

# 基于注意力机制的空时融合深度学习 睡姿监测算法研究

石用伍<sup>1</sup>, 李小勇<sup>2</sup>, 石用德<sup>3</sup>, 石用民<sup>4</sup>, 谢泉<sup>5</sup>

1. 贵州省人民医院 设备处, 贵州 贵阳 550002; 2. 华南师范大学 环境学院, 广东 广州 51000; 3. 贵州省盘州市大山镇卫生院, 贵州 盘州 553507; 4. 贵州省盘州市大山镇城镇规划建设管理所, 贵州 盘州 553507; 5. 贵州大学 大数据与信息工程学院, 贵州 贵阳 550025

**[摘要]** 目的 针对用于无扰睡姿检测的心冲击图 (Ballistocardiogram, BCG) 信号特征微弱, 并且具有非线性、非平稳性强、存在噪声干扰以及信号本身具有空间和时域信息的特点, 提出了一种基于注意力机制融合空时特征的深度学习睡姿检测模型 (Deep Learning Sleeping Posture Monitoring Model, CTAM)。方法 CTAM是一种可实现端到端的实时睡姿检测方案, 通过睡眠带测试真实睡眠状态下睡姿的BCG信号, 并构建数据集进行仿真对比实验。结果 与具有类似结构的传统卷积神经网络 (Convolutional Neural Networks, CNN) 模型和空时融合的卷积-长短期记忆网络 (Convolutional Long Short-Term Memory Network, CNN-LSTM) 相比, CTAM在训练集的收敛性和测试集的准确率上均有显著的提升, 其中, 在测试集上的准确率分别较CNN模型和CNN-LSTM模型提升了1.46%和4.61%。结论 CTAM这种算法模型在基于BCG信号下能实现睡姿的实时、有效、无扰监测, 在改善睡眠质量监测领域具有较好的应用前景。

**[关键词]** 睡姿; 心冲击图; 卷积神经网络; 深度学习睡姿检测模型; 注意力机制

## Attention-Based Spatial Temporal Fusion Deep Learning Sleeping Posture Monitoring Model

SHI Yongwu<sup>1</sup>, LI Xiaoyong<sup>2</sup>, SHI Yongde<sup>3</sup>, SHI Yongmin<sup>4</sup>, XIE Quan<sup>5</sup>

1. Department of Equipment, Guizhou Provincial People's Hospital, Guiyang Guizhou 550002, China; 2. School of Environment, South China Normal University, Guangzhou Guangdong 51000, China; 3. Health Center in Dashan Town, Panzhou Guizhou 553507, China; 4. Urban Planning and Construction Management Institute of Dashan Town, Panzhou Guizhou 553507, China; 5. College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou 550025, China

**Abstract:** Objective This paper focuses on the problems of ballistocardiogram (BCG) signal used for undisturbed sleep position detection has weak signal characteristics, which are non-linearity, strong non-stationarity, noise interference, and the signal itself has spatial and temporal information. A deep learning sleeping posture monitoring model (CTAM) based on attention mechanism and spatial features was proposed. Methods CTAM is an end-to-end real-time sleeping posture detection scheme. BCG signal of sleeping posture in real sleep is tested through the sleep belt, and a data set is constructed for simulation and comparison experiments. Results The results showed that compared with the traditional convolutional neural networks (CNN) model with similar structure and the space-time fusion convolutional-long short-term memory network (CNN-LSTM), CTAM significantly improved the convergence of training set and the accuracy of test set, and the accuracy of test set was 1.46% and 4.61% higher than CNN model and CNN-LSTM model, respectively. Conclusion CTMA algorithm model based on the BCG signal to achieve real-time sleeping position, effective and non-disturbed monitoring of sleeping position, which has a good application prospect in the field of improving sleep quality monitoring.

