



(12)发明专利申请

(10)申请公布号 CN 110890155 A

(43)申请公布日 2020.03.17

(21)申请号 201911167791.6

(22)申请日 2019.11.25

(71)申请人 中国科学技术大学

地址 230026 安徽省合肥市包河区金寨路
96号

(72)发明人 陈勋 张静 梁邓 高敏 张旭
陈香

(74)专利代理机构 安徽省合肥新安专利代理有
限责任公司 34101

代理人 陆丽莉 何梅生

(51)Int.Cl.

G16H 50/20(2018.01)

A61B 5/0402(2006.01)

A61B 5/04(2006.01)

A61B 5/00(2006.01)


权利要求书2页 说明书9页 附图7页

(54)发明名称

一种基于导联注意力机制的多类心律失常
检测方法

(57)摘要

本发明公开了一种基于导联注意力机制的多类心律失常检测方法,其步骤包括:1、对原始ECG信号进行下采样和补齐到固定长度的预处理;2、设计分类模型,集成了四种网络结构,包括导联注意力机制、卷积神经网络、双向门控循环单元和时间注意力机制;3、在公开数据集上采用四折交叉验证训练上述模型;4、利用训练好的模型实现心律失常分类任务。本发明能实现高准确率心律失常自动检测,从而为医生的诊断提供辅助。



1. 一种基于导联注意力机制的多类心律失常检测方法,其特征在于,包括以下步骤:

步骤一、获取原始ECG信号及其对应的标签,对所述原始ECG信号进行下采样,得到采样后的ECG信号;对所述采样后的ECG信号进行裁剪或均值补齐处理,得到预处理后的ECG信号;

步骤二、构建由导联注意力机制模块、卷积神经网络、双向门控循环单元和时间注意力机制模块组成的分类网络;

步骤2.1、构建导联注意力机制模块,包括两个并行的全局池化层、c个全连接层、sigmoid函数层:

将所述预处理后的ECG信号分别输入全局平均池化层和全局最大池化层,得到全局平均池化特征图和全局最大池化特征图,再分别经过所述c个全连接层的处理后,得到两个输出特征图并相加,从而得到融合的全局池化特征图,并经过Sigmoid函数层后,输出导联注意力图;将所述导联注意力图与预处理后的ECG信号相乘,最终得到沿导联轴加权后的ECG信号;

步骤2.2、构建卷积神经网络:

所述卷积神经网络由n个卷积层组成,并以m个卷积层作为一个卷积块,设置每个卷积块前m-1个卷积层的核尺寸小于第m个卷积层的核尺寸;并设置卷积层的核数量均为K;

在每个卷积层之后设置有LeakyReLU激活函数层;

将所述沿导联轴加权后的ECG信号输入所述卷积神经网络中,得到ECG信号的局部特征;

步骤2.3、将所述ECG信号的局部特征输入所述双向门控循环单元,得到ECG信号的全局特征;

步骤2.4、将所述ECG信号的全局特征输入所述时间注意力机制模块,得到沿时间轴加权后的ECG信号;

步骤三、采用K折交叉验证法训练所述分类网络,得到K个分类模型;

步骤四、利用K个分类模型对预处理后的待预测ECG信号分别进行预测,得到各个类别的K个预测概率,并对K个预测概率取均值,从而得到各类的平均预测概率,将平均预测概率最大的类别作为待预测的ECG信号预测标签。

2. 根据权利要求1所述的多类心律失常检测方法,其特征是,所述步骤三是按如下过程进行:

步骤3.1、定义外循环的最大循环次数为K;定义内迭代的最大迭代次数为 $E_{\max}$;

定义当前外循环次数为k,定义当前内迭代次数为e;

将预处理后的ECG信号及其对应的标签划分成同等大小的K个子集;

步骤3.2、初始化k=1;

步骤3.3、将第k个子集作为验证集,其余K-1个子集作为第k次循环的训练集;

步骤3.4、将所述第k次循环的训练集以分批的方式输入到所述分类网络中;

步骤3.5、设置交叉熵作为循环的损失函数;

步骤3.6、利用He正态分布初始化器第k次初始化所述导联注意力机制模块的c个全连接层;利用Xavier均匀分布初始化器第k次初始化所述卷积神经网络中n个卷积层的权重;利用生成随机正交矩阵的初始化器第k次初始化所述双向门控循环单元的元胞;

步骤3.7、利用Adam优化器优化所述分类模型中各个参数,设置学习率为1;

