

基于深度学习的桡动脉脉搏波重构方法

艾海明¹, 张清利¹, 宋现涛², 王野³, 张松³, 杨益民³

1. 北京开放大学科学技术学院, 北京 100081; 2. 首都医科大学附属北京安贞医院心内科, 北京 100029; 3. 北京工业大学环境与生命学部, 北京 100124

【摘要】目的:针对从指端脉搏波重构出桡动脉脉搏波的难题,提出一种基于深度学习的重构方法。**方法:**使用四通道数据采集系统PowerLab分别无创采集指端脉搏波和桡动脉脉搏波,对脉搏波信号噪声源进行分析,利用去基线算法、小波变换去噪算法、归一化预处理算法,得到稳定的信号波形。设计变分自编码器(VAE)网络模型结构参数,利用十折交叉验证法对744例受试者数据进行训练,建立桡动脉脉搏波预测模型。设置学习率、随机失活、正则化项共3项超参数,对VAE网络模型进行优化。**结果:**186例受试者桡动脉脉搏波重构和同步检测结果表明:低阻型和高阻型指端脉搏波经VAE网络模型建模后5%K差、20%K差、K差总方差、FIT分别为49.10%、96.70%、89.74和75.80%;低阻型和高阻型指端脉搏波经VAE网络优化模型建模后5%K差、20%K差、K差总方差、FIT分别为48.50%、94.50%、73.74和66.30%。**结论:**VAE网络模型建模及其优化方法可用于桡动脉脉搏波重构,重构精度较高,并具有较强的鲁棒性和泛化能力。

【关键词】深度学习; 脉搏波; 波形重构; 模型优化; 变分自编码器

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2024)04-0472-07

Reconstruction method for radial artery pulse wave based on deep learning

AI Haiming¹, ZHANG Qingli¹, SONG Xiantao², WANG Ye³, ZHANG Song³, YANG Yimin³

1. College of Science and Technology, Beijing Open University, Beijing 100081, China; 2. Department of Cardiology, Beijing Anzhen Hospital, Capital Medical University, Beijing 100029, China; 3. Faculty of Environment and Life, Beijing University of Technology, Beijing 100124, China

Abstract: Objective To propose a reconstruction method based on deep learning for addressing the challenge of reconstructing radial artery pulse wave from fingertip pulse wave. **Methods** A four-channel data acquisition system PowerLab was used to non-invasively acquire finger pulse waves and radial artery pulse waves. The noise source in the pulse wave signals were analyzed, and the stable signal waveforms were obtained after baseline removal, wavelet transform denoising, and normalization preprocessing. The structure and parameters of the variational auto-encoder (VAE) network model were designed. The model was trained using 10-fold cross-validation on data from 744 subjects to establish a prediction model for radial artery pulse waves; and the VAE network model was optimized by adjusting hyperparameter settings of learning rate, dropout, and regularization term. **Results** The results from the reconstruction and synchronous detection of radial artery pulse waves in 186 subjects showed that for reconstructing radial artery pulse waves from low- and high-resistance fingertip pulse waves, the 5% K difference, 20% K difference, total variance of K difference, and FIT were 49.10%, 96.70%, 89.74, and 75.80% when using VAE network model, and those were 48.50%, 94.50%, 73.74, and 66.30% when using VAE optimization model. **Conclusion** The VAE network model and its optimization method can be used for radial artery pulse wave reconstruction, with high reconstruction accuracy, strong robustness and generalization ability.

Keywords: deep learning; pulse wave; wave reconstruction; model optimization; variational auto-encoder

【收稿日期】2023-11-10

【基金项目】国家重点研发计划(2019YFC0119700);科技部科技创新2030-“新一代人工智能”重大项目(2020AAA0105800);比尔·梅琳达盖茨基金(OPP1148910);北京市教委科技项目(KM201951160001)

【作者简介】艾海明,博士,副教授,研究方向:生物医学信息检测与处理、生物医学电子与医疗仪器,E-mail: aihm@bjou.edu.cn

【通信作者】杨益民,研究生导师,研究方向:心血管血流参数无损检测,E-mail: yym@bjut.edu.cn

前言

近年来随着人口老龄化加剧、社会压力激增和不良生活方式提高等危险因素影响,我国心血管病患率及死亡率呈现上升趋势^[1-2]。心血管状态监测有助于疾病筛查,并能及时采取预防和辅助治疗措施,减少各种不可逆的并发症^[3-4]。脉搏波包含大

