



## 基于ECG信号的高精度血糖监测

李婷 叶松 李景振 马菁菁 陆瑶 洪培涛 聂泽东

### High accuracy blood glucose monitoring based on ECG signals

LI Ting, YE Song, LI Jing-zhen, MA Jing-jing, LU Yao-peng, HONG Pei-tao, NIE Ze-dong

引用本文:

李婷, 叶松, 李景振, 马菁菁, 陆瑶, 洪培涛, 聂泽东. 基于ECG信号的高精度血糖监测[J]. *工程科学学报*, 2021, 43(9): 1215–1223. doi: 10.13374/j.issn2095-9389.2021.01.12.009

LI Ting, YE Song, LI Jing-zhen, MA Jing-jing, LU Yao-peng, HONG Pei-tao, NIE Ze-dong. High accuracy blood glucose monitoring based on ECG signals[J]. *Chinese Journal of Engineering*, 2021, 43(9): 1215–1223. doi: 10.13374/j.issn2095-9389.2021.01.12.009

在线阅读 View online: <https://doi.org/10.13374/j.issn2095-9389.2021.01.12.009>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 卷积神经网络在矿区预测中的研究与应用

Research and application of convolutional neural network in mining area prediction

*工程科学学报*. 2020, 42(12): 1597 <https://doi.org/10.13374/j.issn2095-9389.2020.01.02.001>

#### 基于卷积神经网络的反无人机系统声音识别方法

Sound recognition method of an anti-UAV system based on a convolutional neural network

*工程科学学报*. 2020, 42(11): 1516 <https://doi.org/10.13374/j.issn2095-9389.2020.06.30.008>

#### 基于深度卷积神经网络的地磁导航方向适配性分析

Direction-matching-suitability analysis for geomagnetic navigation based on convolutional neural networks

*工程科学学报*. 2017, 39(10): 1584 <https://doi.org/10.13374/j.issn2095-9389.2017.10.018>

#### 一维卷积神经网络特征提取下微震能级时序预测

Time series prediction of microseismic energy level based on feature extraction of one-dimensional convolutional neural network

*工程科学学报*. 2021, 43(7): 1003 <https://doi.org/10.13374/j.issn2095-9389.2020.11.22.001>

#### 基于集成神经网络的剩余寿命预测

Remaining useful life prediction based on an integrated neural network

*工程科学学报*. 2020, 42(10): 1372 <https://doi.org/10.13374/j.issn2095-9389.2019.10.10.005>

#### 基于深度循环神经网络的协作机器人动力学误差补偿

Error compensation of collaborative robot dynamics based on deep recurrent neural network

*工程科学学报*. 2021, 43(7): 995 <https://doi.org/10.13374/j.issn2095-9389.2020.04.30.003>

# 基于 ECG 信号的高精度血糖监测

李 婷<sup>1,2)</sup>, 叶 松<sup>1)</sup>, 李景振<sup>2)</sup>, 马菁菁<sup>3)</sup>, 陆瑶芃<sup>2)</sup>, 洪培涛<sup>2)</sup>, 聂泽东<sup>2)</sup>✉

1) 桂林电子科技大学电子工程与自动化学院, 桂林 541004 2) 中国科学院深圳先进技术研究院, 深圳 518055 3) 深圳海关工业品检测技术中心, 深圳 518067

✉通信作者, E-mail: [zd.nie@siat.ac.cn](mailto:zd.nie@siat.ac.cn)

**摘 要** 连续血糖监测在糖尿病管理中具有重要的意义。目前糖尿病患者主要通过指尖采血或植入式微创传感器监测血糖, 但上述方法存在疼痛、成本昂贵、易感染等问题, 因此, 无创监测是实现连续血糖监测的理想技术。本文利用心电图 (ECG) 信号, 提出了一种血糖水平无创监测的方法: 通过获取 12 名志愿者共 60 d 756160 个 ECG 周期信号, 利用递归滤波器实现 ECG 信号的滤波, 并采用卷积神经网络和长短期记忆网络相结合 (CNN-LSTM) 的方法, 实现了血糖水平的十分类监测, 并通过实验探索了个体建模和群体建模 2 种建模方式的差异。结果表明, 在个体建模和群体建模的条件下, 血糖监测精确率分别约达到 80% 和 88%。其中群体建模 10 分类的 F1 值可达到 0.95、0.88、0.91、0.85、0.92、0.88、0.86、0.86、0.87 和 0.86。研究表明, 本文提出的基于 ECG 的无创血糖监测方法为实现血糖水平的实时、精准监测提供了一种有力的理论支撑与技术指导。

**关键词** ECG 信号; 连续血糖监测; 卷积神经网络; 长短期记忆网络; 血糖监测

**分类号** R587.1; TN911.7

## High accuracy blood glucose monitoring based on ECG signals

LI Ting<sup>1,2)</sup>, YE Song<sup>1)</sup>, LI Jing-zhen<sup>2)</sup>, MA Jing-jing<sup>3)</sup>, LU Yao-peng<sup>2)</sup>, HONG Pei-tao<sup>2)</sup>, NIE Ze-dong<sup>2)</sup>✉

1) School of Electrical Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China

2) Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China

3) The Testing and Technology Center for Industrial Products of Shenzhen Customs, Shenzhen 518067, China

✉ Corresponding author, E-mail: [zd.nie@siat.ac.cn](mailto:zd.nie@siat.ac.cn)