步骤3.8、在每个卷积块、所述双向门控循环单元和时间注意力机制模块的输出后分别设置Dropout层,丢弃率设置为d;

步骤3.9、初始化 $e=1$;定义性能阈值为 $F_{\max}$,并初始化 $F_{\max}=0$;定义计数器count,并初始化 $\text{count}=0$;

步骤3.10、在第k次外循环的第e次内迭代下利用Adam优化器对所述分类模型进行训练,得到第e次训练后的分类模型;

步骤3.11、计算第e次训练后的分类模型在验证集上的准确率 F_e ;

步骤3.12、判断 $F_e > F_{\max}$ 是否成立,若成立,则将 F_e 赋值给 $F_{\max}$,否则,令计数器count加“1”,并保持 $F_{\max}$ 不变;

步骤3.13、判断 $e+1$ 赋值给 e 后, $e > E_{\max}$ 或count达到所设定阈值是否成立,若成立,则将 $F_{\max}$ 所对应的分类模型作为第k次外循环下的分类模型,并执行步骤3.14;否则,返回步骤3.10;

步骤3.14、将 $k+1$ 赋值给 k 后,判断 $k > K$ 是否成立,若成立,则表示得到K个分类模型,并执行步骤四,否则,返回步骤3.3。

一种基于导联注意力机制的多类心律失常检测方法

技术领域

[0001] 本发明涉及医学信号处理领域,尤其涉及从心电图信号中检测心律失常的方法。

背景技术

[0002] 心脏心律失常是一种心脏电活动不规则的情况。许多类型的心律失常是损害健康甚至危及生命的,如室性心动过速、心室颤动是致死性心律失常。心电图(electrocardiogram, ECG)通过放置在皮肤上的电极记录了一段时间内心脏的电活动,在临床上被广泛用于心律失常检测。心电图通过不同的导联从不同的角度捕捉心脏的电势,通过波形或节律的变化反应心脏心律情况。医生可以通过心电图了解病人患各种心脏病的风险。一个24小时的心电监测仪记录到的心拍多达几十万,分析这些心拍对医生来说是一项耗时的工作,可能会出现误判或漏判。因此,构建一个准确的自动心律失常检测方法辅助医生工作对临床心律失常诊断具有重要帮助。

[0003] 在过去的几十年里,提出了大量的心律失常检测方法。这些方法主要由四个步骤组成,包括降噪、特征提取和选择、特征变换和心律失常分类。在这些步骤中,特征提取将输入的心电信号转化为多种特征,这些特征在心律失常的检测中起着重要作用,主要有P-QRS-T波特征、统计特征、形态特征、小波特征。特征变换将原始的高维心电信号转化为一个更低维的子空间,实现了降维的目的,可以通过主成分分析、线性判别分析、独立成分分析等方法实现。特征工程之后,各种各样的分类器用来对心电信号分类,常用的分类器主要有六种,包括人工神经网络、线性判别分析、k近邻、支持向量机、决策树和贝叶斯分类器。

[0004] 近些年,深度神经网络(deep neural network, DNN)凭借其强大的特征提取能力,在计算机视觉领域取得了巨大的成功。不同于传统的机器学习方法,DNN是一种受数据驱动的方法,无需特征工程的设计。许多研究工作也尝试用DNN解决心律失常检测的问题。卷积神经网络(convolutional neural network, CNN)常被用于分析生理信号,随着卷积层的加深,特征以一种更加抽象的方式被学习和表示。长短时记忆网络(long short-term memory, LSTM)是一种广泛用于分析时间序列的深度学习的方法,也常用于心律失常检测。不少研究人员将LSTM应用在卷积神经网络提取的特征之后,这种堆叠的网络实现了较高的心律失常检测性能。

[0005] 很多研究工作虽然在心律失常检测上取得了一定的效果,可是,他们通常忽略了不是所有的导联,不是所有的时间步对检测心律失常都有同样的贡献。最近,“Multi-class Arrhythmia detection from 12-lead varied-length ECG using Attention-based Time-Incremental Convolutional Neural Network”提出一种有效的多类心律失常检测方法,集成了卷积神经网络、循环元胞和注意力机制。具有意义地是,他们引入了时间维度的注意力机制给从不同的信号片段提取的特征分配相应的权重,帮助定位了信号的感兴趣片段。然而,该研究工作并没有关注“哪些导联”对给定的心电记录是有意义的。

