

基于生成对抗网络的PPG-ECG信号转换方法

周韡鼎, 陈兆学

(上海理工大学健康科学与工程学院, 上海 200093)

摘要: 心电 (Electrocardiogram, ECG) 信号的长期检测与评估对心血管疾病的诊断和预防至关重要。心电信号的检测通常需要在患者身上安装电极, 易使受试者产生不适感, 适用范围有限。相对而言, 使用光电容积描记法 (Photoplethysmography, PPG) 检测得到的脉搏波 (Pulse wave) 信号不仅包含丰富的心血管生理和病理信息, 而且易于测量。考虑到 PPG 与 ECG 信号间存在固有的映射关系, 本文基于生成对抗网络 (Generative adversarial network, GAN) 提出了一种将 PPG 转换为 ECG 信号的模型。该模型生成器由 Unet 模型组成, 并且在特征图融合方面参考了 Unet++ 的结构, 而其判别器由卷积神经网络组成。在训练过程中, 采用梯度惩罚方式增加了生成模型的稳定性。基于公用数据集进行了实验, 通过对比 53 名受试者样本的处理结果, 新模型所生成 ECG 信号的均方根误差 (Root mean square error, RMSE)、Pearson 相关系数 (ρ) 和 Fréchet 距离 (Fréchet distance, FD) 三个指标分别提升了 3.4%、5.5% 和 0.4%, 证明新模型具有更好的 PPG-ECG 转换效果。

关键词: 光电容积描记法; 心电; 脉搏波; 生成对抗网络; 深度学习

中图分类号: R318; R540.4⁺1; TP181 **文献标志码:** A

Method of Transferring PPG to ECG Based on Generative Adversarial Network

ZHOU Weiding, CHEN Zhaoxue

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

Abstract: Long-term detection and evaluation of electrocardiogram (ECG) signals is crucial for the diagnosis and prevention of cardiovascular disease. However, the detection of ECG signals usually needs to install electrodes on the patient, which can easily cause discomfort to the subject, and the scope of application is thus limited. In contrast, pulse wave signals detected by photoplethysmography (PPG) not only contains rich cardiovascular physiological and pathological information, but also is easy to be measured. Considering the inherent mapping relationship between PPG and ECG signals, a model of transferring PPG to ECG signals based on generative adversarial network (GAN) is proposed. The generator network is composed of the Unet model, the structure of Unet++ is referenced in the feature map fusion, and the discriminator network is composed of a convolutional neural network. During the training process, gradient penalty is utilized to increase the stability of the model. The experiment is conducted based on public datasets. By comparing the processing results of a sample of 53 subjects, the root mean square error (RMSE), Pearson correlation coefficient (ρ) and Fréchet distance (FD) of the ECG signal generated by the new model are improved by 3.4%, 5.5% and 0.4%, respectively, proving

that the new model has better PPG-ECG transfer effect.

Key words: photoplethysmography (PPG); electrocardiogram(EGC); pulse wave; generative adversarial network (GAN); deep learning

引 言

心血管疾病是人体健康的首要杀手,长期监测包含心血管信息的生理信号有助于疾病的诊断和治疗。与心血管相关的生理信号包含心电(Electrocardiogram, ECG)信号、血压(Blood volume pressure, BVP)信号和脉搏波(Pulse wave)信号等。这些信号的测量方法各不相同,其中ECG信号需要在患者皮肤上安装电极,且设备不便携带,难以实现长时间的心电信号监测。相对而言,脉搏波信号的监测方法主要采用光电容积描记法(Photoplethysmography, PPG),基于郎伯-比尔定律(Lambert-Beer law),通过检测皮肤组织表面的光线强度变化来测量血液容积的变化^[1],相较于ECG和BVP等信号,具有无创、便捷、廉价等优点,易于实现信号的长时间监测。在健康监护中客观存在对ECG信号进行长期监测的需求,但ECG信号检测起来不太方便,并考虑到PPG与ECG间存在确定的内在联系并且相对容易测量,本文提出了基于生成对抗网络(Generative adversarial network, GAN)的PPG-ECG转换模型。该模型能够克服PPG信号的不稳定性并且可在不接触患者皮肤的情况下生成ECG信号,从而实现从PPG到ECG的转换。

