

基于改进U-Net模型的心电波形分割

徐柏林, 蔡文杰, 杨明菲, 张标

上海理工大学健康科学与工程学院, 上海 200093

【摘要】基于U-Net框架提出一种新的算法用于心电波形的分割。该方法将一定长度的心电信号作为输入,输出P波、QRS波和T波的分割图像,同时定位各个特征波的起始点和终止点,创新性地提出了多通道空洞卷积加上注意力机制的模型结构,并设计了一种数据增强公式用于增加数据的多样性。本研究提出的方法在LUDB上进行训练测试,在QTDB上验证算法的泛化能力。实验结果表明,所提的算法在LUDB的平均灵敏度、平均阳性预测率、平均F1分数分别为99.41%、98.90%、98.75%;在QTDB的平均灵敏度、平均阳性预测率、平均F1分数分别为98.65%、98.43%、98.23%,这说明本文算法效果更好,并具有优异的泛化性能。

【关键词】心电图;改进U-Net模型;算法验证;分割

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2022)10-1274-06

ECG waveform segmentation based on improved U-Net model

XU Bolin, CAI Wenjie, YANG Mingfei, ZHANG Biao

School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract: A new algorithm based on U-Net framework is proposed for ECG waveform segmentation, taking the ECG signal of fixed length as the input, and then outputting the images of P wave, QRS wave and T wave. The method can locate the starting and ending points of each characteristic wave. A novel model structure of multi-channel dilated convolution with attention mechanism is put forward, and a data enhancement formula is designed to increase the diversity of data. The proposed method is trained and tested on LUDB, and the generalization ability of the algorithm is verified on QTDB. The experimental results show that the average sensitivity, average positive prediction rate, and average F1 score of the proposed algorithm are 99.41%, 98.90%, 98.75% on LUDB, and 98.65%, 98.43%, 98.23% on QTDB, indicating that the proposed algorithm performs better and has excellent generalization performance.

Keywords: electrocardiogram; improved U-Net model; algorithm verification; segmentation

前言

我国心血管疾病死亡率逐年上升,并呈现年轻化趋势^[1]。随着城市化和生活方式的改变,可以预见未来患病人数不会下降,因此,对于心血管疾病的预防和检测值得重视^[2]。心电图作为对心脏健康状况进行评估的重要手段,主要包括P波、QRS波和T波,其中各波形都包含着重要信息,心电波形分割对于自动诊断分析具有重要意义^[3]。然而,心电信号的精确分割存在一些困难。例如,P波的振幅很小,甚至因为噪声干

扰无法识别或是P波缺失;T波可能存在双向的情况,这就导致很难确定T波的起点和终点^[4]。因此,亟需提出一种可以精确分割心电波形的算法。传统心电波形分割算法一般先在心电信号中定位R波的位置,然后检测QRS波的起止点,然后再定位P波和T波的起止位置。Aspuru等^[5]使用线性回归来分割心电信号,首先检测心电图的R峰,然后再分离信号,检测P、Q、S和T峰值。该方法对Q点的检验灵敏度为97.5%,对其他心电峰值的检测灵敏度为100%;但是该方法泛化能力没有经受检验,单一的性能指标也不能说明算法的优异。目前主流的用于心电波形分割的传统算法是小波变换,Li等^[6]使用小波变换来检测心电信号的各波形特征点。借助小波变换的多尺度功能将QRS复合波与其他波分离,QRS的识别准确率在MITDB(MIT-BIH Arrhythmia Database)上达到99.8%。虽然很多传统算法都可以用于心电波形分割研究,但大部分都是

【收稿日期】2022-05-17

【基金项目】国家自然科学基金(31830042)

