

DOI:10.3969/j.issn.1005-202X.2023.10.016

医学信号处理与医学仪器

## 基于自适应位置编码的心电图重构算法

纪洁维, 常胜, 王豪, 黄启俊

武汉大学物理科学与技术学院, 湖北 武汉 430072

**【摘要】**可穿戴心电检测的主要挑战是较多导联影响被测者的身体活动,如果减少导联会使心电数据信息减少使检测效果变差。为了平衡被测者日常穿戴舒适性和检测准确性,笔者设计了一个基于Transformer Encoder的自适应相对位置编码重构算法,通过前后重叠的切片方式使相邻片段的信息具备关联性,相对位置编码时加入可训练参数对任意片段进行重构,从而有效地提取位置信息。用3个导联的ECG信号重构标准12导联ECG信号,实验结果表明,重构的ECG数据均方根误差低至0.02758,平均相关系数高达98.43%,显示出本文算法在应用于可穿戴心电检测设备的应用前景。

**【关键词】**心电图; 重构; 位置编码; Transformer Encoder

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2023)10-1285-06

### Adaptive position encoding for ECG reconstruction

Ji Jiewei, Chang Sheng, Wang Hao, Huang Qijun

School of Physics and Technology, Wuhan University, Wuhan 430072, China

**Abstract:** The main challenge in wearable electrocardiogram (ECG) detection is that multiple leads for detection affects the subject's physical activity, but reducing leads will weaken detection performance due to the loss of ECG data. An adaptive position encoding based reconstruction algorithm using Transformer Encoder is proposed to balance wearing comfort and detection accuracy. The information of adjacent slices is correlated through slice overlapping. When encoding relative positions, trainable parameters are added to reconstruct any slice for effectively extracting position information. The standard 12-lead ECG signal is reconstructed from 3-lead ECG signals, and the experimental results show that the root mean square error and average correlation coefficient of the reconstructed ECG data are 0.027 58 and 98.43%, indicating that the proposed algorithm has high application prospect in wearable ECG monitoring equipment.

**Keywords:** electrocardiogram; reconstruction; position encoding; Transformer Encoder

### 前言

心电图(Electrocardiogram, ECG)是检测人心脏状态的主要技术手段,检测心电时往往需要到医院进行,患者需平躺,在胸部和手脚上绑定(贴)多个电极进行ECG测量,通过ECG信号判断被测者是否患有心血管疾病。近年来,随着可穿戴式心电检测技术的发展,可以使用较少导联进行心电检测,然而较少的导联由于心电数据信息的减少使检测效果不尽如人意。如果能够利用导联重构技术重构出标准12导联心电信号,进而利用高精度的多导联血管疾病

检测算法,将提高可穿戴式心电检测的准确性,具有广泛的应用前景。

导联重构原理指出,人体可以视为一个有边界的三维不均匀导体,不同导联的ECG信号是心脏跳动所产生的电信号在不同方向上的投影<sup>[1-2]</sup>。因此,任何导联ECG信号都可以由来自同一身体的3个独立导联ECG信号线性表示。导联重构主要有基于线性的方法和基于机器学习的方法。基于线性方法采用线性回归和最小二乘拟合技术来重构ECG<sup>[3-11]</sup>,基于机器学习方法有人工神经网络<sup>[12]</sup>、卷积神经网络<sup>[13-14]</sup>、长短时记忆网络<sup>[15-16]</sup>等进行ECG信号重构。上述算法虽然可以重构标准12导联信号,但只能以ECG信号中的相邻R峰之间的片段作为整体进行重构,并不能对任意的ECG片段单独重构。另外这些算法没有利用ECG信号的时间特性,忽略了心拍前后的关联性,导致重构效果不够理想。本文提出了一种基于Transformer Encoder的自适应相对位置编

**【收稿日期】**2023-05-16

**【基金项目】**国家自然科学基金(81971702,61874079,61774113)

**【作者简介】**纪洁维,硕士,研究方向:基于深度学习的ECG信号重构,  
E-mail: 1589544756@qq.com

**【通信作者】**黄启俊,教授,研究方向:医学信号处理及微电子系统设计,  
E-mail: huangqj@whu.edu.cn

码ECG重构算法,算法不用考虑心拍片段是否处于R峰间期,不仅可以对任意ECG片段进行重构,而且可以充分提取ECG信号中不同导联之间以及导联内部的特征信息<sup>[17]</sup>,从而取得较好的重构效果。

