



(12)发明专利申请

(10)申请公布号 CN 109864714 A

(43)申请公布日 2019.06.11

(21)申请号 201910267888.8

(22)申请日 2019.04.04

(71)申请人 北京邮电大学

地址 100087 北京市海淀区西土城路10号

(72)发明人 袁学光 张阳安 汪萃萃

(74)专利代理机构 北京迎硕知识产权代理事务所(普通合伙) 11512

代理人 吕良 张群峰

(51)Int.Cl.

A61B 5/00(2006.01)

A61B 5/04(2006.01)

A61B 5/0402(2006.01)

权利要求书2页 说明书7页 附图4页

(54)发明名称

一种基于深度学习的心电信号分析方法

(57)摘要

一种基于深度学习的心电信号自动分析处理方法，包括对原始心电信号进行预处理、切分定长波形以将心电信号数据整理成多个维度一致的向量以及通过全连接神经网络或全卷积神经网络的深度学习模型对整理获得的数据进行训练的操作步骤，最终可以全面准确地输出不同的心电指标类别。通过该方法能够减少医生在判读时的工作量，帮助医生提高判读的准确率，成为医生诊断心脏病疾患的重要辅助方案。



1. 一种基于深度学习的心电信号分析方法,其特征在于,包括如下步骤:
 - (1) 对原始心电信号进行预处理;
 - (2) 切分定长波形,以将心电信号数据整理成多个维度一致的向量;
 - (3) 通过深度学习模型对步骤(2)中整理获得的数据进行训练,输出不同的心电指标类别;

其中,所述步骤(3)中的深度学习模型为全连接神经网络或全卷积神经网络。
2. 根据权利要求1所述的心电信号分析方法,其特征在于,所述步骤(1)中的预处理进一步包括如下步骤:
 - (1-1) 对原始心电信号进行降噪处理;
 - (1-2) 对数据幅度做最大最小归一化。
3. 根据权利要求2所述的心电信号分析方法,其特征在于,所述降噪处理包括对不同种类的噪声使用不同的处理方法:

针对工频干扰采用数字滤波系统进行降噪;

针对基线漂移引起的噪声采用滑动平均方法进行处理;

针对表面肌电噪声使用最小二乘多项式拟合的方法处理。
4. 根据权利要求2或3所述的心电信号分析方法,其特征在于,所述步骤(1)中还包括对信号的连续性做分析和处理。
5. 根据权利要求1所述的心电信号分析方法,其特征在于,所述步骤(2)中还包括如下步骤:
 - (2-1) 定位一个QRS波的波峰;
 - (2-2) 截取此波峰后连续定长时间的数据点。
6. 根据权利要求5所述的心电信号分析方法,其特征在于,所述步骤(2-2)中的定长时间为1秒、2秒、3秒或4秒。
7. 根据权利要求1所述的心电信号分析方法,其特征在于,所述全连接神经网络模型包括输入层、四层隐藏层、Max pooling层、Dropout层、Batch Normalization层和输出层;

其中,输入层神经元数目依据所述步骤(2)整理的数据向量维度而定;

在第二层和第三层隐藏层中间添加一个Max pooling层,在第四层隐藏层和输出层之间添加Max pooling层、Dropout层以及Batch Normalization层。
8. 根据权利要求7所述的心电信号分析方法,其特征在于,所述隐藏层的神经元个数为2的次幂。
9. 根据权利要求8所述的心电信号分析方法,其特征在于,四个隐藏层的神经元个数分别为256、128、64和32。
10. 根据权利要求1所述的心电信号分析方法,其特征在于,所述全卷积神经网络模型包括输入层、六层卷积层、Max pooling层、Dropout层、Batch Normalization层和输出层;

其中,输入层神经元数目依据所述步骤(2)整理的数据向量维度而定;

每两层卷积层之间添加一个Max pooling层,在最后的卷积层和输出层之间添加Dropout层和Batch Normalization层。
11. 根据权利要求10所述的心电信号分析方法,其特征在于,六层卷积层的卷积核大小分别依次为7、7、5、5、3和3,六层卷积层的卷积核个数分别依次为128、128、64、64、32和32。

12.根据权利要求1-11任一项所述的心电信号分析方法，其特征在于，所述心电指标类别包括心律值、心律不齐率、心律值低于60次每分的比率、心律值超过120次每分的比率、PR间期超过0.2s、P波畸形和QRS波宽大畸形。

一种基于深度学习的心电信号分析方法

技术领域

[0001] 本发明涉及心电图的分析与处理。具体而言，涉及一种基于深度学习的心电信号自动分析处理方法。

背景技术

[0002] 近几年来，心血管疾病已经成为全球人类的主要死亡原因之一，然而这类疾病往往急发或突发，为医院进行诊断造成了极大的困难。而心电图能够反应人体心脏的健康状况，在临幊上被广泛用于心血管疾病的前期诊断，至今仍是医院诊断心血管疾病的主要方式。因此，对于心电图信号进行更加精准的分析成为了治疗及预防与心脏相关疾病的重要手段。