**Key words:** sleeping posture; ballistocardiogram signal; convolution neural network; deep learning sleeping posture monitoring model; attention mechanism

**[中图分类号]** R318

doi: 10.3969/j.issn.1674-1633.2022.07.008

**[文献标识码]** A

**[文章编号]** 1674-1633(2022)07-0039-06

## 引言

一般情况下, 睡姿可以分为仰卧、俯卧、左侧卧和右侧卧<sup>[1]</sup>。睡姿是诊断和治疗体位相关性睡眠呼吸障碍的核

心指标之一<sup>[2]</sup>, 如睡眠呼吸暂停综合征等疾病与患者的睡姿具有密切的相关性<sup>[3]</sup>。近年来, 接触式的多导睡眠监测仪 (Polysom-nography, PSG) 已成为常用的睡姿监测和睡眠诊断的“金标准”<sup>[4-7]</sup>。因此, 探究一种可对用户睡姿进行实时、有效、无扰监测并改善睡眠质量的方法具有重要的临床意义。

心冲击图 (Ballistocardiogram, BCG) 是一种时序信

收稿日期: 2021-11-05

基金项目: 国家自然科学基金 (61264004); 广东省企业科技特派员项目 (GDKTP2020031800)。

通信作者: 谢泉, 教授, 主要研究方向为传感器与传感系统、材料模拟与技术。

通信作者邮箱: qxie@gzu.edu.cn

号,其可非接触式描记心脏活动及血液运行时心脏、血管冲击和反弹而引起的躯体微弱运动<sup>[8]</sup>。在不同的睡姿下,可以通过提取心冲击图呈现的不同波形差异的特征工程来实现睡姿的识别分类<sup>[9-12]</sup>。由于传统的机器学习方法大多是一些浅层的学习技术,主要通过特征工程对样本数据进行特征提取,然后进行建模和训练,得到回归或分类模型,实现对信号的回归或分类处理<sup>[12]</sup>,但这种算法容易受到特征工程的限制<sup>[13]</sup>。相对而言,深度学习是解决机器学习特征工程问题的有效途径,可以自动从数据中提取更高级的抽象特征,从而建立更好的分类模型<sup>[14-18]</sup>。本研究选用基于注意力机制的空时融合深度学习睡姿监测算法(Deep Learning Sleeping Posture Monitoring Model, CTAM)来建立睡姿监测模型,并结合卷积神经网络(Convolutional Neural Networks, CNN)和长短时记忆网络(Long Short Term Memory Network, LSTM)融合模型的优点,提出了一种全局分析BCG信号的方法,并用于对基于BCG信号的睡姿监测性能的分析。

## 1 CTAM处理方法

### 1.1 时空特征融合和注意力机制的睡姿检测模型

CTAM主要使用CNN和LSTM两种不同特点的神经网络对BCG信号进行处理,然后加入注意力机制完成BCG信号的关键特征提取。CNN与LSTM结合能够提高提取BCG信号特征的能力,同时结合注意力机制分析数据的特征有助于筛选出BCG信号中有区分度的特征,进而提高睡姿分类的准确性。采用的卷积神经网络和长短时记忆网络作的简要介绍如下。

#### 1.1.1 卷积神经网络

CNN因具有局部感知、共享权值的特性被常用于图像领域中视觉图像的局部特性及网络结构的优化<sup>[19]</sup>。作为一种前馈网络,卷积神经网络擅长于提取信号中包含的空间特征,但不能有效处理时间序列信号。通常的一维CNN模型由输入层、卷积层、激活函数、池化层和输出层五部分组成。本研究在参考LeNet-5<sup>[20]</sup>的基础上设计的卷积神经网络结构如图1所示。其中与LeNet-5不同的是,本研究中的CNN模型输入层数据格式为 $1 \times 250$ 的序列,并且分别在两个最大池化层之后加入批归一化技术(Batch Normalization, BN)、激活函数(Leaky ReLU)和丢弃技术(Dropout)。