# 1 模型结构与实验方法

## 1.1 数据库

本文采用开源PTB (Physikalisch Technische Bundesanstalt)数据库<sup>[18]</sup>,数据库有549条患者信息记录,采样频率为1 000 Hz。每条记录包含12个标准导联ECG数据和3个弗兰克导联ECG数据,通常标准导联ECG数据用于心血管疾病诊断。为了保证数据的均匀一致,每条记录中均提取200段时长为1 s的ECG数据,每个1 s的ECG数据为一个心拍,总共可以获得109 800个心拍ECG数据。其中80%作为训

练集,10%作为验证集,剩余10%作为测试集。

## 1.2 模型算法

基于自适应位置编码的ECG重构算法结构如图1所示,可分为3个部分:数据预处理、基于Transformer Encoder层的编码器、基于全连接层的解码器。与其它12导联重构方法相比,本文算法的创新点体现如下:(1)对原始心拍数据随机采样,无需定位R峰,可以在不同位置处理心电信号,可使信号处理更加灵活方便。(2)考虑心电信号在时间上前后顺序,采用部分重叠的方法对每一段心电信号进行相对位置编码,可以获得时序上的特征。(3)将训练权重添加到网络的固定位置编码,实现位置编码的自适应调节,从而提升了重建效果。(4)首次使用Transformer神经网络结构对心电信号进行处理,经过实验验证其可行性。

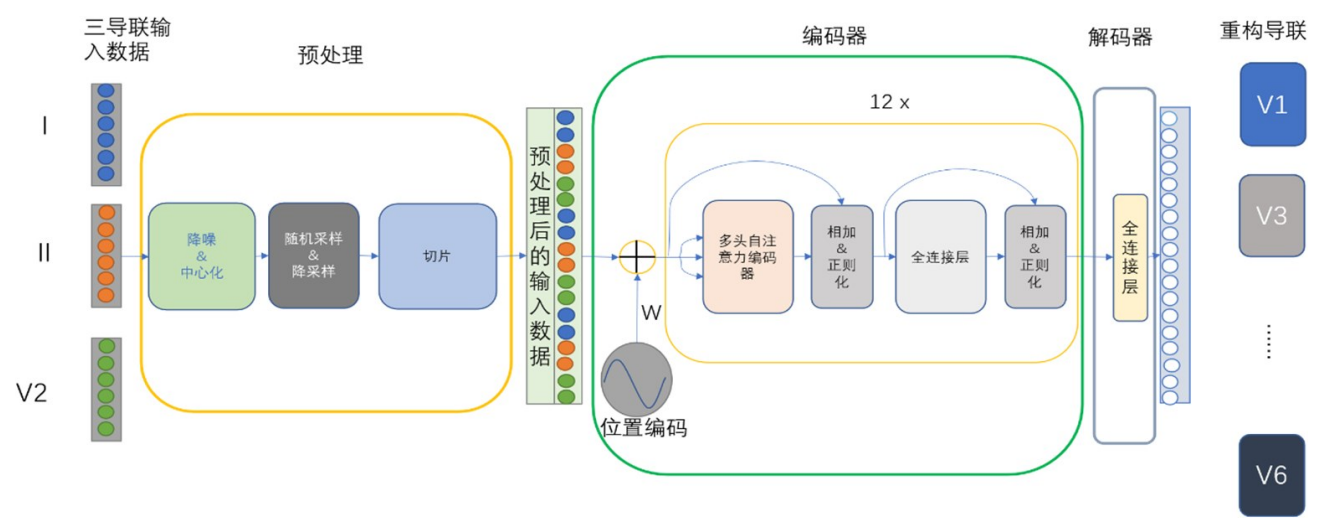


图1 算法结构框图  
Figure 1 Schematic diagram of the algorithm

## 1.3 ECG信号预处理

**1.3.1 降噪和中心化** 为减少噪声和基线漂移的影响,依据美国心脏协会(American Heart Association, AHA)的建议<sup>[19]</sup>,使用Daubechies 6小波对ECG信号进行滤波<sup>[20]</sup>,以消除基线漂移效应;通过去除ECG信号的幅度平均值,来集中(中心化)滤波后的ECG信号,经过滤波和中心化处理,ECG信号将更稳定,更适合于重构。