**ABSTRACT** Continuous glucose monitoring is important in the management of diabetes. According to statistics, diabetes is the third chronic non-infectious disease that seriously endangers people's health, followed by tumor as well as cardiovascular and cerebrovascular diseases. In 2019, globally, there were a total of 460 million diabetics aged 20–79 years, which accounted for 9.1% of the total population in this cohort. Each figure is projected to increase to 592 million and by 10.1% respectively by 2035. Currently, the methods of blood glucose monitoring can be divided into invasive, minimally invasive, and noninvasive. The main methods for blood glucose monitoring include irregular sampling of fingertip blood or consecutive measurement of interstitial fluid glucose based on implantable sensors. However, these methods have some limitations, which include pain sensation, high cost, short service life, and susceptibility. Patients need to measure their blood glucose frequently. Invasive and minimally invasive monitoring will cause physical and psychological pain. Therefore, noninvasive monitoring is one of the most promising techniques for continuous monitoring of blood glucose, and it has a broad market prospect. In this study, the electrocardiogram (ECG signals) were used to achieve the noninvasive monitoring of blood glucose levels. First, 756160 ECG periodic signals of 12 volunteers for 60 d were obtained from the experiment.

收稿日期: 2021–01–12

基金项目: 国家重点研发计划资助项目 (2018YFC2001002); 深圳市基础研究资助项目 (JCYJ20180507182231907)

Second, the ECG signals were preprocessed using an infinite impulse response filter. Furthermore, a method combining convolutional neural networks and long short-term memory networks (CNN-LSTM) was proposed for blood glucose monitoring. In Addition, two modeling methods (individual modeling and group modeling) were investigated in this study. The results show that the precision of blood glucose monitoring under the condition of individual and group modeling is 80% and 88%, respectively. The F1-score of the group modeling can reach 0.95, 0.88, 0.91, 0.85, 0.92, 0.88, 0.86, 0.86, 0.87, and 0.86. Therefore, this study indicates that the proposed method based on ECG signals can provide powerful theoretical support and technical guidance for real-time and accurate blood glucose monitoring.

**KEY WORDS** ECG signal; continuous glucose monitoring; convolutional neural network; long and short term memory network; blood glucose prediction

据统计, 糖尿病已成为继肿瘤、心脑血管疾病后的第 3 种严重危害人民健康的慢性非传染性疾病<sup>[1-2]</sup>. 2019 年全球 20~79 岁的糖尿病患者总位数 4.6 亿, 占该年龄段人口总数的 9.1%, 预计到 2035 年, 上述两个数据将分别增至 5.92 亿和 10.1%<sup>[3]</sup>. 目前糖尿病尚无根治的方法, 连续血糖监测 (Continuous glucose monitoring, CGM) 系统可实时监测患者的血糖, 为临床医生提供详细的血糖变化趋势, 以便于调控血糖水平, 减少糖尿病并发症的发生, 为预后的评估提供重要依据<sup>[4]</sup>. 目前血糖监测的方法可分为有创、微创及无创, 由于患者需要频繁测量血糖, 有创及微创监测会带来身体和心理上的痛苦, 故无创血糖监测具有重要的应用价值和市场前景<sup>[5]</sup>. 考虑到心电信号 (Electrocardiogram, ECG) 可通过可穿戴设备获取, 具有无创、便捷、舒适等优势, 本文提出了一种基于 ECG 信号的无创监测方法实现对血糖水平的实时、精准监测.

ECG 信号可使用心电采集仪器记录人体心脏电位变化<sup>[6-9]</sup>, 相关研究表明人体血糖变化会影响心脏活动<sup>[10-13]</sup>. 人体摄入食物时, 血糖水平会逐渐升高, 此时交感神经系统触发肾上腺 (特别是肾上腺髓质) 释放肾上腺素, 从而引起包括心率加快、心电传导速度加快和不应期缩短为特征的 ECG 变化; 血糖水平较低时, 也将激活交感神经系统和副交感神经系统而引起 ECG 的变化; 血糖水平正常时, 副交感神经系统会释放出乙酰胆碱激素来减慢心率<sup>[13]</sup>. 综上所述, 心电变化与血糖水平存在相关性, 因此通过分析 ECG 的变化规律有望实现血糖水平的实时监测. 血糖监测技术在近年来也在不断突破中, 并取得了较大的成果. Kandhasamy 和 Balamurali<sup>[14]</sup> 分别使用卷积神经网络 (Convolution neural networks, CNN) 与卷积神经网络和长短期记忆网络相结合 (Convolution neural networks and long short-term memory, CNN-LSTM) 算法通过 5 折交叉验证对从加州大学欧文分校数据库中获取的数

据集进行糖尿病监测, 结果显示 CNN 的监测正确率为 93.6%, 而 CNN-LSTM 的正确率最高为 95.1%. Tafa 等<sup>[15]</sup> 使用包含常规饮食、身体活动和糖尿病家族史等特征构建矩阵作为数据集, 提出了一种新的支持向量机 (Support vector machine, SVM) 和朴素贝叶斯综合改进模型来监测人体是否患有糖尿病, 其二分类监测精度高达 97.6%. 此外, 刘宇巍<sup>[16]</sup> 提出了利用超极限学习、卷积神经网络以及分数阶系统算法将血糖水平分为 6 类, 在对用户进行个性化建模且建模所用数据量较多时, 监测准确率可达 85%. 冯培华<sup>[17]</sup> 对采集的光容积脉搏波 (PhotoPlethysmography, PPG) 信号和 ECG 信号采用经验模态分解进行基线去除, 结合弹性网络、自适应增强算法、极端梯度提升 (Extreme gradient boosting, XGBoost) 和基于决策树算法的分布式梯度提升 (Light gradient boosting machine, LightGBM) 4 种算法建模监测, 获得的克拉克错误网格图 A 区均能达到 80% 以上. 本课题组前期提出了多模型分类方法用于糖尿病前期的预测<sup>[13]</sup> 并鉴别了一些重要的生理特征阻止糖尿病病情的恶化<sup>[18-19]</sup>.

