

# Estimativa da Frequência Respiratória Usando Dados Wi-Fi CSI Comparada a Medição com Dispositivos Comerciais

Fábio G. Queirós<sup>1</sup>, Julio C. H. Soto<sup>1</sup>, Iandra Galdino<sup>1</sup>,  
Carla E. C. Silva<sup>1</sup>, Arthur Viana<sup>2</sup>, Leticia de Oliveira<sup>3</sup>,  
Célio Albuquerque<sup>1</sup>, Débora C. Muchaluat-Saade<sup>1</sup>

<sup>1</sup>Laboratório MídiaCom - Instituto de Computação

<sup>2</sup>Laboratorio de Psicofisiologia Cognitiva

<sup>3</sup>Laboratório de Neurofisiologia do Comportamento  
Universidade Federal Fluminense (UFF) – RJ

{fabio gabriel, jsoto, igaldino, celio, debora}@midiacom.uff.br,

{carlaestefany, arthurviana, oliveira leticia}@id.uff.br

**Abstract.** *Technological advancements have driven the development of various devices capable of estimating vital signs, such as respiratory rate. Despite the availability of these devices, they still present disadvantages, such as the discomfort generated during respiratory rate estimation due to the need for physical contact with the patient. In this context, Channel State Information (CSI) technology has emerged as a promising alternative. It allows the monitoring of Wi-Fi signals, which contain information about the transmission state, to estimate the breathing rate in home and hospital environments. In this work, we present the application of CSI, along with signal processing techniques, for estimating the respiratory rate in individuals. To validate our approach, we compared the respiratory rate estimates obtained with CSI to those of commercially validated devices, such as Polar H10 and Biopac. Our database consists of approximately 100 volunteers. The obtained results demonstrate a high similarity between the CSI estimates and those of the validated commercial devices.*

**Resumo.** *Os avanços tecnológicos têm impulsionado o desenvolvimento de diversos dispositivos capazes de estimar sinais vitais, como a frequência respiratória. Apesar da disponibilidade desses dispositivos, eles ainda apresentam desvantagens, como o desconforto gerado durante a estimativa da frequência respiratória, devido à necessidade de contato físico com o paciente. Nesse contexto, a tecnologia baseada em dados de Informação do Estado do Canal (CSI) tem emergido como uma alternativa promissora. Ela permite a utilização de sinais Wi-Fi, que contêm informações sobre o estado do canal de transmissão, para estimar a taxa de respiração em ambientes domiciliares e hospitalares. Neste trabalho, apresentamos a aplicação da CSI, juntamente com técnicas de processamento de sinais, para a estimativa da frequência respiratória em indivíduos. Para validar nossa abordagem, compararmos as estimativas da frequência respiratória obtidas com o CSI com as de dispositivos comerciais já validados, como o Polar H10 e o Biopac. A base de dados utilizada é composta por cerca de 100 voluntários. Os resultados obtidos demonstram uma alta similaridade entre as estimativas do CSI e as dos dispositivos comerciais validados.*

## 1. Introdução

Atualmente, diversos dispositivos médicos são utilizados para monitorar, tratar e diagnosticar doenças ou condições através do contato direto com o corpo humano. Contudo, a pandemia de COVID-19 evidenciou a necessidade de monitoramento remoto, seguro e de baixo custo, visando atender a um número maior de pessoas [Tan et al. 2018]. Além disso, a busca por soluções que preservem o conforto do paciente e minimizem o risco de contaminação para os profissionais de saúde tornou-se imperativa [Sharma et al. 2021, Li et al. 2019].

Dentre as tecnologias de monitoramento remoto, destacam-se FMCW (*Frequency Modulated Carrier Waves*) [Pradhan et al. 2017] e RFID (*Radio Frequency Identification*) [Khan 2017], embora ambas apresentem custos elevados. CSI (*Channel State Information*), presente em redes Wi-Fi, surge como uma alternativa promissora devido à sua ampla disponibilidade em ambientes residenciais e comerciais, bem como ao baixo custo proporcionado pelo reaproveitamento da infraestrutura existente. Através das características do sinal CSI, como amplitude e fase [Gu et al. 2017], é possível identificar atividades humanas [Gu et al. 2018] e sinais vitais [Galdino et al. 2023a].

Dentre os sinais vitais estimados, destacam-se as frequências cardíaca e respiratória. A partir dessas estimativas, é possível detectar outras condições clínicas, como a apneia do sono [Alzaabi et al. 2024]. Dessa forma, a frequência respiratória se torna um sinal vital de grande importância para a avaliação fisiológica de um indivíduo.

Este trabalho realiza a estimativa da frequência respiratória utilizando dados CSI de uma rede Wi-Fi. A estimativa da frequência respiratória por meio de CSI ainda é uma abordagem recente, carecendo de avaliações comparativas com dispositivos padronizados e comercialmente disponíveis. Assim, este trabalho também realiza uma avaliação das estimativas da frequência respiratória, obtidas por CSI, confrontando-as com outros dispositivos comerciais amplamente utilizados, tais como o Polar H10 e o Biopac. As contribuições deste trabalho são apresentadas brevemente a seguir:

- Cálculo da estimativa da frequência respiratória utilizando técnicas de processamento de sinais em dados Wi-Fi CSI.
- Avaliação das estimativas de frequência respiratória frente a outros dois dispositivos: um comercial (Polar H10) e outro médico (Biopac).

