

## Capítulo

# 5

## Monitoramento de Sinais Vitais Utilizando Redes Wi-Fi

Julio C. H. Soto, Iandra Galdino, Egberto Caballero, Vinicius Ferreira, Débora Muchaluat-Saade, Célio Albuquerque

### *Resumo*

*A pandemia de COVID-19 destacou a necessidade de usar procedimentos de monitoramento remoto de baixo custo para pacientes médicos. O uso das informações do canal de transmissão (Channel State Information – CSI) das redes Wi-Fi para monitorar pacientes remotamente é uma ferramenta capaz de suprir informações médicas de forma não invasiva e com baixo custo. Este capítulo apresenta as técnicas de captura de dados Wi-Fi CSI, as técnicas de processamento de sinais utilizadas e as aplicações para o monitoramento de sinais vitais. É comentada uma demonstração prática da captura dos sinais de respiração de um indivíduo utilizando essa tecnologia. Por fim, apresentam-se os desafios e perspectivas para pesquisas na área.*

### *Abstract*

*The COVID-19 pandemic has highlighted the need to use low-cost remote monitoring procedures for medical patients. The use of Channel State Information (CSI) of Wi-Fi networks is a tool capable of providing non-invasive medical information in a low-cost manner. This chapter presents CSI Wi-Fi data capture techniques, signal processing techniques, and applications for vital signs monitoring. We also comment on a practical demonstration of capturing an individual's breathing signal using this technology. Finally, we present the research challenges and perspectives of this area.*

### **5.1. Introdução**

Diversos dispositivos médicos têm sido usados para ajudar a monitorar, diagnosticar e tratar doenças. Usualmente, esses dispositivos permitem a comunicação com uma rede interna ou até mesmo externa, para monitoramento, configuração e controle ou mesmo troca de informação em tempo real. O monitoramento contínuo da saúde do paciente

oferece um melhor conhecimento de sua condição e permite um melhor fluxo de informações para supervisão, tratamento e recuperação [Tan et al. 2018]. Devido à pandemia da COVID-19, observou-se um número crescente de pacientes que demandam cuidados de saúde. Por se tratar de uma doença altamente contagiosa com potencial de agravamento da condição de saúde, o monitoramento dos pacientes infectados deve ser cuidadoso, reduzindo ao máximo o contato entre os indivíduos. Os profissionais de saúde que tratam de pacientes contaminados pela COVID-19 e demais doenças infectocontagiosas devem utilizar equipamentos de proteção individual (EPI) de forma a minimizar o risco de contágio [Sharma et al. 2021, Li et al. 2019].

Diversas propostas têm sido apresentadas na literatura, relacionadas ao monitoramento sem contato de pacientes contaminados com doenças contagiosas, com o objetivo de lidar com essa demanda. Em [Zhao et al. 2018], por exemplo, os autores propuseram usar a tecnologia *Frequency Modulated Carrier Wave* (FMCW) para detectar atividades humanas através de sinais de radiofrequência. No entanto, o FMCW tem um custo elevado, o que torna essa tecnologia não acessível a todos. Outra solução possível para o monitoramento sem contato de pacientes é o uso da tecnologia de identificação por radiofrequência (*Radio Frequency Identification* – RFID) [Khan 2017]. A utilização de RFID é uma abordagem interessante, entretanto, depende da aquisição de etiquetas RFID a serem conectadas aos pacientes. Portanto, a busca por uma abordagem nova, menos dispendiosa e sem o uso de dispositivos invasivos mostrou que os sinais de rádio Wi-Fi podem ser usados para detectar a presença de pessoas, rastrear atividades, movimentos e ainda captar sinais vitais humanos [Ma et al. 2019a, Yousefi et al. 2017].

Atualmente, os dispositivos Wi-Fi estão disponíveis em quase todos os ambientes médicos e residenciais. A tecnologia Wi-Fi está amplamente difundida no mundo e sua aplicação ao monitoramento da saúde é considerada de baixo custo, uma vez que se aproveita de dispositivos já utilizados para estabelecer uma rede Wi-Fi. Ainda, sua utilização é considerada não invasiva, uma vez que não há a necessidade de intervenção física no paciente. As ondas eletromagnéticas dos sinais Wi-Fi têm a particularidade de atravessar paredes, ou seja, em algumas aplicações não se necessita sequer de transmissão com linha de visada para o paciente, o que facilita sua utilização.

Sinais de rádio (ondas eletromagnéticas) podem ser usados para rastrear atividades humanas. As ondas de rádio são afetadas pelos movimentos humanos alterando as características das ondas que chegam até o receptor [Gu et al. 2017, Gu et al. 2018]. Essas alterações podem ser reconhecidas em um conjunto de dados chamado informação de estado do canal (*Channel State Information* - CSI). O CSI fornece informações de estado do canal na camada física (*Physical layer* - PHY), através de informações como amplitude, fase, e/ou indicador de intensidade do sinal recebido (*Received Signal Strength Indicator* - RSSI). Essa informação pode ser obtida em cada uma das subportadoras envolvidas em uma transmissão multiportadora [Wang et al. 2019, Liu et al. 2019]. Os padrões atuais de Wi-Fi, como o 802.11n/ac, utilizam a modulação por divisão ortogonal de frequências (*Orthogonal Frequency Division Multiplexing* - OFDM) na camada física. OFDM é uma técnica de modulação na qual a banda de frequência de transmissão é dividida em várias sub-bandas, cada uma com sua portadora própria, denominadas subportadoras. Cada uma das subportadoras pode fornecer informações detalhadas sobre o estado do canal [Lee et al. 2018]. O sinal CSI representa a resposta em frequência do canal (*Channel Fre-*

*quency Response* - CFR) para cada subportadora entre os pares de antenas de transmissão e recepção.

O CSI pode capturar as interferências que o corpo humano causa no sinal eletromagnético nos domínios do tempo, da frequência e domínios espaciais. Essas informações podem ser usadas para diferentes aplicações, como a detecção da presença humana, detecção de movimentos, identificação humana, detecção de queda, reconhecimento de gestos, localização humana e monitoramento das condições de saúde. Para monitoramento das condições de saúde, as subportadoras OFDM são usadas como vários sensores para detectar a mudança física de uma pessoa. Uma análise de forma de onda CSI é realizada para detectar atividades mínimas do corpo humano, como a respiração, os batimentos cardíacos, dentre outros [Gu et al. 2018, Damodaran et al. 2020, Lee et al. 2018].

Na literatura, encontra-se vários estudos que enfatizam o uso do sinal CSI como uma tecnologia acessível a todos para o monitoramento das atividades humanas [Yousefi et al. 2017, Ma et al. 2019a, Wang et al. 2019, Liu et al. 2019]. Além disso, o CSI é considerado uma ferramenta não invasiva para o paciente, o que gera maior aceitação do seu uso.

Muitos trabalhos de pesquisa foram desenvolvidos com o foco na comparação de diferentes tecnologias de detecção de características do ambiente ou de atividades humanas sem fio [Uchiyama et al. 2021, Wang et al. 2019, Ma et al. 2019a], reconhecimento de comportamento [Yousefi et al. 2017, Liu et al. 2019] e localização [Xiao et al. 2016, Yang et al. 2013]. Em [Uchiyama et al. 2021], os autores se concentraram em revisar as diferenças entre o sinal CSI de dispositivos Wi-Fi (Wi-Fi CSI), RFID e retrodifusão. Os autores de [Wang et al. 2019] analisaram os principais componentes e características centrais da arquitetura do sistema de reconhecimento do comportamento humano. Em [Ma et al. 2019a], os autores apresentaram uma revisão de técnicas de processamento de sinais, algoritmos, aplicações e resultados de desempenho. Youssefi et al. [Yousefi et al. 2017] apresentaram os avanços no reconhecimento passivo do comportamento humano. Em [Liu et al. 2019], os autores pesquisaram os sistemas de detecção sem fio existentes em termos de seus princípios básicos, técnicas e estruturas de sistema. Xiao et al. in [Xiao et al. 2016] também fornecem uma pesquisa sobre a localização interna sem dispositivos e com dispositivos, e [Yang et al. 2013] apresentou uma pesquisa sobre localização com ênfase nos princípios básicos e tendências futuras. Este último também destacou as diferenças entre CSI e RSSI em termos de camadas de rede, resolução de tempo, resolução de frequência, estabilidade e acessibilidade.

Diferentemente dos trabalhos existentes, este capítulo tem como foco a análise de dados de sinais CSI para monitoramento de sinais vitais humanos. Discutem-se técnicas de detecção, reconhecimento e estimativa de sinais vitais através de CSI. Dessa maneira há uma diretriz abrangente para adotar o CSI para fins de saúde sob uma perspectiva segura, escalável e de baixo custo. Por fim, apresentam-se as tendências e desafios futuros para aprimorar os recursos de detecção de sinais vitais através de CSI existentes e habilitar novas aplicações para o monitoramento da saúde.

Na Seção 5.2, são apresentados os principais conceitos relacionados a Wi-Fi CSI, com os conceitos básicos de modulação OFDM, a modelagem do canal sem fio Wi-Fi

e apontam-se as ferramentas utilizadas para a extração de características do canal, utilizando o *Channel State Information* (CSI). Na Seção 5.3, são discutidas as principais ferramentas utilizadas para processar os dados de CSI e algoritmos de detecção dos sinais vitais de indivíduos em ambientes monitorados por CSI. Na Seção 5.4, apresentam-se algumas aplicações de monitoramento de sinais vitais através de Wi-Fi CSI encontradas na literatura. Na Seção 5.5, uma atividade prática é discutida, mostrando todos os passos para se realizar o monitoramento da respiração de um indivíduo através do processamento de dados CSI. Já na Seção 5.6, destacam-se os desafios da obtenção e processamento dos dados de CSI e uma prospecção da diversidade de cenários e possíveis aplicações futuras dessa tecnologia. Por fim, a Seção 5.7 apresenta as considerações finais do capítulo.

## 5.2. Wi-Fi CSI

Esta seção apresenta uma visão geral de como os dados CSI são obtidos utilizando dispositivos Wi-Fi e como eles podem ser processados e utilizados em algumas aplicações. A Figura 5.1, adaptada de [Ma et al. 2019a], mostra a arquitetura geral do sistema usado para coleta, tratamento e estimativa de atividades humanas usando dados Wi-Fi CSI.

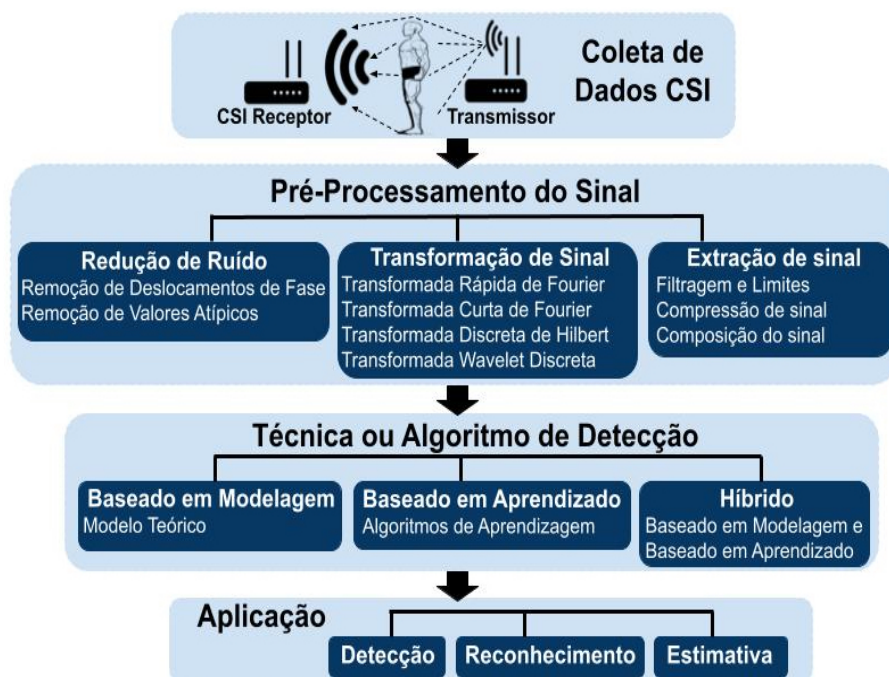


Figura 5.1. Estrutura do sistema Wi-Fi CSI

Em geral, o processo de coleta do CSI é realizado por um dispositivo equipado com placa de interface de rede (NIC - *Network Interface Card*). Então, o sinal de base adequado escolhido, como amplitude e/ou fase, deve ser extraído das informações coletadas. O sinal extraído alimenta o módulo de pré-processamento de sinal em uma segunda fase. Nesta fase, a fim de remover o ruído do sinal e obter dados CSI mais precisos, abordagens de pré-processamento são essenciais. O pré-processamento é realizado através de técnicas de redução de ruído, transformação de sinal e filtragem [Ma et al. 2019a, Gu et al. 2017, Gu et al. 2018]. Após o pré-processamento do sinal, segue-se a análise das ativi-

dades humanas por meio de algoritmos baseados em modelagem teórica e/ou algoritmos baseados em aprendizado. O algoritmo baseado em modelagem geralmente utiliza modelos típicos, como modelo de zona de Fresnel e ângulo de chegada (do inglês, *Angle-of-Arrival* - AoA). A abordagem baseada em modelagem enfrenta desafios na construção de um modelo. A abordagem baseada em aprendizado é usada principalmente em aplicações de identificação de movimento. Apesar de exigir uma etapa de treinamento, essa abordagem pode alcançar um bom desempenho. Finalmente, a aplicação pode detectar, estimar ou reconhecer algumas atividades humanas e sinais vitais [Ma et al. 2019a, Bowen et al. 2019a, Duan et al. 2018a]. Em suma, a arquitetura apresentada fornece uma visão geral da estrutura baseada em CSI para monitoramento de sinais vitais. Uma análise mais detalhada de cada uma das etapas será apresentada nas seções a seguir.

### 5.2.1. Modelagem Matemática do Canal

Esta seção apresenta um modelo matemático do sistema utilizado para coletar os dados CSI. Na especificação IEEE 802.11g/n/ac [IEEE 802.11 Working Group 2003, IEEE 802.11 Working Group 2009, IEEE 802.11 Working Group 2013], a camada física dos sistemas de comunicação Wi-Fi utiliza a técnica de modulação OFDM para bandas de frequência de 2.4GHz e 5GHz. O OFDM é uma técnica de modulação que utiliza um número pré-definido de subportadoras ortogonais entre si [Weinstein and Ebert 1971]. Consequentemente, as informações podem ser transmitidas independentemente entre si e também entre diferentes símbolos OFDM. As características intrínsecas ao OFDM o tornam uma boa alternativa para canais com múltiplos percursos e também para sistemas com múltiplas entradas e múltiplas saídas (do inglês, *Multiple-Input Multiple-Output* - MIMO).

