



(12)发明专利申请

(10)申请公布号 CN 107811626 A

(43)申请公布日 2018.03.20

(21)申请号 201710814713.5

(22)申请日 2017.09.10

(71)申请人 天津大学

地址 300072 天津市南开区卫津路92号

(72)发明人 吕卫 王粟瑶 褚晶辉

(74)专利代理机构 天津市北洋有限责任专利代
理事务所 12201

代理人 杜文茹

(51)Int.Cl.

A61B 5/024(2006.01)

A61B 5/0452(2006.01)

A61B 5/00(2006.01)


权利要求书2页 说明书7页 附图3页

(54)发明名称

一种基于一维卷积神经网络和S变换的心律失常分类方法

(57)摘要

一种基于一维卷积神经网络和S变换的心律失常分类方法：对心电信号预处理；利用一维卷积神经网络提取心电信号的深度非线性特征；利用S变换提取心电信号的时频域特征；将心电信号的深度非线性特征和心电信号的时频域特征融合到一起，经过全连接层继续进行特征学习，得到全连接层输出特征；全连接层输出特征接到一维卷积神经网络的softmax层进行分类；输出分类结果。本发明不需要对心电信号进行压缩和双线性插值来得到固定像素点的图片形式来提取特征。本发明在特征提取方面结合了深度学习特征和时频域特征的优点组合成更完备的特征，能够加快收敛，控制过拟合，降低网络对初始化权重不敏感。提高了多种心律失常识别的准确率。



1. 一种基于一维卷积神经网络和S变换的心律失常分类方法,其特征在于,包括如下步骤:

- 1) 对心电信号预处理;
- 2) 利用一维卷积神经网络提取心电信号的深度非线性特征;
- 3) 利用S变换提取心电信号的时频域特征;
- 4) 将心电信号的深度非线性特征和心电信号的时频域特征融合到一起,经过全连接层继续进行特征学习,得到全连接层输出特征;
- 5) 将全连接层输出特征接到一维卷积神经网络的softmax层进行分类;
- 6) 输出分类结果。

2. 根据权利要求1所述的一种基于一维卷积神经网络和S变换的心律失常分类方法,其特征在于,步骤1)所述的预处理包括:采用中值滤波和低通滤波器去除噪声,依据MIT-BIH数据库中的标注文件,找到心电信号R峰位置并提取心电信号片段。

3. 根据权利要求2所述的一种基于一维卷积神经网络和S变换的心律失常分类方法,其特征在于,对所提取的心电信号片段进行z-score标准化,使数据符合标准正态分布。

4. 根据权利要求1所述的一种基于一维卷积神经网络和S变换的心律失常分类方法,其特征在于,步骤2)所述的提取心电信号的深度非线性特征包括:

设一维卷积神经网络结构为卷积层和池化层的组合,分别设定卷积核和池化层的大小,在卷积层和池化层之间加BatchNormalization规范化处理。

5. 根据权利要求4所述的一种基于一维卷积神经网络和S变换的心律失常分类方法,其特征在于,在卷积层和池化层之间加BatchNormalization层网络规范化处理是:

设心跳采样数据的输入向量为: $x_i^0 = [x_1, x_2 \dots x_n]$,n是每个心跳的采样点个数,x是心跳采样数据,卷积层的输出为:

$$c_i^{l,j} = \sigma(b_j + \sum_{m=1}^M W_m^j x_{i+m-1}^{0j})$$

c_i 是第i个卷积层神经元的输出,i是卷积层的位置,I是层数,j是第I层的神经元的位置, σ 是激活函数,产生非线性输出,b是神经元的偏置,M是核的大小, W_m^j 是第j个神经元的权重,m是神经元的个数;

