

基于深度自编码器的心拍识别方法

白淑雯¹ 游大涛² 武相军^{1,2*}

¹(河南大学计算机与信息工程学院 河南 开封 475004)

²(河南大学软件学院 河南 开封 475004)

摘要 为解决由于噪声的干扰导致心拍识别性能仍不理想的问题,提出一种基于深度自编码器的心拍识别方法。该方法使用收缩自编码器和稀疏自编码器相融合,从噪声心拍信号中生成具有稀疏性的有效心拍特征,并使用余弦距离度量输入样本和生成特征之间的相似度。基于生成的心拍特征,使用面向不同患者的卷积神经网络模型进行心拍识别。在 MIT-BIH 数据库上对该方法进行了实验验证,并与经典心拍识别方法对比。实验结果显示该方法大大提高了心拍识别的总体准确率和 F1 值,且具有较高的识别性能。

关键词 心拍识别 深度自编码器 心拍特征生成 不同患者 卷积神经网络

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.12.024

HEART BEAT RECOGNITION METHOD BASED ON DEPTH AUTO-ENCODER

Bai Shuwen¹ You Datao² Wu Xiangjun^{1,2*}

¹(School of Computer and Information Engineering, Henan University, Kaifeng 475004, Henan, China)

²(School of Software, Henan University, Kaifeng 475004, Henan, China)

Abstract In order to solve the problem that the recognition performance of heart beat is still not ideal due to the interference of noise, an heart beat recognition method is proposed based on depth auto-encoder. The method used the contractive auto-encoder and sparse auto-encoder to generate the effective heart beat feature with sparse characteristics from the noise heart beat signal, and used the cosine distance to measure the similarity between the input sample and the generated feature. Based on the generated beat features, a convolution neural network model for different patients was used to recognize the beat. This method was verified by experiments on MIT-BIH database, and compared with the classical beat recognition method. Experimental results show that this method greatly improves the overall accuracy and F1 value of heart beat recognition, and has high recognition performance.

Keywords Heart beat recognition Depth auto-encode Beat feature generation Different patients Convolutional neural network(CNN)

0 引言

近年来,心血管病是因病死亡率最高的疾病,严重威胁着人们的身体健康。心电图信号是心脏活动的记录,可以被相应的心电图仪捕捉到,心血管疾病引起的心脏异常在患者的心电图信号中均会以某种异常波形表现出来。心电图的诊断目前主要由人工

分析完成,但因心电图数据量极为庞大,且心拍类型非常多样化,所以人工对心电图进行逐个心拍的管理和分析是一项难以有效完成的任务,特别是在临床监护或穿戴式健康监护环境下,对医护人员而言,实时诊断更是一项不可完成的任务。此外,因一些异常心拍出现的突然性和不频繁性,致使心脏病医生很难及时捕获一些紧急病情的重要变化信息,从而直接威胁患者的生命安全。因此,如何从大量

心电图数据中自动、及时地识别出异常心拍成为当前一个既有重要理论意义又有重要实际应用价值的研究课题。

心电图的自动诊断是心电图研究领域的热点之一,特别是在实时心电信号诊断领域更是如此。各类心脏病患者的心拍波形多变且差异并不显著,而且心拍信号的实时记录设备常会受工作环境的影响而引入大量不同类型的噪声信息,导致心电图的有效诊断非常困难,至今仍是一个具有较高挑战性的研究问题。针对此,本文将聚焦于实时心电图诊断方面的研究工作。心电图自动诊断大致分为信号预处理、特征生成和识别三个阶段。信号预处理主要指信号去噪及规则化等;特征生成主要指时域和频域心拍特征信息的提取与生成;特征识别主要指识别模型的构建。在特征生成方面具有代表性的方法有自编码器^[1]、经验模式分解^[2]和符号化特征设计^[3]等,在自然图像特征提取、数据降维、特征增强等领域取得了较大的成功。在心拍识别方面,相继涌现了多种方法,大致分为有监督方法和无监督方法。有监督识别方法是指依据带标签的数据构建的识别算法,具有代表性的方法有最小二乘支持向量机^[4]、循环神经网络^[5]、卷积神经网络^[6-7]和径向基神经网络^[8]等;无监督识别方法是指依据不带标签的数据构建的识别算法,具有代表性的方法是堆叠自编码神经网络^[9]和 K-Means 聚类算法^[10]等。

上述特征生成方法虽然取得了显著进展,但是由于心电信号中通常含有噪声,且实际中很多噪声往往是无法预测的,难以建立精确的噪声模型,掩盖了反映心拍状态的关键信息,进而难以提取有效的心拍特征,造成其特征生成性能仍然很低,很难满足临床诊断的要求。另外,上述识别方法只关注所有患者心拍的识别,而不关注实时记录情况下特定患者的心拍识别;因此上述方法忽略了不同患者之间的心拍波形的差异,对新患者的心拍识别的性能并不理想,其性能有待进一步提升。针对上述问题,本文提出以下解决办法:(1)设计一种基于自编码器的噪声心拍信号特征生成方法。算法思想为:首先,使用收缩自编码器从噪声心拍信号中提取有效特征。其次,使用稀疏自编码器从收缩自编码器生成的信号特征中提取具有稀疏特性的心拍特征,生成最终心拍,并使用余弦距离目标函数度量输入心拍

