beat;
18:    IF label==2:
19:      获取 signal(peaks(j) - avg / 2 : peaks(j) + avg / 2), 作为 Beat;
20:    ...
21:    IF label==8:
22:      获取 signal(peaks(j) - avg / 2 : peaks(j) + avg / 2), 作为 Beat;
23:  保存不同类型的心跳 Beat 为 MAT 文件;

```

---

采用算法 5.1 的流程获取心跳 Beat 主要由三个方面的缺陷:

(1) 需要人为的剔除不合理的 R-R 间隔, 这一过程既繁琐还容易出错, 而且对于大量数据而言, 几乎是一项无法完成的工作;

(2) 平均 R-R 间隔不准确, 由于在计算 R-R 间隔的时候没有区别对待每一种类型的标记, 将所有的标记均作为 R 波峰值标记处理, 但是每条记录中均包含其它类型的标记, 由此计算出的 R-R 间隔肯定是不准确的;

(3) 由于不同的记录采用了不同的 R-R 间隔, 那么从每条记录中提取出的心跳 Beat 不是等长的, 不同记录间的心跳 Beat 对比见图 5.3。




图 5.3 不等长的心跳 Beat

在心律失常检测中，需要将心跳 Beat 作为 1-D CNN 分类模型的输入，如果心跳 Beat 的长度不相等，对于分类器来说是个没必要的麻烦，因此在数据进入分类器之前还需要将所有的心跳 Beat 重新插值到等长度，首先获取到所有记录中心跳 Beat 的最大长度，然后采用三次采样差值得到每个 Beat 需要插入的数据点，再根据时间上的先后顺序从前往后合并原始 Beat 与插值数据点，由此可以得到等长的心跳 Beat，三次采样插值后的心跳 Beat 见图 5.4。




图 5.4 三次采样插值后的心跳 Beat

通过三次采样插值，虽然可以将所有的心跳 Beat 插值到相同长度，但是图 5.3 同时也反映出了另一个问题，心跳 Beat 中的 R 波峰值在时间顺序上后移了一段距离，而波形的出现时间和心脏疾病是紧密相关的，这可能导致原本正常的心跳 Beat 在 R 波后移之后变成了异常心跳 Beat，造成 R 波后移的主要原因是插值点总是从左往右选取，因此总是尽可能的在 Beat 的左边部分完成插值，由此

导致了 R 波的后移。为了解决这个问题，虽然可以通过在 R 波峰值左右两侧均匀的插值到所有心跳 Beat 等长，但是其他波形的问题又会出现。

在算法 5.1 的基础上，只需要稍作改进即可避免上述的所有问题，而且可以避免插值的出现，改进后的心跳 Beat 提取过程见算法 5.2。

---

### 算法 5.2: 改进的心跳 Beat 提取算法

---

```

输入: 连续 ECG 信号;
输出: 八类心跳 Beat;
1: 定义所有 48 条记录的集合 arr;
2: 载入所有的标记数据, 存入 peaks 集合:
3:     load('label_path');
4: 找到所有标记为 N 的标记:
5:     Npeaks = peaks(find(label == 1));
6: 计算 R-R 间隔:
7:     rr_interval(j) = Npeaks(j+1) - Npeaks(j);
8: 剔除不合理 R-R 间隔:
9:     rr_interval(find(rr_interval > BASIC+100)) = [];
10: 计算平均 R-R 间隔的一半: len;
11: 对于集合 arr 中的每一条记录:
12:   载入连续 ECG 数据, 存入 signal 集合:
13:     load('ECG_path');
14:   载入这条记录的标记数据, 存入 peaks 集合:
15:     load('label_path');
16:   预定义空集合: Nbeats=[], Abeats=[], Vbeats=[], Pbeats=[], Lbeats=[],
           Rbeats=[], Wbeats=[], Ebeats=[];存放不同类型的 Beats;
17:   对于 peaks 集合中的每个标记:
18:     IF label==1:
19:       Nbeats(end+1, :) = signal(peaks(j) - len : peaks(j) + len);
20:     IF label==2:
21:       Abeats(end+1, :) = signal(peaks(j) - len : peaks(j) + len);
22:     ...
23:     IF label==8:
24:       Ebeats(end+1, :) = signal(peaks(j) - len : peaks(j) + len);
25:   保存不同类型的心跳 Beat 为 MAT 文件;

```

---

算法 5.2 只在算法 5.1 的基础上做了细微的修改，为了避免心跳 Beat 不等长引起的插值等问题，在算法 5.2 中将 R-R 间隔的计算拿到循环外面，相当于将平均 R-R 间隔上升到全局变量的高度，所有的心跳 Beat 全部使用这一平均 R-R 间隔作为提取 Beat 的标准。同时在算法 5.2 中为了避免人为的剔除不合理的 R-R 间隔，定义了一个常量 BASIC 作为剔除不合理 R-R 间隔的依据，对于 R-R 间隔远超过 BASIC 的以及远低于 BASIC 的将会直接删除。

在心律失常检测中，本文主要针对最常见的七类异常 Beat，加上正常 Beat 分别是正常起搏 (N)、房性早搏 (A)、室性早搏 (V)、起搏心跳 (/)、左

束支传导阻滞（L）、右束支传导阻滞（R）、室扑（!）、室性逸搏（E）。执行算法 5.2 之后，得到的所有心跳 Beat 的长度均为 289，每种类型的心跳 Beat 的各数汇总见表 5.2。

表 5.2 八类心跳 Beat 数

标记	含义	Beat 数
N	正常搏动	74985
A	房性早搏	2544
V	室性早搏	7128
/	起搏心跳	7020
L	左束支传导阻滞	8069
R	右束支传导阻滞	7250
!	室扑	472
E	室性逸搏	106

在表 5.2 中给出了每类心跳 Beat 数量，所有的心跳 Beat 一共有 107574 个。此时经过算法 5.2 提取出的每类心跳 Beat 见图 5.5。




图 5.5 八类心跳 Beat

### 5.2.2 多层 CNN 分类模型

经过数据预处理后，从连续的 ECG 信号中提取出了不同类型的心跳 Beat，共提取了八类心跳 Beat 构成 1-D CNN 模型的数据集。CNN 模型由 LeCun 等人在 1989 年首次提出，并在近十年获得了巨大的发展，现已被广泛应用于计算机视觉、自然语言处理、无人驾驶、智能家居、智慧城市等领域和行业，CNN 模型主要由卷积层和全连接层构成，其中卷积层可以使用少量参数实现某一类数据特征的提取，但卷积层的计算耗时非常大，因为卷积操作需要遍历上一层输出的所有特征图。其中全连接层需要将卷积层提取的多类特征组合在一起，构成典型

的 BP 神经网络，与卷积层相比，全连接层计算用时少，但参数数量十分庞大。

目前，CNN 模型主要应用于图片数据（如大型可视化数据库 ImageNet），因此通常使用的都是 2-D CNN 模型，即处理的数据、卷积核以及池化层都是二维矩阵，由此会引起计算量的增加，如表 5.3 中几种主流 CNN 模型在 ImageNet 上的实验结果和训练时长对比。

表 5.3 几种主流 DNN 模型对比

年份	DNN 模型	网络层数	Top-5 误差 (ImageNet)	参数数量	硬件平台	训练时间
					GTX-530	
2012	AlexNet	8	16.4%	61M	3GB GPU*2	5-6 天
2014	VGG-16	19	7.3%	138M	GTX1060	3-4 小时
2015	GoogLeNet	22	6.7%	7M	Tesla K80 GPU*8	2 天
2016	ResNet	156	3.57%	26M	NVIDIA M40 GPU	14 天

