

基于深度全卷积提升网络的心电信号降噪

杨畅 刘慧妍 刘明*

(河北大学电子信息工程学院河北省数字医疗工程重点实验室 河北保定 071002)

摘要 针对传统的降噪方法难以在不丢失心电信号下准确去除复杂噪声问题,提出一种基于深度全卷积提升网络(FCBN)的心电信号降噪方法。该方法利用全卷积网络的局部连接的特性来保留心电信号波形细节信息,通过提升(Boosting)算法堆叠多个FCN网络形成深度神经网络,多级输入原始信号,保留心电信号的深层信息特征,提高整体网络的降噪性能。实验结果表明,该方法与小波阈值法、S变换法、BP神经网络法和卷积自动编码器比较,信噪比提高明显且均方根误差较小,同时可保留更多心电信号的波形形态信息。

关键词 心电信号 降噪 全卷积网络 提升算法

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.05.007

ECG SIGNAL DENOISING BASED ON DEEP FULLY CONVOLUTIONAL BOOSTING NETWORK

Yang Chang Liu Huiyan Liu Ming*

(Key Laboratory of Digital Medical Engineering of Hebei Province, College of Electronic Information Engineering, Hebei University, Baoding 071002, Hebei, China)

Abstract The traditional method of denoise is difficult to accurately remove the complex noise without losing the ECG signal, an ECG signal denoising method is proposed based on the deep full convolutional Boosting network (FCBN). This method used the characteristics of the local connection of the full convolutional network to retain the detailed information of the ECG signal waveform, and stacked multiple FCN networks through the Boosting algorithm to form a deep neural network. The original signal in multiple stages were inputted, and it retained the deep information of the ECG signal features to improve the denoising performance of the overall network. Experimental results show that compared with wavelet threshold method, S transform method, BPNN method and convolutional autoencoder, this method has obvious improvement in SNR and smaller RMSE, while retaining more ECG signal waveforms morphological information.

Keywords ECG signal Denoising Fully convolutional network Boosting algorithm

0 引言

心血管疾病(CVDs)一直是世界范围内心脏性猝死的主要原因。据2017年世界卫生组织数据表明(WHO),每年有1790万人死于心血管病,占全球死亡总数的31%。心脏病发作和中风占这些死亡的85%。研究表明90%的心脏病发作是可以有效预防和诊断的^[1]。心电图(ECG)作为一种成熟诊断心脏病的技术,可以进行早期有效的诊断,对预防心脏病发

作至关重要。心电图可以评估心脏的生理状况,并检测各种异常,如心律失常、冠状动脉阻塞等。ECG信号在采集和传输过程会因各种噪声干扰而严重损坏,使得提取心电信号中有用的形态特征信息和解释心电信号变得困难,从而导致对心脏疾病的检测不可靠或错误,并阻碍了心脏疾病的发现。ECG中复杂噪声一般主要是肌电干扰、基线漂移、电极干扰和工频干扰。其中工频干扰是由于人体电磁场噪声的固定噪声,一般频率为50 Hz的稳定噪声,较容易去除。因此在不丢失有用信息的前提下,准确去除心电信号的肌电干

扰、基线漂移和电极干扰噪声是非常重要的。

采集到的心电信号中包含复杂噪声,心电信号降噪的目标不仅是去除复杂噪声,同时尽可能多地保留有用信号信息。由于部分 ECG 信号和噪声的频率重叠,这仍是一个具有挑战性的任务。近年来,针对 ECG 信号降噪的研究很多,传统的降噪方法包括小波类算法^[2-4]、经验模态分解法(EMD)^[5]和自适应数字滤波器^[6-8]。其中,小波类去噪算法是通过时频域分解来消除噪声,在 ECG 去噪中应用最为广泛。小波系数可以采用硬阈值和软阈值,硬阈值法在一般情况下具有良好的去噪性能,但可能导致重构出的心电信号振荡,即所谓的伪吉布斯现象,导致其应用有一定局限性^[4]。同时,软阈值可以产生更为平滑的心电信号,并且具有更好的连续性。然而,软阈值会扭曲重构波形的振幅,特别是对诊断很重要的 QRS 复合体中的 R 波的振幅^[9]。在基于 EMD 的降噪方法中,噪声信号被分解为固有模态函数(IMFs),去除含有最多噪声的 IMF,用剩余的 IMF 重构出降噪以后的信号。EMD 方法可能不能很好地区分高频噪声和 QRS 波,且对相似的频率信号不能很好地分离,导致 ECG 信号中 P 波和 T 波可能被滤除,从而发生误诊^[10]。滤波类算法虽然有很好的去噪效果,但是只能在离线状态下对噪声进行滤除,且在信号传输过程容易混入复杂噪声影响波形。常见的简单滤波方法不能保证有效去除噪声的同时还保留完整的 ECG 信号有用信息。Liu 等^[11]首次利用指导滤波算法去除信号中复杂噪声,指导滤波的边缘保持特性能够达到很好的降噪效果,但是算法无法对变异性心拍进行降噪。