样本和生成心拍特征之间的相似度。(2)提出一种适用于患者导向的心拍识别方法。算法思想为:首先,在上述特征基础上结合 CNN 模型构建可有效表达不同患者心拍间共性信息的通用 CNN 识别模型;然后,在通用 CNN 模型基础上,结合特定患者心拍信息,学习得到一个能反映相应患者心拍个性信息的特定 CNN 模型。该方法综合利用了患者心拍间的差异性信息,实验结果显示,本文方法在一定程度上提升了心拍识别性能。

1 本文方法

本文提出的心拍识别方法主要由两部分组成:(1)采用深度自编码模型获取各类心拍信号的特征变换系数,进而得到具有较高鲁棒性和辨别性的心拍特征;(2)在上述心拍特征基础上,基于卷积神经网络学习能有效区分特定患者心拍的模型系数,进而得到各类心拍的识别方法。

1.1 基于 CSCDAE 的噪声心拍信号特征生成方法

心拍特征的鲁棒性和辨别性对心拍识别性能的高低具有重要影响,为了生成具有较高鲁棒性和辨别性的的心拍特征,本文提出基于 CSCDAE 的噪声心拍信号特征生成方法。CSCDAE 是由收缩自编码器(Contractive Auto-Encoder, CAE)和稀疏自编码器(Sparse Auto-Encoder, SAE)融合而成,且使用余弦距离作为损失函数(Cosine Distance based CAE and SAE Auto-Encoder, CSCDAE)。CSCDAE 以无监督的方式学习心拍中的隐含特征,可通过改变 CSCDAE 的隐层节点数或规则化约束函数,实现对输入数据进行降维的同时,学习得到具有较高鲁棒性和辨别性的特征表示,其数据降维及特征提取能力与主成分分析相比,具有更高的灵活性、鲁棒性和辨别性。

为了使 CSCDAE 学习到具有较高鲁棒性和辨别性的的心拍特征,本文设计了 CSCDAE 模型,如图 1 所示,整个流程分为四个步骤:(1)采集心拍样本输入到 CSCDAE 模型中。(2)使用 CAE 从噪声信号中提取特征。(3)使用 SAE 从 CAE 提取的信号特征中提取稀疏的心拍特征。(4)生成最终心拍,并使用余弦距离目标函数控制输入心拍样本和生成心拍特征之间的相似度。

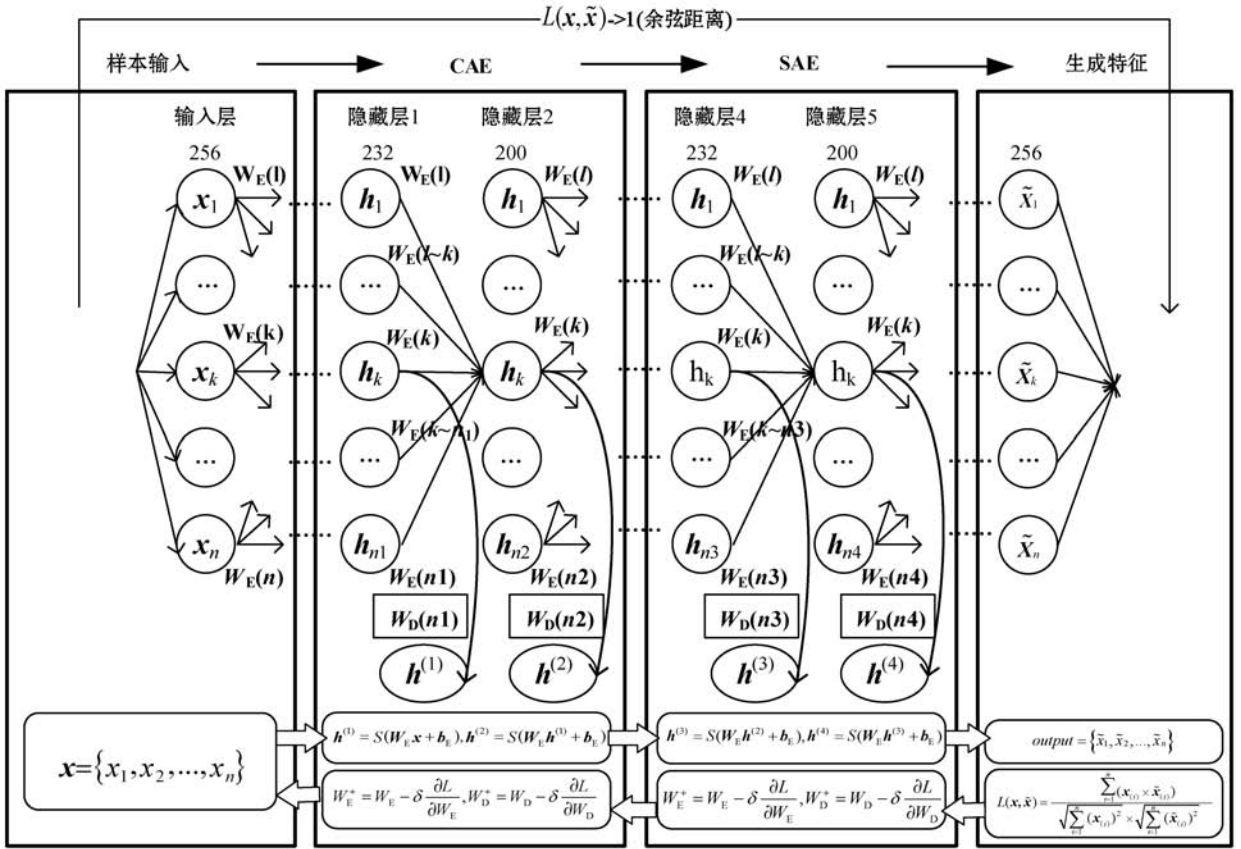


图 1 CSCDAE 特征生成模型

CAE 和 SAE 中每层的神经元个数分别为 256、232、200、232 和 256,前一隐藏层的输出作为后一隐藏层的输入,无监督的逐层训练,使得每层自编码器输入与输出间的误差最小;设置 CAE 中惩罚项系数 δ 为 0.2,SAE 中稀疏惩罚项系数 β 为 0.2,稀疏性参数 ρ 为 0.05。之后通过梯度下降算法对整个 CSCDAE 进行微调,得到最优参数解。实验表明,训练模型 *batch* 大小设为 64,学习率设为 0.01,此时训练精度最高,迭代次数最少。