随着 CNN 层数的增加，需要训练的参数也随着增加，CNN 模型的推理时间也大幅度增加，但是在物联网环境中，计算资源、存储资源和电力资源等硬件资源往往受到严格限制<sup>[100]</sup>，考虑到 ECG 属于信号数据的一种，对比二维图片数据，一维信号数据对计算力的需求相对较小，因此，1-D CNN 模型在本章被应用于动态心电图的心律失常检测中，模型结构见表 5.4。

表 5.4 1-D CNN 心律失常检测模型

	Layer (类型)	输出张量	参数量	核尺寸
Layer 1	Conv2D	(None, 1, 289, 64)	256	1x3
Layer 2	Conv2D	(None, 1, 287, 64)	12352	1x3
Layer 3	MaxPooling2	(None, 1, 143, 64)	0	1x2
Layer 4	Dropout	(None, 1, 143, 64)	0	0.25
Layer 5	Conv2D	(None, 1, 143, 128)	24704	1x3
Layer 6	Conv2D	(None, 1, 141, 128)	49280	1x3
Layer 7	MaxPooling2	(None, 1, 70, 128)	0	1x2
Layer 8	Dropout	(None, 1, 70, 128)	0	0.25
Layer 9	Conv2D	(None, 1, 70, 256)	98560	1x3

Layer 10	Conv2D	(None, 1, 68, 256)	196864	1x3
Layer 11	MaxPooling2	(None, 1, 34, 256)	0	1x2
Layer 12	Dropout	(None, 1, 34, 256)	0	0.5
Layer 13	Flatten	(None, 8704)	0	
Layer 14	Dense	(None, 10000)	87050000	
Layer 15	Dropout	(None, 10000)	0	0.5
Layer 16	Dense	(None, 8)	80008	

在表 5.3 所示的 1-D CNN 模型中，总参数量为 87512024，其中大部分参数来自最后的两个全连接层，模型的主要部分介绍如下：

(1) 初始化；CNN 模型是基于梯度下降的学习方法，其主要缺陷是模型可能会发散或陷入局部极小点。因此，模型权值的初始化对于训练过程来说非常重要。在 CNN 中，权值主要包括卷积核中的参数和全连接层中的参数。Xavier 初始化方法在 2010 年提出，在以下范围内随机初始化权重：

$$\left[ -\sqrt{\frac{6}{n^k + n^{k+1}}}, \sqrt{\frac{6}{n^k + n^{k+1}}} \right] \quad (5.1)$$

其中  $n^k$  和  $n^{k+1}$  分别指输入和输出的神经元个数，通过 Xavier 初始化方法可使每一层输出的方差尽可能相等，保障神经网络中信息更好的流动。

(2) 卷积核；与全连接的人工神经网络不同，CNN 模型的卷积层通过局部连接和权值共享的方式极大的减少了需要训练的参数量。在全连接网络中，如果图片大小为  $1000*1000$  像素，隐藏层有 1 百万个神经元，那么将会有  $1000*1000*1000000$  个连接，即一个隐藏层需要训练  $10^{12}$  个参数。但是在 CNN 模型中，如果卷积核的大小为  $10*10$ ，通过局部链接和权值共享，需要训练的参数将缩减为卷积核的大小\*卷积核的数量，即假设有 100 个卷积核，那么需要训练的参数为  $10*10*100$  个，参数量从  $10^{12}$  减少为  $10^4$ 。而且，在设计卷积核时选择了较小尺寸的卷积核  $1*3$ ，搭配较多的卷积核个数，在保证神经网络模型精度的情况下，减少模型的参数。特征的一般提取过程<sup>[101]</sup>如下：

$$F_{s,t} = \sum_0^{m_a-1} \sum_0^{n_a-1} A_{m,n} B_{s-m,t-n} \quad (5.2)$$

更新参数依靠梯度下降和反向传播算法，其中卷积层和池化层的梯度公式<sup>[101]</sup>如下：

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial v_{ij}} \frac{\partial v_{ij}}{\partial w_{ij}} = \delta_{ij} \frac{\partial v_{ij}}{\partial w_{ij}} \quad (5.3)$$

最后，全连接层的梯度公式<sup>[101]</sup>如下：

$$\frac{\partial E}{\partial W} = \nabla e_{(A)}^T X \quad (5.4)$$

而  $\nabla e_{(A)}$  是如下的矩阵：

$$\nabla e_{(A)} = \begin{bmatrix} \dot{a}_{11} & \dot{a}_{21} & \cdots & \cdots & \dot{a}_{n-1,1} & \dot{a}_{n1} \\ \dot{a}_{12} & \dot{a}_{22} & \cdots & \cdots & \dot{a}_{n-1,2} & \dot{a}_{n2} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \dot{a}_{1,n-1} & \dot{a}_{2,n-1} & \cdots & \cdots & \dot{a}_{n-1,n-1} & \dot{a}_{n-1,n} \\ \dot{a}_{1,n} & \dot{a}_{2,n} & \cdots & \cdots & \dot{a}_{n-1,n} & \dot{a}_{nn} \end{bmatrix} \quad (5.5)$$

(3) 激活函数；在 CNN 模型中，激活函数扮演着十分重要的角色，在不使用激活函数时，CNN 模型的每一层输出都只是线性组合，由于线性组合的复杂性有限，很难从数据中学习复杂函数映射的能力，因此激活函数在学习、理解非常复杂和非线性的函数中具有十分重要的作用，将非线性特性引入到 CNN 模型中。目前主流的激活函数包括如下三种：

$$\text{Sigmoid} : f(x) = \frac{1}{1 + e^{-x}} \quad (5.6)$$

$$\text{Tanh} : f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5.7)$$

$$\text{ReLU} : f(x) = \max(0, x) \quad (5.8)$$

由于 Sigmoid 函数和 Tanh 函数在渐近线附近趋近于饱和，存在梯度消失问题，而 Relu 函数不仅形式简单，其收敛速度较 Tanh 函数提高了 6 倍，在很多深度学习模型中都使用 Relu 作为激活函数，在 1-D CNN 分类模型中也使用了 Relu 作为激活函数。

(4) 池化层；在 CNN 模型中，随着层数的加深，模型的复杂度和参数量随之增加，而池化层可以对输入的特征图进行压缩，不仅可以使特征图变小，简化网络计算复杂度，也可以进行特征压缩，提取主要特征。池化层的另一个作用是对图像的变换保持不变性，即使图像经过简单的旋转、平移、尺度缩放等变换，池化层在相同的位置依旧可以提取到相同的特征，这一点是传统的人工神经网络无法做到的。目前主流的池化方法有平均池化和最大池化两种，平均池化能够减少特征提取过程中的方差偏大问题，从而减少噪声干扰，过程可描述<sup>[102]</sup>如下：

$$\begin{aligned} \alpha_i &\in \{0,1\}^K, \alpha_{i,j} = 1, \\ \text{if } j &= \arg \min \|x_i - d_k\|_2^2, \\ h_m &= \frac{1}{|N_m|} \sum_{i \in N_m} \alpha_i \end{aligned} \quad (5.9)$$