Além das contribuições em destaque, a abordagem proposta oferece outras vantagens pelo fato de o uso de dados CSI fornecer uma estimativa de taxa de respieração sem contato, o que se traduz em um benefício de não gerar incômodo ou invasão na pessoa monitorada com contato físico ao corpo humano. Além disso, a proposta aproveita a infraestrutura de redes Wi-Fi para a estimativa de um sinal vital, o que é transparente para o paciente e a equipe médica, facilitando seu uso prático.

Este trabalho está estruturado da seguinte maneira. A Seção 2 mostra brevemente o conceito Wi-Fi CSI. A Seção 3 fornece uma visão abrangente dos trabalhos relacionados encontrados na literatura. A Seção 4 delinea a proposta desenvolvida para a estimativa da frequência respiratória em um ambiente interno. A Seção 5 apresenta uma exposição detalhada dos resultados experimentais. Finalmente, a Seção 6 realça as conclusões e sugere trabalhos futuros.

## 2. Wi-Fi CSI

Os dados de *Channel State Information* (CSI) fornecem informações cruciais sobre as propriedades dos canais de comunicação, permitindo caracterizar como o sinal se altera enquanto se propaga do transmissor para o receptor.

No contexto da especificação IEEE 802.11ax [Soto et al. 2022a, Caballero et al. 2023], a camada física das redes Wi-Fi adota a técnica de multiplexação por divisão de frequência ortogonal (OFDM). O OFDM é uma técnica que segmenta a largura de banda disponível em múltiplos subcanais ortogonais [Soto et al. 2022b, Soto et al. 2022a], permitindo que a informação seja transmitida de forma independente em diferentes subportadoras [Caballero et al. 2023, Chen et al. 2019]. Como as subportadoras são ortogonais entre si, cada uma delas pode fornecer dados exclusivos de CSI, permitindo tratá-las como sensores independentes que capturam dados de CSI.

Então, quando uma pessoa se posiciona entre os dispositivos transmissor e receptor Wi-Fi, ela altera a propagação do sinal eletromagnético. Essas alterações são refletidas diretamente nos dados de CSI. Ao monitorar e analisar essas variações, é possível não apenas detectar a presença de uma pessoa, mas também identificar movimentos do corpo, e até mesmo frequências cardíaca e respiratória.

## 3. Trabalhos Relacionados

Esta seção apresenta os trabalhos relacionados à estimativa da frequência respiratória utilizando dados Wi-Fi CSI. Os dispositivos que utilizam Wi-Fi estão presentes em diversos locais e as características do sinal são influenciadas por vários fatores ambientais, bem como pela atividade humana e respiração [Soto et al. 2022a]. Muitos trabalhos que investigam a estimativa da taxa de respiração aplicam-na ao reconhecimento da apneia do sono, como demonstrado em [Yu et al. 2021], [Ali et al. 2023] e [Liu et al. 2014].

Em Wang et al. [Wang et al. 2017, Wang et al. 2020], utiliza-se a diferença de fase do sinal CSI entre duas antenas do receptor para calcular a taxa de respiração e o batimento cardíaco. Para obter os resultados através deste dado de entrada, é necessário realizar previamente a detecção de ambiente, a seleção de subportadoras e aplicar uma Transformada Wavelet. No entanto, o estudo abrange apenas 4 voluntários monitorados durante 3 meses, o que limita a generalização para diferentes indivíduos.

Já Yu et al. [Yu et al. 2021] propõem o uso do algoritmo MRC-PCA, que utiliza informações de amplitude e fase para calcular a frequência respiratória e identificar a apneia do sono. No modelo, calcula-se a SNR (*Signal-to-Noise Ratio*) para maximizar a contribuição de informação de cada faixa/subportadora do sinal e refiná-lo formato da onda de cada subportadora. Além disso, é realizada a mixagem entre as diferentes subportadoras, resultando em uma única série temporal da atividade realizada. Os experimentos foram conduzidos com 12 voluntários durante 19 noites em um quarto domiciliar.

Utilizando dados de 80 noites e 5 participantes em ambientes individuais controlados, Ali et al. [Ali et al. 2023] analisam os movimentos e a respiração durante as fases do sono. O movimento da caixa torácica durante a respiração é semelhante a um movimento corporal no espectro do sinal. Na ausência de movimentos, há apenas uma componente variável no domínio do tempo-espacó, e a projeção PCA de maior variância é suficiente para monitorar a respiração. Em contraste, quando há um aumento na variação

do sinal, as componentes principais do CSI são rastreadas em conjunto com a técnica de agrupamento multidimensional, que descarta a contribuição de movimentos no sinal respiratório. São então aplicados filtros para remover ruídos e um filtro passa-banda para limitar a frequência de análise da respiração, capturando assim os picos da série temporal que representam a taxa respiratória.