【作者简介】徐柏林,硕士研究生,研究方向:医学人工智能,E-mail: 1649800018@qq.com

【通信作者】蔡文杰,副教授,研究方向:医学人工智能,E-mail: wj-cai@usst.edu.cn

针对单独的特征波,如QRS波,将所有心电波形进行整体分割的研究相对较少。近年来,使用深度学习的方法识别心电各波形逐渐成为研究热点。Nurmaini等^[7]提出使用双向长短期记忆分类器来对心电图波形进行分割。将心电数据按照心拍进行切割,以P波的起始点作为切割的起点,该方法的平均敏感度达到98.82%,F1分数为98.84%;但该方法存在一个缺陷,从P波的起始点开始切割,以固定心电片段作为训练集投入模型训练,势必会导致模型对P波的识别准确率虚高,缺乏泛化性能。

针对以上算法的不足,本研究提出的基于U-Net模型改进的算法不仅可以检出心电整体波形的起止点,且检测效果更好;在跨数据库实验中也表现较好的泛化性能。

1 方法

1.1 数据集

本研究选取心电公开数据集 Lobachevsky University Database(LUDB),这是一个常用于心电波形分割的开放数据库^[8]。其包含200份来自不同受试者12导联心电图记录,每条记录的采样频率为500 Hz,采样时长10 s;该数据库的P波、QRS波和T波的边界和峰值都由专家手工标注。使用QTDB(QT Database)来验证本文算法的泛化能力^[9]。其包括105条两导联心电图记录,采样频率为250 Hz,采样时长15 min;该数据库的每条记录的P波、QRS波和T波起止位置和峰值同样由专家标注。本研究选取了其中部分记录作为算法验证数据。

1.2 预处理

LUDB中的专家标记从第二或第三个心拍开始到倒数第二个心拍结束。如图1所示,红色为无波,黄色为QRS波,绿色为P波,蓝色为T波。




图1 LUDB标注信息示意图
Figure 1 Schematic diagram of LUDB labeling information

针对LUDB的特点,本研究在构建数据集时截取了从第3秒(第1000个采样点)开始到第8秒(第4000个采样点)为止的心电片段,共3000个采样点。这样截取可以保证选取的信号均有专家标记。将LUDB的200份12导联分别当作独立的记录来处理,得到2400条记录。然而,在根据标注构建数据集过程中发现,LUDB有30条记录存在漏标情况,舍弃这些记录,最后得到2370条记录的数据集。

针对QTDB的处理,首先对记录重采样到500 Hz。考虑到该数据库中有大量记录缺乏专家标注,本研究选取几条完整标记的记录,每3000个采样点作为一条心电片段,共得到800条数据作为验证集。

原始心电信号中含有大量噪声信号,如肌电噪声、基线漂移、工频干扰等,噪声信号的存在影响了模型的性能^[10]。本研究采用小波变换去除噪声干扰,在LUDB和QTDB上使用db3的小波基对心电信号做8尺度分解^[11]。图2为原始波形和去噪后的波形。

1.3 数据增强

LUDB共有2370条记录,为了增加数据的多样




图2 小波变换前后心电波形
Figure 2 ECG waveforms before and after wavelet transform

性,提升模型的鲁棒性以及泛化能力,本研究对数据集进行数据增强^[12]。首先,针对每条记录的3000个采样点,在前600个点中随机选择起点,投入模型训练的记录长度为2400,这样在一定程度上可以保证数据的多样性。其次,本研究构建了一个数据生成器,在训练过程中对心电记录做随机增大或缩放,添加基线漂移和进行平移操作^[13]。其数学表达式定义如下:

$$\text{Signal} = \frac{1}{10} \alpha \text{Signal} + \frac{1}{50} \beta \sin\left(\frac{1}{\gamma} n\pi + \frac{\pi}{10} \delta\right) + \frac{1}{100} \varepsilon(1)$$

式中第一步对数据进行随机放缩操作,α取值为[8,13];第二步将放缩后的数据添加基线漂移,β、γ、δ的取值范围是[0, 30)、[400, 900)、[0, 10);最后做平移操作,ε取值[-20, 21)。对于每一条投入模型训练的记录,都采用这3个步骤和随机选择起点来丰富数据的多样性,增强模型的鲁棒性。

1.4 模型

本研究提出的模型是基于U-Net模型进行改进的。U-Net框架起源于全卷积网络,常用于医学图像分割^[14]。该模型是一个经典的编码-解码器结构,左边部分用来特征提取,右边部分进行上采样和特征融合。本研究以U-Net为基础,针对一维的心电数据对模型进行改进,模型图如图3所示。