图1 CNN模型的结构图

加入BN技术用于CNN训练不仅可以加快模型的收敛

速度,而且可以在一定程度上缓解深层网络中“梯度弥散”的问题<sup>[21]</sup>,使训练的深度学习模型更加稳定。本研究引入Leaky ReLU是为了解决ReLU的输入值为负的时候,输出始终为0,同时一阶导数也始终为0,从而导致神经元不更新参数,也就是神经元不学习的情况<sup>[22]</sup>,公式(1)定义如下。

$$f(x) = \begin{cases} x & x \geq 0 \\ scale \times x & x < 0 \end{cases} \quad (1)$$

式中 $scale$ 为小于1的非负数,当取0时,Leaky ReLU激活函数退化为ReLU函数。Dropout策是一种正则化技术,可通过对训练数据进行复杂的自适应来防止或减少CNN的过拟合,本研究随机选择一部分该层的输出作为丢弃元素实现丢弃策略。虽然CNN能精确的获取BCG信号的局部特征,但由于BCG信号也可以看作是一种时序信号,因此不能充分获取BCG信号时域特征,模型的精度和泛化性能不高。

#### 1.1.2 长短时记忆网络

由于BCG信号可以看作是一种时序信号,而LSTM是一种强大的时序信号处理和分类方法<sup>[23]</sup>。因此,本研究将LSTM作为模型的处理单元引入。两层的LSTM分类网络结构包括输入层、LSTM层、分类层和输出层,结构图如图2所示。




图2 LSTM模型的结构图

其中的单元(Cell)状态为输入的数据提供了时间依赖性,赋予了数据时间特征,LSTM通过单元状态实现长期控制,该功能主要通过输入门、遗忘门、输出门三个门实现的。状态单元的结构如图3所示,这三个门结构在图3中的位置分别对应 $i$ 、 $f$ 和 $o$ ,另外候选值 $g$ 将信息添加到单元状态。




图3 LSTM内部单元结构图

### 1.2 CATM睡姿检测模型

本研究设计的融合时空特征和注意力机制的睡眠检测模型如图4所示。CTAM由输入层、预处理层、CNN层、

LSTM 层、注意力层、softmax 层和输出层组成。CTAM 进行分类的过程如下：输入预处理后的 BCG 信号经过 CNN 层进行空域特征提取，同时经过 LSTM 层进行时域特征提取，融合后的特征信息经过注意力层根据各属性特征的重要性进行加权计算，最后通过 softmax 函数分类计算，输出分类识别结果，各层的具体定义如下。

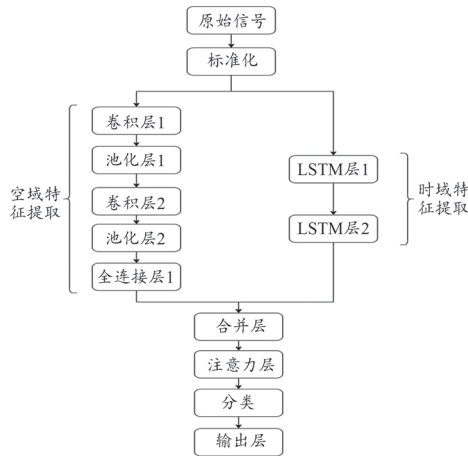


图4 CTAM的结构图

### 1.2.1 预处理层

由于不同受试者的 BCG 信号具有不同的分布，从提升模型的收敛速度、避免数值问题和消除量纲影响角度出发，将原始 BCG 信号标准化为方差为 1 和均值为 0 的序列，具体变换函数如公式 (2) 所示。

$$x' = \frac{x - \text{mean}(x)}{\text{std}(x)} \quad (2)$$

式中， $x$  为原始数据特征值， $\text{mean}(x)$  为原始数据的平均值， $\text{std}(x)$  为原始数据的标准差， $x'$  为标准化后的值。

### 1.2.2 CNN层

完成数据预处理后，使用 CNN 层提取 BCG 信号的局部特征。CNN 层是由许多一维网络堆叠而成，其中包含卷积层、批归一化技术、激活函数，同时用池化层进行采样聚合，而卷积层是 CNN 最为核心的部分，它将输入的特征图与多个卷积核卷积，生成不同的特征图，并通过卷积运算获得 BCG 信号的高级特征。