根据BatchNormalization层网络的计算均值、标准差、归一化处理和重构公式,计算出原始网络所要学习的特征分布,具体公式如下:

$$\begin{aligned} \mu_\beta &\leftarrow \frac{1}{m} \sum_{i=0}^m c_i \\ \sigma_\beta^2 &\leftarrow \frac{1}{m} \sum_{i=0}^m (c_i - \mu_\beta)^2 \\ \hat{c}_i &\leftarrow \frac{c_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \epsilon}} \end{aligned}$$

$$y_i \leftarrow \gamma \hat{c}_i + \beta$$

其中, c_i 为第 i 个卷积层中神经元的输出, m 为卷积层输出神经元的个数, μ_β 为卷积层中 m 个神经元输出的平均值, σ_β^2 为卷积层中 m 个神经元输出的方差, ϵ 为卷积层中 m 个神经元输出方差的随机扰动值, $\hat{c}_i$ 为卷积层中神经元的标准化输出值。 γ 是神经元标准化输出的重构权重, β 神经元标准化输出的重构偏置, y_i 第 i 个卷积层中神经元规范化处理的输出;

池化层神经元的输出为:

$$P_i^{LJ} = \max_{r \in R} (y_{i \times T + r}^{LJ})$$

P 为池化层神经元的输出, R 是池化窗口的大小, T 池化的步长, r 是池化窗口可选的整数值大小;

所述池化层神经元的输出即为深度非线性特征。

6. 根据权利要求1所述的一种基于一维卷积神经网络和S变换的心律失常分类方法, 其特征在于, 步骤4) 是将心电信号的深度非线性特征和心电信号的时频域特征拼接在一起, 得到一组特征向量, 将所述的特征向量输入到一维卷积神经网络的两个全链接层, 设定每个全链接层中神经元的个数, 进行特征学习。

7. 根据权利要求1所述的一种基于一维卷积神经网络和S变换的心律失常分类方法, 其特征在于, 步骤5) 所述的分类是利用BP算法, 正向传播和反向传播不断调整权值和阈值, 使误差减小到最小值, 达到最优的分类结果。

一种基于一维卷积神经网络和S变换的心律失常分类方法

技术领域

[0001] 本发明涉及一种心律失常分类方法。特别是涉及一种基于一维卷积神经网络和S变换的心律失常分类方法。

背景技术

[0002] 心律失常是心脏电信号的速率,节律或传导受到干扰引起的心脏功能不规则的异常现象,被认为是最常见的心脏病。它可以通过分析记录的ECG波形来检测,该波形由与心房和心室的去极化和再极化模式相关联的不同电位形成,并提供关于心脏状况的重要信息。对于医生,在短时间内很难分析长时间的ECG信号,并观察心电信号的微小形态变化,这可能导致医生在诊断的时候丢失重要的信息。ECG信号分析面临的另一个问题是不同患者以及同一患者的ECG波形的形态和时间特征的变化很大。对于不同时间的同一患者,ECG波形可能不同,对于具有不同类型心跳的不同患者,ECG波形可能不同。因此需要精准的计算机辅助的心率失常分类系统。心率失常分类方法包括:预处理、特征提取、特征融合和分类四个步骤。

[0003] 特征提取有深度学习方法和手动提取的方法。深度学习在大数据中自动学习特征的表示,得到更有效果的特征表达。手工设计的特征主要依靠设计者的先验知识。

[0004] 目前深度学习已经是模式识别领域中有效的提取特征的方法,依靠大数据量,自动学习到内部的特征关系,有效的表达特征以更好的进行分类预测等,适用于图像分析,文本处理,医学信号分析等各个领域。目前已有学者利用深度学习网络尝试提取ECG信息,刘志华等人利用深度神经网络无监督地提取特征并分类,利用DBN网络得到的准确率90%左右;利用SAE稀疏自编码的方法提取心电信号特征;另外,将一维心电数据转换成二维的图片形式,经过卷积神经网络进行特征提取。

[0005] 除了深度学习的抽象的非线性特征外,在心电信号分析中,需要充分考虑到信号本身时频域特征,这里有三种手动提取特征的方法:时域分析,基于统计方法,基于变换方法。