Para coletar o sinal CSI, o transmissor Wi-Fi envia um sinal pré-definido (do inglês, *Long Training Fields* - LTFs), que contém informações em cada uma das subportadoras do preâmbulo do bloco. Na recepção, o receptor Wi-Fi estima as informações CSI representadas pela matriz ( $\mathbf{H} \in \mathbb{C}^{M \times M}$ ), utilizando para isso o sinal recebido e os LTFs transmitidos. Desta forma, o sinal recebido  $y$  pode ser modelado no domínio da frequência como  $y = \mathbf{H}x + n$ , onde  $x$  e  $y \in \mathbb{C}^{M \times 1}$  representam os símbolos OFDM transmitidos e recebidos respectivamente,  $\mathbf{H}$  é uma matriz complexa que contém o sinal CSI, e  $n \in \mathbb{C}^{M \times 1}$  representa o ruído [Lee et al. 2018].

Considerando um sistema Wi-Fi MIMO com  $m$  antenas transmissoras e  $n$  antenas receptoras, operando sob a especificação IEEE 802.11n, o sinal que contém a informação CSI estimada de cada fluxo de dados entre as antenas transmissoras e receptoras pode ser expresso como

$$\mathbf{H} = \begin{pmatrix} \mathbf{h}_{1,1} & \mathbf{h}_{1,2} & \cdots & \mathbf{h}_{1,n} \\ \mathbf{h}_{2,1} & \mathbf{h}_{2,2} & \cdots & \mathbf{h}_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{h}_{m,1} & \mathbf{h}_{m,2} & \cdots & \mathbf{h}_{m,n} \end{pmatrix}, \quad (1)$$

onde  $\mathbf{h}_{i,j} \in \mathbb{C}^{M \times M}$  representa os dados CSI entre a  $i$ -ésima antena de transmissão e a  $j$ -ésima antena de recepção.

Seja  $M$  o número de subportadoras do bloco OFDM utilizadas para estimar os dados CSI, a informação de estado do canal estabelecida entre um par de antenas ( $i, j$ ),

definida por  $\mathbf{h}_{i,j} \in \mathbb{C}^{(M \times 1)}$ , pode ser representada matematicamente por um vetor contendo  $M$  elementos. Usa-se  $\mathbf{h}$  para representar um  $h_{i,j}$  genérico como

$$\mathbf{h} = [h_1, h_2, \dots, h_M]^T. \quad (2)$$

Esta análise pode ser desenvolvida utilizando tanto a técnica de RSSI quanto a de Wi-Fi CSI. Entretanto, a análise utilizando Wi-Fi CSI pode fornecer mais informações do que utilizando RSSI, pois a matriz de dados coletados é semelhante a uma imagem digital com alta resolução espacial.

### 5.2.2. Extração de dados CSI

Após apresentar o modelo matemático do sistema utilizado para obter os dados CSI, esta seção descreve brevemente algumas ferramentas utilizadas para capturar e coletar os dados CSI. Várias ferramentas têm sido propostas e estudadas na literatura para acessar os dados CSI com placas de rede de dispositivos Wi-Fi. A Tabela 5.1 resume algumas das ferramentas mais conhecidas [Gringoli et al. 2019].

**Tabela 5.1. Ferramentas para extração de dados CSI**

Ferramenta	Chipsets	Max. BW	Tecnologia
Linux 802.11n CSI Tool [Halperin et al. 2011]	IWL5300	40MHz	802.11n
Atheros CSI Tool [Xie et al. 2018]	AR9580, AR9590 AR9344, QCA9558	40MHz	802.11n
OpenFWWF CSI Tool [Gringoli and Nava 2009]	BCM4318	20MHz	802.11g
Nexmon CSI Extractor [Schulz et al. 2018]	BCM4365, 66 BCM4339, 58, 455	80MHz	802.11ac
GNU Radio [Khan et al. 2017]	USRP B200	80MHz	802.11ac

Linux 802.11n CSITool [Halperin et al. 2011] é uma ferramenta de extração que utiliza o chipset Intel Wi-Fi *Wireless Link* 5300 802.11n rádio MIMO. Esse é um *firmware* modificado que inclui todos os procedimentos adequados para capturar, coletar e analisar os dados CSI de um canal sem fio usando um *driver* de rede sem fio Linux de código aberto. Essa ferramenta inclui todos os *softwares* e *scripts* necessários para executar experimentos, ler e analisar medições de estado do canal, o que a torna uma boa alternativa para monitoramento de sinais vitais por meio de dados Wi-Fi CSI. O *chipset* IWL5300 802.11n fornece informações de estado do canal em um formato matricial. Cada entrada da matriz de canal é um número complexo, com resolução de 8 bits com sinal para as partes real e imaginária. Ele especifica o ganho e a rotação de fase de cada um dos caminhos entre um único par de antenas de transmissão e recepção.

Atheros-CSI-Tool [Xie et al. 2018] é outra ferramenta utilizada para capturar, coletar e analisar dados CSI. Ela permite a extração de informações detalhadas de comunicação sem fio das placas de rede Wi-Fi Atheros. Atheros-CSI-Tool é um *firmware* modificado em um *kernel* Linux de código aberto que utiliza interface de rede 802.11n e opera em várias distribuições Linux, por exemplo, Ubuntu, OpenWRT e Linino. Portanto, está disponível para computadores pessoais, dispositivos embarcados, como roteadores Wi-Fi e dispositivos de Internet das Coisas (do inglês, *Internet of Things* - IoT).

OpenFWWF CSI Tool (do inglês, *Open FirmWare for Wi-Fi networks*) [Gringoli and Nava 2009] é um projeto focado em fornecer uma plataforma completa e econômica para implementar novos protocolos de controle de acesso ao meio (do inglês, *Medium Access Control* - MAC), nos quais a realização de testes é simplificada. Ele também oferece *firmware* de código aberto para chips Broadcom e adota um método de engenharia reversa para obter dados CSI.

O Nexmon CSI Extractor [Schulz et al. 2018] foi proposto para permitir aos pesquisadores acesso ao processamento de quadros de camada inferior e funcionalidades avançadas na camada física. Nexmon é um *firmware* baseado na linguagem de programação C, desenvolvido para chips Wi-Fi *Broadcom/Cypress*, que se concentra principalmente em habilitar o modo de monitoramento para extração de dados CSI. Ele permite a extração de informações de canais de comunicação sem fio entre dois dispositivos Wi-Fi. O Nexmon CSI opera em dispositivos Wi-Fi MIMO com largura de banda de até 80 MHz, além de ser compatível com os padrões 802.11a/n/ac. Ele pode ainda ser usado em dispositivos móveis, como *smartphones*, e em dispositivos de baixo custo, como *Raspberries*.

GNU Radio é um *software* [Khan et al. 2017] de código aberto que permite o desenvolvimento gráfico de módulos de processamento de sinal. É utilizado sem *hardware* específico de forma simulada, ou com *hardware* de RF (Radiofrequência) externo como o USRP. O USRP é projetado para aplicações de RF a 6 GHz, incluindo sistemas MIMO. Exemplos de áreas de aplicação incluem telefonia celular, segurança pública, monitoramento de espectro, redes de rádio, rádio cognitivo, navegação por satélite e rádio amador. O monitoramento de espectro é como o rádio GNU e o USRP são usados para coletar, extrair e analisar dados CSI.

### **5.3. Processamento do Wi-Fi CSI para Monitoramento de Sinais Vitais**

Após a coleta dos dados CSI, são necessários procedimentos para limpar do sinal os ruídos inerentes ao canal de comunicação sem fio e aplicar algoritmos que permitam a detecção de sinais vitais. Nesta seção são abordadas essas técnicas.

#### **5.3.1. Processamento dos sinais de CSI**

Seguindo a arquitetura apresentada na Figura 5.1, na etapa 2 é realizado um procedimento de pré-processamento do sinal capturado que contém os dados CSI. Com base em vários estudos encontrados na literatura [Liu et al. 2019, Wang et al. 2019, Ma et al. 2019b, Uchiyama et al. 2021], esta seção apresenta uma classificação e subclassificação das técnicas mais conhecidas utilizadas na etapa de pré-processamento do sinal recebido.

O sinal obtido através de uma ferramenta de extração, e.g. aquelas apresentadas

na Seção 5.2.2, usualmente está contaminado por ruídos e/ou *outliers*, que podem reduzir e prejudicar o desempenho da detecção. Com o objetivo de mitigar ou diminuir os efeitos causados pelo ruído e *outliers*, são aplicadas técnicas de **redução de ruído**. As técnicas de redução de ruído podem ser classificadas em dois grupos: compensação de fase e remoção de *outliers*. A compensação de fase é importante pois em sistemas de comunicação sem fio sempre há deslocamentos de sinal devido a falhas ocasionadas pelo *hardware* ou *software* e também devido a características dos canais multipercurso. Algumas técnicas de remoção de deslocamentos de fase comumente usadas são baseadas em compensação de tempo e/ou frequência de amostragem [Wang et al. 2017c, Wang et al. 2017b], compensação de frequência da portadora [Wang et al. 2017c, Wang et al. 2017b], compensação de erros de sincronização entre dispositivos [Wang et al. 2017c], atraso de detecção de pacotes, diferença de fase e ainda, regressão linear múltipla.

Enquanto isso, as técnicas de remoção de *outliers* servem para eliminar ruídos de alta frequência presentes no sinal recebido. Algumas técnicas neste grupo são baseadas em média móvel [Wang et al. 2016b, Wu et al. 2017, Li et al. 2021, Liu et al. 2018], filtro mediano [Ma et al. 2016, Liu et al. 2015a, Shang and Wu 2016, Yang et al. 2018], filtro passa-baixa, filtro *wavelet* [Liu et al. 2015b, Liu et al. 2014], filtro de Hampel [Ma et al. 2016, Wang et al. 2016b, Zhang et al. 2018, Zhang et al. 2019, Dou and Huan 2021, Wang et al. 2017c, Li et al. 2021, Liu et al. 2015a, Liu et al. 2018, Wang et al. 2017b, Liu et al. 2015b, Liu et al. 2014, Gu et al. 2021], filtro Savitzky-Golay [Dou and Huan 2021, Zeng et al. 2019], fator *Outlier Local*, anulação de sinal, entre outros.

Outro conjunto de técnicas que também podem ser aplicadas nesta etapa é a **transformação do sinal**, que é utilizada para analisar o sinal recebido no domínio da frequência. Algumas transformações que auxiliam na análise da frequência são: a transformada rápida de Fourier (do Inglês, *Fast Fourier Transform* - FFT) [Wang et al. 2017a, Liu et al. 2015a, Lee et al. 2018, Wang et al. 2020, Wang et al. 2017b, Khan et al. 2017] amplamente utilizada para encontrar frequências dominantes, a transformada curta de Fourier (do Inglês, *Short Time Fourier Transform* - STFT) [Dou and Huan 2021, Li et al. 2021, Liu et al. 2015b], que divide o sinal em segmentos iguais e calcula a FFT em cada segmento independente, a transformada discreta de Hilbert (do Inglês, *Discrete Hilbert Transform* - DHT) que incorpora o deslocamento de fase e é útil para encontrar mudanças instantâneas em um determinado instante de tempo dentro do sinal, e também a transformada discreta de *wavelet* (do Inglês, *Discrete Wavelet Transform* - DWT) [Wang et al. 2017a, Wang et al. 2020, Wang et al. 2017b, Liu et al. 2014], que fornece uma análise do sinal recebido em alta resolução, porque descompõe o sinal em conjuntos de tempos que fornecem a evolução temporal do sinal nas frequências correspondentes.

A **extração de sinal** é a última etapa do pré-processamento. Ele pode ser realizado filtrando e limitando as componentes de frequência do sinal, onde os filtros passa-alta [Zhang et al. 2019], passa-baixa [Shang and Wu 2016] e passa-banda [Zhang et al. 2018] são amplamente utilizados para extrair sinais com determinadas frequências dominantes. A compressão do sinal é importante para reduzir os sinais a poucas ou a uma única dimensão mas que ainda assim represente a enorme quantidade de sinais capturados. Para isso, algumas das técnicas utilizadas incluem Análise de Componentes Principais (do Inglês, *Principal Component Analysis* - PCA) [Li et al. 2021], Análise de Componentes Independentes (do Inglês, *Independent Component Analysis* - ICA) [Zeng et al. 2020, Zhang



et al. 2017], Decomposição de Valor Singular (do Inglês, *Singular Value Decomposition - SVD*) [Liu et al. 2014], autocorrelação, correlação cruzada, distância euclidiana, função distribuição, entre outros. Finalmente, a Composição do Sinal é uma técnica usada para estimar ou detectar um fenômeno usando vários dispositivos ou características de banda de frequência.

### 5.3.2. Algoritmos de Detecção de Sinais Vitais

A terceira etapa da arquitetura apresentada na Figura 5.1 é o uso de algoritmos de detecção. Três grupos de algoritmos podem ser usados nesta etapa: aqueles baseados em modelagem, aqueles baseados em aprendizado e também os algoritmos híbridos. Os algoritmos **baseados em modelagem** são fundamentados pela teoria física, como modelos de análise de sinal. Para esta análise, usa-se o sinal obtido após a etapa de pré-processamento e examinam-se os efeitos causados nas informações CSI através de diversos fenômenos. Por exemplo, a atenuação de amplitude e a mudança de fase do sinal recebido podem ser afetadas pela distância entre o transmissor e o receptor, assim como os efeitos dos múltiplos percursos, incluindo reflexão de rádio, refração, difração, absorção, polarização e espalhamento [Ma et al. 2016, Wang et al. 2016b, Zhang et al. 2018, Zhang et al. 2019, Dou and Huan 2021, Wang et al. 2017c, Wu et al. 2017, Wang et al. 2017a, Zeng et al. 2018, Liu et al. 2015a, Shang and Wu 2016, Wang et al. 2017b, Khan et al. 2017, Yang et al. 2018, Gu et al. 2021]. Dentre os algoritmos baseados em modelagem, existem ainda os modelos estatísticos, baseados em medições empíricas, e os modelos probabilísticos, como o modelo usado para determinar o estado do canal sem fio, e.g. densidade espectral de potência, coerência tempo/frequência, auto correlação e correlação cruzada, etc. [Wang et al. 2016b, Chen et al. 2017a, Liu et al. 2015a, Liu et al. 2018, Wang et al. 2020, Wang et al. 2017b, Zhang et al. 2017]. Esses tipos de algoritmos são amplamente utilizados para estimar os sinais vitais humanos.

