

基于 U-Net++ 的心电信号识别分类研究



杨春德^{1,2} 贾竹¹ 李欣蔚²

1 重庆邮电大学计算机科学与技术学院 重庆 400065

2 重庆邮电大学生物信息学院 重庆 400065

(yangchunde64@126.com)

摘要 探索高效、快速、精准的心电信号识别分类算法是心电诊断的难点。基于心电片段的识别分类更贴合临床应用。基于此,文中将改进的深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Networks, DCGAN)用于数据扩充,将优化的一维 U-Net++ 用于心律不齐的片段信号识别。连续截取 MIT-BIH 数据库中 1 200 个采样点的心电片段作为实验数据集,以每条片段记录中心拍标签次数出现最多的类型作为整段记录的标签。再将优化的一维 U-Net++ 作为 DCGAN 结构的生成器实现部分数据扩充,以解决数据不平衡的问题。在原始心电信号未经过任何预处理以及生成的扩充数据用于完成小波阈值去噪的情况下,优化的一维 U-Net++ 模型对于正常、室性早搏、左束支阻滞、右束支阻滞 4 类不同的心电类型训练集的准确率能够达到 98.10%,且对于测试集的精准率、召回率和 F1 值等指标均有较好的结果。在相同实验数据集下,优化的一维 U-Net++ 模型比 U-Net 模型的准确率提高了 1.05%;在相同实验参数的条件下,与欠采样数据对比,经 DCGAN 数据扩充后的数据集实验模型的准确率提高了 0.85%。

关键词: 心电信号;识别分类;生成对抗网络;U-Net++;MIT-BIH

中图分类号 TN911.7;R540.4

Study on ECG Signal Recognition and Classification Based on U-Net++

YANG Chun-de^{1,2}, JIA Zhu¹ and LI Xin-wei²

1 School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2 School of Biological Information, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract It is difficult to explore efficient, fast and accurate ECG signal recognition and classification algorithm. The classification of ECG fragments is more suitable for clinical application. Based on this, the improved generation countermeasure network (DCGAN) is used for data expansion, and the optimized one-dimensional U-Net++ is used for fragment signal recognition of arrhythmia. ECG fragments from 1 200 sampling points in MIT-BIH database are continuously intercepted as the experimental data set, and the type that appears the most times of beats in each fragment recording center is used as the label of the whole record. Then the DCGAN, which uses optimized one-dimensional U-Net++ as generator, is used to realize partial data expansion to solve the problem of data imbalance. Under the condition that the original ECG signals are not preprocessed and the generated extended data are used to complete the wavelet threshold denoising, the accuracy of the optimized one-dimensional U-Net++ model for normal, ventricular premature beat, left bundle branch block, right bundle branch block four kind of different type can reach 98.10% for the training sets. The precision ratio, recall ratio and F1 score of the test set have good results. Under the same experimental data set, the accuracy of U-Net++ model is 1.05% higher than that of U-Net model. Under the same experimental parameters, compared with under sampling data, the accuracy of the experimental model of the data set expanded by DCGAN is improved by 0.85%.

Keywords ECG, Recognition and classification, DCGAN, U-Net++, MIT-BIH

1 引言

心脏健康状况,成为诊断治疗各类心脏疾病的有效手段^[1-3],而探索高效、快速、精准的心电信号识别算法一直是学者们关注的焦点。对于心电信号的识别诊断,传统识别方法虽准确

心电信号是心脏电活动在人体体表的表现,能直观反映

收稿日期:2020-07-16 返修日期:2020-10-20 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:重庆市教育委员会科学技术研究项目(KJQN201800622)

This work was supported by the Science and Technology Research Project of Chongqing Education Commission(KJQN201800622).