CSCDAE 中的 CAE 和 SAE 由编码器和解码器两部分组成;在编码阶段,设向量 $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$ 为输入样本,则通过编码器可得到 \mathbf{x} 的隐含表示的数学表达式为:

$$\mathbf{h}_k = S(\mathbf{W}_E^{(l)} \mathbf{x} + \mathbf{b}_E^{(l)}) \quad (1)$$

式中: $\mathbf{W}_E^{(l)} \in \mathbf{R}^{N_l \times M_l}$ 为权重矩阵; N_l 表示第 l 层输入数据的维度; M_l 表示第 l 层的激活函数数量; $\mathbf{b}_E^{(l)} \in \mathbf{R}^{M_l}$ 是第 l 层的偏置向量; $S(\cdot)$ 表示第 l 层的激活函数。本文激活函数采用非线性 Sigmoid 函数,表达式如下:

$$S(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

该激活函数使编码器具有较强的非线性变换能力^[11]。

解码器是编码器的对称变换;它通过与编码器相

近的映射变换 $\tilde{\mathbf{h}}$ 作为输入,通过映射函数重构输出 $\tilde{\mathbf{x}}$, $\tilde{\mathbf{x}}$ 和 \mathbf{x} 维度一致:

$$\tilde{\mathbf{x}} = S(\mathbf{W}_D^{(l)} \tilde{\mathbf{h}} + \mathbf{b}_D^{(l)}) \quad (3)$$

式中: $\mathbf{W}_D^{(l)}$ 是 $\mathbf{W}_E^{(l)}$ 的倒置矩阵; $\mathbf{b}_D^{(l)}$ 是 $\mathbf{b}_E^{(l)}$ 的倒置向量。

自编码器模型参数优化是迭代寻找训练样本重构误差最小化的过程;本文 CSCDAE 模型参数优化中的最小化目标函数如下:

$$O(\{\mathbf{W}_E^{(l)}, \mathbf{W}_D^{(l)}, \mathbf{b}_E^{(l)}, \mathbf{b}_D^{(l)}\}) = \sum L(\mathbf{x}_n, \tilde{\mathbf{x}}_n) \quad (4)$$

通常不同的任务使用不同的损失函数;均方误差常作为目标损失函数,该损失函数假设误差符合高斯分布,较适合多维高像素图像类的特征提取过程中的误差分布;但对于相邻采样值变化较为剧烈的一维心电图形而言,其方差并不符合高斯分布,因此会产生实际方差分布与理论假设不同的问题,致使大量有效的波形信息被抑制或忽略,不利于获取具有高鲁棒性和辨别性的心拍特征。针对这一问题,依据心拍波形特征,本文采用余弦距离作为自编码器的损失函数,度量输入样本和输出数据样本之间的误差:

$$L(\mathbf{x}, \tilde{\mathbf{x}}) = \frac{\sum_{i=1}^n (\mathbf{x}_i \times \tilde{\mathbf{x}}_i)}{\sqrt{\sum_{i=1}^n (\mathbf{x}_i)^2} \times \sqrt{\sum_{i=1}^n (\tilde{\mathbf{x}}_i)^2}} \quad (5)$$

式中: \mathbf{x}_i 为 CSCDAE 的输入样本, $\tilde{\mathbf{x}}_i$ 为输出样本, 两者都为二维信号。余弦距离的范围在 $[-1, 1]$ 之间, 其值越趋近于 1, 距离越小; 越趋近于 -1, 距离越大。为便于计算, 本文将余弦值归一化为 $[0, 1]$ 之间, 用于度量输入样本和输出样本之间的差异。本文 CSCDAE 具体训练算法描述见算法 1。

算法 1 CSCDAE 训练算法

Step 1 CSCDAE 模型初始化。 $\mathbf{W}_E^{(l)}, \mathbf{W}_D^{(l)}, \mathbf{b}_E^{(l)}, \mathbf{b}_D^{(l)}$ (第 l 层中的权重和偏移量, 随机生成); $S^{(l)} = \text{Sigmoid}()$ (第 l 层激活函数); 学习率 $\rho = 0.01$; ε 为收敛阈值; $\partial = 0.2$ (CAE 中的惩罚系数); $\beta = 0.2$ (SAE 中的稀疏惩罚系数); $\rho = 0.05$ (SAE 中的稀疏性参数)。

Step 2 CAE 训练。

Step 2.1 输入: $\mathbf{X} \in \mathbf{R}^{256 \times D}$ (输入心拍特征, 其特征为 256 维样本集, D 为样本数量)。

Step 2.2 前向传播计算:

$$\mathbf{X} = S^{(l)}(\mathbf{W}_D^{(l)} \otimes S^{(l)}(\mathbf{W}_E^{(l)} \otimes \mathbf{X} + \mathbf{b}_E^{(l)}) + \mathbf{b}_D^{(l)});$$