而最大池化能够减少特征提取过程中的均值偏移问题，从而更多的保留心电



信号中的纹理信息，过程可描述<sup>[102]</sup>如下：

$$\begin{aligned}\alpha_i &= \arg \min L(\alpha, D) \triangleq \|x_i - D\alpha\|_2^2 + \lambda \|\alpha\|_1 \\ h_{m,j} &= \max_{i \in N_m} \alpha_{i,j}, \text{ for } j = 1, \dots, K\end{aligned}\quad (5.10)$$

最大池化方式能够突出特征，在 1-D CNN 分类模型中采用最大池化的方式提取心电图中的特征。

(5) Dropout 层；在 CNN 模型中，如果模型的参数太多，而训练样本又太少，就必须考虑模型的过拟合问题，防止 CNN 模型在训练数据上损失函数比较小，预测准确率也较高，但是在测试数据上效果不好，损失函数比较大，预测准确率也较低。Dropout 按照一定比例随机地让一部分隐层节点失效来防止 CNN 模型的过拟合，Dropout 广泛应用在深度神经网络模型中。较图片数据，心电信号数据更为简单，为了增强心律自动检测的扩展性，在 1-D CNN 分类模型中多次使用了 Dropout 层。

(6) 损失函数；在任何机器学习算法中，损失函数表示了给定训练样本与期望输出之间的差值，是衡量机器学习算法训练效果的关键。在多分类任务中，softmax 函数是使用最多的激活函数，softmax 的表达式如下：

$$S_i = \frac{e^i}{\sum_j e^j} \quad (5.11)$$

可以将 softmax 理解成概率，在最后选取输出结点的时候，就可以选取概率最大的类别作为预测目标。在使用 softmax 作为输出层的激活函数时，categorical cross\_entropy 常用作对应的损失函数，其表达式如下：

$$L_t = -\sum_j t_{i,j} \log(p_{i,j}) \quad (5.12)$$

其中  $t$  表示样本的真实值， $p$  表示模型的预测值。在最小化损失函数时，选取 Adam 优化器优化分类模型的权值，以 0.0001 作为学习率。

### 5.3 实验和评价

在上一节内容中，分别介绍了 1-D CNN 分类模型中的数据处理方式以及分类模型本身，在数据预处理中，利用标记信息、R 波峰值、R-R 间隔等特征从动态心电图中提取出了心跳 Beat，共八类心跳 Beat 构成了 107574 个样本。其次，八类标记信息正常起搏 (N)、房性早搏 (A)、室性早搏 (V)、起搏心跳 (/)、左束支传导阻滞 (L)、右束支传导阻滞 (R)、室扑 (!)、室性逸搏 (E) 分别用数字 0~7 代替，配合 softmax 激活函数将标记转换为 one-hot 编码形式如下：

$$\begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 1 \end{bmatrix} \quad (5.13)$$

将心跳 Beat 作为 1-D CNN 分类模型的输入，将 one-hot 编码后的标记作为对应的输出，经过 100 轮迭代后，模型趋近于收敛。

### 5.3.1 评价指标

心律失常检测分类的常见评价指标主要包括 AUC (Area Under the Curve)、Accuracy、Precision、Recall 以及 F1-score。这几种常见的评价指标均和混合矩阵相关，混合矩阵记录着分类模型在测试集上的预测结果，用四个指标来反映分类模型的性能，如下表 5.5。

表 5.5 混合矩阵

真实情况	预测结果	
	y=1	y=0
y=1	TP(True Positive)	FN(False Negative)
y=0	FP(False Positive)	TN(True Negative)

表 5.5 中 TP 表示预测为 True，而实际也是 True 的样例数；FN 表示预测为 False，而实际是 True 的样例数；FP 表示预测为 True，而实际是 False 的样例数；TN 表示预测为 False，而实际也是 False 的样例数。根据表 5.5，将 Accuracy、Precision、Recall 分别定义如下式：

$$Accuracy = \frac{\text{预测正确的样本数}}{\text{总样本数}} = \frac{TP+TN}{TP+TN+FP+FN} \quad (5.14)$$

$$Precision = \frac{\text{预测为True且正确预测的样本数}}{\text{所有预测为True的样本数}} = \frac{TP}{TP+FP} \quad (5.15)$$

$$Recall = \frac{\text{预测为True且正确预测的样本数}}{\text{所有真实情况为True的样本数}} = \frac{TP}{TP+FN} \quad (5.16)$$

但是在实际模型评价中，由于 Precision 和 Recall 是两个值，无法根据两个值来对比模型的好坏，F1-score 综合考虑模型的 Precision 和 Recall，只需要计算 F1-score 即可完成模型的对比，将 F1 定义如下式：

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (5.17)$$

最后，AUC 也是一个值，表示 ROC (Receiver Operating Characteristic) 曲线下的面积，AUC 值越大说明模型越好。在解释 ROC 曲线前，还需要定义两个变量，分别是 FPR (False Positive Rate) 和 TPR (True Positive Rate)，将其定义如下式：


$$FPR = \frac{FP}{FP + TN} \quad (5.18)$$

$$TPR = \frac{TP}{TP + FN} \quad (5.19)$$

在 ROC 曲线坐标系中，以 FPR 为横坐标，以 TPR 为纵坐标，以典型的二分类问题为例，经过神经网络模型最后一层的激活函数后通常得到的是一个概率值，表示预测结果是 1 的概率。最终预测结果取 0 还是 1 取决于选取的阈值，概率超过了阈值预测为 1，否则预测为 0。因此，当选取不同的阈值时，会导致分类的结果不同，即混淆矩阵发生改变，由式 5.18 和 5.19 可知 FPR 和 TPR 也会发生改变。在区间[0,1]之间选取不同的阈值时，就会形成很多对 (FPR, TPR) 的值，将不同的 (FPR, TPR) 画在坐标系上，即可得到 ROC 曲线。而 AUC 就表示 ROC 曲线、直线 TPR=0 以及直线 FPR=1 围成的面积。

### 5.3.2 实验结果

在 Keras 2.0 中，实现了表 5.3 所示的 1-D CNN 心律失常检测分类模型，将 107574 个样本随机打乱顺序后，取 90000 条样本作为模型的训练数据，剩余的 17574 条样本作为模型的测试数据。在训练过程中，记录了损失函数、F1、准确率的变化过程，在图 5.6 中分别给出了损失函数、F1 以及准确率随迭代次数的变化规律。






图 5.6 训练过程

从图 5.6 中分别给出了损失函数、F1 值以及模型准确率随着训练步长的变化曲线图，可以看出模型在经过 1000 步（步长为 500 个样本）后已基本收敛，而在文献[156]中，J. T. Jun 等人使用 2-D CNN 模型检测心律失常，同样在第 1000 步时模型开始收敛，能够在较短时间内完成模型的训练主要得益于如下两个方面的原因：

(1) 心电信号结构简单，模型只需要处理 1 维信号数据，而且信号数据只有不到 300 个数据点；

(2) 1-D CNN 分类模型结构简单，虽然模型有较多层，但是只采用了 1\*3 的卷积核，减少了模型的参数量和计算量。

模型训练完成后，在测试集上取得的实验结果如表 5.6。

表 5.6 实验结果

指标	Accuracy	Precision	Recall	F1	AUC
