

基于时频信息融合网络的非干扰呼吸检测方法^①

沈建飞^② 陈益强^③ 谷 洋

(^{*} 移动计算与新型终端北京市重点实验室 北京 100190)

(^{**} 中国科学院计算技术研究所 北京 100190)

(^{***} 中国科学院大学 北京 100049)

摘要 为了能够克服复杂环境中的噪声影响,实现基于多普勒雷达的鲁棒呼吸信号检测,本文提出了一种基于时频信息融合网络的非干扰呼吸信号检测方法。该方法利用多普勒雷达采集用户的胸腔运动信息,提取双通道混频信号(I 和 Q 通道),从时域和频域 2 个维度,构建时频信息融合网络进行呼吸频率的识别。针对时域信号,使用长短期记忆(LSTM)网络提取信号的有效周期信息;针对频域信息,使用选带傅里叶变换(ZoomFFT)实现细粒度的频域特征计算,并结合卷积神经网络(CNN)提取频域特征的有效信息;最后,融合 2 个层面的信息,通过 Lowess 平滑方法,实现对用户呼吸频率的精准检测。实验表明,该方法比其他常用信号处理方法识别平均误差、标准差更小,对不同距离、不同朝向的呼吸都可以进行有效识别。

关键词 非接触检测; 雷达检测; 生理检测; 呼吸检测

0 引言

针对生理信号的非干扰感知研究,受到越来越多的重视,因为其可以在不对用户产生任何干扰的前提下,进行基本的生理信号采集。同时,非干扰感知的方法对于特定场景,如睡眠监测等方面有特殊的优势。

呼吸是较常用的生理信号,目前呼吸的传统检测方式有阻抗式、光电容积脉搏波描记、呼吸感应体积描记、电信号提取法等方法。这些方法虽然测量结果较准确,但是都需要与用户有直接的身体接触,将传感器或面罩紧贴皮肤进行检测^[1],大幅降低了用户在检测过程中的舒适度,只适用于短时间内的检测,无法满足用户对生理信息的长期监测需求。尤其是对睡眠中的呼吸检测和烧伤病人、部分

皮肤病人的生理数据检测,接触式的方法都会对用户造成一定的负面影响,甚至二次伤害^[2-6]。

非干扰的呼吸检测,目前的研究主要集中于使用视频^[7]、热力图^[8]、超声波^[9]、WiFi^[10,11]、雷达^[12-14]等方式来实现对用户生理参数的收集,再通过信号处理、信号识别等技术提取周期信息,实现呼吸频率的实时检测。其中,通过雷达方式进行呼吸检测的方法,在用户相对静止的情况下有更好的识别效果,因电磁波能够穿透衣物、被褥,直接传播到人体表面^[15],因此其能够更直接地检测到人体胸腔的振动,计算得到更准确的呼吸信息^[16]。通过雷达检测呼吸的方法,根据其信号发射和接收方式的不同又可进行细分,比较主流的方式为如下几种:多普勒雷达(Doppler radar)^[17-19],它通过发射和接收连续的定频电磁波,利用多普勒效应来进行检测;调频连续波雷达(frequency modulated continuous wave ra-

^① 国家重点研发计划(2017YFC0803401),北京市自然科学基金(4194091)和北京市科技计划(Z171100000117001)资助项目。

^② 男,1989 年生,博士生;研究方向:可穿戴技术,非干扰生理感知,普适计算等;E-mail: shenjianfei@ict.ac.cn

^③ 通信作者, E-mail: yqchen@ict.ac.cn

(收稿日期:2019-11-26)

dar, FMCW Radar)^[20,21], 通过发射和接收持续调频的连续电磁波, 分析接收信号频率的变化来实现检测; 超宽带雷达(ultra-wideband radar, UWB Radar)^[22,23]通过发出超宽带脉冲电磁波来进行呼吸检测。其中, 由于对周期信号有很好的识别效果, 多普勒雷达是非干扰呼吸检测中使用较多的检测方案。

基于多普勒雷达的呼吸检测方法, 利用电磁波信号被用户身体反射时产生的多普勒效应(Doppler effect), 来提取出用户的呼吸信息^[24]。目前国内外的研究多从数字信号处理角度进行分析, 通过线性、非线性解调雷达信号后, 结合呼吸频率的先验信息进行呼吸的检测^[25]。但环境干扰是影响识别精度的重要因素, 传统的信号处理方法, 在实际环境中很难保证呼吸的精准鲁棒识别。

目前, 在模式识别领域, 机器学习方法已经得到了广泛的应用, 其在图像识别^[26-28]、数据分析^[29,30]等方面已经实现很好的识别结果。在基于雷达的呼吸检测领域, 已有的研究主要集中在通过信号处理方法识别到呼吸频率后, 结合机器学习方法进一步对用户的睡眠、情绪等状态进行分类^[31,32]研究。而本文针对雷达识别过程中的环境干扰问题, 结合机器学习的回归模型, 提出了使用时频融合网络模型直接对呼吸频率进行识别的方法。

本文的主要创新点和贡献归纳如下。

(1) 针对多普勒雷达的呼吸信号检测, 提出了基于神经网络直接获得用户呼吸频率的识别模型。

(2) 提出了通过长短期记忆网络(long short-term memory, LSTM)提取时域信息, 使用选带傅里叶变换(zoom fast Fourier transform, ZoomFFT)提取精细化频域信息, 然后融合神经网络模型, 来对呼吸频率进行识别的方法。

(3) 提出了使用局部加权回归平滑(locally weighted scatterplot smoothing, Lowess)的后处理算法来对模型的输出进行滤波, 得到稳定鲁棒的呼吸频率识别结果。

(4) 采集真实雷达数据, 对时频融合网络模型进行了多角度的实验测试, 实验结果表明该模型对于不同距离、不同朝向和不同个体的呼吸都可以进

行有效的识别。

1 基于多普勒雷达的呼吸信号检测原理

基于多普勒雷达的呼吸信号检测方法, 主要通过连续波(continue wave, CW) 雷达发射模块和正交接收器来完成雷达信号的发射和接收, 正交接收器的使用是为了去除 NULL 点问题(NULL 点会导致信号变化幅度过小, 不利于对信号进行分析)^[33], 其整体原理如图 1 所示。由图可知, 系统通过信号源产生定频电磁波信号, 经由发射器持续发射, 当电磁波传播到达人体表面后, 会有部分的电磁波被人体吸收, 但是大部分的信号会被人体的皮肤和组织反射回来, 最终被雷达的接收器接收。