随着深度学习的发展,针对 ECG 信号降噪出现越来越多的基于深度学习的降噪模型。这些基于深度学习的模型取得了与传统的降噪方法一样好的降噪效果,甚至表现更好。Xiong 等^[10]提出由小波变换后的去噪自动编码器(DAE)组成的深度神经网络(DNN)来消除心电信号噪声。利用小波变换和尺度自适应阈值法对大部分噪声进行滤波,然后利用改进的神经网络对残留噪声进行去除。但是忽略了基线漂移的噪声,基线漂移的噪声的大小可能比 ECG 信号本身高几倍。Antczak^[12]首次尝试使用基于长短期记忆(LSTM)模型的深度学习来抑制 ECG 中的噪声,利用迁移学习方法,将动态心电图模型生成的合成数据对网络进行预训练,并利用真实数据对网络进行微调。不仅没考虑基线漂移对信号的影响,而且该方法容易导致过拟合。Chiang 等^[13]首次对 ECG 信号使用基于全卷积网络(FCN)的去噪自动编码器(DAE)进行降噪处理的研究。在相同的压缩比下,与基于 DNN 和 CNN 的去

噪模型相比,FCN 具有更好的降噪性能。现有的降噪方法虽然取得了一些效果,但是仍存在以下两个问题:第一,ECG 信号中噪声信号复杂,传统的降噪方法无法准确获取噪声的特征,在去噪同时会丢失部分有用的 ECG 信号,导致心血管疾病诊断失败;第二,部分噪声信号和 ECG 信号存在重叠的频率,且有些噪声对微小波 P 波和 T 波的波形形态影响很大,导致波形变化明显。

基于此,为了进一步提高在远程医疗背景下被复杂噪声淹没的 ECG 信号的降噪效果,更准确捕获 ECG 信号的波形特征,在降噪同时避免 ECG 信息的丢失。本文提出一种基于深度全卷积提升网络(FCBN)的心电信号降噪方法。由于卷积层具有局部连通性,每个神经元只依赖于前一层的一个小区域,用卷积层替换 CNN 最后的全连接层得到 FCN。FCN 的接受野小,使 FCN 能够有效地提取和保存局部信息特征。同时,输入信号特征在接受野中共享相同的权值,减少了参数量,硬件实现更简单。再利用 FCN 取代 Boosting 算法中传统的手工提升单元,采用前反馈的方式集成了多个 FCN,其中每个单独的 FCN 作为一个降噪模块,FCN 中卷积层的滤波器可以提取波形特征映射来描述输入信号的数据的特征。由于 ECG 信号和噪声的重叠,在降噪的同时可能将部分信号丢失,而 Boosting 算法通过将每一级 FCN 降噪后的输出信号与原始输入信号相结合,作为下一个独立的网络模块的输入数据,重新训练新的模型参数,逐级去噪。原始输入信号数据输入到每一级独立降噪子模块中可以将 FCN 降噪过程中丢失的信号找回,降噪后的信号和干净的信号相比波形变化小,尽量保留更多的信号形态特征。与其他降噪方法对比,本文方法的降噪效果更好,重构出的 ECG 信号和原始干净信号差异更少,减少了降噪中 ECG 信号的丢失。

1 方法

本文将全卷积网络和 Boosting 算法结合构造出 FCN-Boosting 网络。本文降噪方法主要由 4 部分组成:信号预处理,网络初始化,训练 FCN-Boosting 降噪网络,重构出降噪后的信号。首先对数据库中下载的原始心电信号进行归一化、截取心电样本等预处理,利用干净的原始信号对网络各层权值进行初始化。然后将预处理好的样本数据输入每一级 FCN 网络中进行卷积层处理,卷积层中的滤波器提取信号特征,同时消除噪声。利用 Boosting 算法堆叠多个 FCN 网络形成深度神经网络,由于池化层对特征进行压缩,导致提取的

ECG 信号特征会发生丢失,为了更好地保证信号的完整性,取消 FCN 网络中的池化层。再经过反卷积过程重构出信号。

1.1 全卷积神经网络

FCN 网络是一种特殊的 CNN 网络结构,全卷积网络的基本结构是“卷积-反卷积”,类似编码器-解码器结构,一般用于图像语义分割^[14]。CNN 网络建立在平移不变性的基础上,通常由卷积层、激活函数、池化层和全连接层组成,作用于局部输入区域。卷积层由一组滤波器组成,可以提取特征映射来描述输入数据的特征。同一层中不同的特征映射使用不同的滤波器参数,而一个特征映射共享相同的参数。每个神经元都连接到前一层的所有输出,卷积层通过与滤波器共享参数,大大减少了参数的数量。使用池化实现平移和旋转不变性,典型的池化操作是最大池化。最大池层通过从映射空间中取某个范围的最大值来执行降采样过程,从而降低维数。全连接层用于进行回归或分类。

FCN 与 CNN 的区别在于 FCN 把 CNN 最后的全连接层换成卷积层^[14]。全连接层不能很好地保留前一层的空间信息^[15-16],而 FCN 网络通过舍弃全连接层,使每个输出结果能保留原始输入的局部空间信息^[17]。在 CNN 中,输出层和最后的隐藏层是完全连接的,每个神经元都与前一层的所有神经元完全连接。在输出层中,每个神经元都与最后一个隐藏层中的所有单元完全连接。由于全连接层的权向量相关性高,导致 CNN 中的空间信息容易丢失。相比之下,在 FCN 中的卷积层具有局部连通性。每个神经元只依赖于前一层的一个小区域,即接受野。输入特征在接受野中共享相同的权值,这导致了翻译不变性,使 FCN 能够有效地提取和保存局部信息。同时,减少了参数量,硬件实现更简单。由于网络中的池化层可能会导致网络训练时丢失信号的纹理细节信息,同时本文实验中也为了准确地将输入信号与输出信号对齐,采用的 FCN 网络模型不含有池化层。通过卷积提取信号细节信息及空间信息,通过反卷积重构出降噪后的信号。

