

硕士学位论文

物联网结构的远程心电系统中的智能降噪及 疾病检测分类

湖南大学 信息科学与工程学院



指导老师：李仁发教授



答辩学生：关俊杰



湖南大学

HUNAN UNIVERSITY

- 绪论
- 相关研究基础及进展
- 远程心电监控系统综述
- 动态心电图的智能降噪
- 动态心电图的心律失常检测分类
- 结论

问题提出的背景 研究哪此问

进一步论述给定场景中的相关

第一个研究点：远程心电监控系统的数据采集设备、计算架构以及数据处理模式

提出多层LS


第二个研究点：对降噪后心电图做心律失常检测，引入了1-D CNN分类检测模型

1. 选题背景



现有企业级远程心脏病监控方式，由于心电图采集方式的改变，带来便利的同时引入了较大的噪声干扰，站在信号处理的角度很难将噪声滤除的同时保留心电图中的病理特征，因此本文围绕心电图中的噪声问题展开了一系列研究。

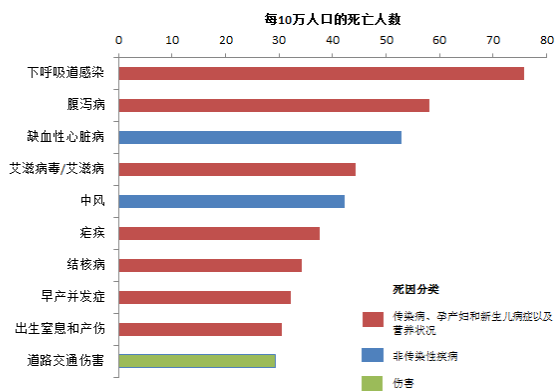
2. 研究背景



心脏病引起的死亡人数：七百万(2000), 九百万(2016), 位列第一名.


3. 不同发展程度国家

2016年低收入国家前十位死亡原因




来源: Global Health Estimates 2016. Deaths by Cause, Age, Sex, by Country and by Region, 2000-2016. Geneva, World Health Organization, 2018.
World Bank list of economies (June 2017). Washington, DC: The World Bank Group, 2017 (<https://datahelpdesk.worldbank.org/knowledgebase/articles/908519-world-bank-country-and-lending-groups>).

2016年中低收入国家前十位死亡原因




来源: Global Health Estimates 2016. Deaths by Cause, Age, Sex, by Country and by Region, 2000-2016. Geneva, World Health Organization, 2018.
World Bank list of economies (June 2017). Washington, DC: The World Bank Group, 2017 (<https://datahelpdesk.worldbank.org/knowledgebase/articles/908519-world-bank-country-and-lending-groups>).

2016年中高收入国家前十位死亡原因



来源: Global Health Estimates 2016. Deaths by Cause, Age, Sex, by Country and by Region, 2000-2016. Geneva, World Health Organization, 2018.
World Bank list of economies (June 2017). Washington, DC: The World Bank Group, 2017 (<https://datahelpdesk.worldbank.org/knowledgebase/articles/908519-world-bank-country-and-lending-groups>).

2016年高收入国家前十位死亡原因



来源: Global Health Estimates 2016. Deaths by Cause, Age, Sex, by Country and by Region, 2000-2016. Geneva, World Health Organization, 2018.
World Bank list of economies (June 2017). Washington, DC: The World Bank Group, 2017 (<https://datahelpdesk.worldbank.org/knowledgebase/articles/908519-world-bank-country-and-lending-groups>).

发展程度	死亡数	排名 (前10)
低收入国家	75 per 100 000	3
中低收入国家	120 per 100 000	1
中高收入国家	144 per 100 000	1
高收入国家	148 per 100 000	1