**1.3.2 降采样和随机采样** 为了减少重构算法中的网络参数和计算量,将原始采样频率为1 000 Hz的ECG数据下采样至600 Hz,由于ECG信号的频率集中在0.5~100 Hz,600 Hz大于ECG信号最大频率的两倍,由奈奎斯特定理可知,经下采样后ECG数据仍然能够保持足够的细节特征。

PTB数据库中549个患者的ECG数据差异较大,每条记录的时间长度不同,平均长度为103 s。为了平衡不同患者的ECG数据量,提高算法的鲁棒性,对每条记录都随机截取为200段长度为1 s的数据(心拍),这样每个心拍都有600个数据点。由于是随机截取,所以每个截取的ECG片段具有不同的形状。其它ECG重构算法都采用包含R峰的心拍片段,需要先定位R峰。而本文算法直接使用不同形状的心拍数据,不需要定位R峰就可以重构任意位置的ECG信号。特别强调的是,输入信号的多样性使重构网络的泛化能力得到了提升,可能少部分有所重叠。

**1.3.3 心拍切片** 为了保证输入神经网络的数据不至于过大,对每个心拍的ECG数据(1 s)进行进一步切

片,如图2所示,每个心拍切成99个片段,每个片段长度为12,第一个片段的后半段与第二个片段的前半段相同,第二个片段的后半段与第三个片段的前半段相同,即每个片段的最后6个数据点与后一片段的前6个数据点相同,这种相邻片段互相重叠的方法可以加强前后的信息连接。在原来没有时序信息的Transformer Encoder层中,通过加强相邻片段之间的

连接可以更好地发挥神经网络提取时序信息的能力。因为只有相邻的片段才会发生部分重叠,所以它可以用作一种新的相对位置编码。切片后,每个600个数据点的心拍变成一个二维矩阵,维度为(99, 12)。然后,需要将3个输入导联的数据聚合。数据形式从3个(99, 12)矩阵变为一个(99, 36)矩阵,该矩阵作为神经网络的输入。




图2 切片

Figure 2 Slices

## 1.4 Transformer Encoder 层

**1.4.1 自适应相对位置编码** Transformer Encoder的核心是它的自注意力机制,但是自注意力机制本身并不包含位置信息,即一个心拍被切片后的不同片段位于不同位置时,在Transformer Encoder中没有差异,这不利于Transformer Encoder充分提取信号时序信息。为了有效提取时序信息,根据文献[21],不同频率的正弦和余弦函数用于表示同一个心拍不同片段的位置信息<sup>[22]</sup>。该固定位置编码的计算公式如下:

$$PE_{(pos, 2i)} = \sin(pos/10000^{2i/d_{model}}) \quad (1)$$

$$PE_{(pos, 2i+1)} = \cos(pos/10000^{2i/d_{model}}) \quad (2)$$

其中,  $PE$  是与输入数据维度(99, 36)相同的二维矩阵;  $pos$  表示片段在整个心拍中的相对位置;  $d_{model}$  表示片段的大小,这里为36;  $i$  表示片段中的点在该片段中的相对位置。可以通过将位置编码和输入信号相加来获得自注意力层的输入信号,位置编码完全取决于输入信号的数据形式。由于自注意力层的输入是位置编码和ECG信号之和,而二者大小没有直接约束关系,如果ECG信号的振幅相对于位置编码太大,网络无法识别位置编码,位置编码将不起作用;反之如果ECG信号的振幅相对于位置编码太小,则位置编码将掩盖ECG信号信息。为了解决这个问题,在将位置编码与输入信号相加之前,将其乘以可训练参数  $W$ ,原始固定位置编码则变为自适应相对位置编码,自适应相对位置编码计算过程如下所示:

$$inputs = W * PE + sig \quad (3)$$

其中,  $inputs$  表示自注意力网络的输入;  $PE$  为传统的固定位置编码;  $sig$  表示信号输入,  $W$  表示一个可训练参数,是一个一维数字。通过前后重叠的切片方式使相邻片段的信息更具关联性,而加入可训练参数  $W$  使网络能关注到位置信息,两者结合有效提升了自注意力网络提取完整位置信息的能力,从而显著提升ECG重构的效果。