[0006] 时域方法即ECG信号的形态特征。如提取RR间隔、QRS复合波和T波持续时间、ECG信号采样值,ECG信号的时变动力学和形态特征显示不同患者和不同时间和物理条件下的显著变化。即使是健康受试者的心电图QRS复合体,P波和R-R间隔的形状在不同情况下从一次跳动到另一次不一样,所以利用形态学特征并不能很有效准确地表达ECG信号细微的变化和隐藏的信息。

[0007] 基于统计的方法ECG信号特征,如通过高阶累积量提取特征来获取ECG信号的特征。此类方法可以抑制高斯噪声,检验和表征信号中隐藏的非线性的信息。但是通过实验验证,虽然能提取到一些隐藏的特征但分类效果并不明显,计算量大。

[0008] 基于变换的方法时将信号从时域中转换到频域中,比如傅里叶变换能得到信号的频域特征,但对于心电信号的非平稳性而言是不能够用该方法表示时频域之间的相互关系。用短时傅里叶变化、小波变换、S变换等时频域变换能适用于信号的非平稳性分析,反应

信号频率随时间变化的关系,能够有效提取非平稳信号的局部特征,有助于分类效果的提升。

[0009] 特征融合可以将两种不同的特征结合起来,相互补充,更有效地学习到ECG信号的信息有助于分类效果的提升。基于深度学习框架,实现端到端的输入输出,全连接层可以将其每一个结点都与上一层的所有结点相连,不需要进行相关性分析等复杂运算就可把前边提取到的特征综合起来。

发明内容

[0010] 本发明所要解决的技术问题是,提供一种不需要对心电信号进行压缩和双线性插值得到固定像素点的图片形式来提取特征的基于一维卷积神经网络和S变换的心律失常分类方法

[0011] 本发明所采用的技术方案是:一种基于一维卷积神经网络和S变换的心律失常分类方法,包括如下步骤:

[0012] 1) 对心电信号预处理;

[0013] 2) 利用一维卷积神经网络提取心电信号的深度非线性特征;

[0014] 3) 利用S变换提取心电信号的时频域特征;

[0015] 4) 将心电信号的深度非线性特征和心电信号的时频域特征融合到一起,经过全连接层继续进行特征学习,得到全连接层输出特征;

[0016] 5) 将全连接层输出特征接到一维卷积神经网络的softmax层进行分类;

[0017] 6) 输出分类结果。

[0018] 步骤1)所述的预处理包括:采用中值滤波和低通滤波器去除噪声,依据MIT-BIH数据库中的标注文件,找到心电信号R峰位置并提取心电信号片段。

[0019] 对所提取的心电信号片段进行z-score标准化,使数据符合标准正态分布。

[0020] 步骤2)所述的提取心电信号的深度非线性特征包括:

[0021] 设一维卷积神经网络结构为卷积层和池化层的组合,分别设定卷积核和池化层的大小,在卷积层和池化层之间加BatchNormalization规范化处理。

[0022] 在卷积层和池化层之间加BatchNormalization层网络规范化处理是:

[0023] 设心跳采样数据的输入向量为: $x_i^0 = [x_1, x_2, \dots, x_n]$,n是每个心跳的采样点个数,x是心跳采样数据,卷积层的输出为:

$$[0024] \quad c_i^{l,j} = \sigma(b_j + \sum_{m=1}^M W_m^j x_{i+m-1}^{0,j})$$

[0025] c_i 是第i个卷积层神经元的输出,i是卷积层的位置,I是层数,j是第I层的神经元的位置, σ 是激活函数,产生非线性输出,b是神经元的偏置,M是核的大小, W_m^j 是第j个神经元的权重,m是神经元的个数;