[0006] 为了便于分析心律失常,最好同步记录3或6个导联,甚至12个导联,以满足临床诊断的需要。换句话说,导联的信息是有冗余的。事实上,某个缺失的肢体导联可以通过其它

已知肢体导联由公式计算得出。比如,根据Einthoven定律,II导联QRS波的振幅等于I和III导联QRS波振幅的总和。心前区导联V1-V6虽然不能通过计算得出,心脏病专家却可以根据经验推断出大致的波形。在之前的工作中,心电信号的12导联特性被忽略。

发明内容

[0007] 本发明为克服现有技术的不足之处,提出一种基于导联注意力机制的多类心律失常检测方法,以期能实现高准确率心律失常自动检测。

[0008] 本发明为达到上述发明目的,采用如下技术方案:

[0009] 本发明一种基于导联注意力机制的多类心律失常检测方法的特点在于,包括以下步骤:

[0010] 步骤一、获取原始ECG信号及其对应的标签,对所述原始ECG信号进行下采样,得到采样后的ECG信号;对所述采样后的ECG信号进行裁剪或均值补齐处理,得到预处理后的ECG信号;

[0011] 步骤二、构建由导联注意力机制模块、卷积神经网络、双向门控循环单元和时间注意力机制模块组成的分类网络;

[0012] 步骤2.1、构建导联注意力机制模块,包括两个并行的全局池化层、c个全连接层、sigmoid函数层:

[0013] 将所述预处理后的ECG信号分别输入全局平均池化层和全局最大池化层,得到全局平均池化特征图和全局最大池化特征图,再分别经过所述c个全连接层的处理后,得到两个输出特征图并相加,从而得到融合的全局池化特征图,并经过Sigmoid函数层后,输出导联注意力图;将所述导联注意力图与预处理后的ECG信号相乘,最终得到沿导联轴加权后的ECG信号;

[0014] 步骤2.2、构建卷积神经网络:

[0015] 所述卷积神经网络由n个卷积层组成,并以m个卷积层作为一个卷积块,设置每个卷积块前m-1个卷积层的核尺寸小于第m个卷积层的核尺寸;并设置卷积层的核数量均为K;

[0016] 在每个卷积层之后设置有LeakyReLU激活函数层;

[0017] 将所述沿导联轴加权后的ECG信号输入所述卷积神经网络中,得到ECG信号的局部特征;

[0018] 步骤2.3、将所述ECG信号的局部特征输入所述双向门控循环单元,得到ECG信号的全局特征;

[0019] 步骤2.4、将所述ECG信号的全局特征输入所述时间注意力机制模块,得到沿时间轴加权后的ECG信号;

[0020] 步骤三、采用K折交叉验证法训练所述分类网络,得到K个分类模型;

[0021] 步骤四、利用K个分类模型对预处理后的待预测ECG信号分别进行预测,得到各个类别的K个预测概率,并对K个预测概率取均值,从而得到各类的平均预测概率,将平均预测概率最大的类别作为待预测的ECG信号预测标签。

[0022] 本发明所述的多类心律失常检测方法的特点是,所述步骤三是按如下过程进行:

[0023] 步骤3.1、定义外循环的最大循环次数为K;定义内迭代的最大迭代次数为 $E_{\max}$;

[0024] 定义当前外循环次数为k,定义当前内迭代次数为e;