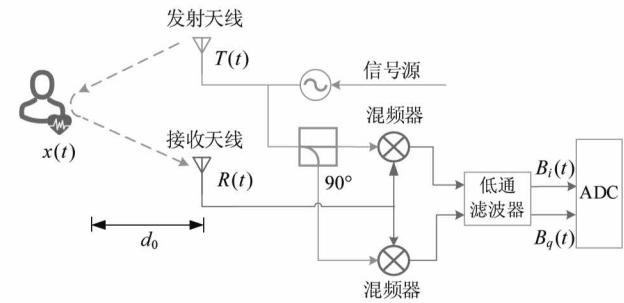


图 1 多普勒雷达测量原理图

在本文中, 设定信号源的发射频率为 f , 波长为 $\lambda = c/f$, 其中 c 为光速, 同时考虑发生元器件产生的噪声 $\phi(t)$, 则发射信号 $T(t)$ 可以用如下公式表示:

$$T(t) = \cos(2\pi ft + \phi(t)) \quad (1)$$

当电磁波信号 $T(t)$ 传播距离 d_0 到达人体表面后, 经由人体表面反射, 部分信号被接收器接收。在此将由于呼吸和心跳引起的胸腔位移定义为 $x_r(t)$, 由心跳引起的胸腔位移定义为 $x_h(t)$, 则最终的胸腔位移为两者的叠加 $x(t) = x_r(t) + x_h(t)$ 。因此, 接收到的信号可以近似表示为

$$R(t) \approx A_r \cos\left(2\pi ft - \frac{4\pi d_0}{\lambda} - \frac{4\pi x(t)}{\lambda} + \phi\left(t - \frac{2d_0}{c}\right)\right) \quad (2)$$

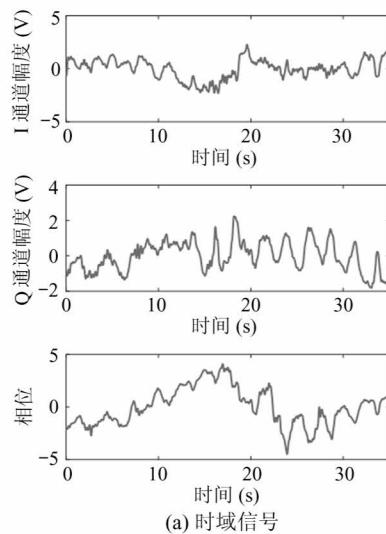
从上式可以看出 $R(t)$ 为一个增加了延时和幅值减小版本的 $T(t)$, 其中 A_r 为幅度减少的系数。

胸腔运动 $x(t)$ 与 d_0 、延时后的相位噪声 $\phi(t - 2d_0/c)$ 共同构成 $R(t)$ 的相位信息。雷达接收到的信号将通过一个前置放大器 (low noise amplifier, LNA) 对信号进行放大, 并通过混频器将接收到的信号与发射信号混频, 混频器的输出端, 使用低通滤波器去除载波信号 $2\pi ft$ 和因混频产生的高频信号, 只剩下中频信号, 该信号即包含了由 $x(t)$ 引起的相位变化。

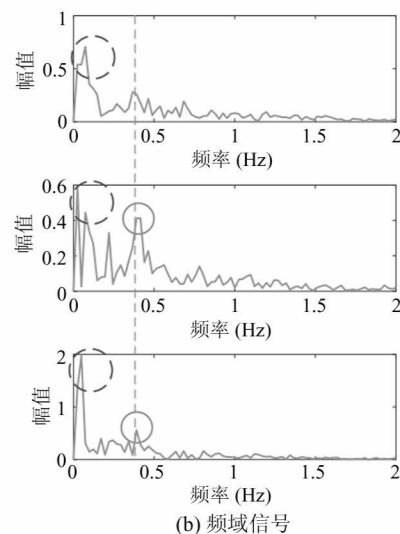
由于本文使用了正交接收器, $R(t)$ 被分成 2 个分量, 其中一个分量与发射信号混频, 另外一个分量与相位延迟 90° 的发射信号进行混频。最终得到一对标准正交的基带信号 $B_i(t)$ 和 $B_q(t)$, 分别表示为

$$B_i(t) = \cos\left(\theta + \frac{4\pi x(t)}{\lambda} + \Delta\phi(t)\right) \quad (3)$$

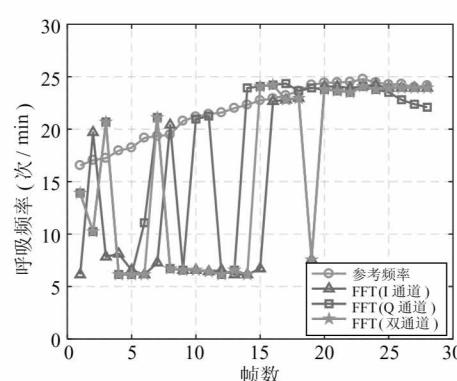
$$\begin{aligned} B_q(t) &= \cos\left(\theta - \frac{\pi}{2} + \frac{4\pi x(t)}{\lambda} + \Delta\phi(t)\right) \\ &= \sin\left(\theta + \frac{4\pi x(t)}{\lambda} + \Delta\phi(t)\right) \end{aligned} \quad (4)$$



(a) 时域信号



(b) 频域信号



(c) 多帧识别结果

图 2 基于多普勒雷达的传统呼吸识别方法

因此本文中将使用时频信息融合网络实现对 I 和 Q 通道信号的分析, 使用 LSTM 网络来对时序信号中的周期信息进行提取, 使用 ZoomFFT 来提取频域信息, 通过融合时频域信息来增强呼吸率的识别精度。

2 LSTM 网络

LSTM 网络是一种特殊的循环神经网络 (recurrent neural networks, RNN)。LSTM 网络的提出, 是为了解决普通 RNN 网络在训练中出现的梯度消失和梯度爆炸问题, 通过引入门逻辑, 识别输入信号中时间间隔较长或者延迟较长的信息。因此该种网络对于时序信号处理有很好的效果, 其在包括自然语言处理、视频处理、手写识别等场景中都获得了很好的识别效果^[34]。也正因其对于周期信号的有效识别, 本文引入 LSTM 网络来对呼吸这种明确的周期

式中 $\theta = 4\pi d_0/\lambda + \theta_0$, 包含了目标和雷达的距离 d_0 及初始相位 θ_0 , $\Delta\phi(t)$ 表示剩余的振荡器相位噪声。由式(3)和式(4)可知 $B_i(t)$ 和 $B_q(t)$ 有 90° 相位差别, 保证接收到的信号至少有一个基带信号在非 NULL 点上。接下来将对 I 和 Q 通道的信号进行分析, 得到呼吸的频率 $x_r(t)$ 。