纵观上述研究, 尽管已取得较大的进展, 但上述研究中对血糖水平或糖尿病的分类较少, 大多为二分类或三分类<sup>[14-15]</sup>. 同时, 大多数血糖监测输入特征局限于部分生理特征, 如: 身高、体重、文化程度、是否有家族遗传等作为神经网络的输入序列<sup>[20]</sup>. 人体的健康监测迫切需要更为精确的血糖水平, 无创的实时血糖精准监测算法有待研究. 针对上述问题, 本文提出了一种基于 ECG 的多分类的血糖监测方法. 本文研究的血糖监测算法与其他传统分析方法不同, 采用 CNN 和 LSTM 相结合的深度学习网络实现血糖水平的自动监测. 该方法兼顾了血糖监测的实时性与精准性, 测试结果表明可精准监测血糖的实时水平, 有利于推动 CGM 技术和糖尿病管理的发展, 对进一步提高血

糖监测准确度具有重要的研究意义。

## 1 数据采集及数据预处理

### 1.1 数据采集

为研究基于 ECG 信号的无创血糖监测方案的可行性,课题组在中国科学院健康信息重点实验室进行了在体实验研究(实验已获得中国科学院深圳先进技术研究院人体实验伦理管理委员会批准,批准号:SIAT-IRB-200815-H0525)。

实验之前,课题组对招募的 12 名志愿者(所有志愿者都已签署志愿者知情同意书)进行了口服葡萄糖耐量试验以确认志愿者是否为糖尿病患

者。在 12 名志愿者中,9 名为健康志愿者,3 名为糖尿病患者(A1, A2...A9 分别对应于 9 名健康志愿者;B1, B2, B3 分别对应于 3 名糖尿病志愿者)。如表 1 所示,所招募的志愿者分布在各个不同年龄段、不同性别及不同体型。其中,有 5 名男性志愿者和 7 名女性志愿者;4 名志愿者年龄小于 24 岁、5 名志愿者年龄在 24 岁到 40 岁之间、大于 40 岁的志愿者有 3 名。此外,考虑到身体质量指数(Body mass index, BMI)常用来衡量人体胖瘦程度,论文中对志愿者的 BMI 进行了分析,其中 3 名志愿者体重偏低,6 名志愿者体重正常,3 名志愿者体重超重。

表 1 12 名志愿者信息分布(人数)

Table 1 Quantity of volunteers with different body information

Gender		Age bracket			BMI		
Male	Female	≤24	(24,40)	≥40	<18.5 (Low weight)	[18.5,23] (Normal weight)	≥23 (Overweight)
5	7	4	5	3	3	6	3

正式实验通过使用采样频率为 1000 Hz、陷波滤波器开关为 ON、高通滤波器为 1.0 Hz、波动模式为 NORM 的 BIOPAC 系统(型号为 MP150)通道 2,该系统可通过电极片实现胸导联以连续获取志愿者 ECG 信号,该设备可以连接到装有 AcqKnowledge(Acq)软件的计算机(PC)并将采集的 ECG 信号转换为数字信号存储在计算机中。并在实验开始 1 d 前为志愿者佩戴德康 G6 设备以获取 CGM 数据,此设备可连续监测志愿者血糖水平,每 5 min 获得一次血糖数据。其中,每位志愿者实验持续 5 d,每天上午 2.5 h。ECG 数据采集实验如图 1 所示。本次研究使用 12 名志愿者共 60 d 756160 个 ECG 周期信号作为数据集。一个 ECG 信号周期如图 2 所示。




图 1 ECG 数据采集实验图

Fig.1 ECG data acquiring experiment

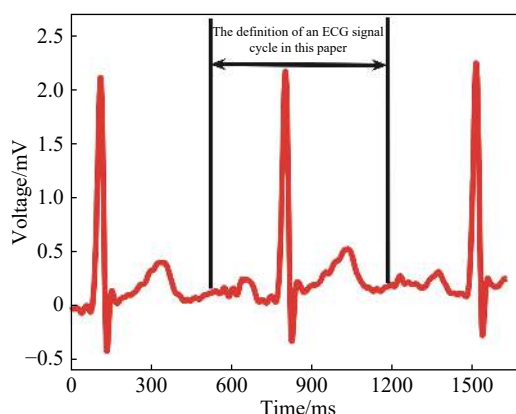


图 2 一个 ECG 信号周期示意图

Fig.2 ECG signal cycle diagram

### 1.2 数据预处理

#### 1.2.1 信号提取及滤波

如图 3(a)所示,实验所采集到的 ECG 信号中存在干扰噪声,去除 ECG 信号噪声干扰是数据预处理的关键步骤。

综合考虑自适应滤波去噪、小波去噪<sup>[21]</sup>及递归滤波器(Infinite impulse response, IIR)等去噪方法<sup>[22]</sup>,本文最终选用高通为 0.2 Hz、低通为 30 Hz 的 IIR 滤波器以滤除部分噪声。滤波前后的 ECG 信号对比如图 3 所示。滤波预处理完成后,根据 Acq 软件获取 ECG 信号中峰值点对应的时间,并利用 Matlab 软件分离出 ECG 信号的单个心跳并连接实时 CGM 的血糖值即完成初步的数据预处理。






