

DOI:10.3969/j.issn.1005-202X.2020.08.022

医学信号处理与医学仪器

应用目标检测网络自动检测ECG信号所含噪声

崔焘¹, 周亚同¹, 张若男¹, 王浩², 李书华¹

1. 河北工业大学电子信息工程学院, 天津 300000; 2. 中国科学院计算技术研究所天津分所, 天津 300000

【摘要】现阶段的心电(ECG)信号去噪网络多通过滤波器滤除噪声,但是通常噪声滤除不彻底,从而造成ECG信号失真。基于此,本研究将目标检测网络用于ECG信号中的噪声检测,首先从MIT-BIT心律不齐数据库中筛选无噪声ECG记录,加入两种来自于MIT-BIH噪声压力测试数据库中的真实噪声,生成4个不同信噪比的含噪信号并构成训练及测试数据集。然后针对ECG信号的特殊性,对YOLOv3网络结构进行修改,设计YOLO-ECG目标检测网络,使用迁移学习策略训练目标检测网络。实验结果表明,本研究提出的网络在ECG信号中噪声检测时的F1值达0.955 8,具有良好的检测效果。

【关键词】心电信号;噪声检测;YOLOv3;目标检测网络

【中图分类号】R318;TN911.7

【文献标志码】A

【文章编号】1005-202X(2020)08-1053-09

Automatic detection of noises in ECG signals by target detection network

CUI Tao¹, ZHOU Yatong¹, ZHANG Ruonan¹, WANG Hao², LI Shuhua¹

1. School of Electronics and Information Engineering, Hebei University of Technology, Tianjin 300000, China; 2. Tianjin Branch of Institute of Computing Technology, Chinese Academy of Sciences, Tianjin 300000, China

Abstract: At present, denoising network removes the noises in electrocardiogram (ECG) signals through the filter, but usually the noise filtering is not complete, which causes ECG signals to be distorted. Herein target detection network is used for the detection of noise in ECG signals. Firstly, two kinds of real noises from MIT-BIH noise stress test database are added in the noise-free ECG records which are screened from MIT-BIT arrhythmia database, thereby generating noisy signals of 4 different signal-to-noise ratios and forming a training set and a test set. Secondly, according to the particularity of ECG signals, the YOLOv3 network structure is modified for developing a YOLO-ECG target detection network, and the migration learning strategy is used to train the network. The experimental results show that the F1 value of the proposed network in the detection of noises in ECG signals is up to 0.955 8, indicating that the proposed method has good performance in detecting noises in ECG signals.

Keywords: electrocardiogram signal; noise detection; YOLOv3; target detection network

前言

心血管疾病是致死率最高的疾病之一,每年可导致1 700万余人死亡,已成为世界的重大公共卫生问题^[1]。对心血管疾病患者进行及时、长效的心脏监控是对于疾病的预防和治疗行之有效的办法^[2]。心电(Electrocardiogram, ECG)检测通过检测体表上的心脏电生理信号来体现心脏节律中所包含的生理和病理信息,已成为无创性心血管疾病诊断的重要依

据。但ECG信号非常微弱,容易受到外界干扰,采集到的ECG信号难以被正确识别。世界上每年超过两千万例的ECG记录需要保存和存储,其中约有5%的ECG信号因混入噪声而导致心律失常信号不能被有效地辨识,从而给医生诊断带来困难^[3]。困难主要取决于两个因素:一方面,动态心电设备(Holter)在使用过程中更容易受到噪声影响,各种噪声对ECG信号的干扰不仅存在于医院ECG设备使用过程中,更广泛存在于缺少医护人员的场景下,由于患者缺乏专业指导,使设备受到更多噪声的影响,如运动导致的电极摩擦、肌电噪声等;另一方面,很多心血管疾病具有突发性,这就需要对心脏进行长时间监测,持续时间通常超过24小时^[4],整个过程会产生大量含有噪声的ECG信号,增加医生工作负担,降低对疾病的诊断效率。

【收稿日期】2020-03-11

【基金项目】国家自然科学基金(61801164);河北省自然科学基金(F2019202364);河北省在读研究生创新能力培养资助项目(CXZZSS2019031)

【作者简介】崔焘,硕士研究生,研究方向:智能信息处理,E-mail: 645111012@qq.com

【通信作者】周亚同,E-mail: zyt@hebut.edu.cn

1 国内外研究现状

现阶段对ECG信号中噪声的处理方法主要分为两种,一种是以经典数字滤波器和自适应滤波器为代表的传统滤波网络,另一种是以小波变换和神经网络为代表的现代滤波网络^[5]。