O segundo grupo de algoritmos utilizados é **baseado em aprendizado** (*learning-based*). Algoritmos baseados em aprendizado são usados principalmente para reconhecimento de gestos humanos, posição e detecção da presença de pessoas. O aprendizado é realizado usando o conjunto de dados de treinamento, processado previamente aos dados que se deseja analisar, onde o efeito do fenômeno a ser detectado é refletido no CSI. Alguns dos algoritmos mais usados são: *Naive Bayes*, *k Nearest Neighbor*, *Support Vector Machine*, *Convolutional/Recurrent Neural Network* e *Long Short-Term Memory* [Wang et al. 2017c, Lee et al. 2018, Zhang et al. 2017].

Além dos já mencionados, a fusão de algoritmos levou ao uso de algoritmos ditos **híbridos** (*hybrid algorithms*). Os algoritmos híbridos combinam os benefícios de algoritmos baseados em modelos com aqueles dos algoritmos baseados em aprendizado. Essa combinação pode ser benéfica para o desenvolvimento de uma detecção mais robusta e completa, dependendo da aplicação.

## 5.4. Aplicações de Wi-Fi CSI para Monitoramento da Saúde

A maioria das pesquisas baseadas em análise CSI mostra três direções claras: detecção, reconhecimento e estimativa. A detecção está relacionada à classificação binária como detecção de presença humana, movimento de queda, mudança de postura, fadiga ao di-

rigir, intrusão, tabagismo, entre outros. Já as pesquisas sobre reconhecimento são basicamente uma classificação multiclasse como reconhecimento de atividades que incluem atividades diárias, exercícios, fala, reconhecimento de gestos com o corpo, cabeça, braço, mão, perna, dedo e gestos, reconhecimento de linguagem de sinais, identificação, autenticação de usuário e reconhecimento de objetos. A terceira direção de pesquisa baseada em análise CSI é a estimativa. Essa categoria envolve quantidade, valores de tamanho, comprimento, ângulo, distância, duração, frequência, contagens, movimento, desenho à mão, velocidade, localização/rastreamento humano baseado em dispositivo, estimativa de umidade, respiração/frequência respiratória e estimativa de frequência cardíaca. Essas estimativas podem envolver uma única pessoa, ou várias pessoas, para aplicações de contagem humana, indicando se estão estáticos ou em movimento, entre outras.

Vários estudos relacionados a diferentes atividades humanas aplicam a análise de dados CSI. [Gu et al. 2018, Gu et al. 2017, Bowen et al. 2019a, Duan et al. 2018a, Damodaran et al. 2020]. Esses trabalhos podem servir como ponto de partida para desenvolver aplicativos de monitoramento de saúde, levando a um sistema robusto de detecção e monitoramento de sinais vitais. Em [Gu et al. 2018] por exemplo, os autores propuseram um sistema chamado EmoSense para detectar emoções humanas. O EmoSense analisa as impressões digitais de tempo e frequência nos dados do canal sem fio casadas pela expressão física das emoções. Em [Gu et al. 2017], os autores propuseram um sistema denominado MoSense para detectar os movimentos que são indicadores críticos da presença humana e das atividades humanas. Além disso, em [Bowen et al. 2019a], foi proposta uma tomografia radioelétrica para detectar pessoas e a passagem de água. Outra abordagem foi apresentada em [Duan et al. 2018a], onde os autores propuseram um sistema denominado WiDriver para monitorar as atividades de um motorista de veículo pesado. Foram detectadas atividades como movimentos do volante, utilização de celulares e escrita de mensagens de texto no celular. Mais recentemente, em [Damodaran et al. 2020], os autores abordaram várias atividades humanas como andar, sentar, ficar em pé e correr.

A análise dos dados CSI apresenta alto potencial para se tornar uma tecnologia poderosa para monitorar os aspectos físicos do ambiente em geral. Este capítulo concentra-se na utilização de dados CSI para monitorar os sinais vitais humanos. Esses sinais são classificados principalmente em (i) frequência respiratória, que é o número de ciclos de respiração que uma pessoa faz por minuto; (ii) frequência cardíaca, que é o número de vezes que o coração se contrai durante um determinado período de tempo, geralmente um minuto (bpm). Esses dois sinais vitais, contados em várias respirações ou batimentos, oferecem informações importantes para determinar o estado de saúde atual do indivíduo. Vale ressaltar que podemos encontrar na literatura diversos estudos para detectar, reconhecer e estimar esses sinais vitais. As técnicas baseadas em Wi-Fi CSI para monitoramento de sinais vitais apresentam-se bastantes atraentes em comparação com as demais devido às suas características como o baixo custo, facilidade de implantação e ausência de dispositivos em contato direto com o corpo do indivíduo.

Nesta seção serão descritos estudos que utilizam dados Wi-Fi CSI para monitorar sinais vitais. Para tanto, destacam-se os sinais vitais monitorados e os recursos relevantes do aplicativo, monitoramento em tempo real ou não e consideração de múltiplas pessoas ou cada indivíduo, conforme apresentado na Figura 5.2. A seguir, são descritas as aplicações de monitoramento de sinais vitais, e as técnicas utilizadas no processo são

apresentadas de acordo com a classificação proposta na Seção 5.2.




Figura 5.2. Diagrama de aplicações de sinais vitais

#### 5.4.1. Monitoramento da Respiração

Muitos estudos recorrem aos dados CSI para monitorar os sinais vitais de um indivíduo. O WiSleep [Liu et al. 2014] foi o primeiro trabalho a detectar a taxa de respiração humana para monitoramento do sono com base em dados CSI utilizando dispositivos Wi-Fi comuns. A abordagem proposta, sem dispositivos físicos fixados ao indivíduo, tem potencial para ser amplamente implantada não somente em ambientes clínicos, como hospitais, mas também em ambientes não clínicos.

Desde então, diversos estudos foram desenvolvidos na tentativa de melhorar o monitoramento da frequência respiratória utilizando dados Wi-Fi CSI. Em [Wang et al. 2016b] por exemplo, os autores inicialmente introduziram a utilização da Zona de Fresnel (do Inglês, *Fresnel Zone* - FZ) no espaço livre, em seguida verificaram sua aplicabilidade em propagação de rádio Wi-Fi considerando ambiente interno. Eles desenvolveram uma teoria para relacionar a profundidade, localização e orientação da respiração de uma pessoa com a detectabilidade da respiração. Com a teoria desenvolvida, não só fica claro quando e por que a respiração humana é detectável utilizando dispositivos Wi-Fi, mas também esclareceu-se a compreensão do limite físico e a fundamentação dos sistemas de detecção baseados em Wi-Fi.

Seguindo a mesma linha de raciocínio, os autores de [Wu et al. 2017] compararam as abordagens baseadas em padrões e as baseadas em modelos para monitorar a taxa de respiração. Eles propuseram expandir o alcance de detecção do modelo Fresnel usado para as vastas regiões fora da primeira Zona de Fresnel. Eles mostraram a superioridade da detecção humana baseada no modelo da Zona de Fresnel em relação às abordagens baseadas em padrões e argumentaram que as abordagens baseadas no modelo de Zona de Fresnel têm grande potencial para alcançar escala centimétrica e até milimétrica na detecção de atividade humana, permitindo um amplo espectro de aplicações. Além disso, os autores [Ma et al. 2016] também usaram o modelo baseado em Zona de Fresnel e

mostraram como uma mudança de posição na escala de centímetros afeta o desempenho da detecção da respiração.

Também com foco no modelo de Zona de Fresnel, os autores de [Zhang et al. 2018] utilizaram o modelo de difração de Fresnel para quantificar com precisão a relação entre o ganho de difração e o sutil deslocamento do tórax do alvo humano, e assim transformar com sucesso a difração de obstrução destrutiva anteriormente considerada na Primeira Zona Fresnel (do Inglês, *First Fresnel Zone* - FFZ), em capacidade de detecção benéfica. Eles foram capazes de apresentar o mapa de calor detalhado da capacidade de detecção em cada local dentro da FFZ, para orientar o sensor de respiração para que os usuários saibam claramente onde estão as posições adequadas para o monitoramento da respiração, assim como identificar se estão em uma posição desfavorável.

Outro sistema, denominado *BreathTrack*, foi proposto por [Zhang et al. 2019] para rastrear o estado da respiração humana utilizando sinais CSI Wi-Fi. Nele os autores propuseram métodos de correção via *hardware* e *software* para remover as distorções de fase invariantes e variantes no tempo e.g. deslocamento de frequência da portadora (do Inglês, *Carrier Frequency Offset* - CFO), deslocamento de frequência de amostragem (do Inglês, *Sampling Frequency Offset* - SFO), atraso de detecção de pacotes (do Inglês, *Packet Detection Delay* - PDD) e *PLL Phase Offset* (PPO), e assim obter dados CSI precisos. Eles também propuseram um método de recuperação esparsa conjunta: ângulo de chegada e tempo de voo (AoA-ToF, do inglês *Angle of Arrival* - *Time of Flight*) para obter o coeficiente de atenuação complexo correspondente, eliminar o efeito de multipercurso no ambiente interno e também extrair a informação do caminho dominante para rastrear o status da respiração. Além disso, em relação à fase dos sinais Wi-Fi, os autores [Zeng et al. 2018] descobriram que sua amplitude e fase são perfeitamente complementares entre si. Eles detalharam o modelo matemático e exploraram a natureza complementar para projetar e implementar um sistema de detecção de respiração em tempo real com dispositivos Wi-Fi comuns. Eles também utilizaram o modelo de Zona de Fresnel. Além disso, os autores de [Wang et al. 2017c] utilizaram a diferença de fase dos dados CSI para estimar de forma inteligente as taxas de respiração para várias pessoas com dispositivos Wi-Fi comuns. Inicialmente, os dados de diferença de fase dos dados CSI entre pares de antenas no receptor Wi-Fi foram usados para criar tensores CSI. Em seguida, foi aplicada a decomposição poliádica canônica [Sorber et al. 2013] (do Inglês, *Canonical Polyadic Decomposition* - CPD) para obter os sinais respiratórios desejados.

Em outra abordagem, os autores de [Wang et al. 2017a] exploraram a detecção da respiração de várias pessoas simultaneamente. Para mitigar o efeito causado por outras pessoas, foi colocado um receptor ao lado de cada usuário, em seguida foram selecionados os dados cujo tempo de chegada (do inglês, *Time of Arrival* - ToA) era maior que um limite de truncamento pré-definido. Também com foco no contexto de várias pessoas em um mesmo ambiente, em [Chen et al. 2017a], os autores introduziram o TR-BREATH, um sistema de monitoramento de respiração baseado em reversão de tempo (do inglês, *Time-Reversal* - TR). Esse sistema é capaz de detectar a respiração e estimar a taxa de respiração de várias pessoas em um curto período de tempo. O TR-BREATH projeta o sinal no espaço de recursos de força ressonante TR (do inglês, *TR Resonating Strength* - TRRS) e analisa o TRRS usando o *Root-MUSIC* e algoritmos de propagação de afinidade para ampliar as variações de CSI. Se a respiração for detectada, o TR-BREATH estima

as taxas de respiração de várias pessoas por meio de propagação de afinidade, atribuição de probabilidade e mesclagem de *cluster*. Além disso, é possível estimar o número de pessoas presentes no ambiente com um erro de aproximadamente 1 ao comparar com o conhecimento prévio do número real de pessoas.

O sistema MultiSense [Zeng et al. 2020] foi desenvolvido para detectar de forma robusta e contínua os padrões detalhados de respiração de várias pessoas, mesmo que tenham taxas de respiração muito semelhantes e estejam fisicamente próximas. Atualmente, os *hardwares* de Wi-Fi mais utilizados geralmente são equipados com várias antenas. Assim, cada antena individual pode receber uma cópia de misturas de diferentes sinais refletidos de várias pessoas. Os autores provaram com sucesso que os sinais refletidos são misturados linearmente em cada antena e propuseram modelar o sensor de respiração de várias pessoas como um problema de separação de fontes cegas (do inglês, *Blind Source Separation* - BSS). Eles resolveram o problema utilizando o ICA para separar o sinal misto e obter as informações de respiração de cada pessoa.

Em [Dou and Huan 2021], os autores usaram ainda a variação da energia espectral Doppler extraída do CSI coletado por dispositivos Wi-Fi para rastrear o deslocamento do tórax induzido pela respiração. O sinal de respiração é extraído da mudança de energia espectral acumulada do deslocamento Doppler na frequência zero de acordo com a periodicidade da ação da respiração.

A proposta FarSense, apresentada em [Zeng et al. 2019], propôs o primeiro sistema que trabalha em tempo real e que pode monitorar a respiração humana de forma confiável quando o alvo está longe (dentro do limite de 8 metros) do par de transceptores Wi-Fi, preenchendo a lacuna entre protótipo de laboratório e implantação na vida real. Os autores propuseram um método chamado CSI-ratio que combina a amplitude e a fase de duas antenas adjacentes para uma melhor estimativa da respiração.

Mais recentemente, o sistema chamado Wi-COVID foi introduzido em [Li et al. 2021]. Essa é uma tecnologia não invasiva e livre de dispositivos fixados ao indivíduo para monitorar indivíduos e rastrear a taxa de respiração para o profissional de saúde. Os autores exploraram a possibilidade de usar a tecnologia baseada em Wi-Fi para monitorar em tempo real pacientes diagnosticados com COVID-19 que estão realizando auto-isolamento. Eles propuseram o uso de um *Raspberry Pi* que funciona como uma espécie de ponto de acesso. Na parte do *software*, eles usaram códigos abertos para implementar o processamento de dados CSI em um *Raspberry Pi*.

Em [Li et al. 2021], os autores usaram o Nexmon para extrair dados CSI do quadro Wi-Fi modulado com OFDM 802.11n por quadro com largura de banda de até 80 MHz no chip Broadcom Wi-Fi de um *Raspberry Pi*. Assim, sua implementação foi mais simples do que outras propostas, pois eles precisavam apenas de um roteador Wi-Fi pronto para uso e um *Raspberry Pi*.

A Tabela 5.2 apresenta um resumo e comparação dos estudos citados sobre monitoramento da respiração usando análise de dados Wi-Fi CSI juntamente com suas próprias características. Apresentamos as ferramentas de processamento de sinal utilizadas, como filtragem de ruído (do inglês, *noise filtering* - NF), transformada de sinal (do inglês, *Transformation do sinal* - ST) e ferramentas de extração de sinal (do inglês, *Signal Extraction* -

SE). Detalhes de quais algoritmos usam quais técnicas de processamento de sinal e para quais aplicativos de detecção de Wi-Fi eles são usados também são discutidos. Também é indicado se a operação é realizada em tempo real ou não.