实际环境中噪声 $\Delta\phi(t)$ 的影响往往会很大, 如图 2(a) 所示, 当有低频干扰时, 传统快速傅里叶变换 (fast Fourier transform, FFT) 方法和峰值检测法会导致呼吸率识别出错。以往规避这种风险的方式是采用带通滤波或加入上下限, 但当低频噪声较高时, 问题依然无法避免。如图 2(b) 中所示, 在对传统频域信号使用峰值检测时, 预期的识别呼吸频率为实线所圈出的频率, 但识别结果很容易被虚线圈出的低频区域所影响, 导致识别结果如图 2(c) 所示, 出现大的偏差。

rent neural networks, RNN)。LSTM 网络的提出, 是为了解决普通 RNN 网络在训练中出现的梯度消失和梯度爆炸问题, 通过引入门逻辑, 识别输入信号中时间间隔较长或者延迟较长的信息。因此该种网络对于时序信号处理有很好的效果, 其在包括自然语言处理、视频处理、手写识别等场景中都获得了很好的识别效果^[34]。也正因其对于周期信号的有效识别, 本文引入 LSTM 网络来对呼吸这种明确的周期

信号进行识别。

LSTM 网络由 Hochreiter 和 Schmidhuber^[35] 在 1997 年提出,通过不断演进,分别增加了遗忘门^[36]和窥视孔连接^[37]。本文中将使用演进后的 LSTM 网络进行模型构建,单个的 LSTM 单元^[38]如图 3 所示。从图中可以看到,LSTM 模型包含 3 个门逻辑即输入门(input gate)、遗忘门(forget gate)、输出门(output gate),输入,细胞(Cell),输出激活模块,以及窥视孔连接(peephole connection),单元的输出同时返回连接到输入和各个门,实现一个循环网络。针对神经网络中一个 LSTM 层,假设其 x^t 为在 t 时刻的输入向量, N 为 LSTM 单元的数量, M 为输入信号的数量,那么 LSTM 层将会产生如下的权重。

输入权重: $W_z, W_i, W_f, W_o \in \mathbb{R}^{N \times M}$

循环权重: $R_z, R_i, R_f, R_o \in \mathbb{R}^{N \times N}$

窥视孔权重: $p_i, p_f, p_o \in \mathbb{R}^N$

偏差权重: $b_z, b_i, b_f, b_o \in \mathbb{R}^N$

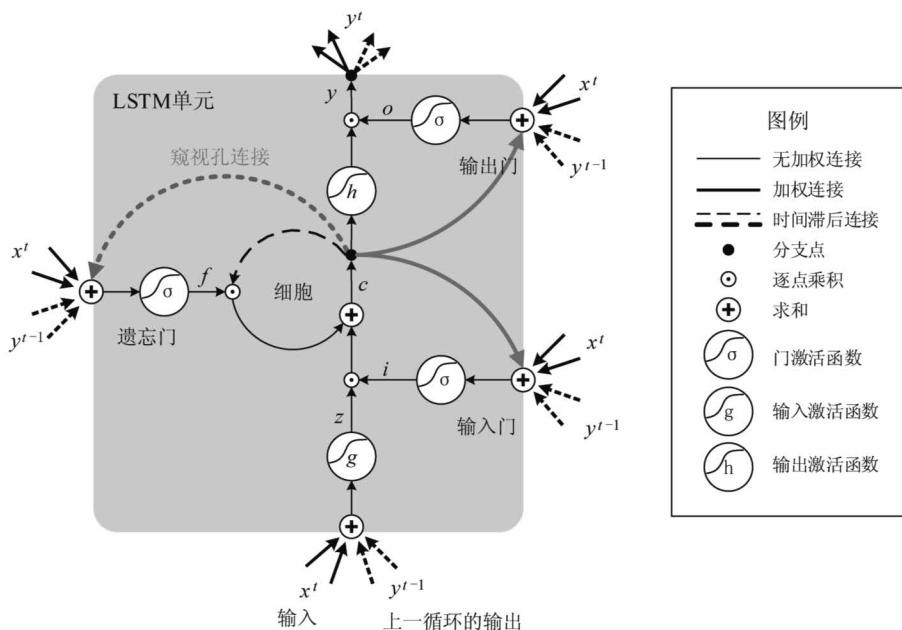


图 3 LSTM 网络单元^[38]

从以上 LSTM 的流程可以看出,通过门逻辑和细胞状态的存储,以及上一时刻状态的加入,即可以实现循环网络的功能。在网络训练过程中,反向传播需要对各个门逻辑和输入输出的传递误差都进行分析,因此其需要确定的参数较多,训练时间较长,具体过程在此不做赘述,可参考文献[34,38]。

针对 t 时刻 LSTM 单元,其各节点的矢量计算公式如下。

$$\text{输入: } z^t = g(W_z x^t + R_z y^{t-1} + b_z)$$

输入门:

$$i^t = \sigma(W_i x^t + R_i y^{t-1} + p_i \odot c^{t-1} + b_i)$$

遗忘门:

$$f^t = \sigma(W_f x^t + R_f y^{t-1} + p_f \odot c^{t-1} + b_f)$$

细胞: $c^t = z^t \odot i^t + c^{t-1} \odot f^t$

输出门:

$$o^t = \sigma(W_o x^t + R_o y^{t-1} + p_o \odot c^{t-1} + b_o)$$

输出: $y^t = h(c^t) \odot o^t$

其中 σ 、 g 、 h 分别为逐点运算的非线性激活函数,通常门逻辑的激活函数为逻辑回归函数(logistic sigmoid),输入输出激活函数为反余切函数(hyperbolic tangent)。同时在 LSTM 层中使用了逐点乘积运算,在式中表示为 \odot ^[38]。

3 时频信息融合网络方法

3.1 信号预处理

雷达接收到经过混频的 I 和 Q 通道模拟信号,将接入模拟到数字信号转换模块(analog to digital, AD),实现模拟信号到数字信号的转换。但是由于

实际使用中的 I 和 Q 通道信号非常微弱,因此通常的方法是在 AD 转换模块前置 1 个信号放大器,这样可以增加有效信号的幅值,降低外部信号的干扰。

(1) 模拟信号预处理

针对雷达 I 和 Q 通道信号的前置放大器在本文中为 2 级放大电路。第 1 级放大电路放大 10 倍,选择该放大倍数是由于经过混频后的信号会有一定的直流偏置,导致信号的基准电压偏高,需要控制放大倍数保证信号电压幅值在放大器上下限范围内。第 1 级放大电路和第 2 级放大电路使用电容连接,滤除直流偏置,只保留更关心的交变信号。第 2 级放大电路将交变信号放大,由于通过多普勒效应产生的低频信号有比较强的周期性的,因此对于这部分周期信号的放大显得尤为重要。经过 2 级模拟放大的信号将进入 AD 转换器,实现模拟到数字的转换,并通过 USB 线连接到个人电脑(PC)进行数据采集。整体流程如图 4 所示。

(2) 数字信号预处理

针对 I 和 Q 通道的数据,首先使用常见的滤波方法来进行信号处理,滤除噪声。由于 I 和 Q 通道

信号的主要成分是人体的胸腔振动(呼吸和心跳)信息。而人的呼吸频率在每分钟 10~30 次,其对应的频率比较低,因此对于信号首先进行一次低通滤波,滤除高频噪声,降低噪声影响,然后将数据输入识别模型进行呼吸频率的识别。