传统滤波网络是在ECG信号分析之前,使用不同频率范围的滤波器进行滤波。带通滤波器广泛应用于ECG信号去噪,常用频率范围为0.1~100.0 Hz^[6],广泛用于去除肌电干扰、基线漂移、运动伪迹及低频和低频噪声分量。除了带通滤波器,模拟低通滤波器也广泛应用于ECG信号去噪,现阶段所使用的模拟低通滤波器的截止频率主要为:11、90、30、35、50、100和70 Hz^[7]。一个好的低通滤波器可以滤除ECG信号中的高频噪声和工频干扰^[8]。模拟高通滤波器的主要目的是去除电极和人体接触引起的直流偏移。截止频率为0.5、1.0、2.2和5.0 Hz的高通滤波器也可用于去除基线漂移^[9]。模拟高通滤波器在使用过程中对信号衰减较小,但会影响信号的前5~10次谐波^[10]。

虽然很多固定参数的数字滤波器可以在一定程度上去除信号中的噪声,但使用固定参数的数字滤波器必须根据ECG信号的主频区间设置参数,由于ECG信号主频变化区间非常广泛,这给数字滤波器的使用带来困难。自适应滤波作为一种非线性滤波网络,利用参考信号来调整滤波系数,依靠参考信号和噪声的相关性来滤除干扰信号^[11]。自适应滤波器根据ECG信号主频率自适应变化,阻带可以更窄,保留更多有用信息。自适应滤波器可用于减少电力线干扰,利用最佳选择的噪声协方差方法设计自适应滤波器,从而去除噪声^[12-13]。

在现代滤波网络中,小波变换广泛应用于信号处理领域。很多学者将小波变换应用于ECG信号去噪,如小波阈值法去噪及小波模极大值去噪等,并取得良好的效果^[14]。小波变换利用不同的阈值处理方法处理小波系数,主要包括硬阈值网络和软阈值网络。软阈值网络处理的ECG信号相比硬阈值网络更平滑,并且可以更好地保持ECG信号的连续性;然而,软阈值网络会改变重建波形的幅度,尤其是QRS波群中R波的幅度^[15]。

近年来,随着人工智能领域的发展,很多学者使用神经网络,根据噪声信号的特征进行信号滤波。Chiang等^[16]提出一种基于全卷积网络的自动编码器,用于对基线漂移、肌肉伪迹和电极运动伪迹污染的ECG信号进行去噪;Xiong等^[17]提出一种堆叠压缩去噪自动编码

器网络,通过构建用于降噪的深度神经网络去除ECG信号中的噪声;Antczak^[18]提出一种基于递归神经网络(RNN)的深度神经网络去除ECG信号中的噪声,并取得良好的效果。然而,基于神经网络的方法在使用较少训练样本时,准确性下降严重。

现阶段对含噪ECG信号的处理方法主要是滤除噪声,但这类方法存在两个问题:(1)不能完全去除噪声。虽然一些噪声信号由于频率范围较为固定,如工频干扰和基线漂移等,很容易被完全去除,但对于电极运动伪迹等噪声,由于其频率分布范围广泛,很难被完全去除。(2)不可避免地造成ECG信号失真,在一定程度上给疾病诊断带来困难。

针对上述问题,本研究拟设计合适的YOLO-ECG目标检测网络用于ECG噪声检测。从MIT-BIT心律不齐数据库中筛选无噪声的ECG记录,加入两种来自于MIT-BIH噪声压力测试数据库中的真实噪声数据,制成4个不同信噪比的含噪ECG信号并作为训练及测试数据集,然后对YOLO-ECG网络进行训练和测试。实验结果表明YOLO-ECG网络在一定程度上可以筛选出所含噪声,减轻医生工作负担,提高疾病诊断的准确率。

2 训练及测试数据集构建

众多公开的ECG数据库可用于评估各类ECG信号处理网络的性能,其中最为著名的是波士顿贝斯以色列医院和麻省理工学院实验室公开的MIT-BIH数据库,本研究主要使用MIT-BIH心律失常数据库和MIT-BIH噪声压力测试数据库^[19-21]。

MIT-BIH心律失常数据库包括48条记录,每个文件中包含两个通道的ECG记录。这些ECG记录是1975年至1979年由波士顿贝斯以色列医院记录。MIT-BIH心律失常数据库包含47人,其中男性25名,女性22名;男性为32~89岁,女性为23~89岁(在所有记录中,从同一男性受试者中收集了两个记录)。每个部分的持续时间为半个小时,采样率为360 Hz。MIT-BIH噪声应力测试数据库由12条半小时ECG记录和3条半小时噪声ECG记录组成。ECG记录是通过在无噪声污染的ECG记录中加入不同大小信噪比的噪声来产生,无噪声污染的ECG记录来自于MIT-BIH心律失常数据库。