将PPG信号转换为相应的ECG信号有助于疾病监测和诊断,但是目前对这一方面的研究成果较少,部分研究仅考虑了PPG与ECG的参数转换或仅实现了ECG的波形重建。其中,Banerjee等^[2]使用基于机器学习的算法,将PPG在时域和频域中提取到的特征作为输入,预测出ECG的RR、PR、QRS和QT间期等参数,但是该方法未能实现ECG的波形重建;McSharry等^[3]使用微分方程对ECG信号进行重建;Sayadi等^[4]基于高斯波建立生成ECG的动力模型;Zhu等^[5]和Golany等^[6]都利用GAN生成ECG信号,但这些模型的输入均为随机噪声,旨在扩大数据量提高分类精度,都只将关注点放在了ECG波形重建方面,却基本未考虑PPG与ECG之间的转换关系,即未实现稳定、高效的转换模型。

还有一些研究通过在变换域寻找规律,实现信号转换。如Zhu等^[7]通过计算单周期PPG与ECG之间的离散余弦变换系数,利用线性回归实现PPG到ECG的转换,该方法的局限性在于实验数据较少,且PPG与ECG之间的关系并非线性;随后,Tian等^[8]又提出了交叉域字典学习,在K-SVD模型的基础上,通过PPG向ECG的映射,使得学习得到的字典具有更高的概括性和更强的转换能力。但是PPG与ECG之间的关系是非线性的,使用线性回归的方法将失去很多细节。

在PPG与ECG之间的非线性关系无法使用传统方法进行回归时,深度学习表现出了更好的效果。Chiu等^[9]基于卷积神经网络(Convolutional neural network, CNN)构建了包含注意力机制的转换模型,通过添加注意力机制和在损失函数中添加高斯函数项,实现对ECG中的QRS波更好的拟合效果,但是该方法没有考虑不同个体之间的差异;Sarkar等^[10]提出了CardioGAN用于PPG向ECG转换,该模型在生成对抗网络的基础上改进了生成器与判别器的结构,其生成器选择了Attention U-Net,即包含注意力机制的U-Net网络,注意力模块处在U-Net网络中的每一步跳跃连接当中,其判别器同时考虑了信号的时域和频域信息;Vo等^[11]基于Wasserstein GAN(WGAN)建立了PPG到ECG的转换模型,在损失函数中,通过计算真实数据与生成数据分布之间的Wasserstein距离,强化了由判别器向生成器的梯度传递,同时选取ECG信号中R波及其他波峰波谷作为特征点,更好地保留了生成信号的主要特征。这些方法所使用的生成网络都基于Unet结构,而在跳跃连接部分有待改进。同时,这些方法都通过改进损失函数,或者在模型中加入注意力机制,以提高ECG信号中QRS波的转换效果,但它们仅仅关注了ECG信号的一部分转换效果,却忽略了ECG信号中P波和T波等细节。

基于以上方法所存在的缺点,本文提出基于生成对抗网络的PPG-ECG转换模型。以Unet++网络为生成网络、卷积神经网络为判别网络,同时在训练过程中加入梯度惩罚以提高训练的收敛速度,最后使用BIDMC公开数据集中的PPG与ECG信号来训练和测试模型,以验证该模型的有效性和可行性。

1 方法与理论

由于本文的目标是将已测得的PPG信号 x 和随机噪声 z 转换为ECG信号 y ,存在约束条件,因此不同于传统的GAN模型,本文选用了cGAN(conditional GAN)模型,其目标函数为

$$L_{cGAN}(G, D) = E_{x, y}[\lg D(x)] + E_{x, z}[\lg(1 - D(x, G(x, z)))] \quad (1)$$

式中: G 为生成网络; D 为判别网络。优化过程是求极大、极小值问题:生成网络经过训练后能够生成足够真实的ECG信号,使 $L_{cGAN}(G, D)$ 最小;而判别网络则经过训练后能够分辨生成的信号是否为真实的ECG信号,使 $L_{cGAN}(G, D)$ 最大。