本研究中 CNN 层输入的大小可以表示为  $H \times W \times 1$ ， $H$  和  $W$  分别代表归一化后得到的数据高度和宽度（本研究所有模型中的  $H$  和  $W$  值分别为 1 和 250），假设有  $N$  个单位的层输入，使用  $M$  宽度的滤波器  $W$ ，卷积层输出为  $(N-m+1)$  个单位，卷积计算过程如公式 (3) 所示。

$$x_{i,k}^{l,j} = f(b_j + \sum_{a=1}^m w_{a,k}^l r_{i+(k-1) \times s+a-1}^{l-1,j}) \quad (3)$$

式中， $x_{i,k}^{l,j}$  为第  $l$  层第  $k$  个截面的  $j$  个特征图的第  $i$  个单位之一， $s$  为截面范围， $f$  为非线性映射，将  $x_{i,k}^{l,j}$  展成向量记为  $y_l$ 。

### 1.2.3 LSTM层

对于 BCG 信号，LSTM 能够有效利用 BCG 信号的前后信息进行特征学习。BCG 信号按顺序输入到 LSTM 层中

学习，最终获得 BCG 信号的时序特征。LSTM 通过单元状态实现长期控制，长期控制功能主要通过遗忘门、输入门、输出门三个门实现。当新的信息进入 LSTM 模型时，根据相关规则判断信息是否有效，只有满足算法认证要求的信息被保留，不一致的信息通过遗忘门被遗忘。

对于  $t$  时刻的 LSTM 模型，生成的特征向量  $h_t$  的隐藏状态如公式 (4) 所示。

$$h_t = \tan(w_{xt}x_t + w_{ht}h_{t-1} + b_h) \quad (4)$$

式中， $x_t$  为  $t$  时刻 BCG 信号的输入， $h_t$  为  $t$  时刻 LSTM 层的隐藏状态， $w$  为两个单元之间的连接权值， $b$  为偏置向量。

### 1.2.4 注意力层

在基于 BCG 信号的睡姿检测过程中，预处理后的 BCG 信号经过 CNN 层进行空域特征提取，同时经过 LSTM 层进行时域特征提取，融合后的特征重要程度存在差异。其中的显著特征通常会蕴藏更多信息量，所以应对 BCG 信号中与睡姿相关的显著特征给予更多关注，来提高睡姿检测的准确性。因此，引入注意力机制 (Attention Mechanism) [24]。

首先，利用空域特征提取模块输出的特征向量  $y_l$  和时域提取模块的特征向量  $h_t$  融合成特征向量  $s_t$  通过非线性变换得到特征向量  $u_t$ ，可用公式 (5) 表示。

$$u_t = \tanh(w_u s_t + b_u) \quad (5)$$

然后，用基于上下信息的特征向量  $u_w$  的相似度表示特征向量  $u_t$  的重要性，并获得归一化的重要性权重系数  $\alpha_t$ ， $u_w$  是一个随机初始化矩阵，该矩阵可以聚焦于  $u_t$  上的重要信息。上述的 BCG 信号特征的权重系数可用公式 (6) 表示。

$$\alpha_t = \frac{\exp(u_t^T u_w)}{\sum \exp(u_t^T u_w)} \quad (6)$$

最后，用  $\alpha_t$  与  $h_t$  的加权和计算对不同睡姿影响更为显著 BCG 信号的特征，用公式 (7) 表示。并由此利用注意力机制分析出数据特征的重要程度，得到对 BCG 信号中与睡姿检测相关更为显著的特征。

$$\text{out}_{AM} = \sum \alpha_t s_t \quad (7)$$

### 1.2.5 输出层

在输出层，将注意力层生成的特征向量  $\text{out}_{AM}$  输入到全连接到分类层进行特征压缩，然后使用 softmax 函数进行睡姿识别，得到分类结果可用公式 (8) 表示。

$$\text{result} = \text{softmax}(w_h \times \text{out}_{AM} + b_h) \quad (8)$$

式中， $w_h$  表示分类器的权值矩阵，其可以将  $\text{out}_{AM}$  映射到一个新的长度为  $h$  的向量。 $h$  为睡姿的类别数。