结果	99.45%	99.45%	99.45%	99.45%	0.99

表 5.6 中给出了模型的整体性能，进一步计算模型在测试集上的混合矩阵见表 5.7。

表 5.7 混合矩阵

	N	A	V	/	L	R	!	E
N	12329	10	10	1	1	3	1	0
A	48	329	0	0	1	2	0	0
V	19	0	1097	0	3	0	3	0
/	2	0	0	1135	0	0	0	1
L	7	1	1	1	1296	0	0	1
R	7	8	2	0	0	1169	0	0
!	1	0	0	0	0	0	63	0
E	0	0	0	0	0	0	0	21

从表 5.7 中给出的混合矩阵可以发现模型有可能混淆正常心跳 Beat 和其他异常的心跳 Beat，但是大部分的心跳 Beat 均被正确的检测出来。进一步，将模型的平均 ROC 曲线绘制见图 5.7。




图 5.7 平均 ROC 曲线

在图 5.7 中同时给出了模型的平均 AUC 为 0.99，同时 ROC 曲线无限靠近左上角，表现了分类模型在心律失常检测上的优良性能。更具体的，对每种类型的心跳 Beat 而言，在同一个坐标系中画出八类心跳 Beat 的 ROC 曲线见图 5.8。

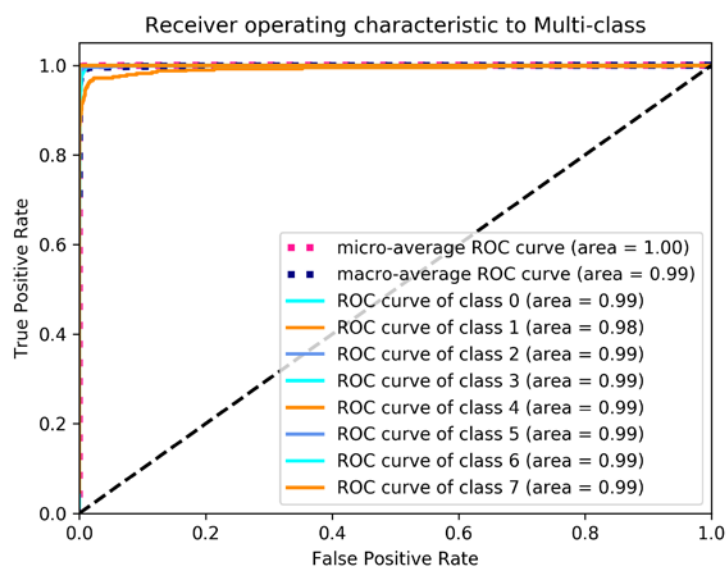


图 5.8 八类 ROC 曲线

在图 5.8 中分别给出了每一类心跳 Beat 在 1-D CNN 分类模型中的 AUC 值，除了第二类心跳 Beat（房性早搏）的 AUC 值为 0.98 之外，其它类别的心跳 Beat 的 AUC 值均为 0.99，所有的 ROC 曲线均无限接近左上角。从以上各项评价指标来看，本章提出的 1-D CNN 分类模型能够较好的检测心律失常 Beat，为临床心律失常检测提供了新思路。

## 5.4 对比分析

在对比分析中，进行了两个方面的对比实验。第一个方面的对比实验是使用降噪前的数据作为 1-D CNN 分类模型的数据集，采用完全一样的分类模型，通过对比降噪前后模型的分​​类准确率等指标，一方面可以验证第四章中提出的降噪方法的性能，即是否在滤除噪声的同时滤除了心电信号中的病理特征；另一方面也可以验证分类模型对噪声的敏感程度，对于带噪心电图数据是否能够以较高的准确率正确识别心跳 Beat 的类型。

### 5.4.1 降噪前后对比实验

在上一节的实验中，使用的是经过降噪后的心电图数据，为了对比降噪前后分类的性能差异，在本节实验中直接使用带噪的心电图作为模型的数据集，并采用相同的提取心跳 Beat 的方法从连续心电信号中提取八类心跳 Beat，在 keras 2.0 中搭建完全相同的 1-D CNN 分类模型，在训练过程中，记录了损失函数、F1、准确率的变化过程，在图 5.9 中仅仅给出损失函数随迭代次数的变化规律。

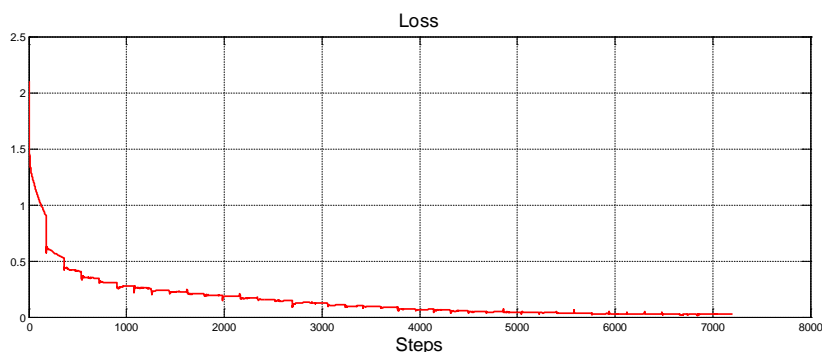


图 5.9 带噪数据集训练过程

从图 5.9 中可以看出存在噪声的情况下，由于噪声对模型的干扰，使得模型的收敛变缓，经过约 4000 个 step 后开始收敛，模型训练完成后，在测试集上取得的实验结果如表 5.8。

表 5.8 带噪数据集实验结果

指标	Accuracy	Precision	Recall	F1	AUC
结果	93.96%	94.01%	93.93%	93.97%	0.98

表 5.8 中给出了模型在带噪数据集上的整体性能，和无噪数据集上的相比，各个评价指标均有所下降，下降了约 5%，由此可见，噪声的存在不仅减慢了模型的收敛速度，同时也降低了分类模型的性能。同样也可计算模型在测试集上的混合矩阵见表 5.9。

表 5.9 带噪数据集混合矩阵

	N	A	V	/	L	R	!	E
N	12338	1	5	0	10	1	0	0
A	92	276	1	0	0	11	0	0
V	47	4	1052	0	12	5	0	2
/	2	0	0	1136	0	0	0	0
L	3	1	0	0	1302	0	0	1
R	16	33	0	0	1	1136	0	0
!	6	0	0	0	0	0	57	1
E	1	0	0	0	0	0	0	20

从表 5.9 中可以发现，检测错误的心跳 Beat 数量增多了，有较多的心律失常心跳 Beat 被检测为正常心跳 Beat，同时也有 17 个正常心跳 Beat 被检测为异常心跳 Beat。和模型在无噪数据集上的混合矩阵相比，每一类心跳 Beat 被检测错误的数量增多了，但是绝大部分的心跳 Beat 均被正确检测。进一步可以得到模型在带噪数据集上的平均 ROC 曲线见图 5.10。




图 5.10 带噪数据集的 ROC 曲线

在图 5.10 中同时给出了模型的 AUC 为 0.98。和模型在无噪数据集上的 AUC 值相比稍有下降。更具体的，对每种类型的心脏病而言，在同一个坐标系中画出八类心脏病的 ROC 曲线见图 5.11。




图 5.11 带噪数据集八类 ROC 曲线

在图 5.11 中分别给出了每一类心跳 Beat 在 1-D CNN 分类模型中的 AUC 值，第一类心跳 Beat 正常起搏的 AUC 值为 0.97，第二类心跳 Beat 房性早搏的 AUC 值为 0.91，其他类型的心跳 Beat 的 AUC 值均为 0.98，和模型在无噪数据集上的结果相比均有所下降，尤其是第二类心跳 Beat 的 AUC 值下降了 7%。

通过上述对比分析，发现所提出的模型在无噪数据集上的评价指标要普遍优于模型在带噪数据集上的评价指标，可见噪声的存在确实对模型的分类性能产生了影响，但是从模型在带噪数据集上的实验结果来看，模型经过 4000 个 steps 才开始收敛，相比较于无噪情况下只需要 1000 个 steps 模型即收敛，收敛速度减缓了，但也取得了不错的分类结果。

#### 5.4.2 现有方法对比实验

在现有心律失常检测方法中，和第二章中的研究现状中提到的方法对应，选取了 2-D CNN<sup>[103]</sup>、CNN（卷积神经网络）<sup>[104]</sup>、FFNN（前向神经网络）<sup>[105,106]</sup>、SVM（支持向量机）<sup>[107,108]</sup>、RNN（循环神经网络）<sup>[109]</sup>、RFT（随机森林）<sup>[110]</sup>、KNN（K 近邻）<sup>[24]</sup>七类方法作为对比方法。各类评价指标的详细表见表 5.10。



表 5.10 现有方法评价指标对比

分类器	Beat 类数	Accuracy	Precision	Recall	AUC
<b>1-D CNN</b>	<b>8 分类</b>	<b>99.45%</b>	<b>99.45%</b>	<b>99.45%</b>	<b>0.99</b>
<b>2-D CNN</b>	8 分类	99.05%	-	97.85%	0.989
<b>CNN</b>	5 分类	96.40%	-	68.80%	-
<b>FFNN</b>	4 分类	96.94%	-	96.31%	-
	8 分类	98.71%	-	-	-
<b>SVM</b>	6 分类	91.67%	-	93.83%	-
	3 分类	95.82%	-	86.16%	-
<b>RNN</b>	4 分类	98.06%	-	98.15%	-
<b>RFT</b>	3 分类	92.16%	-	-	-
<b>KNN</b>	17 分类	97.00%	-	96.60%	-

由于在有些方法中只选取了评价指标中的一个或多个，因此表 5.10 中存在空缺值，从表 5.10 中也可以看出本章提出的 1-D CNN 分类模型在各项指标上均优于现有的方法。

## 5.5 小结

本章内容和第四章的内容紧密相关，在第四章中提出了多层 LSTM 降噪模型，可以在不具备任何经验知识的前提下滤除动态心电图中的噪声，而本章旨在解决动态心电图的自动诊断，即动态心电图的心律失常自动检测。为此，在本章中引入了 1-D CNN 分类模型，整个模型分为两个部分，第一部分是数据预处理，从连续的动态心电图中提取出不同的心跳 Beat，第二部分是分类模型，直接将心电图作为 1 维信号数据考虑，在设计卷积核和池化层的时候，均只考虑 1 维的卷积核和池化层，最终实验结果在各项指标上均要优于现有的心律失常检测方法。同时，为了对比降噪前后分类模型的性能差异，采用完全相同的模型在完全相同的环境下对带噪的心跳 Beat 也进行了实验，实验结果表明噪声的存在不仅减缓了模型的收敛速度，同时也对模型的性能产生了影响，各方面指标均有所下降。由此也说明了降噪的重要性和必要性。