1.1 生成网络

生成网络通过学习ECG信号数据的分布概率,将输入的PPG信号进行转换,得到使判别网络鉴定为真的ECG信号。生成网络的结构如图1所示,采用了Unet++结构的卷积神经网络,其结构可以分为编码路径、解码路径和跳跃连接3个部分,图中每一个矩形框中的数字表示数据的长度 \times 通道数。编码部分即对信号进行下采样,每一步包含卷积模块和最大池化层,实现信号的特征提取;解码部分与编码部分相对称,差别是最大池化层被取代为上采样层;跳跃连接部分不同于Unet结构中直接将编码路径与解码路径的特征图相连接,Unet++结构中将卷积模块加入到跳跃连接中,并融合下一阶段卷积的特征,从而优化了特征融合的步骤。特征图的通道数需要通过卷积模块来改变,每一个卷积模块包含两个一维卷积层、批标准化层(Batch normalization, BN)和ReLU激活层,其中卷积核的大小为3,步长为1。最终将4个上采样后的特征图送入一维卷积层,输出与PPG维度相同的数据。

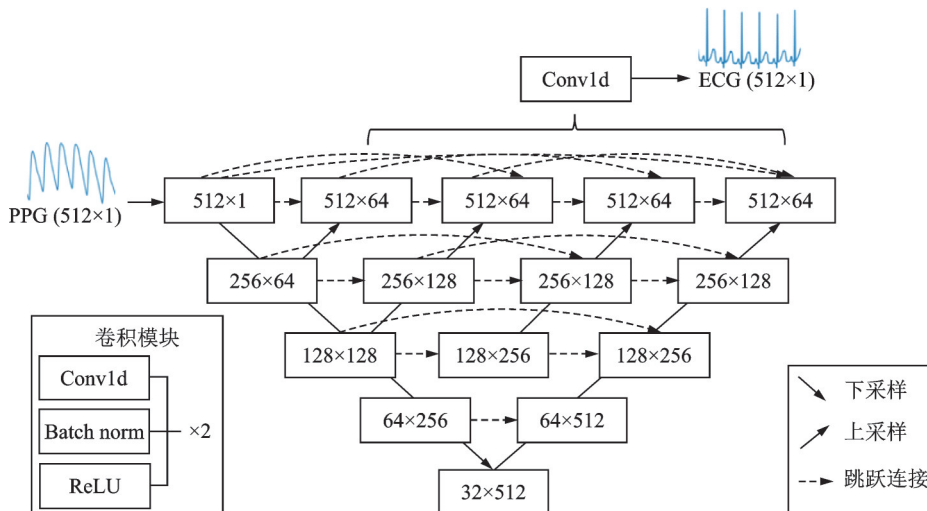


图1 生成网络结构图

Fig.1 Structure of generator network

1.2 判别网络

判别网络用于估计生成网络转换出的ECG数据符合原始ECG数据的概率,其实质为一个二分类器,网络结构如图2所示,图中每一个矩形框中的数字表示数据经过卷积模块后的长度 \times 通道数。将原始PPG信号与生成的ECG信号进行拼接输入到判别网络中,该网络首先使用卷积核大小为3、步长为1

的一维卷积层提取浅层特征,随后使用4个相同的模块来缩小特征图的尺寸。在每一个模块中,包含了一个卷积核大小为4、步长为2的一维卷积层,一个BN层和一个LeakyReLU激活层。最后使用一维卷积层将通道数转换为1,并使用Sigmoid激活函数输出分类结果。该网络使用LeakyReLU激活函数能够防止过拟合,设置负斜率(Negative slope)为0.2,以保证梯度传递更为简单。




图2 判别网络结构图

Fig.2 Structure of discriminator network

1.3 损失函数

损失函数决定了生成对抗网络的训练效果。为了实现数据由PPG向ECG的转换,本文将损失函数定义为

$$L_{\text{WGAN-GP}}(G, D) = -E_{x,y}[D(x)] + E_{x,z}[D(x, G(x, z))] + \delta E_{\hat{y}} \left[\left(\|\nabla_{\hat{y}} D(\hat{y})\|_2 - 1 \right)^2 \right] \quad (2)$$

损失函数 $L_{\text{WGAN-GP}}$ 表示目标函数为最小化生成数据与真实数据之间的Wasserstein距离,并且在两个数据分布之间加入了梯度惩罚项,梯度惩罚项中 $\hat{y} = \epsilon y + (1 - \epsilon)\tilde{y}$, $0 \leq \epsilon \leq 1$, \tilde{y} 表示模型生成的数据, δ 表示梯度惩罚项的权重系数。该方法能够增强由判别网络到生产网络的梯度传播,防止训练无法收敛。