Baseado em um modelo de aprendizado profundo, Mosleh et al. [Mosleh et al. 2022] utilizam dados de fase e amplitude do sinal, além de técnicas de pré-processamento semelhantes aos trabalhos anteriores, como filtragem de frequência, remoção de ruído e normalização do sinal. Devido aos padrões respiratórios presentes no sinal, discute-se o uso de diferentes técnicas de aprendizado, incluindo LSTM (*Long Short Term Memory*) supervisionada com a entrada dos dados. O conjunto de dados é composto por dados de um manequim médico, que simula a respiração de um adulto. Além disso, a sala possui maior controle de ruídos e interferências do ambiente, utilizando mantas acústicas nas paredes.

Em Liu et al. [Liu et al. 2014], são extraídos padrões rítmicos da respiração e mudanças abruptas geradas pelo corpo. Seguindo o trabalho de Liu et al. [Liu et al. 2016], realiza-se uma preparação dos dados com remoção de *outliers* e ruído do sinal coletado, preservando as transições ocasionadas pela interferência humana. Seleciona-se uma subportadora dentre os pares de antenas de transmissão, a qual se mostra mais sensível à frequência respiratória. Dessa forma, é predita a taxa de respiração e, em caso de ausência, identifica-se o tipo de apneia do sono dentre as 6 diferentes posições avaliadas. Os testes são conduzidos com um único indivíduo, com uma coleta total de 10 minutos, durante os quais ele alterna entre respiração normal e os diferentes tipos de apneia.

Semelhante a outros trabalhos, He et al. [He et al. 2019] utilizam dados de amplitude e fase para identificar tanto a presença quanto a taxa de respiração e, em uma etapa subsequente, classificar a apneia. A taxa de respiração é estimada utilizando SVM (*Support Vector Machine*) e métricas extraídas do sinal, como média, mediana e desvio padrão. Para o monitoramento da respiração, é adicionada a identificação de picos, visando detectar anomalias respiratórias. Essa arquitetura é comum em diversas pesquisas, caracterizando-se pelo uso de filtros para remoção de ruído, seleção da faixa de frequência de interesse para análise, entre outros. Ainda, foram considerados 4 voluntários durante duas semanas, alternando entre 3 categorias de presença humana: ausência, estática e dinâmica (atividades em movimento).

#### **4. Estimativa da Frequência Respiratória**

Esta seção apresenta a proposta de estimativa da frequência respiratória utilizando dados CSI de redes Wi-Fi. As capturas de dados foram realizadas em uma sala do Instituto de Computação da Universidade Federal Fluminense, com dimensões de 3x4 metros (12 m<sup>2</sup>).

Nesse ambiente foram coletados dados CSI de 17 posições de diferentes participantes. Também foram coletados metadados totalmente anonimizados desses participantes. Para mais informações, assim como as configurações sobre a captura dos dados, pode-se consultar [Galdino et al. 2023b]. Esta pesquisa foi aprovada pelo Comitê de Ética em Pesquisa da Universidade Federal Fluminense sob o número de projeto CAAE 54359221.4.0000.5243.

Após a captura de dados, foram utilizados dados das seguintes posições: sentado de frente ("1"), sentado de costas ("4"), em pé de frente ("6"), em pé de costas ("8"), em pé caminhando ("15"), em pé correndo ("16") e em pé varrendo ("17"), em relação ao dispositivo de coleta (Raspberry Pi 4B). O participante, além de seguir o protocolo de coleta, deveria respirar normalmente, isto é, cada ciclo corresponde a uma respiração completa (inalação e expiração). Em cada captura de posição realizada, obtém-se dados de 256 subportadoras, devido ao uso de uma largura de banda de 80 MHz. Inicialmente, foi realizada a eliminação das subportadoras nulas e piloto, que não contêm dados CSI e servem principalmente para controle da transmissão. Finalmente, foram consideradas 234 subportadoras.

As 234 subportadoras foram avaliadas para verificar a qualidade do sinal e observar se o sinal é relevante. Para a verificação do sinal, foi aplicado um filtro Savitzky-Golay [Schafer 2011], que permite suavizar a onda e eliminar ruídos. Na Figura 1, observam-se as primeiras 64 subportadoras, onde constatou-se que, a partir da subportadora número 54, o sinal apresenta intensidade muito baixa, compatível com o ruído ambiente, cerca de 20 dB abaixo da intensidade do sinal das primeiras 53 subportadoras. Observou-se também que a subportadora 26 apresenta intensidade muito baixa. Este comportamento requer atenção pois se repete em todas as coletas de dados CSI realizadas. Para não influenciar no processamento do sinal, os dados dessas subportadoras foram eliminados e foram mantidos apenas os dados de 52 subportadoras.