ECG记录通常受到不同类型的噪声污染,典型的噪声类型有:(1)工频干扰,一种频率为50或60 Hz的噪声,其带宽低于1 Hz;(2)基线漂移,一种低频(0.15~0.30 Hz)噪声,这种噪声由于患者呼吸产生,导致采集到的ECG信号发生基线移位;(3)电极接触噪

声,一种由于电极与皮肤间接触不良产生的瞬时噪声;(4)电极运动伪迹,一种由于运动导致皮肤和ECG采集设备电极之间的相对运动发生变化引起的噪声,持续时间较长;(5)肌电噪声,一种由心脏以外的其他肌肉收缩而产生的噪声;(6)电外科噪声,一种由于病人护理环境中其他医疗器械产生的噪声,

频率主要分布在 100 kHz 和 1 MHz。
MIT-BIH 噪声压力测试数据库中包括基线漂移(记录'bw')、肌电噪声(记录'ma')和电极运动伪迹(记录'em'),如图 1 所示。在这 3 种噪声中,基线漂移是很容易被数字滤波器去除的,故本研究主要对肌电噪声和电极运动伪迹进行处理。




图1 MIT-BIH噪声压力测试数据库中包含的噪声类型
Fig.1 Types of noises contained in MIT-BIH noise stress test database

MIT-BIH 噪声压力测试数据库给出了两组加入噪声的 ECG 记录,使用来自 MIT-BIH 心律失常数据库的两个干净记录(118 和 119),使用 WFDB 软件包添加来自记录'em'的噪声,每条记录的前 5 min 不做处理,随后每间隔 2 min 交替添加噪声,使数据变为含噪信号和不含噪声信号交替出现的形式^[36]。所生成数据的信噪比如表 1 所示。

表1 MIT-BIH噪声压力测试数据库ECG记录表
Tab.1 ECG records in MIT-BIH noise stress test database

记录	信噪比/dB	记录	信噪比/dB
118e24	24	119e24	24
118e18	18	119e18	18
118e12	12	119e12	12
118e06	6	119e06	6
118e00	0	119e00	0
118e_6	-6	119e_6	-6

表2 本文所生成的100号数据记录表
Tab.2 No.100 data records generated in the study

记录	信噪比/dB	记录	信噪比/dB	记录	信噪比/dB	记录	信噪比/dB
100em_6	-6	100em00	0	100em06	6	100em12	12
100ma_6	-6	100ma00	0	100ma06	6	100ma06	12

具为 LabelImg,标注原则为对医生诊断有干扰的标记为噪声,如图 3 所示。

本研究采取与 MIT-BIH 噪声压力测试数据库中相同的方式处理数据,因为 MIT-BIH 心律失常数据库中的 ECG 记录包含多种心律失常更加贴近于真实情况。在大多数 ECG 记录中,一个是 MLII 导联,另一个通常是 V1(偶尔是 V2 或 V5)导联,这种导联配置经常各类 ECG 采集设备中使用。
使用 WFDB 软件包对 MIT-BIH 心律失常数据库中的 100~109 共 10 条 ECG 记录进行处理,生成加入信噪比为-6、0、6 和 12 dB 的肌电噪声和电极运动伪迹,合成 80 条 ECG 记录,以 100 号记录为例,所生成的 100 号数据记录如表 2 所示。
合成 80 条 ECG 记录后,分割成包含 3 000 个采样点的 ECG 片段(约 8.3 s),并进行振幅归一化,以排除不同患者数据之间的差异。将得到的 ECG 信号可视化,以 106 号数据为例,如图 2 所示。
对可视化后的 ECG 片段进行筛选,筛选原则是样本中尽量保留噪声信号和正常 ECG 信号且二者特征均较为明显。对筛选后的样本进行标注,标注工
将标注后的数据和标注文件组成数据集。为保证数据分布的多样性,数据集包含 MLII、V1、V2、V5