通信作者:李欣蔚(lixinwei@cqupt.edu.cn)

度较高,但步骤繁琐,耗费时间;而人工智能识别步骤相对简单且准确度较高^[4],能在一定程度上减轻专家医生的压力,提高诊断效率,应用价值大。例如,Feng等^[5]提出将心电信号使用多重小波算法进行滤波之后,再采用SVM分类器进行分类与识别。Venkatesan等^[6]提出基于 K 最邻近分类算法的心律失常分类方法,实现对正常和异常受试者的分类识别。Zhang等^[7]采用卷积神经网络(Convolutional Neural Networks, CNN)和长短时记忆神经网络(Long Short-Term Memory, LSTM)相结合的深度学习算法,对5种不同心拍进行分类识别。Li等^[8]采用基于小波自适应的阈值去噪与深度残差卷积神经网络相结合的识别方法,利用残差块局部神经网络结构单元构建深度残差卷积神经网络,对心电信号进行多类型心拍自动分类。Hesar等^[9]使用两个卡尔曼滤波器分别对QRS波进行高频去噪,对P波与T波进行低频去噪;最后与多种滤波方法进行对比,该方法在信噪比较低的情况下能够很好地处理噪声,保护心电信号的形态。大多数心电分类方法基于心拍,识别准确率较高^[10],但数据处理步骤繁琐,且实际应用性不够强;部分方法基于心电片段,不需要额外的定位算法,但某些不常见类型的心电信号片段数量较少,可能会导致实验模型的分类型准确率不够理想。

针对以上问题,本文提出实现数据扩充的心电信号片段分类识别算法。生成对抗网络采用博弈手段使生成数据无限接近真实数据形态,因此本文使用生成对抗网络实现心电数据的扩充,保证分类数据平衡。U-Net++被广泛用于医疗图像处理,由于心电信号波形大,小卷积不能有效捕捉波形的变化,因此对U-Net++模型进行优化改进来处理一维心电信号,从而实现于心电信号类型的识别及疾病的诊断分类。

2 数据采集处理

心电图是心电信号(Electrocardiogram, ECG)识别分类诊断研究的基础,本文采用麻省理工学院发布的MIT-BIH心电数据库中的48条数据作为实验数据集,其中每条ECG记录长度约为30min,采样率为360Hz,每条记录实际拥有650000个采样点。由于编号102,104,107,217这4条记录所属患者均佩戴有心脏起搏器,可能对实验分析造成干扰,则不予考虑。在剩下的44条完整的心电信号中,以专家标注的类型标签为准,连续截取1200个采样点的心电片段记录作为实验数据集,即实验数据为长度1200的时间序列,以每个片段中心拍标签次数出现最多的类型作为整段记录的类型。若连续片段中正常类标签数量最多,但同时存在异常类型心拍,则此段心电记录将不能作为正常类实验数据被采集,被取作正常的心电片段记录中所有心拍的标注类型均为正常。以数据集中最常见的标签为基准,选取数据量最多且数量差较小的4类心电类型作为分类标签,每个类别的单心拍示意图如图1(a)~图1(d)所示,分别代表正常(normal)、室性早搏(PVC)、左束支阻滞(LBBB)、右束支阻滞(RBBB)。由于室性早搏类的数据量远小于其他3类,因此选取正常、左束支阻滞、右束支阻滞这3类心电片段各500条,室性早搏类300条。




图1 单心拍示意图

Fig. 1 Diagram of single heart beat

3 网络模型

3.1 U-Net++

深度学习训练模型通常需要大量的训练数据,对于ECG这种医疗信号,数据量无法达到训练要求,因此Ronneberger等^[11]提出了专门处理医疗图像的U-Net架构,它能在较小的数据集上取得不错的效果,整体模型架构是一个由FCN^[12]改进而来的全卷积神经网络,是典型的端到端的网络结构。其首先对输入数据编码(下采样),再经过解码(上采样),最后输出和原始图像维度大小保持一致的图像。编码器的作用是在给定输入数据后,通过神经网络学习得到比输入数据更小的特征值谱,相当于数据的压缩;而解码器则在编码器提供特征值谱后,将数据还原到与输入数据相等的大小,逐步实现每个类别的标注,也就是分类。Zhou等^[13]提出了改进架构U-Net++。U-Net++是针对原U-Net结构中skip connection部分提出的一种改进模型,它是从DenseNet^[14]中得到灵感的。U-Net++与U-Net结构大体一致,先依次进行下采样、卷积加激活函数等一系列操作之后,再进行上采样得到 $X_{0.1}, X_{0.2}, X_{0.3}, X_{0.4}$ 等层不同的输出。相对于U-Net, U-Net++将所有层都连接在一起,这样就能抓住不同层的特征,将深浅网络层特征进行充分融合。