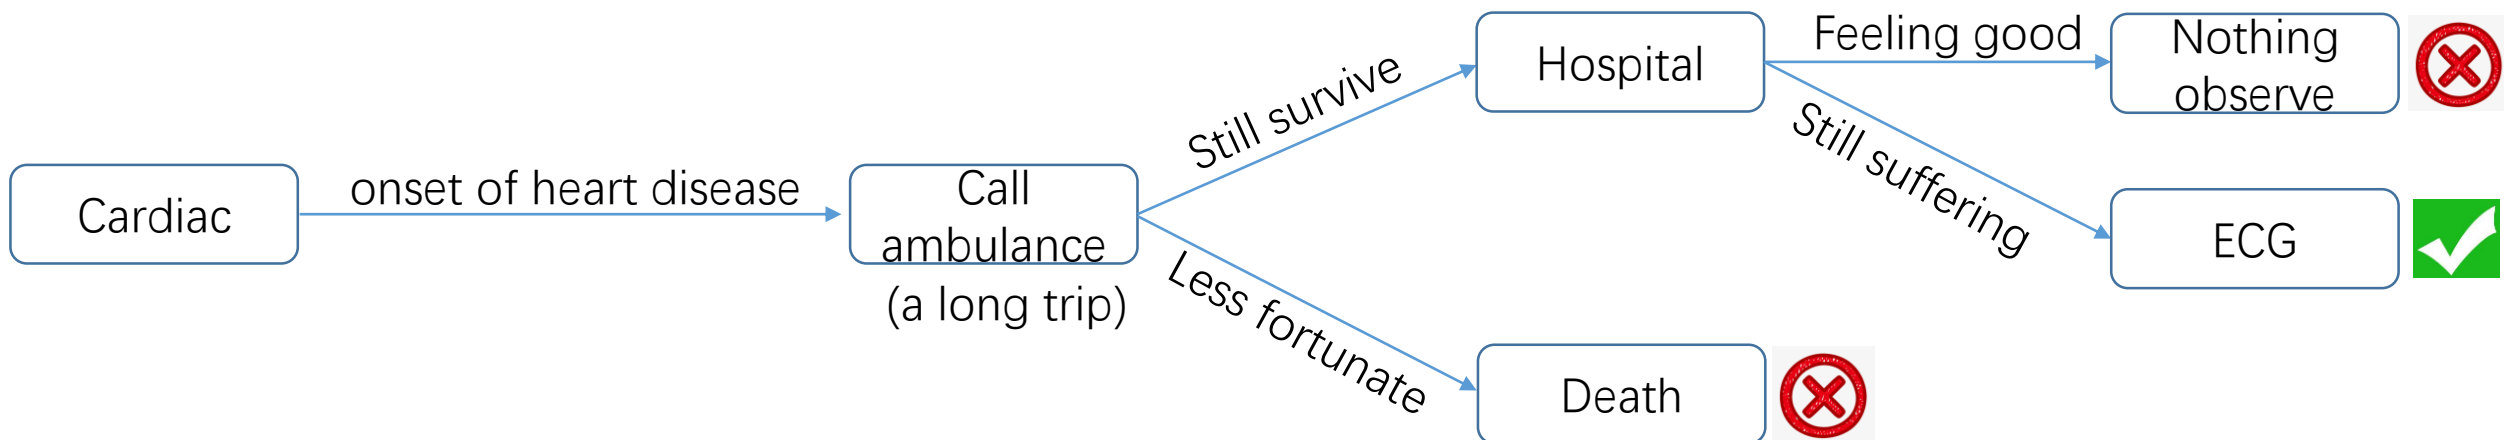
心脏病是引起死亡的一个重要原因。

4. What can we do?

为什么心脏病是人类的噩梦？

心脏病的发病特性：突发性强、死亡率高、病情隐蔽。

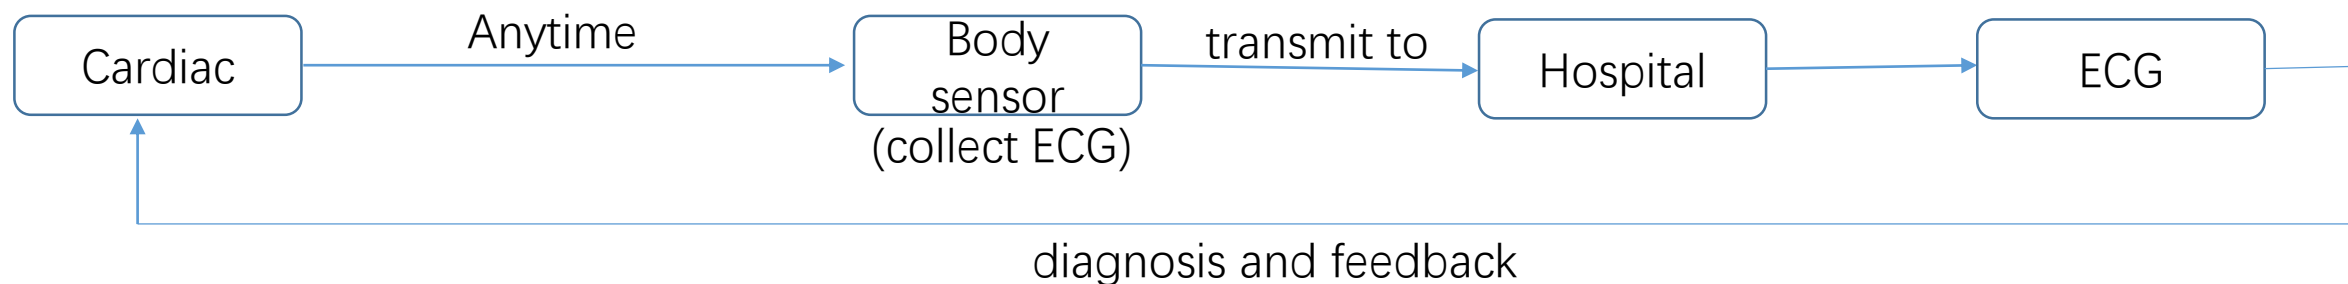
情景 1：现有的心脏病监控方式。



ECG(Electrocardiograph): 广泛用于临床心脏病诊断中，治疗心脏病的前提是能够采集到心脏病患者发病时的ECG。但是这一前提在现有心脏病监控方式下很难满足。

5. Again! What can we do?

情景 2：远程心脏病监控方式。



现有心脏病监控方式的一些很明显的缺陷：

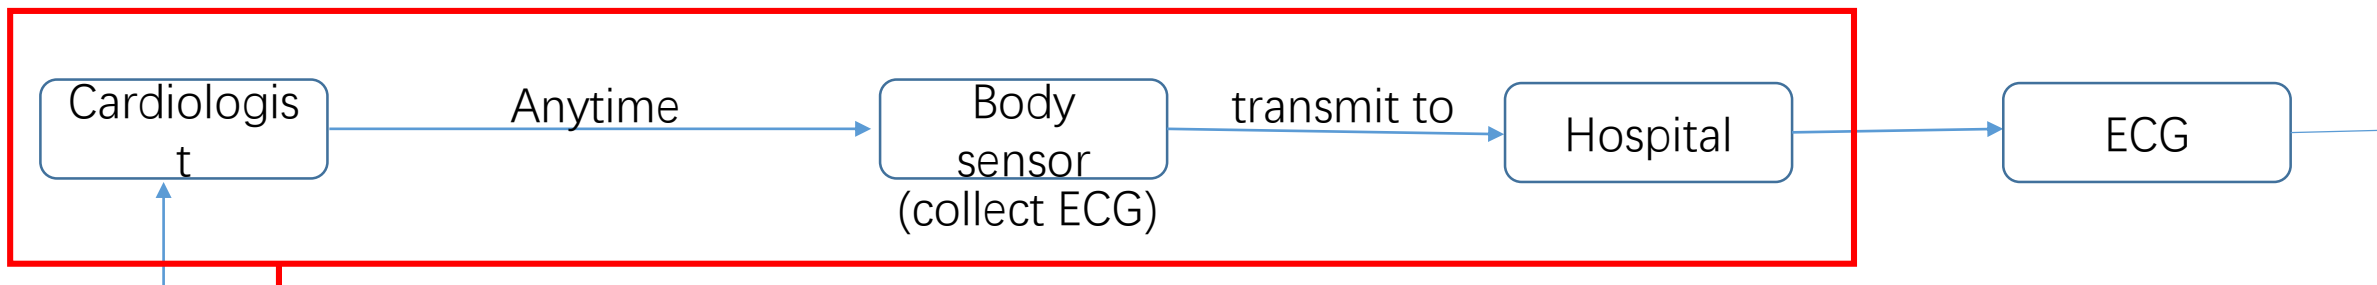
成本高

无法及时诊断


无法持续监控心脏状况

在远程心脏病监控方式
下可以改善这些问题

5. 噪声问题



现有心脏病监控方式




Static ECG(In Hospital)

diagnosis and feedback

← VS →

远程心脏病监控方式




Dynamic ECG(In Home)

← VS →


High noise

1. 远程心脏病监控系统 — 数据流向

远程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图。依赖于三个方面的发展：



(a) 采集即处理方式



(b) 采集、传输及存储

2. 远程心脏病监控系统 – 国内研究

最初的研究可追溯到清华大学在1994年提出的远程监护系统：

机构	研究	年份
清华大学	基于个人PC的远程心脏病和血压监控系统	1994
北京大学	WE CARE项目	2013
中科院	特征检测、便携式远程医疗监护系统、分类	2012
台湾大学	台湾大学附属医院远程监控中心已经部署有一整套完整的心电信号实时监控系统	2015

3. 远程心脏病监控系统 – 国外研究

在1971年就有学者提出远程监控人的生理活动信息；

在1976年正式提出远程心脏病监控系统；

在1994年将远程医疗应用到心电信号的分析；

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；

之后，在远程心脏病监控系统结构方面的研究较少。

4. 远程心脏病监控系统 – 研究热点

虽然在远程心脏病监控系统结构方面的研究较少，在远程心脏病监控系统这一研究领域中的研究仍然较多，主要分布在以下几个方面：


(1) 远程心脏病监控系统中应用，耐用（能耗），重量轻

，测量准确，移动性强，易于使

(2) 心电图QRS检测；QRS检测有重大意义。（算法研

其识别准确率对于很多心脏疾病的

(3) 远程心电监控系统中的信号传输；远程心电系统中需要将心电图从患者端传输到医院端，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。（算法研究）