量的生理和病理信息,其波形特征与心血管疾病如高血压、糖尿病、动脉粥样硬化等密切相关。因此,脉搏波分析被广泛用于心血管功能评估、心血管疾病及相关并发症的无创早期诊断^[5-7]。中医脉诊是指通过中医实践,感触患者的手腕部脉搏变化来诊断疾病,这在很大程度上取决于医生的技能和经验^[8]。脉搏波结合无创血流动力学的心血管监测技术日趋成熟,常用脉搏波采集手段包括桡动脉压力脉搏波和指端容积脉搏波^[9-11]。容积脉搏波和压力脉搏波具有相同的作用机制,波形相似且生理意义基本相同^[12]。微动脉和微静脉之间微循环不畅,易引起血管、血流形态与功能发生微循环紊乱,进而促使机体组织缺氧、缺血性细胞病变,最后导致诸如血管粥样硬化、心梗及脑梗等心脑血管方面的疾病^[13-14]。指端容积脉搏波采用光电传感器获取人体指端容积脉搏血流信号,是分析和评价外周微循环状态的有效方法^[15]。脉搏能量在动脉血管内传播时,其所到之处的血液压力、血管直径与血流速度均会随之发生变化。桡动脉压力脉搏波采用压力传感器测量血液压力并转换为血管直径随时间的脉动变化曲线,从而实现无创测量动脉血管内血压波形^[16]。

桡动脉蕴含丰富的血流动力学信息,但由于个体差异性,桡动脉采集技术要求高,数据稳定性较差且长时程采集易出现偏差^[17];指端采集脉搏波受个体差异性影响小,数据稳定性可用于长时程监测,但缺点在于主动脉搏波流经手部时,脉搏信号更多地反映手部微循环,而周身心血管信息被过滤掉^[18]。为了将信息丰富的桡动脉脉搏波与波形稳定的指端脉搏波相融合,学者们建立多种从指端脉搏波到桡动脉脉搏波重构算法,但这些算法或是基于手动提取特征,亦或是基于数学函数近似,易导致特征信息丢失,且在探索指端脉搏波与桡动脉脉搏波信息关联极不便利^[19-20]。

基于神经网络的深度学习方法不断更新发展,在脉搏波信号预处理、特征分类、心血管生理参数建模等领域已得到广泛应用^[21-23]。但神经网络算法在脉搏波重构领域未见相关研究,因此针对从指端脉搏波重构出桡动脉脉搏波的难题,本文提出一种变分自编码器(Variational Auto-Encoder, VAE)深度学习网络模型(以下简称VAE网络模型),通过模型超参数“学习率”、防止过拟合“随机失活”和“正则化项”对VAE网络模型进行优化,借助脉搏波训练数据集对VAE网络模型进行训练,使用脉搏波验证数据集中低阻型、高阻型指端脉搏波作为模型输入,经VAE网络模型及其优化模型后分别输出低阻型、高阻型桡动脉脉搏波,并通过5个模型效果评价指标对比分析VAE网络模型及其优化模型建模效果。

1 资料与方法

1.1 VAE 网络模型结构及原理

VAE网络模型结构见图1,其原理是对于输入的真实样本 X_i ,VAE网络模型会假设其存在一个服从正态分布的特定后验分布,通过网络节点可深度学习得到均值 μ 和方差 σ^2 ,从而使得根据隐变量 Z_i 能够生成对应样本 \hat{X}_i ,通过最小化 X_i 和 \hat{X}_i 之间距离便能得到最佳的网络模型。

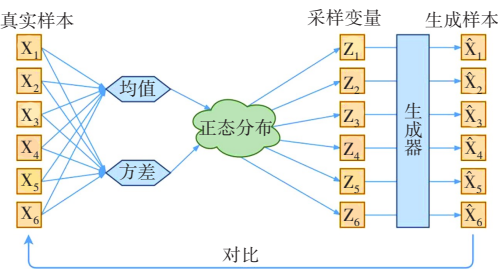


图1 VAE网络模型结构

Figure 1 VAE network model structure

1.2 VAE 网络模型建模算法

VAE网络模型中间编码网络层以概率统计来表达空间分布,通过构造编码器模型输出可能范围的统计分布,将分布值随机采样并传递给解码器模型,其网络结构及参数见图2和表1。

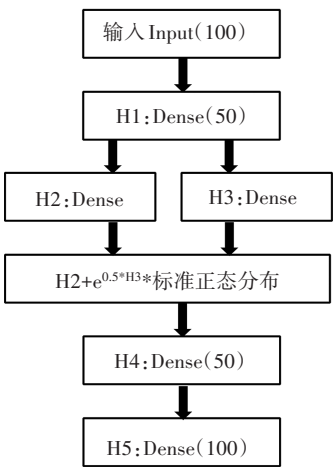


图2 VAE网络模型结构设计

Figure 2 Design of VAE network model structure

1.3 VAE 网络模型优化算法

1.3.1 模型超参数优化 常用的超参数设置有学习率、全连接层的随机失活(Dropout),通过设置训练超参数,有助于提升模型建模效果。当获取神经元节点梯度值 $\partial g/\partial \omega_i$,根据式(1)进行权值更新:

表1 VAE网络模型结构参数
Table 1 VAE network model structure parameters

结构	激活函数	卷积核个数	输出尺寸
Dense	ReLU	50	(50)
Dense	-	5	(5)
Dense	-	5	(5)
Dense	ReLU	50	(50)
Dense	Sigmoid	100	(100)

$$\omega_i = \omega_i - \gamma \frac{\partial g}{\partial \omega_i}$$

(1)

式中, ω_i 为权重, γ 为学习率, g 为目标函数。将历史梯度加入到梯度下降算法中,引导参数朝着更快更好的方向收敛,其计算原理如下:

$$v_i = \mu v_{i-1} + \gamma \frac{\partial g}{\partial \omega_i}$$

(2)

$$\omega_i = \omega_i - v_i$$

(3)

式中, v_i 表示网络节点值, μ 表示历史梯度值的权重值, $\partial g/\partial \omega_i$ 表示目标函数 g 与权重 ω_i 在网络神经元节点梯度下降最快方向。

1.3.2 防止过拟合优化 (1)Dropout。Dropout会在每个训练批次中随机屏蔽某些神经元节点的训练功能即该节点置零,从而网络权值更新不再依赖这些局部特征节点,排除训练过程无关信息,增强网络泛化能力见图3。

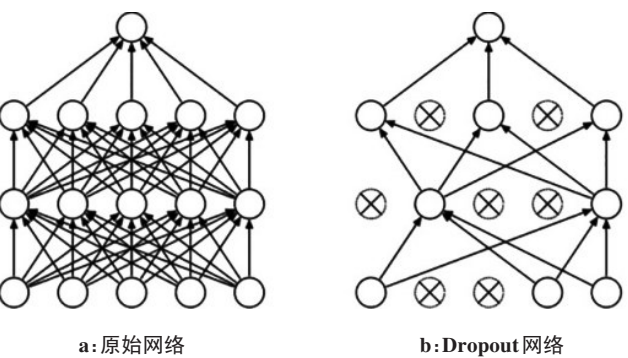


图3 随机失活示意图
Figure 3 Schematic diagram of dropout

(2)正则化项。在VAE网络模型损失函数 $J(\omega; X, y)$ 中加入惩罚项,对模型复杂度高的节点进行惩罚,其计算如下:

$$\bar{J}(\omega; X, y) = J(\omega; X, y) + \alpha \Omega(\omega)$$

(4)

式中, X, y 为训练样本和相应标签, $\Omega(\omega)$ 为惩罚项,参数 α 控制正则化强度。L1正则化参数先验分布为

拉普拉斯分布,L2正则化参数先验分布为正态分布,两者计算如下:

$$L1: \Omega(\omega) = \|\omega\|_1 = \sum_i |\omega_i|$$

(5)

$$L2: \Omega(\omega) = \|\omega\|_2^2 = \sum_i \omega_i^2$$

(6)

1.4 脉搏波信号采集获取

1.4.1 采集准备 首先询问受试者基本信息包括年龄、家族病史、心血管病史、近期服药情况,测量其生理参数包括身高、体质量、心率、血压。其次采集环境要求安静、温度适宜,采集前受试者静坐5 min确保其脉搏波信号稳定。随后采集人员中间3指寻找受试者左手腕部桡动脉搏动最强点并标记,将桡动脉压力传感器探头置于该标记处,使用绑带以恰当力度将桡动脉采集探头固定于手腕,以确保桡动脉脉搏波信号幅值和波形稳健,并使用光电指夹式脉搏波传感器采集受试者指端脉搏波信号。最后要求受试者坐姿稳健且保证手腕与心脏齐平,并通过柯式音法采集受试者血压。

1.4.2 采集方法 数据采集仪器选用ADInstruments公司的PowerLab四通道数据采集系统及LabChart分析处理软件。将数据通道设置为50 Hz数字低通滤波,采样频率为1 kHz,使用应变片式压力传感器采集桡动脉脉搏波信号,使用指夹型光电式传感器采集指端脉搏波信号。北京安贞医院心血管功能无创检测组对935例受试者分别进行桡动脉脉搏波和指端脉搏波信号采集,由于5例受试者低灌注导致信号质量低从而被剔除。930例受试者包含457例心血管功能正常健康者和473例心血管功能异常患者,受试者的基本流行病学信息见表2,每例受试者脉搏波信号采集时间6 s共计600个采样点。

