



(12)发明专利申请

(10)申请公布号 CN 109907733 A

(43)申请公布日 2019.06.21

(21)申请号 201910285158.0

(22)申请日 2019.04.10

(71)申请人 西北工业大学

地址 710072 陕西省西安市友谊西路127号

(72)发明人 周兴社 刘帆 王柱 倪红波

於志文

(74)专利代理机构 西安利泽明知识产权代理有限公司 61222

代理人 刘伟

(51)Int.Cl.

A61B 5/00(2006.01)

A61B 5/04(2006.01)

A61B 5/0402(2006.01)

G06K 9/62(2006.01)

G06N 3/04(2006.01)


权利要求书1页 说明书6页 附图2页

(54)发明名称

一种面向异常心脏节律分类的ECG信号分析方法

(57)摘要

本发明提供一种面向异常心脏节律分类的ECG信号分析方法,可以利用SB-LSTM和TD-CNN从ECG信号中挖掘信号的长期依赖关系和局部特征;所设计的TAG、FAM、LAM可对所得的长期依赖关系和局部特征进行微调,从而获得精确的ECG整体波动模式和局部波动模式。最终,利用FCN得到ECG信号段的处理结果。该方法充分结合了ECG信号的整体波动模式和局部波动模式信息,能在大规模数据集上使用性能更好。此外,该方法避免了人工分类所产生的个体间差异和个体内差异,能够获得稳定的分类结果。特别地,该方法无需借助任何专家知识、无需手动设计各种特征、无需进行特征选择处理、无需单独地构建分类器,是典型的端到端方法,具有使用便捷、分类精度高等特点。



1. 一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:包括以下步骤:

S1:对ECG信号进行预处理操作,得到格式统一的ECG信号段;

S2:设计基于趋势注意门的多层双向长短时记忆神经网络,从S1输出的结果中挖掘ECG信号的整体波动模式;

S3:设计基于特征注意机制及位置注意机制的二维卷积神经网络,从S2输出的结果中挖掘ECG信号的局部波动模式;

S4:利用全连接神经网络对S3的输出结果进行进一步处理,使用全连接神经网络对S3输出的结果进行拟合,并使用softMax函数将拟合结果映射为概率分布,从而得出每个ECG信号段的处理结果。

2. 根据权利要求1所述的一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:所述S1中对ECG信号进行预处理操作包括:首先使用Z-score算法对ECG信号进行归一化处理;然后以ECG信号中的R峰为中心,截取适当数量的采样点作为当前心跳所对应的ECG信号段;最后对所得ECG信号段的集合进行上采样处理,使得每个心脏节律类型包含相同数量的实例个数。

3. 根据权利要求1所述的一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:所述S2中挖掘ECG信号的整体波动模式是指:使用基于趋势注意门的多层双向长短时记忆神经网络挖掘ECG信号的长期依赖关系,并根据每个采样点在ECG中所处的位置及其周围波形对所挖掘的长期依赖关系进行微调,从而获得精确的ECG长期波动模式。

4. 根据权利要求1所述的一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:所述多层双向长短时记忆神经网络结构由三层双向LSTM构成;上一层LSTM的结果输出给下一层同方向的LSTM,每个LSTM单元由四个门构成,即:忘记门、输入门、输出门及趋势注意门;所述四个门相互作用,共同控制LSTM单元状态的更新及结果的输出;其中,忘记门用来丢掉LSTM之前状态中的无用信息;输入门决定当前应当给LSTM状态添加哪些信息;输出门确定当前细胞应当将哪些信息作为LSTM的最终状态;趋势注意门根据当前采样点所处的位置以及周围波形来调整当前采样点所对应的长期依赖关系的权重。

5. 根据权利要求4所述的一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:每个LSTM单元中的隐藏神经元个数设置为16;L设置为8; N' 设置为56, $L=N-N'$ 是周围波形的长度, N 、 N' 为采样点。

6. 根据权利要求1所述的一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:所述S3中挖掘ECG信号的局部波动模式是指:使用基于特征注意机制及位置注意机制的二维卷积神经网络挖掘ECG信号中的局部特征,并分别根据特征的种类及其在ECG信号中所处的位置对特征值进行微调,从而获得精确的ECG局部波动模式。