**1.4.2 多头注意力网络** 多头注意力网络的功能是提取长序列的内部信息,并获得用于重构ECG信号的高阶特征。对输入数据分别进行3次相互独立的线性变换,变换矩阵均由训练得到,以3个矢量  $Q$ 、 $K$  和  $V$  表示。通过公式(4)获得  $Q$ 、 $K$ 、 $V$  的缩放点积<sup>[23]</sup>,这是输入数据单头自注意力编码的结果:

$$Attention(Q, K, V) = \text{soft max} \left( \frac{QK^T}{\sqrt{d^k}} \right) V \quad (4)$$

其中,  $d^k$  表示每个输入片段的长度,为36。当涉及到多头注意力编码时,需要对同一输入进行多次相互独立的单头注意力计算,计算后的结果被聚合,获得多头注意力编码的输出,然后通过线性变换,使输出得到与输入数据相同的维度。不同的单头注意力层可以学习不同子空间维度的时序信息,使用多头注意力允许模型学习多子空间中的相关信息。

**1.4.3 跳连接** 在深度卷积神经网络中,随着卷积层的增加,卷积神经网络的表达能力会下降,产生梯度消失的问题<sup>[24]</sup>。跳连接最初用于ResNet,通过加入跳连接,可以缓解梯度消失,在增加少量运算的情况下明显提高网络的性能。在深度多头注意力网络



中,由于自注意力运算量较大,更容易产生梯度消失的情况。因此,需要频繁地使用跳连接来减少梯度消失的情况。

**1.4.4 层标准正则化(Layer Normalization)** 网络层的输出经过线性变换作为下层网络的输入,输出直接影响下层网络输入分布,这是一种协变量转移的现象。标准正则化的目的是为了固定网络的输入分布,即固定数据的均值和方差,从而降低协变量转移的影响。传统的标准正则化(Batch Normalization)是一种纵向标准正则化,适合于深度卷积神经网络,每一个特征在整个空间都有自己的分布,不适合长时间序列。所以本论文使用的层标准正则化是一种横向标准正则化,适合于长时间序列信号,在每一个时间片段都有自己的特征分布。层标准正则化的计算公式如式(5)所示:

$$y = \gamma \frac{x - \mu}{\sqrt{\delta^2 + \epsilon}} + \beta$$

(5)

其中, $x$ 表示输入数据, $\epsilon$ 是引入的最小量(可忽略不计), $\mu$ 、 $\delta$ 分别是 $x$ 的均值和方差。 $\beta$ 和 $\gamma$ 是新的固定分布的均值和方差。

1.5 模型结构参数

输入导联为I、II、和V2导联,导联I和II的线性组合可以得到4支联III、avR、avL和avF,如公式(6)所示。因此,重构的目标导联是5条心前导联,分别为V1和V3~V6。

$$\begin{cases} \text{III} = \text{II} - \text{I} \\ \text{avR} = -(\text{I} + \text{II})/2 \\ \text{avL} = \text{I} - \text{II}/2 \\ \text{avF} = \text{II} - \text{I}/2 \end{cases}$$

(6)

编码层由12个相同的基于Transformer编码层的模块组成。每个模块由一个自注意力层、两个标准正则化层、两个完全连接层和两个跳连接组成。模块的详细结构参数如表1所示。

对于解码层,首先将编码层的输出展平为batchsize=3 564的向量,然后将其输入到输出向量大小分别为1 000和600的全连接层。

1.6 性能评估标准

采用相关系数(CC)和均方根误差(RMSE)评估ECG重构的效果:

$$\text{CC} = \frac{\sum_{n=1}^N (s_n - s_{\text{mean}})(r_n - r_{\text{mean}})}{(\sqrt{\sum_{n=1}^N (s_n - s_{\text{mean}})^2})(\sqrt{\sum_{n=1}^N (r_n - r_{\text{mean}})^2})}$$

