



(12)发明专利申请

(10)申请公布号 CN 109512423 A

(43)申请公布日 2019.03.26

(21)申请号 201811487253.0

(22)申请日 2018.12.06

(71)申请人 杭州电子科技大学

地址 310018 浙江省杭州市下沙高教园区2号大街

(72)发明人 孟婷婷 邓木清 范慧婕 王聪

(74)专利代理机构 杭州君度专利代理事务所  
(特殊普通合伙) 33240

代理人 朱月芬

(51)Int.Cl.

A61B 5/0402(2006.01)

A61B 5/00(2006.01)

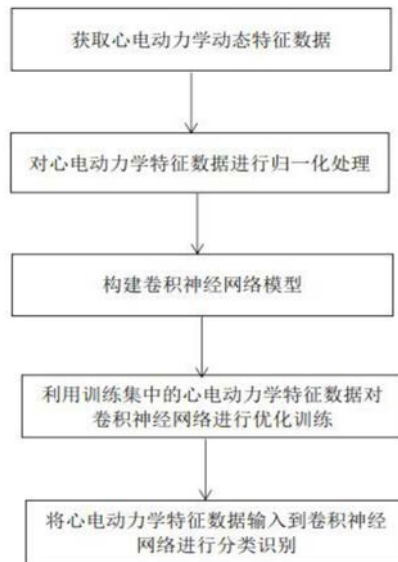
权利要求书2页 说明书6页 附图3页

(54)发明名称

一种基于确定学习与深度学习的心肌缺血危险分层方法

(57)摘要

本发明公开了一种基于确定学习与深度学习的心肌缺血危险分层方法。本发明采集常规12导联心电图信号,基于确定学习理论对浅层心电信号蕴含的内在心电动力学特征进行神经网络建模、辨识,得到心电信号内在动态特征,运用深度学习框架下的卷积神经网络实现对心肌缺血的危险分层。本发明方法首次联合使用了确定学习动态建模方法与深度学习分类方法,并应用于心肌缺血的早期危险分层,基于常规12导联心电信号,不需附加新的检测设备,简单方便、容易操作。确定学习方法提取到对缺血状态更敏感的动态特征,而深度神经网络能够自主学习数据特征,不用进行进一步数据刻画,降低了系统的复杂度。



1. 一种基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,包含如下步骤:

步骤1、获取心电信号动力学动态特征:对采集得到的12导联心电数据进行确定学习动态建模,从而获得心电动力学特征数据;

步骤2、数据预处理:对获得的心电动力学特征数据进行归一化处理;

步骤3、构建卷积神经网络模型:构建的卷积神经网络的结构为输入层-卷积层-池化层-卷积层-池化层-全连接层-输出层;

步骤4、训练卷积神经网络:将步骤2归一化处理好的训练集中的数据输入到步骤3构建的卷积神经网络中进行训练,训练的过程包括前向训练和反向优化;

步骤5、分类识别:将步骤2归一化处理好的测试集中的心电动力学特征数据输入到训练好的卷积神经网络模型中,预测测试数据集中心肌缺血的高危个体与低危个体。

2. 根据权利要求1所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,步骤1所述的进行确定学习动力学建模是指通过既定的公认有效的一种基于确定学习理论的心肌缺血辅助检测方法把原始的心电数据转化成心电动力学特征数据。

3. 根据权利要求1或2所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,步骤2所述的对特征数据进行归一化处理的方法为min-max方法。

4. 根据权利要求3所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,步骤4所述的卷积神经网络的训练包括前向训练和反向优化两个步骤,其中前向训练的具体过程如下:

①卷积层操作:公式表达为:  $X_j^l = f(\sum x_i^{l-1} * k_{ij}^l + b_j^l)$ ,其中,l为卷积层数,k为卷积核, $M_j^l$ 为输入数据的集合,b为每个输出特征图的偏置,\*表示卷积运算;

②池化层操作:公式表达为:  $X_j^l = f(w_j^l \text{down}(X_j^{l-1}) + b_j^l)$ ,式中down(·)表示下采样函数。

5. 根据权利要求4所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,步骤4所述的卷积神经网络的反向优化是采用有监督的学习方式进行调优,通过调优之后使得卷积神经网络模型中的每一层隐层的网络权重和偏置都能够达到最优值,反向优化具体的计算过程如下:

(1)卷积层的梯度计算:公式表达式为:  $\delta_j^l = w_j^{l+1}(f(u_j^l) * \text{up}(\delta_j^{l+1}))$ ,其中,u是卷积之后产生的特征图,up(·)表示上采样函数,\*表示点乘运算;对于卷积层给定的特征图,能够求得该特征图对应偏置项的梯度和对应卷积核的梯度,计算公式为:

$\frac{\partial J}{\partial b_j^l} = \sum_{x,y} (\delta_j^l)_{xy}; \frac{\partial J}{\partial k_{ij}^l} = \sum_{x,y} (\delta_j^l)_{xy} (p_i^{l-1})_{xy}$ ,其中,J为代价函数, $(p_i^{l-1})_{xy}$ 项是 $x_i^{l-1}$ 中在卷积时与 $k_{ij}^l$ 逐元素相乘的一块区域,x,y表示特征图中的坐标;

(2)池化层的梯度计算:在池化层的下采样的前向过程中涉及的参数是每个特征图对应的一个权重参数w和一个偏置项b,若求得此层的残差图,权重参数w和偏置项b的梯度就很容易求得,该过程用公式表达为:  $\delta_j^l = f(u_j^l) * \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), 'full')$ ,在得到残差图

后,权重参数 $w$ 和偏置项 $b$ 对应的梯度计算满足公式: $\frac{\partial J}{\partial b_j} = \sum_{x,y} (\delta_j^l)_{xy}$ ,  $\frac{\partial J}{\partial w_j} = \sum_{x,y} (\delta_j^l * d_j^l)_{xy}$ ,其中, $d_j^l = \text{down}(x_j^{l-1})$ 。

6.根据权利要求5所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,步骤5所述的分类识别是指经过步骤4训练好的卷积神经网络对测试集中的心电动力学特征数据进行分类预测,识别出心肌缺血高危个体和低危个体。

7.根据权利要求5所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于,所采用的min-max方法的具体计算如下:假设对于序列 $x_1, x_2, \dots, x_n$ 进行变换:

$$y_i = \frac{x_i - \min_{1 \leq j \leq n} \{x_j\}}{\max_{1 \leq j \leq n} \{x_j\} - \min_{1 \leq j \leq n} \{x_j\}}, \text{则新序列 } y_1, y_2, \dots, y_n \in [0, 1].$$

8.根据权利要求7所述的基于确定学习与深度学习的心肌缺血危险分层方法,其特征在于卷积神经网络的输入为心电动力学样本数据 $X$ ,网络中第 $i$ 层的特征图为 $X_i$ ;

若第 $i$ 层是卷积层,则 $X_i$ 表示为: $V_i = f(X_{i-1} * W_i + b_i)$ ;其中, $W_i$ 为第 $i$ 层的权值向量,\*为卷积操作, $b_i$ 为第 $i$ 层的偏置向量, $f(\cdot)$ 为激活函数,激活函数的表达式为: $f(x) = \max(0, x)$ ;

若第 $i$ 层是池化层,则 $X_i$ 表示为: $V_i = \text{mean}[X_{i-1}(n \times s + r)]$ ,其中 $r$ 是池化层窗口的大小, $s$ 是池化层的步长, $n$ 是特征图的元素索引,函数 $\text{mean}(\cdot)$ 用于计算合并池化窗口的平均值,池化层窗口 $r$ 等于步长 $s$ 。

## 一种基于确定学习与深度学习的心肌缺血危险分层方法

### 技术领域

[0001] 本发明属于模式识别技术领域,具体涉及一种基于确定学习与深度学习的心肌缺血危险分层方法。

### 背景技术

[0002] 心肌缺血是常见的心血管疾病,严重威胁人类的生命健康。心肌缺血的危险分层对病情的诊断、治疗和预后具有重要意义,与人类健康密切相关。近半个世纪来医学影像学技术逐渐成熟,成为了心肌缺血、冠心病的诊断与治疗的主流方向。而在临床实践中,部分患者临床表现为无症状的心肌缺血,虽然有明显的冠脉改变和心肌缺血的客观依据,却不伴有心绞痛,非常容易受到患者自身和医生的忽视,也成为心肌梗死以及猝死的重要危险因素之一。影像检查也由于自身价格的原因和患者心理的因素,没法在一般人群筛查中广泛使用,单凭影像检查有时无法最大限度发挥诊断效能。相比之下,无创性心电学检测技术,特别是常规的12导联心电图技术,简单实用,受众更广,作为医学影像学的重要补充部分,在心肌缺血诊断和危险分层上起到重要作用。合理、有序的选择无创心电学检查可以提供不同于影像信息的心电信息,实现心肌缺血的早期检测,与影像学检查的优势互补,进一步提高临床诊断的准确率和检出率。