具体基于时空特征融合和注意力机制的睡姿检测模型训练和流程图如图 5 所示。

## 1.3 数据采集

截至目前，BCG 信号测量还未形成标准和公认的数据库，因此，本研究使用深圳市量子慧智科技有限公司开发的基于 PVDF 传感器的睡眠带对受试者进行睡姿数据采集。其中数据场景包括睡姿（仰卧、俯卧、左侧卧和右侧卧）、



离床和体动, 离床和体动可以降低睡姿检测和其他体征检测算法的误判, 数据采集步骤如下。

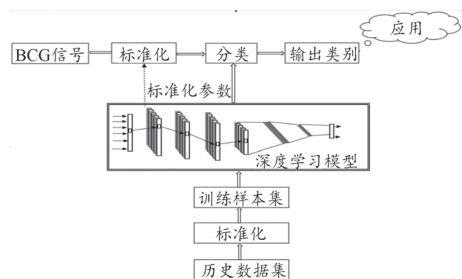


图5 深度学习的睡姿检测模型训练和工作流程框图

① 记录受测人员身份和体征信息, 包括姓名、性别、年龄、身高和体重; ② 放置睡眠带连接数据采集设备, 持续 10 min; ③ 让受测人员躺在睡眠带上模拟体动 10 min, 包括翻身、转体和轻微体动动作; ④ 在某一固定睡姿下睡眠持续 120 min; ⑤ 完成后, 起身离床, 继续采集 10 min 数据后停止, 保存数据。其中采集 BCG 信号具体睡姿、时长和受测人员数的信息如表 1 所示。

表1 BCG信号采集信息记录表

睡姿	离床 /min	体动 /min	正常睡眠状态 /min	离床 /min	人数/名
仰卧	10	20	120	10	20 (10男10女)
俯卧	10	20	120	10	20 (10男10女)
左侧卧	10	20	120	10	20 (10男10女)
右侧卧	10	20	120	10	20 (10男10女)

采集的四种睡姿(仰卧、俯卧、左侧卧和右侧卧)、体动和离床对应的典型 BCG 信号波形如图 6 所示。从图 6 中可以看出, 体动和离床有较为明显的区分特征, 仰卧、俯卧和侧卧三种睡姿也有较为明显的区分特征, 而左侧卧和右侧卧睡姿下对应的 BCG 信号波形相似度较高, 提取特征进行分类需要一定的经验, 表明需使用深度学习进行分类识别。




图6 四种睡姿、体动和离床对应的BCG信号波形图

注: a. 仰卧; b. 俯卧; c. 右侧卧; d. 左侧卧; e. 体动; f. 离床。

本研究使用睡眠带采集的 BCG 信号采样率为 50 Hz。因此, 在对检测睡姿的 BCG 信号进行训练、验证提出的 CTAM 模型之前首先从采集的数据集中选取 5 s 的数据且用 1 s 的时间窗进行截取, 标注对应的标签, 即对应四种睡姿(仰卧、俯卧、左侧卧和右侧卧)、体动和离床中一类,

并且对两大类中间的 BCG 信号做部分丢弃, 消除边界效应。最后共计获得样本总数为 48000 个, 随机取其中的 40000 个样本作为训练集, 余下的 8000 个样本为测试集。

#### 1.4 模型评价指标

为了对模型进行评价, 本研究选取常用评价分类模型性能的 3 种指标: 准确率 (Accuracy, Ac)、精确率 (Precision, P) 和召回率 (Recall, R)。对应的表达式如公式 (9) 所示。

$$Ac = \frac{TP + TN}{TP + FN + FP + TN}$$

$$P = \frac{TP}{TP + FP}$$

$$R = \frac{TP}{TP + FN}$$
(9)