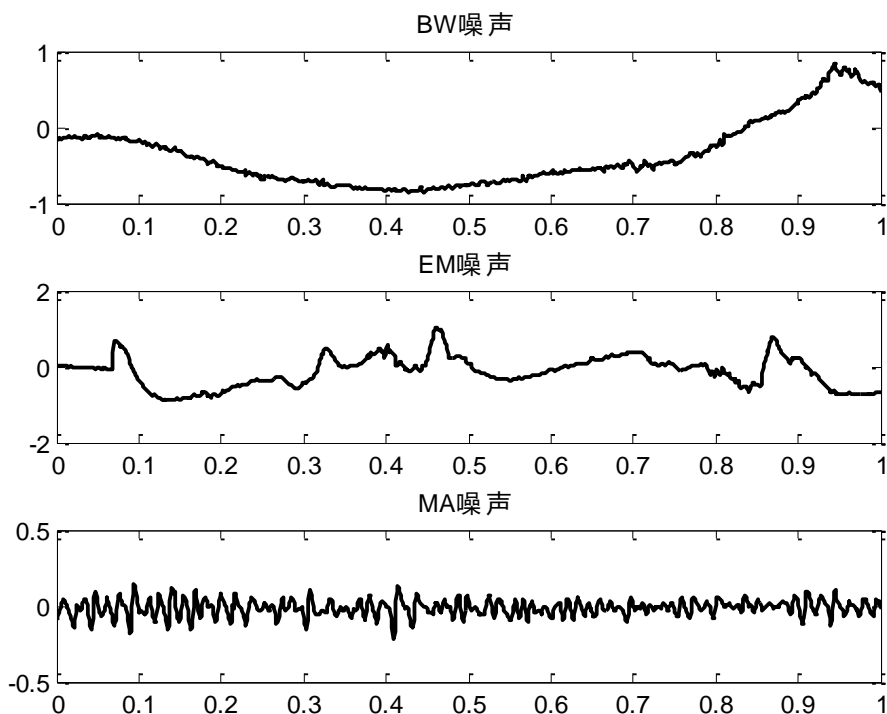
5. 心电图的降噪 – 问题描述

在远程心电监控系统中，噪声伴随着心电图的采集和传输引入，为降噪算法带来了挑战：

- (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；

6. 心电图的降噪 – 噪声类型

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）：



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接触

肌电干扰则来自肌肉等部位的收缩

7. 心电图的降噪 – 现有方法1

(1) **滤波器**；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。使用较多的滤波器有：卡尔曼滤波器（基线漂移）、自适应滤波器（多种噪声）、数字滤波器（实时降噪）。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。

(2) **小波变换**；小波变换通过伸缩平移运算对信号逐步进行多尺度细化，从而可聚焦到信号的任意细节。使用较多的方法有：离散小波变换（基线漂移）、阈值自适应小波变换（低信噪比）、平稳小波变换（较小失真）。但是扩展性较差，而且算法的有效性十分依赖母波，依靠经验选取。

(3) **Empirical Mode Decomposition (EMD)**；EMD方法将信号分解为Intrinsic Mode Functions (IMFs)，分解之后的信号在结构上简单了很多，通过处理IMFs降噪。使用较多的方法有：EMD、EEMD (Ensemble EMD)。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。

(将心电图作为一种信号数据处理，无法避免阈值选取问题)

8. 心电图的降噪 – 现有方法2

(4) 主成分分析 (PCA) ; 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。但是动态心电图中的主要成分和次要成分很难界定。


(5) 独立成分分析 (ICA) ; 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, 可处理频率与心电信号相近的噪声。但是噪声并不总是以线性、平稳的方式和心电图混在一起。

(6) 神经网络 (NN) ; 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, 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。但是通常只考虑了某种特定类型的噪声, 噪声类型改变之后需要重新训练模型, 而实际上无法提前确定动态心电图中的噪声类型, 而且动态心电图往往同时包含多种类型的噪声。

(数学变换提取心电图中的有用成分重构心电图)

10. 心电图的心律失常检测分类 – 问题描述

心电图分类一般是对心跳Beat的分类，通常需要识别心跳Beat的正异常，如果是异常Beat，那么是何种异常：



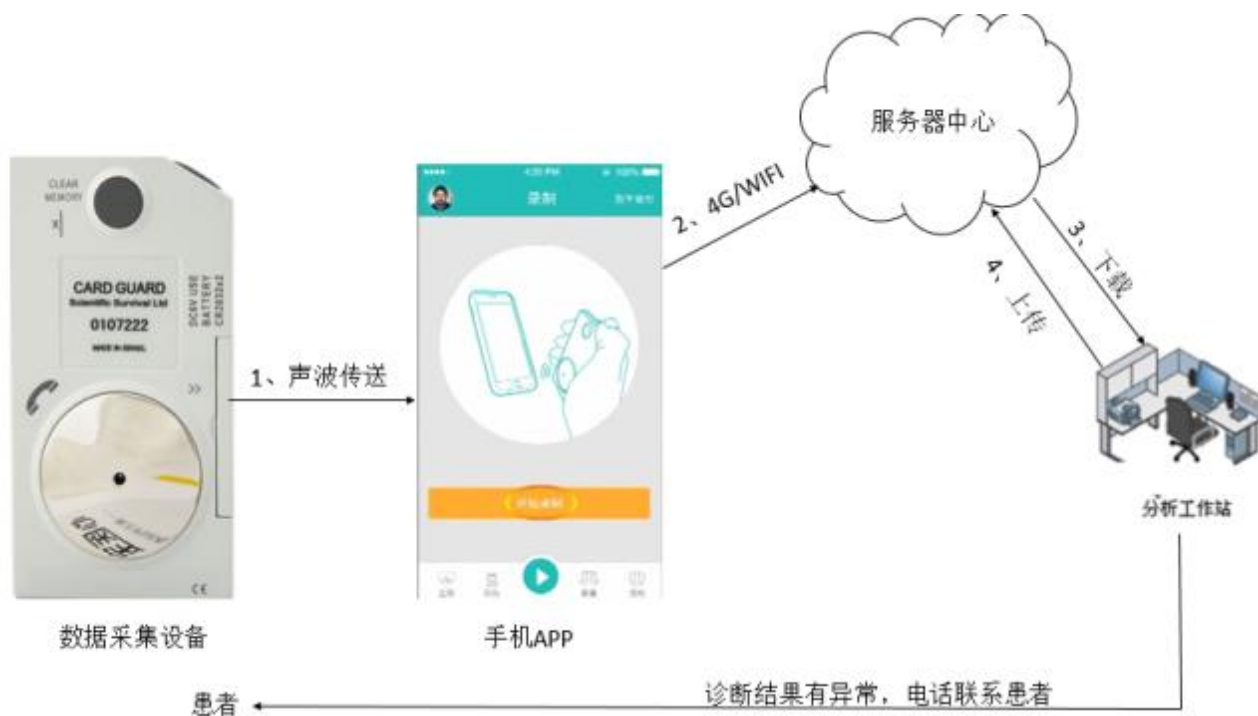
(1) ECG特征从时间的先后顺序上，依次是P波、PR间隔、PR段、Q波、R波、S波、J点、ST段、T波、ST间隔、QT间隔以及RR间隔，其中Q波、R波和S波组成QRS波群间隔。除此之外，ECG的特征还包括波形上的特征、时域特征以及频域等特征；