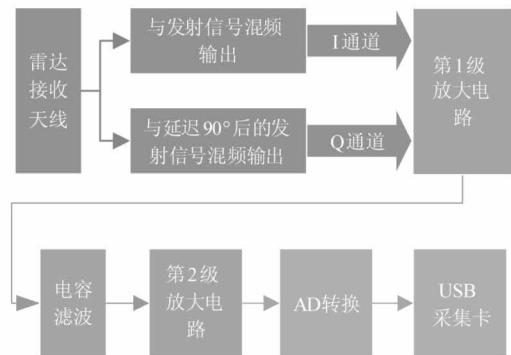


图 4 模拟信号预处理

3.2 基于时频信息融合网络的识别模型

I 和 Q 通道的数据,在本模型中将从时域角度和频域角度分别进行分析,并最终融合进行呼吸频率识别,网络模型结构见图 5。

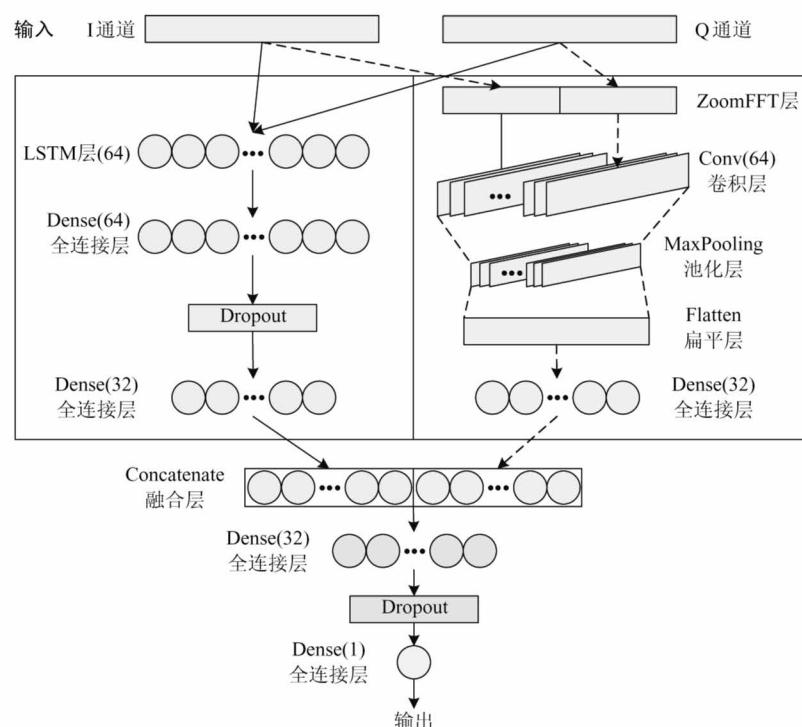


图 5 时频信息融合网络结构

(1) 时域信息提取

将预处理后的 I 和 Q 通道数据,作为 2 个维度信号输入到 LSTM 网络,从时域角度提取周期信息。为了降低网络复杂度和噪声信号的影响,增强呼吸信号的识别,需要将原始高采样率的信号降采样。呼吸信号主要包含在频率为 3 Hz 以下的信号中,由奈奎斯特采样定律可知,只需要保证采样频率高于 6 Hz 即可保留相关的低频信息,但为了同时保证能更好地提取细节信息,经过多次实验,降采样的采样频率在本实验中设定为 20 Hz。I 和 Q 通道的时域数据,经过设定窗口时间的截取,形成固定长度的数据,输入 LSTM 网络层,然后接入全连接层,进行时域信息的提取,成为融合的第 1 个输入,见图 5 中左边部分。

(2) 频域信息提取

针对频域信息,将 I 和 Q 通道的时域信号转换到频域,作为融合的第 2 个输入,从频域角度识别呼吸的频率信息。常见的频域信号提取方法为快速傅里叶变换(FFT),但是其在低频部分的分辨率很低,因此本文中使用 ZoomFFT 方法来对呼吸时序信号进行处理,将呼吸对应的频率范围细化,得到更关心的呼吸频率范围内信息。

ZoomFFT 方法的基本原理是将初始信号进行复调制,将时序序列转变为复序列,利用傅里叶变换的频移性质把选频段的中心频率移至 0 频,再通过低通抗混叠滤波和整数倍抽取,最后对抽取后的信号做 FFT 分析和频率调整,即得到选频段的细化频谱^[39]。通过 ZoomFFT 获得的 I 和 Q 双通道的频域数据将经过卷积神经网络(convolutional neural network,CNN)进行特征提取,通过全连接层连接,最终成为融合的第 2 个输入,见图 5 中右边部分。

(3) 信息融合

时域信息和频域信息将在最后进行融合,获取对应的周期和频率信息,融合提取有效特征,相互印证和补充,最终实现呼吸频率的准确识别。

3.3 鲁棒呼吸频率检测方法

通过基于时频信息融合网络的呼吸识别实验(见 4.3 节)可知,时频信息融合网络模型对个别用户的识别效果不佳,可能会在一定时间内产生波动。

因此本节基于局部加权回归平滑法(Lowess),提出了一种鲁棒呼吸频率检测方法。该方法基于时频信息融合网络模型的识别结果,通过局部加权回归平滑法来过滤模型的输出,实现鲁棒平稳的呼吸率检测。

局部加权回归平滑方法(Lowess)具体如下。

一般的线性回归,是对离散输入 $\mathbf{x}^{(i)}$ 和输出 $\mathbf{y}^{(i)}$ 选取合适的加权参数 $\boldsymbol{\theta}$,使得损失函数最小:

$$\min \sum_{i=0}^m (\mathbf{y}^{(i)} - \boldsymbol{\theta}^T \mathbf{x}^{(i)})^2 \quad (5)$$

而局部加权回归平滑法,不关注所有的数据,而是关注当前预测点相邻数据的分布,减少了较远数据的干扰。具体的为损失函数增加权值 $\boldsymbol{\omega}^{(i)}$,使得优化的目标变为

$$\min \sum_{i=0}^m \boldsymbol{\omega}^{(i)} (\mathbf{y}^{(i)} - \boldsymbol{\theta}^T \mathbf{x}^{(i)})^2 \quad (6)$$

经典地定义权重参数 $\boldsymbol{\omega}^{(i)}$:

$$\boldsymbol{\omega}^{(i)} = \exp\left(-\frac{\|\mathbf{x}^{(i)} - \mathbf{x}\|_2^2}{2\sigma^2}\right) \quad (7)$$