# 结 论

## 1. 工作总结

本文围绕心脏病的监控方式和心电图数据处理两个主体展开，主要工作包括以下内容：

(1) 远程心电监控系统；从一种企业级的远程心电系统出发，详细论述了这种新型远程心电监控系统中的四个主要部分，即心电图采集设备、移动终端、云服务中心以及数据分析站。在这种新型远程心电监控系统中，综合考虑心电图采集设备和云平台后，可以建立以患者为中心的新型医患模式。不仅能将与心脏病患者息息相关的医院、保险、医生、病友等单位和个人均可通过云平台与心脏病患者联系起来，还可以充分利用中心医院的专家资源和医疗设备资源，整个一体化的新型医患模式构成了一个典型的物联网系统。在物联网结构的远程心电监控系统，将关注点放在其数据处理模式和计算模式上，进而引出了后面的数据处理问题。

(2) 动态心电图的智能降噪；基于深度学习模型提出了一种新的心电图降噪方法，这种方法将动态心电图看作数据间存在强依赖关系的时间序列数据，利用 LSTM 网络的记忆单元保留心电信号间的依赖关系，同时抛弃心电信号与噪声信号间的依赖关系，通过多个 LSTM 层提取信号的深层次特征，高质量的还原心电信号。突破了现有心电图降噪方法的限制，取得了较小的 RMSE 和较大的信噪比提升，并且针对物联网结构的远程心脏监控方式，心电信号可能会同时包含多种类型的噪声，而且无法预知信号中的噪声类型的特殊场景，所提出的模型摆脱了对波形的依赖，实验表明所提出的模型能够直接应用到多种类型的心电信号的降噪中，在不同类型下均取得了较小的均方根误差和较大的信噪比提升。心电图的降噪为心电图的心律失常检测分类奠定了基础，进一步引出了下一个问题。

(3) 心电图的心律失常检测分类；为了解决动态心电图的自动诊断，即动态心电图的心律失常自动检测，引入了 1-D CNN 分类模型。模型在数据预处理部分从连续的动态心电图中提取出不同的心跳 Beat，为了得到尽可能准确的心跳 Beat，分别设计了两个提取心跳 Beat 的算法，最终提取出等长的八类心跳 Beat。在模型的分类部分，考虑到物联网结构的远程心电监控系统中，往往是硬件资源受限的环境，因此直接将心电图作为 1 维信号数据考虑，在设计卷积核和池化层的时候，均只考虑 1 维的卷积核和池化层，同时对比图片数据，心电信号

数据更为简单，为了增强心律自动检测的扩展性，在 1-D CNN 分类模型中多次使用了 Dropout 层。最终取得了 99.45% 的 Accuracy, 99.45% 的 Precision, 99.45% 的 Recall, 99.45% 的 F1-score, 以及 0.99 的 AUC, 这一实验数据均要优于现有的心律失常检测方法。除此之外，对带噪的心跳 Beat 也进行了实验，经过约 4000 个 step 的训练后，分类模型取得了 93.96% 的 Accuracy, 94.01% 的 Precision, 93.93% 的 Recall, 93.97% 的 F1-score, 以及 0.98 的 AUC。

## 2. 研究展望

随着生活水平的提高，对健康的需求会越来越高，而人工智能的发展与这一观点不谋而合，因此智慧医疗将会是一个永远值得探索的领域，尤其是对于死亡率一直居高不下的心脏病来说，智能的监控方式的发展与普及将会受到越来越多人的关注，除了本文提及的部分外，以下几个方面有可能成为本领域的热点问题：

(1) 心脏病的智能监控方式；第一个方面仍然是心脏病的监控方式，虽然在本文中提及了云计算为服务的物联网结构的远程心脏病监控方式，但是只是针对单导联的心电信号，实际上很多心脏病需要多个导联的心电信号才能判读，如 2018 年 P. Eedara 等人<sup>[111]</sup>发表的 12 导联的远程心脏病监控方式。

(2) 个性化的高效远程心电监控计算架构；第二个方面是远程心脏病监控中采用何种计算架构，虽然本文提及了云计算架构，但是近年来终端设备-边缘计算-云计算的多层次计算架构<sup>[112]</sup>在物联网系统中开始应用，同时简化的深度学习模型（如 BNN）也开始在物联网系统中应用，均给了新的思考方向。

(3) 心电图的标记；心脏病的自动检测分类的基本前提条件是标记信息，在本文中使用的数据集 MIT-BIH 给出了相关的标记信息，在实际监控系统中采集到的心电图数据是没有标记信息的，标记心电图需要耗费大量的人力物力，而且需要心电专家的干预，如 P. Rajpurkar 等人在文献[113]中使用的数据集花费了大量人力物力完成标记工作，如何将深度学习应用到心电图的标记上将会是一个大难题。

## 参考文献

- [1] [http://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death?=.](http://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death?=)
- [2] 陈伟伟, 高润霖, 刘力生等. 《中国心血管病报.2016》概要[J].中国循环杂志,2017,32(6):521-530.
- [3] World Health Organization. World health statistics 2017: monitoring health for the SDGs, Sustainable Development Goals, ISBN 978-92-4-156548-6[R]. France,2017
- [4] Manogaran G, Varatharajan R, Lopez D, et al. A new architecture of Internet of Things and big data ecosystem for secured smart healthcare monitoring and alerting system[J]. Future Generation Computer Systems, 2018, 82: 375-387.
- [5] 谢洪波, 于为, 李小英, 等. 基于神经网络和模糊理论的心功能辅助诊断专家系统[J]. 天津大学学报, 2000, 33(5): 610-614.
- [6] Acharya U R, Fujita H, Lih O S, et al. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network[J]. Information sciences, 2017, 405: 81-90.
- [7] Taji B , Chan A D C , Shirmohammadi S . False Alarm Reduction in Atrial Fibrillation Detection Using Deep Belief Networks[J]. IEEE Transactions on Instrumentation and Measurement, 2017, PP(99):1-8.
- [8] Corbin T H, Kienitz M E. System and method employing video equipment for remote monitoring of body function activities: U.S. Patent 3,613,669[P]. 1971-10-19.
- [9] Franchi D, Belardinelli A, Palagi G, et al. New telemedicine approach to the dynamic ECG and other biological signals ambulatory monitoring[C]//Computers in Cardiology 1998.Cleveland: IEEE, 1998: 213-216.