[0003] 目前已经有许多科研工作者基于心电图信号做了大量的研究，医生基于心电图中的各种波段信息能够做出越来越多的诊断。例如在“冠心病心绞痛心电图检查及其价值分析，曾莲，《陕西医学杂志》，2017年1月第46卷第1期”中，依据心电图数据，基于心电信号中ST段改变、T波异常、心率、心律等信息可以对冠心病心绞痛做初期判断，其敏感性可达83.5%。

[0004] 心电图中包含了各种波形，一次心动周期就会在心电图上记录出一系列的波形，例如包括P波、QRS波群、T波，各个波形之间都有一定时间的记录是在等电位线上的，因而心电图中还包括P-R间期、S-T段、Q-T间期，上述这些数据信息都是医生进行诊断的重要参考。

[0005] 然而，随着心电图数据量的剧增，心电图数据的判读给医生们每天带来巨大的工作量。而且很多心电监测仪还容易受到外界噪音的干扰，这进一步增加了医生对心电图数据信息判读的难度。

发明内容

[0006] 针对上述现有技术中的不足，本发明提出一种基于深度学习的心电信号自动分析处理方法，通过该方法能够减少医生在判读时的工作量，帮助医生提高判读的准确率，成为医生诊断心脏病疾患的重要辅助方案。所述方法具体包括如下步骤：

[0007] (1) 对原始心电信号进行预处理；

[0008] (2) 切分定长波形，以将心电信号数据整理成多个维度一致的向量；

[0009] (3) 通过深度学习模型对步骤(2)中整理获得的数据进行训练，输出不同的心电指标类别；其中，所述步骤(3)中的深度学习模型为全连接神经网络或全卷积神经网络。

[0010] 由于心电信号很容易受到噪声的影响，且噪声来源主要为几个类别，因此，所述步骤(1)中的预处理进一步包括对原始心电信号进行降噪处理和对数据幅度做最大最小归一化两个步骤。进一步所述降噪处理包括对不同种类的噪声使用不同的处理方法：针对工频干扰采用数字滤波系统进行降噪；针对基线漂移引起的噪声采用滑动平均方法进行处理；针对表面肌电噪声使用最小二乘多项式拟合的方法处理。同时，考虑到数据采集过程中可能会出现采集设备脱落，导致所采集的信号出现中断的情况，因此所述步骤(1)中还可以包

括对信号的连续性做分析和处理。

[0011] 对于深度学习模型来说由于需要保证每一条输入样本的维度一致,因此所述步骤(2)中还包括如下步骤:定位一个QRS波的波峰;截取此波峰后连续定长时间的数据点。其中因为QRS波峰在波形中表现的较为突出,处于整段波形中的最高位置,更易检测识别出来,因此选择QRS波的波峰进行定位。进一步,所述定长时间可以通过实验进行确定,例如为1秒、2秒、3秒或4秒。

[0012] 进一步,为了获得全面准确输出结果,对所述全连接神经网络和全卷积申请网络进行了专门的设计。其中,所述全连接神经网络模型包括输入层、四层隐藏层、Max pooling层、Dropout层、Batch Normalization层和输出层;其中,输入层神经元数目依据所述步骤(2)整理的数据向量维度而定;并且在第二层和第三层隐藏层中间添加一个Max pooling层,在第四层隐藏层和输出层之间添加Max pooling层、Dropout层以及Batch Normalization层。优选地,所述隐藏层的神经元个数为2的次幂,例如四个隐藏层的神经元个数分别为256、128、64和32。而所述全卷积神经网络模型包括输入层、六层卷积层、Max pooling层、Dropout层、Batch Normalization层和输出层;其中,输入层神经元数目依据所述步骤(2)整理的数据向量维度而定;并且每两层卷积层之间添加一个Max pooling层,在最后的卷积层和输出层之间添加Dropout层和Batch Normalization层。优选地,六层卷积层的卷积核大小分别依次为7、7、5、5、3和3,六层卷积层的卷积核个数分别依次为128、128、64、64、32和32。

[0013] 采用上述深度学习模型可以准确地输出包括如下心电指标的类别:心律值、心律不齐率、心律值低于60次每分的比率、心律值超过120次每分的比率、PR间期超过0.2s、P波畸形和QRS波宽大畸形。

[0014] 与现有技术相比,本发明的技术方案具有如下的技术效果:

[0015] 1、得出的结果全面且准确,能够有效降低环境噪音或者病人个体差异带来的干扰;

[0016] 2、方法能够使用GPU进行并行计算实施,在分析处理速度上有很大提升,能够满足大规模应用中对得出诊断辅助信息速率的要求;

[0017] 3、方法基于深度学习,不需要进行人工提取特征,减少了心电图数据处理过程的复杂度;

[0018] 4、所采用的神经网络结构在经过大量真实可靠的原始数据学习训练之后,具有较强的可移植性,可进行广泛应用。

附图说明

[0019] 图1:基于深度学习的心电信号分析处理技术方案框图;

[0020] 图2:原始心电信号波形图;

[0021] 图3:切分定长波形示意图;

[0022] 图4:全连接神经网络结构示意图;

[0023] 图5:全连接神经网络详细结构示意图;