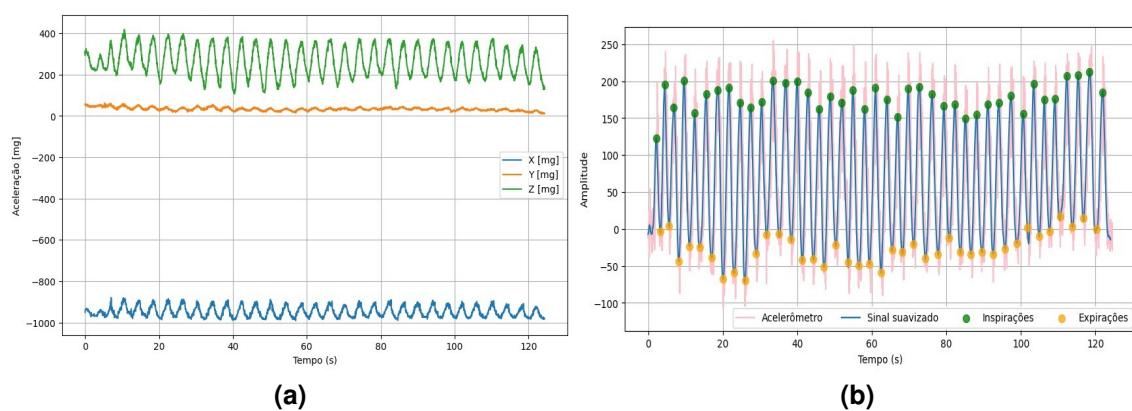
**Figura 1. Análise da intensidade do sinal (dB) nas primeiras 64 subportadoras.**

Após a análise das subportadoras, foi extraída a amplitude de cada uma delas ao longo do período de coleta. Em seguida, procedeu-se à limpeza do sinal, utilizando o filtro de Média Móvel, que permite eliminar ruídos e *outliers* pela suavização da série em relação aos dados vizinhos. Aplicou-se um filtro passa-banda para restringir o sinal às frequências de detecção da respiração, definidas entre 0,1 Hz e 0,4 Hz, considerada a faixa normal da respiração. Esses limites permitem considerar frequências respiratórias entre 6 e 24 rpm. A frequência de amostragem adotada variou de 1 Hz, para garantir a captura de pelo menos um ciclo respiratório completo, até 5 Hz, valor necessário para a reconstrução do sinal. Esses valores estão dentro do intervalo de amostragem calculado a partir da taxa de transmissão de um pacote a cada 0,029 segundos.

Depois, o sinal foi transformado para o domínio da frequência para analisar as frequências com maior intensidade para o cálculo da taxa respiratória. Antes de utilizar a FFT (*Transformada Rápida de Fourier*), é necessário reduzir a dimensionalidade das amostras utilizadas. Para isso, foi aplicada a técnica de PCA (*Análise de Componentes Principais*), e selecionou-se a componente que carrega a maior quantidade de informação. Esta componente é então inserida na FFT. Na FFT foram selecionadas 1, 4 e 10 frequências de maior intensidade, estas frequências foram multiplicadas por 60, que representa a taxa respiratória em um minuto.

#### 4.1. Estimativa da Frequência Respiratória com Polar H10

O dispositivo Polar H10 coleta dados fisiológicos, incluindo dados brutos de seus sensores. Neste trabalho, utilizamos dados do acelerômetro para monitorar o movimento torácico a uma taxa de amostragem de 25 Hz a 200 Hz. Para estimar a frequência respiratória, selecionamos a orientação dos eixos do sensor com base na posição do indivíduo. Na posição sentada, o eixo Z, perpendicular ao movimento torácico, é priorizado para o cálculo adequado. A Figura 2a ilustra a intensidade do sinal nos diferentes eixos, com destaque para o eixo Z.



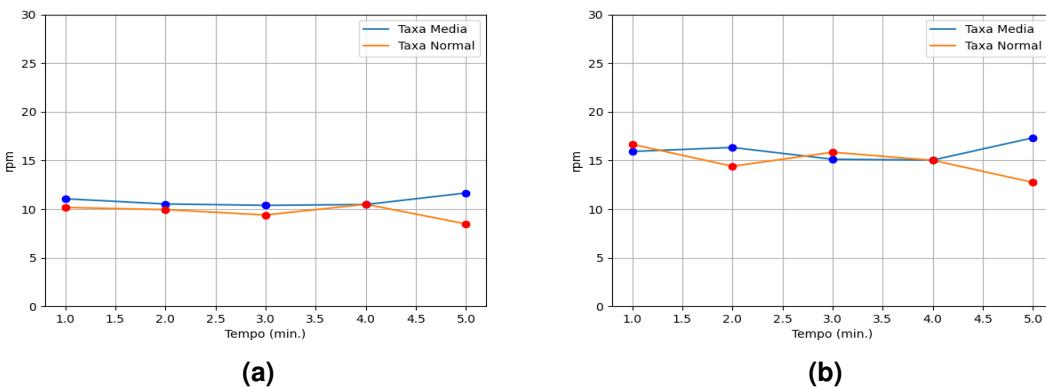
**Figura 2.** (a) Variação dos três eixos do acelerômetro durante a captura na posição sentada.; (b) Variação do acelerômetro suavizado após o cálculo de orientação dos eixos durante a captura na posição sentada.