- [10] Giroud F, Persechini P, Ruedi P F, et al. ECG sensor interface in a low power SoC for wireless portable ECG monitoring[C]//Biomedical Circuits and Systems Conference (BioCAS), 2014 IEEE. IEEE, 2014: 149-152.
- [11] Fensli R, Gunnarson E, Hejlesen O. A wireless ECG system for continuous event recording and communication to a clinical alarm

- station[C]//The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2004, 1: 2208-2211.
- [12] Avcu F, Kavak A, Inner A B. QRS detection on IOS platform based on single channel practical ECG measurement for remote patient monitoring[C]//2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE, 2018: 1-4.
- [13] Vemishetty N, Jain A, Amber A, et al. A low complexity architecture for online on-chip detection and identification of f-QRS feature for remote personalized health care applications[C]//Electronic System Design (ISED), 2014 Fifth International Symposium on. IEEE, 2014: 120-124.
- [14] Mamaghanian H, Khaled N, Atienza D, et al. Compressed sensing for real-time energy-efficient ECG compression on wireless body sensor nodes[J]. IEEE Transactions on Biomedical Engineering, 2011, 58(9): 2456-2466.
- [15] Mahajan R, Bansal D. Hybrid ECG signal compression system: A step towards efficient tele-cardiology[C]//Optimization, Reliability, and Information Technology (ICROIT), 2014 International Conference on. IEEE, 2014: 437-442.
- [16] Hesar H, Mohebbi M. (2016). ECG Denoising Using Marginalized Particle Extended Kalman Filter with an Automatic Particle Weighting Strategy. IEEE Journal of Biomedical & Health Informatics, 21(3), 635.
- [17] Küçükgöz N, Karaboğa N. Noise elimination and finding R peaks of ECG signal by using discrete stationary wavelet transform[C]//2017 25th Signal Processing and Communications Applications Conference (SIU). IEEE, 2017: 1-4.
- [18] Satija U, Ramkumar B, Manikandan M S. (2017). Automated ECG Noise Detection and Classification System for Unsupervised Healthcare Monitoring. IEEE Journal of Biomedical & Health Informatics, 99, 1-1.
- [19] V Zhang Z, Li H, Mandic D. (2016). Blind source separation and artefact cancellation for single channel bioelectrical signal. Wearable and Implantable Body Sensor Networks (BSN), 2016 IEEE 13th International Conference on. IEEE, 177-182.
- [20] Osowski S, Linh T H. ECG beat recognition using fuzzy hybrid neural network[J]. IEEE Transactions on Biomedical Engineering, 2001, 48(11): 1265-1271.

- [21] Osowski S, Hoai L T, Markiewicz T. Support vector machine-based expert system for reliable heartbeat recognition[J]. IEEE transactions on biomedical engineering, 2004, 51(4): 582-589.
- [22] Kumar R G, Kumaraswamy Y S. Investigating cardiac arrhythmia in ECG using random forest classification[J]. International Journal of Computer Applications, 2012, 37(4): 31-34.
- [23] Moody G B, Mark R G. The impact of the MIT-BIH arrhythmia database[J]. IEEE Engineering in Medicine and Biology Magazine, 2001, 20(3): 45-50.
- [24] Park J, Lee K, Kang K. Arrhythmia detection from heartbeat using k-nearest neighbor classifier[C]//Bioinformatics and Biomedicine (BIBM), 2013 IEEE International Conference on. IEEE, 2013: 15-22.
- [25] Al Rahhal M M , Bazi Y , Alhichri H , et al. Deep Learning Approach for Active Classification of Electrocardiogram Signals[J]. Information Sciences An International Journal, 2016, 345(C):340-354.
- [26] Bai J, Zhang Y, Dai B, et al. The design and preliminary evaluation of a home electrocardiography and blood pressure monitoring network[J]. Telemedicine and Telecare, 1996, 2(2): 100-106.
- [27] Chen C, Bian K, Huang A, et al. WE-CARE: A wearable efficient telecardiology system using mobile 7-lead ECG devices[C]//Communications (ICC), 2013 IEEE International Conference on. IEEE, 2013: 4363-4367.
- [28] Hu C, Liao J, Jin P, et al. A portable telemedicine monitoring information system based on mobile internet networks[C]//Robotics and Biomimetics (ROBIO), 2013 IEEE International Conference on. IEEE, 2013: 2274-2279.
- [29] Shih D H, Chiang H S, Lin S B, et al. An intelligent ECG reasoning system for the elderly[C]//Machine Learning and Cybernetics, 2007 International Conference on. IEEE, 2007, 4: 1826-1831.
- [30] Chan C C, Chou W C, Chen C W, et al. Energy efficient diagnostic grade mobile ECG monitoring[C]// NEWCAS 2012: 2012 IEEE 10th International New Circuits and Systems Conference. Montreal: IEEE, 2012: 153-156.
- [31] Lin Y M, Chen Y, Kuo H C, et al. Compressive sensing based ECG telemonitoring with personalized dictionary basis[C]// BioCAS 2015:

- 2015 IEEE Biomedical Circuits and Systems Conference. Atlanta: IEEE, 2015: 1-4.
- [32] 周拓, 葛鑫, 杨翠微, 等. 用于远程心电监护系统的心电信号自动分析和诊断方法[J]. 中国医疗器械杂志, 2009, 33(3):176-178.
- [33] 严飞. 远程心电监护系统中的心律失常自动分析方法研究[D]. 福州大学, 1997.
- [34] Dong J, Zhang S, Jia X. A portable intelligent ECG monitor based on wireless internet and embedded system technology[C]//BioMedical Engineering and Informatics, 2008. BMEI 2008. International Conference on. IEEE, 2008, 2: 553-556.
- [35] 朱洁. 基于无线传感器网络的心电监护系统设计[D]. 电子科技大学, 2008.
- [36] 钱焱. 远程心电监护系统的研究与设计[D]. 东华大学, 2008.
- [37] 刘斌. 远程心电监护平台的设计与实现[D]. 天津大学, 2017.
- [38] 李汉玲. WSN24-Link 无线传感器网络在心电监护系统中的应用[J]. 电脑开发与应用, 2008, 21(1):70-72.
- [39] Liu C, Zhang X, Zhao L, et al. Signal Quality Assessment and Lightweight QRS Detection for Wearable ECG SmartVest System[J]. IEEE Internet of Things Journal, 2018: 1-1.
- [40] 杨思军, 郝继飞, 闫文杰, 等. 小波滤波与 QRS 波检测[D]. , 2011.
- [41] 赵安. 移动式远程心电监护近无损心电数据压缩方法的研究[D]. 第三军医大学, 2005.
- [42] 张增芳, 陈瑞中, 齐保谦, 等. 基于小波神经网络的心电数据压缩研究[D]. , 2002.
- [43] 田絮资, 杨建, 黄力宇. 心电信号去噪的数学形态学滤波器[D]. , 2012.
- [44] 王佳文, 凡友华. 心电信号去噪中的小波方法[D]. , 2009.
- [45] 王太勇, 商同, 吴振勇, 等. 一种模糊神经网络改进算法[J]. 振动工程学报, 2001, 14(4).
- [46] 金林鹏, 董军. 面向临床心电图分析的深度学习算法[J]. 中国科学: 信息科学, 2015 (003): 398-416.
- [47] 冯俊. 基于特征提取与神经网络的心电图分类研究[D]. 四川师范大学, 2005.
- [48] 李慧慧, 金林鹏. 一种基于心率和深度学习的心电图分类算法[J]. 航天医学与医学工程, 2016, 29(3):189-194.
- [49] 李彩玉. 基于 RBF 神经网络的心电信号分类识别技术研究[D]. 云南大学, 2012.

- [50] Hayes-Roth F, Waterman D A, Lenat D B. Building expert system[J]. 1983.
- [51] Steels L, Brooks R. The artificial life route to artificial intelligence: Building embodied, situated agents[M]. Routledge, 2018.