式中, TP (True Positive) 是正类被归为正类的样本数, 即阳性; FP (False Positive) 是正类被归为负类的样本数, 即假阳性; FN (False Negative) 是负类被归为正类的样本数, 即假阴性; TN (True Negative) 是负类被归为负类的样本数, 即真阴性。

#### 1.5 实验运行环境和参数配置

本研究中所有模型均在配置为 Core i9-10900K CPU, 32 GB 内存和 GeForce RTX3090 显卡的计算机上进行训练和测试。计算机操作系统为 ubuntu 18.04 LTS 版, 所有模型使用 Tensorflow 2.3.1 框架实现。仿真实验中所有模型的初始化参数都采用相同的配置, 这样使得所有模型都在相对公平的条件进行对比, 更有利于反映出 CNN 模型、CNN-LSTM 模型和 CTAM 模型的真实性能。其中, CNN 层和全连接层的权系数初始化方法都使用 He 等<sup>[25]</sup>提出的 Kaiming 法, 该方法有利于加速模型的收敛速度, LSTM 层的权系数初始化方法使用正交方法<sup>[26]</sup>。所有模型的优化器都使用 Adam 方法, 该方法具有更快的收敛速度和稳定性<sup>[27]</sup>, 并且在模型训练过程中可以不使用验证集。具体参数配置如表 2 所示。

表2 CNN、CNN-LSTM和CTAM的参数配置

CNN层	LSTM层	全连接层	优化器	学习率
Kaiming法	正交法	Kaiming法	Adam	1e-3
损失函数	Leaky ReLu	训练轮数	丢弃率	批尺寸
交叉熵	0.01	20	0.2	4000

## 2 结果

CNN 模型、CNN-LSTM 模型和 CTAM 模型训练过程的准确率曲线和损失函数曲线如图 7 所示, 可以看出, CTAM 模型具有最快的速度使得训练过程分类准确率达到稳定状态, 同时具有最快的速度使得损失函数值达到接近 0 的稳定状态, 而 CNN-LSTM 模型次之。综合训练过程分类准确率和损失函数收敛曲线可以看出, 在模型的收敛速度上性能依次降低的顺序为 CTAM 模型、CNN-LSTM 模型和 CNN 模型, 这也体现出了 CTAM 模型相对其他两种模型具有更快的收敛速度。

CNN、CNN-LSTM 和 CTAM 模型训练后测试集上得

到性能指标,如表3所示,CTAM模型的准确率最高,为99.49%,分别较CNN模型和CNN-LSTM模型的98.03%和94.88%有1.46%和4.61%的提升。

综合实验结果中的训练过程准确率曲线、训练过程损失函数值曲线和各模型预测分类的准确率,可以看出CTAM模型相比CNN模型、CNN-LSTM模型在入侵检测中具有更好的性能。其中CTAM模型在对随机分割得到的8000个测试样本的预测分类混淆矩阵如图8所示,可以看出,容易出现混淆的是右侧卧和左侧卧,其他状态的分类准确率达到了100%,这也印证图6所示的各状态波形图直观印象。综合上述实验结果,说明空时融合技术和注意力机制模型在基于BCG信号的睡姿检测中的有效性较高。




图7 CNN、CNN-LSTM和CTAM准确率 and 损失函数对比曲线图

表3 各模型性能指标对比

模式	准确率	精确度	召回率
CNN	0.9488	0.9498	0.9498
CNN-LSTM	0.9803	0.9811	0.9807
CTAM	0.9949	0.9952	0.9952




图8 CTAM模型对测试集分类的混淆矩阵

注:纵坐标上的数值表示颜色的深浅程度,颜色越深代表数值越大。

### 3 讨论

目前,在基于BCG信号睡姿检测方面的深度学习模型较少,相关研究人员对非接触式睡姿监测技术,如基于红外图像识别<sup>[6]</sup>、基于压力的阵列传感等技术的睡姿识别