(2) 多数文献中心电图的心律失常检测分类准确率能够达到90%，有些甚至达到了97%、98%，但是临床诊断上准确率只有60%~70%；

9. 心电图的心律失常检测分类 – 现有研究

分类器	特征	准确率
人工神经网络 (NN)	高阶统计量特征	90%以上
支持向量机 (SVM)	RR间隔、形态学特征、高阶统计量特征、QRS波群、R波, S波和T波	95%以上
决策树和随机森林	RR间隔、波形特征	95%以上
K近邻算法 (KNN)	QRS波群、P波	93.5%以上
深度学习模型 (DNN)	自动特征提取	98.8%左右

1. 远程心电监控系统的企业级实现



(1) **心电图采集设备**；一张名片大小，却集心电图的采集和传输功能于一体，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，一次完全充电后可持续使用2年。

(2) **移动终端**；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。

(3) **云服务中心**；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。

(4) **分析工作站**；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，用户在较短时间内得到诊断结果，而人工分析依靠心电专家复核心电图自动分析结果。

2. 心电图采集设备 – 类型

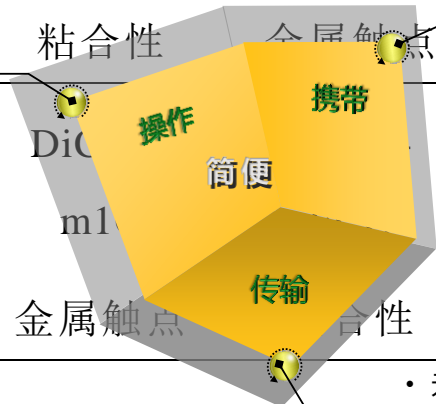


(1) 粘合性电极片；目前使用最广的一种心电图采集设备（包括医院），能够采集到静态心电图，也可包装成可穿戴设备，提供全天候的监控方式。

(2) 金属触点电极片；外观更加多样化，只需要身体的某个部位接触设备上的金属触点，不需要穿戴使用，但只能采集到动态心电图。

3. 心电图采集设备 - 商用

ECG 设备	V-Patch	Lifecare	REKA- E100	Lifestar- ACT	ECG- PEN	ECG- nano
电极片类型	粘合性 · 一键两步完成心电图数据采集与发送 · 无需电极贴片	粘合性	金属触点	粘合性 尺寸105*55*10mm, 相当于随身名片盒的大小 重量3g, 仅为一个硬币的重量	金属触点	粘合性
ECG 设备	doc@home	DiC ml		iPhone- ECG ^[138]	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 ^[139]	ELI-10 mobile	MD-100E	ECG-80A ^[140]	ECG-80 ^[140]	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



· 无论何时何地, 通过声波即可完成即时传输, 实时监控, 避免恶性事件发生
· 多渠道 (短信、邮件、APP) 获取反馈报告

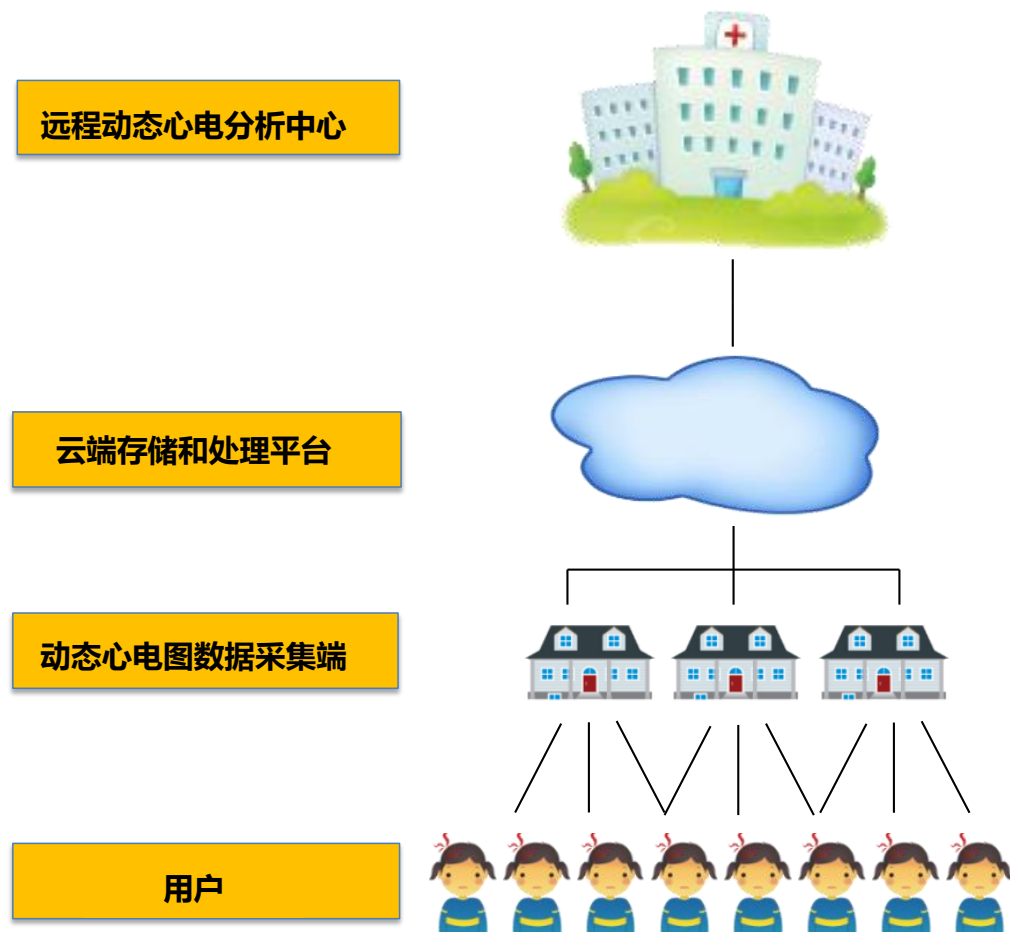
4. 云服务中心



(1) 建立以患者为中心的新型医患模式；和者息息相关的医院、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，提供成体系的服务。

(2) 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。

5. 智慧医疗体系



(1) 充分利用中心医院的专家资源和医疗设备资源;