- [0025] 将预处理后的ECG信号及其对应的标签划分成同等大小的K个子集；
- [0026] 步骤3.2、初始化 $k=1$ ；
- [0027] 步骤3.3、将第k个子集作为验证集，其余 $K-1$ 个子集作为第k次循环的训练集；
- [0028] 步骤3.4、将所述第k次循环的训练集以分批的方式输入到所述分类网络中；
- [0029] 步骤3.5、设置交叉熵作为循环的损失函数；
- [0030] 步骤3.6、利用He正态分布初始化器第k次初始化所述导联注意力机制模块的c个全连接层；利用Xaiver均匀分布初始化器第k次初始化所述卷积神经网络中n个卷积层的权重；利用生成随机正交矩阵的初始化器第k次初始化所述双向门控循环单元的元胞；
- [0031] 步骤3.7、利用Adam优化器优化所述分类模型中各个参数，设置学习率为1；
- [0032] 步骤3.8、在每个卷积块、所述双向门控循环单元和时间注意力机制模块的输出后分别设置Dropout层，丢弃率设置为d；
- [0033] 步骤3.9、初始化 $e=1$ ；定义性能阈值为 $F_{\max}$ ，并初始化 $F_{\max}=0$ ；定义计数器count，并初始化 $\text{count}=0$ ；
- [0034] 步骤3.10、在第k次外循环的第e次内迭代下利用Adam优化器对所述分类模型进行训练，得到第e次训练后的分类模型；
- [0035] 步骤3.11、计算第e次训练后的分类模型在验证集上的准确率 F_e ；
- [0036] 步骤3.12、判断 $F_e > F_{\max}$ 是否成立，若成立，则将 F_e 赋值给 $F_{\max}$ ，否则，令计数器count加“1”，并保持 $F_{\max}$ 不变；
- [0037] 步骤3.13、判断 $e+1$ 赋值给e后， $e > E_{\max}$ 或count达到所设定阈值是否成立，若成立，则将 $F_{\max}$ 所对应的分类模型作为第k次外循环下的分类模型，并执行步骤3.14；否则，返回步骤3.10；
- [0038] 步骤3.14、将 $k+1$ 赋值给k后，判断 $k > K$ 是否成立，若成立，则表示得到K个分类模型，并执行步骤四，否则，返回步骤3.3。
- [0039] 与已有技术相比，本发明的有益效果体现在：
- [0040] 1、本发明通过构建由导联注意力机制模块、卷积神经网络、双向门控循环单元和时间注意力机制模块组成的分类网络，给不同的导联、不同的信号片段分配权重，能够定位到空间和时间上ECG信号的信息性部分，在多类心律失常检测上实现了平均 F_1 得分为0.8634的高性能；
- [0041] 2、本发明提出了导联注意力机制，通过给不同的导联分配权重，定位到空间上ECG信号的信息性部分，提高了3.33%的心律失常检测性能；
- [0042] 3、本发明通过卷积神经网络提取ECG信号的局部特征，提取的特征提高了心律失常检测性能；
- [0043] 4、本发明通过双向门控循环单元提取ECG信号的全局特征，提取的特征提高了心律失常检测性能；
- [0044] 5、本发明通过时间注意力机制给不同的信号片段分配权重，定位到时间上ECG信号的信息性部分，提高了心律失常检测性能。

附图说明

- [0045] 图1为本发明方法的流程图；

[0046] 图2为本发明网络结构图,Conv1D 3×12 代表卷积核尺寸为3,核数量为12的卷积层,以此类推;

[0047] 图3为本发明导联注意力机制结构图;

[0048] 图4为本发明方法和未集成导联注意力机制模块时对原始的正常导联II信号的注意力映射对比图;

[0049] 图5为本发明方法和未集成导联注意力机制模块时对原始的正常导联II信号的注意力映射对比图;

[0050] 图6为本发明方法和未集成导联注意力机制模块时对原始的一度房室传导阻滞导联II信号的注意力映射对比图;

[0051] 图7为本发明方法和未集成导联注意力机制模块时对原始的左束支传导阻滞导联II信号的注意力映射对比图;

[0052] 图8为本发明方法和未集成导联注意力机制模块时对原始的右束支传导阻滞导联II信号的注意力映射对比图;

[0053] 图9为本发明方法和未集成导联注意力机制模块时对原始的房性早搏导联II信号的注意力映射对比图;

[0054] 图10为本发明方法和未集成导联注意力机制模块时对原始的室性早搏导联II信号的注意力映射对比图;

[0055] 图11为本发明方法和未集成导联注意力机制模块时对原始的ST段压低导联II信号的注意力映射对比图;

[0056] 图12为本发明方法和未集成导联注意力机制模块时对原始的ST段抬高导联II信号的注意力映射对比图。

具体实施方式

[0057] 本实施例中,一种基于导联注意力机制的多类心律失常检测方法,命名为LTA-CNN,如图1所示,其包括如下步骤:

[0058] 步骤一、获取原始ECG信号及其对应的标签,对原始ECG信号进行下采样,得到采样后的ECG信号;对采样后的ECG信号进行裁剪或均值补齐处理,得到预处理后的ECG信号;

[0059] 步骤1.1、从中国生理信号挑战赛(the China Physiological Signal Challenge, CPSC) 2018的公开数据获取实验所需的原始ECG信号及其对应的标签。CPSC2018的公开数据提供6877条12导联ECG记录,时间长度范围为6秒到60秒。记录收集自11家医院,采样率500Hz。ECG记录包含九种心律类型,八种心律失常和正常心律,如表1所示。