图3 改进U-Net模型
Figure 3 Improved U-Net model

原有的U-Net模型左边部分的单通道下采样结构换成了3通道,并将普通卷积改成了空洞卷积。因为心电信号是一种基于幅度的低频数据,使用小的感受野很难包含心电信号幅度较大范围的变化^[15];另外心拍本身是一段短时一维信号,不能过分关注整体而忽视局部信息。本研究提出的模型左侧部分的3个通道均会对输入信号进行卷积、批量标准化(BN)及激活(ReLU)操作^[16];在模型中使用空洞卷积代替普通卷积,空洞卷积进行卷积操作时会跳过一些像素点进行卷积,在使用相同大小的卷积核情况下,可以获得更大的感受野;同时,给各个通道设计不同的空洞率,输出神经元能获得不同的感受野^[17]。各通道空洞模块结构参数如表1所示。这种多通道加空洞卷积的设计更适合提取类似心电信号的一维数据的特征信息。每个通道的每一层经过上述操作后,将结果按照通道维度进行拼接,该结果用于与右侧部分上采样结果特征融合。为了将3个通道所提取的特征信息整合到一起,本研究使用注意力机制(SENNet)对特征重要性进行调整,即通过学习的方式

自动获取每个特征通道的重要程度,按照这个重要程度去提升有用的特征权重并抑制作用不大的特征权重,对整个网络进行重新调整^[18]。

表1 空洞模块结构参数
Table 1 Structural parameters of dilated convolution

卷积层	卷积核尺寸	空洞率		
		通道1	通道2	通道3
卷积层 1,2	11	1	2	4
卷积层 3,4	9	1	2	4
卷积层 5,6	7	1	4	8
卷积层 7,8	7	1	8	16
卷积层 9,10	5	1	8	32

输入长度为2400个采样点的预处理心电信号,左边部分的多个通道的编码器进行特征提取工作,每次经过池化层尺度减半。右边解码器部分使用上采样的方法恢复尺寸,然后将左边部分的多通道合并结果与上采样特征进行特征融合。最后,模型得到的输出结果为2400×4,蕴含着属于P波、QRS波、T波的像素级分割信息,使用Softmax激活函数可以得到每个波形的预测结果^[19]。

2 实验结果

2.1 实验配置与性能指标

模型训练使用的优化器是Adagrad,损失函数为交叉熵损失函数,初始学习率设置为0.015,学习率衰减率为0.001,随着模型训练,学习率可以动态地变化^[20]。Batchsize为256,模型训练次数设置为300个epoch。本研究采用pycharm作为开发环境和pytorch框架^[21]。在Ubuntu环境上进行训练,显卡为GA106[GeForce RTX 3060 Lite Hash Rate] 12 G。图4显示了模型在训练阶段的损失曲线。

根据医疗器械协会(Association for Medical Instrumentation)规定,当算法得到的起始点和终止点与专家标记的绝对值不超过150 ms,则可以判定预测是正确的^[22]。由此,可以定义一些性能指标来对算法的质量进行评定。

本实验采用敏感度(SE)、阳性预测率(PPV)、F1分数作为性能指标。SE可以表达算法预测特征点的能力,PPV表示检测出的特征点是正确的比例,F1分数是二者的综合指标^[23]。性能指标各公式如下:

$$SE = \frac{TP}{TP + FN} \tag{2}$$

$$PPV = \frac{TP}{TP + FP} \tag{3}$$




图4 模型的训练和验证损失曲线

Figure 4 Training and validation loss curves of the model

$$F1 = 2 \times \frac{SE \times PPV}{SE + PPV}$$

(4)

其中,TP代表提出的算法预测的特征点与专家标记点的误差的绝对值不超过 150 ms;FP代表算法预测特征点周围 150 ms 没有专家标记的点;FN表示在专家标记点 150 ms 范围内无法找到算法预测的特征点。