(2) 构成了一个典型的物联网 (IoT) 系统。

6. 物联网结构的远程心电监控系统 – 数据处理

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：

(1) **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，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；

(2) **流处理模式**中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，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；

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，因此属于典型的流式时序数据处理。

6. 物联网结构的远程心电监控系统 – 计算架构

在处理物联网数据时，主要有三种计算架构，分别是云计算、雾计算以及云-雾混合计算模式：

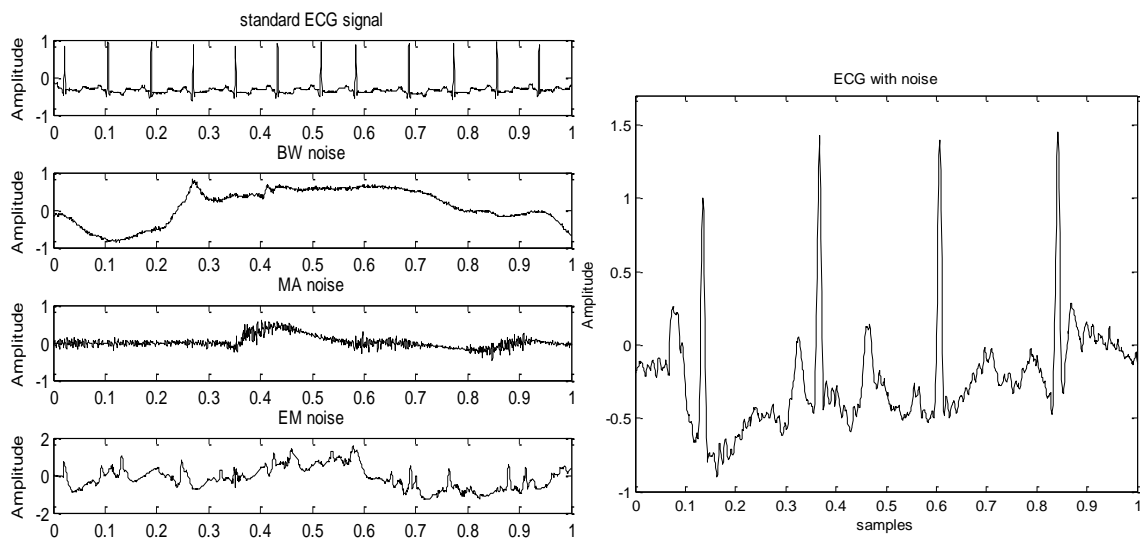
(1) **云计算模式**通过互联网按需提供计算能力、数据库存储、数据库、网络、应用程序和其他 IT 资源，用户就能随时随获得高出现有设备几十倍甚至几百倍的计算能力和存储空间，但是会因为网络的拥塞造成较大的时间开销，同时用户的隐私数据也需要一并上传到云端参与计算；

(2) **雾计算模式**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，节点数量多、分布广、节点之间的结构异构且具有流动性；

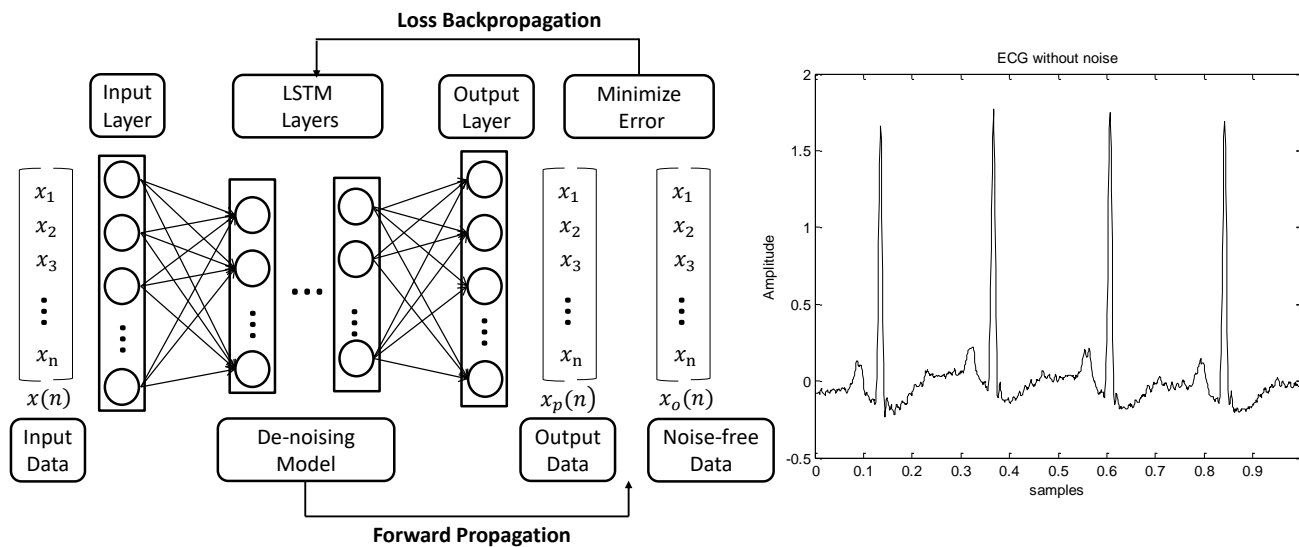
(3) **云-雾混合计算模式**综合考虑了云计算和雾计算的优缺点，让部分数据在雾节点上进行计算，最小时延的返回计算结果，另外一部分数据进一步上传到云节点上进行计算；

在这种物联网结构的远程心电监控系统中，采用的是云计算模式。

1. 多层LSTM降噪模型




数据生成




降噪模型

2. 数据生成


静态ECG





BW 噪声



MA 噪声




EM 噪声



输入数据: $x(n) = x_o(n) + a * x_{bw}(n) + b * x_{ma}(n) + c * x_{em}(n)$.