7. 根据权利要求1所述的一种面向异常心脏节律分类的ECG信号分析方法,其特征在于:所述S4中全连接神经网络由两个全连层构成,其所含的神经元个数分别设为32和5;特别地,第二个全连层与数据集中心脏节律类型的数量相等;在最后一个全连层之后添加一个Softmax层,将网络输出结果转换成概率分布形式,从而确定处理结果。

一种面向异常心脏节律分类的ECG信号分析方法

技术领域

[0001] 本发明涉及生物健康计算领域,具体地,涉及一种面向异常心脏节律分类的ECG信号分析方法。

背景技术

[0002] 心脏节律通常分为五类:非异位型(N:Non-ectopic)、室性异位型(V:Ventricular ectopic)、室上性异位型(S:Supraventricular ectopic)、混合型(F:Fusion)、未知型(Q:Unknown)。每种子类型通常具有不同的临床表现,需要不同的治疗方法,因此,对异常心脏节律进行准确分类是提供有效治疗的前提。

[0003] 现有的异常心脏节律分类方法主要分为两大类:1)基于专业医生的人工视检法;2)基于特征工程的计算机辅助分类方法。前者需要医生具有极其丰富的临床经验,且需耗费大量的时间成本,效率很低;此外,由于ECG往往会表现出个体间差异和个体内差异,因此基于专业医生的人工视检法通常精度较低。后者虽然借助计算机技术大大降低了时间成本,且保证了结果的一致性,但其必须根据专家知识提前设计若干个特征。由于ECG波动模式在个体间和个体内都存在巨大差异,统一设计的特征难以准确刻画所有情况下的ECG波动模式,这在某种程度上限制了基于特征工程的计算机辅助处理方法的处理精度。

发明内容

[0004] 针对以上问题,本发明提供一种面向异常心脏节律分类的ECG信号分析方法,以解决基于特征工程的计算机辅助处理方法精度较低的问题。

[0005] 本发明一种基于异常心脏节律分类的ECG信号分析方法的技术方案为:一种面向异常心脏节律分类的ECG信号分析方法,包括以下步骤:

[0006] S1:对ECG信号进行预处理操作,得到格式统一的ECG信号段;

[0007] S2:设计基于趋势注意门的多层双向长短时记忆神经网络,从S1输出的结果中挖掘ECG信号的整体波动模式;

[0008] S3:设计基于特征注意机制及位置注意机制的二维卷积神经网络,从S2输出的结果中挖掘ECG信号的局部波动模式;

[0009] S4:利用全连接神经网络对S3的输出结果进行进一步处理,使用全连接神经网络对S3输出的结果进行拟合,并使用softMax函数将拟合结果映射为概率分布,从而得出每个ECG信号段的处理结果。

[0010] 进一步的,一种面向异常心脏节律分类的ECG信号分析方法,所述S1中对ECG信号进行预处理操作包括:首先使用Z-score算法对ECG信号进行归一化处理;然后以ECG信号中的R峰为中心,截取适当数量的采样点作为当前心跳所对应的ECG信号段;最后对所得ECG信号段的集合进行上采样处理,使得每个心脏节律类型包含相同数量的实例个数。

[0011] 进一步的,一种面向异常心脏节律分类的ECG信号分析方法,所述S2中挖掘ECG信号的整体波动模式是指:使用基于趋势注意门的多层双向长短时记忆神经网络挖掘ECG信

号的长期依赖关系,并根据每个采样点在ECG中所处的位置及其周围波形对所挖掘的长期依赖关系进行微调,从而获得精确的ECG长期波动模式。

[0012] 进一步的,一种面向异常心脏节律分类的ECG信号分析方法,所述多层双向长短时记忆神经网络结构由三层双向LSTM构成;上一层LSTM的结果输出给下一层同方向的LSTM,每个LSTM单元由四个门构成,即:忘记门、输入门、输出门及趋势注意门;所述四个门相互作用,共同控制LSTM单元状态的更新及结果的输出;其中,忘记门用来丢掉LSTM之前状态中的无用信息;输入门决定当前应当给LSTM状态添加哪些信息;输出门确定当前细胞应当将哪些信息作为LSTM的最终状态;趋势注意门根据当前采样点所处的位置以及周围波形来调整当前采样点所对应的长期依赖关系的权重。

[0013] 进一步的,一种面向异常心脏节律分类的ECG信号分析方法,每个LSTM单元中的隐藏神经元个数设置为16;L设置为8; N^* 设置为56, $L=N-N^*$ 是周围波形的长度, N,N^* 为采样点。