[0024] 图6:卷积神经网络详细结构示意图;

[0025] 图7:卷积神经网络结构示意图。

具体实施方式

[0026] 随着计算机技术和算法的发展,计算机辅助诊断技术越来越多地被融入到医疗领域方面中,适用于各种医疗数据的算法和模型不断被提出,这对实现分级诊疗,合理配置医疗资源等有重大意义。对于患者来说,可以更快速地实现健康检查,获得更为精准的诊断结果和更好的个性化治疗方案建议;对于医师来讲,则可以消减诊断时间,降低误诊的概率;对于医疗体系来说,人工智能则可以提高各种准确率,同时系统性降低医疗成本。

[0027] 本发明将人工智能、计算机辅助技术引入到心电图数据信息的分析处理当中,提出基于深度学习的心电信号分析处理方法。本方法模型结构简单,分析结果全面可靠。利用大量真实数据对模型进行训练与学习,最终获得稳定有效的模型,具有较强的可移植性。

[0028] 参见说明书附图1所示,本发明提出的一种基于深度学习的心电信号分析处理方法主要包括:降噪与归一化、切分定长波形、搭建深度学习模型、获得心电指标分析结果并输出。以下将详细说明上述各个操作步骤。

[0029] 1) 降噪与归一化

[0030] 心电信号是体表的电生理信号,一般比较微弱,同时,其不仅是随机的,而且是非平稳的,幅度在 $10\mu\text{V} \sim 4\text{mV}$,频率为 $0.05 \sim 100\text{Hz}$,参见说明书附图2。由于心电信号是十分微弱的,而且人体自身也是十分复杂的系统,各自系统对于心电信号的捕捉也会产生一定的影响,因此信号容易受到噪声干扰。同时,在心电图检测过程中极易受到各种噪声源的干扰,从而使图像质量变差,使均匀和连续变化的心电数值产生突变,在心电图上形成一些毛刺。这使得原本就很微弱的信号更难和噪声进行分解。根据最近研究表示,正常心电信号范围在 $0.05\text{--}100\text{Hz}$ 之间,90%的心电信号(ECG)频谱能量是集中在 $0.25\text{--}35\text{Hz}$ 之间,这也使得我们想要采集出有效的心电信号肯定会受到大量噪音的干扰。研究表明,这些噪音的来源往往以下几种:工频干扰、电极接触噪声、人为运动、肌电干扰、基线漂移和呼吸时ECG幅值的变化、信号处理中用电设备产生的仪器噪声等。因此,对于心电图数据的预处理,首先需要降低噪声。针对不同的噪声干扰,需要采用不同的噪声消除方法,如滤波法,SVD重构信号法,平滑法等。同时,考虑到数据采集过程中可能会出现采集设备脱落,导致所采集的信号出现中断的情况,还需要对信号的连续性做分析和处理。

[0031] 对于不同的噪声来源选择不同的降噪方法来处理,以下一些实施例将作为优选。

[0032] 由于心电图机等心电检测仪器所使用的工业供电会产生电磁场,作用于人体自身所形成的分布电容之上,会导致测量的心电信号产生频率为 50Hz 的噪声污染。由于心电信号本身比较微弱,有时这种干扰信号的能量会是心电信号的成百上千倍,这将严重影响心电信号的获取。但是,由于工频干扰频率较为固定,因此基于这一特性该噪声也比较容易消除,例如可以采用带通数字滤波系统进行消除。因此,想要去除心电信号中的工频干扰,优选对心电信号进行带通滤波,滤除 50Hz 的干扰信号。这就需要做好前端数据采集的软硬件设备的设计,使得其能够稳定的对心电信号进行滤波,从而保证心电数据的可靠和准确。具体心电信号通过多路输入缓冲器缓冲放大,然后通过导联选择后再交由前置多路电压放大,并使其适应A/D转换的幅度要求,从而进行数字滤波处理,并最终输出滤波后的心电信号。数字滤波有很多优点,不仅仅能够大幅度的提高设备的性能,同时其适应性也十分强大,不同的使用环境均能够通过设置软件参数来完美适应,大大降低了医疗设备的成本,提高了通用性能。

[0033] 而针对基线漂移,其主要是由于测量电极在测量过程中和人体产生相对位移而产生的,例如人在自然情况下的呼吸、肢体抖动都会产生基线漂移,其频率十分低,一般在0.15~0.3Hz之间。由于90%的心电信号(ECG)频谱能量集中在0.25~35Hz之间,这也使得上述噪声与心电信号的波段分量相接近,因此可以采取滑动平均方法来滤除基线漂移。滑动平均法又称移动平均法,是在简单平均数法基础上,通过顺序逐期增减新旧数据求算移动平均值,借以消除偶然变动因素,找出事物发展趋势,并据此进行预测的方法。滑动平均法重在实现“重近轻远”的原则,对数据加以不同的权重,近期数据给予较大权数,远期数据给予较少的权数,目的在于强化近期数据的作用,弱化远期数据的影响。滑动平均法最主要特点在于简捷性。它相对于其它动态测试数据处理方法而言,算法很简便,计算量较小,尤其可采用递推形式来计算,可节省存储单元,快速且便于实时处理非平稳数据等。