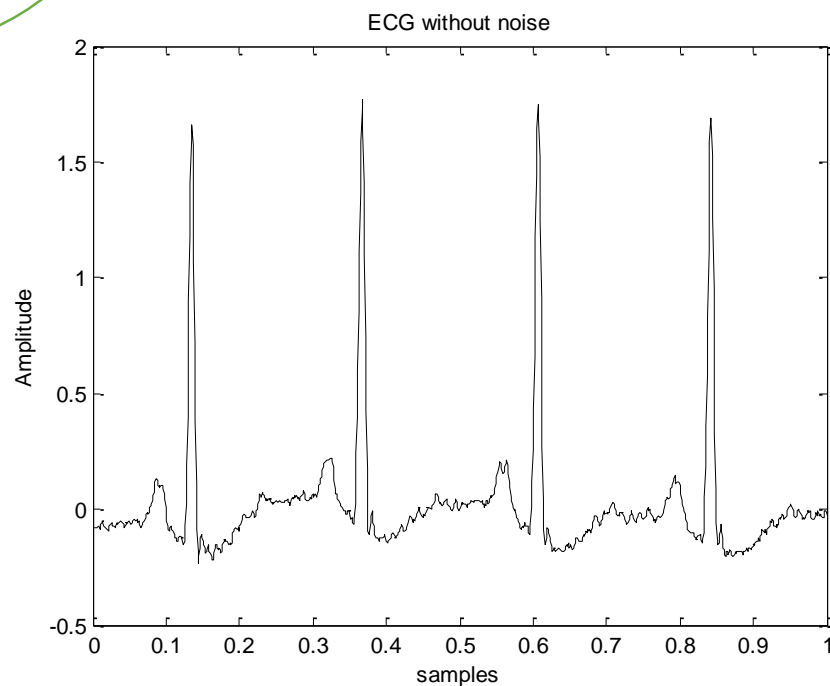
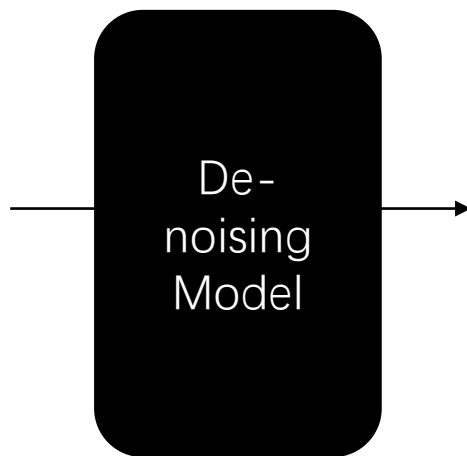
静态心电图和三种噪声数据的组合。

3. 输入&输出



动态心电图

应该学习如何从
动态心电图中重
建静态心电图。



静态心电图

4. 噪声混合分类


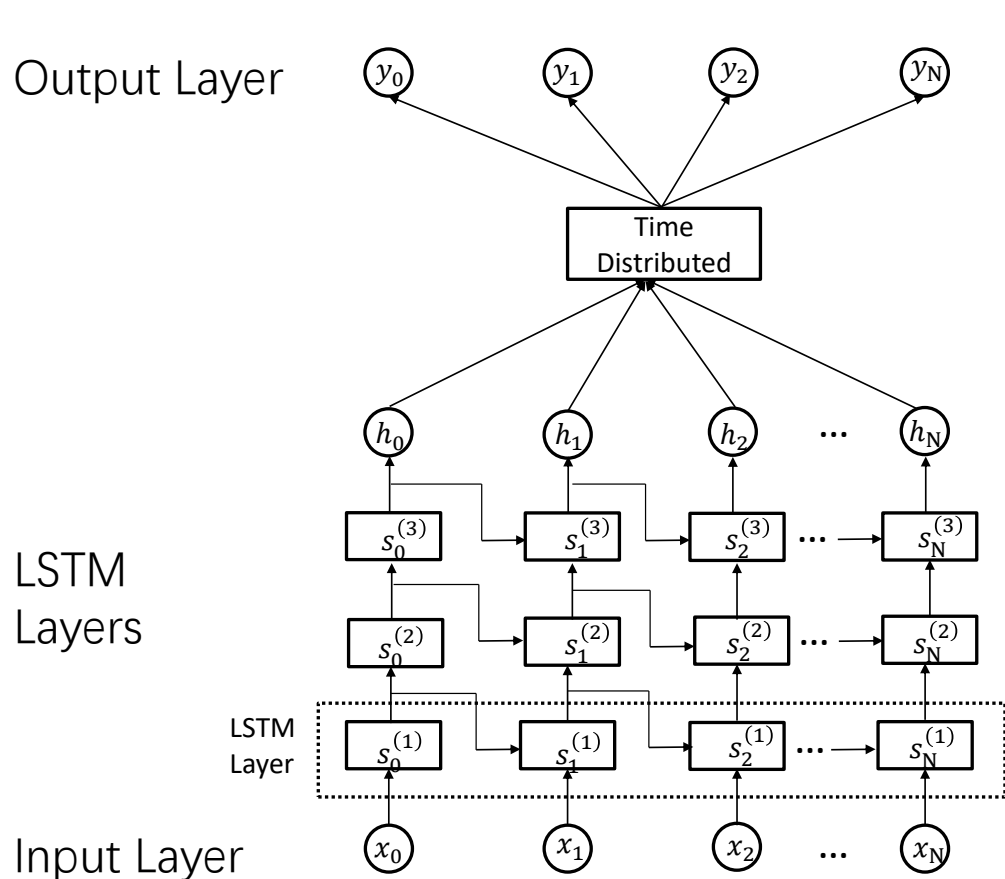
在物联网结构的远程心电监控系统中，噪声类型无法提前确定，而且心电图中可能同时包含多种类型的噪声，为了应对复杂的物联网环境，对噪声混合类型进行划分：

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

$$x(n) = x_o(n) + a * x_{bw}(n) + b * x_{ma}(n) + c * x_{em}(n).$$

通过改变比例因子来模拟产生不同混合类型的动态心电图


5. 多层LSTM降噪模型



- 心电信号可视为一种特殊的**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。
- **信息需要传递到之后的时刻**。
 - 当前神经元的状态不仅由当前的输入决定，同时由之前时刻的状态决定。

LSTM 是循环神经网络的一种变形。

5. 多层LSTM降噪模型 – 神经元



(1) 神经元（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；

(2) 遗忘门作用于上一时刻的状态单元决定需要遗忘哪些记忆；

(3) 输入门作用于上一时刻的状态单元和当前时刻的输入单元决定需要保留哪些信息；

(4) 输出门作用于当前时刻的状态单元决定需要传递哪些信息；

$$W_t^{(3)} := W_{t-1}^{(3)} - \alpha \cdot \frac{\beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot \left(\frac{\partial J}{\partial W^{(3)}} \right)^2}{1 - \beta_2^2} + \varepsilon$$

04

动态心电图的智能降噪

6. 降噪算法

- (1) 初始化; 随即初始化权值
 - (2) 前向计算;
 - (3) 计算梯度;
 - (4) 更新权值; Adam优化器
 - (5) 七类噪声混合类别降噪
- } BPTT算法