3.2 心电信号分类识别的网络模型

本文提出了一种优化的一维U-Net++结构,如图2所示。将U-Net++模型优化为可以处理一维信号的多结构块网络。原始U-Net模型采用的是卷积核尺寸为3的小卷积,由于ECG信号的QRS波形变化较大,本文实验采用卷积尺寸较大的32个卷积核来有效捕捉波形的变化。对于输入长度为1200的实验数据,最多连续进行5次下采样,因此本文实验最多采用5层一维U-Net++模型。此时每一个结构块均由2个 32×1 的卷积层组成,结构块中每个卷积层的输出均作为此结构块中后面卷积层的输入。每个结构块的最后输出进入 2×1 的最大池化层,然后进入下一层卷积。上采样部分是先经过一个 2×1 的卷积层的上采样后,再经过两个 32×1 的卷积层。一维U-Net++结构有4个输出,输出结构块后面跟了一个深度监督,即每个输出分支后接 1×1 卷积层^[15]。

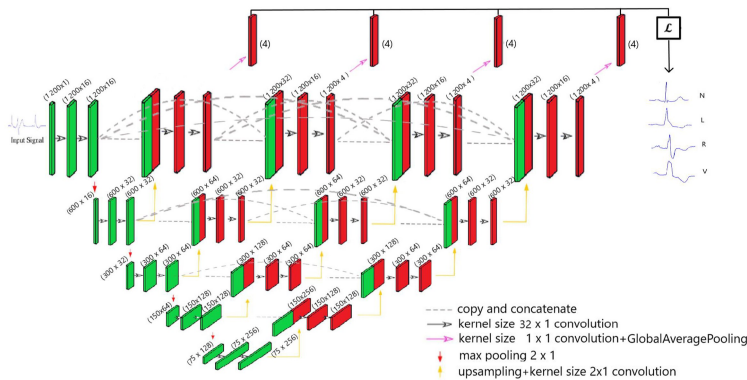


图 2 优化的一维 U-Net++ 结构模型

Fig. 2 Optimized one-dimensional U-Net++ structure model

本文研究心律失常多分类问题,损失函数采用 CCE(Categorical Cross-Entropy,即 SoftMax+CE)和 Dice coefficient 的组合方式,如式(1)所示,目的是使一维 U-Net++ 模型能在 Accurate mode 和 Fast mode 方式中选择性地进行操作。

$$L(Y, \hat{Y}) = -\frac{1}{N} \sum_{a=1}^N \sum_{b=0}^C \left(\frac{1}{2} \cdot Y_{a,b} \cdot \log \hat{Y}_{a,b} + \frac{2 \cdot Y_{a,b} \cdot \hat{Y}_{a,b}}{Y_{a,b} + \hat{Y}_{a,b}} \right) \quad (1)$$

4 数据扩充

4.1 DCGAN 数据扩充

由于心电片段截取的室性早搏类数据量远远少于其他几类数据量,实验数据的不平衡可能会造成网络训练结果偏向数据量多的类型,容易出现过拟合。解决数据不均可通过欠采样或过采样的方法。欠采样即减少数据量多的类型,使得每类数据均等,但实验数据总体样本量减少,不利于深度学习的训练。为了使学习达到更好的效果,采用深度卷积生成对

抗网络^[16](DCGAN)实现过采样,即对室性早搏类数据扩增,以解决数据不均衡的问题。生成对抗网络^[17]主要包含生成器(generator)和判别器(discriminator)两个独立的神经网络,通过两个网络相互博弈,使得随机噪声能够生成一些无限接近真实数据形态^[18]且判别器也无法正确判别的假数据。本文将优化的一维 U-Net++ 的主要结构作为 DCGAN 中的生成器,其模型如图 3 所示。




