



(12)发明专利申请

(10)申请公布号 CN 110584654 A

(43)申请公布日 2019. 12. 20

(21)申请号 201910955726.3

(22)申请日 2019.10.09

(71)申请人 中山大学

地址 510275 广东省广州市海珠区新港西路135号

(72)发明人 李惠川 刘树郁

(74)专利代理机构 广州粤高专利商标代理有限公司 44102

代理人 张金福

(51)Int.Cl.

A61B 5/0402(2006.01)

A61B 5/0472(2006.01)

A61B 5/00(2006.01)

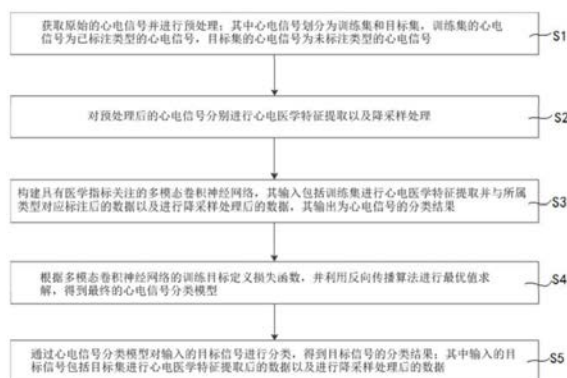
权利要求书3页 说明书7页 附图1页

(54)发明名称

一种基于多模态卷积神经网络心电信号分类方法

(57)摘要

本发明公开了一种基于多模态卷积神经网络心电信号分类方法,通过对大量已标注分类结果的心电数据集训练得到一个由三个支路组成的具有医学指标关注的多模态卷积神经网络,分别为第一支路、第二支路和第三支路,其中第一支路用于处理预先提取出来的心电特征信息,该心电特征信息能有效辅助该多模态卷积神经网络进行最终预测;第一支路用以处理原始的心电信号;第三支路将第一支路与第二支路的输出进行融合并对输入的心电信号类型进行分类。本发明方法通过结合三条支路的损失函数,采取非端到端的训练方式,并引入具有重要价值的传统医学指标关注,从而准确预测出心电信号的所属类别,取得良好的心电分类效果。



1. 一种基于多模态卷积神经网络心电信号分类方法,其特征在于,包括以下步骤:

S1. 获取原始的心电信号并对所述心电信号进行预处理;其中所述心电信号划分为训练集和目标集,所述训练集的心电信号为已标注类型的心电信号,所述目标集的心电信号为未标注类型的心电信号;

S2. 对预处理后的心电信号分别进行心电医学特征提取以及降采样处理;

S3. 构建具有医学指标关注的多模态卷积神经网络,其输入包括所述训练集进行心电医学特征提取并与所属类型对应标注后的数据以及进行降采样处理后的数据,其输出为心电信号的分类结果;

S4. 根据所述多模态卷积神经网络的训练目标定义损失函数,并利用反向传播算法进行最优值求解,得到最终的心电信号分类模型;

S5. 通过所述心电信号分类模型对输入的目标信号进行分类,得到目标信号的分类结果;其中输入的目标信号包括所述目标集进行心电医学特征提取后的数据以及进行降采样处理后的数据。

2. 根据权利要求1所述的基于多模态卷积神经网络心电信号分类方法,其特征在于,所述步骤S1中对所述心电信号进行预处理具体包括:

S11. 对获取得到的心电信号进行模数转换,得到心电数字信号;

S12. 对所述心电数字信号进行分段处理,得到若干段时长为L秒的心电数字信号;其中L小于等于60秒;

S13. 对每段心电数字信号进行滤波处理。

3. 根据权利要求1所述的基于多模态卷积神经网络心电信号分类方法,其特征在于,所述步骤S2中提取的心电医学特征包括:R波幅值、RR间期、P波幅值、PR间期4组特征。

4. 根据权利要求1所述的基于多模态卷积神经网络心电信号分类方法,其特征在于,所述步骤S2中进行降采样处理后,所述心电信号的频率降为100Hz。

5. 根据权利要求3所述的基于多模态卷积神经网络心电信号分类方法,其特征在于,所述步骤S2中对预处理后的心电信号分别进行心电医学特征提取的具体步骤包括:

S21. 使用Pan-Tompkins算法对预处理后的心电信号进行QRS波群检测,定位R波的位置;

S22. 根据步骤S21中定位的R波位置,检索R波发生前一段时间内心电幅值的最大值处,即为P波位置;

S23. 根据步骤S21和S22定位的R波位置及P波位置,分别确定R波和P波在所述心电信号中的幅值大小,计算得到R波幅值、RR间期、P波幅值、PR间期4组特征;

S24. 对计算得到的4组特征进行对齐,所述对齐以其中最长片段的长度为标准,以自我填充的数据对齐方式补齐至4组特征的长度一致;