模型<sup>[7]</sup>等进行了广泛的研究,并获得了较好的效果。针对BCG信号用于睡姿检测的特点及当前常用模型特征提取不充分的问题,本研究创新性地利用BCG信号空时域信息,将CNN和LSTM提取的特征进行融合,提出了注意力机制下的空时特征融合深度学习模型CTAM,充分利用了各网络的优势,并引入注意力机制完成空时融合后的关键特征提取,获得了BCG信号用以睡姿监测的最优特征表示。该模型避免了人工特征存在的有区分度特征表达不充分的问题,同时提升了模型的收敛速度和泛化性能,使得本研究提出的模型更适合基于BCG信号的睡姿监测。今后将进一步增加验证样本量,深化该算法模型在健康领域的应用研究。

### 4 结论

CTAM模型实现了端到端的实时睡姿检测方案,通过睡眠带测试真实睡眠状态下睡姿的BCG信号,构建数据集进行仿真对比实验。结果表明,相比具有类似结构的传统CNN模型和空时融合的CNN-LSTM模型,CTAM在训练集的收敛性和测试集的准确率上都有显著的提升,其中,在测试集上的准确率分别较CNN模型和CNN-LSTM模型提升了1.46%和4.61%。该算法模型在基于BCG信号实现睡姿的实时、有效、无扰监测和睡眠质量监测领域具有较好的应用前景。

#### [参考文献]

- [1] Yu JF, Chen YS, Li HY, et al. Sleeping position can reduce the effect of snoring on sleeping partners[J]. *J Acoust Society Am*, 2014, 135(4): 2165.
- [2] 张翼, 宾光宇, 吴水才. 一种可穿戴式多参数心脏活动监测设备的设计[J]. *中国医疗设备*, 2018, 33(3): 18-21.
- [3] Teeraprairuk B, Chirakalwasan N, Simon R, et al. Clinical and polysomnographic data of positional sleep apnea and its predictors[J]. *Sleep Breath*, 2012, 16(4): 1167-1172.
- [4] 张丽枫, 杨萍. 动态心电图睡眠呼吸联合监测与多导睡眠仪监测对比研究[J]. *当代医学*, 2020, 26(7): 165-166.
- [5] 段鹏慧, 严加勇, 段世梅, 等. 基于心冲击信号的自动睡眠分期算法研究进展[J]. *软件导刊*, 2019, 18(5): 5-8, 12.
- [6] 苏鹭梅, 张辑, 徐敏. 一种基于红外图像的夜间人体睡姿监测方法及系统: 中国, CN201610231511.3[P]. 2016-09-07.
- [7] Mineharu A, Kuwahara N, Morimoto K. A study of automatic classification of sleeping position by a pressure-sensitive sensor[A]. 2015 International Conference on Informatics, Electronics and Vision (ICIEV)[C]. IEEE, 2015.
- [8] 李倩, 王飞, 刘芊, 等. 心冲击图信号的采集和特征分析及其应用[J]. *中国医学物理学杂志*, 2020, 37: 89-95.
- [9] Liu M, Jiang F, Jiang H, et al. Low-power, noninvasive measurement system for wearable ballistocardiography in