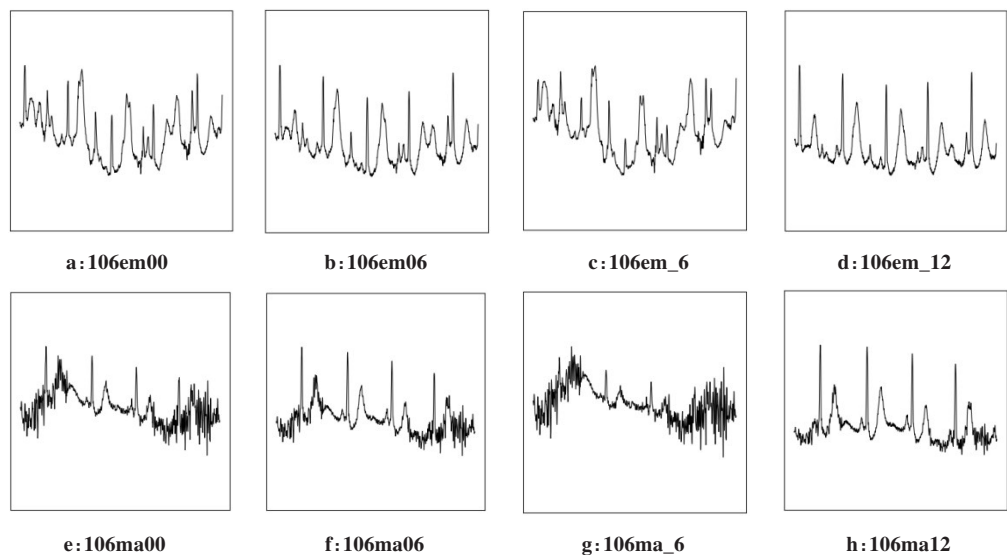


图2 106号数据可视化样例图
Fig.2 Sample visualization of data 106




图3 数据标注示例图
Fig.3 Examples of data annotation

这4个导联数据,训练集与验证集数据来自于102~109号ECG记录,训练集样本共9 167张,验证集样本共1 033张;比例约为9:1。测试集数据来自于101、102号两条ECG记录,测试集样本共1 121张,与训练集比例约为9:1。

3 ECG 信号噪声检测网络

3.1 YOLO 目标检测网络

YOLO 是 Redmon 等^[22]于2015年提出的基于单个神经网络的目标检测网络。YOLO 的核心思想是利用整张图作为网络的输入,直接在输出层回归边界框(bounding box)的位置及其所属的类别,能够实现端到端的目标检测和识别,其最大的优势就是检测速度快。在此基础上,诸多优化网络,如YOLOv2、YOLO9000、YOLOv3 相继被提出^[23-24]。相比YOLOv2, YOLOv3 使用残差网络和采用 Feature Pyramid Networks(FPN)架构,提高了对小目标的检出率。YOLOv3-Tiny 网络作为 YOLO 网络简化版本,广泛应用于移动设备中。

3.2 YOLO 目标检测网络结构

YOLOv3 和 YOLOv3-Tiny 在应用中取得了良好效果,但依然存在一些缺陷,YOLOv3 网络参数较多,对设备的计算能力要求高,YOLOv3-Tiny 网络在 YOLOv3 网络的基础上减少了网络参数,提高了检测速度,但准确率不够理想。针对上述问题,本研究对 YOLOv3 网络进行改进。

YOLOv3 网络结构如图4所示,由 DarkNet53 和 DetectionNet 两部分组成。DarkNet53 为特征提取网络,作用是从输入图像中提取特征,输出3个尺度不同的特征图到 DetectionNet 中。DetectionNet 为预测网络,借鉴 FPN,采用多尺度来对不同大小的目标进行检测,输出3个不同尺度的预测特征图对目标种类和位置进行预测。

在 YOLOv3 网络结构图中,ConvBlock 的网络结构见图5a,由卷积层(Conv)、批量归一化层(BN)和激活函数(LeakReLU)组成。ResLink 的网络结构见图5b, ConvBlock 结构采用残差网络的形式连接。ConvSet 的网络结构见图5c,由5个 ConvBlock 模块连接,Concatenate 表示融合层,UpSamp 表示上采样层。