为了使生成的数据与真实ECG信号在形态上更接近,本文添加了 L_{L_2} 损失函数用于计算生成数据与真实数据之间的欧式距离,其表达式为

$$L_{L_2}(G) = E_{x,y,z} \left[\|y - G(x, z)\|_2 \right] \quad (3)$$

最终的目标函数即损失函数的加权和为

$$G = \arg \min_G \max_D L_{\text{WGAN-GP}}(G, D) + \lambda L_{L_2}(G) \quad (4)$$

式中 λ 为损失函数 L_{L_2} 的权重。

2 实验结果

2.1 实验数据与环境

本文采用pytorch框架搭建网络模型,算法使用python语言编写,运行平台的硬件配置为:内存16 GB; Intel(R) Core(TM) i5-11500 @ 2.70 GHz; 显卡 GeForce GTX 2080Ti 11 GB。

实验所使用的数据为BIDMC公开数据集^[12]。BIDMC数据集收集的是53名危重症患者的生理信号,其中PPG和ECG信号采集时长为8 min,采样频率为125 Hz。使用窗宽为512的窗口对信号进行截取,在两段窗口之间保留长度为100的重叠,以保证信号两个端点处的特征得以保留,如图3所示。以该方法截取获得3 180组PPG-ECG数据对并对其进行随机排序,将其中的2 544组作为训练集,并将训练得到的模型在636组测试集数据中进行验证。

为了验证生成器网络结构和梯度惩罚的训练策略对信号转换结果的影响,使用4个不同的模型来比较每一个机制在PPG-ECG转换中的表现,其命名分别为:

(1)UnetPP-WGAN。本文所提出的网络,生成器采用的是Unet++网络,在训练过程中加入了梯度惩罚。

(2)UnetPP-GAN。与本文提出的网络结构相同,在训练过程中仅采用了传统的对抗训练,未使用梯度惩罚。

(3)Unet-WGAN。生成器采用传统的Unet网络,即在跳跃连接中直接将编码路径的特征图与解码路径的特征图相结合,其他步骤与本文方法相同。

(4)UnetAttn-WGAN。生成器采用包含注意力机制的Unet网络,即在跳跃连接中添加了注意力机制。

2.2 评价标准

为了评估ECG波形的转换效果,采用均方根误差(RMSE)、Pearson相关系数(ρ)和Fréchet距离(Fréchet distance, FD)三个指标进行客观评价。

RMSE用于衡量原始信号与重建信号之间的差异,其表达式为

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (5)$$

式中 y_i 与 y'_i 分别为原始信号 y 与重建信号 y' 的第 i 个点。

Pearson相关系数(ρ)用于评价重建信号与原始信号之间的变化趋势,其表达式为

$$\rho = \frac{\sum_{i=1}^N (y'_i - \bar{y}'_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^N (y'_i - \bar{y}'_i)^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2}} \quad (6)$$

ρ 值的范围为 $[-1, 1]$,数值表达两个信号之间的相关性大小,符号表示正相关或是负相关。

Fréchet距离(FD)用于检验重建信号与原始信号之间的路径相似性,该标准同时考虑了信号中每个采样点的位置与顺序。两个离散时间信号的Fréchet距离的计算表达式为

$$\text{FD} = \min_M (\max_{(y_i, y'_i) \in M} (d(y_i, y'_i))) \quad (7)$$

式中 $d(y_i, y'_i)$ 表示两条曲线之间的欧式距离; $M \subseteq \{(y_i, y'_i) | y_i \in y, y'_i \in y'\}$ 。FD的值越小,曲线间的相似性就越高。

2.3 结果分析

2.3.1 模型训练收敛速度

为了分析梯度惩罚对模型训练收敛速度的影响,本文分别对比了UnetPP-GAN和UnetPP-WGAN两个模型在训练过程中的训练集和测试集损失曲线,结果如图4所示。由图4可知,在生成器网络与判