[0003] 针对上述背景和存在的问题,在中国发明专利申请:一种基于确定学习理论的心肌缺血辅助检测方法(申请号:201310496628.0)中提出了一个确定学习动态理论的心肌缺血早期诊断的新方法,使得本来难以发现的微小病态信息得以充分表示。然而,该方法仅给出了依靠图形散乱与否的定性主观结果,无法采用量化手段对其进行标准规划。在中国发明专利申请:一种心电动力学数据量化分析方法(申请号:201710587538.0)中提出了一种心电动力学数据图量化分析方法,对上述结果进行量化指标的提取,但在指标提取环节仍存在相当大的主观性,没法给出确切的指标提取数量,以及指标数量与最终诊断正确率之间的关联。

### 发明内容

[0004] 本发明的目的是克服现有技术存在的问题,提供一种基于确定学习与深度学习的心肌缺血危险分层方法,一种更为简单准确自动的,适合临床使用的基于确定学习与深度学习的心肌缺血危险分层方法。

[0005] 本发明的具体技术方案通过如下步骤实现:

[0006] 步骤1、获取心电信号动力学动态特征:对采集得到的12导联心电数据进行确定学习动态建模,从而获得心电动力学特征数据。

[0007] 步骤2、数据预处理:对获得的心电动力学特征数据进行归一化处理。

[0008] 步骤3、构建卷积神经网络模型:构建的卷积神经网络的结构为输入层-卷积层-池化层-卷积层-池化层-全连接层-输出层。

[0009] 步骤4、训练卷积神经网络:将步骤2归一化处理好的训练集中的数据输入到步骤3

构建的卷积神经网络中进行训练,训练的过程包括前向训练和反向优化。

[0010] 步骤5、分类识别:将步骤2归一化处理好的测试集中的心电动力学特征数据输入到训练好的卷积神经网络模型中,预测测试数据集中心肌缺血的高危个体与低危个体。

[0011] 上述方法中,步骤1所述的进行确定学习动力学建模是指通过既定的公认有效的一种基于确定学习理论的心肌缺血辅助检测方法把原始的心电数据转化成心电动力学特征数据。在心电信号动态建模环节,通过确定学习理论,利用RBF神经网络实现对心电非线性系统动态的局部准确的辨识,并将学习到的知识以常值RBF神经网络权值的形式保存起来。时变的心电动态模式就可以由系统动态的局部准确的神经网络逼近来表示。

[0012] 对心电信号进行确定学习动力学建模的步骤如下:(1)将12导联心电图ECG数值数据进行常规滤波,通过既定的公认有效的变换法则转换为三维的心电向量图数据,表示为: $V(t) = [v_x(t), v_y(t), v_z(t)]^T$ ,式中 $t=1, \dots, m$ 为采样时刻,然后截取三维数据中的ST-T段数据,从而提取ST-T环。(2)采用动态RBF神经网络辨识器,对ST-T环的内在系统动态利用确定学习算法进行局部准确RBF神经网络逼近,获得关于心电图ST-T段信号内在的动力学特性:

$$[0013] \quad \begin{aligned} F_{ST}(V(t)) &= [F_1(V(t)), F_2(V(t)), F_3(V(t))] |_{V(t) \in V_{ST}} \\ &\cong [\overline{W}_1^T S(V(t)), \overline{W}_2^T S(V(t)), \overline{W}_3^T S(V(t))] |_{V(t) \in V_{ST}} \end{aligned}$$

[0014] 其中 $F_{ST}(V(t))$ 表示内在系统动态特性, $\overline{W}_1, \overline{W}_2, \overline{W}_3$ ,是常值神经网络权值向量, $S(V(t))$ 是高斯型径向基函数。由上式所示,得到的系统动态知识保存下来的常值权值矩阵 $\overline{W}^T S(V(t))$ 就是心电动力学特征数据。

