

Saúde sem Fios: Monitoramento Não Invasivo Utilizando Seleção de Subportadoras OFDM

Wilson Conegundes de Freitas Filho, Flávio Geraldo Coelho Rocha e Henrique Pires Corrêa

Resumo— O monitoramento de sinais vitais é tradicionalmente realizado por meio de sensores corporais ou dispositivos vestíveis, o que pode ser incômodo e resultar em baixa adesão, especialmente entre pessoas que necessitam de acompanhamento contínuo, como idosos e pessoas com doenças crônicas. Além disso, as soluções atuais costumam exigir um dispositivo por indivíduo, o que limita o monitoramento simultâneo de múltiplas pessoas. Com o uso de redes de comunicação sem fio, como o Wi-Fi, torna-se possível detectar sinais vitais, como a respiração, utilizando ondas de radiofrequência, sem contato físico e sem a necessidade de dispositivos vestíveis. Este trabalho apresenta uma abordagem baseada na seleção de subportadoras a partir das informações do estado do canal (CSI) do Wi-Fi, permitindo a detecção simultânea da frequência respiratória de dois indivíduos.

Palavras-Chave— CSI, OFDM, Wi-Fi, sinal de respiração, sensoriamento sem fio.

Abstract— The monitoring of vital signs is traditionally carried out using body sensors or wearable devices, which can be uncomfortable and lead to low adherence, especially among individuals who require continuous monitoring, such as the elderly and people with disabilities. In addition, current solutions typically require one device per person, which limits the simultaneous monitoring of multiple individuals. With the use of wireless communication networks, such as Wi-Fi, it is possible to detect vital signs, such as respiration, through radio frequency waves, without physical contact or usage of wearable devices. This work presents an approach based on subcarrier selection via the Wi-Fi Channel State Information (CSI), enabling the simultaneous detection of respiratory frequency from two individuals.

Keywords— CSI, OFDM, Wi-Fi, respiratory signal, wireless sensing.

I. INTRODUÇÃO

O monitoramento respiratório é um componente fundamental em diversas aplicações na área da saúde, sendo especialmente relevante em contextos como unidades de terapia intensiva, cuidados domiciliares, diagnósticos de distúrbios respiratórios e acompanhamento de pacientes com doenças crônicas [1]. A frequência e o padrão da respiração são indicadores vitais que podem refletir alterações fisiológicas significativas, permitindo uma resposta clínica mais rápida e eficiente. Nesse cenário, métodos confiáveis de medição respiratória são indispensáveis para a detecção precoce de condições clínicas críticas, como apneia do sono, insuficiência respiratória e outras disfunções pulmonares.

Tradicionalmente, o monitoramento respiratório tem sido realizado por meio de técnicas que envolvem contato direto

com o corpo do paciente, como sensores de pressão, cintas torácicas, acelerômetros e dispositivos vestíveis. Embora essas soluções sejam amplamente utilizadas, elas apresentam limitações importantes, dentre as quais o desconforto advindo do contato físico contínuo, especialmente em pacientes idosos, pediátricos ou em pessoas com deficiência. Além disso, esses métodos podem restringir a mobilidade, interferir na rotina do paciente e até mesmo comprometer a qualidade dos dados obtidos devido à má fixação ou movimentação involuntária.

Trabalhos Relacionados. Diante dessas limitações, surgem com destaque as abordagens de monitoramento sem contato [2], que oferecem uma alternativa não invasiva, mais confortável e de fácil integração ao ambiente clínico ou domiciliar. Tecnologias baseadas em sinais de radiofrequência (RF), como o Wi-Fi, têm se mostrado promissoras por possibilitarem a detecção de padrões respiratórios passivamente [3], sem a necessidade de emprego de sensores corporais. Este tipo de solução reduz as barreiras de usabilidade previamente mencionadas, ampliando o potencial de aplicação em cenários de monitoramento contínuo, escalável e de longo prazo.

Dentre as principais etapas desses métodos está a seleção de subportadoras, que define quais componentes do *Channel State Information* (CSI) são mais relevantes para representar com precisão os sinais respiratórios. Diversos trabalhos propõem estratégias de seleção baseadas em métricas de qualidade de subportadora, como a variância no domínio do tempo [4], a variância espectral [5] e a energia na banda respiratória [6], as quais demonstraram bons resultados em contextos específicos.