[0034] 表面肌电噪声是人的肌肉神经系统在运作时,出现肌肉纤维收缩而引起的生物电的变化,在捕捉心电信号时,心电电极会引起此噪声的出现,肌电噪声的出现是不定时不规则的,其波形一般较为快速且不规则,从属于高频噪声,其频率一般集中在5~40Hz之间,持续时间为50ms,其幅度为毫伏级。对表面肌电噪声的处理可以使用最小二乘多项式拟合方法。最小二乘法(又称最小平方法)是一种数学优化技术。它通过最小化误差的平方和寻找数据的最佳函数匹配。利用最小二乘法可以简便地求得未知的数据,并使得这些求得的数据与实际数据之间误差的平方和为最小。最小二乘法可用于曲线拟合,对给定数据点集合 $\{(X_i, Y_i)\} (i=0, 1, 2, 3, 4 \dots m)$,在取定的函数类 φ 中,求 $P(x) \in \varphi$,使误差的平方和 E^2 最小, $E^2 = \sum [p(X_i) - y_i]^2$ 。从几何意义上讲,就是寻求与给定点集 $\{(X_i, Y_i)\} (i=0, 1, 2, 3, 4 \dots m)$ 的距离平方和为最小的曲线 $y=p(x)$ 。函数 $p(x)$ 称为拟合函数或最小二乘解,求拟合函数 $p(x)$ 的方法称为曲线拟合的最小二乘法。具体例如将固定个数的测试点合并在一起从而形成一个多项式,在这个多项式中,多项式在 x_i 的值给出光滑值 g_i 。一个M次多项式用 $P_i(x)$ 表示,它在最小二乘意义下拟合 n_L+n_R+1 个点,其中 n_L 为 x_i 左边点的个数, n_R 为 x_i 右边点的个数,这样就有 $g_i=P_i(x)$ 。实施例中将每一个采样点前后7个采样点进行近似值计算,测试数据频率为250Hz, $n_L=n_R=7$,令 $M=4$ 。据具体测试可以实现对高频段肌电噪声进行较为明显的抑制。

[0035] 经过上述降噪处理后,对原始数据幅度做最大最小归一化。这样可以保证在训练过程中模型收敛的更快。

[0036] 2) 切分定长波形方法

[0037] 在模型的训练阶段,需要对每一条训练样本分别输入,让模型学习其中的关联知识。而每一条样本所组织的形式在模型的角度看来,就是一系列的数字,例如心电信号对于模型来说其实是一串数字,也称为向量,其中数字的个数表示向量的维度。由于本方法设计的深度神经网络包含了全连接网络,网络结构确定之后,每一层所包含的神经元的个数便确定了,而每一个神经元最终对应的是数据的一个维度,这也就是说所能接受的样本的维度也就确定了。所以需要保证每一条输入样本的维度一致。在本方法中,输入为心电信号序列,因此要求序列长度一致。

[0038] 心电信号的每个周期的形态基本一致,其中QRS波峰在波形中表现的较为突出,处于整段波形中的最高位置,更易检测识别出来。因此,针对整条心电信号,首先定位一个QRS波的波峰,然后取此波峰后连续定长时间的数据点。而如果选择其他波形结构,由于波动性较小,且心电信号也易受到干扰,这就导致这些波形结构识别时较为困难,容易造成错误识

别,产生错误的输入样本,最终导致模型的输出不准确。

[0039] 具体上述定长时间的时间长度可以选择1秒、2秒、3秒和4秒,最终通过实验确定合适的数据长度,参见附图3所示。由于心电信号是一个周期信号,每个周期所包含的信息基本一致,所以只需要保证样本至少包含了一个周期的波形即可,具体的时间长度可以从设计实验来确定。针对具体的模型结构,设计3组实验,所有模型参数设置一致,针对同一批训练数据,分别产生长度为1秒,2秒,3秒和4秒的四组训练数据,由于本实验数据采样率为250Hz,也就是数据长度分别为250点,500点,750点和1000点,输入模型中进行训练,再使用同一批测试数据做测试,得出结果,如下表1所示。从实验结果可以看出,2秒和3秒的数据,也就是500点和750点的训练数据长度的效果较好。而1秒和4秒的数据长度则在训练集精度和测试集精度上都表现不佳,有可能是数据过于短导致包含信息不够,或者过于长导致信息冗余。

[0040] 表1切分定长波形时间选择实验数据

[0041]

数据长度(数据点)	测试集精度	训练集精度
250	0.55	0.68
500	0.62	0.78
750	0.61	0.77
1000	0.42	0.43

[0042] 3) 深度学习模型

[0043] 深度学习模型在许多应用中都取得了不错的效果。由于本例中的数据为心电信号,是一个序列信号,与全连接模型的结构和一维全卷积结构相吻合,因此本发明中对于深度学习模型设计了两种不同结构的模型,即全连接模型和全卷积模型结构,而针对具体的问题时,可以通过实验来确定选择哪一种模型结构更为有效。