图 1 为本文信号降噪时 FCN 网络结构,此结构类似编码器-解码器结构,网络的输入为 $1\ 024 \times 1$ 的 ECG 信号经过 5 层一维卷积处理后,得到尺寸为 64×1 的特征图,再经过 5 个上采样层和一个反卷积层,恢复出 ECG 信号。由于没有池化层,本文实验中将卷积层步长设置为 2 作为下采样过程。并采用指数线性单元(ELU)作为隐层的激活函数。本文中 FCN 的网络参数如表 1 所示。




图 1 FCN 网络结构

表 1 FCN 网络参数

网络结构	网络参数	
一维卷积 下采样	Conv1	滤波器个数:20,大小: 8×1 ,步长:2
	Conv2	滤波器个数:10,大小: 8×1 ,步长:2
	Conv3	滤波器个数:10,大小: 8×1 ,步长:2
	Conv4	滤波器个数:20,大小: 8×1 ,步长:2
	Conv5	滤波器个数:1,大小: 8×1 ,步长:1
上采样	Deconv1	滤波器个数:1,大小: 8×1 ,步长:1
	Deconv2	滤波器个数:20,大小: 8×1 ,步长:2
	Deconv3	滤波器个数:10,大小: 8×1 ,步长:2
	Deconv4	滤波器个数:10,大小: 8×1 ,步长:2
	Deconv5	滤波器个数:20,大小: 8×1 ,步长:2
反卷积	Deconv1	滤波器个数:1,大小: 8×1 ,步长:1

FCN 网络通过损失函数来衡量模型是否满足要求,模型参数需通过反向传播算法进行修正优化。本文的损失函数为:

$$L(\theta) = \sum_i \|x(n) - \hat{x}(n)\|_2^2 \quad (1)$$

式中: $x(n)$ 为原始输入 ECG 信号; $\hat{x}(n)$ 为降噪后输出的信号; n 为训练样本数量。

1.2 Boosting 算法

Boosting 是通过迭代多个可操纵模型来提高不同任务的性能的一种鲁棒算法。Schapire^[18]提出了最早的多项式时间的 Boosting 算法,但由于缺陷太多而无法应用于实际问题研究。Freund 等^[19]提出 AdaBoost 算法,解决了早期 Boosting 算法的许多实际问题,并逐渐用于多方面研究。如图像去噪模型^[20-22]通过提取残差信号或是消除噪声残余,对去噪后的信号进行再增强,迭代增强信噪比,提高图像重构性能。Romano 等^[23]提出增强-操作-减去(Strengthen-Operate-Subtract, SOS)算法,它是 Boosting 算法的改进,将去噪后的图像与原始输入相结合,迭代提高了信噪比,取得了很好的改进效果。Chen 等^[24]提出深度 Boosting 框架(DBF),以密集膨胀融合网络(DDFN)作为增强单元的体现,实现真实世界的图像去噪。该网络解决了由

于网络级联过长而导致训练过程中梯度消失的问题,同时提高了有限参数的效率。

利用 Boosting 算法进行降噪,主要是从被噪声污染的信号样本 $y(n)$ 中恢复出干净的信号 $x(n)$ 。假设: $y(n) = x(n) + v(n)$, 其中: $x(n)$ 为原始干净的心电信号, $v(n)$ 为噪声信号。降噪过程表示为:

$$\hat{x}(n) = S(y(n)) = S(x(n) + v(n)) \quad (2)$$

式中: $S(\cdot)$ 为降噪方法; $\hat{x}(n)$ 为降噪后输出的信号, 若降噪效果好, $\hat{x}(n)$ 为 $x(n)$ 的近似值。

实际上, $\hat{x}(n)$ 不等于 $x(n)$, 且两者之间的差为:

$$u(n) = \hat{x}(n) - x(n) = v(n)_r - x(n)_r \quad (3)$$

式中: $x(n)_r$ 为降噪过程中丢失的原始信号; $v(n)_r$ 为未去掉的噪声信号。

将 Boosting 算法应用于信号降噪的一个简单想法是, 迭代地从残差中提取未恢复信号 $x(n)_r$ 并将其重新添加到降噪后的信号 $\hat{x}(n)$ 中。经过 N 次迭代得到:

$$\hat{x}(n)^{(N+1)} = \hat{x}(n)^{(N)} + H(y(n) - \hat{x}(n)^{(N)}) \quad (4)$$

式中: $H(\cdot)$ 表示迭代过程; 设 $\hat{x}(n)^{(0)} = 0$ 。 $y(n) - \hat{x}(n)$ 不仅包含未恢复的信号 $x(n)_r$, 而且包含一部分噪声。

$$\begin{aligned} y(n) - \hat{x}(n) &= (x(n) + v(n)) - (x(n) + u(n)) = \\ &= (x(n) + v(n)) - (x(n) + v(n)_r - x(n)_r) = \\ &= x(n)_r + (v(n) - v(n)_r) \end{aligned} \quad (5)$$