(7)

$$\text{RMSE} = \sqrt{\frac{\sum_{n=1}^N (s_n - r_n)^2}{N}}$$

(8)

其中, $(s_n, r_n)$ 和 $(s_{\text{mean}}, r_{\text{mean}})$ 分别表示目标导联信号和

表1 模型的详细配置信息  
Table 1 Detailed configuration information of the proposed model

模块名	操作名	输入数据尺寸	输出数据尺寸
预处理	降噪&中心化	-	-
	随机采样&降采样	-	200×600
	切片	3×600×1	99×36
编码器	自适应位置编码	-	99×36
	多头自注意力编码	99×36	99×36
	相加&正则化	99×36	99×36
	全连接	99×36	99×36
	相加&正则化	99×36	99×36
解码器	全连接	99×36	600×1

重构信号的第 $n$ 个值和平均值。 $N$ 是信号中采样点的总数。作为一个反映两个信号之间相似性的参数,CC被广泛用于评估ECG重构的效果。然而,CC不能表征重构信号和目标导联原始信号之间的绝对误差,因此引入RMSE。

ECG重构的最终目的是用于心血管疾病的检测。因此,为了验证ECG重构信号的可用性,将重构的ECG数据放入用目标导联ECG数据训练的分类器中,判断是否能够检测出心肌梗死。ECG分类结果通过准确性(Acc)、敏感性(Se)、特异性(Sp)和阳性预测值(Pp)进行评估:

$$\text{Acc} = \frac{N_t - N_e}{N_t}$$

(9)

$$\text{Se} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

(10)

$$\text{Sp} = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

(11)

$$\text{Pp} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

(12)

其中, $N_t$ 表示测试心拍的总数; $N_e$ 表示错误分类的心拍的数量;FP、FN是假阳性、假阴性分类的数量;TP、TN分别表示真阳性、真阴性分类的数量。

2 实验结果

按照前述的处理,从PTB数据库的549条患者ECG记录获取109 800个心拍,随机选取80%的心拍用于训练,10%的心拍用于验证,10%的心拍用于测试。为了使测试结果更加可靠,使用五折交叉验证的方法来获得最终实验结果。各个导联重构的RMSE和CC结果如表2所示。

从表2可以看出,本文方法实现了高质量的ECG信号重构,所有重构导联的平均CC为0.984 3,平均RMSE为0.027 58;最高CC为0.993 8,最低RMSE为

表2 重构导联V1,V3~V6的CC和RMSE  
Table 2 CC and RMSE of the reconstructed V1 and V3~V6

导联	相关系数	均方根误差
V1	0.983 8	0.020 99
V3	0.993 8	0.026 15
V4	0.982 8	0.034 06
V5	0.981 3	0.031 68
V6	0.979 6	0.025 05
平均值	0.984 3	0.027 58

0.020 99。综合来看,重构V3导联的结果最佳,V6导联的重构效果最差,但也在合理范围内。

为了验证重构导联ECG数据的真实可用性,本文将导联ECG数据用于心肌梗死检测,同时也使用了目标导联原始数据用于心肌梗死检测。检测算法来自文献[25],该算法用相对简单的计算即可获得良好的检测效果。在PTB数据集上进行训练和测试,采用五折交叉验证获得最终实验结果,测试结果如表3和表4所示。可以看出,对比表4使用原始数据进行检测的结果,使用重构的ECG数据进行心肌梗死检测时,检测性能略有下降。导联V5和导联V6上重构数据的分类结果比其它导联差,原因是这两条导联的重构结果相对较差,但是依然在可接受范围内,说明本文的ECG重构算法所重构的其它导联数据,可以用于实际的心血管疾病诊断。

表3 重构导联数据用于心肌梗死检测的结果  
Table 3 Results of myocardial infarction identification  
with reconstructed leads