[0026] 根据BatchNormalization层网络的计算均值、标准差、归一化处理和重构公式,计算出原始网络所要学习的特征分布,具体公式如下:

$$[0027] \quad \mu_{\beta} \leftarrow \frac{1}{m} \sum_{i=0}^m c_i$$

$$[0028] \quad \sigma_{\beta}^2 \leftarrow \frac{1}{m} \sum_{i=0}^m (c_i - \mu_{\beta})^2$$

$$[0029] \quad \hat{c}_i \leftarrow \frac{c_i - \mu_{\beta}}{\sqrt{\sigma_{\beta}^2 + \epsilon}}$$

$$[0030] \quad y_i \leftarrow \gamma \hat{c}_i + \beta$$

[0031] 其中, c_i 为第 i 个卷积层中神经元的输出, m 为卷积层输出神经元的个数, μ_{β} 为卷积层中 m 个神经元输出的平均值, σ_{β}^2 为卷积层中 m 个神经元输出的方差, ϵ 为卷积层中 m 个神经元输出方差的随机扰动值, $\hat{c}_i$ 为卷积层中神经元的标准化输出值。 γ 是神经元标准化输出的重构权重, β 神经元标准化输出的重构偏置, y_i 第 i 个卷积层中神经元规范化处理的输出;

[0032] 池化层神经元的输出为:

$$[0033] \quad p_i^{l,j} = \max_{r \in R} (y_{i \times T + r}^{l,j})$$

[0034] P 为池化层神经元的输出, R 是池化窗口的大小, T 池化的步长, r 是池化窗口可选的整数值大小;

[0035] 所述池化层神经元的输出即为深度非线性特征。

[0036] 步骤4) 是将心电信号的深度非线性特征和心电信号的时频域特征拼接在一起, 得到一组特征向量, 将所述的特征向量输入到一维卷积神经网络的两个全链接层, 设定每个全链接层中神经元的个数, 进行特征学习。

[0037] 步骤5) 所述的分类是利用BP算法, 正向传播和反向传播不断调整权值和阈值, 使误差减小到最小值, 达到最优的分类结果。

[0038] 本发明的一种基于一维卷积神经网络和S变换的心律失常分类方法, 用1D-CNN的方法, 直接将一维的心电数据输入到网络中, 不需要对心电信号进行压缩和双线性插值来得到固定像素点的图片形式来提取特征。在每一层卷积核输出和激活函数之间加规范化 (BatchNormalization) 层, 该层将前一层的激活值重新规范化, 使得输出数据的均值接近0, 其标准差接近1, 能够加快收敛, 控制过拟合, 降低网络对初始化权重不敏感。本发明在特征提取方面结合了深度学习特征和时频域特征的优点组合成更完备的特征。该算法在训练过程中, 网络能够快速学习特征并且以很快的速度收敛, 而且提高了多种心律失常识别的准确率。利用本发明的方法, 能够提高分类结果的准确率, 对于医疗辅助检测心律失常很有帮助。

附图说明

[0039] 图1是本发明一种基于一维卷积神经网络和S变换的心律失常分类方法的流程图;

[0040] 图2是本发明实例中特征提取的流程图;

[0041] 图3是本发明实例中融合算法的流程图。

具体实施方式

[0042] 下面结合实施例和附图对本发明的一种基于一维卷积神经网络和S变换的心律失常分类方法做出详细说明。

[0043] 本发明的一种基于一维卷积神经网络和S变换的心律失常分类方法：首先对心电信号进行预处理，z-score标准化，随后进行两种特征提取，一种是将心电信号放入3层1D-CNN网络中提取特征，另一种是对心电信号进行S变换提取时频域特征。之后对两种方法提取的特征拼接在一起成为一个特征向量，再经过全连接层进一步学习特征，最后经过softmax进行分类，通过反向传播算法不断训练网络，以达到最优的训练效果，并能在测试集中准确分类。

[0044] 特征提取采用两种方法，一种是通过深度学习中CNN网络来提取心电信号抽象的非线性特征，网络中每一卷积层都经过规范层处理，对一个训练样本批量集使用了求和的输入分布来计算均值和方差，然后用这两个值来规范化神经元在每个训练样本的求和输入，减少前馈神经网络的训练时间。另一种是对心电信号进行S变换提取时频域特征，S变换采用高斯窗口函数，窗口宽度与频率倒数成正比，不用进行窗函数选择，表示各频率分量的相位谱与原始信号保持的直接关系，保留了各频率分量的绝对相位信息，同时，S变换提取的特征向量对噪声不敏感。