Na Tabela 5.2, pode-se observar que a maioria dos estudos utiliza a ferramenta de extração Linux 802.11n CSI Tool. Esse fato se deve à natureza da maior parte dos dispositivos Wi-Fi que utilizam Linux. Vale ressaltar que uma nova proposta foi aplicada recentemente aos sistemas de monitoramento de saúde Wi-Fi CSI usando Nexmon. Essa é uma tecnologia promissora, pois oferece uso simples em dispositivos como *smartphones* e *Raspberries*.

Outro ponto importante a ser observado é a implementação em tempo real. Alguns estudos têm sido desenvolvidos com o objetivo de desenvolver o monitoramento em tempo real, o que os torna mais adequados para trabalhar em ambientes reais. Por outro lado, várias das propostas encontradas têm alta precisão, especialmente quando apenas um indivíduo é considerada no ambiente de teste. A precisão diminui com o aumento do número de indivíduos. Além disso, as configurações do ambiente e o posicionamento do indivíduo influenciam na precisão da proposta, oferecendo os melhores resultados quando os pacientes estão em boa posição, ou seja, na Primeira Zona de Fresnel.

#### **5.4.2. Monitoramento da Frequência Cardíaca**

O monitoramento da frequência cardíaca é outra tarefa relevante no acompanhamento dos sinais vitais para monitoramento da condição de saúde do indivíduo. Vários estudos monitoram a frequência cardíaca e a respiração simultaneamente, no entanto, foi encontrada apenas uma proposta na literatura para monitorar apenas a frequência cardíaca.

O sistema CardioFi, proposto em [Khamis et al. 2018], monitora a frequência cardíaca via *hardware* Wi-Fi com antenas omnidirecionais. O principal desafio observado foi o considerável nível ruído de radiofrequência que afeta as transmissões Wi-Fi em ambientes do mundo real. O CardioFi utiliza um esquema chamado *Dynamic-Window* para identificar um comportamento anômalo no sinal e descartar os sinais que não representam maior sensibilidade. Assim, eles obtiveram frequências altamente sensíveis. O CardioFi foi testado em cenários fora da linha de visão (do inglês, *Non-Line-Of-Sight* - NLOS) com uma baixa relação sinal-ruído (do inglês, *Signal-to-Noise Ratio* - SNR) e melhorou seu erro percentual. Essa solução considera o monitoramento de uma pessoa, que pode ser realizado em tempo real. No entanto, é apresentada apenas a arquitetura utilizada para a estimativa da frequência cardíaca, necessitando ser estendida para possibilitar a utilização em aplicações médicas de tempo real.

#### **5.4.3. Monitoramento da Respiração e da Frequência Cardíaca**

Também podemos encontrar na literatura trabalhos mais ambiciosos, que se concentraram não apenas no monitoramento da respiração, ou no monitoramento da frequência cardíaca, mas em ambos ao mesmo tempo. Por exemplo, em [Liu et al. 2015a], Liu et al. propuseram rastrear a respiração e a frequência cardíaca durante o sono utilizando dispositivos Wi-Fi prontos para uso. O algoritmo desenvolvido faz uso das informações do canal no domínio do tempo e da frequência para estimar a respiração e os batimentos cardíacos simultaneamente, e funciona bem quando um indivíduo ou duas pessoas estão

**Tabela 5.2. Monitoramento da respiração utilizando sinais Wi-Fi CSI**

Ref.	Ferramenta de extração	Pre-processamento	Algoritmos de detecção	Múltiplas pessoas	Tempo real	Desempenho
[Ma et al. 2016]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	Não	N/D
[Wang et al. 2016b]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	Não	N/D
[Zhang et al. 2018]	Linux 802.11n CSI Tool	Redução de ruído Extração do sinal	Baseado em modelos	Não	Não	Indivíduos bem posicionados 98.8%, mal posicionados 61.5%
[Zhang et al. 2019]	Linux 802.11n CSI Tool	Redução de ruído Extração do sinal	Baseado em modelos	Não	Não	Mais de 99%
[Dou and Huan 2021]	Linux 802.11n CSI Tool	Redução de ruído Transformação do sinal	Baseado em modelos	Não	Não	Erro máximo < 0.7 bpm, média de erro $\approx$ 0.15 bpm
[Zeng et al. 2020]	Linux 802.11n CSI Tool	Extração do sinal	Baseado em modelos	Sim	Não	Taxa de erros de 0.73 bpm (respirações por minuto)
[Wang et al. 2017c]	Linux 802.11n CSI Tool	Redução de ruído	Híbrido	Sim	Não	Erro de estimação: 1 pessoa 96% menos que 0.5bpm, 2 e 3 pessoas 93% menos que 0.5 bpm, e 5 pessoas 62% menos que 0.5bpm
[Wu et al. 2017]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	N/D	Erro médio: 0.09 bpm, 0.15 bpm, 0.06 bpm para três regiões detectáveis diferentes
[Wang et al. 2017a]	Linux 802.11n CSI Tool	Transformação do sinal	Baseado em modelos	Sim	Sim	> 95% (1 pessoa) > 88% (2 pessoas)
[Chen et al. 2017a]	Linux 802.11n CSI Tool	Transformação do sinal	Baseado em modelos	Não	Sim	Desempenho médio: uma pessoa NLOS 99%, 12 pessoas LOS 98.65%, 9 pessoas NLOS 98.07%
[Zeng et al. 2018]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	Sim	100% in LOS
[Zeng et al. 2019]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	Sim	A taxa geral de detecção 100%; Média absoluta de erros menor que 0.3bpm para taxa de respiração
[Li et al. 2021]	Nexmon CSI Extractor	Redução de ruído Extração do sinal	Baseado em modelos	Não	Sim	N/D

na cama.

Também em [Liu et al. 2018], Liu et al. reutilizaram a rede Wi-Fi existente para rastrear a respiração e os batimentos cardíacos simultaneamente durante o sono. Os resultados mostraram que o sistema proposto fornece uma estimativa precisa da frequência respiratória e da frequência cardíaca não apenas em configurações típicas, mas também abrangendo cenários desafiadores, incluindo a longa distância entre o dispositivo Wi-Fi e o ponto de acesso (do inglês, *Access Point* - AP), situações sem linha de visão direta (NLOS) e diferentes posturas de sono.

Também seguindo a linha de pesquisa que considera o monitoramento de vários sinais vitais, o PhaseBeat [Wang et al. 2017b] aproveita as diferenças de fase do sinal coletado entre duas antenas de recepção em dispositivos Wi-Fi para detectar e monitorar a frequência respiratória e cardíaca em tempo real. Os autores descobriram que os dados de diferença de fase são bastante estáveis após calibração adequada. Eles também provaram que, para ambientes com múltiplos percursos internos sob desvanecimento de pequena escala, os dados de diferença de fase representam um sinal periódico com a mesma frequência que o sinal de respiração quando o sinal sem fio é refletido no peito de uma pessoa. Eles também mostraram que o PhaseBeat é altamente robusto para estimativa da taxa de respiração em vários ambientes, como diferentes distâncias entre o transmissor e o receptor.

Em [Shang and Wu 2016], os autores projetaram um sistema de reconhecimento de respiração e batimentos cardíacos baseado em sinal Wi-Fi denominado Wi-Health. O sistema proposto tem a capacidade de determinar se um ser humano está vivo ou não, e o número de batimentos cardíacos e respirações por unidade de tempo. Eles também propuseram eliminar atividades humanas semelhantes, que têm frequência semelhante à respiração (0Hz - 1Hz), como acenar as mãos. A eliminação da frequência dessas atividades de forma eficaz se faz necessária, caso contrário, elas podem introduzir picos extras no espectro e ocasionar em estimativas imprecisas de respiração e batimentos cardíacos.

Além disso, em [Lee et al. 2018], os autores propuseram um método para reconhecer e distinguir as mudanças no padrão de respiração e frequência cardíaca de uma pessoa utilizando o sinal Wi-Fi CSI. A amplitude das ondas do sinal pode representar os movimentos periódicos do tórax para cima e para baixo causados pela respiração e batimentos cardíacos, e mudanças proeminentes no padrão do sinal podem ser detectadas usando o algoritmo DTW (do inglês, *Dynamic Time Warping*). Os autores mostraram que esse método pode identificar o estado físico da pessoa. Além disso, avaliaram a eficácia do método proposto através de vários experimentos com 10 participantes.

Mais recentemente, outro sistema que detecta respiração e frequência cardíaca, denominado PhaseBeat, foi apresentado em [Wang et al. 2020]. Foi realizada uma análise rigorosa da diferença de fase da informação do estado do canal em relação à sua estabilidade e periodicidade. Os autores mostraram que, para ambientes internos com múltiplos percursos e sob desvanecimento em pequena escala, os dados de diferença de fase do sinal coletado são periódicos e têm a mesma frequência que o sinal de respiração quando o sinal Wi-Fi é refletido no peito de uma pessoa. Além disso, a diferença de fase do CSI também é mais robusta do que o RSSI em vários cenários de implantação, como diferentes distâncias, obstáculos/paredes e orientações. Nessa proposta, a subportadora



mais sensível foi selecionada e processada por DTW para obtenção da informação sobre a respiração e dos batimentos cardíacos reconstruídos. Finalmente, eles aplicaram FFT para medir as frequências respiratória e cardíaca.

O resumo das aplicações desenvolvidas para monitoramento da respiração e dos batimentos cardíacos baseados em sinais Wi-Fi é apresentado na Tabela 5.3. Como pode-se notar, quando o foco está na aplicação dos sinais vitais monitorados, a maior parte das pesquisas desconsidera a operação em tempo real. Pode-se observar ainda que em geral a acurácia das propostas é maior e o erro médio é menor para a detecção da frequência respiratória em relação à detecção da frequência cardíaca. Além disso, a maioria desses estudos considera apenas o monitoramento de apenas um indivíduo de cada vez.

#### 5.4.4. Monitoramento de Múltiplos Sinais Vitais

Além da frequência respiratória e dos batimentos cardíacos, alguns estudos propuseram novas modalidades de sensoriamento das atividades humanas, como mudança de posição, micromovimentos, tremores, detecção de quedas, entre outros. A proposta do WiSleep [Liu et al. 2014], por exemplo, teve como foco extrair do CSI padrões rítmicos associados à respiração e mudanças bruscas devido ao movimento do corpo. A proposta do WiSleep foi estendida em [Liu et al. 2015b] para identificar de forma confiável a taxa de respiração na presença de ruído. A respiração é considerada periódica, no entanto, uma consequência indesejável é que informações como respiração anormal (por exemplo, apneia do sono) que violam a suposição periódica não são facilmente identificadas. Comparado com os trabalhos existentes, o sistema proposto em [Liu et al. 2015b] pode rastrear a respiração anormal (por exemplo, apneia do sono) e também pode fornecer informações sobre a respiração quando a pessoa está em diferentes posições de sono.

O sistema WiCare [Zhang et al. 2017] é outro exemplo de trabalho que utiliza sinais Wi-Fi CSI para monitorar diferentes sinais vitais em paralelo: frequência respiratória com a coexistência de alguns micromovimentos (por exemplo, ler, escrever, usar o telefone). Mais especificamente, o WiCare é capaz de distinguir os micromovimentos de um indivíduo específico de sua respiração. Esta abordagem baseia-se no fato de que a respiração resulta em flutuações da informação CSI com banda de frequência mais estreita em comparação com os micromovimentos.

Em [Khan et al. 2017], os autores apresentaram um sistema de extração de fase bidimensional usando sensor Wi-Fi passivo para monitorar três atividades básicas de cuidados com idosos, incluindo frequência respiratória, tremor essencial e quedas. Toda a implementação foi realizada usando rádios definidos por *software*. Os autores também usaram técnicas de processamento de sinais para analisar a função de ambiguidade cruzada e identificar variações de fase em dois planos separados.

Os autores de [Gu et al. 2021] propuseram um método para aprimorar a capacidade de detecção de movimento baseado na teoria Rice-K e na teoria de Fresnel. Movimentos como o giro afetam a precisão do monitoramento dos sinais vitais, assim, eles também propuseram um algoritmo de detecção da alteração da posição baseado na detecção de regularidade para distinguir rapidamente esses movimentos.

A dificuldade de monitorar a respiração do sono de várias pessoas geralmente

Tabela 5.3. Monitoramento da frequência respiratória e da frequência cardíaca usando sinais Wi-Fi CSI

Ref.	Ferramenta de extração	Pre-processamento	Algoritmos de detecção	Múltiplas pessoas	Tempo real	Desempenho
[Liu et al. 2015a]	Linux 802.11n CSI Tool	Redução de ruído Transformação do sinal	Híbrido	Não	Não	Erro da taxa de respiração: < 1.1bpm (1 pessoa), < 1.2bpm (2 pessoas); Erro da taxa cardíaca: < 5bpm (1 pessoa)
[Lee et al. 2018]	Linux 802.11n CSI Tool	Transformação do sinal Extração do sinal	Baseado em modelos	Não	Não	Taxa de respiração 94% frequência cardíaca 82%
[Liu et al. 2018]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	Não	Erros de estimação 80% < 0.5rpm para a taxa de respiração, 90% < 4bpm para a taxa cardíaca
[Wang et al. 2020]	Linux 802.11n CSI Tool	Transformação do sinal	Baseado em modelos	Não	Não	Erro médio: 0.25 respirações por minuto (rpm) para taxa de respiração; 1.19 bpm para taxa cardíaca
[Shang and Wu 2016]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Não	N/D	Erro médio de estimativa abaixo de: 0.6rpm para taxa de respiração; 6bpm para taxa cardíaca
[Wang et al. 2017b]	Linux 802.11n CSI Tool	Redução de ruído Transformação do sinal	Baseado em modelos	Não	Sim	Erro de estimação: < 0.85rpm para taxa de respiração, < 10bpm para taxa cardíaca

vem da necessidade de separar os efeitos da respiração de cada uma das pessoas. Outro problema é que, embora a separação possa ser viável com alguns algoritmos, ainda é complexo mapear os múltiplos estados respiratórios identificados para as pessoas correspondentes. Para resolver este problema, os autores de [Yang et al. 2018] propuseram uma abordagem através da implantação de transceptores Wi-Fi. Um transceptor Wi-Fi cuidadosamente colocado pode ser afetado apenas pela pessoa em um determinado local. Além disso, eles consideraram a movimentação do indivíduo durante o sono, bem como a mudança de postura, isso para melhorar a robustez do sistema. Assim, empregaram a diferença entre o valor máximo e mínimo e a variação da amplitude do pico extraída do domínio da frequência entre os fluxos CSI de todas as subportadoras para detectar apneia.