图3 ECG信号滤波前后图像。(a)未滤波的ECG信号;(b)IIR滤波器去噪后的ECG信号

Fig.3 Images of ECG signals before and after filtering: (a) unfiltered ECG signal; (b) ECG signal followed by IIR filter

### 1.2.2 数据分类

考虑到实验所采集到的CGM数据波动较大,根据CGM数据作为神经网络的标签存在数据不均衡问题,因此从提高血糖监测模型精准性出发,本次研究在血糖数据分类时通过重复采样的方法扩充数据集以提升模型泛化能力。以采集到的12名志愿者的总数据量(694413个ECG周期信号及CGM数据)作为数据集为例,其血糖分类标签及各标签的数据量如表2所示。其中,血糖(Blood glucose, BG)大于 $14.9 \text{ mmol}\cdot\text{L}^{-1}$ 、标签为9的数据最多,共有75616个ECG周期信号及CGM数据,通过重复采样使每个标签的数据量扩充为75616个ECG周期信号,最终神经网络训练和测试所使用的数据集为10个标签的数据总量共计756160个ECG周期信号。

表2 群体建模血糖分类标签及数据量

Table 2 Blood glucose classification labels and data volumes upon group modeling

Blood glucose classification/( $\text{mmol}\cdot\text{L}^{-1}$ )	Labels	Data	
		Size	Ration/%
$\leq 5.6$	0	70164	10.1
$>5.6$ and $\leq 6.2$	1	75424	10.9
$>6.2$ and $\leq 6.6$	2	66765	9.6
$>6.6$ and $\leq 7.2$	3	75247	10.8
$>7.2$ and $\leq 7.8$	4	66346	9.5
$>7.8$ and $\leq 8.4$	5	61272	8.9
$>8.4$ and $\leq 9.1$	6	68823	9.9
$>9.1$ and $\leq 10.4$	7	68464	9.9
$>10.4$ and $\leq 14.9$	8	66292	9.5
$>14.9$	9	75616	10.9

图4显示了血糖值分别为 $5.9$ 、 $8.1$ 和 $10.5 \text{ mmol}\cdot\text{L}^{-1}$ 时不同志愿者的ECG波形。由图4可知,对于不同个体而言相同血糖水平下的ECG信号存在差异性,因此在建模时由于个体数据量有限可能会影响血糖监测效果。

## 2 模型建立

CNN由输入层、卷积层、激活层、池化层、全连接层及输出层组成,多用于实现基于大量数据或图片的分类<sup>[23-25]</sup>。设第 $n$ 层卷积核为 $p\times q$ 的矩阵 $\mathbf{k}_{p,q}^{(n)}$ ,若第 $n$ 层为卷积层,其输出的 $i\times j$ 矩阵 $\mathbf{u}_{i,j}^{(n)}$ 可表示为

$$\mathbf{u}_{i,j}^{(n)} = \sum_{p=1}^s \sum_{q=1}^s \chi_{i+p-1,j+q-1}^{(n-1)} * \mathbf{k}_{p,q}^{(n)} + b^{(n)} \quad (1)$$

式中, $b$ 为偏置参数、 $s$ 为卷积核移动的步幅、 $f$ 为激活函数、输入特征映射为 $\chi$ ,其映射的前向传播可表示为

$$\chi_{i,j}^{(n)} = f(\mathbf{u}_{i,j}^{(n)}) \quad (2)$$

为了实现神经网络重要特征的自动提取和准确分类,利用损失函数计算模型输出与真实输出之间的差异以调整CNN隐藏层的连接权重和偏移量 $b$ 以提高神经网络的泛化能力。根据链式法则,损失函数 $L$ <sup>[26]</sup>对卷积核的偏导数的偏差项可计算为<sup>[26-29]</sup>:

$$\frac{\partial L}{\partial \mathbf{k}_{p,q}^{(n)}} = \sum_i \sum_j \left( \frac{\partial L}{\partial \chi_{i,j}^{(n)}} \cdot \frac{\partial \chi_{i,j}^{(n)}}{\partial \mathbf{k}_{p,q}^{(n)}} \right) = \sum_i \sum_j \left[ \frac{\partial L}{\partial \chi_{i,j}^{(n)}} \cdot f'(\mathbf{u}_{i,j}^{(n)}) \cdot \chi_{i+p-1,j+q-1}^{(n-1)} \right] \quad (3)$$

$$\frac{\partial L}{\partial b^{(n)}} = \sum_i \sum_j \left( \frac{\partial L}{\partial \chi_{i,j}^{(n)}} \cdot \frac{\partial \chi_{i,j}^{(n)}}{\partial b^{(n)}} \right) = \sum_i \sum_j \left[ \frac{\partial L}{\partial \chi_{i,j}^{(n)}} \cdot f(\mathbf{u}_{i,j}^{(n)}) \right] \quad (4)$$

式中, $\frac{\partial L}{\partial \mathbf{k}_{p,q}^{(n)}}$ 表示损失函数对卷积核 $\mathbf{k}_{p,q}^{(n)}$ 求偏导,

$$f'(\mathbf{u}_{i,j}^{(n)}) = \frac{\partial \chi_{i,j}^{(n)}}{\partial \mathbf{u}_{i,j}^{(n)}}$$