[0014] 进一步的,一种面向异常心脏节律分类的ECG信号分析方法,所述S3中挖掘ECG信号的局部波动模式是指:使用基于特征注意机制及位置注意机制的二维卷积神经网络挖掘ECG信号中的局部特征,并分别根据特征的种类及其在ECG信号中所处的位置对特征值进行微调,从而获得精确的ECG局部波动模式。

[0015] 进一步的,一种面向异常心脏节律分类的ECG信号分析方法,所述S4中全连接神经网络由两个全连层构成,其所含的神经元个数分别设为32和5;特别地,第二个全连层与数据集中心脏节律类型的数量相等;在最后一个全连层之后添加一个Softmax层,将网络输出结果转换成概率分布形式,从而确定处理结果。

[0016] 本发明的有益效果为:所述的ECG信号分析方法,可以利用SB-LSTM和TD-CNN从ECG信号中挖掘信号的长期依赖关系和局部特征。特别地,所设计的TAG、FAM、LAM可对所得的长期依赖关系和局部特征进行微调,从而获得精确的ECG整体波动模式和局部波动模式。最终,利用FCN得到ECG信号段的处理结果。该方法充分结合了ECG信号的整体波动模式和局部波动模式信息,能在大规模数据集上使用性能更好。此外,该方法避免了人工分类所产生的个体间差异和个体内差异,能够获得稳定的分类结果。特别地,该方法无需借助任何专家知识、无需手动设计各种特征、无需进行特征选择处理、无需单独地构建分类器,是典型的端到端方法,具有使用便捷、分类精度高等特点。

附图说明

[0017] 图1是本发明基于ECG的异常心脏节律分类模型的结构示意图;

[0018] 图2是本发明实施例中一种面向异常心脏节律分类的ECG信号分析方法总体流程示意图;

[0019] 图3是本发明实施例中所设计的TAG-SB-LSTM中LSTM单元的结构示意图;

[0020] 图4是本发明实施例中所设计的FAM-LAM-TD-CNN中卷积层的结构示意图。

具体实施方式

[0021] 下面结合附图来进一步描述本发明的技术方案:

[0022] 为了使本技术领域的人员更好地理解本发明方案,下面将结合本发明的实施例及

其附图,对本发明中的技术方案进行清楚、完整地描述。

[0023] 一种面向异常心脏节律分类的ECG信号分析方法,利用TAG-SB-LSTM及FAM-LAM-TD-CNN分别从ECG信号中挖掘长期依赖关系和局部特征,并根据采样点所处的位置及周围波形对长期依赖关系进行微调、根据所提取特的类型及所处的位置对特征值进行微调,从而获得精确的ECG整体波动模式和局部波动模式,最后再利用全连接网络确定该ECG信号段的处理结果。该方法的整体框架结构如图1所示。

[0024] 一种面向异常心脏节律分类的ECG信号分析方法,如图2所示,包括以下步骤:

[0025] S1:对ECG进行归一化、分段、上采样等预处理操作,得到格式统一的ECG信号段。

[0026] 本发明实施例中,ECG信号通常表现为明显的个体间差异和个体内差异,不同的ECG信号幅值范围会影响处理结果的准确性,为此,首先使用Z-score方法对ECG信号进行归一化处理,如下公式所示:

$$[0027] \quad X_{nor_i} = \frac{X_i - \mu}{\sigma},$$

[0028] 其中, μ 为ECG信号序列的平均值, σ 为信号序列的标准差, X_i 是ECG信号序列中第i个信号值, X_{nor_i} 是 X_i 经过归一化处理后的值。然后利用已有算法确定ECG信号中R峰的位置(本发明实施例利用流行的Pan-Tompkins算法进行R峰检测),然后以R峰所在时刻为中心,选取适当数量的采样点来代表当次心跳所对应的ECG信号段。鉴于本发明实施例中ECG信号的采样频率为360Hz,而人体正常心率范围为60-100次/分,因此以R峰为中心选择256个采样点作为当次心跳所对应的ECG信号段,这样既可以最大程度保留当次心跳的主要信息,又避免混入相邻心跳的信息。最后,对实例数较少的心脏节律类型进行上采样操作,使得每种心脏节律包含相同数量的实例。本发明实施例利用已有的SMOTE (Synthetic Minority Over-sampling Technique) 技术实现该上采样操作。