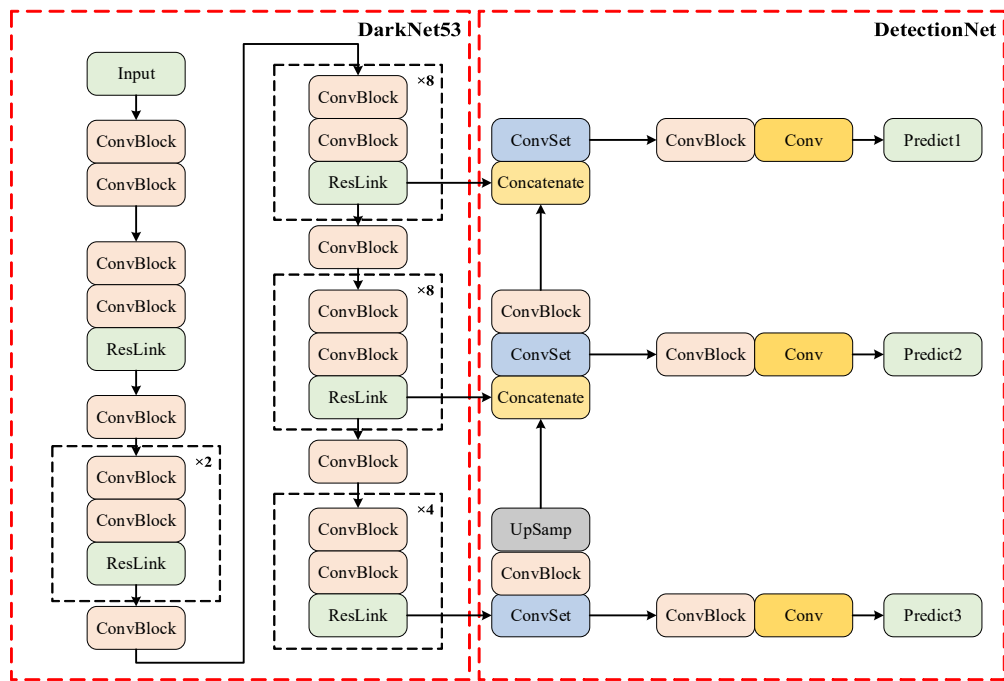


图4 YOLOv3网络结构图
Fig.4 YOLOv3 network structure




图5 YOLOv3中部分网络模块示意图
Fig.5 Structure of some network modules in YOLOv3

3.3 YOLO-ECG 目标检测网络结构

针对YOLOv3网络中存在的问题,本研究借鉴移动设备中广泛使用的MobileNet网络,提出YOLO-ECG目标检测网络^[25]。MobileNet网络是建立在深度可分割卷积上,把标准的卷积分解成一个深度卷

积和一个1×1卷积(Pointwise Convolution),减少计算量和网络大小,如图6所示。图6a为标准卷积模块,由Conv、BN和激活函数(ReLU)组成;图6b为深度卷积模块,由深度可分离卷积层(DepthConv)、BN、ReLU、Conv、ReLU依次连接组成。




图6 两种不同卷积结构示意图
Fig.6 Structures of two different convolution structures

YOLO-ECG目标检测网络的结构如图7所示。由于YOLOv3网络中的网络参数集中于DarkNet53特征提取网络中,本研究使用MobileNet网络中的深度可分离卷积结构组成ECG-MoNet网络,由12个卷积层和11个深度可分离卷积层组成。

4 ECG 信号所含噪声检测实验

4.1 检测评价指标

ECG信号噪声自动检测网络可以使用模式识别领域常用的评价指标进行评估。对二分类问题而言,TP是正样本的正确预测样本数,TN是负样本的正确预测样本数,FN是正样本的错误预测样本数,FP是负样本的错误预测样本数。