表2 受试者基本流行病学信息
Table 2 Basic epidemiological information of subjects

临床信息	健康组(n=457)	患者组(n=473)
性别/例(%)		
男	224(49.02)	262(55.39)
女	233(50.98)	211(44.61)
年龄/岁	21.00±7.01	54.00±14.03
身高/cm	173.00±9.14	165.00±8.05
体质量/kg	63.00±13.10	68.00±12.01
BMI/kg·m ⁻²	21.00±3.28	25.00±4.09
收缩压/mmHg	116.00±9.20	128.00±19.30
舒张压/mmHg	73.00±8.49	76.00±12.21
心率/beat·min ⁻¹	61.00±10.90	68.00±12.03

1.4.3 实验数据分组 VAE网络模型构建过程中训练集样本数量定为总样本数量的80%(744例),验证集样本数量定为总样本数量的20%(186例)。744例受试者桡动脉脉搏波检测值和指端脉搏波检测值数据集分成10份,轮流将其中9份作为训练数据,1份作为测试数据,对VAE网络模型进行训练,10次模型训练后可建立鲁棒性VAE网络模型。验证集样本选取原则是覆盖所有受试者脉搏波波形,包括低阻型和高阻型^[24]。

1.4.4 脉搏波信号预处理 (1)噪声源分析:脉搏波信号有效成分集中在0.1~40.0 Hz频段,指端和桡动脉离脉搏波信号源的心脏较远,两者脉搏波信号幅值为微弱的毫伏级^[25-26]。因此,脉搏波信号具有频率低、幅值小、个体差异性、易受主观和客观因素影响等特点。脉搏波信号采集过程中极易受到其他信号的扰动,如由于受试者的呼吸、运动造成的基线漂移干扰,由于外界电磁场环境、附近电子设备以及信号采集系统内部电路所致的电磁干扰。

(2)去基线算法:将(桡动脉/指端)脉搏波波形沿时间轴前后各叠加1份,找到波形的极小值点,通过3次样条插值法得到基线,使用“波形采样点-基线对应点”得到1800个波形数据点,并取出中间600个数据点作为最终去基线后的波形,见图4。根据脉搏波数据统计分析,对于极小值点横坐标小于7或大于590对应单波去除,以防止存在不完整的单波波形。

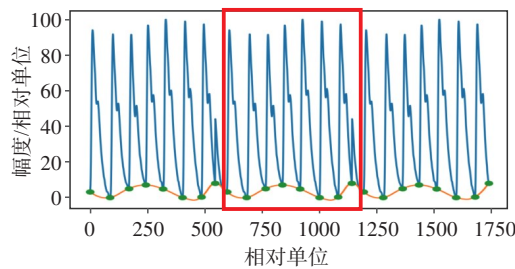


图4 去基线处理示意图

Figure 4 Schematic diagram of baseline removal processing

(3)小波变换去噪算法:首先采取db9小波函数对脉搏波信号(桡动脉/指脉)进行分解,其噪声主要集中在第1层高频段,运动伪迹分布在第8层低频段,见表3。其次由于脉搏波信号与噪声不同,经过小波分解后,在不同尺度小波系数存在差异。最后采用改进型VisuShrink的软阈值去噪算法,其原理是随着分解尺度 j 的增大,干扰信号会不断衰减。其计算方法如下:

$$\text{Vis} = \sqrt{2\ln N} / \ln(j + 1)$$

(7)

表3 各分解尺度频率带宽

Table 3 Frequency bandwidth of each decomposition scale

分解尺度/层	低频段带宽/Hz	高频段带宽/Hz
1	0~50.00	50.00~100.00
2	0~25.00	25.00~50.00
3	0~12.50	12.50~25.00
4	0~6.25	6.25~12.50
5	0~3.13	3.13~6.25
6	0~1.56	1.56~3.13
7	0~0.78	0.78~1.56
8	0~0.39	0.39~0.78

$$Y = \begin{cases} \text{sign}(X)(|X| - \text{Vis}), & |X| \geq \text{Vis} \\ 0, & |X| < \text{Vis} \end{cases} \quad (8)$$

式中, N 为离散信号采样点总数, j 为分解尺度,Vis为软阈值, X 为信号值。

(4)数据归一化算法:将(桡动脉/指端)脉搏波通过3次样条插值进行横向归一化,统一到100个采样点。并根据式(9)将波形幅值统一到[0,1]内,得到预处理后的单波:

$$y_N(i) = (y(i) - y_{\min}) / (y_{\max} - y_{\min}) \quad (9)$$

1.4.5 VAE网络模型评价指标 (1)根据文献[27]中脉搏波 K 值,定义 K 差如下:

$$K\text{差} = \frac{\text{原桡动脉单波}K\text{值} - \text{重构桡动脉单波}K\text{值}}{\text{原桡动脉单波}K\text{值}} \times 100\% \quad (10)$$

(2)统计测试集中所有样本在一定范围内 K 差的样本数占比,百分 K 差计算如下:

$$\text{百分}K\text{差} = \frac{K\text{差小于}5\%/20\%\text{样本数}}{\text{总样本数}} \times 100\% \quad (11)$$