S25. 对补齐后的4组特征数据进行拼接打包。

6. 根据权利要求1所述的基于多模态卷积神经网络心电信号分类方法,其特征在于,步骤S3所述的具有医学指标关注的多模态卷积神经网络包括三条支路,其中第一支路用于处理所述训练集进行心电医学特征提取并与所属类型对应标注后,第二支路用于处理所述训练集进行降采样处理的数据,第三支路用于对所述第一支路和第二支路的信息进行特征融合并进行心电信号分类。

7. 根据权利要求6所述的基于多模态卷积神经网络心电信号分类方法,其特征在于,所述步骤S4中根据所述多模态卷积神经网络的训练目标定义损失函数的具体步骤包括:

S41. 将所述多模态卷积神经网络的训练过程等同为以下的最值求解过程:

$$\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c = \arg \max_{\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c} P(\mathbf{w}_a | \mathbf{X}, \mathbf{T}) P(\mathbf{w}_b | \mathbf{Y}, \mathbf{T}) P(\mathbf{w}_c | \mathbf{Z}, \mathbf{T})$$

其中P表示概率; $\mathbf{X} = \{X_1, \dots, X_N\}$,表示所述训练集进行降采样处理后的数据; $\mathbf{T} = \{T_1, \dots, T_N\}$,表示所述训练集的标签; \mathbf{Y} 表示所述训练集进行心电医学特征提取后的数据; \mathbf{Z} 表示第一支路和第二支路的融合特征; $\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c$ 分别对应所述多模态卷积神经网络中三条支路的网络参数;

S42. 根据贝叶斯公式以及条件概率和联合分布的原理,且P(X,T)与网络参数 \mathbf{w}_a 相互独立,得到下式:

$$P(\mathbf{w}_a | \mathbf{X}, \mathbf{T}) = \frac{P(\mathbf{X}, \mathbf{T} | \mathbf{w}_a) P(\mathbf{w}_a)}{P(\mathbf{X}, \mathbf{T})} = P(\mathbf{T} | \mathbf{X}, \mathbf{w}_a) P(\mathbf{X} | \mathbf{w}_a) P(\mathbf{w}_a)$$

其中 $\mathbf{X} = \{X_1, \dots, X_N\}$,表示所述训练集进行降采样处理后的数据; $\mathbf{T} = \{T_1, \dots, T_N\}$,表示所述训练集的标签; \mathbf{w}_a 表示多模态卷积神经网络中第一支路的网络参数;

其中P(X| \mathbf{w}_a)视为常量,得到下式:

$$P(\mathbf{w}_a | \mathbf{X}, \mathbf{T}) = P(\mathbf{T} | \mathbf{X}, \mathbf{w}_a) P(\mathbf{w}_a)$$

同理对P($\mathbf{w}_b | \mathbf{Y}, \mathbf{T}$)和P($\mathbf{w}_c | \mathbf{Z}, \mathbf{T}$)分别作以上的变换,则步骤S41的最值求解过程转换为:

$$\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c = \arg \min_{\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c} -P(\mathbf{T} | \mathbf{X}, \mathbf{w}_a) P(\mathbf{T} | \mathbf{X}, \mathbf{w}_b) P(\mathbf{T} | \mathbf{X}, \mathbf{w}_c) P(\mathbf{w}_a) P(\mathbf{w}_b) P(\mathbf{w}_c)$$

S43. 若 $i \neq j$, X_i, X_j 相互独立,且P(w)是满足均值为0的高斯分布 $\mathcal{N}(\mathbf{w}; 0)$,取得w最优解的过程便是最小化以下损失函数的过程:

$$\mathcal{L} = \prod_i -P(T_i | X_i, \mathbf{w}_a) P(T_i | Y_i, \mathbf{w}_b) P(T_i | Z_i, \mathbf{w}_c) \mathcal{N}(\mathbf{w}_a; 0) \mathcal{N}(\mathbf{w}_b; 0) \mathcal{N}(\mathbf{w}_c; 0)$$

其中 \mathcal{L} 表示总的损失函数;

S44. 对步骤S43的损失函数作对数变换,得到:

$$\mathcal{L} = \sum_i -\ln P(T_i | X_i, \mathbf{w}_a) + \gamma_a \|\tilde{\mathbf{w}}_a\|^2 - \ln P(T_i | Y_i, \mathbf{w}_b) + \gamma_b \|\tilde{\mathbf{w}}_b\|^2 - \ln P(T_i | Z_i, \mathbf{w}_c) + \gamma_c \|\tilde{\mathbf{w}}_c\|^2$$

其中 γ_a 为常量;