2.2 结果与讨论

对于U-Net模型的改进方向,本研究采取对原模型加入空洞卷积模块、增加 SENet 模块以及改变通道个数等方式,分别对每一种改进方向都进行训练和 5 折交叉验证。各个模型在测试集上的表现如表 2 所示。提出的算法在测试集上的分割结果如图 5 所示。

DC+U-Net (Dilated Convolution, U-Net)模型是在原 U-Net 模型的基础上将单通道下采样改为 3 通道下采样,普通卷积模块变成空洞卷积模块,但未加入 SENet。DC+U-Net 模型平均性能在 PPV 和 F1 上

表 2 不同模型的心电分割结果(LUDB)

Table 2 ECG segmentation results of different models (LUDB)

模型		P 波	QRS 波	T 波	平均值
U-Net	SE	0.985 5	0.995 0	0.994 7	0.991 7
	PPV	0.950 9	0.989 2	0.990 4	0.976 8
	F1	0.944 4	0.990 8	0.991 0	0.975 4
DC+U-Net	SE	0.989 8	0.994 8	0.994 1	0.992 9
	PPV	0.956 5	0.995 3	0.992 5	0.981 4
	F1	0.954 2	0.994 4	0.992 0	0.980 2
SE+DC+U-Net	SE	0.991 1	0.994 8	0.996 2	0.994 0
	PPV	0.969 9	0.994 3	0.986 7	0.983 6
	F1	0.967 6	0.993 9	0.990 4	0.984 0
本文模型	SE	0.990 5	0.995 5	0.996 3	0.994 1
	PPV	0.978 5	0.997 2	0.991 4	0.989 0
	F1	0.974 0	0.996 0	0.992 5	0.987 5




图5 信号真实标签与算法分割结果

Figure 5 Signal real label and algorithm segmentation results

相对于U-Net模型有大约0.5%的提升,在P波和QRS波的分割上性能明显更加优秀,T波效果与U-Net相差不大。SE+DC+U-Net(SENNet, Dilated Convolution, U-Net)与DC+U-Net区别在于将3通道下采样改成了两个通道,加入了 SENet 模块;平均性能相比于DC+U-Net模型提升了大约0.3%。本研究提出的模型通道数为3,加入了空洞卷积和 SENet 模块,在P波、QRS波、T波的分割上性能都优于其他模型,平均性能对于U-Net模型大约提升了1.2%。

因为LUDB数据标注问题,本研究舍弃了部分心电信号。黄鑫^[24]采用了与本文类似的做法,在第3秒和第9秒之间随机选择了6 s的心电片段构建数据集;Sereda等^[22]用中值滤波去除基线漂移后也选择了6 s的心电信号作为数据集的一条序列;Viktor等^[4]从第2秒到第4秒随机选择起点,序列长度是4 s。将本文方法与其他方法的研究结果进行比较,结果如表3所示。本文算法在T波的性能上有着明显的优势,但是在QRS波的检测上不如Viktor等^[4]的方法。从平均性能来看,本文方法在敏感度、阳性预测率上都取得了更好的表现。

为了验证本文提出的算法的泛化能力,在处理好的QTDB上进行算法验证。表4是在LUDB上训练好的算法在QTDB上进行验证的结果与其他方法的研究结果对比。同Kalya-Kulina等^[25]的方法相比可以看到本文方法在P波段的效果不够明显,但在QRS段和T波段有明显优势。Bote等^[26]采用小波分析方法对心电波形进行分割,本文方法在QRS波段

表3 与其他论文方法对比(LUDB)
Table 3 Comparison with other methods (LUDB)

方法		P波	QRS波	T波	平均值
黄鑫 ^[24]	SE	0.982 7	0.995 5	0.995 2	0.991 1
	PPV	0.983 3	0.995 2	0.976 9	0.985 1
	F1	0.983 0	0.995 3	0.985 9	0.988 1
Sereda等 ^[22]	SE	0.953 0	0.995 1	0.977 6	0.975 2
	PPV	0.826 3	0.980 7	0.948 9	0.918 6
	F1	0.885 1	0.987 8	0.963 0	0.945 3
Viktor等 ^[4]	SE	0.973 7	0.999 6	0.994 6	0.989 3
	PPV	0.955 3	0.998 4	0.989 1	0.980 9
	F1	0.964 5	0.999 0	0.991 8	0.985 1
本文方法	SE	0.990 5	0.995 5	0.996 3	0.994 1
	PPV	0.978 5	0.997 2	0.991 4	0.989 0
	F1	0.974 0	0.996 0	0.992 5	0.987 5