可以看到, $\boldsymbol{\omega}^{(i)}$ 为一个钟形函数,其中 $\mathbf{x}^{(i)}$ 为当前点的向量, \mathbf{x} 为其他点的向量, σ 为设定的方差。 $\mathbf{x}^{(i)}$ 距离 \mathbf{x} 越近,其权值越接近于 1,距离越远越接近于 0,进而实现对数据的局部加权回归^[40,41]。呼吸频率的变化非常符合这种局部特性,因此在时频信息融合网络模型后加入局部加权回归平滑,可以有效地降低识别误差,提高识别精度。

3.4 与传统方法对比

采用时频信息融合网络模型对雷达数据进行分析,是从时域角度提取周期信息,从频域角度获取频率信息,最终融合 2 种信息进行最终的结果识别。这种方法的信息维度比采用单一的传统信号处理更多,有助于提取隐层信息,防止因为噪声干扰导致的识别偏差,而实验结果也验证了这一点。

对比经典的频域处理方法,使用神经网络模型进行回归分析,能够更好地实现复杂非线性信号的分析。而且可以从多个特征维度,对信号进行分析,更加全面地应对不同距离、不同角度导致的信号变化。从实验结果也可以看出,对比其他信号处理方法,使用时频信息融合网络模型的识别结果精度更高、更稳定。

4 实验结果及分析

4.1 数据采集

针对本文的实验,采集了 7 名志愿者(6 名男性,1 名女性)的 220 min 有效数据,分别对坐姿静止状态下不同朝向(前后左右)、不同距离(0.5 m、1 m、2 m、3 m)进行了多场景的雷达数据采集,如图 6 所示。雷达采集方案是使用 RFbeam 公司的 ST200 实验平台和 K-MC1 商用微型雷达模块来进行数据采集^[42]。该模块包含 1 个发射天线和 1 个接收天线,发射频率为 24 GHz,输出 I 和 Q 共 2 通道信号。ST200 平台通过 USB 连接至 PC 端,采用 LabVIEW^[43] 环境进行实时数据采集和保存。

参考的呼吸信号,采用 Vernier 公司的 LabQuest 2^[44] 平台进行采集,使用了呼吸计传感器获取呼吸的原始数据。

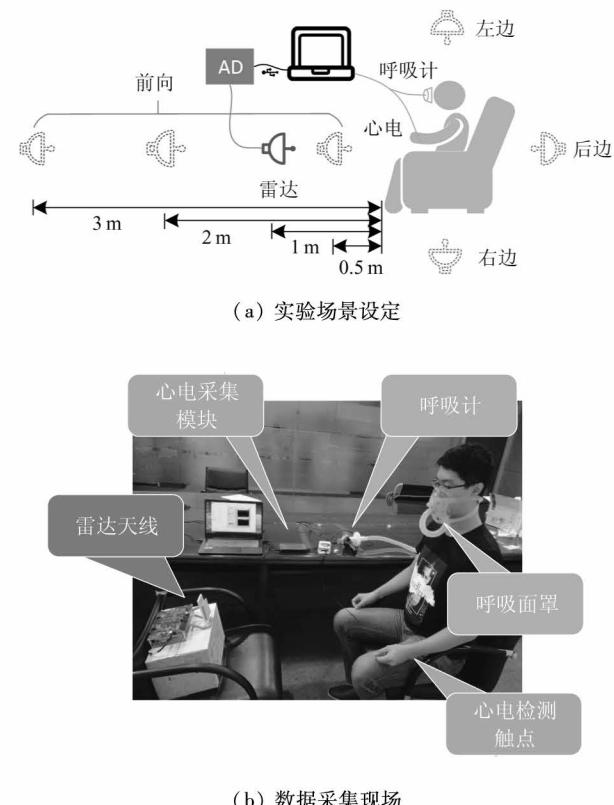


图 6 实验场景设定和数据采集现场

4.2 呼吸频率识别效果

本节针对时频信息融合网络对呼吸频率识别效

果进行实验。实验使用志愿者在静止时的数据,包含不同朝向和不同距离。由于本文的学习方法不同于直接进行信号处理的方法,需要将整体数据进行划分,将所有数据随机划分为测试集和验证集,进行交叉验证,本实验使用 10 折交叉验证(10 fold cross validation)来对模型的效果进行验证。

针对雷达接收到的连续数据,首先对其进行分帧,即按照固定窗口大小来进行截断,构成多个帧,再进行验证。在本实验中,根据呼吸周期的特点和经验,将窗口大小设置为 35 s,并采用滑动窗口的方式分帧,滑动步长设置为 3 s。对比方法有 FFT 方法、ZoomFFT 方法、CZT(chirp z-transform)方法和小波变换方法将时域信号转变成频域信息,再通过峰值检测构成的传统频域测量方法;用自相关方法,从时域信号角度进行呼吸识别的传统方法;使用 Bootstrap^[45],增加随机噪声重构信号,来识别呼吸的方法。对比指标为常用的平均误差(mean absolute error, MAE) 和 均方根误差(root mean square error, RMSE),具体结果见表 1。

通过表 1 可知,对比传统方法,基于时频信息融合网络的识别误差最小、识别效果最好,详见“时频信息融合网络模型(10 折交叉验证)”项。同时,为了考量模型的泛化能力,继续采用留一法(leave one subject out, LOSO)进行验证,结果详见表 1“时频信息融合网络模型(LOSO)”项。可知采用留一法识别结果虽有所降低,但依然有最好的识别效果,识别精度高于其他方式,平均误差和均方根误差都最小。

4.3 不同个体的呼吸识别

为了进一步验证模型的普适性,本节采用留一法(LOSO)来对模型进行验证,通过对采集到的 7 个人数据进行逐次详细分析,检验模型的泛化能力。该方法为取其中一个志愿者的数据进行模型测试,其他志愿者数据进行模型训练,以模拟在现实生活中,将设备和模型应用于一个新用户时的识别效果。

在实验中使用了最常见的 FFT 方法,以及在前面测试中表现较好的小波变换方法作为对比,使用识别呼吸频率的 RMSE 值进行判断。最终实验结果如图 7 所示,通过该图可知虽然每个不同的个体都有差异,但是基于时频信息融合网络识别的结果,在

所有方法中均有较低的平均识别误差,且有最小的标准差。

表1 不同方法的模型识别结果(次/min)

方法名称	使用通道	MAE	RMSE
FFT 方法	I 通道	3.89	7.58
	Q 通道	1.92	4.51
	双通道	2.23	5.44
ZoomFFT 方法	I 通道	4.17	7.76
	Q 通道	2.36	5.35
	双通道	5.97	7.88
CZT 方法	I 通道	4.15	7.75
	Q 通道	2.40	5.42
	双通道	5.97	7.90
小波变换方法	I 通道	6.25	10.24
	Q 通道	4.04	7.21
	双通道	2.36	3.36
自相关方法	I 通道	24.07	97.31
	Q 通道	6.89	26.35
	双通道	4.67	6.53
Bootstrap 方法	I 通道	3.30	5.40
	Q 通道	2.93	4.90
	双通道 *	-	-
LSTM 网络模型	双通道	0.74	1.01
时频信息融合网络 (10 折交叉验证)	双通道	0.54	0.72
时频信息融合网络 (LOSO)	双通道	1.90	2.94