[0044] 神经网络包括输入层、输出层,以及中间所有节点组成的隐藏层。Max pooling层是指在一定的窗口内,只取最大值。Dropout层是指在模型训练时随机让网络某些隐含层节点的权重不工作,不工作的那些节点可以暂时认为不是网络结构的一部分,但是它的权重得保留下来,只是暂时不更新而已,因为下次样本输入时它可能又得工作了。训练神经网络模型时,如果训练样本较少,为了防止模型过拟合,Dropout可以作为一种选择。Batch Normalization(BN)层就是将每个隐藏层的输出结果在batch上进行标准化后再送入下一层。卷积层通过一块块的卷积核在原始数据上平移来提取特征,每一个特征就是一个特征映射。在图像处理时,给定输入图像情况下,在输出图像中每一个像素是输入图像中一个小区域中像素的加权平均,其中权值由一个函数定义,这个函数称为卷积核,图像情况下是一个二维的卷积核。而在本例中的输入数据为心电信号,是一维序列,所以对应的卷积核则是一个一维的卷积核,原理与图像处理时的二维卷积核类似。

[0045] 本发明设计的第一种是全连接神经网络模型,参见说明书附图4所示,对心电信号所包含的信息做特征提取,利用人工提取的多个特征作为网络模型的输入,利用多层全连接,通过多层全连接网络对特征做分析,经过模型的训练学习,输出分析处理结果。

[0046] 全连接神经网络模型主要包括输入层,4层隐藏层,Max pooling层,Dropout层,Batch Normalization层和输出层。Max pooling层提取局部最大值,这样可以突出信息并

且减小模型的参数数量。Dropout层的使用可以避免在模型训练的过程中出现过拟合现象，而Batch Normalization层的使用可以较好的解决梯度消失的情况。输入层神经元数目依据数据长度决定，比如在本实施例中，使用2秒即500点的数据，则输入层的神经元数目为500，而3秒750点的数据，则输入层的神经元数目为750。另外，基于计算机处理数据的模式是以二进制的模式，所以每一层隐藏层的神经元个数最好设置为2的次幂，并且递减。所以在本模型结构中，隐藏层神经元个数分别为256、128、64和32，最后输出层包括7个神经元，分别对应不同分析处理后的输出类别，即心律值、心律不齐率、心律值低于60次每分的比率、心律值超过120次每分的比率、PR间期超过0.2s、P波畸形和QRS波宽大畸形，这些输出类别将帮助医生对病人进行诊断。在第二层和第三层隐藏层中间添加一个Max pooling层，在第四层隐藏层和输出层之间添加Max pooling层和Dropout层以及Batch Normalization层，可以提取有效信息，避免过拟合和梯度消失现象，具体结构参见附图5所示，括号中为隐藏神经元个数。

[0047] 第二种是全卷积网络模型，但是本发明使用的卷积网络与在图像应用中所使用的卷积网络有所不同。图像是二维结构，所以相应的要用二维卷积核。而本发明中的心电信号是一维序列，所以需要用一维卷积来做。参见说明书附图6所示，利用一维卷积核对信号做卷积，自动提取特征。当使用多个不同的卷积核时，则会产生多组不同的序列，这表示从心电信号中提取出了多种不同层面的特征信息，有利于对心电信号后续的分析处理。然后再经过循环卷积网络提取时间序列的信息，得出结论。

[0048] 全卷积网络模型主要包括输入层，6层卷积层，Max pooling层，Dropout层，Batch Normalization层和输出层。输入层神经元数目依据数据长度决定，比如在本例中，使用2秒即500点的数据，则输入层的神经元数目为500，而3秒750点的数据，则输入层的神经元数目为750。由于在处理的过程中，信号的原始信息在处理管道中只会减少，不会增加，所以卷积层的参数也是呈现递减的规律，而大小则依据原始信号的大小设置，原始信号维度较高时，则使用较大的卷积核，反之亦然，卷积核的个数则反映信号不同层面的特征信息，也就是一个卷积核可以类似看成产生了一种特征表示。当然，参数越大也意味着模型增大，训练所需数据更多，所以这是一个权衡的问题。最终本模型的卷积层的卷积核大小分别为7、7、5、5、3和3，卷积核个数分别为128、128、64、64、32和32。每两层卷积层之间添加一个Max pooling层，在最后的卷积层和输出层之间添加Dropout层和Batch Normalization层。Max pooling层的添加可以使模型关注局部最大值，也就是提取明显特征信息，丢弃冗余信息，同时可以减少模型参数，添加Dropout层以及Batch Normalization层，可以避免训练过程中的过拟合和梯度消失现象。输出层为全连接层，神经元个数为7，对应不同的输出类别，具体结构参见附图7所示，括号中为卷积核个数。

[0049] 对两种深度学习模型网络结构搭建完成之后，使用处理过后的数据进行训练和测试。由于原始样本中正常类别占比比较大，占总样本的50%左右，而最少的一类标签样本数据只占总样本的10%，共计1500条数据，样本分布不均衡。所以在所有正常类别的数据中，随机采样了1500条数据，在其他标签的样本数据中也都分别随机采样1500条数据。经过采样之后，使得最终训练数据集中的样本分布均衡，所有不同标签的数据的数量基本一致，为1500条，占比均衡，保证训练结果的可靠性。采样之后一共获得10000条样本，按照70%，15%和15%的比例分为训练集、验证集和测试集。也就是7000条样本用于训练，1500条样本