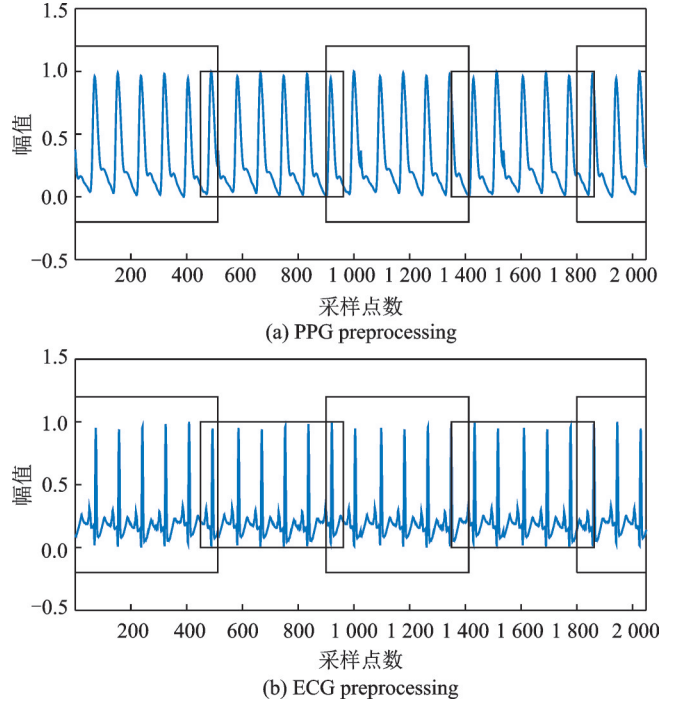


图3 数据集预处理

Fig.3 Dataset preprocessing

别器网络结构相同,且学习率和训练迭代次数相同时,在训练中添加梯度惩罚有助于模型更快地收敛,损失变得更小,模型的准确度更高。

为了分析生成器网络结构对模型训练收敛速度的影响,本文对比了Unet-WGAN、UnetAttn-WGAN和UnetPP-WGAN三个模型训练过程中的损失曲线,结果如图5所示。由图5可知,UnetPP-WGAN的训练集损失曲线相较于另外两个模型下降幅度更加缓慢,这是因为UnetPP-WGAN采用的生成器网络所需要训练的参数更多;而在测试集损失曲线中,UnetPP-WGAN的损失更小,且波动的幅度更小,体现出该模型在测试集中的泛化性更强、模型的精度更高。

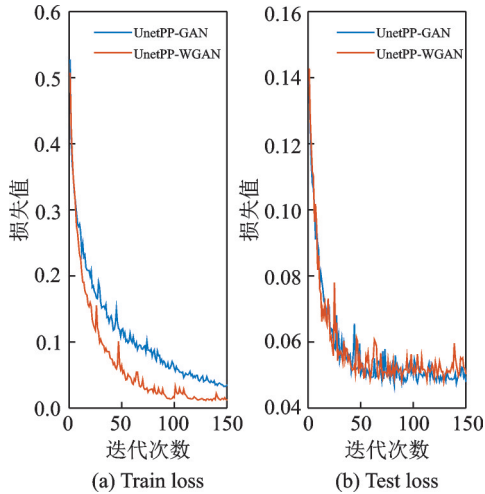


图4 UnetPP-GAN与UnetPP-WGAN损失曲线对比

Fig.4 Comparison of loss curves between UnetPP-GAN and UnetPP-WGAN

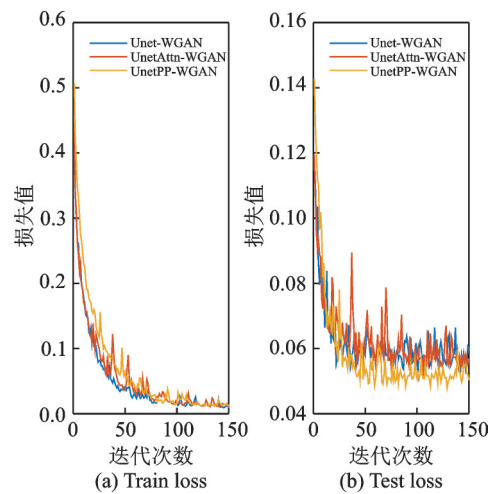


图5 Unet-WGAN、UnetAttn-WGAN与UnetPP-WGAN损失曲线对比

Fig.5 Comparison of loss curves among Unet-WGAN, UnetAttn-WGAN and UnetPP-WGAN

2.3.2 PPG-ECG信号转换效果

为了验证模型对PPG-ECG信号的转换效果,本文将训练得到的UnetPP-WGAN模型在测试集中进行验证,转换结果如图6所示。图6(a~d)分别展示了测试集中4种不同类型的PPG信号经模型输出得到的ECG信号的实验结果。从结果中可以发现,本文所提出的模型能够较好地实现由PPG信号向ECG信号的转换,且转换所得的ECG信号的波形特征,如QRS波、P波等都与原始ECG信号有较高的拟合度。由于该模型使用的是卷积神经网络,因此当输入的PPG信号波动较大时,能够对波动有抑制作用,所生成的ECG依然有较高的拟合度。