LSTM中的内存块由一个或多个存储单元组成的<sup>[27]</sup>。对于任意长度为 $n+1$ 的数据输入序列 $\mathbf{X}(x_1, x_2, \dots, x_n, l)$ 输入到LSTM体系中,最终输出序列 $\mathbf{O}(o_1, o_2, \dots, o_n, l')$ 经过连续写、读和复位估计三个乘法单元:输入门(in)、输出门(ot)和遗忘门(fr)对记忆单元(c)在LSTM体系结构的递归隐含层中运算,其输出是以 $t=1$ 到 $t$ 的迭代方式。在时间步

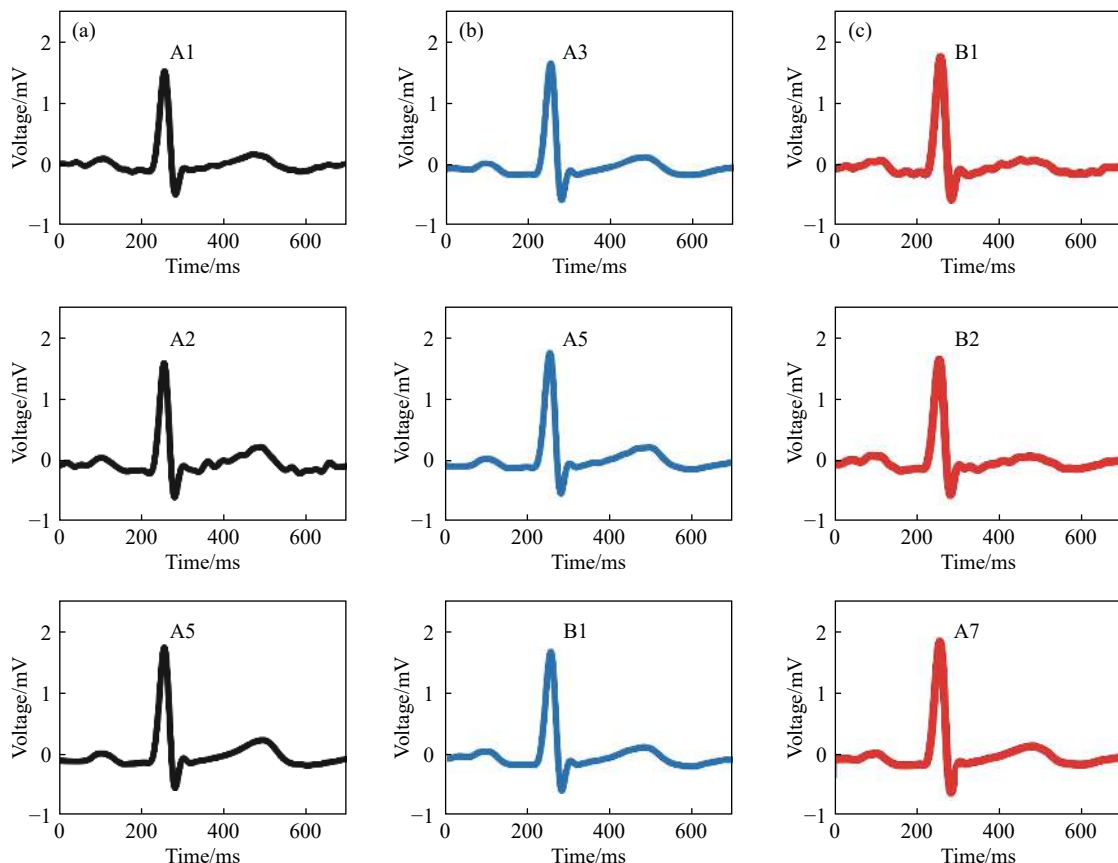


图4 不同志愿者在相同血糖水平下的一个 ECG 信号周期波形示例。(a)BG=5.9 mmol·L<sup>-1</sup>; (b)BG=8.1 mmol·L<sup>-1</sup>; (c)BG=10.5 mmol·L<sup>-1</sup>

Fig.4 ECG signal cycle waveforms at the same BG level for different subjects: (a) BG = 5.9 mmol·L<sup>-1</sup>; (b) BG = 8.1 mmol·L<sup>-1</sup>; (c) BG = 10.5 mmol·L<sup>-1</sup>

长处经 LSTM 复杂处理单元经过各层后的输出可简单地用下列公式表示<sup>[25]</sup>:

$$D_{in,t} = \sigma(w_{X,in}x_t + w_{h,in}h_{t-1} + w_{cl,in}D_{cl,t-1} + b_{in}) \quad (5)$$

$$D_{fr,t} = \sigma(w_{X,fr}X_t + w_{h,fr}h_{t-1} + w_{cl,fr}D_{cl,t-1} + b_{fr}) \quad (6)$$

$$D_{cl,t} = D_{fr,t} \odot D_{cl,t-1} + D_{in,t} \odot \tanh(w_{X,cl}X_t + w_{h,cl}h_{t-1} + b_{cl}) \quad (7)$$

$$O_t = \sigma(w_{X,ot}X_t + w_{h,ot}h_{t-1} + w_{cl,ot}D_{cl,t} + b_{ot}) \quad (8)$$

$$h_t = O_t \odot \tanh(D_{cl,t}) \quad (9)$$

其中,  $\sigma$  为 sigmoid 激活函数、 $h$  为输出、 $w$  和  $b$  为各个门对应的参数矩阵和偏置参数。

在 LSTM 的输出端使用全连接层作为分类神经网络模型输出层。经过预处理后的单个 ECG 周期及 CGM 数据输入到 CNN-LSTM 网络中, 其输出为不同的血糖标签的概率。血糖监测模型性能的评估通过血糖监测精确率 (Precision)、召回率 (Recall)、F1 值 (F1-score) 及混淆矩阵评估<sup>[30]</sup>。其原理如下:

$$P = \frac{n_{rg}}{n_{cr}} \quad (10)$$

$$R = \frac{n_{rg}}{n_{rl}} \quad (11)$$

$$F1-s = 2 \times \frac{P \times R}{P + R} \quad (12)$$

其中,  $P$  为精确率、 $R$  为召回率、F1-s 为 F1 值;  $n_{rg}$  表示分类正确的正样本数量、 $n_{cr}$  表示所有被分为正样本的数量、 $n_{rl}$  表示真正正样本的数量。混淆矩阵为可直观的看出每种分类标签监测效果的错误矩阵, 其正确监测结果都在矩阵对角线上。