S45. 将步骤S44中进行对数变换后的损失函数分为 \mathcal{L}_a , \mathcal{L}_b , \mathcal{L}_c 三个部分,分别对应于所述三条支路,其中 \mathcal{L}_a 表示为下式:

$$\mathcal{L}_a = \sum_i \underbrace{-\ln P(T_i | X_i, \mathbf{w}_a)}_{\mathcal{L}_T} + \underbrace{\eta_a \|\tilde{\mathbf{w}}_a\|^2}_{\mathcal{L}_w}$$

其中 \mathcal{L}_T 用交叉熵表示后,得到下式:

$$\mathcal{L}_a = \eta_T \sum_i \sum_j T_{i,j} \ln \hat{T}_{X,i,j} + \eta_a \|\tilde{\mathbf{w}}_a\|^2$$

其中 η_T, η_a 为参数; $T_{i,j}$ 表示真实标签, $\hat{T}_{X,i,j}$ 表示通过第一支路预测出来的类别;

同理对 \mathcal{L}_b , \mathcal{L}_c 分别作以上的变换,则包括 \mathcal{L}_a , \mathcal{L}_b , \mathcal{L}_c 三个部分的总的损失函数为:

$$\mathcal{L} = \alpha \mathcal{L}_a + \beta \mathcal{L}_b + \chi \mathcal{L}_c$$

其中 α, β, χ 分别表示三个参数。

8. 根据权利要求7所述的基于多模态卷积神经网络心电信号分类方法, 其特征在于, 所述步骤S4中利用反向传播算法进行最优值求解, 得到最终的心电信号分类模型具体包括以下步骤:

S46. 冻结第二支路和第三支路的网络参数, 分别将第二支路和第三支路的损失权重置为0, 对步骤S45得到的总的损失函数使用梯度下降和反向传播算法对第一支路进行权重更新, 直至所述第一支路的网络参数收敛;

S47. 冻结第一支路的网络参数, 将第一支路损失权重置为0, 将第二支路和第三支路的损失权重进行重置, 对步骤S45得到的总的损失函数使用梯度下降和反向传播算法对第二支路和第三支路进行权重更新, 直至所述多模态卷积神经网络收敛, 得到最终的心电信号分类模型。

一种基于多模态卷积神经网络心电信号分类方法

技术领域

[0001] 本发明涉及心电信号分类技术领域,尤其涉及一种基于多模态卷积神经网络心电信号分类方法。

背景技术

[0002] 心电信号分类结果是医生诊断心脏病疾患的重要辅助手段和参考信息,随着深度学习的兴起,目前相继的出现了用神经网络应对心电信号分类的方法,并且取得了突破性的结果。然而目前用神经网络应对心电信号分类的方法多为对心电信号进行直接的分析,抛却当下医学已发展而来的分析指标,整个模型对于人们而言是一个“黑匣子”,无法满足实际的给医生提供辅助诊断信息的需要。

发明内容

[0003] 本发明为解决现有的心电信号分类方法均难以实现高准确率的问题,提供了一种基于多模态卷积神经网络心电信号分类方法。

[0004] 为实现以上发明目的,而采用的技术手段是:

[0005] 一种基于多模态卷积神经网络心电信号分类方法,包括以下步骤:

[0006] S1.获取原始的心电信号并对所述心电信号进行预处理;其中所述心电信号划分为训练集和目标集,所述训练集的心电信号为已标注类型的心电信号,所述目标集的心电信号为未标注类型的心电信号;

[0007] S2.对预处理后的心电信号分别进行心电医学特征提取以及降采样处理;

[0008] S3.构建具有医学指标关注的多模态卷积神经网络,其输入包括所述训练集进行心电医学特征提取并与所属类型对应标注后的数据以及进行降采样处理后的数据,其输出为心电信号的分类结果;

[0009] S4.根据所述多模态卷积神经网络的训练目标定义损失函数,并利用反向传播算法进行最优值求解,得到最终的心电信号分类模型;

[0010] S5.通过所述心电信号分类模型对输入的目标信号进行分类,得到目标信号的分类结果;其中输入的目标信号包括所述目标集进行心电医学特征提取后的数据以及进行降采样处理后的数据。

[0011] 上述方案中,通过设计具有医学指标关注的多模态卷积神经网络,并输入大量已标注分类结果的心电数据进行端对端训练,预先提取出来的心电特征信息有效辅助网络进行最终预测,从而准确预测出心电信号的所属类别,可用作后续心脏病疾患判断的参考信息。

[0012] 其中的第一支路处理预先提取出来的心电特征信息,用于作为医学指标关注,从而有效辅助网络进行心电检测;第二支路处理原始的心电信号;第三支路将第一支路与第二支路的输出进行融合并对目标心电信号进行分类。

[0013] 优选的,所述步骤S1中对所述心电信号进行预处理具体包括:

[0014] S11.对获取到的心电信号进行模数转换,得到心电数字信号;

[0015] S12.对所述心电数字信号进行分段处理,得到若干段时长为L秒的心电数字信号;其中L小于等于60秒;