在信号边缘处拟合度较低,是因为生成网络中使用了卷积神经网络,所以在信号边缘处获得的特征较少。为了避免信号边缘转换效果差,本文在训练模型时所输入的信号是包含多个周期的长时间序列,并且在制作数据集时,数据两端有重叠的部分。利用该方法可以使重建出的ECG信号忽略边缘的误差。

本文分别使用RMSE、 ρ 和FD这3个指标对UnetPP-GAN、Unet-WGAN、UnetAttn-WGAN和UnetPP-WGAN四个模型进行评估,结果如表1所示。由表1结果可知,本文提出的基于Unet++网络为生成器、训练中添加梯度惩罚所获得的模型在3个指标上都取得了更好的转换效果;当生成网络都采用Unet++网络、训练中加入梯度惩罚时,3个指标分别提升了3.4%、5.5%和0.4%;当训练过程相同时,采用Unet++作为生成网络相较于Unet网络和Attention-Unet网络有更好的效果。

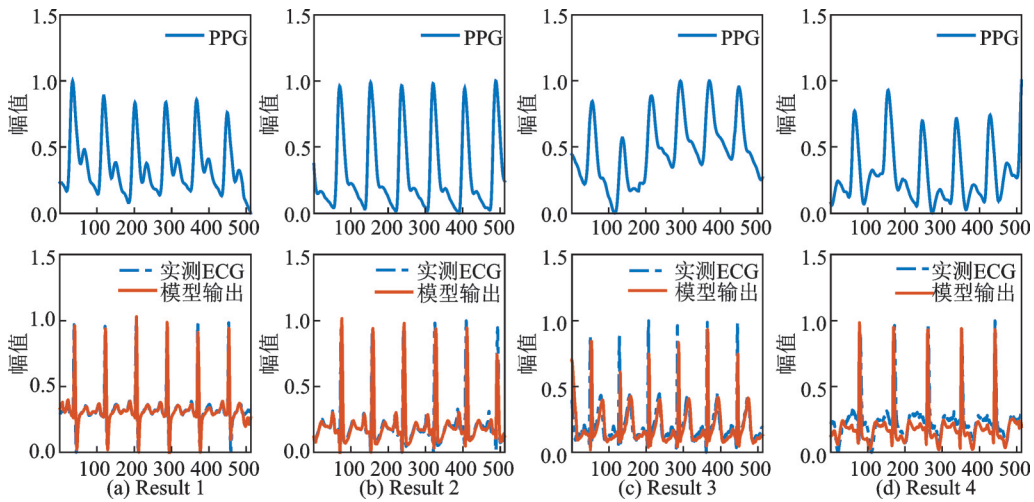


图6 PPG-ECG转换结果

Fig.6 PPG-ECG transferring results

表1 模型转换性能评估结果

Table 1 Evaluation results of model conversion performance

模型	RMSE		ρ		FD	
	μ	σ	μ	σ	μ	σ
UnetPP-GAN	0.145	0.051	0.508	0.264	0.751	0.131
Unet-WGAN	0.152	0.055	0.490	0.264	0.759	0.122
UnetAttn-WGAN	0.152	0.053	0.476	0.265	0.764	0.134
UnetPP-WGAN	0.140	0.055	0.536	0.268	0.748	0.137

2.3.3 与现有方法进行对比

本文将 UnetPP-WGAN 模型与以往工作进行了对比。由于其他工作所使用的评价指标和数据集不同,因此本文仅对比 RMSE 一项指标,对比结果如表 2 所示。本文提出的模型相较于现有方法取得了更好结果。另外,本文还与该方面的最前沿研究,即 Vo 等^[11]工作进行比较。本文将 Unet++ 网络取代了其使用的生成网络,在计算损失时没有对目标信号的特征点进行额外讨论的情况下,转换效果依然得到了提升。

表2 本文方法与现有方法比较

Table 2 Comparing of the proposed method with existing methods

方法	RMSE	
	μ	σ
文献[7]	0.67	0.26
文献[8]	0.39	0.31
文献[10]	0.36	—
文献[11]	0.16	0.06
本文方法	0.14	0.06