Step 2.3 基于 $\tilde{\mathbf{X}}$ 计算误差:

$$\delta = \frac{\sum_{i=1}^n (\mathbf{x}_i \times \tilde{\mathbf{x}}_i)}{\sqrt{\sum_{i=1}^n (\mathbf{x}_i)^2} \times \sqrt{\sum_{i=1}^n (\tilde{\mathbf{x}}_i)^2}} + \frac{\partial}{2N} \sum_{i=1}^N \|L_j(x_i)\|_F^2$$

Step 2.4 $\delta < \varepsilon$, 判断是否收敛, 若收敛则执行 Step 2.2; 否则执行 Step 2.6。

Step 2.5 依据误差 δ 和学习率 ρ , 采用反向传播计算并更新 $\mathbf{W}^{(l)}$ 和 $\mathbf{b}^{(l)}$ 。

Step 2.6 输出: $\mathbf{H} \in \mathbf{R}^{256 \times D}$ (输出心拍特征, 其特征为 256 维样本集, D 为样本数量)。

Step 3 SAE 训练。

Step 3.1 输入: $\mathbf{H} \in \mathbf{R}^{256 \times D}$ (由 Step 2 传入)。

Step 3.2 前向传播计算:

$$\mathbf{X} = S^{(l)}(\mathbf{W}_D^{(l)} \otimes S^{(l)}(\mathbf{W}_E^{(l)} \otimes \mathbf{X} + \mathbf{b}_E^{(l)}) + \mathbf{b}_D^{(l)}).$$

Step 3.3 基于 \mathbf{X} 计算误差:

$$\delta = \frac{\sum_{i=1}^n (\mathbf{x}_i \times \tilde{\mathbf{x}}_i)}{\sqrt{\sum_{i=1}^n (\mathbf{x}_i)^2} \times \sqrt{\sum_{i=1}^n (\tilde{\mathbf{x}}_i)^2}} + \beta \sum_{j=1}^m KL(\rho \| \rho_j)$$

Step 3.4 $\delta < \varepsilon$, 判断是否收敛, 若收敛则执行 Step 3.2; 否则执行 Step 3.6。

Step 3.5 依据误差 δ 和学习率 ρ , 采用反向传播计算并更新 $\mathbf{W}^{(l)}$ 和 $\mathbf{b}^{(l)}$ 。

Step 3.6 输入: $\mathbf{X} \in \mathbf{R}^{256 \times D}$ (输出心拍特征, 其特征为 256 维样本集, D 为样本数量)。

1.2 基于患者个性信息的心拍识别方法

深度卷积神经网络在心拍识别方面表现优异, 但是对于患者相关的心拍识别模型而言, 由于各类心拍的样本数量相差甚大, 以及不同患者存在个体性差异, 致使现有深度卷积网络存在欠拟合的问题。为了降低

欠拟合问题进而提升心拍识别性能, 本文首先基于深度卷积网络结合来自不同患者的等量各类心拍样本训练一个通用背景模型, 之后采用单个患者的心拍数据在通用背景模型基础上进行优化与微调, 进而生成患者相关的心拍识别模型。

本文针对特定患者的心拍识别提出具体解决方案, 该方案的整个流程分为训练阶段和测试阶段, 见算法 2。在训练阶段, 首先对采集的心拍进行滤波和分割预处理; 其次, 使用本文提出的 CSCDAE 提取心拍特征, 组成通用数据集 (Universal Set, USet) 用来训练通用模型 (Universal CNN, UCNN)。在特定患者训练阶段, 采集特定患者的前 5 分钟心拍, 进行数据预处理和 CSCDAE 特征提取, 生成特定患者数据集 (Specific Patient Set, SPSet); 将 SPSet 中的心拍特征作为 UCNN 的输入进行学习, 从而生成一个用于特定患者的 CNN 模型 (Specific Patient CNN, SPCNN)。在测试阶段, 将每位患者剩余大约 25 分钟的心拍特征组成测试集 (testSet), 放入 SPCNN 中测试, 获取识别结果, 进而衡量整个系统的准确率和识别精度。

算法 2 特定患者心拍识别算法

Step 1 UCNN 训练。

Step 1.1 **Initial:** USet $\{\mathbf{X}^k, \mathbf{Y}^k\}$ (通用数据集); $\mathbf{X}^k \in \mathbf{R}^{256 \times D}$, $k = 1, 2, \dots, 4$ (k 类心拍的 256 维样本集, D 为样本数量); $\mathbf{Y}^k \in \mathbf{R}^{4 \times D}$ (k 类心拍的 4 维标签向量集); $\mathbf{W}_l, \mathbf{b}_l$, $l = 1, 2, \dots, 13$ (第 l 层权重和偏移量, 随机生成); ε 为收敛阈值; 学习率 $\rho = 1e-5$; 第 i 层卷积函数 f_i^c , $i = 1, 2, 3, 5, 6, 7, 9, 10, 11$; 第 j 层池化函数 f_j^p , $j = 4, 6$; 激活函数 $\text{ReLU}()$ 。

Step 1.2 前向传播计算误差 $\sigma = -\frac{1}{m} \sum_{i=1}^m y_i \ln \hat{y}_i$ (y_i 为期望输出, \hat{y}_i 为实际输出)。

Step 1.3 **while:** $\sigma < \varepsilon$, 判断是否收敛, 若收敛则执行 Step 1.6; 否则执行 Step 1.4。

Step 1.4 $\mathbf{X}^l = f_i^c(f_j^p(\text{ReLU}(f_i^c(f_j^p(\text{ReLU}(f_i^c(\mathbf{X}^k)))))))$, 执行 Step 1.5。