Contribuições. Neste trabalho, propõe-se uma nova abordagem baseada na junção dessas três métricas, visando explorar as vantagens complementares de cada critério e estimar a frequência respiratória. Além disso, diferente da maioria dos trabalhos da literatura, aplica-se o algoritmo proposto para detecção dos sinais vitais de duas pessoas simultaneamente.

II. FUNDAMENTAÇÃO TEÓRICA

O CSI é uma propriedade que descreve como os sinais de rádio se propagam entre o transmissor e o receptor em diferentes frequências portadoras. Em sistemas Wi-Fi que utilizam *Multiple-Input Multiple-Output Orthogonal Frequency-Division Multiplexing* (MIMO-OFDM) [7], o CSI é representado como uma matriz tridimensional de valores complexos que encapsulam a atenuação de amplitude e o deslocamento de fase dos canais de múltiplos caminhos. Essa informação é estimada a partir dos símbolos de treinamento contidos nos preâmbulos dos pacotes Wi-Fi, permitindo ao receptor reconstruir a matriz do canal com base nos sinais recebidos e nos símbolos conhecidos enviados.

O processo de estimativa do CSI envolve a transmissão de *Long Training Symbols* (LTFs), os quais são analisados pelo receptor para calcular a resposta do canal para cada subportadora, por par transmissor-receptor e a cada instante de tempo. Assim, o CSI fornece um acompanhamento dinâmico e sensível das variações do ambiente, refletindo mudanças causadas por obstáculos e movimentação humana [8].

Matematicamente, para uma transmissão na subportadora k em um sistema MIMO com N_t antenas transmissoras e N_r antenas receptoras, o modelo de canal pode ser expresso como:

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{n}_k, \quad (1)$$

onde:

- $\mathbf{y}_k \in C^{N_r \times 1}$ é o vetor de sinais recebidos,
- $\mathbf{x}_k \in C^{N_t \times 1}$ é o vetor de sinais transmitidos,
- $\mathbf{H}_k \in C^{N_r \times N_t}$ é a matriz do canal (o CSI),
- $\mathbf{n}_k \in C^{N_r \times 1}$ é o vetor de ruído.

Durante o processo de estimativa, o receptor utiliza os símbolos x_k conhecidos dos LTFs e os sinais recebidos y_k para calcular $\mathbf{H}_k$. O ruído $\mathbf{n}_k$ denota as imperfeições do ambiente, do *hardware* de receptor e dos efeitos multi-percurso.

O comportamento do CSI o torna uma ferramenta promissora para aplicações de sensoriamento sem contato, como o monitoramento respiratório. Pequenos movimentos do tórax provocados pelo ciclo respiratório impactam a propagação dos sinais Wi-Fi, gerando variações detectáveis na amplitude e na fase do CSI ao longo do tempo [9]. Com a aplicação de técnicas de processamento de sinais, como filtros e transformadas no domínio do tempo e da frequência, tais alterações podem ser analisadas para estimar-se a frequência respiratória.

III. METODOLOGIA

Propõe-se um método de estimação da frequência respiratória baseado na análise da fase ou da magnitude do CSI. Os valores de CSI são extraídos de um link Wi-Fi (IEEE 802.11ax). O procedimento dividido em três etapas principais: captura do CSI, pré-processamento e seleção de subportadoras.

Com ênfase na seleção de subportadoras, propõe-se a junção de diferentes métricas, as quais foram empregadas isoladamente em trabalhos anteriores [4], [5], [6], para realizar-se a avaliação da relevância das subportadoras na representação do sinal respiratório. Tais métricas são: i) proporção de energia na faixa respiratória; ii) variância espectral na faixa respiratória; e iii) energia do sinal na banda de interesse.

Cada uma dessas métricas captura aspectos distintos do comportamento do sinal respiratório. Ao combiná-las, é possível selecionar subportadoras mais representativas, reforçando os componentes relacionados à respiração. Essa abordagem visa melhorar a robustez e a precisão da estimação em comparação com métodos que se baseiam em apenas uma métrica. Cada uma das etapas do método é descrita a seguir.