[0015] 上述方法中,步骤2所述的对心电动力学特征数据进行归一化处理的方法为min-max方法。

[0016] 上述方法中,步骤4所述的卷积神经网络的训练包括前向训练和反向优化两个步骤。

[0017] 前向训练的具体过程如下:

[0018] ①卷积层操作:公式表达为: $X_j^l = f(\sum x_i^{l-1} * k_{ij}^l + b_j^l)$ ,其中, $l$ 为卷积层数, $k_{ij}^l$ 为第 $l$ 层第 $j$ 个特征图于第 $l-1$ 层第 $i$ 个特征图连接之间的卷积核, $M_j$ 为输入数据的集合, $b$ 为每个输出特征图的偏置,“\*”表示卷积运算, $f(\cdot)$ 表示激励函数, $X_j^l$ 表示第 $l$ 层第 $j$ 个特征图。

[0019] ②池化层操作:公式表达为: $X_j^l = f(w_j^l \text{down}(X_j^{l-1}) + b_j^l)$ ,式中 $\text{down}(\cdot)$ 表示下采样函数, $w_j^l$ 表示第 $l$ 层第 $j$ 个特征图对应的系数, $b_j^l$ 为其对应的偏置项系数。

[0020] 反向优化是采用有监督的学习方式进行调优,通过调优之后使得卷积神经网络模型中的每一层隐层的网络权重和偏置都能够达到最优值。反向优化具体的计算过程如下:

[0021] (1)卷积层的梯度计算:公式表达式为: $\delta_j^l = w_j^{l+1} (f(u_j^l) * \text{up}(\delta_j^{l+1}))$ ,其中, $u$ 是卷积之后产生的特征图, $\text{up}(\cdot)$ 表示上采样函数,“\*”表示点乘运算。对于卷积层给定的特征图,可以求得该特征图对应偏置项的梯度和对应卷积核的梯度,计算公式为:

$$\frac{\partial J}{\partial b_j} = \sum_{x,y} (\delta_j^l)_{xy}$$

$\frac{\partial J}{\partial k_{ij}^l} \sum_{x,y} (\delta_j^l)_{xy} (p_i^{l-1})_{xy}$ ，其中，J为代价函数， $(p_i^{l-1})_{xy}$ 项是 $x_i^{l-1}$ 中在卷积时与 $k_{ij}^l$ 逐元素相乘的一块区域，x,y表示特征图中的坐标。

[0022] (2)池化层的梯度计算：在池化层的下采样的前向过程中涉及的参数是每个特征图对应的一个权重参数w和一个偏置项b，若求得此层的残差图，这两个参数的梯度就很容易求得，该过程可以用公式表达为： $\delta_j^l = f'(u_j^l) * conv2(\delta_j^{l+1}, rot180(k_j^{l+1}), 'full')$ ，式中rot180()函数表示逆时针旋转180度，参数full表示进行完全的卷积操作。在得到残差图后，w和b的计算满足公式： $\frac{\partial J}{\partial \omega_j} = \sum_{x,y} (\delta_j^l)_{xy}$ ， $\frac{\partial J}{\partial b_j} = \sum_{x,y} (\delta_j^l * d_j^l)_{xy}$ ，其中， $d_j^l = down(x_j^{l-1})$ 。

[0023] 上述方法中，步骤5所述的分类识别是指经过步骤4训练好的卷积神经网络对测试集中的心电动力学特征数据进行分类预测，识别出心肌缺血高危个体和低危个体。

[0024] 本发明与现有技术相比，具有如下优点和有益效果：

[0025] 1、本发明方法首次联合使用了确定学习动态建模和深度学习分类方法，并应用于心肌缺血的早期危险分层。确定学习动态建模能提取到对心肌缺血状态更敏感的动态特征，深度学习能够自主学习数据特征，不用进行进一步的数据刻画，降低了系统的复杂度，而且不需要增加新的检测设备，简单方便，容易操作。

[0026] 2、本发明采用深度学习方法进行心肌缺血危险分层识别，相比于传统的方法，深度学习学习能力强，能够学习到更好的特征，有更好的表达能力。本方法随着训练数据量的增加，可以取得更好的识别效果。