Após definir a composição de eixos na análise, é aplicado um filtro de Suavização Exponencial que permite definir momentos importantes de inspiração e expiração na série temporal, evidenciando o início e fim de cada ciclo respiratório, como visto na Figura 2b.

Realizado o procedimento de suavização da série temporal, pode-se calcular a frequência respiratória de duas maneiras para diferentes propósitos:

1. Calcular a frequencia respiratória a cada ciclo (pondera-se a duração do ciclo) - Ideal para identificar paradas respiratórias, ou curtos períodos de respiração com base em cada ciclo.
2. Calcular o número de ciclos completos (inspirados e expirados) realizados durante um minuto - Usado para definir a taxa de respiração a cada minuto do paciente e identificar sua evolução ao longo do tempo.

Observa-se uma variação na frequência respiratória dependendo do método de cálculo. A Figura 3 mostra os resultados da estimativa da frequência respiratória utilizando dados do dispositivo Polar H10. A Figura 3a mostra os resultados da estimativa respiratória de uma pessoa com um ritmo de respiração de 10 respirações por minuto (rpm), ou seja, um ciclo de inspiração e expiração a cada 6 segundos. A taxa normal indica que os dados coletados foram utilizados para a estimativa respiratória sem a aplicação de suavização. No caso da taxa média, foi utilizada uma janela de tempo para a recepção de dados do Polar H10 e, ao completar a janela, foi calculada a média dos valores para a estimativa da frequência respiratória. Pode-se observar que a média gera um cálculo mais suavizado e estável em comparação com a taxa normal.



**Figura 3. Frequência respiratória: (a) medição com dispositivo Polar H10 a 0,16 Hz; (b) medição com dispositivo Polar H10 a 0,25 Hz.**

A Figura 3b apresenta a estimativa da frequência respiratória obtida quando o indivíduo realiza 15 ciclos respiratórios por minuto (0,25 Hz). Observa-se que os cálculos da taxa instantânea (normal) e média apresentam variações consideráveis, possivelmente devido ao ritmo respiratório acelerado. Esta aceleração resulta no cálculo de valores atípicos, gerando uma leve instabilidade na estimativa da frequência respiratória.

#### 4.2. Estimativa da frequência respiratória com Biopac

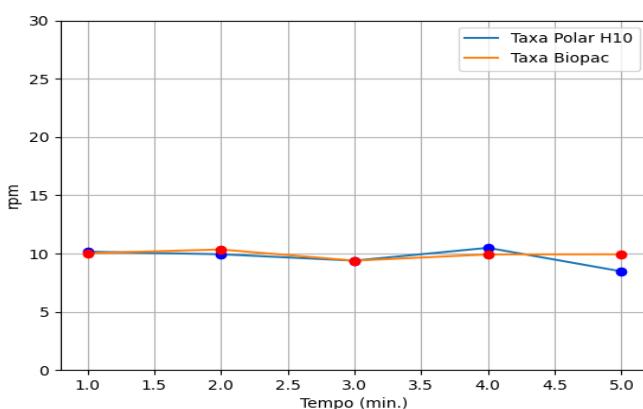
O Biopac MP150 é um dispositivo médico para monitoramento hospitalar, pesquisa em fisiologia e psicologia. Utiliza módulos para coleta de diversos dados fisiológicos. Para a respiração, o Sensor de Cinta Respiratória, com transdutor (eletrodos), capture a expansão e retração por sinais elétricos ou pressão na fita. A posição da fita no corpo depende do tipo de movimento respiratório, abdominal ou torácico. Possui uma taxa de amostragem

de 1 kHz, que oferece alta granularidade e refinamento do sinal respiratório. Permite o uso de filtros passa-banda e ajuste da condutividade do transdutor, eliminando ruídos e adaptando-se individualmente ao corpo, com calibração inicial para garantir a coerência dos dados.

São fornecidos dados da fase do ciclo respiratório digitalizado, juntamente com a estimativa da taxa de respiração a cada ciclo completo, calculada pelo equipamento. Embora existam módulos que realizam o mesmo cálculo, como sensores de fluxo respiratório (que medem a velocidade do ar inspirado/expirado) e oxímetros (que monitoram a saturação de oxigênio), optou-se por um monitoramento equivalente ao da fita cardíaca Polar H10, que utiliza uma fita abdominal, para fins de comparação.

Considera-se que o Biopac, por ser um dispositivo médico, é o *ground truth* para medidas de frequência respiratória. Portanto, o dispositivo Biopac foi utilizado neste trabalho para validar a estimativa da frequência respiratória calculada com o uso da faixa Polar H10, atestando que o H10 também pode ser utilizado como *ground truth* na comparação com as medidas estimadas através dos dados CSI.