[0016] S13.对每段心电数字信号进行滤波处理;在本优选方案中,滤波的频谱范围在3Hz至45Hz之间,用于滤除其中心电信号以为的噪声,以进一步保障后续检测的准确率;

[0017] 优选的,所述步骤S2中提取的心电医学特征包括:R波幅值、RR间期、P波幅值、PR间期4组特征。

[0018] 优选的,所述步骤S2中进行降采样处理后,所述心电信号的频率降为100Hz。在本优选方案中,将心电信号进行降采样处理可以简化数据量、提高计算效率。

[0019] 优选的,所述步骤S2中对预处理后的心电信号分别进行心电医学特征提取的具体步骤包括:

[0020] S21.使用Pan-Tompkins算法对预处理后的心电信号进行QRS波群检测,定位R波的位置;

[0021] S22.根据步骤S21中定位的R波位置,检索R波发生前一段时间内心电幅值的最大值处,即为P波位置;由于心电信号的PR间期通常情况下在0.12s至0.20s之间,检索R波发生前一段时间内心电幅值的最大值处即可提取出心电信号的P波位置;

[0022] S23.根据步骤S21和S22定位的R波位置及P波位置,分别确定R波和P波在所述心电信号中的幅值大小,计算得到R波幅值、RR间期、P波幅值、PR间期4组特征;

[0023] S24.对计算得到的4组特征进行对齐,所述对齐以其中最长片段的长度为标准,以自我填充的数据对齐方式补齐至4组特征的长度一致;

[0024] S25.对补齐后的4组特征数据进行拼接打包。

[0025] 优选的,步骤S3所述的具有医学指标关注的多模态卷积神经网络包括三条支路,其中第一支路用于处理所述训练集进行心电医学特征提取并与所属类型对应标注后,第二支路用于处理所述训练集进行降采样处理的数据,第三支路用于对所述第一支路和第二支路的信息进行特征融合并进行心电信号分类。

[0026] 优选的,所述步骤S4中根据所述多模态卷积神经网络的训练目标定义损失函数的具体步骤包括:

[0027] S41.将所述多模态卷积神经网络的训练过程等同为以下的最值求解过程:

[0028] $w_a, w_b, w_c = \arg \max_{w_a, w_b, w_c} P(w_a | X, T) P(w_b | Y, T) P(w_c | Z, T)$

[0029] 其中P表示概率; $X = \{X_1, \dots, X_N\}$,表示所述训练集进行降采样处理后的数据; $T = \{T_1, \dots, T_N\}$,表示所述训练集的标签;Y表示所述训练集进行心电医学特征提取后的数据;Z表示第一支路和第二支路的融合特征; w_a, w_b, w_c 分别对应所述多模态卷积神经网络中三条支路的网络参数;

[0030] S42.根据贝叶斯公式以及条件概率和联合分布的原理,且P(X,T)与网络参数 w_a 相互独立,得到下式:

[0031] $P(w_a | X, T) = \frac{P(X, T | w_a) P(w_a)}{P(X, T)} = P(T | X, w_a) P(X | w_a) P(w_a)$

[0032] 其中 $X = \{X_1, \dots, X_N\}$,表示所述训练集进行降采样处理后的数据; $T = \{T_1, \dots,$

$T_N\}$,表示所述训练集的标签; w_a 表示多模态卷积神经网络中第一支路的网络参数;

[0033] 其中 $P(X|w_a)$ 视为常量,得到下式:

[0034] $P(w_a|X,T)=P(T|X,w_a)P(w_a)$

[0035] 同理对 $P(w_b|Y,T)$ 和 $P(w_c|Z,T)$ 分别作以上的变换,则步骤S41的最值求解过程转换为:

[0036] $w_a, w_b, w_c = \arg \min_{w_a, w_b, w_c} -P(T|X, w_a)P(T|X, w_b)P(T|X, w_c)P(w_a)P(w_b)P(w_c)$

[0037] S43.若 $i \neq j$, X_i, X_j 相互独立,且 $P(w)$ 是满足均值为0的高斯分布 $\mathcal{N}(w;0)$,取得 w 最优解的过程便是最小化以下损失函数的过程:

[0038] $\mathcal{L} = \prod_i -P(T_i|X_i, w_a)P(T_i|Y_i, w_b)P(T_i|Z_i, w_c)\mathcal{N}(w_a;0)\mathcal{N}(w_b;0)\mathcal{N}(w_c;0)$

[0039] 其中 \mathcal{L} 表示总的损失函数;

[0040] S44.对步骤S43的损失函数作对数变换,得到:

[0041] $\mathcal{L} = \sum_i -\ln P(T_i|X_i, w_a) + \gamma_a \|\bar{w}_a\|^2 - \ln P(T_i|Y_i, w_b) + \gamma_b \|\bar{w}_b\|^2 - \ln P(T_i|Z_i, w_c) + \gamma_c \|\bar{w}_c\|^2$