[0045] 特征融合充分考虑深度特征和时频域特征的各自的优点，将两种特征结合起来形成互补。时频域分析能够同时表示ECG信号中时间和频率的相互关系，通过提取S变换的幅度与相位作为时频域特征来揭示ECG信号隐藏的特征。经过CNN网络提取特征过程是对某个局部的加权求和，对应局部感知，得到局部抽象特征，能够增加信息量，增加了更多的抽象特征，有助于更精准的分类。所以提取深度特征和时频域特征并将其组合起来经过全连接层综合学习，得到更好的，有助于分类判别的特征。

[0046] 如图1所示，本发明的一种基于一维卷积神经网络和S变换的心律失常分类方法，具体包括如下步骤：

[0047] 1) 对心电信号预处理；包括：

[0048] 采用中值滤波和低通滤波器去除噪声，依据MIT-BIH数据库中的标注文件，找到心电信号R峰位置并提取心电信号片段；对所提取的心电信号片段进行z-score标准化，使数据符合标准正态分布。

[0049] 2) 利用一维卷积神经网络(1D-CNN网络)提取心电信号的深度非线性特征；包括：

[0050] 设一维卷积神经网络结构为卷积层和池化层的组合，分别设定卷积核和池化层的大小，在卷积层和池化层之间加BatchNormalization规范化处理。

[0051] 其中，所述的在卷积层和池化层之间加BatchNormalization层网络规范化处理是：

[0052] 设心跳采样数据的输入向量为： $x_i^0 = [x_1, x_2, \dots, x_n]$ ，n是每个心跳的采样点个数，x是心跳采样数据，卷积层的输出为：

$$[0053] \quad c_i^{l,j} = \sigma(b_j + \sum_{m=1}^M W_m^j x_{i+m-1}^{0j})$$

[0054] c_i 是第*i*个卷积层神经元的输出,*i*是卷积层的位置,*I*是层数,*j*是第*I*层的神经元的位置, σ 是激活函数,产生非线性输出,*b*是神经元的偏置,*M*是核的大小, w_m^j 是第*j*个神经元的权重,*m*是神经元的个数;

[0055] 根据BatchNormalization层网络的计算均值、标准差、归一化处理和重构公式,计算出原始网络所要学习的特征分布,具体公式如下:

$$[0056] \quad \mu_\beta \leftarrow \frac{1}{m} \sum_{i=0}^m c_i$$

$$[0057] \quad \sigma_\beta^2 \leftarrow \frac{1}{m} \sum_{i=0}^m (c_i - \mu_\beta)^2$$

$$[0058] \quad \hat{c}_i \leftarrow \frac{c_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \epsilon}}$$

$$[0059] \quad y_i \leftarrow \gamma \hat{c}_i + \beta$$

[0060] 其中, c_i 为第*i*个卷积层中神经元的输出,*m*为卷积层输出神经元的个数, μ_β 为卷积层中*m*个神经元输出的平均值, σ_β^2 为卷积层中*m*个神经元输出的方差, ϵ 为卷积层中*m*个神经元输出的方差的随机扰动值, $\hat{c}_i$ 为卷积层中神经元的标准化输出值。 γ 是神经元标准化输出的重构权重, β 神经元标准化输出的重构偏置, y_i 第*i*个卷积层中神经元规范化处理的输出;

[0061] 池化层神经元的输出:

$$[0062] \quad p_i^{l,j} = \max_{r \in R} (y_{i \times T + r}^{l,j})$$

[0063] *P*为池化层神经元的输出,*R*是池化窗口的大小,*T*池化的步长,*r*是池化窗口可选的整数值大小;

[0064] 所述池化层神经元的输出即为深度非线性特征。

[0065] 3) 利用S变换提取心电信号的时频域特征;

[0066] 4) 将心电信号的深度非线性特征和心电信号的时频域特征融合到一起,经过全连接层继续进行特征学习,得到全连接层输出特征;