图 3 DCGAN 模型结构

Fig. 3 DCGAN model structure

由生成对抗网络生成的室性早搏类型心电信号与真实心电信号片段的对比如图 4 所示。




图 4 真实心电信号与 DCGAN 生成心电信号

Fig. 4 Real ECG signal and DCGAN generated ECG signal

4.2 扩充数据预处理

生成对抗网络生成的数据中含有一定的噪声。目前常用的去除噪声的方法有很多,基本上都能很好地去除基线漂移、工频干扰、肌电干扰这 3 类主要噪声^[19-22]。本文采用小波软阈值去噪算法对 DCGAN 数据进行预处理,得到平滑的心电信号。基于小波软阈值去噪的原理如图 5 所示,首先使用小波 lifting scheme 提升小波,再对小波进行多尺度分解,通过对每层的高频系数进行阈值设定,进行消噪处理;最后通过小波逆变换将各层依次进行小波重构,得到去噪后的信号。




图 5 小波软阈值滤波的原理

Fig. 5 Principle of wavelet threshold denoising

阈值公式如式(2)所示:

$$\lambda = \sigma \sqrt{2 \log(N)} \quad (2)$$

其中, $\sigma = \text{MAD} / 0.6745$,MAD 为第一层小波分解系数绝对值的中间值,0.6745 为高斯噪声标准方差的调整系数, N 为每层小波高频系数的长度值。

该阈值能够区别噪声和信号分量,将二者分离可以得到平滑的信号。小波软阈值法得到的重构信号比硬阈值得到的信号更平滑,因此本文采用软阈值算法。软阈值是将信号的绝对值和阈值进行比较,如式(3)所示:

$$f(x) = \begin{cases} \text{sgn}(x)(|x| - \lambda), & |x| > \lambda \\ 0, & |x| \leq \lambda \end{cases} \quad (3)$$

其中, $\text{sgn}(x)$ 为符号函数,如式(4)所示:

$$\text{sgn}(n) = \begin{cases} 1, & x > 0 \\ -1, & x < 0 \end{cases} \quad (4)$$

其中, λ 是阈值; x 为高频小波系数; $f(x)$ 是经阈值处理后的高频系数。

原始扩充数据与经过软阈值去噪后的心电信号对比如图 6 所示, 可以看出, 去噪后的信号比原始信号更为平滑。

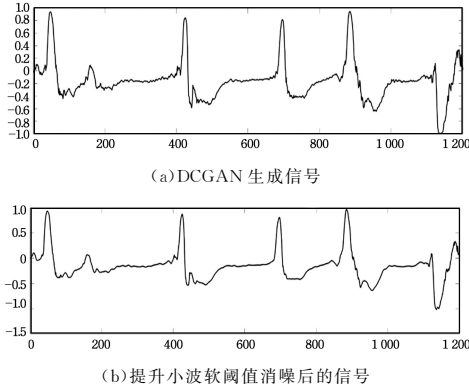


图 6 原始扩充数据与经软阈值去噪后的扩充数据的对比图

Fig. 6 Comparison diagram of the original extended data and the extended data after soft threshold denoising

5 实验与分析

5.1 实验流程

本文实验是将作为测试集数据的时间序列 $X = \{X_0, X_1, \dots, X_{1199}\}$, 即长度为 1200 的连续心电图片段输入训练好的网络模型中, 输出对应的心电类型标签。整体流程结构如图 7 所示^[23]。




图 7 网络结构

Fig. 7 Network structure

心电信号分类的具体步骤如下:

(1) 获取连续心电数据。以 1200 采样点作为数据长度, 连续截取符合 4 类心电类型标签标注的心电片段, 完成数据集的采集, 获得时间序列 X , 不进行任何预处理。

(2) 数据扩充。由于连续截取心电片段导致符合要求的数据过少, 数据不均衡, 难以合理地完成深度学习训练, 因此使用 DCGAN 完成对数据的扩充, 解决数据过少以及数据不均衡的问题, 将生成的数据进行滤波后添加到训练集中。