Step 1.5 基于 \mathbf{X}^l 采用反向传播方式极小化误差 σ , 依据学习率 ρ 调整 \mathbf{W}_l 和 \mathbf{b}_l 。

Step 1.6 **Return:** $\mathbf{W}_l, \mathbf{b}_l$ ($l = 1, 2, \dots, 13$)。

Step 2 SPCNN 训练。

Step 2.1 **Initial:** SPSet $\{\mathbf{X}^k, \mathbf{Y}^k\}$ (特定患者前 5 分钟数据集); $\mathbf{X}^k \in \mathbf{R}^{256 \times D}$, $k = 1, 2, \dots, 4$ (k 类心拍的 256 维样本集, D 为样本数量); $\mathbf{Y}^k \in \mathbf{R}^{4 \times D}$ (k 类心拍的 4 维标签向量集); $\mathbf{W}_l, \mathbf{b}_l$ ($l = 1, 2, \dots, 13$) (第 l 层权重和偏移量, 由 Step 1 传入); ε 为收敛阈值; 学习率 $\rho = 1E-5$; 第 i 层卷积函数 f_i^c , $i = 1, 2, 3, 5, 6, 7, 9, 10, 11$; 第 j 层池化函数 f_j^p , $j = 4, 6$; 激活函数 $\text{ReLU}()$ 。

Step 2.2 前向传播计算误差 $\sigma = -\frac{1}{m} \sum_{i=1}^m y_i \ln \hat{y}_i$ (y_i 为期望输出, \hat{y}_i 为实际输出)。

Step 2.3 **while:** $\sigma < \varepsilon$, 判断是否收敛, 若收敛则执行 Step

2.6;否则执行 Step 2.4。

Step 2.4 $X^l = f_l^c(f_j^p(\text{ReLU}(f_i^c(f_j^p(\text{ReLU}(f_i^c(X^k)))))))$, 执行 Step 2.5。

Step 2.5 基于 X^l 采用反向传播方式反向传播极小化误差 σ , 依据学习率 ρ 调整 W_l 和 b_l 。

Step 2.6 Return: $W_l, b_l (l=1, 2, \dots, 13)$ 。

Step 3 SPCNN 测试。

Step 3.1 Require: testSet $\{X^k\}$ (特定患者剩余 25 分钟数据集); $X^k \in \mathbf{R}^{256 \times D}, k=1, 2, \dots, 4$ (k 类心拍的 256 维样本集, D 为样本数量)。

Step 3.2 Return: Acc(准确率)、Se(灵敏度)、P(精确率) 和 F1-score(综合指标)。

SPCNN 可针对特定患者进行心拍识别,解决了由于患者间心拍的特异性造成的识别性能较低的问题。它可嵌入到特定患者的穿戴设备中,实时监测心拍;若出现异常心拍,设备可实时警告患者。在此识别系统中,UCNN 可检测到大量长期心电信号中的异常心拍,而 SPCNN 可以针对特定患者进行实时检测。显然,该方案不仅适用于患病者,而且适用于无病者。

通常,CNN 的输入样本是具有两个或两个以上维度的图像,如灰度图像或分辨率较高的彩色图像。但在本实验中,心拍波形是由不同时刻的振幅构成的一维向量。因此,在使用模型对心拍信号识别之前,须对模型的图像分析结构进行修改,使卷积层中的所有卷积运算适用于一维序列,每一层卷积核也修改为适用于一维序列的尺度。同时,卷积核的设计采用小尺度和多尺度相结合的方法。小尺度可捕捉心拍之间的微小异常,并且能降低计算复杂度和计算成本;多尺度可避免提取的特征过于单一化,有利于多视野提取数据特征。本文提出的用于心拍识别的卷积神经网络模型如图 2 所示。

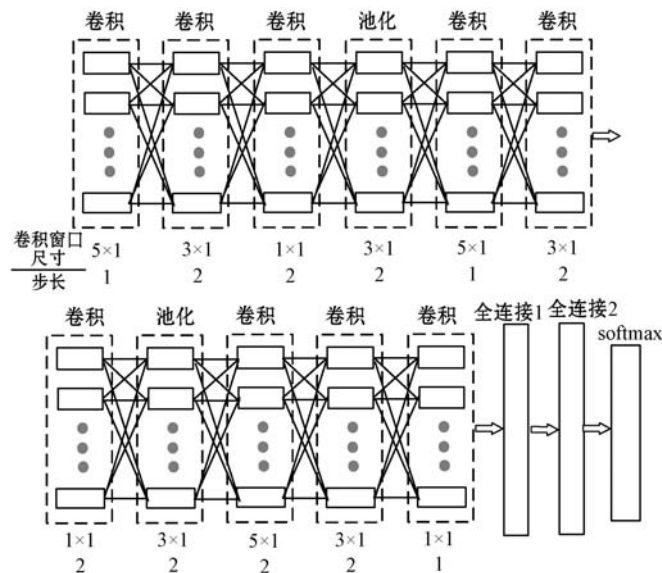


图 2 CNN 训练模型

整个模型共 13 层,其中 9 个卷积层,2 个池化层,2 个全连接层;激活函数使用 ReLU,损失函数为交叉熵。实验表明,将 UCNN 的 $batch_size$ 设置为 40,将 SPCNN 的 $batch_size$ 设置为 50,结合学习率 $\rho = 1E-5$,模型收敛速度快。