- [52] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]//Advances in neural information processing systems. 2012: 1097-1105.
- [53] Huang A, Chen C, Bian K, et al. WE-CARE: an intelligent mobile telecardiology system to enable mHealth applications[J]. IEEE journal of biomedical and health informatics, 2014, 18(2): 693-702.
- [54] Shi F, Li X. Development of automatic motion artifact detection in mobile ECG monitor based on wavelet transform[C]//Intelligent Control, Automatic Detection and High-End Equipment (ICADE), 2012 IEEE International Conference on. IEEE, 2012: 166-170.
- [55] Xue S, Chen X, Fang Z, et al. An ECG arrhythmia classification and heart rate variability analysis system based on android platform[C]//Future Information and Communication Technologies for Ubiquitous HealthCare (Ubi-HealthTech), 2015 2nd International Symposium on. IEEE, 2015: 1-5.
- [56] Ko L W, Lai P W, Yang B J, et al. Mobile EEG & ECG integration system for monitoring physiological states in performing simulated war game training[C]//CIG 2015: 2015 IEEE Conference on Computational Intelligence and Games. Taiwan: IEEE, 2015: 542-543.
- [57] Lin Y M, Chen Y, Kuo H C, et al. Compressive sensing based ECG telemonitoring with personalized dictionary basis[C]// BioCAS 2015: 2015 IEEE Biomedical Circuits and Systems Conference. Atlanta: IEEE, 2015: 1-4.
- [58] Lewis D E. Remote ECG monitoring system: U.S. Patent 3,986,498[P]. 1976-10-19.
- [59] Bedini R. Telemedicine in Electrocardiographic Analysis[J]. ERCIM News (European Research Consortium for Informatics and Mathematics), 1994 (17): 27-28.
- [60] Polania L F, Carrillo R E, Blanco-Velasco M, et al. Exploiting prior knowledge in compressed sensing wireless ECG systems[J]. IEEE journal of Biomedical and Health Informatics, 2015, 19(2): 508-519.



- [61] Rakshit M, Das S. (2017). An Improved EMD based ECG Denoising Method using Adaptive Switching Mean Filter, International Conference on Signal Processing & Integrated Networks, SPIN. 2017.
- [62] Mittal A, Rege (2016). A. Design of digital FIR filter implemented with window techniques for reduction of power line interference from ECG signal. International Conference on Computer, Communication and Control. IEEE, 1-4.
- [63] Smital L, Vítek M, Kozumplík J, et al. (2013) Adaptive wavelet Wiener filtering of ECG signals. IEEE Transactions on Biomedical Engineering, 60(2), 437.
- [64] Chang C H, Wang T M, Hsu H L. (2017). Denoising of mixed noises in ECG with separate noise estimators based on discrete wavelet transform. International Conference on Advanced Materials for Science and Engineering. IEEE, 562-564.
- [65] Mithun P, Pandey P C, Sebastian T, et al. (2011). A wavelet based technique for suppression of EMG noise and motion artifact in ambulatory ECG. Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE. IEEE, 7087-7090.
- [66] Chang K M. (2010). Ensemble empirical mode decomposition based ECG noise filtering method. Machine Learning and Cybernetics (ICMLC), 2010 International Conference on. IEEE, 1, 210-213.
- [67] Barhatte A S, Ghongade R, Tekale S V. (2016). Noise analysis of ECG signal using fast ICA. Advances in Signal Processing. IEEE, 118-122.
- [68] Sameni R, Clifford G D. (2010). A review of fetal ECG signal processing; issues and promising directions. The open pacing, electrophysiology & therapy journal, 3-4.
- [69] Sultana N, Kamatham Y, Kinnara B. Performance Analysis of Artificial Neural Networks for Cardiac Arrhythmia Detection[C]//2016 IEEE 6th International Conference on Advanced Computing (IACC). IEEE, 2016: 421-425.
- [70] Swietojanski P, Ghoshal A, Renals S. (2014). Convolutional neural networks for distant speech recognition. IEEE Signal Processing Letters, 21(9), 1120-1124.

- [71] Dahl G E, Yu D, Deng L, et al. (2012). Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition. *IEEE Transactions on audio, speech, and language processing*, 20(1), 30-42.
- [72] Linh T H, Osowski S, Stodolski M. On-line heart beat recognition using Hermite polynomials and neuro-fuzzy network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2003, 52(4): 1224-1231.
- [73] 童佳斐, 董军. 分类器组合在心电图分类中的应用[J]. *计算机应用*, 2010, 30(4):1125-1128.
- [74] Ceylan R, Özbay Y. Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network[J]. *Expert Systems with Applications*, 2007, 33(2): 286-295.
- [75] Ye C, Kumar B V K V, Coimbra M T. Heartbeat classification using morphological and dynamic features of ECG signals[J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(10): 2930-2941.
- [76] Sultana N, Kamatham Y. MSVM-based classifier for cardiac arrhythmia detection[C]//*Advances in Computing, Communications and Informatics (ICACCI)*, 2016 International Conference on. IEEE, 2016: 1314-1318.
- [77] Raj S, Ray K C. ECG signal analysis using DCT-based DOST and PSO optimized SVM[J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(3): 470-478.
- [78] Moavenian M, Khorrami H. A qualitative comparison of artificial neural networks and support vector machines in ECG arrhythmias classification[J]. *Expert Systems with Applications*, 2010, 37(4): 3088-3093.
- [79] Alickovic E, Subasi A. Medical decision support system for diagnosis of heart arrhythmia using DWT and random forests classifier[J]. *Journal of medical systems*, 2016, 40(4): 108.
- [80] Sadiq A T, Shukr N H. Classification of Cardiac Arrhythmia using ID3 Classifier Based on Wavelet Transform[J]. *Iraqi Journal of Science*, 2013, 54(5): 1167-1175.
- [81] Christov I, Jekova I, Bortolan G. Premature ventricular contraction classification by the Kth nearest-neighbours rule[J]. *Physiological Measurement*, 2005, 26(1):123-130.

- [82] Jun T J , Park H J , Yoo H , et al. GPU based cloud system for high-performance arrhythmia detection with parallel k-NN algorithm[C]//Engineering in Medicine & Biology Society. IEEE, 2016.
- [83] Yan Y, Qin X, Wu Y, et al. A restricted Boltzmann machine based two-lead electrocardiography classification[C]//BSN. 2015: 1-9.
- [84] Wang D , Shang Y . Modeling Physiological Data with Deep Belief Networks.[J]. Int J Inf Educ Technol, 2013, 3(5):505-511.
- [85] Huanhuan M, Yue Z. Classification of electrocardiogram signals with deep belief networks[C]//2014 IEEE 17th International Conference on Computational Science and Engineering. IEEE, 2014: 7-12.
- [86] Acharya U R, Fujita H, Oh S L, et al. Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network[J]. Future Generation Computer Systems, 2018, 79: 952-959.
- [87] Mell P, Grance T. The NIST definition of cloud computing[J]. 2011.
- [88] <http://www.docobo.co.uk/index.html> [2018-12-14]
- [89] Jeon T, Kim B, Jeon M, et al. Implementation of a portable device for real-time ECG signal analysis[J]. Biomedical engineering online, 2014, 13(1): 160.
- [90] Benini A, Donati M, Iacopetti F, et al. User-friendly single-lead ECG device for home telemonitoring applications[C]//Medical Information and Communication Technology (ISMICT), 2014 8th International Symposium on. IEEE, 2014: 1-5.
- [91] Atzori L, Iera A, Morabito G. The internet of things: A survey[J]. Computer networks, 2010, 54(15): 2787-2805.
- [92] Dean J, Ghemawat S. MapReduce: simplified data processing on large clusters[J]. Communications of the ACM, 2008, 51(1): 107-113.