与他们取得的效果接近,但是在T波段的检测上更胜一筹。因此,本文方法已经接近了目前的主流水平,在跨数据库上取得较好的表现,具有良好的泛化能力。

表4 QT数据库上算法验证结果对比
Table 4 Comparison of algorithm verification results on QT database

方法		P波	QRS波	T波	平均值
Bote等 ^[26]	SE	0.990 0	0.995 0	0.969 8	0.987 9
	PPV	0.951 5	0.997 8	0.989 8	0.977 7
	F1	0.970 3	0.996 4	0.979 7	0.982 6
Kalya-Kulina等 ^[25]	SE	0.975 0	0.984 2	0.961 6	0.973 6
	PPV	0.979 0	0.982 4	0.948 7	0.970 0
	F1	0.976 9	0.983 3	0.955 1	0.971 8
本文方法	SE	0.979 3	0.994 3	0.985 9	0.986 5
	PPV	0.979 6	0.992 1	0.981 2	0.984 3
	F1	0.974 4	0.992 2	0.980 5	0.982 3

3 结 语

本研究提出一种基于U-Net框架的改进模型,用于心电波形分割。采用LUDB和QTDB构建训练集,进行5折交叉验证。LUDB用来训练模型并进行测试,在QTDB上做算法验证。实验结果充分验证了算法的有效性和泛化能力,在LUDB测试集上的5折交叉验证结果为:平均灵敏度99.41%,平均阳性预测率98.90%,平均F1分数98.75%。在QTDB上性能可以比拟主流的方法。本研究的缺陷如下:首先对于

LUDB和QTDB中部分漏标的记录,没有充分利用数据;其次,对于一些疾病类型的心电图,例如房颤等尚无法进行准确分割。这些工作有待进一步研究。

【参考文献】

[1] Shen CX, Ge JB. Epidemic of cardiovascular disease in China: current perspective and prospects for the future[J]. Circulation, 2018, 138(4): 342-344.

[2] 《中国心血管健康与疾病报告2020》编写组.《中国心血管健康与疾病报告2020》概述[J]. 中国心血管病研究, 2021, 19(7): 582-590. Writing Committee of the Report on Cardiovascular Health and Diseases in China. Key points of report on cardiovascular health and disease in China 2020[J]. Chinese Cardiovascular Research, 2021, 19(7): 582-590.

[3] 胡丹琴, 蔡文杰. QRS复合波检测技术综述[J]. 中国医学物理学杂志, 2020, 37(9): 1208-1212. Hu DQ, Cai WJ. Review on technologies for QRS complex detection [J]. Chinese Journal of Medical Physics, 2020, 37(9): 1208-1212.

[4] Viktor M, Nikolai Z, Grigory O. Deep learning for ECG segmentation [C]//Neuroinformatics 2019, Cham: Springer International Publishing, 2020: 246-254.

[5] Aspuru J, Ochoa-Brust A, Felix RA, et al. Segmentation of the ECG signal by means of a linear regression algorithm[J]. Sensors, 2019, 19(4): 775.

[6] Li T, Zhou M. ECG classification using wavelet packet entropy and random forests[J]. Entropy, 2016, 18(8): 285.

[7] Nurmainsi S, Darmawahyuni A, Rachmatullah MN, et al. Beat-to-beat electrocardiogram waveform classification based on a stacked convolutional and bidirectional long short-term memory[J]. IEEE Access, 2021, 99: 1.

[8] Kalyakulina AI, Yusipov II, Moskalenko VA, et al. LUDB: a new open-access validation tool for electrocardiogram delineation algorithms[J]. IEEE Access, 2020, 8: 186181-186190.