A Tabela 5.4 resume e compara os estudos citados sobre o monitoramento de diferentes sinais vitais usando análise Wi-Fi CSI. São apresentadas também algumas de suas características como ferramentas de processamento e extração de sinais, modelo utilizado e desempenho. Também é indicada se a operação é realizada em tempo real ou não. Conforme mostrado na Tabela 5.4, a maioria dos estudos focados no monitoramento de diversos sinais vitais considera também uma implementação em tempo real e algoritmos de detecção baseados em modelos. Nesses, a precisão da detecção da frequência respiratória é ligeiramente inferior quando comparada às propostas de detecção de apenas uma pessoa mencionadas nas seções anteriores.

Tabela 5.4. Monitoramento de múltiplos sinais vitais usando Wi-Fi CSI

Ref.	Ferramenta de extração	Pre-processamento	Algoritmos de detecção	Múltiplas pessoas	Tempo real	Sinal Extra	Desempenho
[Liu et al. 2015b]	Linux 802.11n CSI Tool	Redução do ruído Transformação do sinal	Baseado em modelos	Não	Não	Postura	Estimação da taxa de respiração: maior que 85%; Estimação da apneia: 82.1%, Mudança de posição: maior que 80%
[Zhang et al. 2017]	Linux 802.11n CSI Tool	Redução de ruído Extração do sinal	Baseado em modelos	Não	Não	Micromovimentos	Erros de estimacão < 2bpm para 80% dos experimentos
[Liu et al. 2014]	Linux 802.11n CSI Tool	Redução de ruído Extração do sinal	Baseado em modelos	Não	Sim	Postura	Estimação da taxa de respiração: 85%; Mudança de postura $\approx$ 80%
[Khan et al. 2017]	USRp B200	Transformação do sinal	Baseado em modelos	Não	Sim	Movimentos	Precisão: respiração 87%, detecção de quedas 98%, classificação de tremor 93%
[Yang et al. 2018]	Linux 802.11n CSI Tool	Redução de ruído	Baseado em modelos	Sim	Sim	Postura	Média absoluta de erro: Respiração 0.614bpm no meio da ZF; 3.130bpm nas bordas; Falso alarme de apneia 6.8%, apneia perdida 7.09%
[Gu et al. 2021]	Linux 802.11n CSI Tool	Redução do ruído	Baseado em modelos	Não	Sim	Postura	96.618% para taxa de respiração e 94.708% para batimentos cardíacos

## 5.5. Atividade Prática

Esta seção apresenta uma atividade prática. São mostrados os passos necessários para o processo de captura e processamento de dados CSI. Inicialmente, é apresentada uma configuração do ambiente de captura, destacando os requisitos básicos de *software* e *hardware*, além do cenário de coleta de dados. Posteriormente, é mostrada a extração da informação CSI a partir dos sinais coletados e o seu processamento, utilizando técnicas de filtragem e algoritmos conhecidos, como o PCA (do inglês, *Principal Component Analysis*) e a Transformada Rápida de Fourier – FFT (do inglês, *Fast Fourier Transform*). Finalmente, são apresentados dois casos que consideram a estimativa da taxa de respiração e do batimento cardíaco de um indivíduo a partir dos dados CSI capturados utilizando dispositivos Wi-Fi.

### 5.5.1. Configuração do Ambiente de Captura

Para a captura e coleta do sinal utilizou-se o *firmware* NEXMON. O *firmware* é instalado em um dispositivo Raspberry Pi modelo 4B. Para a instalação utilizou-se o Raspbian, um Sistema Operacional (SO) compatível com o *firmware* NEXMON. Para a instalação do SO no Raspberry Pi, são necessários os equipamentos listados na Tabela 5.5.

**Tabela 5.5. Dispositivos utilizados pelo NEXMON**

Dispositivo	Descrição
Raspberry Pi 4 Modelo B	Hardware compatível com o Raspbian e NEXMON.
Cartão Micro SD	Memória para o SO
Leitor de cartão Micro SD	Para a instalação do SO
Cabo HDMI	Para conectar o monitor ao Raspberry.
Monitor	Tela para visualizar o Raspberry.
Teclado USB	Para trabalhar no Raspberry.
Cabo Ethernet	Para configurar o roteador sem fio.
Roteador TP-Link Archer C6	Para criar e configurar a rede Wi-Fi.
PC	Para instalar e transferir arquivos ao Raspbian.
Mouse	Para trabalhar com o Raspberry.

Primeiramente, deve-se introduzir o cartão SD no leitor de cartão Micro SD para conectá-lo ao slot USB do computador. Em seguida, deve-se instalar a imagem do Raspbian 2021-01-11-raspbpios-buster-armhf-full no cartão SD. Essa imagem contém o Kernel 5.4, compatível com o *firmware* NEXMON, que será instalado. Para instalar a imagem do Raspbian no cartão SD utilizamos uma ferramenta chamada Etcher. Assim que a imagem do Raspbian estiver instalada no cartão SD, deve-se retirar o cartão do PC do leitor de cartão Micro SD, e inseri-lo no Raspberry Pi 4B.

O Raspberry Pi 4B deve estar conectado ao monitor através de um cabo HDMI. Além disso, conectamos um teclado e mouse às interfaces USB do Raspberry para controlá-lo. Finalizadas as conexões e inserção do cartão SD, o Raspberry Pi 4B pode ser ligado e a inicialização do Raspbian será realizada. Ao inicializar o SO, utiliza-se o usuário e senha padrão do Raspbian para efetuar o login (user:pi, pass:raspberry). Posteriormente,

deve-se proceder com as configurações básicas do dispositivo, como as interfaces e habilitar os serviços que serão utilizados, como o idioma, a interface sem fio WLAN e o acesso remoto via SSH (*Secure SHell*). Para acessar essas configurações, executa-se o seguinte comando no terminal:

```
~$ sudo raspi-config
```

O comando abre uma janela com as opções de configuração. Na opção *Interfacing Options*, habilite a conexão SSH para se conectar futuramente ao Raspberry a partir do PC. Caso queira utilizar uma interface gráfica na conexão remota, habilite o servidor VNC. Configure o *Time Zone*, *WLAN Country* e teclado. Recomenda-se utilizar a opção Estados Unidos da América (USA) como país na configuração, para que habilite o uso de todos os canais Wi-Fi. Após as configurações anteriores, é necessário verificar a versão do kernel instalado, através do comando:

```
~$ uname -a
```

O resultado dessa consulta deve mostrar a versão do kernel conforme o exemplo a seguir:

```
Linux raspberrypi 5.4.83-v7l+ #1379 SMP Mon Dec 14  
13:11:54 GMT 2020 armv7l GNU/Linux
```

Observando-se o resultado da consulta `~$ uname -a`, o kernel instalado é o 5.4.83-v7l+, o qual é compatível com a versão do *firmware* NEXMON. Deve-se considerar que, durante todo o trabalho com o Raspbian e NEXMON, não se pode fazer um *upgrade* do SO, porque esse procedimento alteraria a versão do kernel e geraria uma incompatibilidade com a versão do *firmware* NEXMON.

Além das configurações já realizadas, é necessário ter acesso à conexão Internet para a instalação do NEXMON. Essa conexão pode ser feita utilizando a interface WLAN ou Ethernet. A configuração de rede também pode ser realizada no menu do comando `| sudo raspi-config`. Deve-se alertar que após a instalação do NEXMON, o acesso à Internet só poderá ser feito pela interface Ethernet, pois a interface WLAN é modificada e fica exclusivamente para o uso do *firmware* NEXMON. Portanto, recomenda-se utilizar a interface Ethernet para a conexão à Internet desde o início.

### **Instalação do firmware NEXMON**

O NEXMON é um firmware que modifica o kernel e a interface sem fio do Raspberry para poder capturar e coletar dados CSI. A instalação é realizada executando os comandos diretamente no Raspberry Pi 4B mediante o teclado, ou a partir do PC com conexão remota, utilizando o SSH ou VNC. A instalação segue diversos passos que são descritos a seguir:

## 1. Instalar dependências

Para instalar as dependências, são executados os seguintes comandos:

```
~$ sudo apt update
```

Logo que executar esta linha de comando, aparecerá na tela a pergunta: *Do you want to accept these changes and continue updating from this repository? [y/n]*, Respondemos “y” para que a atualização ocorra de acordo à versão do kernel instalada e as dependências possam ser instaladas corretamente. Logo instalam-se as seguintes dependências:

```
~$ sudo apt install libgmp3-dev gawk
qpdf bc bison flex libssl-dev make
automake texinfo libtool-bin tmux
libncurses5-dev git tcpdump
```

```
~$ sudo reboot
```

Deve-se verificar a versão do kernel após reiniciar o SO, utilizando o comando “**uname -a**”. A versão deverá ser a mesma verificada inicialmente.

```
Linux raspberrypi 5.4.83-v7l+ 	$#1379 SMP
Mon Dec 14 13:11:54 GMT 2020 armv7l GNU/Linux
```

Alerta-se que **NÃO DEVE-SE** executar o comando “*sudo apt upgrade*”, para não alterar a versão do kernel. Apenas kernels até a versão 5.4 são compatíveis com o NEXMON.

## 2. Obter Kernel Headers

Ao utilizar o kernel *Linux raspberrypi 5.4.83-v7l+*, há ainda um problema de compatibilidade entre os headers disponíveis no repositório *apt*, que estão disponíveis apenas para versões mais atualizadas. Assim, deve-se sincronizar os headers para a versão correta do kernel. Para isso, utiliza-se o *rpi-source project*, executando os seguintes comandos:

```
~$ sudo wget https://raw.githubusercontent.com/
RPI-Distro/rpi-source/master/rpi-source
-O /usr/local/bin/rpi-source && sudo chmod
+x /usr/local/bin/rpi-source && /usr/local/
bin/rpi-source -q --tag-update
```

```
~$ rpi-source
```

```
~$ sudo reboot
```

### 3. Instalar NEXMON e NEXMON-CSI

Finalmente, o firmware NEXMON e seu complemento NEXMON-CSI podem ser instalados. O firmware NEXMON modifica o kernel com múltiplos propósitos, um deles é a captura e coleta de dados CSI, através do complemento NEXMON-CSI. Para a instalação, deve-se executar os seguintes comandos:

```
~$ sudo su

~$ wget https://raw.githubusercontent.com/zeroby0/nexmon_csi/pi-5.4.51/install.sh
-O install.sh

~$ tmux new -c /home/pi -s nexmon 'bash
install.sh | tee output.log'
```

### Configuração do Cenário de Teste

Para realizar a coleta de dados CSI, é necessário configurar uma rede Wi-Fi, formada por um roteador e um dispositivo Wi-Fi cliente, conforme apresentado na Figura 5.3. Nessa rede, é gerado um tráfego entre o cliente e o roteador utilizando o utilitário “ping”. O Raspberry, com o NEXMON instalado, mantém a interface sem fio em modo de escuta, capturando os quadros do meio de transmissão sem fio. Capturam-se os quadros da comunicação entre o roteador e o cliente Wi-Fi. O Raspberry coleta os dados de requisição (echo-request) e de resposta (echo-reply), ou apenas um deles. No exemplo a seguir, a captura é feita apenas nos quadros que têm como origem o cliente Wi-Fi, que envia o ping para o roteador.

A rede Wi-Fi formada para a captura e coleta de dados CSI deve trabalhar nas faixas frequência ISM de 2.4 GHz ou 5 GHz. Recomendamos utilizar a faixa de frequências de 5 GHz, pois possui menos interferências quando comparada a versão de 2.4 GHz e permite a utilização de canais de maior largura de banda. Ao utilizar a faixa de 5GHz, configuramos uma rede com largura de banda que vai de 20 MHz a 160 MHz. Já na faixa de 2.4 GHz, apenas canais com largura de banda de 20 MHz e 40 MHz são permitidos. No exemplo de extração de dados da Seção 5.5.2, utilizou-se uma rede com o roteador configurado para trabalhar na faixa de frequência de 5GHz, utilizando o canal 36 e largura de banda de 80 MHz. Por outro lado, a configuração do dispositivo cliente Wi-Fi basicamente consiste em se conectar à rede do roteador, indicando o SSID e senha da rede Wi-Fi configurada no roteador.

Para gerar o tráfego, executa-se o comando *ping* no cliente com destino ao roteador. Assim, gera-se um fluxo pela interface sem fio do laptop para o roteador. Um detalhe importante é a configuração do intervalo entre pacotes do *ping*, que deve ser configurado de acordo com a taxa de amostragem necessária para a estimação, detecção ou reconhecimento de atividade humana que é desejado. Neste exemplo, deseja-se obter os sinais de batimento cardíaco, que possuem uma frequência má-






Figura 5.3. Cenário de teste

xima de 220 batimentos por minuto<sup>1</sup>, ou seja, 3,67 Hz. De acordo com o teorema de Nyquist, a taxa de amostragem mínima deve ser o dobro da frequência máxima do sinal amostrado, ou seja, 7,34 Hz. Portanto, o intervalo máximo entre pacotes configurado para o ping deve ser de 0,13 seg.

O comando `|ping|` a seguir foi parametrizado para ser executado pela interface sem fio `wlan0` (`-I wlan0`), no modo *flooding* (`-f`) para que seja exibido cada envio e resposta, com intervalo entre pacotes de 0.13 s (`-i 0.13`), enviados para um roteador configurado com o IP 192.168.1.1:

```
~$ sudo ping -I wlan0 -f -i 0.13 192.168.1.1
```

Finalmente, como mostrado na Figura 5.3, a distância entre o participante e os equipamentos é de 1 metro, formando assim o cenário de captura. O participante permanece no meio dos equipamentos a fim de que os sinais eletromagnéticos possam se propagar através ou ao redor dele e essas interferências no sinal sejam capturadas pelo Raspberry através do NEXMON.

### 5.5.2. Extração de Dados de Wi-Fi CSI Utilizando o NEXMON

Após instalar o NEXMON-CSI e configurar o cenário de teste, inicia-se a captura e coleta de dados CSI para posterior extração dos sinais vitais. Esta seção é subdividida, portanto, no passo-a-passo da captura e coleta e em seguida a extração de dados CSI a partir dos arquivos coletados.