精准率(Precision):表示符合要求的正确识别目

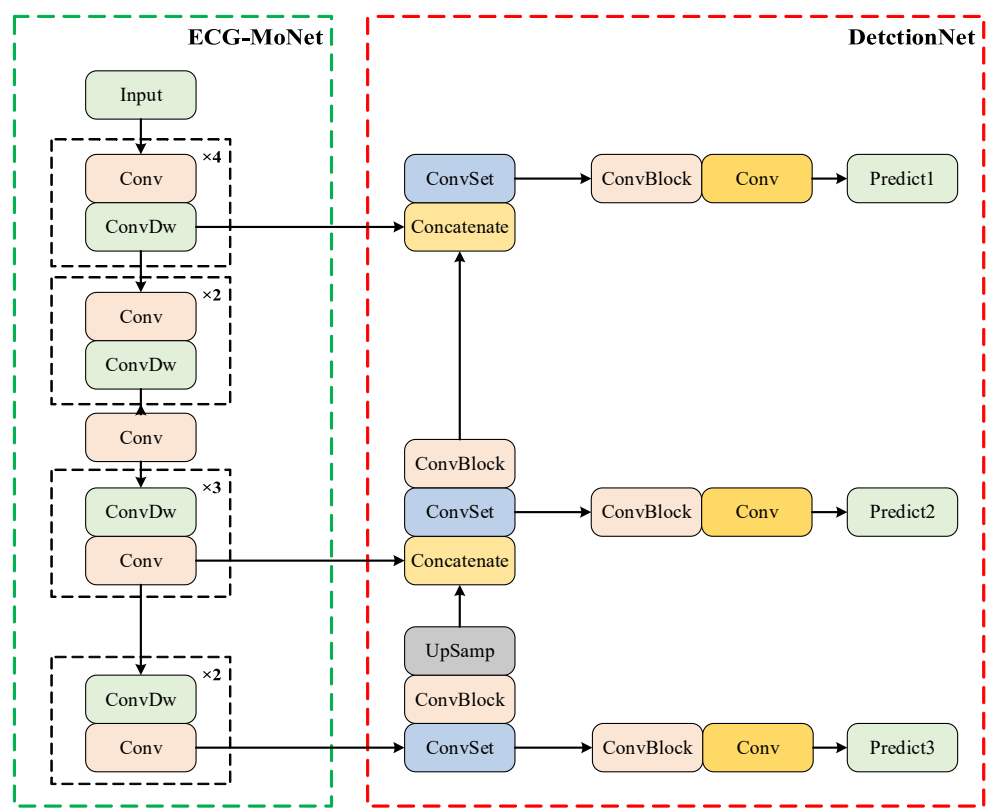


图7 YOLO-ECG目标检测网络结构图
Fig.7 Structure of YOLO-ECG object detection network

标的个数占总识别出目标个数的百分数。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{1}$$

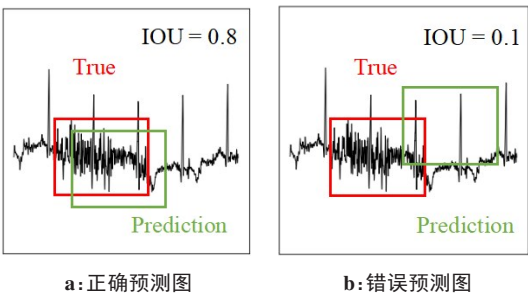
召回率(Recall):表示符合要求正确识别目标的个数占测试集中物体的总个数的百分数。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{2}$$

F1 指标(F1):表示精准率和召回率的调和平均数。

$$\text{F1} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{3}$$

在本研究中,通过 Intersection Over Union(IOU)值衡量图片的预测情况,IOU值相当于两个区域交集得到的面积除以两个区域并集得到的面积。将 IOU 值>0.5 的 ECG 片段判定为预测正确,IOU 值≤0.5 的 ECG 片段判定为预测错误,如图 8 所示。



a:正确预测图 b:错误预测图
图8 不同ECG片段的预测情况
Fig.8 Predictions for different ECG segments

4.2 实验设备与设置

本研究中所有实验的硬件配置如下:GPU 为 NVIDIA GeForce GTX 1080Ti Founders Edition,CPU 为 Intel 酷睿 i7 7700K,软件配置为 Python 3.5.2、Keras 2.1.5、Tensorflow 1.6.0。

实验中 epoch 为 100,初始学习率为 0.01, batch size 为 64,使用 Keras 中的 LearningRateScheduler 和 ReduceLROnPlateau 函数,学习率随着 epoch 的增加而减小,当评价指标不再提升时,减少学习率。

4.3 训练过程

对 YOLOv3、YOLOv3-Tiny 和 YOLO-ECG 这 3 种网络使用相同实验设备和数据集进行训练,结合迁移学习策略,darknet53 和 ECG-MoNet 网络用于 COCO 数据集进行预训练,再用于本研究的目标检测网络中的训练过程。前 30 个 epoch 过程中,冻结网络第 1 层至倒数第 4 层,只训练后 3 层,30~100 个 epoch 过程中,解冻所有层,继续训练。训练过程的损失曲线如图 9 所示。YOLOv3-Tiny 的损失曲线收敛最快, YOLO-ECG 次之,YOLOv3 最慢。验证集损失函数曲线所呈现的规律与训练集类似。

4.4 不同噪声水平检测效果分析

选择含肌电噪声为 6、0、-6 dB 的 ECG 记录图片各 200 张,组成正样本;无噪声 ECG 记录图片 200 张,组成负样本。使用 YOLO-ECG 进行测试,实验结果如表 3 所




图9 3种网络的损失曲线
Fig.9 Loss function curves of 3 networks

示。以F1值作为衡量标准,含肌电噪声为6 dB的ECG记录图片的F1值为0.918 1,-6 dB为0.970 1,0 dB为0.958 0。实验证明YOLO-ECG网络对于噪声水平越高的ECG记录图片,检测效果越好。检测效果如图10所示。

表3 不同噪声水平检测效果分析表
Tab.3 Detection results at different noise levels

肌电噪声/dB	TP	FP	TN	FN	准确率	召回率	F1值
-6	195	5	193	7	0.975 0	0.965 3	0.970 1
0	194	6	189	11	0.970 0	0.946 3	0.958 0
6	185	15	182	18	0.925 0	0.911 3	0.918 1