[0029] S2:设计基于趋势注意门的多层双向长短时记忆神经网络 (TAG-SB-LSTM:Trend Attention Gate based Stacked Bidirectional Long Short-term Memory Network),从S1输出的结果中挖掘ECG信号的整体波动模式。

[0030] 本发明实施例中使用TAG-SB-LSTM来挖掘每ECG信号中采样点之间的长期依赖关系,以刻画ECG信号段的整体波动模式。所设计的TAG-SB-LSTM网络结构由三层双向LSTM构成。其中,上一层LSTM的结果输出给下一层同方向的LSTM。每个LSTM单元的内部结构如图3所示,它由四个门构成,即:忘记门、输入门、输出门及趋势注意门。四个门相互作用,共同控制LSTM单元状态的更新及结果的输出。其中,忘记门用来丢掉LSTM之前状态中的无用信息;输入门决定当前应当给LSTM状态添加哪些信息;输出门确定当前细胞应当将哪些信息作为LSTM的最终状态;趋势注意门根据当前采样点所处的位置以及周围波形来调整当前采样点所对应的长期依赖关系的权重。给定t时刻的输入向量 x_t ,LSTM的输出 h_t 以及LSTM的状态 c_t 按照如下公式进行更新:

$$[0031] \quad f_t = \sigma(W_{xf} \cdot x_t + W_{hf} \cdot h_{t-1} + b_f) \quad (1)$$

$$[0032] \quad i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + b_i) \quad (2)$$

$$[0033] \quad o_t = T_t \odot \sigma(W_{xo} \cdot x'_t + W_{ho} \cdot h_{t-1} + b_o) \quad (3)$$

$$[0034] \quad T_t = \sigma(W_{xt} \cdot x'_t + \sigma(W_{rt} \cdot R_t) + b_t) \quad (4)$$

$$[0035] \quad c_t = f_t \odot c_{t-1} + i_t \odot T_t \odot \tanh(W_{xc} \cdot x'_t + W_{hc} \cdot h_{t-1} + b_c) \quad (5)$$

[0036] $h_t = o_t \odot \tanh(c_t)$ (6)

[0037] 其中, f_t, i_t, o_t, T_t 分别代表忘记门、输入门、输出门、趋势注意门; W, b 分别代表权重和偏置项; σ 表示激活函数; $\odot$ 表示矩阵按元素相乘操作; R_t 表示当前采样点 (即 x_t) 所处的位置及周围波形信息。具体地, R_t 由如下过程可得: 给定一个 ECG 信号段 $x = x_1, x_2, \dots, x_N$, 截取中间的 N' 个采样点作为 TAG-SB-LSTM 的输入, 记为 x' 。对于 x' 中第 t 个元素 x'_t , 它的相对位置和周围波形信息可以表示为:

[0038] $R_t = [0_1, \dots, 0_{t-1}, x_t, \dots, x_{t+L}, 0_{t+L+1}, \dots, 0_N]$, (7)

[0039] 其中, $x_t, \dots, x_{t+L}$ 部分是 x'_t 的周围波形; $L = N - N'$ 是周围波形的长度。特别地, $x_t, \dots, x_{t+L}$ 的中间元素 $x_{t+L/2}$ 即为 x'_t 本身, 因此, x'_t 在 R_t 中的位置可以代表 x'_t 在整个 ECG 信号段中的位置。 R_t 中的若干零值, 一方面可以屏蔽其他距离较远的采样点对当前采样点的影响, 另一方面还可以保证每个采样点的位置及周围波形信息拥有相同的格式, 以便于 LSTM 处理。具体在实施时, 每个 LSTM 单元中的隐藏神经元个数设置为 16; L 设置为 8; N' 设置为 56; 最终, 我们将 TAG-SB-LSTM 在每个时刻所输出的前向结果和后向结果融合成一个矩阵, 如下公式所示:

[0040] $Y = \begin{bmatrix} Y_{1,f} & Y_{1,b} \\ \vdots & \vdots \\ Y_{N,f} & Y_{N,b} \end{bmatrix}$, (8)