通过迭代滤波降噪后信号 \hat{x} 去除剩余 u_r 的噪声。

为了进一步提高框架的性能, Romano 等^[23] 提出了一种新的 SOS 算法。在每个网络迭代中降噪目标是“增强的”信号 $y(n) + \hat{x}(n)^{(N)}$, 而不是 $y(n) - \hat{x}(n)^{(N)}$ 或降噪后的 $\hat{x}(n)^{(N)}$, 结果显示信噪比得到了提升。然而, 为了保证 SOS 算法的可迭代性, 它必须在每个步骤中“减去”相同的 $\hat{x}(n)^{(N)}$:

$$\hat{x}(n)^{(N+1)} = g(y(n) + \hat{x}(n)^{(N)}) - \hat{x}(n)^{(N)} \quad (6)$$

式中: $g(\cdot)$ 是对增强后的信号的降噪模型。为了清楚阐述 SOS 算法, 增强后的信号 $y(n) + \hat{x}(n)$ 表示为:

$$\begin{aligned} y(n) + \hat{x}(n) &= (x(n) + v(n)) + (x(n) + u(n)) = \\ &= 2x(n) + (v(n) + u(n)) \end{aligned} \quad (7)$$

1.3 FCN-Boosting 网络

本文实验中所提出的深度全卷积 Boosting 网络对 ECG 信号降噪算法正是受图像去噪中 Boosting 算法的启发, 用 FCN 网络作为增强单元, 迭代多个 FCN 网络。具体流程如图 2 所示, 当输入信号 $y(n) = x(n) + v(n)$ 进入第一个 FCN 网络结构后得到第一个输出信号即 $\hat{x}(n)^{(1)}$; 此时将第一个 FCN 网络的输出 $\hat{x}(n)^{(1)}$ 和原始输入 $y(n) = x(n) + v(n)$ 叠加后作为第二个 FCN 网络的输入信号进而得到第二个输出 $\hat{x}(n)^{(2)}$, 如此反复达到最后一层的 FCN 网络。每一个独立的 FCN 网络

预训练时得到的网络参数作为网络的初始参数, 利用网络的优化目标函数对网络参数权重进行优化, 在前向传播得到网络的整体损失函数后, 将损失从输出层后向传播至网络各层。堆叠的 FCN 网络根据输入输出的改变重新训练。




图2 FCN-Boosting 网络结构

受 SOS 算法式(5)启发, 在每一个迭代过程加入 FCN 网络:

$$\hat{x}(n)^{(N+1)} = F_{\theta}(y(n) + \hat{x}(n)^{(N)}) - \hat{x}(n)^{(N)} \quad (8)$$

式中: θ 为 FCN 的训练集; $F_{\theta}(\cdot)$ 为基于 FCN 网络的 Boosting 算法降噪算法。

由于可以在每个独立的增强单元学习不同的降噪模型, 式(8)中的约束不再需要。本文的 FCN-Boosting 网络框架可以在不受相同减法约束的情况下调整其参数, 这更好地针对每一个单元输入的样本变化调整参数。经过 N 个网络的输出为:

$$\hat{x}(n)^{(N)} = F_{\theta_N} \{ y(n) + F_{\theta_{N-1}} [y(n) + \dots + F_{\theta_1} (y(n))] \} \quad (9)$$

FCN-Boosting 网络中堆叠多个 FCN 网络, 由于 Boosting 算法使得每一个 FCN 网络子单元的网络参数会根据前一层输出和原始输入结合作为新的输入数据重新训练。由于网络中不进行归一化处理, 用 N 个网络输出 $\hat{x}(n)$ 的均值作为整体网络输出, 最终输出 $\hat{y}(n)$ 为:

$$\hat{y}(n)^{(N)} = \frac{\hat{x}(n)^{(N)}}{N} \quad (10)$$

本文实验经过多次实验测试采用 3 个 FCN 网络,根据上一个 FCN 网络输出,结合原始输入,分别做了 3 个训练集逐层训练框架模型。所以输出应为:

$$\hat{y}(n)^3 = \frac{1}{3}(F_{\theta_3}\{y(n) + F_{\theta_2}[y(n) + F_{\theta_1}(y(n))]\}) \quad (11)$$

2 实验与结果分析

2.1 实验数据

本文实验中的数据来自 MIT-BIH 心律失常数据库^[25]中干净的心电信号。该数据库中包括以 360 Hz 采样的 48 组动态 ECG 记录,其中每组记录的数据长度为 30 min。实验选择数据库中 10 个数据(103 号、105 号、111 号、116 号、122 号、205 号、213 号、219 号、223 号和 230 号)进行展示。

实验中所用噪声采集自 MIT-BIH 噪声压力测试数据库 (NSTDB)^[26],其中包含基线漂移 (Baseline Wander, BW)、肌电干扰 (Muscle Artifacts, MA) 和电极干扰 (Electrode Motion, EM)。实验中为更好地模拟出真实情况下采集的心电信号,将 BW、MA 和 EM 三类噪声按照 1.25 dB 和 5 dB 的信噪比叠加到干净的心电信号。

2.2 预处理

实验中先将所有信号预处理,含噪 ECG 信号由 3 种噪声数据按照输入信噪比为 1.25 dB 和 5 dB 叠加到心律失常数据库中的 48 组 ECG 信号上。网络中的输入数据样本是根据心电信号周期特征选择合适长度的心电向量。本文实验中从每条数据中截取 300 个片段,每个片段 1 024 个采样点作为样本输入,共 14 400 个片段,其中:80% 组成训练集,10% 组成验证集,10% 组成测试集。其中训练集和验证集的信噪比水平相同。