- [93] Bonomi F, Milito R, Zhu J, et al. Fog computing and its role in the internet of things[C]//Proceedings of the first edition of the MCC workshop on Mobile cloud computing. ACM, 2012: 13-16.
- [94] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.
- [95] Goldberger A L, Amaral L A N, Glass L, et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23): e215-e220.

- [96] Ari S, Das M K, Chacko A. ECG signal enhancement using S-Transform[J]. Computers in Biology and Medicine, 2013, 43(6): 649-660.
- [97] Reddy G U, Muralidhar M, Varadarajan S. ECG De-Noiseing using improved thresholding based on Wavelet transforms[J]. International Journal of Computer Science and Network Security, 2009, 9(9): 221-225.
- [98] Li X P, Chen L Z. Research on the Application of BP Neural Networks in 3D Reconstruction Noise Filter[J]. Advanced Materials Research, 2014: 911-914.
- [99] Vincent P. A connection between score matching and denoising autoencoders[J]. Neural Computation, 2011, 23(7): 1661-1674.
- [100] Kim Y D , Park E , Yoo S , et al. Compression of Deep Convolutional Neural Networks for Fast and Low Power Mobile Applications[J]. Computer Science, 2015, 71(2):576-584.
- [101] Lecun Y , Boser B , Denker J S , et al. Backpropagation Applied to Handwritten Zip Code Recognition[J]. Neural Computation, 1989, 1(4):541-551.
- [102] Teerapittayanon S, Mcdanel B, Kung H T, et al. Distributed Deep Neural Networks Over the Cloud, the Edge and End Devices[J]. international conference on distributed computing systems, 2017: 328-339.
- [103] Jun T J , Nguyen H M , Kang D , et al. ECG arrhythmia classification using a 2-D convolutional neural network[J]. 2018.
- [104] 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.
- [105] Güler İ, Übeyli E D. ECG beat classifier designed by combined neural network model[J]. Pattern recognition, 2005, 38(2): 199-208.
- [106] Yu S N, Chou K T. Integration of independent component analysis and neural networks for ECG beat classification[J]. Expert Systems with Applications, 2008, 34(4): 2841-2846.
- [107] Melgani F, Bazi Y. Classification of electrocardiogram signals with support vector machines and particle swarm optimization[J]. IEEE transactions on information technology in biomedicine, 2008, 12(5): 667-677.
- [108] Dutta S, Chatterjee A, Munshi S. Correlation technique and least square support vector machine combine for frequency domain based ECG beat

- classification[J]. *Medical engineering & physics*, 2010, 32(10): 1161-1169.
- [109] Übeyli E D. Combining recurrent neural networks with eigenvector methods for classification of ECG beats[J]. *Digital Signal Processing*, 2009, 19(2): 320-329.
- [110] Kumar R G, Kumaraswamy Y S. Investigating cardiac arrhythmia in ECG using random forest classification[J]. *International Journal of Computer Applications*, 2012, 37(4): 31-34.
- [111] Prabhakararao E, Dandapat S. Automatic Quality Estimation of 12-lead ECG for Remote Healthcare Monitoring Systems[C]//2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES). IEEE, 2018: 554-559.
- [112] Teerapittayanon S, McDanel B, Kung H T. Distributed deep neural networks over the cloud, the edge and end devices[C]//Distributed Computing Systems (ICDCS), 2017 IEEE 37th International Conference on. IEEE, 2017: 328-339.
- [113] Rajpurkar P, Hannun A Y, Haghpanahi M, et al. Cardiologist-level arrhythmia detection with convolutional neural networks[J]. *arXiv preprint arXiv:1707.01836*, 2017.

## 附录 A 攻读硕士学位期间发表的学术论文

- [1] Junjie Guan, Rui Li, Renfa Li, Wanli Li, Jilong Wang, and Guoqi Xie. 2018. Automated Dynamic Electrocardiogram Noise Reduction Using Multilayer LSTM Network. In Proceedings of the 15th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services (MobiQuitous '18). ACM, New York, NY, USA, 197-206. DOI: <https://doi.org/10.1145/3286978.3286988> (CCF C).

## 附录 B 攻读硕士学位期间所参与的项目

- [1] 智慧医疗项目。（北京生息握持公司）
- [2] 雷达目标自动识别项目。（湖南航天捷成电子装备有限责任公司）

## 致 谢

研究生三年时间一晃而过，从刚开始的不知不觉到现在的后知后觉，依稀记得 2016 年的三月，我来到湖南大学参加复试，也是我第一次来到长沙，给我的第一感觉是好长的一条美食街，可这不是最吸引我的地方，最让我喜欢的是学校就在湘江边上，这也算是稍微补偿了一点曾经幻想着我的大学可能是临海的。就这样，在老师的帮助下、在父母的呵护下、在朋友的陪伴下，我在这所依山傍水的校园里顺利地完成学业。

首先，我要感谢我的导师李仁发教授。和李老师的第一次见面是在 2016 年的三月份参加复试的时候，那时的场景还历历在目，李老师非常和蔼的对我说到：“小伙子很自信嘛，拿了不少证书嘛，很好啊，实验室欢迎你啊。”李老师的轻松爽朗反而让紧张不自在的我显得格格不入，后来的第二次见面是在研究生创新基地，在李老师的办公室里，李老师语重心长的跟我讨论关于是否读博士的意向，我认真的想过之后还是告诉李老师我没有读博士的意向。后来从研究生选题到论文写作，李老师都给了我不少启发。平时组会也让我们和博士师兄师姐们一起讨论，增长了见识，学习了方法，端正了态度。在我心中，李老师是一位试图通过教育来改变国内的一些现状的一位老师，曾经我也遇到过一位这样的语文老师，但是这两位老师是完全不同的类型，但都是让人十分敬佩的老师，是一种坚持，不肯握手言和的坚持，即使失望也要继续的坚持。

还要感谢实验室的李蕊老师，和李蕊老师不仅是师生关系，更是一起开过会、做过项目、写过论文的，小论文的修改和发表李老师给了我很多的建议，甚至可以说一点一点的指导我修改小论文，所以我想在这里给李蕊老师点个赞。

还要感谢基地的彭老师经常帮我们修理电脑，还有曾经送我的一个苹果，彭老师平时话不多，但是很有爱心，工作也做的很棒。还要感谢付彬老师、刘彦老师、彭怀亮老师在我开题以及中期检查上提供的指导建议，感谢所有教过我课程的老师。

感谢实验室的陈伟宏老师、龚红仿老师、黄晶师兄、吴武飞师兄、李万里师兄、周佳师兄、白洋师姐、黄一智师兄，博士师兄师姐们人都很好，也都很厉害，学习和生活上都有值得我学习的东西。感谢实验室同门邹文超、汪继龙，龙哥是我们三个人中唯一直博的人，道一声保重哥们先走了，超哥进了了不得的百度，这么好的读博士的苗子被挖走了，可惜。还要感谢李桂芬、何妍、陈毅杰、马温红、杨远达、张开厂、段宇、彭浩、庾章伟，这些人陪我一起走过的开心岁月，和你们一起学习让我倍感快乐，大家游戏玩的不咋地，但是这并不影响我们



成为朋友，毕竟你们有一颗爱瞎分析的心，大家路过广州的时候一定要来喝杯茶。特别感谢李桂芬小朋友，和你在一起的每一天都感觉很快乐，你也是我毕业之后最舍不得的人，但我还是要毕业。还要感谢基地的小伙伴们，尚浩、黄方媛、张振燕等小伙伴们都很可爱，你们丰富了我的研究生涯。还有那些曾经出现在我人生里的人，大家各自珍重。

特别感谢我的父母以及亲戚朋友，妈妈李腊美、爸爸关晒平、室友马岩松、室友王平、室友赵京鸣，你们对我的支持让我不断前进，让我顺利地完成学业，我将永远记得你们为我付出的心血。

最后衷心感谢评审专家以及答辩组老师们在百忙中对本文的审阅与指导。