[0041] 其中, $Y_{i,f}, Y_{i,b}$ 分别表示 x'_i 所对应的前向结果和后向结果。

[0042] S3: 设计基于特征注意机制及位置注意机制的二维卷积神经网络 (FAM-LAM-TD-CNN: Feature Attention Mechanism and Location Attention Mechanism based Two-dimensional Convolutional Neural Network), 从 S2 输出的结果中挖掘 ECG 信号的局部波动模式。

[0043] 本发明实施例中使用 FAM-LAM-TD-CNN 神经网络结构, 从 S2 的输出 Y 中进一步挖掘 ECG 信号的局部波动模式。本发明实施例中所设计的 FAM-LAM-TD-CNN 网络结构为: 卷积层+最大值池化层+卷积层+平均值池化层。每个卷积层的结构如图 4 所示, 特别地, FAM 及 LAM 的计算过程具体如下:

[0044] FAM: 假设 $F^l \in \mathbb{R}^{H \times W \times C}$ 、 $K_i^l \in \mathbb{R}^{H' \times W' \times C}$ 及 $F_i^{l+1} \in \mathbb{R}^{H'' \times W''}$ 分别表示第 1 个卷积层中的特征图、第 i 卷积核及与该卷积核对应的卷积结果。首先将 F^l 及 K_i^l 的形状分别调整为 $F^l = [f_1, \dots, f_{H \times W \times C}]$, $K_i^l = [k_1, \dots, k_{H' \times W' \times C}]$, 其中 $f_i \in \mathbb{R}^1$, $k_i \in \mathbb{R}^1$ 。然后根据如下公式计算 F_i^{l+1} 的特征注意力权重 W_i^{l+1} :

[0045] $f^i = \tanh(W_f \cdot F^l + W_k \cdot K_i^l + b_f)$, (9)

[0046] $W_i^{l+1}(j) = \frac{\exp(f_j^i)}{\sum_{j=1}^{H'' \times W''} \exp(f_j^i)}$, $W^{l+1} \in \mathbb{R}^{1 \times (H'' \times W'')}$, (10)

[0047] 其中 $W_f \in \mathbb{R}^{(H \times W \times C) \times (H'' \times W'')}$ 及 $W_k \in \mathbb{R}^{(H' \times W' \times C) \times (H'' \times W'')}$ 为转换矩阵, 用来将 F^l

及 K_i^l 映射到 $\mathbb{R}^{1 \times (H'' \times W'')}$ 。然后,我们将 W_i^{l+1} 的形状调整为 $\mathbb{R}^{H'' \times W''}$ 。于是,与 K_i^l 对应的权重化的卷积结果 $F_{W,i}^{l+1}$ 可计算为:

$$[0048] \quad F_{W,i}^{l+1} = F_i^{l+1} \odot W_i^{l+1}, \quad F_W^{l+1} \in \mathbb{R}^{H'' \times W''}, \quad (11)$$

[0049] 最终,由第1个卷积层所得的权重化的卷积结果 F_W^{l+1} 可表示为:

$$[0050] \quad F_W^{l+1} = [F_{W,1}^{l+1}, \dots, F_{W,C''}^{l+1}], \quad F_W^{l+1} \in \mathbb{R}^{H'' \times W'' \times C''}, \quad (1)$$

[0051] 其中, C'' 是第1个卷积层中卷积核的个数。

[0052] LAM:一方面卷积操作的输入是一个矩阵,且矩阵的第 i 行对应于ECG信号段中的第 i 个采样点;另一方面,卷积操作和池化操作均不会改变特征图的空间关系。因此,特征图中行的顺序可以表征特征在ECG信号中的相对位置。所以,我们可以根据 F_W^{l+1} 中特征所属的行来对特征值进行调整,从而模拟特征在ECG中所处位置对特征重要性的影响。

[0053] 假定 $S \in \mathbb{R}^{1 \times N}$ 表示与 F_W^{l+1} 对应的ECG信号段。首先将 F_W^{l+1} 的形状调整为 $F_{W'}^{l+1} \in \mathbb{R}^{H'' \times (W'' \times C'')}$ 。然后位置注意力权重 W_L 可以按如下公式计算:

$$[0054] \quad l = \tanh(W_l \cdot F_{W'}^{l+1} + W_s \cdot S + b_l), \quad (13)$$

$$[0055] \quad W_L(j) = \frac{\exp(l_j)}{\sum_{j=1}^{j=H''} \exp(l_j)}, \quad W_L \in \mathbb{R}^{H'' \times 1}, \quad (14)$$