注: * Bootstrap 方法为单通道的识别方法,没有双通道的识别结果。

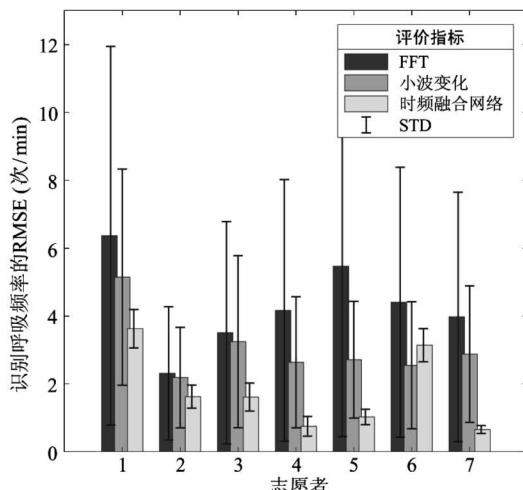
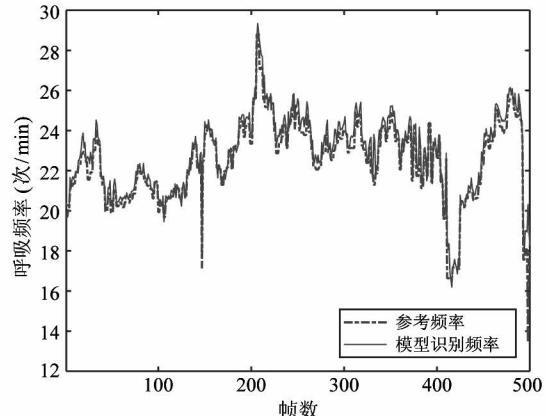
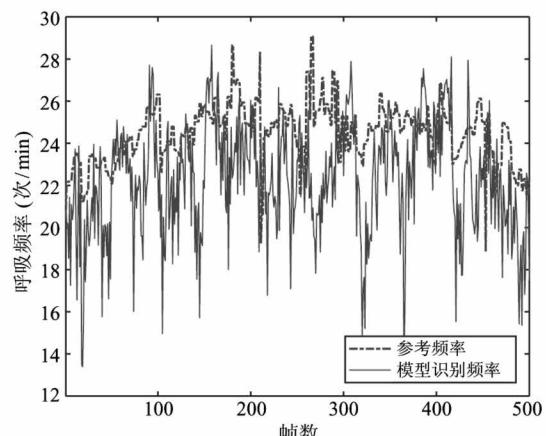


图7 针对不同个体、不同方法的呼吸频率识别效果

志愿者 7 和志愿者 1 是识别精度最高和最差的 2 个志愿者,进一步对 2 者数据提取和分析,见图 8。通过该图可知对于志愿者 7,呼吸识别效果最好,基本逼近参考呼吸频率,大部分呼吸频率在 20 次/min 附近。对于志愿者 1,识别模型结果变化较大,体现出模型对特定状态下的识别结果有一定偏差,但是整体形势趋于稳定,后续将通过基于局部加权回归平滑法的鲁棒识别模型进行优化,具体实验结果见 4.6 节。



(a) 志愿者 7 的模型识别结果



(b) 志愿者 1 的模型识别结果

图8 特定个体基于时频信息融合网络模型的识别详情

4.4 距离对模型识别的影响

雷达发射的无线电信号,由于距离越远,其在传播时的衰减也就越大,尤其对于 24 GHz 的无线电波,其在空间内传输的衰减比低频信号更大。因此,雷达距离人体的距离,将严重地影响雷达接收到的回波信号的强度,也对识别模型增加了更高的识别

挑战。在本实验中,雷达至人体的距离被分别设定为 0.5 m、1 m、2 m、3 m,以验证不同距离对于模型识别结果的影响,识别结果如表 2 所示。

表 2 距离对模型识别结果的影响(次/min)

雷达放置在 人体的方位	距离	MAE	RMSE
正前方	0.5 m	2.73	3.69
正前方	1 m	2.24	3.25
正前方	2 m	1.98	2.70
正前方	3 m	2.56	3.35

通过实验结果可知,对于 1~2 m 范围内模型识别效果最好,当距离过近时身体各个部位都会出现比较强的反射,很有可能会导致不同相位信号相互叠加干扰,因而导致在过近距离识别效果不佳。当识别距离变得更远时,接收到信号的强度会随着雷达到人体的距离增加而快速降低,而且由于其接受的是人体反射信号,因此将以 2 倍的距离降低,最终导致雷达接收到的有效信号泯灭在噪声信号中,导致识别结果误差变大。

4.5 朝向对模型识别的影响

人在呼吸过程中会产生胸腔的位移变化,但是胸腔的位移在不同的方向上会有很大的区别,比如在呼吸过程中,人胸腔的前向位移变化最大,左右朝向的位移变化次之,背部朝向的位移最弱,这是由于胸腔本身的组织结构决定的。因此,对于雷达从不同朝向进行呼吸检测识别十分有必要。

所以在本实验中,分析了雷达放置在不同的方位,距离 1 m 朝向实验者时的识别效果。实验采用留一法(LOSO)进行验证,即将特定朝向的数据作为测试数据,其他数据作为训练数据,进行训练和测试。实验结果如表 3 所示。

表 3 朝向对模型识别结果的影响(次/min)

雷达放置在 人体的方位	距离	MAE	RMSE
正前方	1 m	2.24	3.25
左边	1 m	2.00	2.70
右边	1 m	2.39	3.32
正后方	1 m	1.95	2.65

通过识别结果可以看到对于正后方的识别准确度更高,误差更小,具体原因可能由于在 1 m 距离,正后方的胸腔运动更加趋近于平面的往复运动,而且腹部运动的反射会更小,胸腔发射信号更明显,因此其识别效果会更好。

4.6 鲁棒呼吸检测方法的识别效果

鲁棒呼吸检测方法,适用于对独立个体进行分别识别的情况,因此使用留一法(LOSO)进行数据分析。具体的实验结果如表 4 所示,通过该表可知,基于局部加权回归平滑法(Lowess)的鲁棒呼吸检测模型能够提高最终的呼吸频率识别精度,降低误差。

表 4 鲁棒检测方法的识别效果(次/min)