导联	准确性	敏感性	特异性	阳性预测值
V1	0.885 5	0.930 0	0.784 6	0.907 2
V3	0.902 7	0.954 6	0.785 1	0.909 6
V4	0.893 3	0.940 3	0.786 9	0.909 0
V5	0.868 8	0.891 6	0.816 9	0.916 9
V6	0.861 5	0.862 3	0.859 7	0.933 0
平均值	0.8824	0.915 8	0.806 6	0.915 1

为了验证本文算法的创新性和有效性,进行了3个对比试验:对应网络模型分别为基于Transformer Encoder的自适应相对位置编码算法、基于Transformer Encoder的相对位置编码算法、基于Transformer Encoder的传统固定位置编码算法。测试结果如图3和图4所示。可以看出,自适应相对位置编码算法效果最好,其CC最大,RMSE最小,平均值分别为0.94和0.32。固定位置

表4 目标导联原始数据用于心肌梗死检测的结果  
Table 4 Results of myocardial infarction identification  
with target leads

导联	准确性	敏感性	特异性	阳性预测值
V1	0.919 9	0.913 8	0.933 6	0.968 9
V3	0.941 6	0.967 5	0.882 9	0.949 3
V4	0.938 4	0.968 5	0.870 1	0.944 1
V5	0.955 3	0.968 2	0.925 8	0.967 3
V6	0.947 3	0.962 7	0.912 2	0.961 3
平均值	0.940 5	0.956 1	0.904 9	0.958 1

编码算法使用外部信号为分段的ECG信号提供位置信息,但添加外部信息会干扰原始ECG信号,虽然增加权重可以在一定程度上减少外部信号的干扰,但重构效果不佳。相对位置编码算法在不引入外部信息的情况下,增强了相邻信号之间的相关性,一定程度上提升了重构效果,但是不如自适应相对位置编码算法。简而言之,基于Transformer Encoder的自适应相对位置编码算法,是一种较为有效的ECG重构算法。




图3 3种重构模型的RMSE结果  
Figure 3 Comparison of RMSE among 3 reconstruction models




图4 3种重构模型的CC结果  
Figure 4 Comparison of CC among 3 reconstruction models

### 3 结果与讨论

本文提出了一种基于Transformer Encoder的自适应相对位置编码算法,不同于传统的神经网络,不需要使用外部信号提供位置信息,而是通过重叠切片获取心拍的处理技术,本文算法的新型神经网络可以自动地探索输入信号与目标导联之间的关系,基于局部可感知性提取局部特征,基于重叠心拍感知时序上的特征,引入了相对位置编码来增强相邻时间片段的时间信息恢复,将相对位置编码和自适应位置编码相结合,可有效地获得每个导联信号中的位置信息。与传统的基于线性的重构方法相比,采用非线性网络使本文方法在处理复杂的非线性生物信号方面更有效。通过PTB数据库的实验验证,本文算法获得了较好的导联重构效果,模型具有很好的泛化性能。通过对比实际导联原始数据和重构导联数据检测心肌梗死的效果,证明了算法的有效性和实用,可应用于可穿戴心电监测设备,在较少的导联的前提下,通过导联重构重组12导联ECG数据,为应用于高精度的心血管疾病检测算法(通常采用12导联ECG数据)提供了一条新途径。

### 【参考文献】

- [1] Maheshwari S, Acharyya A, Puddu P, et al. Reduced lead system selection methodology for reliable standard 12-lead reconstruction targeting personalised remote health monitoring applications [J]. *Comput Methods Biomech Biomed Eng*, 2014(2): 107-120.
- [2] Dower G. A lead synthesizer for the Frank system to simulate the standard 12-lead electrocardiogram [J]. *J Electrocardiol*, 1968, 1(1): 101-116.
- [3] Tsouri GR, Ostertag MH. Patient-specific 12-Lead ECG reconstruction from sparse electrodes using independent component analysis [J]. *IEEE J Biomed Health Inform*, 2014, 18(2): 476-482.
- [4] Xu ZJ, Zhou YS, Cao BB, et al. Reconstruction of 12-lead electrocardiogram based on GVM//6th International Conference on Advanced Cloud and BigData (CBD). *IEEE*, 2018: 275-280.
- [5] Lee J, Kim M, Kim J. Reconstruction of precordial lead electrocardiogram from limb leads using the state-space model [J]. *IEEE J Biomed Health Inform*, 2016, 20(3): 818-828.
- [6] Scherer JA, Jenkins JM, Nicklas JM. Synthesis of the 12-lead electrocardiogram from a 3-lead subset using patient-specific transformation vectors-an algorithmic approach to computerized signal synthesis [J]. *J Electrocardiol*, 1989, 22: 128.
- [7] Nelwan SP, Kors JA, Meij SH. Minimal lead sets for reconstruction of 12-lead electrocardiograms [J]. *J Electrocardiol*, 2000, 33: 163-166.
- [8] Nelwan SP, Kors JA, Meij SH, et al. Reconstruction of the 12-lead electrocardiogram from reduced lead sets [J]. *J Electrocardiol*, 2004,