[0042] 其中 γ_a 为常量;

[0043] S45.将步骤S44中进行对数变换后的损失函数分为 \mathcal{L}_a , \mathcal{L}_b , \mathcal{L}_c 三个部分,分别对应于所述三条支路,其中 \mathcal{L}_a 表示为下式:

[0044] $\mathcal{L}_a = \sum_i \underbrace{-\ln P(T_i|X_i, w_a)}_{\mathcal{L}_T} + \underbrace{\eta_a \|\bar{w}_a\|^2}_{\mathcal{L}_w}$

[0045] 其中 \mathcal{L}_T 用交叉熵表示后,得到下式:

[0046] $\mathcal{L}_a = \eta_T \sum_i \sum_j T_{i,j} \ln \hat{T}_{X,i,j} + \eta_a \|\bar{w}_a\|^2$

[0047] 其中 η_T, η_a 为参数; $T_{i,j}$ 表示真实标签, $\hat{T}_{X,i,j}$ 表示通过第一支路预测出来的类别;

[0048] 同理对 \mathcal{L}_b , \mathcal{L}_c 分别作以上的变换,则包括 \mathcal{L}_a , \mathcal{L}_b , \mathcal{L}_c 三个部分的总的损失函数为:

[0049] $\mathcal{L} = \alpha \mathcal{L}_a + \beta \mathcal{L}_b + \chi \mathcal{L}_c$

[0050] 其中 α, β, χ 分别表示三个参数。

[0051] 优选的,所述步骤S4中利用反向传播算法进行最优值求解,得到最终的心电信号分类模型具体包括以下步骤:

[0052] S46.冻结第二支路和第三支路的网络参数,分别将第二支路和第三支路的损失权重重置为0,对步骤S45得到的总的损失函数使用梯度下降和反向传播算法对第一支路进行权重更新,直至所述第一支路的网络参数收敛;

[0053] S47.冻结第一支路的网络参数,将第一支路损失权重重置为0,将第二支路和第三支路的损失权重进行重置,对步骤S45得到的总的损失函数使用梯度下降和反向传播算法对第二支路和第三支路进行权重更新,直至所述多模态卷积神经网络收敛,得到最终的心电信号分类模型。

[0054] 与现有技术相比,本发明技术方案的有益效果是:

[0055] 本发明提供了一种基于多模态卷积神经网络心电信号分类方法,通过设计具有医学指标关注的多模态卷积神经网络,其中的第一支路处理预先提取出来的心电特征信息,用于作为医学指标关注,从而有效辅助网络进行心电检测;第二支路处理原始的心电信号;第三支路将第一支路与第二支路的输出进行融合并对目标心电信号进行分类。本发明方法通过结合三条支路的损失函数,采取非端到端的训练方式,并引入具有重要价值的传统医学指标关注,从而准确预测出心电信号的所属类别,取得良好的心电分类效果。

附图说明

[0056] 图1为本发明的总流程图。

[0057] 图2为目标信号的心电信号分类过程的流程图。

具体实施方式

[0058] 附图仅用于示例性说明,不能理解为对本专利的限制;

[0059] 为了更好说明本实施例,附图某些部件会有省略、放大或缩小,并不代表实际产品的尺寸;

[0060] 对于本领域技术人员来说,附图中某些公知结构及其说明可能省略是可以理解的。

[0061] 下面结合附图和实施例对本发明的技术方案做进一步的说明。

[0062] 实施例1

[0063] 一种基于多模态卷积神经网络心电信号分类方法,如图1所示,包括以下步骤:

[0064] S1. 获取原始的心电信号并对所述心电信号进行预处理;其中所述心电信号划分为训练集和目标集,所述训练集的心电信号为已标注类型的心电信号,所述目标集的心电信号为未标注类型的心电信号;

[0065] S2. 对预处理后的心电信号分别进行心电医学特征提取以及降采样处理;

[0066] S3. 构建具有医学指标关注的多模态卷积神经网络,其输入包括所述训练集进行心电医学特征提取并与所属类型对应标注后的数据以及进行降采样处理后的数据,其输出为心电信号的分类结果;

[0067] S4. 根据所述多模态卷积神经网络的训练目标定义损失函数,并利用反向传播算法进行最优值求解,得到最终的心电信号分类模型;

[0068] S5. 通过所述心电信号分类模型对输入的目标信号进行分类,得到目标信号的分类结果;其中输入的目标信号包括所述目标集进行心电医学特征提取后的数据以及进行降采样处理后的数据。

[0069] 实施例2

[0070] 一种基于多模态卷积神经网络心电信号分类方法,如图1所示,包括以下步骤:

[0071] S1. 获取原始的心电信号并对所述心电信号进行预处理;其中所述心电信号划分为训练集和目标集,所述训练集的心电信号为已标注类型的心电信号,所述目标集的心电信号为未标注类型的心电信号;

[0072] 其中对所述心电信号进行预处理具体包括:

[0073] S11. 对获取得到的心电信号进行模数转换,得到心电数字信号;

[0074] S12.对所述心电数字信号进行分段处理,得到若干段时长为L秒的心电数字信号;其中L小于等于60秒;

[0075] S13.对每段心电数字信号进行滤波处理。

[0076] S2.对预处理后的心电信号分别进行心电医学特征提取以及降采样处理;提取的心电医学特征包括:R波幅值、RR间期、P波幅值、PR间期4组特征;降采样处理后心电信号的频率降为100Hz;

[0077] 其中对预处理后的心电信号分别进行心电医学特征提取的具体步骤包括:

[0078] S21.使用Pan-Tompkins算法对预处理后的心电信号进行QRS波群检测,定位R波的位置;

[0079] S22.根据步骤S21中定位的R波位置,检索R波发生前一段时间内心电幅值的最大值处,即为P波位置;

[0080] S23.根据步骤S21和S22定位的R波位置及P波位置,分别确定R波和P波在所述心电信号中的幅值大小,计算得到R波幅值、RR间期、P波幅值、PR间期4组特征;

[0081] S24.对计算得到的4组特征进行对齐,所述对齐以其中最长片段的长度为标准,以自我填充的数据对齐方式补齐至4组特征的长度一致;此处以自我填充的方式进行数据对齐,即首先获取4组特征数据中长度最长的片段作为标准,然后短序列不足的部分复制自身的数据填补缺少部分的数据,从第一个点开始复制直至与最长片段的长度相等为止;

[0082] S25.对补齐后的4组特征数据进行拼接打包。

[0083] S3.构建具有医学指标关注的多模态卷积神经网络,该网络包括三条支路,其中第一支路用于处理所述训练集进行心电医学特征提取并与所属类型对应标注后,第二支路用于处理所述训练集进行降采样处理的数据,第三支路用于对所述第一支路和第二支路的信息进行特征融合并进行心电信号分类,该网络的输入包括所述训练集进行心电医学特征提取并与所属类型对应标注后的数据以及进行降采样处理后的数据,其输出为心电信号的分类结果;

[0084] S4.根据所述多模态卷积神经网络的训练目标定义损失函数,并利用反向传播算法进行最优值求解,得到最终的心电信号分类模型;具体包括如下步骤:

[0085] S41.将所述多模态卷积神经网络的训练过程等同为以下的最值求解过程:

$$[0086] \quad \mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c = \arg \max_{\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c} P(\mathbf{w}_a | \mathbf{X}, \mathbf{T}) P(\mathbf{w}_b | \mathbf{Y}, \mathbf{T}) P(\mathbf{w}_c | \mathbf{Z}, \mathbf{T})$$

[0087] 其中P表示概率; $\mathbf{X} = \{X_1, \dots, X_N\}$,表示所述训练集进行降采样处理后的数据; $\mathbf{T} = \{T_1, \dots, T_N\}$,表示所述训练集的标签;Y表示所述训练集进行心电医学特征提取后的数据;Z表示第一支路和第二支路的融合特征; $\mathbf{w}_a, \mathbf{w}_b, \mathbf{w}_c$ 分别对应所述多模态卷积神经网络中三条支路的网络参数;

[0088] S42.根据贝叶斯公式以及条件概率和联合分布的原理,且P(X,T)与网络参数 \mathbf{w}_a 相互独立,得到下式:

$$[0089] \quad P(\mathbf{w}_a | \mathbf{X}, \mathbf{T}) = \frac{P(\mathbf{X}, \mathbf{T} | \mathbf{w}_a) P(\mathbf{w}_a)}{P(\mathbf{X}, \mathbf{T})} = P(\mathbf{T} | \mathbf{X}, \mathbf{w}_a) P(\mathbf{X} | \mathbf{w}_a) P(\mathbf{w}_a)$$

[0090] 其中 $\mathbf{X} = \{X_1, \dots, X_N\}$,表示所述训练集进行降采样处理后的数据; $\mathbf{T} = \{T_1, \dots, T_N\}$,表示所述训练集的标签; \mathbf{w}_a 表示多模态卷积神经网络中第一支路的网络参数;

[0091] 其中 $P(X|w_a)$ 视为常量,得到下式:

[0092] $P(w_a|X, T) = P(T|X, w_a)P(w_a)$

[0093] 同理对 $P(w_b|Y, T)$ 和 $P(w_c|Z, T)$ 分别作以上的变换,则步骤S41的最值求解过程转换为:

[0094] $w_a, w_b, w_c = \arg \min_{w_a, w_b, w_c} -P(T|X, w_a)P(T|X, w_b)P(T|X, w_c)P(w_a)P(w_b)P(w_c)$