(3)通过计算脉搏波数据样本中所有单波 K 差值、 K 差值均值、 K 差值方差,从而定义一个评价模型重构稳定性指标即 K 差总方差,其计算如下:

$$K\text{差总方差} = \frac{1}{n} \sum_{i=1}^n (K\text{差}_i - \bar{K})^2 \quad (12)$$

(4)为从细节上对比重构波形与原始波形之间差异程度,引入残差值绝对和 RL_{abs} ,其计算如下:

$$\text{RL}_{\text{abs}} = \sum_i |y_i - y'_i| \quad (13)$$

(5)为客观评价模型建模算法性能,采用波形匹配度(FIT)来评价重构效果,其计算如下:

$$\text{FIT} = \sqrt{\sum_{i=1}^N [y_i - y'_i]^2 / \sum_{i=1}^N [y_i - \bar{y}]^2} \times 100\% \quad (14)$$

2 结果

各1例低阻型、高阻型指端脉搏波经VAE网络模

型重构后得到2例桡动脉脉搏波波形结果见图5。中,低阻型波形和高阻型波形总体的5%K差、20%K

差、K差总方差、FIT 分别为49.10%、96.70%、89.74和75.80%。

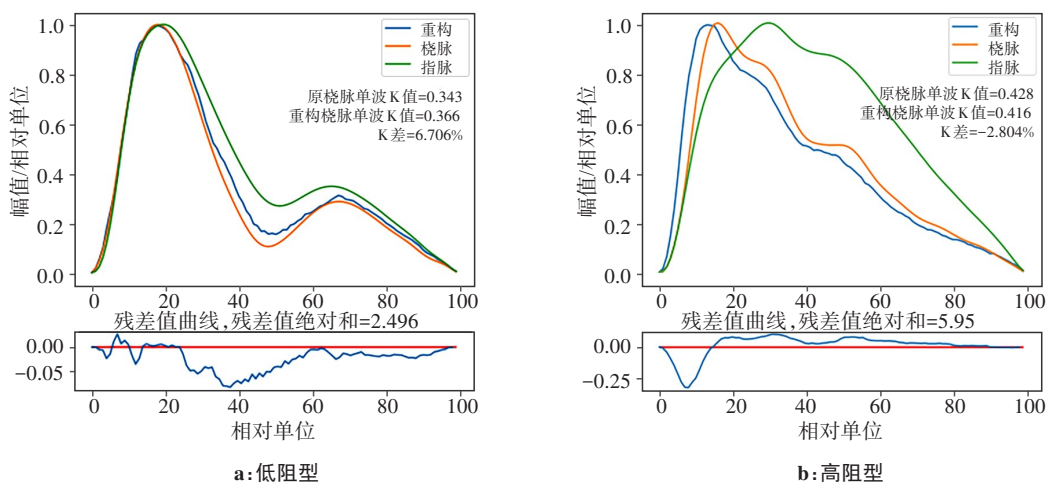


图5 桡动脉脉搏波重构结果
Figure 5 Radial artery pulse wave reconstruction results

训练轮数 epochs=500, batch_size=128, 使用Adam作为优化器,VAE模型最优调参结果是学习率($\gamma=0.002$)、调节参数($\beta_1=0.9$ 、 $\beta_2=0.999$);Dropout参数用于编码器和解码器权重共同调参,其网络搜索结果见图6;正则化参数(L1、L2)用于卷积层和全连接层正则化操作,两者均在[0,1]内以0.1为间距调参,其网络搜索结果见图7。