2.3 评价指标

本文采用信噪比 (Signal-to-Noise Ratio, SNR) 和均方根误差 (Root Mean Square Error, RMSE) 两个指标来评估降噪算法的性能。

如果 $x(n)$ 表示干净的 ECG 信号, $\hat{x}(n)$ 为去噪后的 ECG 信号, N 为心电信号长度,则 SNR 定义为:

$$S_{NR} = 10 \log \left(\frac{\sum_{i=1}^N (x(i))^2}{\sum_{i=1}^N (x(i) - \hat{x}(i))^2} \right) \quad (12)$$

信噪比表示干净心电信号与噪声之间的比值,单位为分贝 (dB),是评价信号质量的重要指标,信噪比越高说明信号降噪效果越好。

另外一项指标为均方根误差,均方根误差表示降噪后信号和原始真实信号的差值,均方根误差越低说明对于信号的滤波性能越好。RMSE 定义为:

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x(i) - \hat{x}(i))^2} \quad (13)$$

2.4 实验结果分析

为了验证本文所提出的降噪方法对特异性心电信号也有良好的降噪效果,实验结果以 MIT-BIH 数据库中 219 号 ECG 信号添加 1.25 dB 噪声的降噪结果进行展示。因为 219 号数据患者患有阵发性房颤,致使该数据信号中出现阵发性变异性心拍,且 RR 间期 (心电图上两个 R 波之间的间隔) 不规则。特异性心电信号对医生的正确诊断往往会起到至关重要的作用,但是很多心电信号降噪方法无法很好地对变异性心电信号进行降噪。同时本文提出的针对 BM、MA 和 EM 三种噪声的降噪方法与小波阈值法 (WT-Subband)、S 变换法 (S-Transform)、BP 神经网络法 (BPNN)、卷积自编码器 (CAENN) 降噪算法进行比较,选择数据库中 10 个数据(103 号、105 号、111 号、116 号、122 号、205 号、213 号、219 号、223 号和 230 号)进行展示。本文实验中降噪网络在训练学习信号特异性的特征时表现较好,可以在滤除噪声时,保留其病理信息。

2.4.1 基线漂移 (BW) 降噪结果

基线漂移 (BW) 是一种最常见的心电信号噪声,源于采集过程中人体的呼吸对心脏跳动的影响。图 3 所示为 219 号信号添加 1.25 dB 基线漂移 (BW) 的降噪结果。图 3 第一个波形图为干净信号,第二个波形图为加 1.25 dB 基线漂移后的信号,第三个波形图为经过降噪处理后的波形。由于基线漂移的频率发生在 0.05 ~ 2 Hz 之间,属于低频信号,可能对 ST 段和微小波 P 波或 T 波的波形形态产生影响。由图 3 中虚线框处的波形变化可知,基线漂移导致 ECG 信号波形的基线发生偏离,整体走势发生变化。第一个波形图中虚线框处 ST 段向下,而在基线漂移干扰后 ST 段发生明显变化,ST 段抬高。而 ST 段的变化会导致误诊为其他疾病。但经过本文提出的网络模型进行降噪处理后,与原始信号对比可知,降噪后的信号波形基线回归正常,且波形形态也与原始信号基本一致。




图 3 滤除 1.25 dB 基线漂移的降噪结果

表 2 所示为 10 个数据在滤除 1.25 dB 和 5 dB 基线漂移噪声时本文所提出的降噪方法与小波阈值法、S 变换法、BP 神经网络法和卷积自编码器降噪算法对比的平均结果。SNR 越大, RMSE 越小, 降噪后的信号越接近原始干净信号, 失真越小。由表 2 可得, 本文方法整体结果比其他四种的降噪效果更好, SNR 和 RMSE 有了明显改善, 表明了本文的降噪方法对 ECG 信号中基线漂移噪声滤除效果更好。

表 2 滤除基线漂移实验结果

噪声 /dB	参数	小波变换	S 变换	BPNN	CAENN	本文方法
1.25	SNR	1.520	11.386	11.250	14.853	17.331
	RMSE	0.838	0.273	0.143	0.095	0.059
5.00	SNR	5.307	12.672	12.007	15.832	18.858
	RESM	0.542	0.273	0.114	0.082	0.047

图 4、图 5 分别为 10 个数据使用 5 种降噪方法后滤除 1.25 dB 基线漂移噪声的平均 SNR 和 RMSE 得分。由图 4 和图 5 可知, 但用卷积自编码缺少对 122 号数据的降噪结果, 导致 SNR 和 RMSE 发生突变。但对于其他几个数据, 本文提出的降噪方法相比其他方法, SNR 和 RMSE 有了明显改善。例如 230 号数据在加入 1.25dB 的基线漂移后, 对比其他 4 种方法, 经本文的降噪方法处理后 SNR 提高明显。整体而言, 对叠加 1.25 dB 基线漂移的 ECG 信号经过 WT-Subband、S-Transform、BPNN 和 CAENN 方法降噪后的平均 SNR 分别为 1.520、11.386、11.250 和 14.853, 平均 RMSE 分别为 0.838、0.273、0.143 和 0.095; 经本文算法降噪后平均 SNR 达到 17.331, 平均 RMSE 值降为 0.059。特别是 219 号数据的实验结果中, 本文方法相比其他几种方法降噪后 SNR 提高较多。以上结果表明本文实验中降噪网络在训练学习信号特异性的特征时表现较好, 可以在滤除噪声时, 保留其病理信息。