[0095] S43. 若 $i \neq j$, X_i, X_j 相互独立, 且 $P(w)$ 是满足均值为0的高斯分布 $\mathcal{N}(w; 0)$, 取得 w 最优解的过程便是最小化以下损失函数的过程:

[0096] $\mathcal{L} = \prod_i -P(T_i|X_i, w_a)P(T_i|Y_i, w_b)P(T_i|Z_i, w_c)\mathcal{N}(w_a; 0)\mathcal{N}(w_b; 0)\mathcal{N}(w_c; 0)$

[0097] 其中 \mathcal{L} 表示总的损失函数;

[0098] S44. 对步骤S43的损失函数作对数变换, 得到:

[0099] $\mathcal{L} = \sum_i -\ln P(T_i|X_i, w_a) + \gamma_a \|\bar{w}_a\|^2 - \ln P(T_i|Y_i, w_b) + \gamma_b \|\bar{w}_b\|^2 - \ln P(T_i|Z_i, w_c) + \gamma_c \|\bar{w}_c\|^2$

[0100] 其中 γ_a 为常量;

[0101] S45. 将步骤S44中进行对数变换后的损失函数分为 \mathcal{L}_a , \mathcal{L}_b , \mathcal{L}_c 三个部分, 分别对应于所述三条支路, 其中 \mathcal{L}_a 表示为下式:

[0102] $\mathcal{L}_a = \sum_i \underbrace{-\ln P(T_i|X_i, w_a)}_{\mathcal{L}_T} + \underbrace{\eta_a \|\bar{w}_a\|^2}_{\mathcal{L}_w}$

[0103] 其中 \mathcal{L}_T 用交叉熵表示后, 得到下式:

[0104] $\mathcal{L}_a = \eta_T \sum_i \sum_j T_{i,j} \ln \hat{T}_{X,i,j} + \eta_a \|\bar{w}_a\|^2$

[0105] 其中 η_T, η_a 为参数; $T_{i,j}$ 表示真实标签, $\hat{T}_{X,i,j}$ 表示通过第一支路预测出来的类别;

[0106] 同理对 \mathcal{L}_b , \mathcal{L}_c 分别作以上的变换, 则包括 \mathcal{L}_a , \mathcal{L}_b , \mathcal{L}_c 三个部分的总的损失函数为:

[0107] $\mathcal{L} = \alpha \mathcal{L}_a + \beta \mathcal{L}_b + \chi \mathcal{L}_c$

[0108] 其中 α, β, χ 分别表示三个参数;

[0109] S46. 冻结第二支路和第三支路的网络参数, 分别将第二支路和第三支路的损失权重置为0, 对步骤S45得到的总的损失函数使用梯度下降和反向传播算法对第一支路进行权重更新, 直至所述第一支路的网络参数收敛;

[0110] S47. 冻结第一支路的网络参数, 将第一支路损失权重置为0, 将第二支路和第三支路的损失权重进行重置, 对步骤S45得到的总的损失函数使用梯度下降和反向传播算法对第二支路和第三支路进行权重更新, 直至所述多模态卷积神经网络收敛, 得到最终的心电信号分类模型;

[0111] S5. 如图2所示, 通过所述心电信号分类模型对输入的目标信号进行分类, 得到目标信号的分类结果; 其中输入的目标信号包括所述目标集进行心电医学特征提取后的数据以及进行降采样处理后的数据。

[0112] 附图中描述位置关系的用语仅用于示例性说明, 不能理解为对本专利的限制;

[0113] 显然,本发明的上述实施例仅仅是为清楚地说明本发明所作的举例,而并非是对本发明的实施方式的限定。对于所属领域的普通技术人员来说,在上述说明的基础上还可以做出其它不同形式的变化或变动。这里无需也无法对所有的实施方式予以穷举。凡在本发明的精神和原则之内所作的任何修改、等同替换和改进等,均应包含在本发明权利要求的保护范围之内。