[0067] 是将心电信号的深度非线性特征和心电信号的时频域特征拼接在一起,得到一组特征向量,将所述的特征向量输入到一维卷积神经网络的两个全链接层,设定每个全链接层中神经元的个数,进行特征学习。

[0068] 5) 将全连接层输出特征接到一维卷积神经网络的softmax层进行分类;

[0069] 所述的分类是利用BP算法,正向传播和反向传播不断调整权值和阈值,使误差减小到最小值,达到最优的分类结果。

[0070] 6) 输出分类结果。

[0071] 下面给出具体实例:

[0072] 本实例的ECG信号数据来自公开数据库中。实例具体过程如下:

[0073] (1) 预处理:在噪声去除方面,使用中值滤波法去除基线漂移,利用低通滤波器去除电力线干扰和高频噪声。R波检测采用幅度阈值、小波阈值。

[0074] (2) 特征提取:如图2所示,根据预处理检测到的R位置,取R波位置前90个采样点信号,R波位置后197个采样点信号,共288个采样点的ECG片段,提取1D-CNN特征和时频域特征。

[0075] 本实例的1D-CNN特征是:搭建3层的1D-CNN网络,每一层CNN网络中包含一个卷积层和一个池化层。卷积核的大小为3,个数分别为64,128,256。池化层的大小分别为3,3,2。在卷积层和池化层中间加一BatchNormalization层。CNN具有很大的潜力来提取信号的特征,在卷积层中,前一层的特征图与多个卷积核(滤波器)进行卷积,并通过偏置相加,然后通过激活函数产生下一层的特征图。心跳采样数据的输入向量为: $x_i^0 = [x_1, x_2, \dots, x_n]$,n是每个心跳的采样点个数。卷积层的输出:

$$[0076] \quad C_i^{l,j} = \sigma(b_j + \sum_{m=1}^M W_m^j x_{i+m-1}^{0j})$$

[0077] l是层数, σ 是激活函数,产生非线性输出,b是jth特征谱的偏置,M是核的大小, W_m^j 是jth特征谱的权重,mth是滤波器。

[0078] BatchNormalization层网络的前向传导公式:

$$[0079] \quad \mu_\beta \leftarrow \frac{1}{m} \sum_{i=0}^m x_i$$

$$[0080] \quad \sigma_\beta^2 \leftarrow \frac{1}{m} \sum_{i=0}^m (x_i - \mu_\beta)^2$$

$$[0081] \quad \hat{x}_i \leftarrow \frac{x_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \epsilon}}$$

$$[0082] \quad y_i \leftarrow \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i)$$

[0083] 上述公式分别为计算均值、标准差、归一化处理、重构变化公式,让网络可以学习恢复出原始网路所要学习的特征分布。

[0084] 池化层也叫下采样层,通过对输入特征谱进行二次采样,增加输入失真的不变性,从而降低特征谱的分辨率,池化层的输出:

$$[0085] \quad P_i^{l,j} = \max_{r \in R} (C_{i \times T + r}^{l,j})$$

[0086] R是池化窗口的大小,T池化的步长。

[0087] 时频特征:对288个采样点的ECG片段进行S变换,利用数学统计方法获取ECG信号频率范围内的时频特征。S变换是基于可变窗口的短时傅里叶变换和可缩放的定位高斯窗口的小波变换的扩展而来的,S变换为:

$$[0088] \quad S(\tau, f) = \int_{-\infty}^{\infty} x(t) w(t - \tau) e^{-i2\pi f t} dt$$

$$[0089] \quad w(t - \tau) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(t-\tau)^2}{2\sigma^2}}$$

[0090] 其中t为时间, τ 为时间窗口,f为频率,w(t- τ)为高斯窗口, $\sigma = 1/|f|$ 是关于频数的

倒数,由此S变换的窗口形状可随频率的变化而变化。连续信号 $x(t)$ 的离散形式为 $x[kT]$,S变换的离散形式为:

$$[0091] \quad \begin{cases} S[jT, \frac{n}{NT}] = \sum_{m=0}^{N-1} X[\frac{m+n}{NT}] e^{\frac{2\pi^2 m^2}{n^2}} e^{\frac{i2\pi m j}{N}}, n \neq 0 \\ S[jT, 0] = \frac{1}{N} \sum_{k=0}^{N-1} x[kT], n = 0 \end{cases}$$