方法名称	MAE	RMSE
时频信息融合网络模型(LOSO)	1.90	2.94
鲁棒检测方法(LOSO)	1.77	2.36

通过对每个人的识别精度进行逐个分析(见图 9,虚线为仅基于时频信息融合网络的识别结果作为对比),可见对于本身误差较大的个体,鲁棒检测方法能够有效降低其识别误差。但是对于误差较小的用户,识别精度有所下降,原因可能在于通过加权回归后,由于部分准确识别点会受相邻不准确点的干扰,产生错误偏移。但该影响有限,从模型的整体识别误差变化看,可以明显看出基于局部加权回

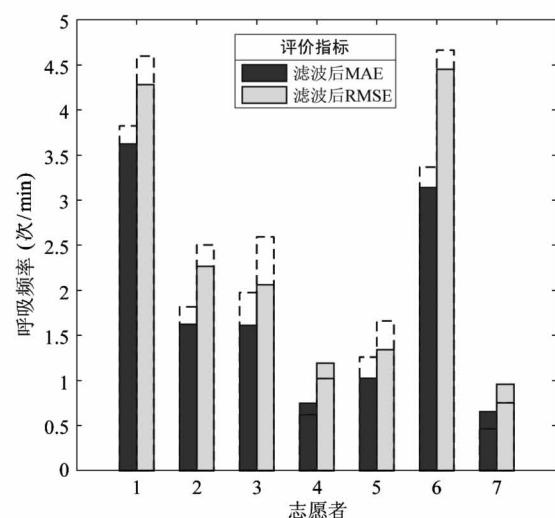


图 9 不同个体使用鲁棒检测方法的识别效果

归平滑后的识别结果更佳。特别的,针对志愿者1的呼吸频率识别(见图10),对比图8(b)可知鲁棒检测方法的加入,使其识别呼吸频率的波动明显降低,整体呼吸频率的识别精度进而提高。

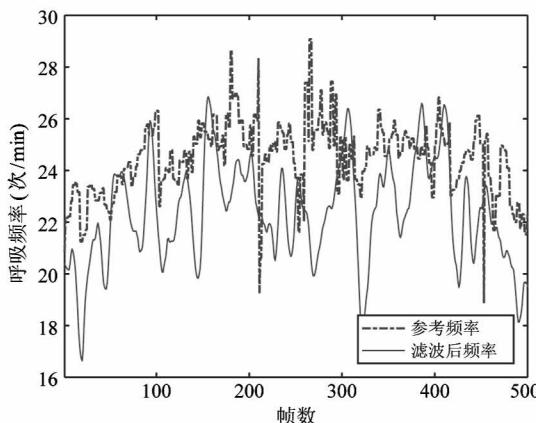


图10 志愿者1使用鲁棒检测方法的识别结果

4.7 不足和展望

基于时频信息融合的识别模型在没有使用任何先验知识,即没有个性化数据参与训练时,对新用户的呼吸识别效果有可能较差。后续将针对用户个性化数据在线更新展开研究,对识别模型架构进行更多的探索。同时,未来将基于目前的研究成果,设计和实现基于雷达的呼吸频率实时检测系统,并将其与睡眠、异常检测等事件结合,实现对用户健康的全面感知。

5 结 论

本文提出了基于时频信息融合网络非干扰呼吸检测方法,该方法通过雷达采集用户胸腔信号,融合I和Q通道信号的时域特性和频域特性,结合Lowess方法,实现对呼吸频率的精准、鲁棒检测。该方法对比其他常用信号处理方法的识别效果更好,有较强的泛化能力,对于不同距离、不同朝向和不同个体的呼吸都可以进行有效的识别。

参考文献

- [1] 严旭, 刘洪英, 贾子如, 等. 呼吸频率检测技术研究现状[J]. 北京生物医学工程, 2017, 36(5): 545-549
- [2] Krishnan R. A survey of contactless[J]. *Journal of Current Research*, 2017, 9(3): 48344-48348
- [3] El-Samad S, Obeid D, Zaharia G, et al. Feasibility of heartbeat detection behind a wall using CW Doppler radar [C] // 2016 IEEE Middle East Conference on Antennas and Propagation (MECAP), Beirut, Lebanon, 2016: 1-4
- [4] Kuutti J, Paukkunen M, Aalto M, et al. Evaluation of a Doppler radar sensor system for vital signs detection and activity monitoring in a radio-frequency shielded room [J]. *Measurement*, 2015, 68: 135-142
- [5] El-Samad S, Obeid D, Zaharia G, et al. Measurements of cardiac and cardiopulmonary activities using contactless Doppler radar [C] // 2015 International Conference on Advances in Biomedical Engineering (ICABME), Beirut, Lebanon, 2015: 193-196
- [6] Lee Y S, Pathirana P N, Steinfort C L, et al. Monitoring and analysis of respiratory patterns using microwave Doppler radar[J]. *IEEE Journal of Translational Engineering in Health and Medicine*, 2014, 2: 1-12
- [7] Qi H, Guo Z, Chen X, et al. Video-based human heart rate measurement using joint blind source separation[J]. *Biomedical Signal Processing and Control*, 2017, 31: 309-320
- [8] Tarlungă D D, Mocanu B, Tapu R. Automatic real time derivation of breathing rate from thermal video sequences [C] // 2017 Nordic-Baltic Conference on Biomedical Engineering and Medical Physics, Tampere, Finland, 2017: 81-84
- [9] Wang T, Zhang D, Zheng Y, et al. C-FMCW based contactless respiration detection using acoustic signal [J]. *Proceedings of the ACM on Interactive Mobile Wearable and Ubiquitous Technologies*, 2018, 1(4): 170
- [10] Niu K, Zhang F, Chang Z, et al. A fresnel diffraction model based human respiration detection system using COTS Wi-Fi devices[C] // Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers, New York, USA, 2018: 416-419
- [11] Zhang F, Zhang D, Xiong J, et al. From fresnel diffraction model to fine-grained human respiration sensing with commodity Wi-Fi devices[J]. *Proceedings of the ACM on Interactive Mobile Wearable and Ubiquitous Technologies*, 2018, 2(1): 53
- [12] Adib F, Mao H, Kabelac Z, et al. Smart homes that monitor breathing and heart rate [C] // Proceedings of the 33rd Annual ACM Conference on Human Factors in Com-