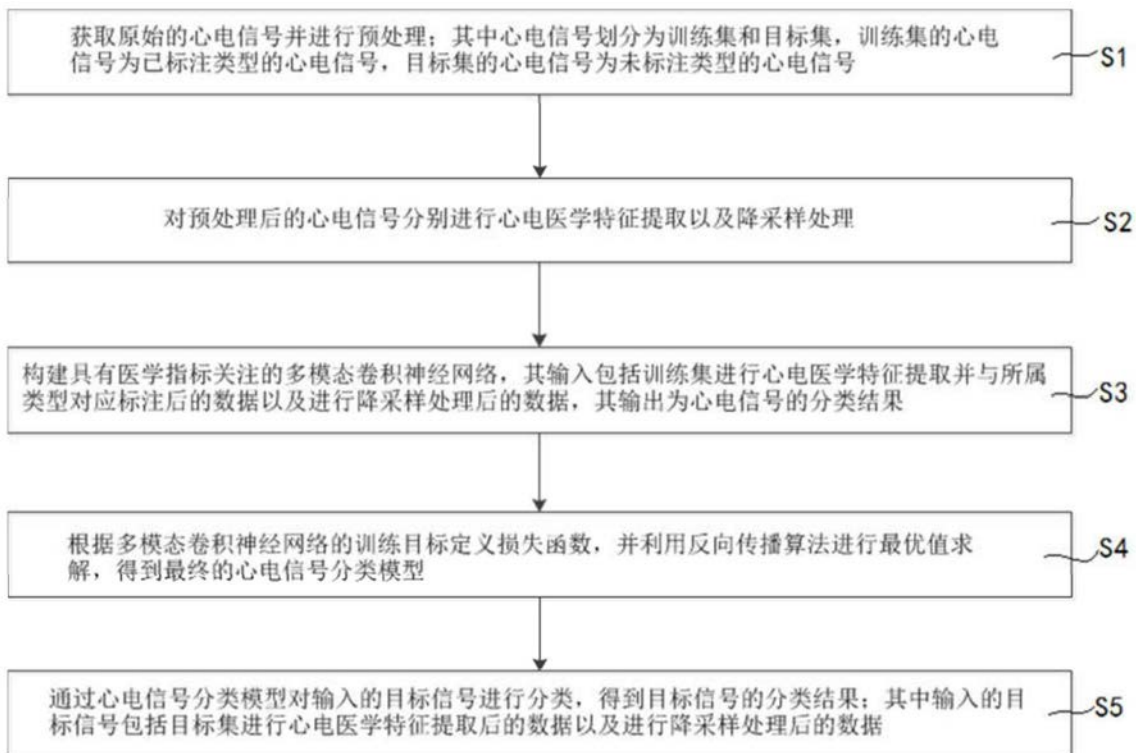


图1

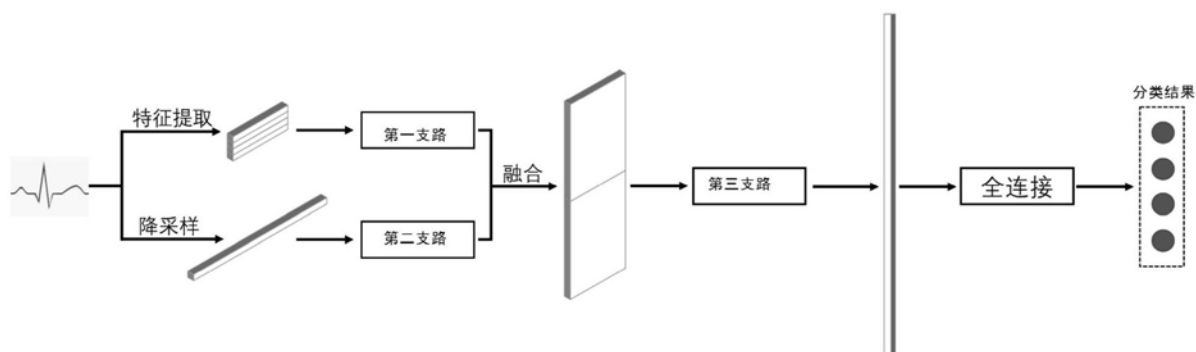


图2

专利名称(译)	一种基于多模态卷积神经网络心电信号分类方法		
公开(公告)号	CN110584654A	公开(公告)日	2019-12-20
申请号	CN201910955726.3	申请日	2019-10-09
[标]申请(专利权)人(译)	中山大学		
申请(专利权)人(译)	中山大学		
当前申请(专利权)人(译)	中山大学		
[标]发明人	李惠川 刘树郁		
发明人	李惠川 刘树郁		
IPC分类号	A61B5/0402 A61B5/0472 A61B5/00		
CPC分类号	A61B5/0402 A61B5/0472 A61B5/7203 A61B5/7267		
代理人(译)	张金福		
外部链接	Espacenet SIPO		

摘要(译)

本发明公开了一种基于多模态卷积神经网络心电信号分类方法，通过对大量已标注分类结果的心电数据集训练得到一个由三个支路组成的具有医学指标关注的多模态卷积神经网络，分别为第一支路、第二支路和第三支路，其中第一支路用于处理预先提取出来的心电特征信息，该心电特征信息能有效辅助该多模态卷积神经网络进行最终预测；第一支路用以处理原始的心电信号；第三支路将第一支路与第二支路的输出进行融合并对输入的心电信号类型进行分类。本发明方法通过结合三条支路的损失函数，采取非端到端的训练方式，并引入具有重要价值的传统医学指标关注，从而准确预测出心电信号的所属类别，取得良好的心电分类效果。