(3) 网络模型训练。选用优化的一维 U-Net++ 5 层结构, 最后接 Softmax 层, 作为整体网络框架。以训练集所有心电图片段作为网络输入, 每条记录中出现次数最多的类型作为整条记录类型标签来进行训练。

(4) 心电识别分类。将测试集作为输入, 加载到训练好的模型中, 通过模型分类器输出测试集的标签, 将其与真实标签进行对比, 验证模型预测心电图片段的准确率。

5.2 数据集划分

经数据扩充后的实验数据集分布如表 1 所列。4 类心电类型中, 正常、左束支阻滞、右束支阻滞的真实心电图记录各 500 条, 室性早搏类的真实数据 300 条。在 4 类不同的真实心电图数据中各随机选取 50 条记录, 组成总量为 200 的测试集。将剩下的 1600 条真实数据与生成对抗网络生成的 200 条合并, 以 5:1 的比例分为训练集与验证集, 即训练集 1500 条, 验证集 300 条, 数据集划分示意图如图 8 所示。

表 1 实验数据集的分布

Table 1 Number distribution of ECG data set

Types	Data Set
Normal	500
PVC	300+200(DCGAN)
LBBB	500
RBBB	500
Total	2000




图 8 数据集的划分

Fig. 8 Dataset partitioning

5.3 评估指标

使用深度学习进行目标识别任务时, 通常使用 TP, TN, FP, FN 等 4 个评价术语来完成评价指标的描述。这 4 个评价术语的第一个字母代表分类预测是否正确, T 代表 True, F 代表 False; 第二个字母一般代表分类预测的评判结果, P 代表将实验数据评判为正例, N 代表将实验数据评判为负例。TP 表示分类预测正确, 被分类判定为正例; TN 表示分类预测正确, 被分类判定为负例; FP 表示分类预测错误, 被分类判定为正例, 实际为负例样本; FN 表示分类预测错误, 被分类判定为负例, 实际为正例样本。准确率使用率最高的指标之一。而对于深度学习的不同识别任务, 由于模型的不同, 实验的评估指标也不同。在本文模型分类实验中, 采用准确率 (accuracy)、精准率 (precision)、召回率 (recall)、F1 值作为评价指标。准确率指分类正确的样本数除以总样本数, 如式(5)所示; 精准率指分类正确的正样本个数占分类器分成的所有正样本个数的比例, 如式(6)所示; 召回率指分类正确的正样本个数占总正样本个数的比例, 如式(7)所示; F1 值分数兼顾了分类模型的精准率和召回率, 是两者调和均值, 如式(8)所示。

$$ACC = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (5)$$

$$Precision = \frac{TP}{(TP+FP)} \quad (6)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (7)$$

$$F1 = 2 \times \frac{(precision \times recall)}{(precision + recall)} \quad (8)$$

5.4 实验结果

本文采用以 TensorFlow 为后端的 Keras 开发库进行网络搭建,完成优化的一维 U-Net++ 模型的迭代。本文对一维 U-Net++ 不同卷积核尺寸与不同层数结构的训练效果进行了对比,实验结果分别如图 9、图 10 所示。从图中可以看出,当卷积核尺寸大小为 32 时,5 层一维 U-Net++ 结构优于其他参数模型。该模型对于训练集整体的准确率能够达到 98.10%。




图 9 一维 U-Net++ 模型卷积核尺寸对比

Fig. 9 One-dimensional U-Net++ model convolution kernel




图 10 一维 U-Net++ 模型层数对比

Fig. 10 One-dimensional U-Net++ model layer number comparison

该模型对于测试集中 4 类心电类型分类的精准率、召回率与 F1 值指标结果如表 2 所列,对整体测试集的准确率能达到 97.50%。改进的一维 U-Net++ 模型对测试集的预测混淆矩阵如图 11 所示。该实验结果表明,由生成对抗网络生成的数据能够较好地贴合真实数据分布,未经过任何预处理的原始心电信号在此模型下也能够有较好的训练效果,模型的预测分类准确率也较高。