puting Systems, Seoul, Korea, 2015: 837-846

- [13] Hsu C Y, Ahuja A, Yue S, et al. Zero-effort in-home sleep and insomnia monitoring using radio signals [J]. *Proceedings of the ACM on Interactive Mobile Wearable and Ubiquitous Technologies*, 2017, 1(3): 1-18
- [14] Li C, Peng Z, Huang T Y, et al. A review on recent progress of portable short-range noncontact microwave radar systems [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2017, 65(5): 1692-1706
- [15] Woo E J, Hua P, Webster J G, et al. Measuring lung resistivity using electrical impedance tomography [J]. *IEEE Transactions on Biomedical Engineering*, 1992, 39(7): 756-760
- [16] Li C, Lubecke V M, Boric-Lubecke O, et al. A review on recent advances in Doppler radar sensors for noncontact healthcare monitoring [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2013, 61(5): 2046-2060
- [17] Mercuri M, Liu Y, Lorato I, et al. A direct phase-tracking Doppler radar using wavelet independent component analysis for non-contact respiratory and heart rate monitoring [J]. *IEEE Transactions on Biomedical Circuits and Systems*, 2018, 12(3): 632-643
- [18] Gu X, Zhang L, Xiao Y, et al. Non-contact fatigue driving detection using CW doppler radar [C] // 2018 IEEE MTT-S International Wireless Symposium (IWS), Chengdu, China, 2018: 1-3
- [19] Tu J, Lin J. Fast acquisition of heart rate in noncontact vital sign radar measurement using time-window-variation technique [J]. *IEEE Transactions on Instrumentation and Measurement*, 2016, 65(1): 112-122
- [20] Fang Z, Lou L, Yang C, et al. A Ku-band FMCW radar on chip for wireless micro physiological signal monitoring by interferometry phase analysis [C] // 2018 IEEE International Symposium on Circuits and Systems (ISCAS), Florence, Italy, 2018: 1-4
- [21] Postolache O, Girão P S, Postolache G, et al. Cardio-respiratory and daily activity monitor based on FMCW Doppler radar embedded in a wheelchair [C] // 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Boston, USA, 2011: 1917-1920
- [22] Javaid A Q, Noble C M, Rosenberg R, et al. Towards sleep apnea screening with an under-the-mattress IR-UWB radar using machine learning [C] // 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA), Miami, USA, 2015: 837-842
- [23] Zito D, Pepe D, Mincic M, et al. SoC CMOS UWB pulse radar sensor for contactless respiratory rate monitoring [J]. *IEEE Transactions on Biomedical Circuits and Systems*, 2011, 5(6): 503-510
- [24] Lohman B, Boric-Lubecke O, Lubecke V M, et al. A digital signal processor for Doppler radar sensing of vital signs [J]. *IEEE Engineering in Medicine and Biology Magazine*, 2002, 21(5): 161-164
- [25] Massagram W, Hafner N M, Park B K, et al. Feasibility of heart rate variability measurement from quadrature Doppler radar using arctangent demodulation with DC offset compensation [C] // 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Lyon, France, 2007: 1643-1646
- [26] Zhang X Y, Shi H, Li C, et al. Learning transferable self-attentive representations for action recognition in untrimmed videos with weak supervision [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 9227-9234
- [27] 杨海清, 徐勇军, 王明雪. 基于深度强化学习和循环卷积神经网络的图像恢复算法 [J]. 高技术通讯, 2019, 29(5): 432-437
- [28] 胡硕, 赵银妹, 孙翔. 基于卷积神经网络的目标跟踪算法综述 [J]. 高技术通讯, 2018, 28(3): 207-213
- [29] Zhang X Y, Wang S, Yun X. Bidirectional active learning: a two-way exploration into unlabeled and labeled data set [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(12): 3034-3044
- [30] Zhang X Y, Shi H, Zhu X, et al. Active semi-supervised learning based on self-expressive correlation with generative adversarial networks [J]. *Neurocomputing*, 2019, 345: 103-113
- [31] Kuboi R, Jimi K, Inoue M, et al. Estimating stress states using respiratory monitoring by 24 GHz wideband radar [C] // 2016 IEEE 5th Global Conference on Consumer Electronics, Kyoto, Japan, 2016: 1-4
- [32] Zaffaroni A, Chazal P D E, Heneghan C, et al. Sleep-Minder: an innovative contact-free device for the estimation of the apnoea-hypopnoea index [C] // 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Minneapolis, USA, 2009: 7091-7094
- [33] Girbau D, Lazaro A, Ramos, et al. Remote sensing of vital signs using a Doppler radar and diversity to overcome Null detection [J]. *IEEE Sensors Journal*, 2012, 12(3):

512-518

- [34] 沈旭. 基于序列深度学习的视频分析:建模表达与应用[D]. 合肥:中国科学技术大学自动化系, 2017
- [35] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780
- [36] Gers F A, Schmidhuber J, Cummins F. Learning to forget: continual prediction with LSTM[J]. *Neural Computation*, 1999, 12(10): 850-855
- [37] Gers F A, Schmidhuber J. Recurrent nets that time and count[C] // Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN 2000), Como, Italy, 2000: 189-194
- [38] Greff K, Srivastava R K, Koutník J, et al. LSTM: a search space Odyssey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2222-2232
- [39] 赵宏强. 频谱细化算法分析[J]. 四川兵工学报, 2013, 34(5): 105-109, 112
- [40] Cleveland W S. Robust locally weighted regression and smoothing scatterplots[J]. *Journal of the American Statistical Association*, 1979, 74(368): 829-836
- [41] 张金艺, 张晶晶, 李若涵, 等. 流水线型局部加权回归RFID室内定位[J]. 应用科学学报, 2014, 32(2): 125-132
- [42] RFbeam Microwave GmbH. RFbeam[EB/OL]. <http://www.rfbeam.ch/product? id=35>; RFbeam, 2019
- [43] National Instruments Corporation. 什么是LabVIEW? - National Instruments[EB/OL]. <http://www.ni.com/zh-cn/shop/labview.html>; 上海恩艾仪器有限公司, 2019
- [44] Vernier Software & Technology. LabQuest 2-Vernier[EB/OL]. <https://www.vernier.com/products/interfaces/labq2/>; Vernier, 2019
- [45] Nejadgholi I, Sadreazami H, Baird Z, et al. Estimation of breathing rate with confidence interval using single-channel CW radar[J]. *Journal of Healthcare Engineering*, 2019, 2019: 1-14

Non-contact respiratory detection based on time and frequency fusion network

Shen Jianfei, Chen Yiqiang, Gu Yang

(* Beijing Key Laboratory of Mobile Computing and Pervasive Device, Beijing 100190)

(** Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190)

(*** University of Chinese Academy of Sciences, Beijing 100049)

Abstract

To overcome the noise influence in respiratory detection based on Doppler radar, a non-contact respiratory detection method is proposed based on the time and frequency fusion network. This method collects information of the chest movements with Doppler radar, and analyses the mixing signals I and Q from two domains. For the time-domain, the period information of the signal is extracted with the long short-term memory (LSTM) network. For the frequency domain, the zoom fast Fourier transform (ZoomFFT) is used to implement the fine-grained frequency domain features, and the CNN network is used to extract the effective information from the frequency domain features. The last part converges two-dimension information to achieve accurate detection of the user's respiratory rate with the Lowess smoothing method. Experiment results show that the proposed method can achieve less average error and root mean square error than other common signal processing methods, and it can effectively identify the breathing rate from different distances or different orientations.

Key words: non-contact detection, radar detection, vital sign detection, respiratory rate detection