- 37(1): 11-18.
- [9] Trobec R, Tomasic I. Synthesis of the 12-lead electrocardiogram from differential leads [J]. *IEEE Trans Inf Technol Biomed*, 2011, 15(4): 615-621.
- [10] Zhu HY, Pan Y, Cheng KT, et al. A lightweight piecewise linear synthesis method for standard 12-lead ECG signals based on adaptive region segmentation [J]. *PLoS One*, 2018, 13(10): e0206170.
- [11] Yodjaiphet A, Theera-Umporn N, Auephanwiriyakul S, et al. Electrocardiogram reconstruction using support vector regression [C]//12th IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). *IEEE*, 2012: 269-273.
- [12] Atoui H, Fayn J, Rubel P. A novel neural-network model for deriving standard 12-lead ECGs from serial three-lead ECGs: application to self-care [J]. *IEEE Trans Inf Technol Biomed*, 2010, 14(3): 883-890.
- [13] Matyschik M, Mauranen H, Karel J, et al. Feasibility of ECG reconstruction from minimal lead sets using convolutional neural networks [C]//2020 Computing in Cardiology Conference, 2020.
- [14] Wang LD, Zhou W, Xing Y, et al. A novel method based on convolutional neural networks for deriving standard 12-lead ECG from serial 3-lead ECG [J]. *Frontiers of Information Technology & Electronic Engineering*, 2019, 20(3): 405-413.
- [15] Sohn J, Yang S, Lee J, et al. Reconstruction of 12-lead electrocardiogram from a three-lead patch-type device using a LSTM network [J]. *Sensors (Basel)*, 2020, 20(11): 3278.
- [16] Kumar PS, Ramasamy M, Kallur KR, et al. Personalized LSTM models for ECG lead transformations led to fewer diagnostic errors than generalized models: deriving 12-lead ECG from lead II, V2, and V6 [J]. *Sensors (Basel)*, 2023, 23(3): 1389.
- [17] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [J]. *arXiv preprint arXiv: 1706.03762*, 2017.
- [18] Goldberger A, Amaral L, 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.
- [19] Kligfield P. Recommendations for the standardization and interpretation of the electrocardiogram: Part I: the electrocardiogram and its technology a scientific statement from the American heart association electrocardiography and arrhythmias committee, council on clinical cardiology; the American college of cardiology foundation; and the heart rhythm society endorsed by the international society for computerized electrocardiology [J]. *J Am Coll Cardiol*, 2017, 49(10): 1109-1127.
- [20] Makowski D, Pham T, Lau Z, et al. NeuroKit2: a Python toolbox for neurophysiological signal processing [J]. *Behav Res Methods*, 2021, 53(4): 1689-1696.
- [21] Jonas G, Michael A, David G, et al. Convolutional sequence to sequence learning [J]. *arXiv preprint arXiv:1705.03122v2*, 2017.
- [22] Dzmitry B, Kyunghyun C, Yoshua B. Neural machine translation by jointly learning to align and translate [C]//International Conference on Learning Representations, 2015.
- [23] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition [C]//in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. *IEEE*, 2016: 770-778.
- [24] Einthoven W. The different forms of the human electrocardiogram and their signification [J]. *Lancet*, 1912, 179: 853-861.
- [25] Acharya UR, Fujita H, Shu LO, et al. Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals [J]. *Inform Sci*, 2017, 415. Doi: 10.1016/j.ins.2017.06.027.

(编辑:薛泽玲)