### 3 高精度血糖监测模型

#### 3.1 模型建立

在本文研究的 CNN-LSTM 网络中, CNN 是由大小卷积核相结合的一维卷积、正则化过程和最大池化层组成, 最大池化输出被馈送到后续的 LSTM 层。由于模型的超参数直接影响算法的性能, 因此需要调节学习速率、隐层数、池化层步长、卷积核大小等超参数进行不同的实验验证, 以提高血糖监测模型的泛化能力<sup>[29]</sup>使其具有鲁棒性。研究所使用的模型超参数如表 3 所示。

#### 3.2 实验验证

本文使用单个 Intel(R)Core(TM)i7-7700 中的 CPU 进行训练和测试数据。经过对比不同的损失

表 3 CNN-LSTM 模型参数设置

Table 3 Parameter setting of the CNN-LSTM model

Layers	Type	Neurons	Filters	Kernel-size	Strides	Padding	Pool-size
1	Conv1d	(1,1,700)	8	3	1	0	—
2	BatchNorm1d	(8,1, 698)	—	—	—	—	—
3	ReLU	(8,1, 698)	—	—	—	—	—
4	MaxPool1d	(8,1, 698)	—	—	—	0	2
5	Conv1d	(8,1, 348)	16	5	1	0	—
6	BatchNorm1d	(16,1, 344)	—	—	—	—	—
7	ReLU	(16,1, 344)	—	—	—	—	—
8	MaxPool1d	(16,1, 344)	—	—	—	0	2
9	Conv1d	(16,1, 172)	32	8	1	0	—
10	BatchNorm1d	(32,1, 165)	—	—	—	—	—
11	ReLU	(32,1, 165)	—	—	—	—	—
12	MaxPool1d	(32,1,165)	—	—	—	0	2
13	Conv1d	(32,1, 83)	128	2	1	0	—
14	BatchNorm1d	(128,1, 82)	—	—	—	—	—
15	ReLU	(128,1, 82)	—	—	—	—	—
16	LSTM	(128,1, 82)	128	—	—	—	—
17	Fully-connected	(1,128)	—	—	—	—	—
18	Fully-connected	(1, 64)	—	—	—	—	—
19	Output	10	—	—	—	—	—

函数和学习率, 最终选择 Adam 优化器及交叉熵函数作为损失函数. 为了达到更快的收敛速度, 学习率设置为 0.001, 模型迭代的次数为 40<sup>[24]</sup>. 为研究数据集对血糖监测模型分类性能的影响, 研究分别选取两名健康志愿者和两名糖尿病患者志愿者进行个体建模、12 名志愿者群体建模分别评估分类性能.

### 3.2.1 个体建模

分别以 A1、A2、B1、B2 作为数据集, 经数据分类后输入 CNN-LSTM 血糖监测模型中, 对神经网络进行训练和测试, 其性能评估如表 4 所示. 神经网络对 4 名志愿者血糖监测的精确率分别为 79%、80%、81% 和 86%.

表 4 A1、A2、B1 和 B2 分别进行个体建模性能评估

Table 4 Individual modeling performance evaluations for A1, A2, B1, and B2

Volunteer	Precision	Recall	F1-score
A1	0.79	0.79	0.79
A2	0.80	0.80	0.80
B1	0.81	0.79	0.79
B2	0.86	0.86	0.86

### 3.2.2 群体建模

使用 12 名志愿者共计 756160 个 ECG 周期信号, 并利用 CNN-LSTM 模型对数据进行训练和测试. 计算得到的血糖水平 10 分类监测的精确率为 88.4%, 血糖监测模型的混淆矩阵和性能评估如表 5、表 6 所示.

### 3.3 结果分析及展望

本文提出了将血糖水平分为 10 类, 利用卷积神经网络和长短期记忆网络相结合的 CNN-LSTM 对人体血糖水平进行高精度监测. 首先提取 ECG 信号并使用 IIR 滤波器滤除噪声, 然后利用 Acq 及 Matlab 软件分离出完整的 ECG 周期信号, 将 ECG 周期信号及 CGM 数据集作为输入, 利用 CNN-LSTM 神经网络模型分别对个体模型和群体模型进行训练和测试. 研究表明, 群体建模的血糖监测性能优于个体建模.