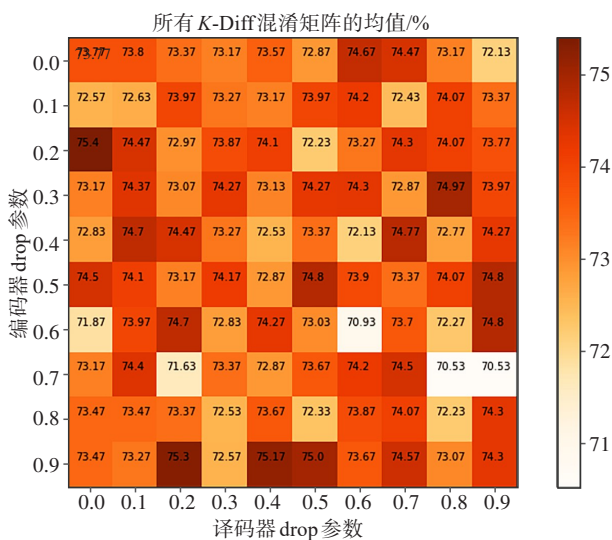


图6 Dropout调参矩阵
Figure 6 Tuning matrix for dropout parameters

图5中低阻型和高阻型桡动脉重构结果均经过上述学习率、调节参数、Dropout参数和正则化参数调

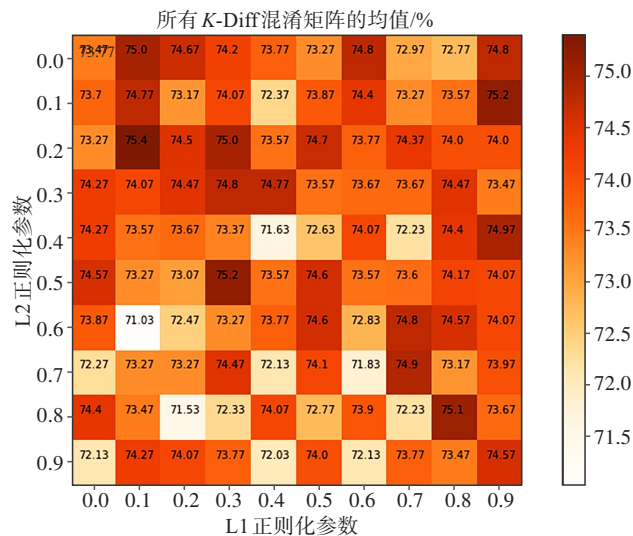


图7 L1和L2调参矩阵
Figure 7 Tuning matrix for L1 and L2 parameters

参,VAE模型优化重构结果分别见图8a和图8b。低阻型波形和高阻型波形总体的5%K差、20%K差、K差总方差、FIT 分别为48.50%、94.50%、73.74和66.30%。

3 讨论

自动编码器是一种无监督神经网络模型,它是一个“编码器-解码器”结构。自动编码器尽管可有效提取输入数据的有效特征,但是该模型中间编码信息是经训练后取值固定的参数,若编码器输入相同数据,将得到相同的中间编码向量以及固定解码输

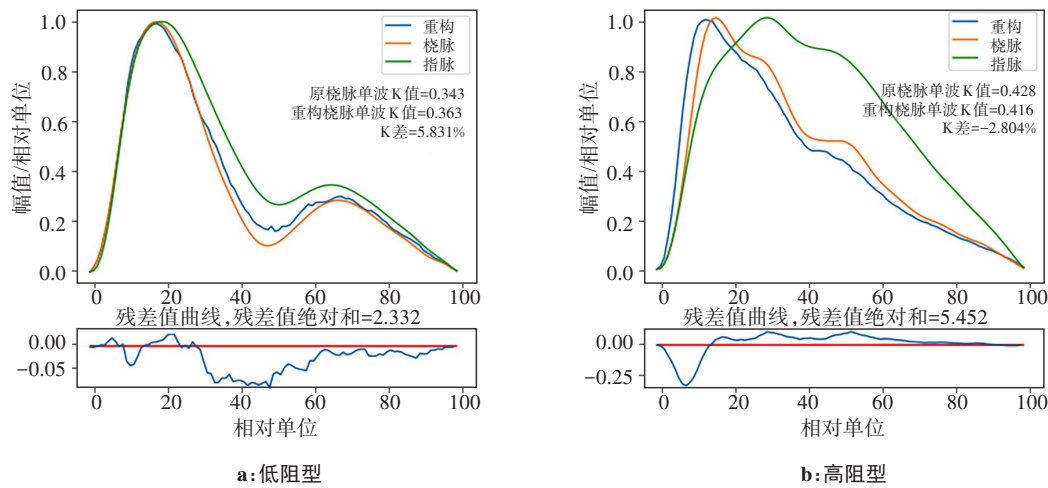


图8 基于VAE网络优化模型的桡动脉脉搏波重构结果

Figure 8 Results of radial artery pulse wave reconstruction using VAE optimization model

出^[28]。卷积自编码器是将自动编码器中全连接部分替代,借助卷积结构更好地提取特征,但并不能满足多种不同输入能得到相同的解码输出,可知自动编码器和卷积自编码器都是将输入数据压缩为潜在的状态表示模型,每个维度都表示学习到的数据属性,但其中间层编码网络参数固定,显然降低了网络泛化能力^[29]。VAE网络模型中间编码层是以概率来表达潜在空间分布,通过构造编码器统计模型,输出的分布值随机采样并传递至解码器模型,最终实现了连续、平滑的中间编码空间的潜在表示^[30]。相比于自动编码器和卷积编码器,VAE网络模型显著地增强了模型泛化能力。