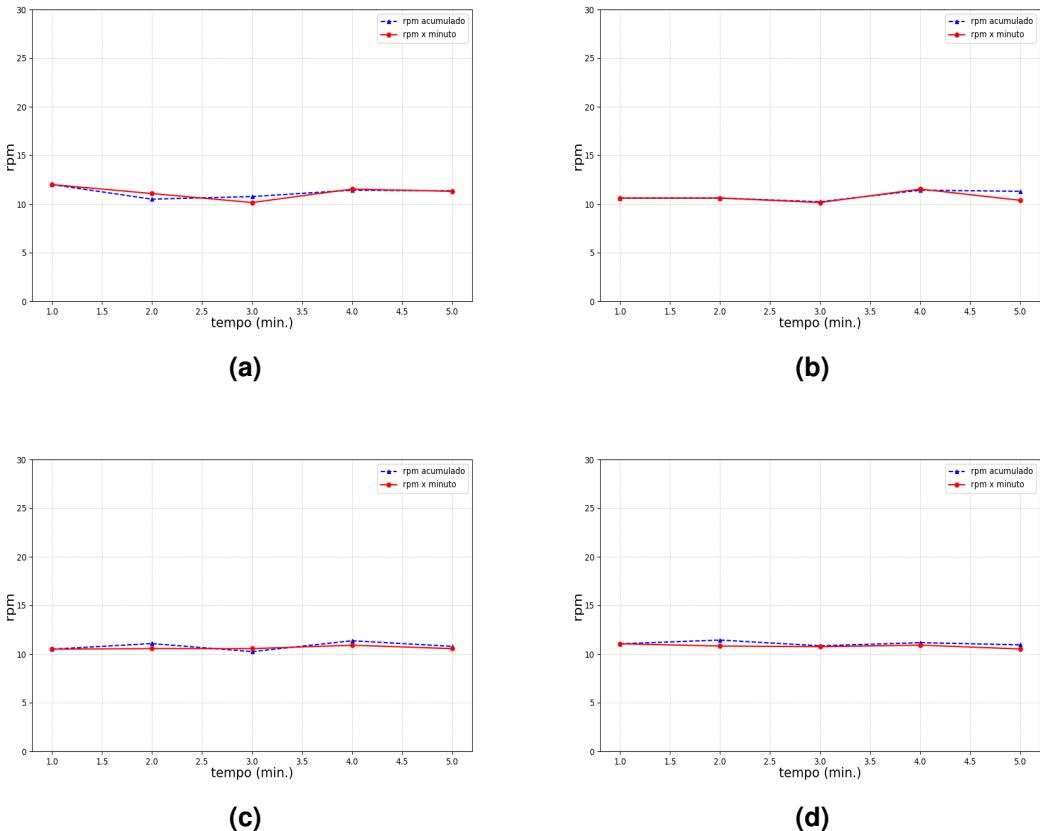
A Figura 4 apresenta a comparação entre as estimativas da frequência respiratória obtidas pelo Biopac e Polar H10. Neste experimento, o indivíduo manteve o ritmo respiratório de 10 ciclos por minuto (0,16 Hz) para os dois dispositivos. As médias dos 5 minutos de coleta foram aproximadamente 9,69 rpm para o Polar H10, e 9,92 rpm para o Biopac. Este resultado apresenta um erro médio de 2,32%, representando uma diferença de 0,23 rpm. Portanto, os cálculos da frequência respiratória com os dados do acelerômetro do Polar H10 são corroborados pela avaliação de um dispositivo médico como o Biopac, o que torna o Polar H10 uma referência confiável na medição respiratória. Portanto, sendo o Polar H10 um dispositivo mais confortável para os testes, além de haver bases de dados já coletados em maior volume, este será considerado o *ground truth* para as medidas a serem estimadas com dados CSI.



**Figura 4. Comparação da frequência respiratória obtida com Polar H10 e Biopac.**

## 5. Resultados

O cenário experimental foi detalhado na Seção 4, utilizando dados coletados durante cinco minutos de um participante na posição sentada. A Figura 5 ilustra a estimativa da frequência respiratória a partir de dados CSI de redes Wi-Fi.