<sup>1</sup><https://www.cdc.gov/physicalactivity/basics/measuring/hearttrate.htm>

## Captura e Coleta de Dados CSI com NEXMON

Para capturar dados, pode-se executar o NEXMON no Raspberry de duas formas: executando comando a comando no terminal, ou através de um script. Neste exemplo, o utilizou-se a forma iterativa, para fins de demonstração. Portanto, os seguintes comandos devem ser executados no terminal:

```
~$ sudo su
~$ mcp -c 36/80 -C 1 -N 1
```

O comando `mcp` (*makecsiparams*) configura o canal 36 e largura de banda 80 MHz com um *core* e uma antena. Esta linha de comando retorna uma informação própria do NEXMON, similar à mostrada abaixo, que deve ser copiada pois será utilizada nos comandos seguintes:

```
m+IBEQAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAA==
```

Apos da execução dos comando anteriores, iniciamos a configuração da interface utilizada:

```
~$ sudo ifconfig wlan0 up

~$ nexutil -Iwlan0 -s500 -b -l34
-vm+IBEQAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAA==
```

O comando `ifconfig` habilita a interface `wlan`. O comando `nexutil` configura a interface. Perceba que a informação copiada anteriormente deve ser colocada ao final da linha. Logo, a interface `wlan0` é colocada em modo *monitor*. Para obter os dados coletados em um arquivo `.pcap` é preciso utilizar o comando `tcpdump` que escuta os pacotes pela porta 5500 (porta padrão de saída do NEXMON). Esses passos são mostrados a seguir:

```
~$ sudo iw dev wlan0 interface add mon0 type monitor

~$ sudo ip link set mon0 up

~$ sudo tcpdump -i wlan0 dst port 5500 -vv
-w output.pcap -c 500
```

## Extração de Dados CSI

Para extração de dados CSI a partir dos arquivos coletados *.pcap*, utilizam-se scripts desenvolvidos em python por um grupo de pesquisadores. Para maior detalhe pode ser encontrado no repositório do GitHub<sup>2</sup>. Esses scripts configuram a extração a partir do dispositivo indicado, extraem os dados dos arquivos *.pcap* utilizando uma contagem de bit no payload capturado. Para começar a extração, deve-se configurar o dispositivo de captura e coleta de dados CSI. Neste exemplo, utilizou-se o chipset relativo ao Raspberry Pi 4B, o bcm43455c0. Seleciona-se essa opção de chipset no arquivo de configuração *config.py*:

```
# chip = 'bcm4339'      # Nexus 5
chip = 'bcm43455c0'    # Raspberry Pi 3B+ and 4B
# chip = 'bcm4358'     # Nexus 6P
# chip = 'bcm4366c0'   # Asus RT-AC86U
```

Em seguida, remove-se do conjunto de dados as informações relativas às subportadoras nulas e piloto do OFDM<sup>3</sup>, denominadas “NULL” e “PILOT”. Assim recuperam-se apenas informações relativas às subportadoras utilizadas na transmissão de dados. Logo, obtêm-se os dados CSI capturados, além disso, pode-se obter outros dados que são de controle. Segundo a Tabela 5.6, os dados coletados têm diferente tamanho em bytes e representam diversas informações.

**Tabela 5.6. Payload dos pacotes CSI coletados**

Bytes	Tipo	Nome	Descrição
4	uint32	Magic Bytes	0x11111111
6	uint8[6]	Source Mac	Endereço MAC de origem do quadro Wi-Fi
2	uint16	Sequence Number	Número de sequência do quadro Wi-Fi
2	uint16	Core and Spatial Stream	3 bits indicam o Core e os próximos 3 bits o Spatial Stream number
2	uint16	Chanspec	Especificação do Canal usado na extração. Veja <i>nexutil -k</i>
2	uint16	Chip Version	Versão do Chipset
Variável	int16[]	CSI Data	Cada amostra CSI tem 4 bytes com intervalos de uma parte real e outra imaginária

Na extração de dados é importante esclarecer que os dados CSI são números complexos. Esses números complexos contêm uma parte real e outra parte imaginária. A manipulação desses números complexos é importante porque a partir desse processo podemos obter a amplitude, fase ou resultados mais complexos como detecção, reconhecimento ou detecção de alguma atividade humana. A seguir, é mostrado um exemplo de obtenção de amplitude e fase. Esses dados são obtidos a partir

<sup>2</sup>[https://github.com/nexmonster/nexmon\\_csi/tree/feature/python/utils/python](https://github.com/nexmonster/nexmon_csi/tree/feature/python/utils/python)

<sup>3</sup><https://www.oreilly.com/library/view/80211ac-a-survival/9781449357702/ch02.html>

dos dados CSI extraídos em forma de números complexos. Foi aplicada a função `np.abs()` para obter a amplitude e `np.angle()` para obter fase do sinal coletado. Nas funções aplicadas, foi passada como referência a matriz `csi` que contém os dados coletados em forma de uma matriz bidimensional.

```
self.ax_amp.plot(self.x_amp, np.abs(csi))
self.ax pha.plot(self.x pha,
                 np.angle(csi, deg=True))
```

### 5.5.3. Pré-processamento de Sinais CSI e Obtenção de Sinais Vitais com Python

Após a extração dos dados CSI dos arquivos coletados, inicia-se a fase de processamento desses dados.

Para a extração dos sinais vitais, realiza-se uma sequência de procedimentos que serão categorizados como processamento dos dados CSI e algoritmos de detecção dos sinais vitais.

A etapa de processamentos dos dados CSI é realizada a partir da extração dos dados, como mostrado na Seção 5.5.2. Esses dados passam por diversos tipos de filtros, para remoção de ruído ou *outliers* (valores atípicos) que possam ter sido capturados.

Os dados CSI são representados por uma matriz, e suas dimensões são referentes à quantidade de subportadoras, que dependem da largura de banda utilizada e da quantidade de amostras. A matriz contém todos os dados CSI coletados válidos, sem considerar as subportadoras PILOTs e NULLs, mas contendo uma grande quantidade de ruído próprio do meio de transmissão.

A Figura 5.4(a) apresenta um exemplo de dados coletados, ainda com o ruído e outliers. Para remover esses valores indesejados, podemos utilizar uma série de filtros. Na aplicação desta atividade, o filtro Hampel é utilizado para este fim. O objetivo do filtro Hampel é identificar e substituir valores atípicos em uma série temporal. Esse filtro analisa uma janela deslizante para percorrer os dados e calcula a mediana e o desvio padrão nessa janela. Há duas variáveis que podem ser configuradas, o tamanho da janela deslizante (`window_size`) e a quantidade de desvios padrão (`n`) a partir da qual se classifica um valor como atípico. Os valores atípicos são substituídos pela mediana da janela. O trecho abaixo mostra como é aplicado o filtro Hampel no código de exemplo:

```
hampel(series[key], window_size=31,
       n=3, imputation=True)
```

Após a aplicação do filtro Hampel, ainda podem restar ruídos e *outliers*, que podem interferir na estimação dos sinais vitais. Para garantir que os dados sejam mais confiáveis, aplica-se outro filtro. O filtro aplicado é o filtro de média, ou *Moving Average*. O *Moving Average* é utilizado para suavizar variáveis aleatórias (outliers), em termos de reduzir as amplitudes fora do intervalo normal do sinal coletado. Este filtro se calcula obtendo a média dos dados do sinal em um período de tempo ou janela (*windows*) com

uma quantidade mínima de observações (*min\_periods*). Neste exemplo, é aplicado como segue:

```
series[key].rolling(window=10, min_periods=1,
                    center=True).mean()
```


Após o processamento dos dados CSI inicia-se a estimação de sinais vitais. Para os sinais vitais de interesse, frequência cardíaca e frequência respiratória, aplica-se um filtro passa-banda, para limitar o espectro de frequências em que estão localizados esses sinais vitais. Nesse estudo de caso, o filtro passa-banda deve ser configurado com uma frequência de corte entre 0.2 Hz e 0.4 Hz, para estimação da respiração. O movimento de inalar e exalar faz uma movimentação da caixa peitoral, que gera uma perturbação nos sinais electromagnéticos capturadas pelos dados CSI. Essas perturbações são observadas nas frequências acima mencionadas [Khamis et al. 2018, Zhang et al. 2019]. No caso da frequência cardíaca, as perturbações ocasionadas pelo batimento do coração podem ser sobrepostas pelo movimento do peito ao respirar. Para observar esses batimentos do coração, configura-se o filtro passa-banda com as frequências de corte 0.6 Hz e 3.5 Hz [Khamis et al. 2018, Wang et al. 2020]. A seguir é mostrada essa parte da configuração no código:

```
fs = 7.64 %taxa de amostragem
lowcut = 0.2 %0.6
highcut = 0.4 %3.5
butter(5, [lowcut / (fs / 2), highcut / (fs / 2)],
        'band', analog=False, output='ba')
```

Com o filtro passa-banda, recupera-se um conjunto de sinais que estão entre as frequências recomendadas para estimar os sinais vitais requeridos. Entretanto, é necessário estabelecer um único sinal que represente esse grande conjunto de sinais CSI. Na Figura 5.4(b) estão os resultados após o uso dos filtros Hampel e Moving Average. Além disso, a Figura 5.4(c) mostra os dados CSI processados pelo filtro passa-banda, para obter só as frequências de interesse. Existe diversas formas de obter sinais representativos, uma delas segundo a literatura é aplicar o PCA (do inglês, *Principal Component Analysis*) [Li et al. 2021]. O PCA faz com que esse conjunto de sinais seja representado por um conjunto mínimo de componentes. No exemplo, limita-se a representação dos sinais de todas as subportadoras a um único componente, que represente o total de sinais CSI. A seguir, apresenta-se o trecho de código da aplicação do PCA, enquanto a Figura 5.4(c) mostra o resultado da aplicação do PCA.

```
PCA(n_components=1)
pca.fit_transform(series)
```

A partir do resultado do PCA como uma só componente, utilizamos a FFT (do inglês, *Fast Fourier Transform*). A FFT é utilizada para a conversão do sinal que está no domínio do tempo para uma representação no domínio de frequência. A FFT resulta em um



**Figura 5.4. (a) Dados CSI coletados sem processamento. (b) Dados CSI pre-processados pelos filtros Hampel e Moving Average. (c) Sinal CSI obtido pelo PCA, que representa o conjunto de sinais coletados. (d) Exemplo de frequências obtidas para a estimação da frequência respiratória com o uso de FFT.**

conjunto discreto de valores de frequências, que estão dentro das faixas de interesse selecionadas no filtro passa-banda. Para a frequência respiratória, a faixa de interesse é entre 0.2 Hz e 0.4 Hz, e estima-se a frequência respiratória como sendo a frequência de maior amplitude dentro dessa faixa do espectro e ela representa a taxa de rpm (respirações por minuto). Por exemplo, os resultados estimados para um adulto normal são mostrados em uma faixa entre 15 e 20 rpm. No caso da estimação do batimento cardíaco, as frequências são limitadas entre 0.6 Hz e 3.5 Hz com o filtro passa-banda. Nesse intervalo, a frequência cardíaca é estimada a partir de uma média entre as quatro frequências com maior amplitude. Os resultados da frequência cardíaca para uma pessoa normal em repouso são exibidos em uma faixa de 60 a 100 bpm (batimentos por minuto). A Figura 5.4(d) mostra um exemplo das frequências consideradas para o cômputo da frequência respiratória (sinal vital), que estão de 0.2 Hz e 0.4 Hz.

## 5.6. Desafios e Tendências Futuras

O monitoramento de sinais vitais e atividade humana usando Wi-Fi CSI pode oferecer suporte a aplicações de saúde. No entanto, os desafios devem ser superados para que se

possa obter a implementação prática. No que se referir à detecção de sinais vitais, a definição de cenários para captura de dados CSI não é trivial. Os movimentos e as atividades diárias têm maior impacto no CSI quando comparados à respiração e à frequência cardíaca. Portanto, a detecção de sinais vitais impõe restrições na recepção e processamento do sinal. Além disso, desafios como interferência eletromagnética, reconhecimento de movimentos simultâneos de diferentes partes do corpo, ambientes com muitas pessoas e cenários sem linha de visão direta (NLOS) devem ser enfrentados. Esta seção aborda esses desafios e também as perspectivas de aplicações futuras e melhorias do uso de Wi-Fi CSI para monitoramento de sinais vitais.

### 5.6.1. Desafios

O primeiro estágio da arquitetura CSI é a captura de dados. Nessa etapa, as antenas colocadas no ambiente para transmissão e recepção de sinais Wi-Fi podem variar em quantidade e formato. Existem cenários definidos para usar uma única antena transmissora e uma única antena receptora (do inglês, *Single-Input Single-Output* - SISO) em uma configuração ponto a ponto. Outra configuração corresponde à tecnologia MIMO, com várias antenas utilizadas para transmitir e receber os dados CSI. A configuração MIMO é necessariamente regida pelo padrão 802.11n/ac. Em ambas as configurações, o ponto de convergência é a quantidade de informações CSI capturadas. Quanto maior o número de antenas ou dispositivos envolvidos, maior a quantidade de dados.

Especificamente, o número de dispositivos necessários para obter as informações necessárias e aumentar a precisão do reconhecimento do comportamento é uma questão que precisa ser estudada. Estudos como [Zhu et al. 2017] e [Li et al. 2018] confirmam que aumentar o número de dispositivos Wi-Fi pode melhorar o desempenho do sistema. No entanto, aumentar o número de dispositivos também aumenta a interferência eletromagnética, e esse é um dos principais desafios na identificação de sinais vitais.

Aumentar o número de dispositivos Wi-Fi permite ampliar a área de cobertura e melhorar o desempenho de modelos baseados em zonas de Fresnel, por exemplo. No entanto, as zonas de Fresnel de vários links são complexas [Chen et al. 2017b]. Então, detectar vários limites de zona de Fresnel é um grande desafio. É difícil identificar as melhores localizações do transceptor e orientações corretas [Wang et al. 2017a]. A configuração do cenário é uma etapa crítica para a coleta eficiente de dados CSI que permite uma detecção mais precisa dos sinais vitais. Além disso, o número de dispositivos depende exclusivamente da quantidade de informação capaz de se analisar e se a ferramenta utilizada suporta esta captura. As ferramentas de captura de dados CSI mencionadas na Seção 5.2.2 diferem de acordo com as características do cenário escolhido.

Uma discussão fundamental para o desempenho de captura CSI é a linha de visão (*Line-Of-Sight* - LOS) de antenas e dispositivos. Em um cenário em que as antenas e dispositivos possuem uma linha de visão entre eles e o paciente, os dados capturados são mais robustos e descrevem de forma completa os sinais vitais a serem detectados. No entanto, em um cenário onde os dispositivos e antenas não possuem linha de visão (NLOS) entre eles e nem com o paciente, os resultados da captura de dados podem ser insuficientes. Isso torna a detecção de sinais vitais em cenários NLOS um desafio importante. Essas consequências ocorrem devido à interferência em um cenário LOS ser menor do

que em um cenário NLOS.