表 2 优化的一维 U-Net++ 模型分类评价指标值

Table 2 Classification evaluation indexes of optimized one-dimensional U-Net++ model

Types	Normal	PVC	LBBB	RBBB
Precision	0.9412	1.000	0.9796	0.9800
Recall	0.9600	1.000	0.9600	0.9800
F1 score	0.9505	1.000	0.9697	0.9800
Support	50	50	50	50




图 11 优化的一维 U-Net++ 模型预测混淆矩阵

Fig. 11 Optimized one-dimensional U-Net++ model prediction confusion matrix

本文对比了相关文献中心电信号分类识别的方法,结果如表 3 所列。对比实验方法均采用 MIT-BIH 心电数据且均基于心电片段数据进行实验。从表 3 可以看出,本文采用的优化的一维 U-Net++ 模型在心电信号分类识别中仍然获得了较高的准确率。为了进一步探究本文算法与其他方法的差异,使用同样的数据集在 U-Net 网络上进行对比实验,得到其与一维 U-Net++ 模型实验结果的对比(如图 12 所示)。可以看出,一维 U-Net 模型的准确率达到了 97.05%,与文献 [24] 中提出的一维 U-Net 处理心电信号片段 97.32% 的准确率结果相近。可以看出,U-Net++ 结构比 U-Net 更快收敛,且有更优的实验结果,能够更精确地对心电信号进行分类。

表 3 不同实验模型的性能对比

Table 3 Performance comparison of different experimental models

Algorithm	Number of types	Acc/%
SVM	4	96.69
U-Net	5	97.32
This paper	4	98.10




图 12 U-Net 与 U-Net++ 的对比

Fig. 12 Comparison of U-Net and U-Net++

为了验证过采样与欠采样方法对实验模型训练学习的影响,取 4 类真实心电记录各 300 条作为实验数据,其中每类各取 50 条作为测试集数据,剩下的 1000 条数据以 4:1 的比例分为训练集与验证集,以完成相同训练参数条件下的实验。实验对比结果如图 13 所示。




图 13 欠采样与过采样数据实验对比

Fig. 13 Experimental comparison of under sampling and over sampling data

欠采样数据训练出的模型准确率达到到了 97.25%,与进行部分数据扩充后的数据集实验结果相比,准确率较低。实验结果表明,欠采样处理数据的随机性可能会舍弃一些重要数据信息,实验模型未得到更好的训练,导致实验模型精度不高。

结束语 心电信号的自动识别分类是心律失常分类的核心,本文提出了一种基于 DCGAN 与 U-Net++ 的心电信号分类识别算法。由于心电异常类数据较少,符合要求的连续的心电片段也很少,从而为心电信号的深度学习研究带来了一

定困难。本文利用 DCGAN 网络实现数据扩增,在一定程度上贴合真实数据,解决了实验数据过少以及数据不平衡等问题。为了提高算法识别的准确率,本文研究了 U-Net++ 模型,在原始模型上进行优化,将其优化为可以处理一维心电信号的模型,使其在未经任何预处理的心电数据集上也能达到较好的分类效果。