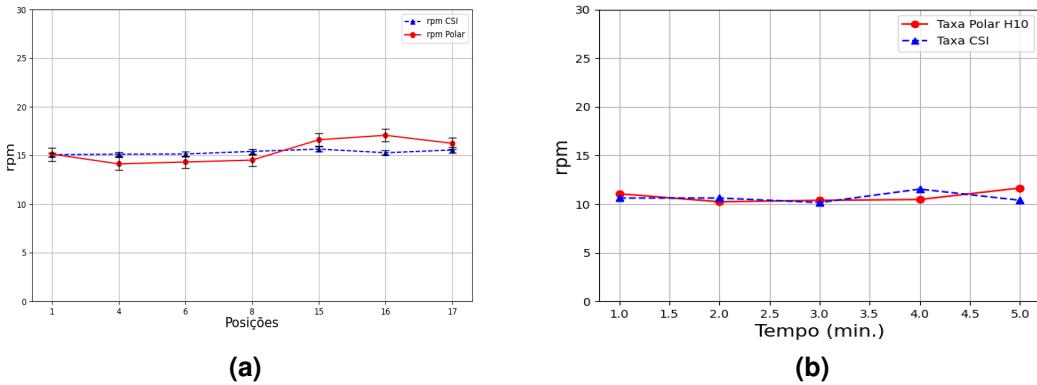


**Figura 5.** Frequência respiratória obtida a partir de dados CSI: (a) Utilização de 234 subportadoras e média calculada com base em 4 frequências; (b) Utilização de 52 subportadoras e frequência única; (c) Utilização de 52 subportadoras e média calculada com base em 4 frequências; (d) Utilização de 52 subportadoras e média calculada com base em 10 frequências.

Na Figuras 5a, observa-se a estimativa da frequência respiratória (rpm) utilizando as 234 subportadoras e uma frequência de maior intensidade. A linha tracejada representa a estimativa da frequência respiratória acumulada, que considera os dados CSI dos minutos anteriores ao minuto de interesse no cálculo. A linha contínua representa a estimativa da frequência respiratória para o minuto de interesse, considerando apenas os dados desse minuto. Observa-se que a estimativa apresenta variação significativa entre os valores. Isso ocorre porque o uso das 234 subportadoras, em dados onde a intensidade do sinal não é uniforme, introduz uma variância considerável no cálculo final da frequência respiratória.

As Figura 5b, 5c e 5d apresentam uma estimativa realizada utilizando apenas 52 subportadoras com maior relevância de sinal, e utilizando uma, quatro e dez frequências com maior intensidade. Observa-se que o cálculo da estimativa da frequência respiratória nos três casos demonstra maior estabilidade. Em particular, a Figura 5b exibe uma estimativa bastante similar em ambos os cenários (cálculo acumulado e por minuto). Isso indica que a utilização de sinais com melhor qualidade resulta em um cálculo de estimativa mais estável e menos sensível a valores atípicos.

A Figura 6 apresenta a comparação entre as estimativas da frequência respiratória obtidas por Wi-Fi CSI e pelo Polar H10. A Figura 6a compara as estimativas de rpm



**Figura 6. (a) Rpm estimado por posição do CSI vs. Polar H10.; (b) Comparação do rpm estimado por CSI e Polar H10 em 5 min. de coleta continua.**

calculadas para cada posição sentada ou pé de todos participantes disponíveis no dataset utilizado. Neste experimento, os participantes respiram em seu ritmo normal. Foi utilizada uma frequência de amostragem de 3,5 Hz, com frequências de corte de 0,1 Hz e 0,4 Hz. Cada coleta em cada posição teve a duração de um minuto. Os resultados demonstraram um erro percentual médio de 0,71%, o que representa um erro médio absoluto de 0,11 rpm em relação às estimativas do polar H10, validando a estimativa obtida pelo CSI.

No experimento apresentado na Figura 6b, um indivíduo manteve um ritmo respiratório controlado de 10 ciclos por minuto (0,16 Hz) durante toda a captura na posição de sentado, utilizando uma frequência de amostragem de 5 Hz. As médias dos dados coletados ao longo de 5 minutos foram de aproximadamente 10,66 rpm para o CSI e 10,75 rpm para o Polar H10. A variação entre as estimativas resultou em um erro percentual médio de 0,89%, o que corresponde a uma diferença média absoluta de 0,1 rpm em relação aos dados do polar H10 *ground truth*.

Os resultados demonstraram um erro médio percentual inferior a 1% ao considerar a frequência de amostragem de 3,5Hz, levando em conta a taxa de transmissão dos pacotes. Os resultados obtidos são promissores quando comparados a dispositivos já consolidados no mercado, com a vantagem do CSI de não gerar desconforto ou invasão fisiológica no paciente.

## 6. Conclusões

Este trabalho apresentou uma nova abordagem para estimar a frequência respiratória utilizando dados CSI de uma rede Wi-Fi. Os resultados foram avaliados em comparação com dispositivos comerciais como o Polar H10 e um dispositivo médico dedicado, o Biopac. O Polar H10 foi estabelecido como uma referência confiável (*ground truth*) devido ao seu pequeno erro percentual médio de 2,32%, encontrado em comparação com o Biopac, um dispositivo médico amplamente utilizado. Em seguida, realizamos uma comparação entre as estimativas da frequência respiratória obtidas com o CSI e o Polar H10, resultando em um erro percentual médio inferior a 1%. Estes resultados são promissores para a busca de uma nova abordagem na estimativa da frequência respiratória, reutilizando a infraestrutura Wi-Fi já existente, de forma totalmente transparente para o paciente.