图 4 滤除 1.25 dB 基线漂移的 SNR 结果




图 5 滤除 1.25 dB 基线漂移的 RMSE 结果

2.4.2 肌电干扰 (MA) 降噪结果

肌电干扰 (MA) 是由于肌肉收缩扩张运动造成的影响。图 6 所示为 219 号信号添加 1.25 dB 肌电干扰 (MA) 的降噪结果。肌电干扰噪声表现在信号中为不断变化的小毛刺, 属于高频信号。此类噪声会淹没心电信号的 P 波和 T 波, 造成原有形态模糊。由于肌电干扰与 ECG 信号频率存在重叠, 所以在滤除此类噪声时常会造成 ECG 信号中有用信息的丢失。由图 6 可得, 当 1.25 dB 肌电干扰噪声加入时, ECG 信号中低频成分信号波形形态被淹没, 造成低频信号的丢失。219 号 ECG 信号由于房颤的发生导致 P 波消失, 但当肌电噪声干扰时, 低频信号波形形态发生严重变化, 无法确定是否存在 P 波或是 T 波, 从而无法从含噪的信号中诊断出疾病。但经过本文方法降噪后, 不仅消除了肌电干扰噪声的影响, 而且部分 RR 周期很好保存了其原始信号中 P 波消失的病理信号特征。




图 6 滤除 1.25 dB 肌电干扰的降噪结果

表 3 所示为 10 个数据滤除 1.25 dB 和 5 dB 肌电干扰噪声时本文方法与小波阈值法、S 变换法、BP 神经网络法和卷积自编码器降噪算法对比的结果。图 7 和图 8 分别为对 10 个数据使用 5 种降噪方法后滤除 1.25 dB 肌电干扰噪声的平均 SNR 和 RMSE 得分。由图 7 和图 8 可知,本文方法相比其他方法,SNR 和 RMSE 有了明显改善,表明了本文的降噪方法对 ECG 信号中肌电干扰噪声滤除效果更好。可以看出,在叠加 1.25 dB 肌电干扰的 ECG 信号降噪中,本文降噪方法对 230 号数据的降噪效果最为突出。整体上,对叠加 1.25 dB 肌电干扰的 ECG 信号经过 WT-Subband、S-Transform、BPNN 和 CAENN 方法降噪后的平均 SNR 分别为 2.821、9.660、9.257 和 11.900,平均 RMSE 分别为 0.730、0.332、0.181 和 0.134;经本文算法降噪后平均 SNR 达到 13.869,平均 RMSE 值降为 0.079。

表 3 滤除肌电干扰实验结果

噪声 /dB	参数	小波变换	S 变换	BPNN	CAENN	本文方法
1.25	SNR	2.821	9.66	9.257	11.90	13.869
	RMSE	0.730	0.332	0.181	0.134	0.079
5.00	SNR	6.390	11.570	10.300	13.180	14.883
	RESM	0.484	0.267	0.157	0.116	0.069




图 7 滤除 1.25 dB 肌电干扰的 SNR 结果

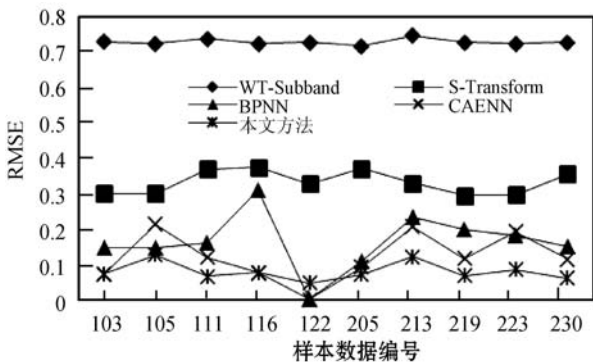


图 8 滤除 1.25 dB 肌电干扰的 RMSE 结果

2.4.3 电极干扰(EM)降噪结果

电极干扰(EM)是肌肤上粘贴的电极贴片产生的噪声。图 9 所示为 219 号信号添加 1.25 dB 电极干扰(EM)的降噪结果。它会随机产生阶跃干扰而改变 ECG 的幅值形态和基线位置。由图 9 可知,电极干扰噪声的幅值比肌电干扰噪声幅值小,而且电极干扰的加入改变了原始 ECG 信号中低频波的形态,但与原始信号中波形幅值非常相似,这对在滤除电极干扰噪声的同时又要将原始的低频波形态保留提出了一个挑战。尤其是 219 号信号本身有变异性心拍,电极干扰噪声加入后使得出现类似 P 波的波形形态,混淆了原始信号中变异性心拍的病理波形特征。但经过本文提出的降噪方法进行降噪处理后很好地滤除了电极干扰,对变异性心拍的波形特征进行了很好的保存。