- sitting and standing positions[J].*Comput Ind*,2017,91:24-32.
- [10] Gou H,Yan L,Xiao J,*et al*.A gait recognition system based on SVM and accelerations[J].*Matec Web Conf*,2015,30:06001.
- [11] Yu LL,Tan BX,Meng TX.The automatic classification of ecg based on bp neural network[J].*Adv Mater Res*,2010,121-122:111-116.
- [12] Li X,Yi X, Liu Z,*et al*.Application of novel hybrid deep leaning model for cleaner production in a paper industrial wastewater treatment system[J].*J Clean Product*,2021(2):126343.
- [13] Avanzo M,Wei L,Stancanella J,*et al*.Machine and deep learning methods for radiomics[J].*Med Phys*,2020,47(5):e185-e202.
- [14] Peng Y,Kondo N,Fujiura T,*et al*.Dam behavior patterns in Japanese black beef cattle prior to calving: Automated detection using LSTM-RNN[J].*Comput Electron Agric*,2020,169:105178.
- [15] Chen Y,Chen W. Finger ECG based two-phase authentication using 1D convolutional neural networks[J].*Annu Int Conf IEEE Eng Med Biol Soc*,2018,2018:336-339.
- [16] Kim BH,Pyun JY.ECG Identification for personal authentication using LSTM-based deep recurrent neural networks[J].*Sensors (Basel)*,2020,20(11):3069.
- [17] Saadatnejad S,Oveisi M,Hashemi M.LSTM-based ECG classification for continuous monitoring on personal wearable devices[J].*IEEE J Biomed Health Inform*,2020,24(2):515-523.
- [18] Dithapron A,Banluesombatkul N,Ketrat S,*et al*.Universal Joint feature extraction for P300 EEG classification using multi-task autoencoder[J].*IEEE Access*,2019,7(99):68415-68428.
- [19] Liu F,Shen C,Lin G,*et al*.Learning depth from single monocular images using deep convolutional neural fields[J].*IEEE Trans Pattern Anal Mach Intell*,2016,38(10):2024-2039.
- [20] El-Sawy A,El-Bakry H,Loey M.CNN for handwritten arabic digits recognition based on lenet-5[A].International Conference on Advanced Intelligent Systems and Informatics[C]. Cham,2016.
- [21] Zhang X,Lu S,Wang SH,*et al*.Diagnosis of COVID-19 Pneumonia via a novel deep learning architecture[J].*J Comput Sci Technol*,2022,37(2):330-343.
- [22] Liu Y,Wang X,Wang L,*et al*.A modified leaky ReLU scheme (MLRS) for topology optimization with multiple materials[J].*Appl Math Comput*,2019,352:188-204.
- [23] Karevan Z,Suykens JAK.Transductive LSTM for time-series prediction: An application to weather forecasting[J].*Neural Netw*,2020,125:1-9.
- [24] Xiao T,Xu Y,Yang K,*et al*. The application of two-level attention models in deep convolutional neural network for fine-grained image classification[A].2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)[C]. IEEE,2015.
- [25] He K,Zhang X,Ren S,*et al*.Delving deep into rectifiers: surpassing human-level performance on imageNet classification[A]. CVPR[C].IEEE Computer Society,2015.
- [26] Grzegorzczak K,Kurczel M,Wojcik PI.Encouraging orthogonality between weight vectors in pretrained deep neural networks[J].*Neurocomputing*,2016,202(19):84-90.
- [27] Chang ZH,Yang Z,Chen WB.Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform[J].*Energy*,2019,187:115804.

本文编辑 盛伟

## 参考文献格式编排举例

### (5) 国际、国家标准格式(文献类型标识:S)

[序号] 标准编号,标准名称[S].出版地(任选):出版者(任选),出版年(任选).

[9] GB/T 6663.1-2007,直热式负温度系数热敏电阻器第1部分:总规范[S].

[10] ISO 4,Information and Documentation—Rules for the Abbreviation of Title Words and Titles of Publications[S].

### (6) 技术报告(文献类型标识:R)

[序号] 主要责任者.报告题名[R].编号,出版年.

[11] 冯西桥.核反应堆压力管道与压力容器的LBB分析[R].北京:清华大学核能技术设计研究院,1997.

[12] Kyungmoon N. Automatic landing system design using fuzzy logic[R].AIAA-98-4484,1998.

### (7) 专利(文献类型标识:P)

[序号] 专利所有者.专利题名:专利国别,专利编号[P].公告日期.

[13] 姜锡洲.一种温热外敷药制备方案:中国,88105607.3[P].1989-07-06.

[14] Kramer DP. Hermetic Fiber Optic to Metal Connection Technique:USP,5143531[P].1992.