2 实验与结果分析

2.1 数据库

本文实验数据选用 MIT-BIH 心律失常数据库。MIT-BIH 数据库包含 48 个心电图记录,来自 47 名受试者,其中 25 名是 32 岁至 89 岁的男性,22 名是 23 岁至 89 岁的女性^[12],每条记录持续 30 分钟左右,采样频率为 360 Hz(以每秒 360 个样本的速度数字化),通过将电极放在胸部获得心电图记录^[10],其中包含两个来自不同电极的导联:MLII 导联和 V1 导联。在本研究中,使用 MLII 导联的信号进行训练和测试,且所有的记录都由心脏病专家注释其类别。

因 MIT-BIH 数据库中 4 个心电图记录(102,104,107 和 217)为起搏心拍,所以本文共收集了除上述四个心电记录之外的 99 065 个心拍用于实验验证与分析。根据 AAMI 标准,本文将心拍信号分为四类:正常心拍、室上性心拍、心室上性心拍和融合心拍^[13]。在心拍特征提取阶段,将 MIT-BIH 数据集中的 30 条记录 $\{100, 101, 105, 106, 109, 111, 113, 114, 116, 117, 119, 121, 123, 124, 201, 202, 205, 207, 209, 210, 213, 214, 219, 220, 222, 223, 230, 231, 233, 234\}$ 构建为训练集;记录 $\{103, 108, 112, 115, 118, 122, 200, 203, 208, 212, 215, 221, 228, 232\}$ 构建为测试集来验证本文特征生成模型 CSCDAE。在心拍识别阶段,将 MIT-BIH 数据集中的 24 条记录 $\{101, 105, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 214, 215, 220, 223, 230\}$ 构建为初始训练集,其余 20 条记录 $\{100, 103, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 219, 221, 222, 228, 231, 232, 233, 234\}$ 中每条记录的前 5 分钟心拍构成特定患者训练集,其他的 25 分钟左右心拍构建为测试集(此阶段每条记录中的心拍特征为 CSCDAE 生成的特征)。

2.2 结果分析

本文在数据预处理阶段使用小波变换和中值滤波器相结合的方法去除基线漂移、工频干扰和肌电干扰噪声。实验结果表明,以 Daubechies 5 为小波基的小波变换和以窗口大小为 60 的中值滤波器相结合能有效地去除其三类噪声,提升信号质量。在心拍分割中,基于 R 峰向前取 0.35 s,向后取 0.35 s 分割单个波形,将所有心电记录分割为 99 065 个同尺度的单一心拍

进行训练。由于在心电图采集的过程中出现横向漂移的情况,造成重叠分割。基于此问题,采用均值填充方法将小尺度的心拍进行缩放,保证了关键特征不变性,对之后的分类检测提供了重要的基础。

在特征提取阶段,针对大量有效的波形信息被抑制或被忽略,导致无法获取具有高鲁棒性和辨别性心拍特征的问题,本文依据心拍波形特性,使用改进的堆叠自编码器(CSCDAE)进行有效特征提取。为验证CSCDAE模型的性能,本文选取具有代表性的特征提取方法进行对比见表1。

表1 使用CSCDAE性能对比

序号	对标方法				
	参考文献	特征生成方法	分类器	Acc/%	提升/百分点
1	文献[14]	自编码器	DNN	95.03	3.57
2	文献[15]	集成经验模式分解	CNN	97.70	1.07
3	文献[16]	归一化	SPCNN	93.25	0.30
4	本文方法	CSCDAE	SPCNN	98.43	3.58

由表1可知,基于本文提出的分类模型,未使用CSCDAE特征的准确率是94.85%,而使用基于CSCDAE特征的准确率则是98.43%,有明显的性能提升。颜菲等^[14]提出的自编码器和DNN融合的分类算法得出准确率为95.03%,低于本文的识别性能。Hasan等^[15]将每个心电信号先通过经验模态分解(EMD)进行分解,再结合高阶本征模态函数(IMFs)形成修正后的心电信号,并使用CNN对修正后的信号进行分类,准确率为97.70%,低于本文方法。Ma等^[16]对特征数据进行归一化,可加快模型训练速度,但准确率为93.25%。综上所述,使用本文的CSCDAE模型进行有效特征提取,能提升识别精度和准确率。

本文算法在20条记录的测试集中进行检验,其中为每条记录的后25分钟心拍,得出每个类别的正确和错误分类数量见表2。综合得知,识别模型的准确率达到98.43%,验证了本文所提出的CSCDAE特征生成方法结合SPCNN模型用于心拍的识别有较好的效果。

表2 测试集每条记录的准确率

记录	N		S		V		F		Acc/%
	正确	错误	正确	错误	正确	错误	正确	错误	
100	1 832	3	18	11	0	1	0	0	99.19
103	1 690	8	1	1	0	0	0	0	99.47
111	1 741	1	0	0	1	0	0	0	99.94
113	1 464	9	3	2	0	0	0	0	99.25
117	1 245	14	0	1	0	0	0	0	98.80
121	1 513	12	0	1	1	0	0	0	99.14
123	1 236	4	0	0	2	1	0	0	99.59
200	1 389	21	19	9	615	78	1	1	94.88
202	1 735	25	45	10	11	4	0	1	97.81
210	2 153	27	16	3	119	38	6	3	96.72
212	2 248	0	0	0	0	0	0	0	100.00
213	2 155	14	22	4	153	40	21	53	95.81
219	1 661	23	4	3	42	7	0	0	98.10
221	1 668	1	0	0	315	2	0	0	99.84
222	1 934	18	169	40	0	0	0	0	97.19
228	1 374	0	2	1	255	40	0	0	97.54
231	1 250	1	0	0	0	0	0	0	99.92
232	289	25	1 104	41	0	0	0	0	95.47
233	1 823	3	3	1	620	59	5	1	97.45
234	2 173	26	38	12	1	2	0	0	98.22
总计	32 573	235	1 444	140	2 135	272	33	59	98.43