3 结束语

本文针对 PPG-ECG 信号转换问题进行了研究和探索,采用生成对抗网络模型,在生成器中的跳跃连接部分加入卷积模块,在训练过程中加入梯度惩罚,快速稳定地提高准确率,最后建立综合的数学评价方法对生成的 ECG 信号质量进行评估。本文的主要贡献包括:(1)提出了一种非接触式的端到端模型来重建 ECG 信号;(2)使用 CNN 为基础的神经网络来适应 PPG 与 ECG 信号的多变性,并且能够在实际应用中发挥作用;(3)采用公用数据集对模型进行训练,得到了更好的转换效果。经实验验证,本

文算法相较于文献[7]的离散余弦变换(Discrete cosine transform, DCT)算法适应性更强,相较于其他生成对抗网络的算法所得ECG信号的准确性更高。但由于训练数据集是危重症患者的生理信号,在健康人PPG-ECG转换方面,该算法性能还有待在合适数据集基础上进一步予以验证。今后将基于更多的数据集对模型进行改进和完善,扩展并提高网络信号转换性能。

参考文献:

- [1] BISWAS D, SIMOES-CAPELA N, VAN HOOFF C, et al. Heart rate estimation from wrist-worn photoplethysmography: A review[J]. IEEE Sensors Journal, 2019, 19(16): 6560-6570.
- [2] BANERJEE R, SINHA A, CHOUDHURY A D, et al. PhotoECG: Photoplethysmography to estimate ECG parameters[C]// Proceedings of 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). [S.l.]: IEEE, 2014: 4404-4408.
- [3] MCSHARRY P E, CLIFFORD G D, TARASSENKO L, et al. A dynamical model for generating synthetic electrocardiogram signals[J]. IEEE Transactions on Biomedical Engineering, 2003, 50(3): 289-294.
- [4] SAYADI O, SHAMSOLLAHI M B, CLIFFORD G D. Synthetic ECG generation and Bayesian filtering using a Gaussian wave-based dynamical model[J]. Physiological Measurement, 2010, 31(10): 1309.
- [5] ZHU F, YE F, FU Y, et al. Electrocardiogram generation with a bidirectional LSTM-CNN generative adversarial network[J]. Scientific Reports, 2019, 9(1): 1-11.
- [6] GOLANY T, RADINSKY K. PGANs: Personalized generative adversarial networks for ECG synthesis to improve patient-specific deep ECG classification[C]// Proceedings of the AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2019, 33(1): 557-564.
- [7] ZHU Q, TIAN X, WONG C W, et al. ECG reconstruction via PPG: A pilot study[C]// Proceedings of 2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). [S.l.]: IEEE, 2019: 1-4.
- [8] TIAN X, ZHU Q, LI Y, et al. Cross-domain joint dictionary learning for ECG inference from PPG[EB/OL]. (2021-01-07). <https://doi.org/10.1109/JIOT.2022.3231862>.
- [9] CHIU H Y, SHUAI H H, CHAO P C P. Reconstructing QRS complex from PPG by transformed attentional neural networks [J]. IEEE Sensors Journal, 2020, 20(20): 12374-12383.
- [10] SARKAR P, ETEMAD A. CardioGAN: Attentive generative adversarial network with dual discriminators for synthesis of ECG from PPG[C]// Proceedings of the AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2021: 488-496.
- [11] VO K, NAEINI E K, NADERI A, et al. P2E-WGAN: ECG waveform synthesis from PPG with conditional Wasserstein generative adversarial networks[C]// Proceedings of the 36th Annual ACM Symposium on Applied Computing. [S.l.]: ACM, 2021: 1030-1036.
- [12] PIMENTEL M A F, JOHNSON A E W, CHARLTON P H, et al. Toward a robust estimation of respiratory rate from pulse oximeters[J]. IEEE Transactions on Biomedical Engineering, 2016, 64(8): 1914-1923.

作者简介:



周韡鼎(1998-),通信作者,男,硕士研究生,研究方向:生物医学信号处理,E-mail: idonashino@163.com。



陈兆学(1975-),男,博士,副教授,研究方向:生物医学图像处理、生物医学信号处理、中医大数据等,E-mail: chenzhaoxue@163.com。

(编辑:王静)