[9] Abdolrahman P, Sadasivan P. DENS-ECG: a deep learning approach for ECG signal delineation[J]. Expert Syst Appl, 2021, 165: 1-15.

[10] 顾秀秀, 朱明亮, 王璐, 等. 基于小波变换的心电信号特征提取[J]. 软件导刊, 2021, 20(5): 77-81. Gu XX, Zhu ML, Wang L, et al. Feature extraction of ECG signal based on wavelet transform[J]. Software Guide, 2021, 20(5): 77-81.

[11] Kumar A, Tomar H, Mehla VK, et al. Stationary wavelet transform based ECG signal denoising method [J]. ISA Trans, 2021, 114: 251-262.

[12] Do E, Boynton J, Lee BS, et al. Data augmentation for 12-lead ECG beat classification[J]. SN Comput Sci, 2022, 3(1): 1-17.

[13] Hu S, Cai W, Gao T, et al. Robust wave-feature adaptive heartbeat classification based on self-attention mechanism using a transformer model[J]. Physiol Meas, 2021, 42(12): 125001.

[14] 莫春梅, 周金治, 李雪, 等. 基于改进U-Net的肝脏分割方法[J]. 中国医学物理学杂志, 2021, 38(5): 571-577. Mo CM, Zhou JZ, Li X, et al. Liver segmentation method based on improved U-Net[J]. Chinese Journal of Medical Physics, 2021, 38(5): 571-577.

[15] Vijayakumar V, Ummar S, Varghese T J, et al. ECG noise classification using deep learning with feature extraction[J]. Signal Image Video Proces, 2022, 1: 1-7.

[16] Yan G, Liang S, Zhang Y, et al. Fusing transformer model with temporal features for ECG heartbeat classification[C]//2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE, 2019.

[17] Ma H, Chen C, Zhu Q, et al. An ECG signal classification method based on dilated causal convolution[J]. Comput Math Method Med, 2021, 2021(3): 1-10.

[18] Guo X, Wang Q, Zheng J. An intelligent computer-aided diagnosis approach for atrial fibrillation detection based on multi-scale convolution kernel and Squeeze-and-Excitation network[J]. Biomed Signal Proces, 2021, 68(6): 102778.

[19] Thompson S, Fergus P, Chalmers C, et al. Detection of obstructive sleep Apnoea using features extracted from segmented time-series ECG signals using a one dimensional convolutional neural network

- [C]//2020 International Joint Conference on Neural Networks (IJCNN), 2020: 1-8.
- [20] Xu H, Yang M, Deng L, et al. Neutral cross-entropy loss based unsupervised domain adaptation for semantic segmentation[J]. IEEE Trans Image Proces, 2021, 99: 1.
- [21] Imambi S, Prakash KB, Kanagachidambaresan GR. PyTorch[M]. EAI/ Springer Innovations in Communication and Computing. Cham: Springer, 2021.
- [22] Sereda I, Alekseev S, Koneva A, et al. ECG segmentation by neural networks: errors and correction [C]//2019 International Joint Conference on Neural Networks (IJCNN), 2019.
- [23] Londhe AN, Atulkar M. Semantic segmentation of ECG waves using hybrid channel-mix convolutional and bidirectional LSTM[J]. Biomed Signal Proces, 2021, 63: 102162.
- [24] 黄鑫. 心电特征波形分割及常见心律失常分类识别研究[D]. 成都: 电子科技大学, 2021.
- Huang X. Research on ECG characteristic waveform segmentation and common arrhythmia classification and recognition [D]. Chengdu: University of Electronic Science and technology, 2021.
- [25] Kalya-Kulina AI, Yusipov II, Moskalenko VA, et al. Finding morphology points of electrocardiographic-signal waves using wavelet analysis[J]. Radiophys Quant El+, 2019, 61(8-9): 689-703.
- [26] Bote JM, Recas J, Rincon F, et al. A modular low-complexity ECG delineation algorithm for real-time embedded systems[J]. IEEE J Biomed Health Inform, 2018, 22(2): 429-441.

(编辑:谭斯允)