为了进一步验证和分析本文提出的心拍识别方法的性能,本文还在测试阶段分别计算了 N、S、V 和 F 四类心拍对应的准确性、敏感性和 F1 值,基线系统则选取了 4 个具有代表性文献的心拍识别方法,具体结果如表 3 所示。

表 3 使用不同方法时的实验结果比较(%)

属性		文献 [17]	文献 [18]	文献 [19]	文献 [20]	文献 [21]	本文方法
N	Se	97.59	97.81	97.79	79.27	81.95	99.67
	P	96.54	97.49	95.54	94.16	98.74	99.16
S	Se	71.84	77.20	27.51	11.05	88.39	92.33
	P	57.68	96.60	55.33	27.25	33.63	91.55
V	Se	62.73	68.70	89.04	57.49	77.74	97.24
	P	93.12	94.70	81.04	17.96	69.20	97.75
F	Se	77.78	74.67	23.24	99.22	89.04	90.65
	P	65.53	90.79	100.00	29.53	81.04	96.45
Acc		94.05	95.62	93.69	74.00	93.63	98.43
F1		77.84	86.52	69.23	43.66	74.08	95.57

由表 3 可知,文献[17]使用 SAE 和 DNN 算法融合识别心拍,准确率达到 94.05%,但其 F1 值只有 77.84%,算法的识别能力和有效性低于本文方法。文献[18]中方法的性能是四个基线系统中最优的,而本文方法的识别性能则明显高于文献[18]中方法的性能。文献[19]使用 DNN 模型识别,相比本文算法,该方法没有考虑到不同患者间的差异性,且测试数据量大,存储成本高,不适用于健康实时监护。文献[20]提出用于解决每个类别之间不平衡性问题的卷积神经网络模型,在通用模型训练完成后,分别训练 N、S、V 和 F 四类数据模型,训练负担大,且最终准确率和 F1 值较低,不适合用于实际临床应用。文献[21]针对单导联心拍提出受限玻尔兹曼机和深度置信网络相融合的分类框架,其 F1 值偏低。综上所述,本文使用小波变换和中值滤波器结合滤除噪声,使用 CSCDAE 进行特征提取,针对 SPCNN 结构对心拍进行识别,识别的准确率和 F1 值与现有的算法相比得到提高,在实际应用中更加可行。

本文提出的心拍识别方法在 Intel(R) Core(TM) i5-8400 CPU @ 2.8 GHz、8 GB 内存的 64 位系统上,UCNN 模型和 SPCNN 模型的训练时间为 18 min,而每个心拍在 SPCN 模型中的测试时间则仅需 0.2 ms。

3 结 语

针对心电噪声的干扰,大量有效的波形信息被抑

制或被忽略,无法获取具有高鲁棒性和辨别性的心拍特征问题,本文首先设计一种基于余弦距离的堆叠自编码器进行心拍特征提取。在此基础上,针对不同患者心拍间的差异性对心拍识别性能具有较大影响等问题,本文提出一种基于通用背景模型和患者心拍个性信息的深度卷积神经网络识别方法。实验结果表明,本文所设计的心拍识别方法具有更好的性能,非常适合用于实时监测的嵌入式穿戴设备的需求。

参 考 文 献

- [1] 季琳雅,吕鑫,陶飞飞,等. 基于对抗自编码网络的水利数据补全方法[J]. 计算机工程,2019,45(4):307-310.
- [2] Rajesh K N, Dhuli R. Classification of imbalanced ECG beats using re-sampling techniques and AdaBoost ensemble classifier[J]. Biomedical Signal Processing and Control, 2018,41:242-254.
- [3] Niu J, Tang Y, Sun Z, et al. Inter-Patient ECG classification with symbolic representations and Multi-Perspective Convolutional Neural Networks[J]. IEEE Journal of Biomedical and Health Informatics, 2020,24(5):1321-1332.
- [4] Rajesh K N, Dhuli R. Classification of ECG heartbeats using nonlinear decomposition methods and support vector machine[J]. Computers in Biology and Medicine, 2017,87:271-284.
- [5] Wang G, Zhang C, Liu Y, et al. A global and updatable ECG beat classification system based on recurrent neural networks and active learning[J]. Information Sciences, 2019, 501:523-542.
- [6] Hammad M, Zhang S, Wang K. A novel two-dimensional ECG feature extraction and classification algorithm based on convolution neural network for human authentication[J]. Future Generation Computer Systems, 2019,101:180-196.
- [7] Kiranyaz S, Ince T, Gabbouj M. Real-Time Patient-Specific ECG classification by 1-D Convolutional Neural Networks[J]. IEEE Transactions on Biomedical Engineering, 2016, 63(3):664-675.
- [8] Dong X, Wang C, Si W. ECG beat classification via deterministic learning[J]. Neurocomputing, 2017,240:1-12.
- [9] 曾安,张艺楠,潘丹,等. 基于稀疏降噪自编码器的深度置信网络[J]. 计算机应用,2017,37(9):2585-2589.
- [10] Liu T, Si Y, Wen D, et al. Dictionary learning for VQ feature extraction in ECG beats classification[J]. Expert Systems with Applications, 2016,53:129-137.
- [11] 张玉彦. 基于深度自编码器的机械故障诊断方法研究[D]. 武汉:华中科技大学,2019.
- [12] Sharma T, Sharma K K. QRS complex detection in ECG signals using locally adaptive weighted total variation denoising[J]. Computers in Biology and Medicine, 2017, 87:187-

199.