相比基于回归算法或人工神经网络模型<sup>[15-17]</sup>, 本文所提出的 CNN-LSTM 模型监测血糖可达 10 分类, 精度更高. 随着可穿戴技术的发展, 实时的心电信号和血糖数据可便捷保存为数字信号, 存储在计算机中, 为可穿戴的无创血糖系统研究提供了条件<sup>[22-25]</sup>. 前人的研究大多基于人体生理

表 5 群体建模下的血糖监测混淆矩阵

Table 5 Confusion matrix for blood glucose prediction under group modeling

Labels	Predict 0	Predict 1	Predict 2	Predict 3	Predict 4	Predict 5	Predict 6	Predict 7	Predict 8	Predict 9
0	1083	45	9	10	0	0	0	0	0	0
1	37	1021	35	29	0	0	0	0	0	0
2	9	35	1093	31	0	1	0	0	0	0
3	10	90	98	926	34	0	0	0	0	0
4	0	0	0	20	1119	47	12	1	1	2
5	0	0	1	0	65	945	77	2	8	40
6	0	0	0	0	3	4	1010	99	24	50
7	0	0	0	0	2	0	19	966	87	71
8	0	0	0	0	2	0	6	43	982	105
9	0	0	0	0	5	10	24	3	27	1051

表 6 血糖监测模型性能评估

Table 6 Performance evaluation of the proposed glucose prediction model

Labels	Precision	Recall	F1-score
0	0.95	0.94	0.95
1	0.86	0.91	0.88
2	0.88	0.93	0.91
3	0.91	0.80	0.85
4	0.91	0.93	0.92
5	0.94	0.83	0.88
6	0.88	0.85	0.86
7	0.87	0.84	0.86
8	0.87	0.86	0.87
9	0.80	0.94	0.86

特征、外界环境特征或血糖数据监测血糖<sup>[20-21]</sup>, 本研究使用课题组实验获得的 ECG 周期信号和 CGM 数据, 为实现血糖水平的实时、精准监测提供了一种有力的理论支撑与技术指导。

本文对比了刘宇巍提出的基于 PPG 和 ECG 信号融合的非创血糖检测方法<sup>[16]</sup>, 发现基于 ECG 周期信号的群体建模方法, 其精确率更高, 达到 88%, 相比刘宇巍使用 5 次数据的 6 分类监测精确率和分类精度都有所提升, 表 7 对比了血糖监测模型性能。实验证明本研究方法能实现基于 ECG 信号精准监测血糖水平。在今后的血糖水平监测研究中, 将致力于规范实验流程: 首先, 增加志愿者数量及正式实验时长以扩大数据集; 其次, 提高实验设备精确性以减少 ECG 信号噪声。

表 7 血糖监测模型对比

Table 7 Comparison of glucose prediction models

Related work	Classification	Using signals	Modeling method	Model	Precision/%
Literature <sup>[16]</sup>	6	ECG+PPG	Individual modeling	ELM	83.5
				CNN	81.2
				Fractional order system	77.3
This paper	10	ECG	Individual modeling	CNN-LSTM	81.5
			Group modeling	CNN-LSTM	88.4

课题组还将进一步探索与血糖水平密切关联的生理信号, 今后的研究将考虑在数据中加入其他与人体血糖关联密切的生理数据继续优化模型, 提升模型普适性, 以致力于对高精度无创血糖仪的研制提供新思路。

#### 4 结论

(1) 提出了一种基于 ECG 的血糖水平 10 分类

监测模型, 相比于回归算法和其他人工神经网络模型, 所提出的 CNN-LSTM 模型具有较为优越的性能, 血糖监测精确率明显提升。

(2) 提出了将一个完整的 ECG 周期信号数据作为 CNN-LSTM 的输入特征, 经过对比实验表明, 与个体建模相比, 群体建模的血糖监测性能更优, 扩大数据集将会在一定程度上优化血糖监测模型的性能。



(3) 今后的研究可通过改进可穿戴式传感器的设计, 采集多种人体生理数据(如 PPG、脑电信号及血氧含量等), 实现多模生理信号的融合, 这对于今后无创血糖技术的发展及可穿戴的个性化健康监测设备的研制有重大的意义。