用于验证,1500条样本用于测试。在全连接网络中训练了100轮之后,在测试集上的分类精度达到65%,心率值差在 2.86 ± 1.55 次/分。在全卷积网络中训练了100轮之后,在测试集上的分类精度达到70%,心率值误差在 2.45 ± 1.37 次/分。

[0050] 与现有技术相比,本方法使用GPU进行并行计算,解决了实际应用中对快速给出辅助诊断意见的要求;具有更好的针对性;所需的数据标注量少,而且不需要进行人工提取特征,减少了处理过程的复杂度;由于本发明的卷积神经网络便于在大量真实的数据集上进行迁移学习,因此本发明还具有较强的可移植性。

[0051] 上面所述的只是说明本发明的一种基于深度学习的心电信号分析方法的实施方式,由于对相同技术领域的普通技术人员来说很容易在此基础上进行若干修改和改动,因此本说明书并非是要将本发明的心电信号分析方法局限在所示和所述的具体步骤范围内,故凡是所有可能被利用的相应修改及等同方法,均属于本发明所申请的专利范围。



图1

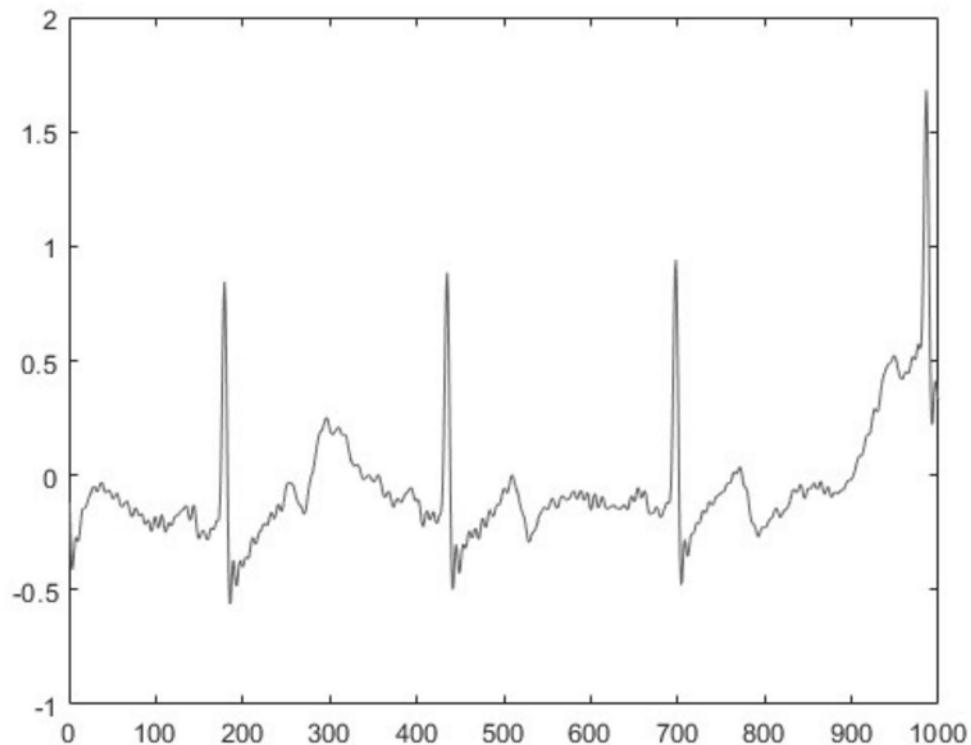


图2

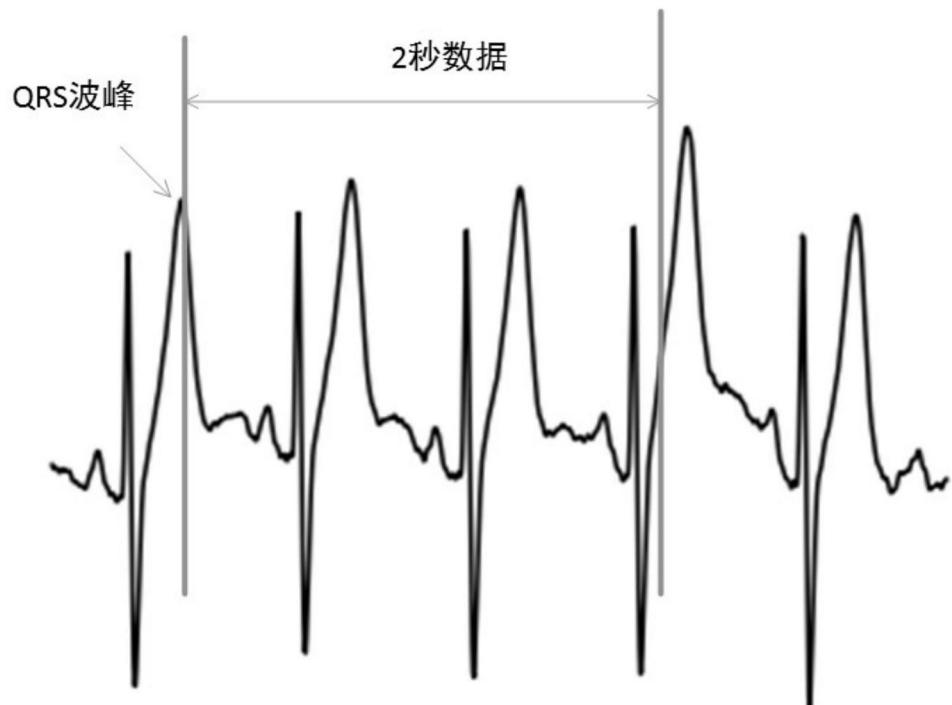


图3

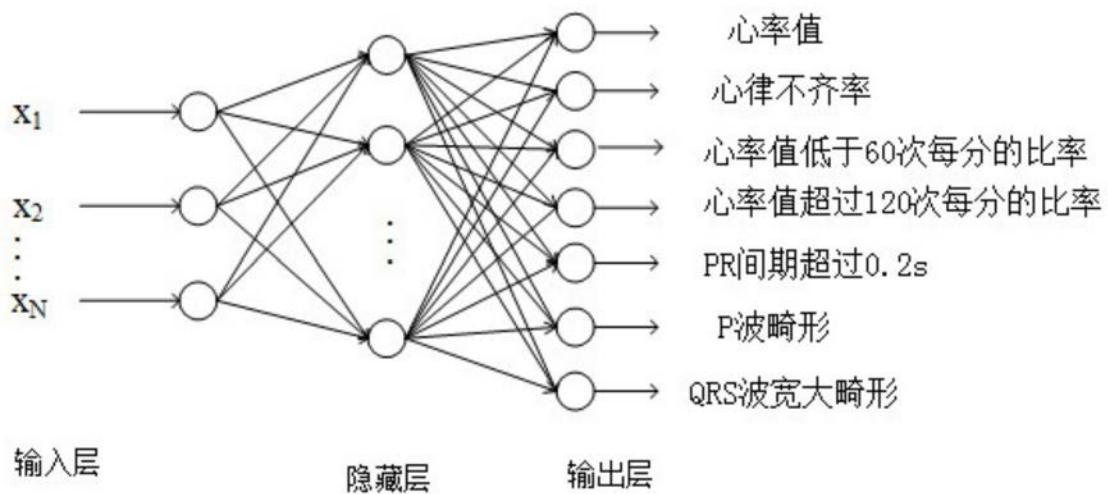


图4

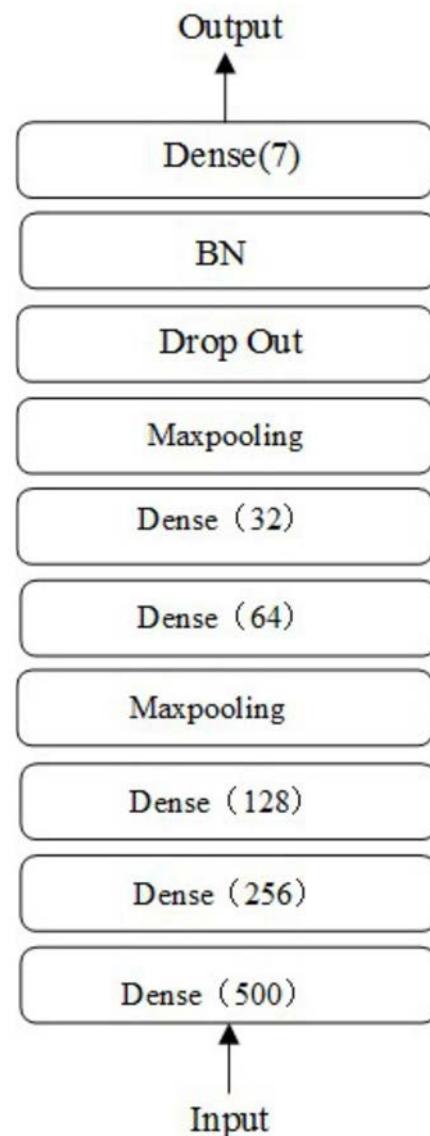


图5

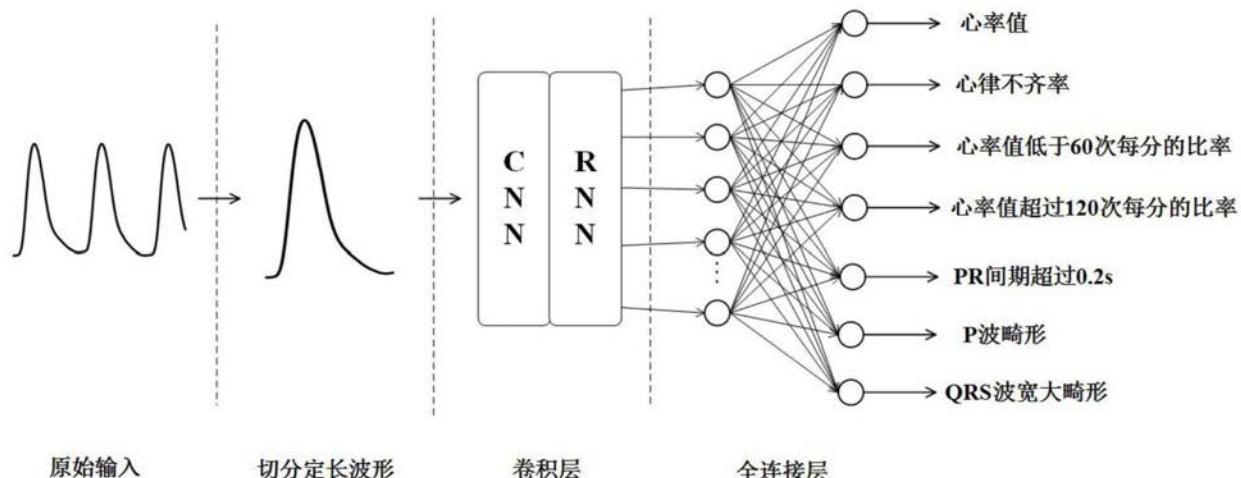


图6

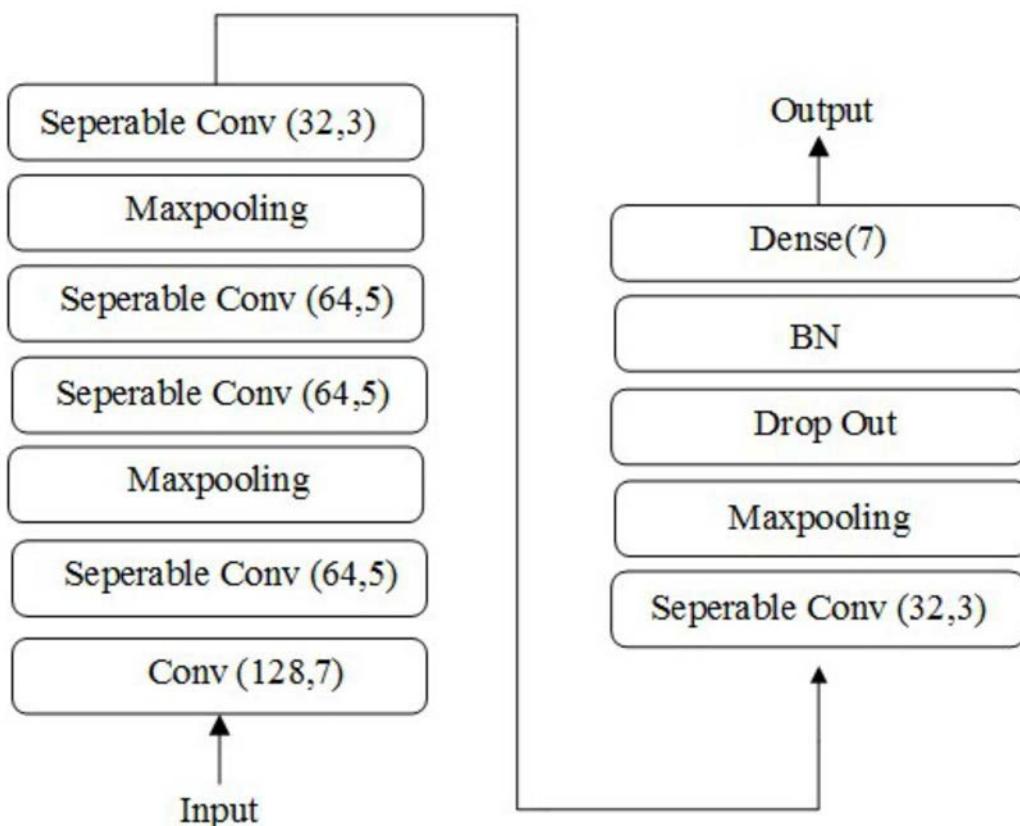


图7

专利名称(译)	一种基于深度学习的心电信号分析方法		
公开(公告)号	CN109864714A	公开(公告)日	2019-06-11
申请号	CN201910267888.8	申请日	2019-04-04
[标]申请(专利权)人(译)	北京邮电大学		
申请(专利权)人(译)	北京邮电大学		
当前申请(专利权)人(译)	北京邮电大学		
[标]发明人	袁学光 张阳安		
发明人	袁学光 张阳安 汪萃萃		
IPC分类号	A61B5/00 A61B5/04 A61B5/0402		
代理人(译)	吕良 张群峰		
外部链接	Espacenet Sipo		

摘要(译)

一种基于深度学习的心电信号自动分析处理方法，包括对原始心电信号进行预处理、切分定长波形以将心电信号数据整理成多个维度一致的向量以及通过全连接神经网络或全卷积神经网络的深度学习模型对整理获得的数据进行训练的操作步骤，最终可以全面准确地输出不同的心电指标类别。通过该方法能够减少医生在判读的工作量，帮助医生提高判读的准确率，成为医生诊断心脏病疾患的重要辅助方案。