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  $\{x_o(n)\}_{i=1}^{Samples}$ ;
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:         $o_t = linear(Vh_t^{(3)});$ 
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:         $\frac{\partial J}{\partial U^{(3)}} = \sum_{t=1}^T \sum_{k=1}^t \frac{\partial h_k^{(3)}}{\partial U^{(3)}} \left( \prod_{i=k+1}^t U^{(3)^T} = diag[\tanh'(h_{i-1}^{(3)})] \right) \frac{\partial o_t}{\partial h_t^{(3)}} \cdot \frac{\partial (J_t)}{\partial o_t}$ 
14:         $\frac{\partial J}{\partial W^{(3)}} = \sum_{t=1}^T \sum_{k=1}^t \frac{\partial h_k^{(3)}}{\partial W^{(3)}} \left( \prod_{i=k+1}^t U^{(3)^T} diag[\tanh'(h_{i-1}^{(3)})] \right) \frac{\partial o_t}{\partial h_t^{(3)}} \cdot \frac{\partial (J_t)}{\partial o_t}$ 
15:    Update weights for last LSTM layer through Adam as:
16:         $W_t^{(3)} := W_{t-1}^{(3)} - \alpha \cdot \frac{\beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot \frac{\partial J}{\partial W^{(3)}}}{1 - \beta_1^t} - \frac{\beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot \left( \frac{\partial J}{\partial W^{(3)}} \right)^2}{1 - \beta_2^t} + \varepsilon$ 
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

```


7. 降噪算法的优势

和物联网复杂环境对降噪算法的挑战相对应:

- 滤除噪声的同时保留心电图中的病理特征.
 - 将噪声信号和心电信号一并作为时序数据考虑;
 - 降噪模型从海量数据中学习哪些信息需要保留, 哪些信息需要遗忘.
- 不依赖于人为设定的阈值.
 - 很难找到一个精确的阈值区分噪声信号和心电信号;
 - 多层LSTM模型自适应、自学习的调整模型的权值.
- 对噪声不敏感.
 - 噪声混合类型划分;
 - 降噪算法没有限定噪声类型, 而是将算法直接应用于七种类型的噪声混合类型;

8. 实验

主要实验评价指标：RMSE和SNR

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

损失函数：均方误差

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


9. RMSE & 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

(1) RMSE; 类别1~类别7下的RMSE均在0.03左右, 说明降噪模型对噪声是不敏感的, 模型能够在不重新训练的前提下直接应用于七种噪声混合类型的降噪中;

(1) SNR; 类别1~类别7下的SNR提升在40db左右, 而且降噪前心电图的SNR越低, 模型取得的SNR提升越大, 在类别7下, 模型取得了55db的SNR提升, 远远高于现有降噪方法。

10. 心电图重建 - 单一噪声

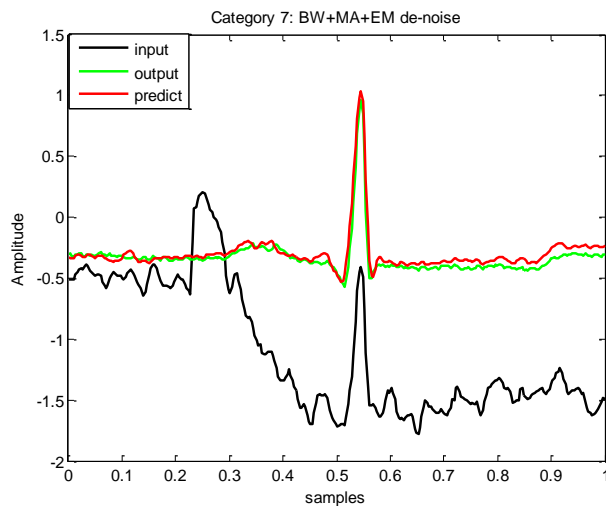





黑线对应动态心电图。(降噪模型的输入)

绿线对应Ground-truth。(降噪模型的输出)

红线对应重建的心电图。(降噪的预测模型)

11. 心电图重建 - 多种噪声




(1) 动态心电图和静态心电图之间存在巨大差异

(2) 模型重建的心电图和静态心电图几乎一直

(3) 噪声类型发生改变或多种噪声同时存在时, 模型仍能高质量的重建心电图

12. 对比分析 -- RMSE




(1) 对比方法皆仅考虑了单种噪声存在的情形，没有考虑多种噪声同时存在的复杂情形

(2) 深度神经网络方法明显优于其他方法

(3) 当噪声类型发生改变时，自编码器模型需要重新训练模型

13. 对比分析 – SNR提升





(1) 对比方法皆仅考虑了单种噪声存在的情形，没有考虑多种噪声同时存在的复杂情形

(2) 对比方法皆应用在噪声干扰较小的场景，动态心电图的SNR在0db~5db间

(3) 第3类噪声类别下，SNR提升达到53db，远远高于对比方法

1. 心律失常检测分类 – 问题描述

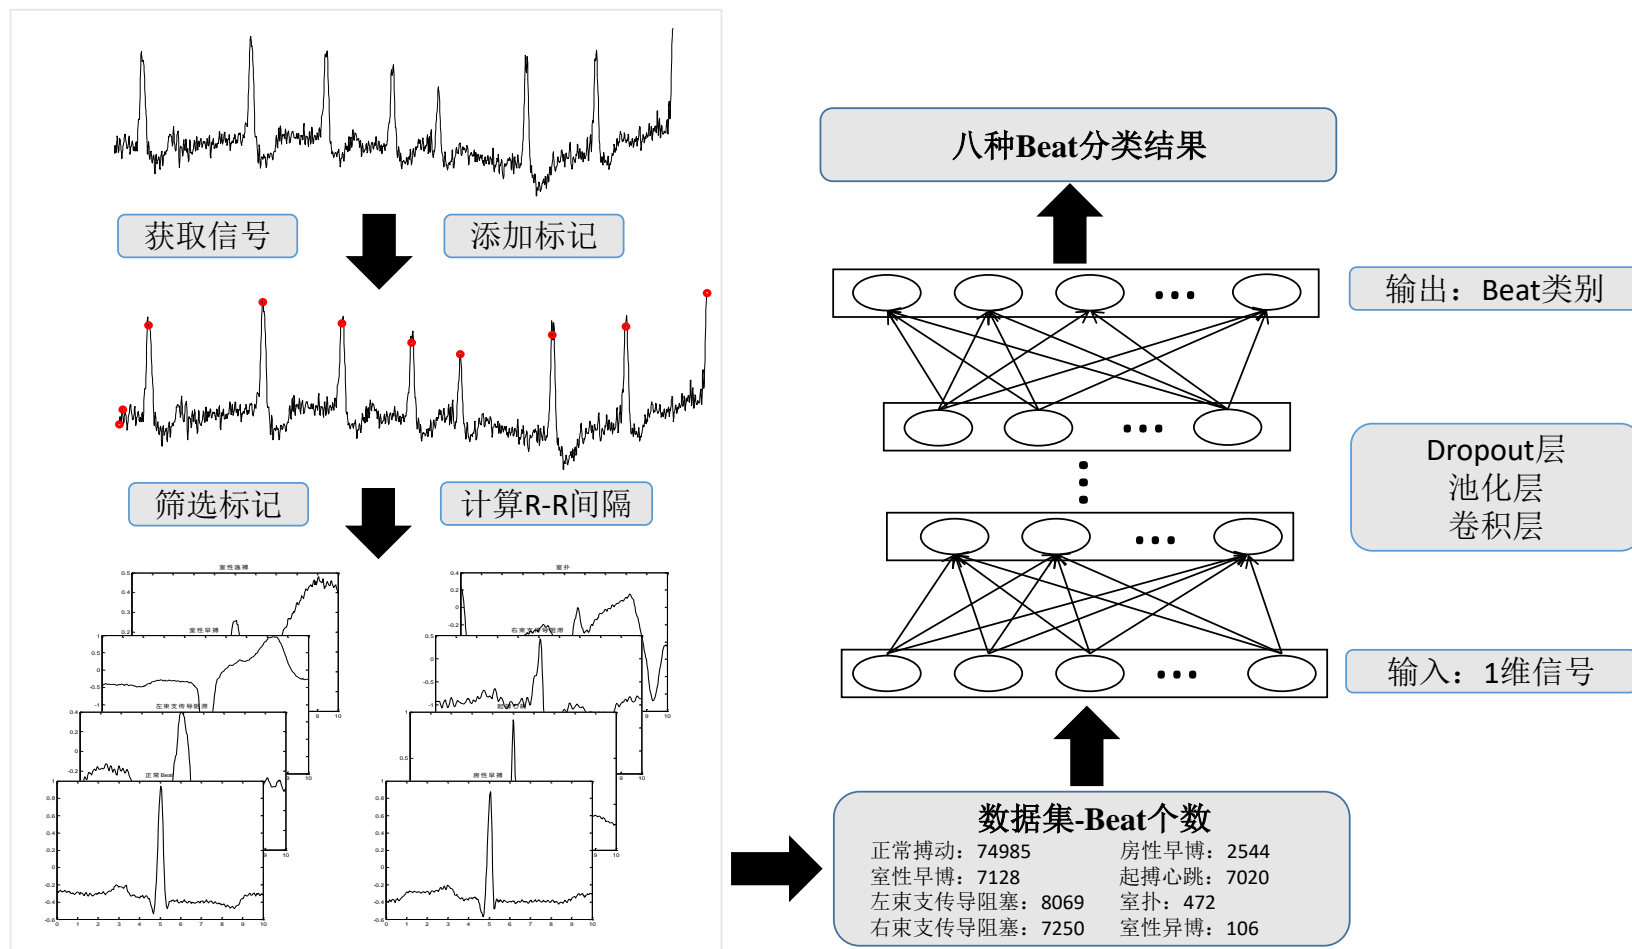
心律失常自动检测分类的基本数据对象通常有两种，分别是以心跳Beat为基本对象和以ECG片段为基本对象：



(1) 心跳Beat; 依赖精确的R波峰值, 但是结构清晰;

(2) ECG片段; 每隔2s或者5s截取一段连续的ECG信号, 但是心跳Beat的分布极不均匀;

2. 1-D CNN分类模型



3. 数据集说明 – MIT-BIH

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

(1) MIT-BIH; 数据集由两位专业医师标记, 标记可信度高;

(2) 标记; 标记共有23类;

(3) 提取八类心跳Beat; 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)。

4. 心跳Beat提取 – 算法1

虽然能够提取到八类心跳 Beat, 但是存在缺陷:

(1) 需要手工剔除不合理的R-R间隔

(2) 平均R-R间隔不准确; 没有区分标记类型

(3) 提取出的心跳Beat不是等长的

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;

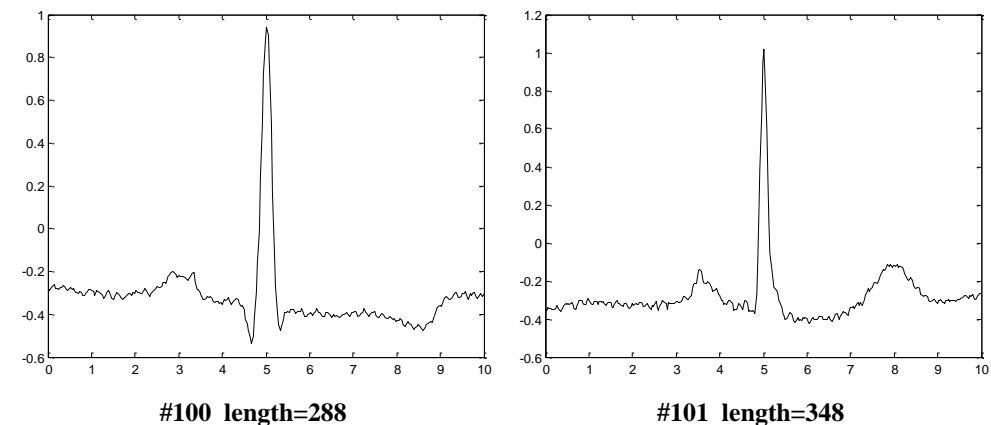
20: ...

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;

5. 不等长心跳Beat



(1) 算法1只能提取到不等长的心跳Beat



(2) 虽然可以通过三次采样差值得到等长的心跳Beat，但是心电图的波形在时域上的特性被改变了，而波形出现的时间先后与心律失常紧密相关

6. 心跳Beat提取 – 算法2

(1) 虽然标记多达23类，但是感兴趣的只有8类标记，直接处理感兴趣的标记，而不是处理每一个标记；

(2) 只根据感兴趣的标记计算平均R-R间隔，提取到等长的心跳Beat；

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;