[0060] 表1:数据集的配置

	类型	#记录	时间长度(s)				
			均值	标准差	最小值	中位数	最大值
[0061]	正常 (normal)	918	15.43	7.61	10.00	13.00	60.00
	房颤(AF)	1098	15.01	8.39	9.00	11.00	60.00
	一度房室传导阻滞(1-AVB)	704	14.32	7.21	10.00	11.27	60.00
	左束支传导阻滞(LBBB)	207	14.92	8.09	9.00	12.00	60.00
	右束支传导阻滞(RBBB)	1695	14.42	7.60	10.00	11.19	60.00
	房性早搏(PAC)	556	19.46	12.36	9.00	14.00	60.00
	室性早搏(PVC)	672	20.21	12.85	6.00	15.00	60.00
	ST段压低(STD)	825	15.13	6.82	8.00	12.78	60.00
	ST段抬高(STE)	202	17.15	10.72	10.00	11.89	60.00
	总计	6877	15.79	9.04	6.00	12.00	60.00

[0062] 从以上数据集中随机划分出1/5作为测试集,用来测试算法性能。

[0063] 步骤1.2、将原始ECG信号从500Hz下采样到256Hz,得到采样后的ECG信号。

[0064] 步骤1.3、将60s作为采样后的ECG信号的固定长度,不足60s的信号补其均值,超过60s的信号裁剪其前60s,得到预处理后的ECG信号。

[0065] 步骤二、构建由导联注意力机制模块、卷积神经网络、双向门控循环单元和时间注意力机制模块组成的分类网络,如图2所示;

[0066] 步骤2.1构建导联注意力机制模块,如图3所示,包括两个并行的全局池化层、c个全连接层、sigmoid函数层:

[0067] 将预处理后的ECG信号分别输入全局平均池化层和全局最大池化层,得到全局平均池化特征图和全局最大池化特征图,再分别经过c个全连接层的处理后,得到两个输出特征图并相加,从而得到融合的全局池化特征图,并经过Sigmoid函数层后,输出导联注意力图;将导联注意力图与预处理后的ECG信号相乘,最终得到沿导联轴加权后的ECG信号;

[0068] 示例性地,可以设置: $c=2$,两个全连接层的输出尺寸分别设置为6、12。

[0069] 步骤2.2、构建卷积神经网络:

[0070] 卷积神经网络由n个卷积层组成,并以m个卷积层作为一个卷积块,设置每个卷积块前m-1个卷积层的核尺寸小于第m个卷积层的核尺寸;并设置卷积层的核数量均为K;

[0071] 在每个卷积层之后设置有LeakyReLU激活函数层;

[0072] 将沿导联轴加权后的ECG信号输入卷积神经网络中,得到ECG信号的局部特征;

[0073] 本实施例中,可以设置: $n=15, m=3, K=12$;这种参数设置下共有五个卷积块,每个卷积块的前两层卷积核尺寸是3,步长为1,小卷积核用来提取心电信号的细节信息;前四个卷积块的第三层核尺寸是24、第五个卷积块的第三层核尺寸是48,步长均为2,大卷积核用来提取心电信号更全局的信息。

[0074] 步骤2.3、将ECG信号的局部特征输入双向门控循环单元,得到ECG信号的全局特征;

[0075] 本实施例中,可以设置:双向门控循环单元的输出维度为12。

[0076] 步骤2.4、将ECG信号的全局特征输入时间注意力机制模块,得到沿时间轴加权后的ECG信号;

[0077] 参考“Hierarchical Attention Networks for Document Classification”,引

进时间注意力机制,实现步骤如式(1)-式(3)所示:

$$[0078] \quad u_{it} = \tanh(W_{wh_{it}} + b_w) \quad (1)$$

$$[0079] \quad \alpha_{it} = \frac{\exp(u_{it}^T u_w)}{\sum_i \exp(u_{it}^T u_w)} \quad (2)$$

$$[0080] \quad s_i = \sum_t \alpha_{it} h_{it} \quad (3)$$

[0081] 首先将双向门控循环单元输出的状态 h_{it} 输入到一个单层感知机,得到 h_{it} 的隐藏表示 u_{it} 。然后通过Softmax函数计算出每个时间步的重要性权重 α_{it} ,最后通过对 h_{it} 进行加权平均得到每个信号的表示。