[0027] 3、本发明通过构建卷积神经网络来进行心肌缺血危险分层识别，能够通过训练样本的心电动力学特征数据进行自主学习，同时具有权值共享的特征，降低了模型的复杂度，池化层的操作增强了系统的鲁棒性。本发明在实施例中提供了一个数层的卷积神经网络模型，达到了较好的识别效果。

## 附图说明

[0028] 图1是本发明实施例中心肌缺血危险分层方法的流程图。

[0029] 图2是本发明实施例中某一心肌缺血高危个体的心电动力学特征数据显示图。

[0030] 图3是本发明实施例中某一心肌缺血低危个体的心电动力学特征数据显示图。

[0031] 图4是本发明实施例中卷积神经网络模型的结构示意图。

[0032] 图5是本发明实施例中卷积神经网络具体参数配置。

[0033] 图6是本发明实施例中神经网络全连接层的参数设置。

[0034] 图7是本发明实施例中心电动力学特征数据的分类识别结果。

## 具体实施方式

[0035] 下面结合实施例及附图对本发明的具体实施方式作进一步详细的描述，但本发明的实施和保护范围不限于此。

[0036] 本发明方法提出了基于确定学习与深度学习的心肌缺血危险分层方法，首次联合了确定学习动态建模技术与当前最火的深度学习神经网络技术，首先通过确定学习理论对

心电信号内在非线性系统动态实现神经网络建模,然后利用卷积神经网络算法,对心电动力学特征数据进行识别分类,识别出心肌缺血高危个体与低危个体。本发明方法适用于心电动力学信号的自动无特征分类识别,应用于心肌缺血的危险分层。特别是在一般人群中,高危结果可以引起临床医师及个体自身的进一步关注,引导潜在高危患者做进一步检查。而低危结果则可以排除因为非心源性症状引起的患者心理恐慌,减少不必要的医疗资源浪费。

[0037] 实施例

[0038] 本发明的具体实施例选取医院临床采集的心电数据。

[0039] 如图1所示,为本发明实施例的心肌缺血危险分层方法的流程图,包括以下步骤:

[0040] 获取心电信号动力学动态特征:对采集得到的12导联心电数据进行确定学习动态建模,从而获得心电动力学特征数据。动态建模的操作如步骤说明所述。心电动力学特征数据是指通过确定学习理论对心电数据内在非线性系统动态进行神经网络建模和全息特征提取,并将所学到的系统动态知识保存下来的常值权值矩阵。若将心电动力学特征数据进行三维可视化显示,如图2所示是心肌缺血高危个体的心电动力学特征数据显示图,如图3所示是心肌缺血低危个体的心电动力学特征数据显示图。

[0041] 数据预处理:为了消除心电动力学特征数据的数值差异,对获得的心电动力学特征数据进行归一化处理,所采用的方法是min-max方法。其计算方法如下:假设对于序列 $x_1, x_2, \dots, x_n$ 进行变换:

$$y_i = \frac{x_i - \min_{1 \leq j \leq n} \{x_j\}}{\max_{1 \leq j \leq n} \{x_j\} - \min_{1 \leq j \leq n} \{x_j\}}, \text{ 则新序列 } y_1, y_2, \dots, y_n \in [0, 1].$$

[0042] 构建卷积神经网络模型:卷积神经网络以其局部权值共享的特殊网络结构在模式识别领域有着独特的优越性。如图4所示,构建的卷积神经网络模型结构主要由一个输入层、若干隐含层和一个输出层组成。其中,隐含层包括卷积层、池化层和全连接层。在卷积神经网络的单个卷积层中,通常包括若干个特征平面,同一特征平面共享一套权值滤波器。在卷积神经网络的一个池化层中,通常有均值池化(Mean Pooling)和最大值池化(Max Pooling)两种形式。在本发明实施例中,卷积神经网络的池化层都采用均值池化操作。卷积神经网络的卷积和池化操作简化了模型复杂度,减少了模型参数数目。