由图5可知,由指端脉搏波重构出的桡动脉脉搏波波形与实测桡动脉脉搏波波形相近,且两者总体间的5%K差、20%K差、K差总方差、FIT、RL_{abs} 5个评价指标均取值合理。因此,VAE网络模型可较好地完成从指端脉搏波重构桡动脉脉搏波。VAE网络模型优化采用Adam优化器,它是一个带有动量项的优化器,其优点在于善于处理稀疏梯度和非平稳目标,对内存容量需求小,可用于不同参数计算自适应学习率,在各类学习任务中应用效果突出^[31]。学习率是每一步权重更新的跨度,保证损失值不断减小的关键,决定了神经元权值更新的速度,若取值过大会使模型优化效率过快,则可能无法优化全局最小值,易导致重建波形与原始波形存在较大差异^[32]。若取值过小会使模型训练时长增加,也易陷入局部最小值,无法优化到全局最优值,因此,通过迭代衰减训练找出合理值为0.002。

本研究学习率和训练轮数取值固定,分别调节

参数 β_1 、 β_2 ,并在5个模型评价指标控制下,确定2个调节参数(β_1 、 β_2)最优值分别为0.9、0.999,即Adam优化器初始值效果最佳。编解码器Dropout参数用于全连接结构,并采用网格搜索法对编码器和解码器权重共同调参见图6。此外,VAE网络模型每个卷积层和全连接层加入正则化操作且每层正则化系数相同,正则化参数采用网格搜索法进行权重调参见图7,并在5个模型评价指标控制下确定最优值分别为0.19、0.27。VAE网络模型优化后,低阻型桡动脉脉搏波重构结果中K差降低且波形更加贴合目标桡动脉波形,残差曲线绝对和均有降低,见图8a。对于高阻型桡动脉脉搏波重构结果中,波形和K差变化不显著,但波形残差曲线绝对和也有降低,见图8b。总体上VAE网络模型调参优化后低阻型和高阻型桡动脉脉搏波重构效果更好。

4 结论

本课题研究一种桡动脉脉搏波重构方法,包括VAE网络模型建模算法及其优化算法,其中,优化算法通过调节VAE网络模型超参数并引入防止过拟合结构,桡动脉脉搏波重构效果更佳。整个重构过程由计算机自动完成而无需手工特征提取,便于今后心血管疾病临床诊断应用。综上所述,本文提出的VAE网络模型建模及其优化方法重构精度较高,具有较强的鲁棒性和泛化能力,可很好地实现从指端脉搏波到桡动脉脉搏波重构,为后续探究脉搏波传递规律以及心血管功能无创监测仪研发提供理论依据。