Em um cenário com linha de visão, a interferência detectada deve-se principalmente ao paciente, no qual os sinais interferem (refletem, espalham, atenuam, etc.), podendo-se obter o CSI para posteriormente inferir os sinais vitais. Por outro lado, em um cenário sem linha de visão, não apenas o paciente gera interferência, mas também outros objetos, por exemplo, paredes de concreto, que podem distorcer o sinal e as medições CSI. Conseqüentemente, as informações capturadas não geram a confiabilidade adequada para seu tratamento posterior e inferência de sinais vitais.

Uma vez que os dados CSI foram capturados, a próxima etapa é o pré-processamento do sinal. Este estágio se concentra em limpar o sinal o máximo possível do ruído externo, Gaussiano, branco, térmico ou qualquer outro ruído inerente à comunicação sem fio, que são acoplados ao sinal com a informação transmitida. Vários tipos de filtros são aplicados na tentativa de limpar o sinal, conforme descrito na Seção 5.3.1. Para uma análise mais aprofundada do sinal, filtros devem ser aplicados para obter um sinal resultante o mais confiável possível, assim, a limpeza do sinal torna-se um desafio. É necessário que o sinal limpo defina as formas de onda mais confiáveis, ou seja, quando a frequência respiratória é detectada, o sinal é analisado inicialmente em um intervalo de 0,2Hz a 0,4Hz, e a variação da onda, causada pelo movimento do tórax do paciente inspirando ou expirando, pode ser observado.

Após a detecção da frequência respiratória, é realizada a detecção da frequência cardíaca, que devido ao seu processo inerente de batimentos cardíacos é representada em menor intensidade em relação à respiração. Essa detecção cardíaca pode ser afetada pela frequência respiratória, pois o efeito da respiração no CSI é consideravelmente mais forte quando comparado ao efeito do batimento cardíaco. No monitoramento da respiração, os requisitos para filtragem de sinal podem ser menos complexos e exigentes em comparação com o monitoramento cardíaco. A detecção cardíaca requer que o sinal resultante exiba os picos de onda em detalhes enquanto conserva as distorções de ondas pequenas (picos) causadas pelo batimento cardíaco. Por isso é importante usar a técnica de filtragem mais adequada para limpar o sinal sem perder o efeito de pulsação no CSI capturado.

A próxima etapa é a detecção de sinais vitais usando vários algoritmos mostrados na Seção 5.3.2. O que encontramos nos estudos apresentados na literatura é que existem dois aspectos na detecção de sinais vitais ou atividades humanas em geral. Quando falamos em detectar uma pessoa, reconhecer gestos ou estimar movimentos, os estudos propostos induzem ao uso de algoritmos de inteligência artificial, especificamente aprendizado de máquina. No entanto, quando nos referimos à detecção de sinais vitais, as técnicas envolvidas são baseadas em modelos teóricos. Isso porque, conforme descrito anteriormente, quando detectamos sinais vitais como a frequência cardíaca, é necessário que as formas de onda (picos) sejam detalhadas da forma mais clara possível e, para isso, as técnicas teóricas de modelagem de sinais apresentam bom desempenho. No entanto, a falta de estudos que usem algoritmos de aprendizado de máquina para detectar sinais vitais nos leva a pensar em quão bem eles podem atuar nesse tipo de detecção. Partindo do ponto de que, por exemplo, para detecção de frequência cardíaca, os picos produzidos pelos batimentos que afetam o sinal capturado representam padrões de distorção, então esses padrões poderiam ser identificados por um algoritmo de aprendizado de máquina



como uma recorrência ao longo do monitoramento, em que o real valor da frequência cardíaca pode ser determinado. Em resumo, nesta fase o uso de técnicas teóricas de modelagem de sinais e algoritmos de aprendizado de máquina para a detecção de sinais vitais varia de acordo com o objetivo final da detecção. Da mesma forma, os algoritmos e/ou técnicas utilizadas têm um comportamento diferente dependendo do sinal vital detectado, o que desencadeia a necessidade de padronização das técnicas ou algoritmos de detecção.

A detecção de sinais vitais resulta em uma tarefa desafiadora, principalmente devido aos movimentos simultâneos de diferentes partes do corpo e/ou a presença de várias pessoas no mesmo ambiente. Comumente, as pessoas realizam vários movimentos simultaneamente e o CSI coletado contém o efeito misto resultante de todos esses movimentos. Distinguir a mudança de sinal causada por cada movimento do corpo é a base para garantir o melhor desempenho na detecção de sinais vitais. No entanto, a detecção simultânea de movimentos corporais é um desafio a ser enfrentado. Por outro lado, alguns estudos como TR-BREATH [Chen et al. 2016, Wang et al. 2017a] mostraram que o aumento no número de usuários geralmente diminui a precisão do reconhecimento. Também é importante identificar a presença de várias pessoas no mesmo ambiente e, eventualmente, poder diferenciar o efeito de cada pessoa no CSI. Dessa forma, seria possível monitorar mais de uma pessoa ao mesmo tempo. Além disso, evitando a interferência de outras pessoas nos sinais vitais do paciente que está sendo monitorado. No entanto, reconhecimento de comportamento multiusuário torna-se um desafio à medida que o número de pessoas aumenta.

Finalmente, o último estágio de aplicação leva à detecção, estimativa ou reconhecimento de alguma atividade humana. No campo da saúde, é necessário que a detecção seja tomada como principal aplicação. Esta aplicação leva à detecção de sinais vitais de pessoas/pacientes. Uma das perspectivas é que a detecção dos sinais vitais deve ser realizada de forma contínua, em tempo real. Essa avaliação contínua é feita com o objetivo de fornecer informações médicas atualizadas sobre o paciente à equipe médica e tomar melhores decisões em benefício do paciente. Os estudos na literatura carecem dessa adaptação da detecção contínua em tempo real e não fornecem uma abordagem aplicada à detecção de sinais vitais. Além disso, novos desafios como segurança, confiabilidade e portabilidade das informações de detecção surgem e podem gerar complicações na detecção contínua de sinais vitais. Esses desafios surgem em todo o processo de detecção e no cenário sem fio inerente, onde a detecção ocorre. Assim, a segurança pode ser afetada na captura de dados, uma vez que é realizada em um ambiente sem fio. Ele pode estar sujeito a ataques maliciosos que podem distorcer os dados CSI capturados. Na área de confiabilidade, as informações obtidas pelo médico assistente podem não ser confiáveis ou mesmo não contíguas. Considerando a portabilidade, há a necessidade de equipamentos de monitoramento (antenas, dispositivos) serem tão portáteis quanto possível para acoplamento a diferentes tipos de aplicações. Da mesma forma, as aplicações finais devem ser acopladas às informações fornecidas por esses dispositivos de monitoramento. Portanto, os problemas e desafios aumentam à medida que novos elementos são adicionados à detecção de sinais vitais. É importante superar esses desafios e propor tecnologias que trabalhem em conjunto com a detecção de sinais vitais e retornem um sistema médico robusto que utilize a tecnologia CSI, mas sem afetar sua finalidade inicial, que é a detecção de sinais vitais para aplicações médicas.

## 5.6.2. Tendências Futuras

O monitoramento em tempo real permite reduzir o risco de vida. Quando um paciente enfrenta uma situação de risco de vida, ele pode ser identificado imediatamente e um sinal de alerta pode ser acionado instantaneamente. Assim, o paciente pode receber a assistência médica necessária. Muitos eventos como: Reconhecimento de Atividade Humana (do inglês, *Human Activity Recognition* - HAR), detecção de queda, detecção de respiração e batimentos cardíacos e até diagnóstico de doenças, são de interesse para aplicações de saúde digital. Um desses eventos ou uma combinação de alguns deles pode indicar a necessidade de ajuda médica que uma pessoa pode ter. O reconhecimento de doenças usando CSI é o menos abordado na literatura e é um campo de pesquisa aberto interessante [Liu et al. 2015b, Yang et al. 2018].

Para extração de recursos e classificação de atividades, as técnicas de aprendizado de máquina (do inglês, *Machine Learning* - ML) se tornaram uma alternativa promissora. Na literatura, entre os principais algoritmos de ML utilizados para a detecção e reconhecimento da atividade humana e sinais vitais estão: LSTM [Damodaran et al. 2020, Bowen et al. 2019b, Shi et al. 2018], SVM [Damodaran et al. 2020, Li et al. 2019, Zhu et al. 2017], k-NN [Gu et al. 2018] e *Backpropagation Neural Network* (BPNN) [Duan et al. 2018b, Wu et al. 2018, Xiao et al. 2017]. Esses estudos demonstram a capacidade dos algoritmos de ML para detecção e reconhecimento da atividade humana e sinais vitais e abrem caminho para novas pesquisas focadas na detecção de doenças e na melhoria das aplicações de saúde digital.

Na literatura, estudos mostram que o algoritmo LSTM é capaz de extrair características dos dados de entrada automaticamente sem a necessidade de utilizar técnicas complexas para o tratamento de sinais Wi-Fi CSI. Portanto, o LSTM é considerado um bom candidato para a tarefa de classificação em aplicações de saúde digital em tempo real. Por isso, é uma opção interessante usar o LSTM para realizar uma análise profunda da respiração e do sinal de batimento cardíaco extraídos dos sinais CSI. Como o componente de fase do sinal é sensível ao movimento do tórax causado pela respiração [Tan et al. 2018], considera-se que algoritmos de classificação podem ser usados para estimar a atividade respiratória humana e eventualmente inferir ou detectar problemas respiratórios, como apneia do sono.

Uma combinação de detecção de atividade humana e taxa de respiração, semelhante ao BodyScan [Fang et al. 2016], é uma abordagem interessante. No BodyScan, como o CSI é capturado por dois dispositivos vestíveis projetados, ele não se encaixa na classificação de detecção de atividade sem dispositivo. No entanto, essa proposta apresenta bons resultados na determinação da taxa de respiração do usuário quando o movimento não é detectado e o corpo está em estado estacionário.

Identificar o efeito de atividades humanas comuns no CSI pode melhorar o desempenho da extração de sinais vitais. Além disso, conhecer a atividade imediatamente antes de uma anomalia no sinal respiratório e no batimento cardíaco pode ajudar na classificação e identificação de problemas de saúde ou mesmo de uma emergência médica. Por exemplo, quando há uma anormalidade no sinal respiratório ou nos batimentos cardíacos após uma queda ou após uma longa caminhada. Essas anomalias de sinal podem estar associadas a deficiência pulmonar, taquicardia, bradicardia ou arritmia. Desta forma, as

técnicas híbridas são uma opção interessante para melhorar o desempenho na detecção de sinais vitais.

Na literatura, alguns estudos [Wang et al. 2016a, Gu et al. 2018] mostram como o CSI é sensível a pequenos movimentos do corpo e que é possível detectar e analisar reflexões de rádio de granularidade fina a partir de movimentos faciais. O fato de emoções e expressões comuns de pessoas poderem ser reconhecidas a partir de CSI [Gu et al. 2018] abre a possibilidade de também identificar expressões associadas à dor e assim identificar quando uma pessoa está sofrendo alguma dor. Outra possibilidade interessante resulta em inferir o risco de uma pessoa sofrer depressão quando um padrão de tristeza se torna repetitivo. Além disso, como é possível ler os movimentos da boca e saber do que uma pessoa está falando a partir do CSI, como mostrado em [Wang et al. 2016a], palavras ou sequências de palavras usadas pelas pessoas para solicitar ajuda podem ser identificadas. Esse aplicativo pode ser usado para identificar o pedido de socorro de uma pessoa com parada cardiorrespiratória, em que a pessoa não consegue emitir o som da fala.

## 5.7. Conclusão

Este capítulo forneceu um levantamento sobre a detecção de sinais vitais usando informações de estado do canal sem fio através de dispositivos Wi-Fi comuns. Foi apresentada uma visão geral das informações de estado do canal, discutida brevemente a arquitetura geral de um sistema baseado em CSI, e seu modelo matemático. Estudos encontrados na literatura que tratam da detecção de sinais vitais humanos como respiração, frequência cardíaca, ou ambos, utilizando os dados CSI foram apresentados de acordo com as ferramentas utilizadas para extração de dados, técnicas empregadas no processamento dos sinais e algoritmos de detecção de sinais vitais. Assim, uma classificação e descrição foi apresentada, levando em conta também recursos como monitoramento em tempo real ou multiusuário e desempenho nos cenários propostos. Esses estudos de Wi-Fi CSI para monitoramento de sinais vitais mostram um desempenho promissor em vários cenários de aplicação.

Além disso, também foram apontadas as limitações das atuais abordagens de monitoramento de sinais vitais baseadas em Wi-Fi CSI e discutidos alguns desafios ainda a serem superados para que a análise de CSI possa ser totalmente usada na prática para monitorar sinais vitais e apoiar uma variedade de aplicações de saúde. Apresentando algumas tendências futuras, diversos temas de pesquisa foram elencados motivando mais trabalhos na área.

## Agradecimentos

Este trabalho teve o apoio de CNPq, CAPES, CAPES Print, FAPERJ, FAPESP, INCT-MACC.

## Referências

[Bowen et al. 2019a] Bowen, L., Hulbert, R., Fong, J., Rentz, Z., and Debruhl, B. (2019a). Democratized radio tomography: Using consumer equipment to see through walls. *IEEE Vehicular Technology Conference*, pages 1–6.