[0082] 步骤三、采用四折交叉验证法训练分类网络:

[0083] 步骤3.1、定义外循环的最大循环次数为 $K=4$;定义内迭代的最大迭代次数为 $E_{\max}=500$;

[0084] 定义当前外循环次数为 k ,定义当前内迭代次数为 e ;

[0085] 将预处理后的ECG信号及其对应的标签划分成同等大小的 K 个子集;

[0086] 步骤3.2、初始化 $k=1$;

[0087] 步骤3.3、将第 k 个子集作为验证集,其余 $K-1$ 个子集作为第 k 次循环的训练集;

[0088] 步骤3.4、将第 k 次循环的训练集以64个信号为一批的方式输入到分类网络中;

[0089] 步骤3.5、设置交叉熵作为循环的损失函数;

[0090] 步骤3.6、利用He正态分布初始化器第 k 次初始化导联注意力机制模块的 c 个全连接层;利用Xaiver均匀分布初始化器第 k 次初始化卷积神经网络中 n 个卷积层的权重;利用生成随机正交矩阵的初始化器第 k 次初始化双向门控循环单元的元胞;

[0091] 步骤3.7、利用Adam优化器优化分类模型中各个参数,设置学习率为 $l=0.001$;

[0092] 步骤3.8、在每个卷积块、双向门控循环单元和时间注意力机制模块的输出后分别设置Dropout层,丢弃率设置为 $d=0.2$;

[0093] 步骤3.9、初始化 $e=1$;定义性能阈值为 $F_{\max}$,并初始化 $F_{\max}=0$;定义计数器 $count$,并初始化 $count=0$,阈值设置为100;

[0094] 步骤3.10、在第 k 次外循环的第 e 次内迭代下利用Adam优化器对分类模型进行训练,得到第 e 次训练后的分类模型;

[0095] 步骤3.11、计算第 e 次训练后的分类模型在验证集上的准确率 Fe ;

[0096] 步骤3.12、判断 $Fe > F_{\max}$ 是否成立,若成立,则将 Fe 赋值给 $F_{\max}$,否则,令计数器 $count$ 加“1”,并保持 $F_{\max}$ 不变;

[0097] 步骤3.13、判断 $e+1$ 赋值给 e 后, $e > E_{\max}$ 或 $count$ 达到所设定阈值是否成立,若成立,则将 $F_{\max}$ 所对应的分类模型作为第 k 次外循环下的分类模型,并执行步骤3.14;否则,返回步骤3.10;

[0098] 步骤3.14、将 $k+1$ 赋值给 k 后,判断 $k > K$ 是否成立,若成立,则表示得到 K 个分类模型,并执行步骤四,否则,返回步骤3.3;

[0099] 步骤四、利用 K 个分类模型对预处理后的待预测ECG信号分别进行预测,得到各个类别的 K 个预测概率,并对 K 个预测概率取均值,从而得到各类的平均预测概率,将平均预测概率最大的类别作为待预测的ECG信号预测标签。

[0100] 步骤五、为了说明本发明中导联注意力机制的性能,在有无导联注意力模块的情

况下分别测试了模型性能。为了公平比较,设置相同的超参数,相同的预处理方法和训练策略等也被使用,如上述具体实施方式所描述。本发明检测每类心律失常的性能由F₁值来评估,如式(4)-式(6)定义:

$$[0101] \quad Precision = \frac{TP}{TP + FP} \quad (4)$$

$$[0102] \quad Recall = \frac{TP}{TP + FN} \quad (5)$$

$$[0103] \quad F_1 = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (6)$$

[0104] 式(4)-式(6)中,TP是某类分类正确的样本数,FN是属于某类却被误分做其它类的样本数,而FP是属于其它类却被被错分到某类的样本数。模型最终的性能由F₁值的平均值来评估。

[0105] 步骤5.1、表2比较了集成导联注意力模块的模型LTA-CNN和没有集成该模块的模型TA-CNN在检测九类心律类型上的F₁得分。结果表明LTA-CNN在所有类的F₁得分均优于TA-CNN,平均F₁得分分别为0.8634、0.8301,导联注意力模块提升了3.33%的分类性能。在检测PAC、PVC和STD上,比起TA-CNN,LTA-CNN有非常明显的性能提高,分别提升了5.56%、5.09%和4.1%。