[0043] 针对心肌缺血的检测分类,卷积神经网络的输入为心电动力学样本数据 $X$ ,网络中第 $i$ 层的特征图为 $X_i$ 。若第 $i$ 层是卷积层,则 $X_i$ 可以表示为: $V_i = f(X_{i-1} * W_i + b_i)$ ;其中, $W_i$ 为第 $i$ 层的权值向量,\*为卷积操作, $b_i$ 为第 $i$ 层的偏置向量, $f(\cdot)$ 为激励函数。在本发明实施例中采用的激活函数为Relu函数,其表达式为: $f(x) = \max(0, x)$ 。若第 $i$ 层是池化层,则 $X_i$ 可以表示为: $V_i = \text{mean}[X_{i-1}(n \times s + r)]$ ,其中 $r$ 是池化层窗口的大小, $s$ 是池化层的步长, $n$ 是特征图的元素索引,函数 $\text{mean}(\cdot)$ 用于计算合并池化窗口的平均值。

[0044] 为了利用所有的提取到的特征,将池化层的输出传到flatten层中,把多维的输入一维化,一维化的特征向量可表示为: $X = [X_1, X_2, \dots, X_i]$ ,其中 $X$ 是全局特征向量,并作为全连接层的输入。在全连接层中执行矩阵乘法,最终输出 $C$ 个元素向量,其中 $C$ 是类别的数量。此外,在最终采用softmax分类器来计算每个类的预测概率。全连接层的操作可表示为:

$$\hat{Y} = \frac{e^{W_c X}}{\sum_{c=1}^C e^{W_c X}}$$
，其中 $W_c$ 是与输出层的第 $c$ 个神经元连接的权重向量， $\hat{Y}$ 是最终的输出向量(预测标签)。

上式中输出的 $\hat{Y}$ 值是从0到1的正数，表示为目标类别的预测概率。

[0045] 在本发明实施例中，构建的卷积神经网络包括2个卷积层和2个池化层以及一个全连接层，如图5所示，为实施例中卷积神经网络的具体参数设置，如图6所示，为实施例中全连接层的具体参数设置。

[0046] 训练卷积神经网络：将卷积神经网络的结构搭建好后，就要对网络结构进行训练。训练的目的在于优化网络参数得到最佳的权重和偏置值，接着利用这些训练好的权重和偏置值对神经网络进行配置，最后被配置的神经网络能够进行具有一定准确率的心肌缺血识别分类。

[0047] 卷积神经网络的训练包括前向训练和反向优化两个步骤。前向训练的过程如下：

(a) 卷积层操作：公式表达为： $X_j^l = f(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l)$ ，其中， $l$ 为卷积层数， $k_{ij}^l$ 为第 $l$ 层第 $j$ 个

特征图于第 $l-1$ 层第 $i$ 个特征图连接之间的卷积核， $M_j$ 为输入数据的集合， $b$ 为每个输出特征图的偏置，“\*”表示卷积运算， $f(\cdot)$ 表示激励函数， $X_j^l$ 表示第 $l$ 层第 $j$ 个特征图。

(b) 池化层操作：公式表达为： $X_j^l = f(w_j^l \text{down}(X_j^{l-1}) + b_j^l)$ ，式中 $\text{down}(\cdot)$ 表示下采样函数。反向优化是采用有监督的学习方式进行调优，通过调优之后使得卷积神经网络模型中的每一层隐层的网络权重和偏置都能够达到最优值。反向优化具体的计算过程如下：

(a) 卷积层的梯度计算：公式表达式为： $\delta_j^l = w_j^{l+1}(f(u_j^l) * \text{up}(\delta_j^{l+1}))$ ，其中， $u$ 是卷积之后产生的特征图， $\text{up}(\cdot)$ 表示上采样函数，“\*”表示点乘运算。对于卷积层给定的特征图，可以求得该特征图对应偏置项的

梯度和对应卷积核的梯度，计算公式为： $\frac{\partial J}{\partial b_j^l} = \sum_{x,y} (\delta_j^l)_{xy}$ ， $\frac{\partial J}{\partial k_{ij}^l} = \sum_{x,y} (\delta_j^l)_{xy} (p_i^{l-1})_{xy}$ ，其中， $J$ 为代价函数， $(p_i^{l-1})_{xy}$ 项是 $x_i^{l-1}$ 中在卷积时与 $k_{ij}^l$ 逐元素相乘的一块区域， $x, y$ 表示特征图中的坐标。