【参考文献】

- [1] Zhao D, Liu J, Wang M, et al. Epidemiology of cardiovascular disease in China: current features and implications[J]. *Nat Rev Cardiol*, 2019, 16(4): 203-212.
- [2] Liu FC, Li JX, Chen JC, et al. Predicting lifetime risk for developing atherosclerotic cardiovascular disease in Chinese population: the China-PAR project[J]. *Sci Bull (Beijing)*, 2018, 63(12): 779-787.
- [3] Qiu TC, Liang CX, Ming B, et al. Comparison and optimization of cardiovascular risk scores in predicting the 4-year outcome of patients with obstructive coronary arteries disease[J]. *Ther Clin Risk Manag*, 2023, 19: 319-328.
- [4] Nardelli M, Greco A, Danzi OP, et al. Cardiovascular assessment of supportive doctor-patient communication using multi-scale and multi-lag analysis of heartbeat dynamics[J]. *Med Biol Eng Comput*, 2019, 57(1): 123-134.
- [5] Jia DG, Chao J, Li S, et al. A fiber bragg grating sensor for radial artery pulse waveform measurement[J]. *IEEE Trans Biomed Eng*, 2018, 65(4): 839-846.
- [6] Kouz K, Scheeren TW, de Backer D, et al. Pulse wave analysis to estimate cardiac output[J]. *Anesthesiology*, 2021, 134(1): 119-126.
- [7] Ma YJ, Choi J, Hourlier-Fargette A, et al. Relation between blood pressure and pulse wave velocity for human arteries[J]. *Proc Natl Acad Sci U S A*, 2018, 115(44): 11144-11149.
- [8] Shu JJ, Sun YG. Developing classification indices for Chinese pulse diagnosis[J]. *Complement Ther Med*, 2007, 15(3): 190-198.
- [9] Li GY, Watanabe K, Anzai H, et al. Pulse-wave-pattern classification with a convolutional neural network[J]. *Sci Rep*, 2019, 9(1): 14930.
- [10] Pereira T, Tran N, Gadhomi K, et al. Photoplethysmography based atrial fibrillation detection: a review[J]. *NPJ Digit Med*, 2020, 3: 3.
- [11] Wang YJ, Chen CH, Sue CY, et al. Estimation of blood pressure in the radial artery using strain-based pulse wave and photoplethysmography sensors[J]. *Micromachines (Basel)*, 2018, 9(11): 556.
- [12] Liu CY, Zheng DC, Murray A, et al. Modeling carotid and radial artery pulse pressure waveforms by curve fitting with Gaussian functions[J]. *Biomed Signal Process Control*, 2013, 8(5): 449-454.
- [13] Strain WD, Paldanius PM. Diabetes, cardiovascular disease and the microcirculation[J]. *Cardiovasc Diabetol*, 2018, 17(1): 57.
- [14] Pries AR, Badimon L, Bugiardini R, et al. Coronary vascular regulation, remodelling, and collateralization: mechanisms and clinical implications on behalf of the working group on coronary pathophysiology and microcirculation[J]. *Eur Heart J*, 2015, 36(45): 3134-3146.
- [15] Rundo F, Conoci S, Ortis A, et al. An advanced bio-inspired PhotoPlethysmography (PPG) and ECG pattern recognition system for medical assessment[J]. *Sensors*, 2018, 18(2): 405.
- [16] Liu S, Zhang SL, Zhang YT, et al. A novel flexible pressure sensor array for depth information of radial artery[J]. *Sens Actuators A*, 2018, 272: 92-101.
- [17] Jun MH, Jeon YJ, Cho JH, et al. Pulse wave response characteristics for thickness and hardness of the cover layer in pulse sensors to measure radial artery pulse[J]. *Biomed Eng Online*, 2018, 17(1): 118.
- [18] Abay TY, Kyriacou PA. Photoplethysmography for blood volumes and oxygenation changes during intermittent vascular occlusions[J]. *J Clin Monit Comput*, 2018, 32(3): 447-455.
- [19] 徐礼胜, 杜尚杰, 何殿宁, 等. 基于传递函数和指端脉搏波的桡动脉脉搏波重建[J]. *东北大学学报(自然科学版)*, 2014, 35(11): 1539-1543.
- [20] Xu LS, Du SJ, He DN, et al. Radial pulse wave reconstruction based on the transfer function and finger pulse wave [J]. *Journal of Northeastern University (Natural Science)*, 2014, 35(11): 1539-1543.
- [21] Choudhari P, Panse MS. Finite element modeling and simulation of arteries in the human arm to study the aortic pulse wave propagation [J]. *Procedia Comput Sci*, 2016, 93: 721-727.
- [22] Paviglianiti A, Randazzo V, Villata S, et al. A comparison of deep learning techniques for arterial blood pressure prediction[J]. *Cognit Comput*, 2022, 14(5): 1689-1710.
- [23] Paiva JS, Cardoso J, Pereira T. Supervised learning methods for pathological arterial pulse wave differentiation: a SVM and neural networks approach[J]. *Int J Med Inform*, 2018, 109: 30-38.
- [24] Poh MZ, Poh YC, Chan PH, et al. Diagnostic assessment of a deep learning system for detecting atrial fibrillation in pulse waveforms[J]. *Heart*, 2018, 104(23): 1921-1928.
- [25] 罗亚欣. 基于单导脉搏波的多生理参数测量研究与实现[D]. 大连: 大连理工大学, 2017.
- [26] Yuan YX. Research and realization of multi-physiological parameters measurement based on single-lead pulse wave[D]. Dalian: Dalian University of Technology, 2017.
- [27] Jiang ZX, Zhang D, Lu GM. Radial artery pulse waveform analysis based on curve fitting using discrete Fourier series [J]. *Comput Methods Programs Biomed*, 2019, 174: 25-31.
- [28] Liu WC, Fang X, Chen QQ, et al. Reliability analysis of an integrated device of ECG, PPG and pressure pulse wave for cardiovascular disease[J]. *Microelectron Reliab*, 2018, 87: 183-187.
- [29] 罗志昌, 张松, 杨益民. 脉搏波的工程分析与临床应用[M]. 北京: 科学出版社, 2006.
- [30] Luo ZC, Zhang S, Yang YM. Engineering analysis for pulse wave and its application in clinical practice[M]. Beijing: Science Press, 2006.
- [31] Sun K, Zhang JS, Zhang CX, et al. Generalized extreme learning machine autoencoder and a new deep neural network [J]. *Neurocomputing*, 2017, 230: 374-381.
- [32] Thill M, Konen W, Wang H, et al. Temporal convolutional autoencoder for unsupervised anomaly detection in time series [J]. *Appl Soft Comput*, 2021, 112: 107751.
- [33] Lu GQ, Zhao XS, Yin J, et al. Multi-task learning using variational auto-encoder for sentiment classification[J]. *Pattern Recognit Lett*, 2020, 132: 115-122.
- [34] Kohli H, Agarwal J, Kumar M. An improved method for text detection using Adam optimization algorithm[J]. *Glob Transit Proc*, 2022, 3(1): 230-234.
- [35] Yu CY, Qi X, Ma HT, et al. LLR: learning learning rates by LSTM for training neural networks[J]. *Neurocomputing*, 2020, 394: 41-50.

(编辑:陈丽霞)