[0106] 表2. 模型有无集成导联注意力模块时的分类性能

	类型	F ₁ 得分	
		TA-CNN	LTA-CNN
[0107]	normal	0.8399	0.8596
	AF	0.9209	0.9254
	1-AVB	0.8911	0.9103
	LBBB	0.9318	0.9524
	RBBB	0.9315	0.9374
[0108]	PAC	0.7602	0.8158
	PVC	0.8626	0.9135
	STD	0.8333	0.8743
	STE	0.5	0.5818
	average F ₁	0.8301	0.8634

[0109] 步骤5.2、Grad-CAM被用来可视觉解释TA-CNN和LTA-CNN学习到的特征,进一步证明导联注意力机制帮助模型更好地定位心电信号中的异常,也改善了深度学习模型的可解释性。根据输出特征,对分类正确的九类心律进行注意力映射,如图4-图12所示,颜色越亮表示对应的心电信号片段越被注意,其中:

[0110] 图4中的(a)部分为原始的正常导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0111] 图5中的(a)部分为原始的房颤导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0112] 图6中的(a)部分为原始的一度房室传导阻滞导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0113] 图7中的(a)部分为原始的左束支传导阻滞导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0114] 图8中的(a)部分为原始的右束支传导阻滞导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0115] 图9中的(a)部分为原始的房性早搏导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0116] 图10中的(a)部分为原始的室性早搏导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c部分)为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0117] 图11中的(a)部分为原始的ST段压低导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0118] 图12中的(a)部分为原始的ST段抬高导联II信号;(b)部分为分类正确时,本发明方法的注意力映射;(c)部分为分类正确时,本发明方法未集成导联注意力机制模块时的注意力映射;

[0119] 从图4-图12,可以看出:

[0120] (1)如图4中的(b)部分所示,模型对正常心律的注意力集中在P波和T波;

[0121] (2)房颤发生时,P波消失,代之以连续不规则的基线波动(f波),如图5中的(b)所示,房颤的注意力集中在P波;

[0122] (3)如图6中的(b)部分-图8中的(b)部分,对于三种传导阻滞(1-AVB,LBBB和RBBB),模型的注意力集中在异常的QRS波;

[0123] (4)出现房性早搏时,P'-QRS-T波提前出现,P'形态与窦性P波略有不同,或P'波后无QRS波群,如图9中的(b)部分所示,房性早搏的注意力集中在P波和QRS波上;

[0124] (5)室性早搏的T波与主波方向相反,如图10中的(b)所示,室性早搏的注意力集中在T波;

[0125] (6)如图11中的(b)部分和12中的(b)部分所示,对于ST段改变的两种心律情况(STD和STE),模型的注意力集中在ST段。

[0126] 对比图4-图12中的(b)部分和(c)部分可以看出,集成导联注意力模块的LTA-CNN比未集成导联注意力模块的TA-CNN更有效地定位了心电信号中的异常,证明了导联注意力机制的有效性。从LTA-CNN的注意力映射可以看出,模型提取的特征与临床判断相符,本发

明对大多数心律失常具有高检测性能。




图1




图2




图3




图4




图5




图6




图7




图8




图9




图10




图11




图12

专利名称(译)	一种基于导联注意力机制的多类心律失常检测方法		
公开(公告)号	CN110890155A	公开(公告)日	2020-03-17
申请号	CN201911167791.6	申请日	2019-11-25
[标]申请(专利权)人(译)	中国科学技术大学		
申请(专利权)人(译)	中国科学技术大学		
当前申请(专利权)人(译)	中国科学技术大学		
[标]发明人	陈勋 张静 高敏 张旭 陈香		
发明人	陈勋 张静 梁邓 高敏 张旭 陈香		
IPC分类号	G16H50/20 A61B5/0402 A61B5/04 A61B5/00		
CPC分类号	A61B5/04012 A61B5/0402 A61B5/7267 A61B5/7271 G16H50/20		
代理人(译)	何梅生		
外部链接	Espacenet SIPO		

摘要(译)

本发明公开了一种基于导联注意力机制的多类心律失常检测方法，其步骤包括：1、对原始ECG信号进行下采样和补齐到固定长度的预处理；2、设计分类模型，集成了四种网络结构，包括导联注意力机制、卷积神经网络、双向门控循环单元和时间注意力机制；3、在公开数据集上采用四折交叉验证训练上述模型；4、利用训练好的模型实现心律失常分类任务。本发明能实现高准确率心律失常自动检测，从而为医生的诊断提供辅助。