- [Bowen et al. 2019b] Bowen, L., Hulbert, R., Fong, J., Rentz, Z., and DeBruhl, B. (2019b). Democratized radio tomography: Using consumer equipment to see through walls. In *IEEE Vehicular Technology Conference*, pages 1–6. IEEE.
- [Chen et al. 2017a] Chen, C., Han, Y., Chen, Y., Lai, H.-Q., Zhang, F., Wang, B., and Liu, K. R. (2017a). TR-BREATH: Time-reversal breathing rate estimation and detection. *IEEE Transactions on Biomedical Engineering*, 65(3):489–501.
- [Chen et al. 2016] Chen, C., Han, Y., Chen, Y., and Liu, K. R. (2016). Multi-person breathing rate estimation using time-reversal on wifi platforms. In *IEEE Global Conference on Signal and Information Processing*, pages 1059–1063. IEEE.
- [Chen et al. 2017b] Chen, L., Chen, X., Ni, L., Peng, Y., and Fang, D. (2017b). Human behavior recognition using wi-fi csi: Challenges and opportunities. *IEEE Communications Magazine*, 55(10):112–117.
- [Damodaran et al. 2020] Damodaran, N., Haruni, E., Kokhkhharova, M., and Schäfer, J. (2020). Device free human activity and fall recognition using WiFi channel state information (CSI). *Transactions on Pervasive Computing and Interaction*, 2(1):1–17.
- [Dou and Huan 2021] Dou, C. and Huan, H. (2021). Full respiration rate monitoring exploiting doppler information with commodity wi-fi devices. *Sensors*, 21(10):3505.
- [Duan et al. 2018a] Duan, S., Yu, T., and He, J. (2018a). WiDriver: Driver Activity Recognition System Based on WiFi CSI. *International Journal of Wireless Information Networks*, 25(2):146–156.
- [Duan et al. 2018b] Duan, S., Yu, T., and He, J. (2018b). Widriver: Driver activity recognition system based on wifi csi. *International Journal of Wireless Information Networks*, 25(2):146–156.
- [Fang et al. 2016] Fang, B., Lane, N. D., Zhang, M., Boran, A., and Kawsar, F. (2016). Bodyscan: Enabling radio-based sensing on wearable devices for contactless activity and vital sign monitoring. In *Proceedings of the international conference on mobile systems, applications, and services*, pages 97–110.
- [Gringoli and Nava 2009] Gringoli, F. and Nava, L. (2009). Open firmware for wifi networks.
- [Gringoli et al. 2019] Gringoli, F., Schulz, M., Link, J., and Hollick, M. (2019). Free your CSI: A channel state information extraction platform for modern Wi-Fi chipsets. *Mobile Computing and Networking (MOBICOM)*, pages 21–28.
- [Gu et al. 2018] Gu, Y., Liu, T., Li, J., Ren, F., Liu, Z., Wang, X., and Li, P. (2018). Emosense: Data-driven emotion sensing via off-the-shelf wifi devices. In *IEEE International Conference on Communications (ICC)*, pages 1–6. IEEE.
- [Gu et al. 2017] Gu, Y., Zhan, J., Ji, Y., Li, J., Ren, F., and Gao, S. (2017). MoSense: An RF-Based Motion Detection System via Off-the-Shelf WiFi Devices. *IEEE Internet of Things Journal*, 4(6):2326–2341.

- [Gu et al. 2021] Gu, Y., Zhang, X., Yan, H., Liu, Z., and Ren, F. (2021). Wital: WiFi-based Real-time Vital Signs Monitoring During Sleep.
- [Halperin et al. 2011] Halperin, D., Hu, W., Sheth, A., and Wetherall, D. (2011). Tool release: Gathering 802.11 n traces with channel state information. *ACM SIGCOMM Computer Communication Review*, 41(1):53–53.
- [IEEE 802.11 Working Group 2003] IEEE 802.11 Working Group (2003). Ieee 802.11g-2003 - ieee standard for information technology. Technical report, IEEE.
- [IEEE 802.11 Working Group 2009] IEEE 802.11 Working Group (2009). Ieee 802.11n-2009 - ieee standard for information technology. Technical report, IEEE.
- [IEEE 802.11 Working Group 2013] IEEE 802.11 Working Group (2013). Ieee 802.11ac-2013 - ieee standard for information technology. Technical report, IEEE.
- [Khamis et al. 2018] Khamis, A., Chou, C. T., Kusy, B., and Hu, W. (2018). Cardiofi: Enabling heart rate monitoring on unmodified COTS WiFi devices. *ACM International Conference Proceeding Series*, pages 97–106.
- [Khan 2017] Khan, S. F. (2017). Health care monitoring system in internet of things (iot) by using rfid. In *2017 6th International Conference on Industrial Technology and Management (ICITM)*, pages 198–204. IEEE.
- [Khan et al. 2017] Khan, U. M., Kabir, Z., and Hassan, S. A. (2017). Wireless health monitoring using passive wifi sensing. In *International Wireless Communications and Mobile Computing Conference*, pages 1771–1776. IEEE.
- [Lee et al. 2018] Lee, S., Park, Y. D., Suh, Y. J., and Jeon, S. (2018). Design and implementation of monitoring system for breathing and heart rate pattern using WiFi signals. *IEEE Annual Consumer Communications and Networking Conference*, pages 1–7.
- [Li et al. 2021] Li, F., Valero, M., Shahriar, H., Khan, R. A., and Ahamed, S. I. (2021). Wi-covid: A covid-19 symptom detection and patient monitoring framework using wifi. *Smart Health*, 19:100147.
- [Li et al. 2019] Li, H., He, X., Chen, X., Fang, Y., and Fang, Q. (2019). Wi-motion: A robust human activity recognition using WiFi signals. *IEEE Access*, 7:153287–153299.
- [Li et al. 2018] Li, H., Ota, K., Dong, M., and Guo, M. (2018). Learning human activities through wi-fi channel state information with multiple access points. *IEEE Communications Magazine*, 56(5):124–129.
- [Liu et al. 2018] Liu, J., Chen, Y., Wang, Y., Chen, X., Cheng, J., and Yang, J. (2018). Monitoring vital signs and postures during sleep using WiFi signals. *IEEE Internet of Things Journal*, 5(3):2071–2084.
- [Liu et al. 2019] Liu, J., Liu, H., Chen, Y., Wang, Y., and Wang, C. (2019). Wireless sensing for human activity: A survey. *IEEE Communications Surveys & Tutorials*, 22(3):1629–1645.

- [Liu et al. 2015a] Liu, J., Wang, Y., Chen, Y., Yang, J., Chen, X., and Cheng, J. (2015a). Tracking vital signs during sleep leveraging off-the-shelf wifi. In *Proceedings of the ACM International Symposium on Mobile Ad Hoc Networking and Computing*, pages 267–276.
- [Liu et al. 2014] Liu, X., Cao, J., Tang, S., and Wen, J. (2014). Wi-sleep: Contactless sleep monitoring via wifi signals. In *IEEE Real-Time Systems Symposium*, pages 346–355. IEEE.
- [Liu et al. 2015b] Liu, X., Cao, J., Tang, S., Wen, J., and Guo, P. (2015b). Contactless respiration monitoring via off-the-shelf wifi devices. *IEEE Transactions on Mobile Computing*, 15(10):2466–2479.
- [Ma et al. 2016] Ma, J., Wang, Y., Wang, H., Wang, Y., and Zhang, D. (2016). When can we detect human respiration with commodity wifi devices? In *ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct*, pages 325–328.
- [Ma et al. 2019a] Ma, Y., Zhou, G., and Wang, S. (2019a). WiFi sensing with channel state information: A survey. *ACM Computing Surveys*, 52(3).
- [Ma et al. 2019b] Ma, Y., Zhou, G., and Wang, S. (2019b). Wifi sensing with channel state information: A survey. *ACM Computing Surveys*, 52(3):1–36.
- [Schulz et al. 2018] Schulz, M., Gringoli, F., Link, J., and Hollick, M. (2018). Shadow Wi-Fi: Teaching smartphones to transmit raw signals and to extract channel state information to implement practical covert channels over Wi-Fi. *ACM International Conference on Mobile Systems, Applications, and Services*, pages 256–268.
- [Shang and Wu 2016] Shang, J. and Wu, J. (2016). Fine-grained vital signs estimation using commercial wi-fi devices. In *Proceedings of the Eighth Wireless of the Students, by the Students, and for the Students Workshop*, pages 30–32.
- [Sharma et al. 2021] Sharma, A., Li, J., Mishra, D., Batista, G., and Seneviratne, A. (2021). Passive WiFi CSI sensing based machine learning framework for COVID-Safe occupancy monitoring. In *IEEE International Conference on Communications Workshops*, pages 1–6. IEEE.
- [Shi et al. 2018] Shi, Z., Zhang, J. A., Xu, R., and Fang, G. (2018). Human activity recognition using deep learning networks with enhanced channel state information. In *IEEE Globecom Workshops*, pages 1–6. IEEE.
- [Sorber et al. 2013] Sorber, L., Van Barel, M., and De Lathauwer, L. (2013). Optimization-based algorithms for tensor decompositions: Canonical polyadic decomposition, decomposition in rank- $(l_r, l_r, 1)$  terms, and a new generalization. *SIAM Journal on Optimization*, 23(2):695–720.
- [Tan et al. 2018] Tan, B., Chen, Q., Chetty, K., Woodbridge, K., Li, W., and Piechocki, R. (2018). Exploiting WiFi Channel State Information for Residential Healthcare Informatics. *IEEE Communications Magazine*, 56(5):130–137.

- [Tan et al. 2018] Tan, B., Chen, Q., Chetty, K., Woodbridge, K., Li, W., and Piechocki, R. (2018). Exploiting wifi channel state information for residential healthcare informatics. *IEEE Communications Magazine*, 56(5):130–137.
- [Uchiyama et al. 2021] Uchiyama, A., Saruwatari, S., Maekawa, T., Ohara, K., and Higashino, T. (2021). Context recognition by wireless sensing: A comprehensive survey. *Journal of Information Processing*, 29:46–57.
- [Wang et al. 2016a] Wang, G., Zou, Y., Zhou, Z., Wu, K., and Ni, L. M. (2016a). We can hear you with wi-fi! *IEEE Transactions on Mobile Computing*, 15(11):2907–2920.
- [Wang et al. 2016b] Wang, H., Zhang, D., Ma, J., Wang, Y., Wang, Y., Wu, D., Gu, T., and Xie, B. (2016b). Human respiration detection with commodity wifi devices: do user location and body orientation matter? In *Proceedings of the ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pages 25–36.
- [Wang et al. 2017a] Wang, P., Guo, B., Xin, T., Wang, Z., and Yu, Z. (2017a). Tiny-sense: Multi-user respiration detection using wi-fi csi signals. In *IEEE International Conference on e-Health Networking, Applications and Services*, pages 1–6. IEEE.
- [Wang et al. 2017b] Wang, X., Yang, C., and Mao, S. (2017b). PhaseBeat: Exploiting CSI phase data for vital sign monitoring with commodity WiFi devices. In *IEEE International Conference on Distributed Computing Systems*, pages 1230–1239. IEEE.
- [Wang et al. 2017c] Wang, X., Yang, C., and Mao, S. (2017c). Tensorbeat: Tensor decomposition for monitoring multiperson breathing beats with commodity wifi. *ACM Trans. Intell. Syst. Technol.*, 9(1).
- [Wang et al. 2020] Wang, X., Yang, C., and Mao, S. (2020). On CSI-Based Vital Sign Monitoring Using Commodity WiFi. *ACM Transactions on Computing for Healthcare*, 1(3):1–27.
- [Wang et al. 2019] Wang, Z., Jiang, K., Hou, Y., Dou, W., Zhang, C., Huang, Z., and Guo, Y. (2019). A survey on human behavior recognition using channel state information. *IEEE Access*, 7:155986–156024.
- [Weinstein and Ebert 1971] Weinstein, S. and Ebert, P. (1971). Data transmission by Frequency-Division Multiplexing using the Discrete Fourier Transform. *IEEE Transactions on Communication Technology*, 19(5):628–634.
- [Wu et al. 2017] Wu, D., Zhang, D., Xu, C., Wang, H., and Li, X. (2017). Device-free wifi human sensing: From pattern-based to model-based approaches. *IEEE Communications Magazine*, 55(10):91–97.
- [Wu et al. 2018] Wu, X., Chu, Z., Yang, P., Xiang, C., Zheng, X., and Huang, W. (2018). Tw-see: Human activity recognition through the wall with commodity wi-fi devices. *IEEE Transactions on Vehicular Technology*, 68(1):306–319.
- [Xiao et al. 2017] Xiao, F., Guo, Z., Zhu, H., Xie, X., and Wang, R. (2017). Ampn: Real-time los/nlos identification with wifi. In *IEEE International Conference on Communications (ICC)*, pages 1–7. IEEE.

- [Xiao et al. 2016] Xiao, J., Zhou, Z., Yi, Y., and Ni, L. M. (2016). A survey on wireless indoor localization from the device perspective. *ACM Computing Surveys*, 49(2):1–31.
- [Xie et al. 2018] Xie, Y., Li, Z., and Li, M. (2018). Precise power delay profiling with commodity wi-fi. *IEEE Transactions on Mobile Computing*, 18(6):1342–1355.
- [Yang et al. 2018] Yang, Y., Cao, J., Liu, X., and Xing, K. (2018). Multi-person sleeping respiration monitoring with cots wifi devices. In *IEEE International Conference on Mobile Ad Hoc and Sensor Systems*, pages 37–45. IEEE.
- [Yang et al. 2013] Yang, Z., Zhou, Z., and Liu, Y. (2013). From rssi to csi: Indoor localization via channel response. *ACM Computing Surveys*, 46(2):1–32.
- [Yousefi et al. 2017] Yousefi, S., Narui, H., Dayal, S., Ermon, S., and Valaee, S. (2017). A survey on behavior recognition using wifi channel state information. *IEEE Communications Magazine*, 55(10):98–104.
- [Zeng et al. 2018] Zeng, Y., Wu, D., Gao, R., Gu, T., and Zhang, D. (2018). Fullbreathe: Full human respiration detection exploiting complementarity of csi phase and amplitude of wifi signals. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2(3):1–19.
- [Zeng et al. 2020] Zeng, Y., Wu, D., Xiong, J., Liu, J., Liu, Z., and Zhang, D. (2020). Multisense: Enabling multi-person respiration sensing with commodity wifi. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 4(3):1–29.
- [Zeng et al. 2019] Zeng, Y., Wu, D., Xiong, J., Yi, E., Gao, R., and Zhang, D. (2019). FarSense: Pushing the range limit of WiFi-based respiration sensing with CSI ratio of two antennas. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 3(3):1–26.
- [Zhang et al. 2019] Zhang, D., Hu, Y., Chen, Y., and Zeng, B. (2019). BreathTrack: Tracking indoor human breath status via commodity WiFi. *IEEE Internet of Things Journal*, 6(2):3899–3911.
- [Zhang et al. 2018] Zhang, F., Zhang, D., Xiong, J., Wang, H., Niu, K., Jin, B., and Wang, Y. (2018). From Fresnel Diffraction Model to Fine-grained Human Respiration Sensing with Commodity Wi-Fi Devices. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, pages 1–23.
- [Zhang et al. 2017] Zhang, J., Xu, W., Hu, W., and Kanhere, S. S. (2017). Wicare: Towards in-situ breath monitoring. In *EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pages 126–135.
- [Zhao et al. 2018] Zhao, M., Adib, F., and Katabi, D. (2018). Emotion recognition using wireless signals. *Communications of the ACM*, 61(9):91–100.
- [Zhu et al. 2017] Zhu, D., Pang, N., Li, G., and Liu, S. (2017). Notifi: A ubiquitous wifi-based abnormal activity detection system. In *International Joint Conference on Neural Networks*, pages 1766–1773. IEEE.