[0056] 其中 $W_l \in \mathbb{R}^{(W'' \times C'') \times 1}$ 及 $W_s \in \mathbb{R}^{N \times H''}$ 为转换矩阵,用来将 $F_{W'}^{l+1}$ 和 S 映射为长度为 H'' 的向量,从而使所得的 W_L 能与特征中的每一行相互对应起来。之所以在公式13中引入原始ECG信号 s ,是因为在这种情况下,模型可以更好地确定ECG中哪些位置应该具有更高的权重。最终,经过位置注意力权重 W_L 调整后的特征图 F_{WL}^{l+1} 可以表示为:

$$[0057] \quad F_{WL}^{l+1} = W_L \odot F_W^{l+1}, \quad F_{WL}^{l+1} \in \mathbb{R}^{H'' \times W'' \times C''}, \quad (15)$$

[0058] 其中, F_W^{l+1} 中的第 i 个元素与 W_L 中的第 i 个元素进行乘积运算。

[0059] 在具体实施时,两个卷积层的卷积核的个数设为32,每个卷积核的大小设为 4×4 ,且步长为2;最大值池化层的接收域大小也为 4×4 ,但步长为4;平均值池化层的接收域大小及步长与最大值池化层相同。最后,将FAM-LAM-TD-CNN的输出结果进行扁平化处理,以便于后续全连接网络处理。

[0060] S4:利用全连接神经网络 (FCN:Fully Connected Network) 对S3的输出结果进行进一步处理,最终获得每个ECG信号段的处理结果。

[0061] 本发明实施例中,FCN由两个全连层构成,其所含的神经元个数分别设为32和5。特别地,第二个全连层与数据集中心脏节律类型的数量相等。然后,在最后一个全连层之后添加一个Softmax层,从而将网络输出结果转换成概率分布形式,从而确定原始ECG信号段的处理结果。

[0062] 在训练整个神经网络模型时,每个心率不齐分型使用one-hot格式进行编码,采用分类交叉熵函数计算网络的损失;使用LeakyRelu作为网络中神经元的激活函数;使用Adam优化器来更新网络中的各个参数;网络中的各种参数,如权重矩阵、偏置等均初始化为随机值;为了避免过拟合现象,本发明实施例使用下降学习率技术(学习率初始值为0.002,每200次迭代,学习率下降为原来的90%)、dropout技术(dropout层位于FAM-LAM-TD-CNN与FCN之间,且保持率设置为0.95)对网络进行处理;按0.7:0.1:0.2的比例将数据集划分为训练集、验证集、测试集,每次训练以128个实例作为一个mini-batch,整个数据集训练5遍,选择在测试集上性能最优的模型作为最终的模型。




图1




图2




图3




图4

专利名称(译)	一种面向异常心脏节律分类的ECG信号分析方法		
公开(公告)号	CN109907733A	公开(公告)日	2019-06-21
申请号	CN201910285158.0	申请日	2019-04-10
[标]申请(专利权)人(译)	西北工业大学		
申请(专利权)人(译)	西北工业大学		
当前申请(专利权)人(译)	西北工业大学		
[标]发明人	周兴社 刘帆 王柱 倪红波 於志文		
发明人	周兴社 刘帆 王柱 倪红波 於志文		
IPC分类号	A61B5/00 A61B5/04 A61B5/0402 G06K9/62 G06N3/04		
代理人(译)	刘伟		
外部链接	Espacenet SIPO		

摘要(译)

本发明提供一种面向异常心脏节律分类的ECG信号分析方法，可以利用SB-LSTM和TD-CNN从ECG信号中挖掘信号的长期依赖关系和局部特征；所设计的TAG、FAM、LAM可对所得的长期依赖关系和局部特征进行微调，从而获得精确的ECG整体波动模式和局部波动模式。最终，利用FCN得到ECG信号段的处理结果。该方法充分结合了ECG信号的整体波动模式和局部波动模式信息，能在大规模数据集上使用性能更好。此外，该方法避免了人工分类所产生的个体间差异和个体内差异，能够获得稳定的分类结果。特别地，该方法无需借助任何专家知识、无需手动设计各种特征、无需进行特征选择处理、无需单独地构建分类器，是典型的端到端方法，具有使用便捷、分类精度高等特点。