### 参 考 文 献

- [1] Wan X S. Review of the risk factors and intervention of type 2 diabetes. *Chin J Soc Med*, 2006, 23(4): 251  
(万晓珊. 2型糖尿病的危险因素及干预综述. *中国社会医学杂志*, 2006, 23(4): 251)
- [2] Zheng C Z, Ding D. Guiding opinions of Chinese diabetes surgery experts (2010). *Chin J Pract Surg*, 2011, 31(1): 54  
(郑成竹, 丁丹. 中国糖尿病外科治疗专家指导意见(2010). *中国实用外科杂志*, 2011, 31(1): 54)
- [3] Hou Q T, Li Y, Li S Y, et al. The global burden of diabetes mellitus. *Chin J Diabetes*, 2016, 24(1): 92  
(侯清涛, 李芸, 李舍予, 等. 全球糖尿病疾病负担现状. *中国糖尿病杂志*, 2016, 24(1): 92)
- [4] Zheng Z J. *Application of Continuous Glucose Monitoring System in Critical Illness: A Preliminary Study* [Dissertation]. Hangzhou: Zhejiang University, 2016  
(郑志骏. 连续血糖监测系统在危重患者中应用的初步研究[学位论文]. 杭州: 浙江大学, 2016)
- [5] Wei Z, Zhang B X, Shi H B, et al. The development of noninvasive detection technique of blood glucose. *China Med Equip*, 2020, 17(12): 196  
(韦哲, 张秉玺, 石恒兵, 等. 无创血糖检测技术的发展. *中国医学装备*, 2020, 17(12): 196)
- [6] Wang L P. *Study on Approach of ECG Classification with Domain Knowledge* [Dissertation]. Shanghai: East China Normal University, 2013  
(王丽苹. 融合领域知识的心电图分类方法研究[学位论文]. 上海: 华东师范大学, 2013)
- [7] Liu C Y, Yang M C, Di J N, et al. Wearable ECG: History, key technologies and future challenges. *Chin J Biomed Eng*, 2019, 38(6): 641  
(刘澄玉, 杨美程, 邸佳楠, 等. 穿戴式心电: 发展历程、核心技术与未来挑战. *中国生物医学工程学报*, 2019, 38(6): 641)
- [8] Wang J H. What are the hazards of hyperglycemia and hypoglycemia. *Prevent treat cardiovasc*, 2016(4): 19  
(王建华. 高血糖、低血糖各有哪些危害. *心血管病防治知识*, 2016(4): 19)
- [9] Acharya U R, Fujita H, Lih O S, et al. Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network. *Knowl Based Syst*, 2017, 132: 62
- [10] Pfeifer M A, Cook D, Brodsky J, et al. Quantitative evaluation of cardiac parasympathetic activity in normal and diabetic man. *Diabetes*, 1982, 31(4pt1): 339
- [11] Porumb M, Stranges S, Pescapè A, et al. Precision medicine and artificial intelligence: A pilot study on deep learning for hypoglycemic events detection based on ECG. *Sci Rep*, 2020, 10: 170
- [12] Jin X F, Liu C H, Xu T L, et al. Artificial intelligence biosensors: Challenges and prospects. *Biosens Bioelectron*, 2020, 165: 112412
- [13] Tobore I, Kandwal A, Li J Z, et al. Towards adequate prediction of prediabetes using spatiotemporal ECG and EEG feature analysis and weight-based multi-model approach. *Knowl Based Syst*, 2020, 209: 106464
- [14] Kandhasamy J P, Balamurali S. Performance analysis of classifier models to predict diabetes mellitus. *Procedia Comput Sci*, 2015, 47: 45
- [15] Tafa Z, Pervetica N, Karahoda B. An intelligent system for diabetes prediction//2015 4th Mediterranean Conference on Embedded Computing (MECO). Budva, 2015: 378
- [16] Liu Y W. *Research on Non-Invasive Blood Glucose Detection Based on PPG and ECG Fusion Signal* [Dissertation]. Guangzhou: Guangdong University of Technology, 2018  
(刘宇巍. 基于PPG和ECG信号融合的无创血糖检测方法研究[学位论文]. 广州: 广东工业大学, 2018)
- [17] Feng P H. *Research on Blood Glucose Estimation Based on Signal Processing Technology* [Dissertation]. Guangzhou: Guangdong University of Technology, 2019  
(冯培华. 基于信号处理技术的无创血糖估计研究[学位论文]. 广州: 广东工业大学, 2019)
- [18] Tobore I, Li J, Yuhang L, et al. Deep learning intervention for health care challenges: Some biomedical domain considerations. *JMIR Mhealth Uhealth*, 2019, 7(8): e11966
- [19] Tobore I, Li J, Kandwal A, et al. Statistical and spectral analysis of ECG signal towards achieving non-invasive blood glucose monitoring. *BMC Med Inform Decis Mak*, 2019, 19(Suppl6): 266
- [20] Chen W, Xie X S, Wang J L, et al. A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility. *CATENA*, 2017, 151: 147
- [21] Yang H B, Wu X W, Yuan R, et al. Establishment and verification of the prediction model and nomogram for type 2 diabetes blood glucose control [J/OL]. *J Chengdu Med College* (2020-7-22) [2020-12-30]. <http://kns.cnki.net/kcms/detail/51.1705.R.20200722.1640.004.html>  
(杨恒博, 吴行伟, 袁蓉, 等. 2型糖尿病血糖控制预测模型及列线图的建立与验证[J/OL]. *成都医学院学报*(2020-7-22) [2020-

- 12-30]. <http://kns.cnki.net/kcms/detail/51.1705.R.20200722.1640.004.html>)
- [22] Teng J L, Rong Z J, Xu Y, et al. Blood glucose prediction method based on gru. *Comput Appl Softw*, 2020, 37(10): 107  
(滕建丽, 容芷君, 许莹, 等. 基于GRU网络的血糖预测方法研究. *计算机应用与软件*, 2020, 37(10): 107)
- [23] Seyd A P T, Joseph P K, Jacob J. Automated diagnosis of diabetes using heart rate variability signals. *J Med Syst*, 2012, 36(3): 1935
- [24] Acharya U R, Fujita H, Oh S L, et al. Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Inf Sci*, 2017, 415-416: 190
- [25] Ashiquzzaman A, Tushar A K, Islam M R, et al. Reduction of overfitting in diabetes prediction using deep learning neural network//*IT Convergence and Security* 2017. Singapore, 2017: 35
- [26] Swapna G, Acharya R U, Vinithasree S, et al. Automated detection of diabetes using higher order spectral features extracted from heart rate signals. *Intell Data Anal*, 2013, 17(2): 309
- [27] Porumb M, Griffen C, Hattersley J, et al. Nocturnal low glucose detection in healthy elderly from one-lead ECG using convolutional denoising autoencoders. *Biomed Signal Process Control*, 2020, 62: 102054
- [28] Yannakoulia M, Lykou A, Kastorini C M, et al. Socio-economic and lifestyle parameters associated with diet quality of children and adolescents using classification and regression tree analysis: The DIATROFI study. *Public Health Nutr*, 2016, 19(2): 339
- [29] Yuan C X, Jia D N, Zhou S H. Research and application of convolutional neural network in mining area prediction. *Chin J Eng*, 2020, 42(12): 1597  
(袁传新, 贾东宁, 周生辉. 卷积神经网络在矿区预测中的研究与应用. *工程科学学报*, 2020, 42(12): 1597)