- [13] 樊承柱. 基于深度神经网络的心电图自动分类方法研究与实现[D]. 济南:山东大学,2016.
- [14] 颜菲,胡玉平. 叠加去噪自动编码器结合深度神经网络的心电图信号分类方法[J]. 计算机应用与软件,2019,36(4):178-185.
- [15] Hasan N I, Bhattacharjee A. Deep learning approach to cardiovascular disease classification employing modified ECG Signal from empirical mode decomposition[J]. Biomedical Signal Processing and Control, 2019, 52: 128-140.
- [16] Ma G, Wang X, Yu J. ECG signal classification algorithm based on fusion features[C]//2019 3rd International Conference on Control Engineering and Artificial Intelligence,2019.
- [17] Rahhal M M A, Bazi Y, AlHichri H, et al. Deep learning approach for active classification of electrocardiogram signals [J]. Information Sciences,2016,345:340-354.
- [18] Li Y, Pang Y, Wang J, et al. Patient-specific ECG classification by deeper CNN from generic to dedicated[J]. Neurocomputing,2018,314:336-346.
- [19] Sannino G, Pietro G D. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection[J]. Future Generation Computer Systems,2018, 86:446-455.
- [20] 原永朋,游大涛,武相军,等. 类内类间距离在 CNN 识别心拍类中的应用研究[J]. 计算机工程与应用,2019,55(14):242-248.
- [21] Mathews S M, Kambhamettu C, Barner K E. A novel application of deep learning for single-lead ECG classification [J]. Computers in Biology and Medicine,2018,99:53-62.

(上接第 82 页)

- [9] Kerstin B, Sven H, Michael B, et al. Stochastic neighbor embedding (SNE) for dimension reduction and visualization using arbitrary divergences[J]. Neurocomputing,2012,90: 23-45.
- [10] Domínguez M, Alonso S, Morán A, et al. Dimensionality reduction techniques to analyze heating systems in buildings [J]. Information Sciences,2015,294:553-564.
- [11] Zhang L, Zhang L, Tao D, et al. A modified stochastic neighbor embedding for multi-feature dimension reduction of remote sensing images[J]. ISPRS Journal of Photogrammetry & Remote Sensing,2013,83:30-39.
- [12] 张康,黄亦翔,赵帅,等. 基于 t-SNE 数据驱动模型的盾构装备刀盘健康评估[J]. 机械工程学报,2019,55(7):19-26.
- [13] Laurens V D M, Hinton G. Visualizing data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9 (2605):2579-2605.
- [14] Aggarwal C C, Hinneburg A, Keim D A. On the surprising behavior of distance metrics in high dimensional space[C]//

International Conference on Database Theory,2001.

- [15] Chapelle O, Haffner P, Vapnik V N. Support vector machines for histogram-based image classification [J]. IEEE Transactions on Neural Networks,1999,10(5):1055-1064.
- [16] Vapnik V N, Lerner A. Pattern recognition using generalized portrait method[J]. Automation and Remote Control,1963, 24(6):774-780.
- [17] Vapnik V N. The nature of statistical learning theory[M]. Springer,2000.
- [18] Fawcett T. An introduction to ROC analysis [J]. Pattern Recognition Letters,2006,27(8):861-874.
- [19] Wang Z, Wang Z, He S, et al. Fault detection and diagnosis of chillers using Bayesian network merged distance rejection and multi-source non-sensor information [J]. Applied Energy,2017, 188(15):200-214.
- [20] Han H, Gu B, Wang T, et al. Important sensors for chiller Fault Detection and Diagnosis (FDD) from the perspective of feature selection and machine learning[J]. International Journal of Refrigeration,2011,34(2):586-599.

(上接第 136 页)

- [8] Psaras I, Chai W K, Pavlou G. In-network cache management and resource allocation for information-centric networks [J]. IEEE Transactions on Parallel and Distributed Systems,2014,25(11):2920-2931.
- [9] Wang Y, Li Z, Tyson G, et al. Design and evaluation of the optimal cache allocation for content-centric networking[J]. IEEE Transactions on Computers,2016,65(1):95-107.
- [10] Gu J, Wang W, Huang A, et al. Proactive storage at caching-enable base stations in cellular networks[C]//IEEE International Symposium on Personal, 2013: 1543-1547.
- [11] Gharaibeh A, Khreishah A, Ji B, et al. A provably efficient online collaborative caching algorithm for multicell-coordinated systems[J]. IEEE Transactions on Mobile Computing, 2015,15(8):1863-1876.
- [12] Zhao Z, Peng M, Ding Z, et al. Cluster content caching: An energy-efficient approach to improve quality of service in cloud radio access networks[J]. IEEE Journal on Selected Areas in Communications,2016,34(5): 1207-1221.
- [13] Liu G, Lan J, Wang P. Cooperative caching and routing scheme based on local centralized control in content centric networking[J]. Application Research of Computers,2018, 35(2):564-568,581.
- [14] Ge Z, Xu K, Chen L, et al. A hierarchical cooperative caching strategy for mobile content delivery network[J]. Chinese Journal of Computers,2018,41(12):2769-2786.
- [15] Sun W, Li Y, Hu C, et al. Joint optimization of cache placement and bandwidth allocation in heterogeneous networks[J]. IEEE Access,2018,6(6):37250-37260.