图10 不同噪声水平检测效果图
Fig.10 Diagrams of detection results at different noise levels

4.5 不同噪声类型检测效果分析

选择信噪比为0 dB的含肌电噪声(ma)和电极运动伪迹(em)的ECG记录图片各200张,组成正样本;无噪声的ECG记录图片200张,组成负样本。使用YOLO-ECG进行测试,实验结果如表4所示。以F1值作为衡量标准,对于含肌电噪声的ECG记录图片,F1值为0.977 5;对于含电极运动伪迹的ECG记录图片,F1值为0.915 6。实验结果表明YOLO-ECG网络对于肌电噪声的检测准确率要高于电极运动伪迹。检测效果例图如图11所示。

4.6 不同网络性能评估与分析

YOLOv3、YOLOv3-Tiny和YOLO-ECG这3种网络完成训练之后,对测试集共1 121张图片,810张包含噪声的正样本、311张不含噪声的负样本,进行测试,结果如表5所示,YOLOv3的F1值为0.964 6,YOLO-ECG为0.955 8,YOLOv3-Tiny为0.914 3。在同样的实验条件下,训练之后生成的网络大小间接体现了网络的参数量,YOLOv3生成网络的大小为235 MB、YOLOv3-Tiny为33.15 MB、YOLO-ECG为92.5 MB。

表4 不同噪声类型检测效果分析表
Tab.4 Detection results for different noise types

噪声	TP	FP	TN	FN	准确率	召回率	F1值
ma	196	4	195	5	0.980 0	0.975 1	0.977 5
em	179	21	188	12	0.895 0	0.937 1	0.915 6




图 11 不同噪声类型检测效果图
Fig.11 Diagrams of detection results for different noise types

表5 不同网络性能评估表
Tab.5 Evaluation of detection performances of different algorithms

网络	TP	FP	TN	FN	准确率	召回率	F1值
YOLOv3	789	21	274	37	0.974 1	0.955 2	0.964 6
YOLOv3-Tiny	753	57	227	84	0.929 6	0.899 6	0.914 3
YOLO-ECG	784	26	264	46	0.967 9	0.944 6	0.955 8

综上所述,本研究所提出的YOLO-ECG网络F1值明显大于YOLOv3-Tiny网络,略低于YOLOv3网络,但生成网络的大小远小于YOLOv3网络网络,网络越小,越适合在移动设备中使用。综合网络检测精度和网络大小,YOLO-ECG网络在移动设备使用中优势更加明显。

5 结 论

本研究采用目标检测网络检测ECG记录中的噪声,针对Holter中ECG信号易受噪声干扰的问题,提出YOLO-ECG目标检测网络。从MIT-BIT心律不齐数据库中筛选无噪声的ECG记录,加入两种来自于MIT-BIH噪声压力测试数据库中的真实噪声数据,制作出4个不同信噪比等级的含噪信号组成数据集,使用YOLO-ECG网络进行训练、验证和测试,对不同噪声信噪比、不同噪声类型和不同网络进行评估,本研究所提出的网络准确率高出移动端广泛使用的YOLOv3-Tiny网络,所训练出的网络大小仅为YOLOv3网络的39%,能够更好的应用于Holter中。

虽然本文网络取得了良好的效果,但还是存在

一些问题:(1)本研究的网络仅对MIT-BIH噪声压力测试数据库中涉及的肌电噪声和电极运动伪迹进行分析,还需要对更多的噪声进行训练和测试,增强网络的鲁棒性和泛化能力;(2)在网络测试过程中,在错误检测的图片中,多数是因为心律失常波形和特殊的心搏波形,对检测噪声造成影响,接下来的工作需要在训练过程中增加更多的心律失常波形和特殊的心搏波形进行训练;(3)本研究的主要目的是准确检测出噪声,并没有对检测出的噪声进行去除。下一步是根据噪声特点有效去除。

【参考文献】

[1] BENJAMIN E J, VIRANI S S, CALLAWAY C W, et al. Heart disease and stroke statistics—2018 update: a report from the American Heart Association[J]. Circulation, 2018, 137(12): e493.

[2] 张金玲, 崔彤, 刘为斌. 基于自适应时间窗函数优化的心电特征波形识别[J]. 北京邮电大学学报, 2018, 23: 1-7.

ZHANG J L, CUI T, LIU W B. ECG characteristic waveform recognition based on optimization of adaptive time window function [J]. Journal of Beijing University of Posts and Telecommunications, 2018, 23: 1-7.