```


7. 心跳Beat数据集

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


(1) 心跳Beat一共有107574个;

(2) 所有心跳Beat的长度均为289;


8. 八类心跳Beat




N




A



V




/




L



R



!



E

9. 心律失常自动检测模型

(1) 考虑物联网环境常常是计算资源、存储资源和电力资源等硬件资源受到严格限制，引入1-D CNN模型；

(2) 采用Xavier初始化方法；

(3) 选择了较小尺寸的1维卷积核1*3；

(4) Relu激活函数不仅形式简单，且收敛速度快；

(5) 最大池化能够减少特征提取过程中的均值偏移问题，突出特征，从而更多的保留心电信号中的纹理信息；

(6) Dropout层；

	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	

10. 评价指标

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)

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

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall}$$


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

AUC值 (ROC曲线下方面积)


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

11. 模型训练


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：



Loss变化曲线；1000个steps开始收敛




F1变化曲线；




Accuracy变化曲线；

13. ROC曲线




8类平均ROC曲线, AUC=0.99



8类ROC曲线

14. 对比分析 – 降噪前后



带噪数据集的Loss变化曲线；4000个steps开始收敛，收敛变缓

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


带噪数据集上各个指标值均下降

15. 对比分析 – 降噪前后2


	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

带噪数据集的混合矩阵中，识别错误的数量明显增多

15. 对比分析 – 降噪前后3



带噪数据集的平均ROC曲线，AUC值略有下降



带噪数据集的8类ROC曲线，AUC值均略有下降

16. 对比分析 – 现有方法

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

(1) **远程心电监控系统**；从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，结合云平台后，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。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。

(3) **心电图的心律失常检测分类**；引入了1-D CNN分类模型，在数据预处理部分分别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了等长的8类心跳Beat。在分类部分直接将心电图作为1维信号数据考虑，在Accuracy、Precision、Recall、F1-score以及AUC各项指标上均优于现有方法。同时对带噪的心跳Beat也进行了实验，经过约4000个step的训练后，分类模型在各项指标上也取得了较好的效果。

THANK YOU

请各位专家批评指正