(b) 池化层的梯度计算：在池化层的下采样的前向过程中涉及的参数是每个特征图对应的一个权重参数 $w$ 和一个偏置项 $b$ ，若求得此层的残差图，这两个参数的梯度就很容易求得，该过程可以用公式表达为： $\delta_j^l = f(u_j^l) * \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), 'full')$ ，在得到残差图后， $w$ 和 $b$

对应的梯度计算满足公式： $\frac{\partial J}{\partial \omega_j^l} = \sum_{x,y} (\delta_j^l)_{xy}$ ， $\frac{\partial J}{\partial b_j^l} = \sum_{x,y} (\delta_j^l * d_j^l)_{xy}$ ，其中， $d_j^l = \text{down}(x_j^{l-1})$ 。

[0048] 在本发明实施例中采用的反向传播算法为随机梯度下降法(SGD, Stochastic Gradient Descent)。训练过程基于前向和后向传递的迭代完成，定义训练数据集中的每个批次的大小，SGD的损失函数定义为： $J(\theta) = -\frac{1}{Q} \sum_{q=1}^Q [Y \log \hat{Y} + (1-Y) \log(1-\hat{Y})]$ ；其中， $Q$ 是训练集中选择每次样本数量的批量大小， $Y$ 是所需的输出向量(真实标签)。上式损失函数也被称为交叉熵函数，在分类任务中经常用到的一种有效的损失函数计算公式。让 $\theta$ 表示模型中

可训练参数,如权重和偏置,那么参数的更新规则可定义为: $\theta_{t+1} = \theta_t - \frac{\eta}{Q} \sum_{q=1}^Q \nabla_{\theta_t} J(\theta)$ ,其中, $J(\theta)$ 表示损失代价函数, $\eta$ 是学习率, $\nabla$ 是梯度算子, $t$ 表示训练步骤。在训练过程中,超参数(如学习率、小批量大小、训练次数)对训练效果都有一定的影响,需要反复试验来调整它们以达到最佳的实验效果。

[0049] 在本发明实施例中,采用的反向传播算法训练批量为20,学习率参数设置为0.001,总共进行了500次训练,使得模型得到更好的训练效果。

[0050] 分类识别:在完成卷积神经网络的搭建和训练之后,需要对采集到的心电动力学特征数据进行分类识别,验证本发明实施例的心肌缺血危险分层方法的识别性能。

[0051] 在本发明实施例中,对采集的医院心电数据进行确定学习建模,共获得1524条心电动力学特征数据其中健康人的特征数据有116条,患有心肌缺血的特征数据有1408条。在实施例中用总数据的75%(1143条)特征数据用来训练卷积神经网络,总数据的25%(381条)特征数据用来进行测试,其中包含37条健康人特征数据和344条心肌缺血特征数据。在本发明实施例中实验得到的心肌缺血危险分层的混淆矩阵如图7所示。

[0052] 为了验证本发明方法的有效性,使用灵敏度、特异度和准确率来评估模型用于心肌缺血检测的性能。灵敏性是指通过模型正确分类的实际有疾病的百分比,特异度是指被模型正确分类的无疾病的百分比,准确率是指通过模型正确分类的百分比。灵敏度、特异度和准确率的定义如下:

$$[0053] \quad \text{灵敏度} = \frac{TP}{TP + FN} (\%)$$

$$[0054] \quad \text{特异度} = \frac{TN}{TN + FP} (\%)$$

$$[0055] \quad \text{准确率} = \frac{TP + TN}{TP + TN + FP + FN} (\%)$$

[0056] 其中,TP, TN, FP, FN分别代表真阳性,真阴性,假阳性和假阴性的数量。

[0057] 在本发明实施例中通过对心电动力学特征数据的实验,得到的灵敏度、特异度和准确率分别为90.98%、75%、90.83%。通过实施例的实验可以看出,本发明方法能有效地提高心肌缺血检测的识别率,特别是在大量数据集的情况下,能够提供快速的识别方法。实施例验证了本发明方法的有效性和检测结果的可靠性,本发明的识别结果可作为心血管疾病诊断的重要参考,为医生诊断病情提供快速有效的工具。上述实施例为本发明较佳的实施方式,但本发明的实施方式并不受上述实施例的限制,其他的任何未背离本发明的精神实质与原理下所作的改变、修饰、替代、组合、简化,均应为等效的置换方式,都包含在本发明的保护范围之内。