图 9 滤除 1.25 dB 电极干扰的降噪结果

表 4 所示为 10 个数据滤除 1.25 dB 和 5 dB 电极干扰噪声时本文方法与小波阈值法、S 变换法、BP 神经网络法和卷积自编码器降噪方法对比 SNR 和 RMSE 的平均结果。通过与表 3 对比可以看出,本文方法在滤除电极干扰时同样具有明显优势。图 10、图 11 分别为对 10 个数据使用 5 种降噪方法后滤除 1.25 dB 电极干扰噪声的平均 SNR 和 RMSE 得分。122 号数据突变是由于卷积自编码器降噪方法缺少 122 号数据的 SNR 和 RMSE 实验结果。由图 10 和图 11 可知,本文方法相比其他 4 种方法,SNR 提高的同时 RMSE 均为最小值。这表明了本文的降噪方法对 ECG 信号中电极干扰噪声滤除效果更好,且能更好地保留信号的信息。经过 WT-Subband、S-Transform、BPNN 和 CAENN 方法降噪后的平均 SNR 分别为 1.641、7.013、9.340 和 14.227,平均 RMSE 分别为 0.824、0.447、0.171 和 0.097;经本文算法降噪后平均 SNR 达到 16.316,平均

RMSE 值降为 0.066。

表 4 滤除电极干扰实验结果

噪声 /dB	参数	小波变换	S 变换	BPNN	CAENN	本文方法
1.25	SNR	1.641	7.013	9.340	14.227	16.316
	RMSE	0.824	0.447	0.171	0.097	0.066
5.00	SNR	5.406	9.708	10.757	15.137	17.308
	RESM	0.535	0.329	0.148	0.084	0.058

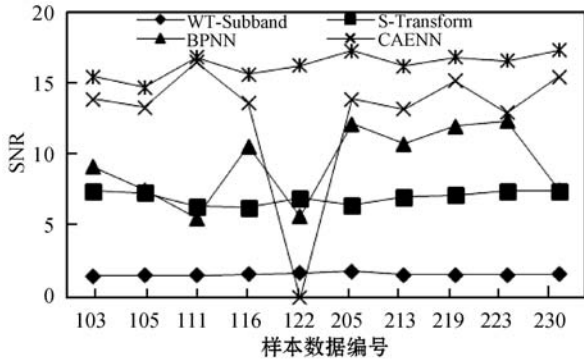


图 10 滤除 1.25 dB 电极干扰的 SNR 结果




图 11 滤除 1.25 dB 电极干扰的 RMSE 结果

2.5 结果分析

由图 3、图 6 和图 9 可知,本文方法可以在一定噪声水平影响的心电信号中重构出降噪的信号。且当噪声严重影响 ECG 信号的形态时,比如在 P 波和 T 波的消失和 QRS 复合物的扭曲,FCN-Boosting 网络模型很好维持了 QRS 复合物的形状。而使用高保真 QRS 复合物可以保存更多的临床相关信息。这表明该网络结构通过深度学习捕获心电信号的主要形态学特征,从有噪声的输入信号中提取原始信号。从表 2 - 表 4 可得,与小波阈值法、S 变换法、BP 神经网络法和卷积自编码器相比,采用基于深度 FCN-Boosting 网络模型的方法对三种噪声降噪,SNR 普遍高于其他 4 种降噪方法,而且 RMSE 值更小。

通过三种噪声结果对比,发现本文的降噪方法的滤除基线漂移的结果高于对肌电干扰和电极干扰的结

果,其中肌电干扰的 SNR 最小。是因为肌电干扰噪声在信号中为不断变化的小毛刺,此类噪声会淹没心电信号的 P 波和 T 波,造成原有形态模糊。由于肌电干扰与 ECG 信号频率存在重叠,所以在滤除此类噪声时常会造成 ECG 信号中有效信息的丢失。而 FCN-Boosting 网络模型利用 SOS 增强算法,通过多级输入原始的输入信号,增强 FCN 网络学习 ECG 的波形信息的能力,避免滤除噪声的过程中对有用 ECG 信息的丢失。本文方法对肌电干扰的滤除结果高于其他 4 种降噪方法,在提高降噪性能的同时,也尽可能多保留原始 ECG 信号的信息。

3 结 语

本文研究并提出一种基于深度全卷积提升网络降噪方法,将 Boosting 算法与 FCN 相结合用于滤除设备采集的 ECG 信号中的复杂噪声。无论是降噪后波形的变化上还是与小波阈值法、S 变换法、BP 神经网络法和卷积自动编码器的降噪结果定量对比,基于深度 FCN-Boosting 网络模型的降噪方法在降噪和临床细节保留方面优于其他 4 种方法,能够达到更好的降噪效果。同时利用 SOS 增强算法,通过多级输入原始的加噪 ECG 信号,堆叠多个 FCN 网络,从而增加网络的深度,增强 FCN 网络学习和捕获心电信号的主要波形形态特征,P 波和 T 波等特征波得到很好保留,避免滤除噪声的过程中对有用 ECG 信息的丢失。综上所述,本文所提出的降噪方法在心血管疾病的智能诊断的预处理阶段具有很好的应用价值和实际意义。

参 考 文 献

- [1] Cardiovascular diseases[EB/OL]. [2021-02-20]. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).
- [2] Reddy G U, Muralidhar M, Varadarajan S. ECG denoising using improved thresholding based on wavelet transforms [J]. International Journal of Computer Science and Network Security,2009,9(9):221 - 225.
- [3] Liu S, Li Y P, Hu X Y, et al. A novel thresholding method in removing noises of electrocardiogram based on wavelet transform[J]. Journal of Information & Computational Science,2013,10(15):5031 - 5041.
- [4] B'charri O E, Latif R, Elmansouri K, et al. ECG signal performance denoising assessment based on threshold tuning of dual-tree wavelet transform[J]. Biomedical Engineering On-