Como trabalhos futuros, pretende-se analisar os dados CSI e do polar H10 para ou-

tras posições disponíveis no dataset, como a posição deitada, que é comum em ambientes clínicos. Também pretende-se considerar dados de fase, além dos dados de amplitude já explorados. Pretende-se também realizar uma análise detalhada da interferência de sinais emitidos por outros equipamentos nas estimativas CSI. Adicionalmente, os resultados obtidos serão confrontados com trabalhos relevantes encontrados na literatura especializada.

## Agradecimentos

O presente trabalho contou com o apoio financeiro parcial do CNPq, CAPES, CAPES Print, FAPERJ, INCT-MACC, INCT-ICONIoT e FINEP, às quais agradecemos pelo apoio recebido.

## Referências

- Ali, K., Alloulah, M., Kawsar, F., and Liu, A. X. (2023). On goodness of wifi based monitoring of sleep vital signs in the wild. *IEEE Transactions on Mobile Computing*, 22(1):341–355.
- Alzaabi, A., Arslan, T., and Polydorides, N. (2024). Non-contact wi-fi sensing of respiration rate for older adults in care: A validity and repeatability study. *IEEE Access*, 12:6400–6412.
- Caballero, E., Galdino, I., Soto, J. C., Ramos, T. C., Guerra, R., Muchaluat-Saade, D., and Albuquerque, C. (2023). Human activity recognition using wi-fi csi. In *International Conference on Pervasive Computing Technologies for Healthcare*, pages 309–321. Springer.
- Chen, Z., Zhang, L., Jiang, C., Cao, Z., and Cui, W. (2019). Wifi csi based passive human activity recognition using attention based blstm. *IEEE Transactions on Mobile Computing*, 18(11):2714–2724.
- Galdino, I., Gouveia, B., Soto, J., Caballero, E., Ramos, T., Muchaluat-Saade, D., and Albuquerque, C. (2023a). Otimização de parâmetros para detecção de batimentos cardíacos através do sinal wi-fi. In *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 348–359, Porto Alegre, RS, Brasil. SBC.
- Galdino, I., Soto, J. C. H., Caballero, E., Ferreira, V., Ramos, T. C., Albuquerque, C., and Muchaluat-Saade, D. C. (2023b). ehealth csi: A wi-fi csi dataset of human activities. *IEEE Access*, 11:71003–71012.
- 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 *2018 IEEE International Conference on Communications (ICC)*, pages 1–6.
- 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.
- He, Z., Guo, L., Lu, Z., Wen, X., Zheng, W., and Zhou, S. (2019). Contact-free in-home health monitoring system with commodity wi-fi. In *2019 IEEE International Conference on Communications Workshops (ICC Workshops)*, pages 1–6.
- 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.

- 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.
- Liu, X., Cao, J., Tang, S., and Wen, J. (2014). Wi-sleep: Contactless sleep monitoring via wifi signals. In *2014 IEEE Real-Time Systems Symposium*, pages 346–355.
- Liu, X., Cao, J., Tang, S., Wen, J., and Guo, P. (2016). Contactless respiration monitoring via off-the-shelf wifi devices. *IEEE Transactions on Mobile Computing*, 15(10):2466–2479.
- Mosleh, S., Coder, J. B., Scully, C. G., Forsyth, K., and Kalaa, M. O. A. (2022). Monitoring respiratory motion with wi-fi csi: Characterizing performance and the breathes-smart algorithm. *IEEE Access*, 10:131932–131951.
- Pradhan, A., Singh, A., and Saraswat, S. (2017). Emotion recognition through wireless signal. In *2017 4th International Conference on Signal Processing and Integrated Networks (SPIN)*, pages 91–95.
- Schafer, R. W. (2011). What is a savitzky-golay filter? [lecture notes]. *IEEE Signal Processing Magazine*, 28(4):111–117.
- 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 *2021 IEEE International Conference on Communications Workshops (ICC Workshops)*, pages 1–6.
- Soto, J. C., Galdino, I., Caballero, E., Ferreira, V., Muchaluat-Saade, D., and Albuquerque, C. (2022a). A survey on vital signs monitoring based on wi-fi csi data. *Computer Communications*, 195:99–110.
- Soto, J. C. H., Galdino, I., Gouveia, B. G., Caballero, E., Ferreira, V., Muchaluat-Saade, D., and Albuquerque, C. (2022b). Wi-fi csi-based human presence detection using dtw features and machine learning. In *2022 IEEE Latin-American Conference on Communications (LATINCOM)*, pages 1–6.
- 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.
- Wang, X., Yang, C., and Mao, S. (2017). Phasebeat: Exploiting csi phase data for vital sign monitoring with commodity wifi devices. In *2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*, pages 1230–1239.
- Wang, X., Yang, C., and Mao, S. (2020). Resilient respiration rate monitoring with real-time bimodal csi data. *IEEE Sensors Journal*, 20(17):10187–10198.
- Yu, B., Wang, Y., Niu, K., Zeng, Y., Gu, T., Wang, L., Guan, C., and Zhang, D. (2021). Wifi-sleep: Sleep stage monitoring using commodity wi-fi devices. *IEEE Internet of Things Journal*, 8(18):13900–13913.