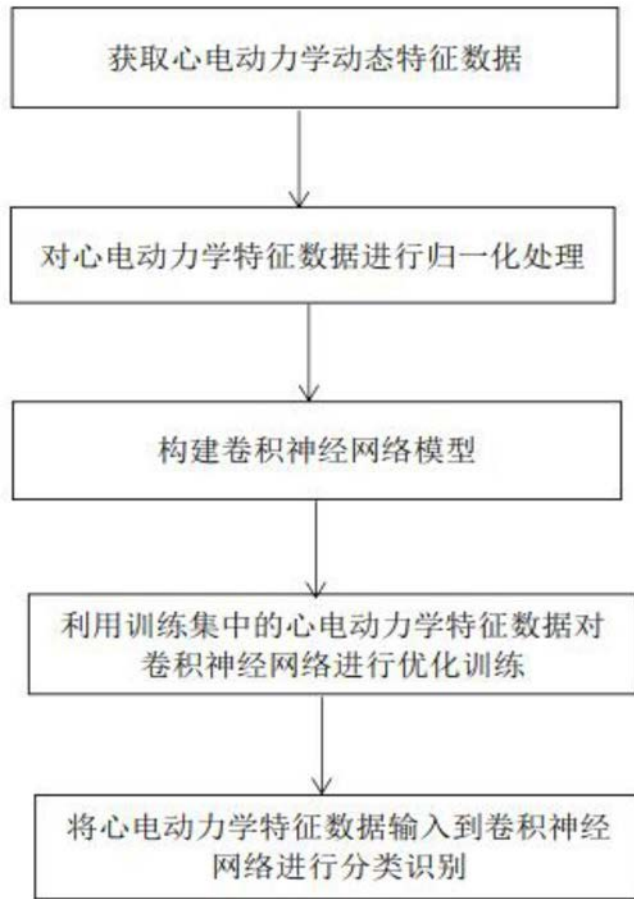


图1




图2




图3




图4

第 N 层	网络层类型	神经元个数	卷积核大小	步长	激活函数
1	卷积层	2000x3	3	1	Relu
2	均值池化层	1000x3	1	1	-
3	卷积层	500x3	3	1	Relu
4	均值池化层	250x3	1	1	-
5	Flatten 层	750	-	-	-

图5

第 N 层	网络类型	神经元个数	激活函数
1	全连接层	50	Relu
2	输出层	2	softmax

图6

分类		预测标签		总计
		阳性	阴性	
真实 标签	阳性	343	1	344
	阴性	34	3	37
总计		377	4	381

准确率=90.83% 灵敏度=90.98%，特异度=75.00%

图7

专利名称(译)	一种基于确定学习与深度学习的心肌缺血危险分层方法		
公开(公告)号	<a href="#">CN109512423A</a>	公开(公告)日	2019-03-26
申请号	CN201811487253.0	申请日	2018-12-06
[标]申请(专利权)人(译)	杭州电子科技大学		
申请(专利权)人(译)	杭州电子科技大学		
当前申请(专利权)人(译)	杭州电子科技大学		
[标]发明人	孟婷婷 邓木清 范慧婕 王聪		
发明人	孟婷婷 邓木清 范慧婕 王聪		
IPC分类号	A61B5/0402 A61B5/00		
CPC分类号	A61B5/0402 A61B5/04012 A61B5/7235 A61B5/7267 A61B5/7275		
代理人(译)	朱月芬		
外部链接	<a href="#">Espacenet</a> <a href="#">SIPO</a>		

摘要(译)

本发明公开了一种基于确定学习与深度学习的心肌缺血危险分层方法。本发明采集常规12导联心电图信号，基于确定学习理论对浅层心电信号蕴含的内在心电动力学特征进行神经网络建模、辨识，得到心电信号内在动态特征，运用深度学习框架下的卷积神经网络实现对心肌缺血的危险分层。本发明方法首次联合使用了确定学习动态建模方法与深度学习分类方法，并应用于心肌缺血的早期危险分层，基于常规12导联心电信号，不需附加新的检测设备，简单方便、容易操作。确定学习方法提取到对缺血状态更敏感的动态特征，而深度神经网络能够自主学习数据特征，不用进行进一步数据刻画，降低了系统的复杂度。