[3] 郭继鸿. 中国心脏性猝死现状与防治[J]. 中国循环杂志, 2013, 28

- (5): 323-326.
HUO J H. Status and prevention of sudden cardiac death in China[J]. Chinese Circulation Journal, 2013, 28(5): 323-326.
- [4] 杜欣, 曾伟杰, 李承炜, 等. 基于移动医疗的孕产妇健康监护系统[J]. 生物医学工程学杂志, 2016, 33(1): 2-7.
DU X, ZENG W J, LI C W, et al. A maternal health care system based on mobile health care[J]. Journal of Biomedical Engineering, 2016, 33(1): 2-7.
- [5] 张清丽, 苏士美, 王猛. 基于改进小波变换的QRS特征提取算法研究[J]. 郑州大学学报(理学版), 2017, 49(4): 100-103.
ZHANG Q L, SU S M, WANG M. QRS feature extraction algorithm based on wavelet transform[J]. Journal of Zhengzhou University (Natural Science Edition), 2017, 49(4): 100-103.
- [6] CHUI K T, TSANG K F, CHI H R, et al. An accurate ECG-based transportation safety drowsiness detection scheme[J]. IEEE Trans Ind Inform, 2016, 12(4): 1438-1452.
- [7] LI Q, RAJAGOPALAN C, CLIFFORD G D. Ventricular fibrillation and tachycardia classification using a machine learning approach[J]. IEEE Trans Biomed Eng, 2013, 61(6): 1607-1613.
- [8] ZHANG Z, DONG J, LUO X, et al. Heartbeat classification using disease-specific feature selection[J]. Comput Biol Med, 2014, 46: 79-89.
- [9] PADHY S, DANDAPAT S. Third-order tensor based analysis of multilead ECG for classification of myocardial infarction[J]. Biomed Signal Proces Control, 2017, 31: 71-78.
- [10] CHUI K T, TSANG K F, CHI H R, et al. An accurate ECG-based transportation safety drowsiness detection scheme[J]. IEEE Trans Ind Inform, 2016, 12(4): 1438-1452.
- [11] SHEMI P M, SHAREENA E M. Analysis of ECG signal denoising using discrete wavelet transform[C]. the 2nd IEEE International Conference on Engineering and Technology, 2016: 713-718.
- [12] SU L, ZHAO G. De-noising of ECG signal using translation-invariant wavelet de-noising method with improved thresholding[C]. 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference. IEEE, 2006: 5946-5949.
- [13] 陈耿铎, 曾有灵, 李喆. 自适应双阈值心电信号检测算法研究[J]. 暨南大学学报(自然科学与医学版), 2018, 39(3): 262-268.
CHEN G Z, ZENG Y L, LI Z. Research of self-adaptive double threshold method for ECG signal detection[J]. Journal of Jinan University (Natural Science & Medicine Edition) 2018, 39(3): 262-268.
- [14] MARIA C A, MARIUS R N. Study of ECG signal processing using wavelet transforms[C]. International Symposium on Advanced Topics in Electrical Engineering, 2015: 27-30.
- [15] EL B'CHARRI O, LATIF R, ELMANSOURI K, et al. ECG signal performance de-noising assessment based on threshold tuning of dual-tree wavelet transform[J]. Biomed Eng Online, 2017, 16(1): 26.
- [16] CHIANG H T, HSIEH Y Y, FU S W, et al. Noise reduction in ECG signals using fully convolutional denoising autoencoders[J]. IEEE Access, 2019, 7: 60806-60813.
- [17] XIONG P, WANG H, LIU M, et al. A stacked contractive denoising auto-encoder for ECG signal denoising[J]. Physiol Meas, 2016, 37 (12): 2214.
- [18] ANTCZAK K. Deep recurrent neural networks for ECG signal denoising[J]. arXiv Preprint. arXiv: 1807.11551, 2018.
- [19] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database[J]. IEEE Eng Med Biol, 2001, 20(3): 45-50.
- [20] MOODY G B, MULDEROW W, MARK R G. A noise stress test for arrhythmia detectors[J]. Comput Cardiol, 1984, 11(3): 381-384.
- [21] GOLDBERGER A L, AMARAL L A, GLASS L, et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23): e215-e220.
- [22] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.
- [23] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017.
- [24] REDMON J, FARHADI A. Yolov3: an incremental improvement[J]. arXiv Preprint. arXiv: 1804.02767, 2018.
- [25] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[J]. arXiv Preprint. arXiv: 1704.04861, 2017.

(编辑:谭斯允)