由于心电疾病类型多种多样,目前实验考虑的心电类型较少,在接下来的工作中,将进一步考虑增加心电信号的分类类别数量,在保证准确率的情况下,进一步完善分类算法。

参 考 文 献

- [1] MA J W, LIU S P. Overview of ECG Signal Recognition and Classification Algorithms[J]. Journal of Chongqing University of Technology (Natural Science), 2018, 32(12): 122-128.
- [2] JIN L P, DONG J. Study on Classification Algorithm of Clinical Electrocardiogram based on Integrated Learning[J]. Journal of Biomedical Engineering, 2016, 33(5): 825-833.
- [3] MA R L, LIU X, ZHANG Y, et al. Deep learning based on ECG Signal anomaly Recognition Method[J]. Transducer and Microsystem Technologies, 2020, 39(1): 29-32.
- [4] CHEN M, WANG R F. Arrhythmia Classification Based on Two-Dimensional Image and Transfer Convolutional Neural Network[J]. Computer Engineering, 2020, 46(10): 315-320.
- [5] FENG Y R, CHEN W, CAI G Y. Biometric Extraction and Recognition based on ECG Signals[J]. Computer & Digital Engineering, 2016, 46(6): 1099-1103.
- [6] VENKATESAN C, KARTHIGA KUMAR P, VARATHARAJAN R. A novel LMS Algorithm for ECG Signal Preprocessing and KNN Classifier-based Abnormality Detection[J]. Multimedia Tools and Applications, 2018, 77(8): 10365-10374.
- [7] ZHANG K, LI X, XIE X J, et al. Study on Arrhythmia Detection Algorithm based on Deep Learning[J]. Chinese Medical Equipment Journal, 2008, 39(12): 6-9, 31.
- [8] LI D, ZHANG H X, LIU Z Q, et al. Recognition of Arrhythmia in ECG based on Deep Residual Convolution Neural Network [J]. Journal of Biomedical Engineering, 2019, 36(2): 189-198.
- [9] HESAR H D, MOHEBBI M. An Adaptive Kalman Filter Bank for ECG Denoising[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 25(1): 13-21.
- [10] GAO N H, WANG H, FENG X H. Classification Method of Electrocardiogram Signals Based on Dynamic Fuzzy Decision Tree[J]. Computer Engineering, 2020, 46(1): 80-86.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]// International Conference on Medical Image Computing & Computer-assisted Intervention. Cham; Springer, 2015: 234-241.
- [12] LONG J, SHELHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation[C]// IEEE Conference on Computer Vision and Pattern Recognition. 2015: 3431-3440.
- [13] ZHOU Z, SIDDIQUEE M M R, TAJBAKHS N, et al.

U-Net++: A Nested U-Net Architecture for Medical Image Segmentation[C]// Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Cham; Springer, 2018: 3-11.

- [14] HUANG G, LIU Z, MAATEN L V D, et al. Densely Connected Convolutional Networks[C]// IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2261-2269.
- [15] LIN M, CHEN Q, YAN S. Network in network [J]. arXiv: 1312. 4400, 2013.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image-net Classification with Deep Convolutional Neural Networks[C]// Advances in Neural Information Processing Systems. 2012: 1097-1105.
- [17] LIANG J J, WEI J J, JIANG Z F. Overview of GAN Generation Adversarial Network[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(1): 1-17.
- [18] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets[C]// Advances in Neural Information Processing Systems. 2014: 2672-2680.
- [19] CHEN G D, ZENG Y L, LI Z. Adaptive Double Threshold ECG Signal Detection Algorithm Research[J]. Journal of Jinan University (Natural Science & Medicine Edition), 2008, 39(3): 262-268.
- [20] LUO B. Research on the solution of interference signal removal in electrocardiograph [J]. Quality & Market, 2020(14): 88-90.
- [21] LI F, XIE S H. Abnormal Diagnosis of Mobile ECG based on Unsupervised Learning[J]. Computer Science, 2017, 44(S2): 68-71, 109.
- [22] FAN M, WANG X F, MENG X F. Research on Wearable ECG Adaptive Classification Algorithm [J]. Computer Science, 2019, 46(12): 292-297.
- [23] GAO H J, QIU T S, CHOU Y T, et al. Fundus Image Vascular Segmentation based on Improved U-Net Network[J]. Chinese Journal of Biomedical Engineering, 2019, 38(1): 1-8.
- [24] OH S L, NG E Y K, TAN R S, et al. Automated Beat-wise Arrhythmia Diagnosis using Modified U-Net on Extended Electrocardiographic Recordings with Heterogeneous Arrhythmia Types[J]. Computers in Biology and Medicine, 2019, 105: 92-101.



YANG Chun-de, born in 1964, master, professor. His main research interests include digital image processing, information and computing theory.



LI Xin-wei, born in 1990, Ph.D, lecturer. Her main research interests include biomedical image processing and so on.