- line,2017,16(1):26.
- [5] Kabir M A, Shahnaz C. Denoising of ECG signals based on noise reduction algorithms in EMD and wavelet domains[J]. *Biomedical Signal Processing and Control*,2012,7(5):481-489.
- [6] Chandrakar C, Kowar M. Denoising ECG signals using adaptive filter algorithm[J]. *International Journal of Soft Computing and Engineering*,2012,2(1):120-123.
- [7] Rahman M Z U, Shaik R A, Reddy D R. Efficient and simplified adaptive noise cancelers for ECG sensor based remote health monitoring[J]. *IEEE Sensors Journal*,2012,22(3):566-573.
- [8] Moradi M H, Rad M A, Khezerloo R B. ECG signal enhancement using adaptive Kalman filter and signal averaging [J]. *International Journal of Cardiology*,2014,173(3):553-555.
- [9] Liu S, Li Y P, Hu X Y, et al. A novel thresholding method in removing noises of electrocardiogram based on wavelet transform[J]. *Journal of Information & Computational Science*,2014,10(15):5031-5041.
- [10] Xiong P, Wang H R, Liu M, et al. ECG signal enhancement based on improved denoising auto-encoder[J]. *Engineering Applications of Artificial Intelligence*,2016,52:194-202.
- [11] Liu M, Hao H Q, Xiong P, et al. Constructing a guided filter by exploiting the Butterworth filter for ECG signal enhancement[J]. *Journal of Medical & Biological Engineering*,2018,38:980-992.
- [12] Antczak K. Deep recurrent neural networks for ECG signal denoising[EB]. arXiv:1807.11551v1,2018.
- [13] Chiang H T, Hsieh Y, Fu S W, et al. Noise reduction in ECG signals using fully convolutional denoising autoencoders [J]. *IEEE Access*,2019,7:60806-60813.
- [14] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2015,39(4):640-651.
- [15] Fu S W, Tsao Y, Lu X G, et al. Raw waveform-based speech enhancement by fully convolutional networks[C]//Asia-Pacific Signal and Information Processing Association Annual Summit and Conference,2017:6-12.
- [16] Fu S W, Wang T W, Tsao Y, et al. End-to-end waveform utterance enhancement for direct evaluation metrics optimization by fully convolutional neural networks[J]. *IEEE Transactions on Audio Speech & Language Processing*,2018,26(9):1570-1584.
- [17] Taigman Y, Yang M, Ranzato M, et al. DeepFace: Closing the gap to human-level performance in face verification [C]//IEEE Conference on Computer Vision & Pattern Recognition,2014:1701-1708.
- [18] Schapire R E. The strength of weak learnability[J]. *Machine Learning*,1990,5(2):197-227.
- [19] Freund Y, Schapire R E. A decision-theoretic generalization of online learning and an application to boosting[J]. *Journal of Computer and System Sciences*,1997,55(1):119-139.
- [20] Charest M R, Elad M, Milanfar P. A general iterative regularization framework for image denoising[C]//Conference on Information Sciences & Systems,2006:452-457.
- [21] Milanfar P. A tour of modern image filtering: New insights and methods, both practical and theoretical[J]. *IEEE Signal Processing Magazine*,2013,30(1):106-128.
- [22] Talebi H, Zhu X, Milanfar P. How to SAIF-ly boost denoising performance[J]. *IEEE Transactions on Image Processing*,2013,22(4):1470-1485.
- [23] Romano Y, Elad M. Boosting of image denoising algorithms [J]. *SIAM Journal on Imaging Sciences*,2015,8(2):1187-1219.
- [24] Chen C, Xiong Z W, Tian X M, et al. Real-world image denoising with deep boosting[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2019,42(12):99.
- [25] Moody G B, Mark R G. The impact of the MIT-BIH arrhythmia database [J]. *IEEE Engineering Medicine & Biology Magazine*,2001,20(3):45-50.
- [26] Moody G B, Muldrow W K, Mark R G. Noise stress test for arrhythmia detectors [J]. *Computers in Cardiology*,1984,11:381-384.
- ~~~~~
- (上接第 20 页)**
- [11] Burns B, Beda J, Hightower K. Kubernetes: Up and running: dive into the future of infrastructure [M]. O'Reilly Media, 2019.
- [12] 徐奎. 基于微服务架构的大数据分析平台设计与实现 [D]. 济南:山东大学,2020:23-25.
- [13] Rad B B, Bhatti H J, Ahmadi M. An introduction to docker and analysis of its performance[J]. *International Journal of Computer Science and Network Security (IJCSNS)*,2017,17(3):228.
- [14] Red Hat. GlusterFS documentation[EB/OL]. [2021-02-05]. <https://docs.gluster.org/en/latest/>.
- [15] Lee C H, Li Z, Lu X, et al. Multi-Tenant machine learning platform based on Kubernetes [C]//2020 6th International Conference on Computing and Artificial Intelligence,2020:5-12.
- [16] 罗杨,沈晴霓,吴中海. 一种基于元模型的访问控制策略描述语言[J]. *软件学报*,2020,31(2):439-454.