[0092] 其中N为总采样点数,T为时域采样间隔, $j, m, n=0, 1, \dots, N-1$ 分别代表采样点的不同位置, $X[\frac{n+m}{NT}]$ 为 $x[kT]$ 的N点离散傅里叶变换,k为总采样点数中离散点位置。信号S变换后得到一个 $N \times M$ 的复时频矩阵,其行为频率值,列为采样点。

[0093] (3) 特征融合:如图3所示,将CNN特征和S变换提取的时频域特征拼接在一起,得到一组特征向量,将组合起来的特征输入到全连接层。第一个全连接层有64个神经元,第二的全连接层有32个神经元,进行特征学习。

[0094] (4) 多分类:在网络的最后用softmax层实现多种心律失常识别。

[0095] 训练过程中通过前向传播初始化权重,并且通过随机梯度下降最小化损失函数。然后执行反向传播,其中预测误差在每层的每个参数上传播回来,并且通过计算卷积权重的梯度来调整权重。重复执行正向和反向传播,直到损失函数值不再减小,分类效果达到最佳。

[0096] 下面以具体的实验来验证本发明方法的有效性:

[0097] MIT-BIH心律失常数据库包含48条ECG记录,每条记录由两种不同类型导联(记为A、B导联)记录了长约30分钟的数据,采样率为360Hz;其中45条记录的A导联采用MLII导联,其余采用V5导联;40条记录的B导联采用V1导联,其余采用II、V2、V4和V5导联。本实验采用的ECG数据集来自MIT数据库中MLII导联记录的数据,根据AAMI标准共有5种心跳类型:正常搏动(normal beats)、室上异位搏动(supraventricular ectopic beats)、心室异位搏动(ventricular ectopic beats)、融合心跳(fusion beats)、无法分类心跳(unclassifiable beats),对这5种心跳类型进行分类。

[0098] 表1给出了使用不同提取特征方法进行分类的性能,实验结果如下:

[0099] 表1:不同特征提取方法下的分类性能

[0100]	方法	准确率/%
	1D-CNN	97.81
	S 变换	96.78
	1D-CNN+S 变换	98.98

[0101] 通过表1可以看出,本发明的一种基于一维卷积神经网络和S变换的心律失常分类方法明显的优于单独使用1D-CNN和S变化的方法,分类准确率提高显著。




图1




图2




图3

专利名称(译)	一种基于一维卷积神经网络和S变换的心律失常分类方法		
公开(公告)号	CN107811626A	公开(公告)日	2018-03-20
申请号	CN2017110814713.5	申请日	2017-09-10
[标]申请(专利权)人(译)	天津大学		
申请(专利权)人(译)	天津大学		
当前申请(专利权)人(译)	天津大学		
[标]发明人	吕卫 王粟瑶 褚晶辉		
发明人	吕卫 王粟瑶 褚晶辉		
IPC分类号	A61B5/024 A61B5/0452 A61B5/00		
CPC分类号	A61B5/024 A61B5/0452 A61B5/7267		
外部链接	Espacenet SIPO		

摘要(译)

一种基于一维卷积神经网络和S变换的心律失常分类方法：对心电信号预处理；利用一维卷积神经网络提取心电信号的深度非线性特征；利用S变换提取心电信号的时频域特征；将心电信号的深度非线性特征和心电信号的时频域特征融合到一起，经过全连接层继续进行特征学习，得到全连接层输出特征；全连接层输出特征接到一维卷积神经网络的softmax层进行分类；输出分类结果。本发明不需要对心电信号进行压缩和双线性插值来得到固定像素点的图片形式来提取特征。本发明在特征提取方面结合了深度学习特征和时频域特征的优点组合成更完备的特征，能够加快收敛，控制过拟合，降低网络对初始化权重不敏感。提高了多种心律失常识别的准确率。