A. Captura do CSI

Para a captura do CSI, foram utilizadas duas placas de rede WiFi 6E Intel AX210, configuradas para transmitir sinais a uma taxa de 100 pacotes por segundo, frequência central

do canal de 6,025 GHz e largura de banda de 160 MHz. As capturas com extração de CSI foram feitas através do software PicoScenes [10] e tiveram duração de 30 segundos.

B. Pré-processamento

O pré-processamento é essencial para mitigar ruídos e imperfeições introduzidas pelo *hardware* ou pelo ambiente. Essa etapa é dividida em dois componentes principais:

1) *Calibração de Fase*: As medições de fase obtidas em dispositivos Wi-Fi comerciais (COTS) contêm erros causados por fatores como falta de sincronismo entre os osciladores dos transmissores e receptores, que se manifestam como desvios nas frequências de portadora (CFO) e de amostragem (SFO). Para corrigir tais desvios, aplica-se uma transformação linear que remove a tendência linear introduzida na fase do CSI. Ou seja, subtrai-se o *fit* linear da fase em função da frequência de subportadora a cada pacote recebido [11].

2) *Filtragem Temporal*: Após a calibração, são aplicados filtros para destacar os componentes do sinal associados à respiração. Utiliza-se o filtro de Hampel para remoção de *outliers* e, em seguida, duas janelas de média móvel: uma para eliminar variações de baixa frequência (componente passa-altas) e outra para suavizar ruídos de alta frequência (componente passa-baixas). O filtro passa-altas é implementado subtraindo-se o resultado da média móvel do sinal original. Juntas, essas janelas atuam como um filtro passa-faixa, isolando frequências típicas da respiração (entre 5 e 45 cpm).

C. Seleção de Subportadoras

Com os sinais filtrados, realiza-se uma análise espectral para identificar padrões respiratórios. Cada subportadora (por antena e por tipo de componente: magnitude ou fase) é transformada para o domínio da frequência por meio da Transformada Rápida de Fourier (FFT), aplicando uma janela de suavização Nuttall. Três métricas são então calculadas:

- **Proporção de energia na faixa respiratória** (c_1): representa a fração da energia espectral concentrada na banda de interesse (respiração), definida entre $f_{\min}$ e $f_{\max}$. Seja $S(f)$ o espectro de magnitude da subportadora, então:

$$c_1 = \frac{\sum_{f=f_{\min}}^{f_{\max}} |S(f)|^2}{\sum_{f=f_{\text{total}}} |S(f)|^2}. \quad (2)$$

- **Variância espectral na faixa respiratória** (c_2): avalia a dispersão da energia dentro da banda de respiração. Considerando μ como a média espectral dentro da faixa $[f_{\min}, f_{\max}]$, tem-se:

$$c_2 = \frac{1}{N} \sum_{f=f_{\min}}^{f_{\max}} (|S(f)| - \mu)^2. \quad (3)$$

- **Energia do sinal na banda de interesse** (c_3): mede a energia do sinal após remoção da média. Seja $x(t)$ o sinal da subportadora ao longo do tempo:

$$c_3 = \sqrt{\frac{1}{T} \sum_{t=1}^T (x(t) - \bar{x})^2}. \quad (4)$$




Fig. 1. Metodologia utilizada para estimação da respiração

Cada métrica é normalizada em relação ao valor máximo obtido entre todas as subportadoras analisadas, resultando em valores no intervalo $[0, 1]$. As subportadoras com valores acima de um determinado limiar de cada métrica são selecionadas. Em seguida, calcula-se um espectro médio ponderado para cada antena e tipo de dado (magnitude ou fase), combinando as subportadoras selecionadas. Por fim, soma-se o espectro combinado de todas as antenas, obtendo-se um espectro final, cuja frequência de pico dentro da faixa respiratória corresponde à frequência respiratória estimada.

IV. RESULTADOS

Para avaliar a eficácia do método proposto na estimação da frequência respiratória de mais de um indivíduo em um mesmo ambiente, foi realizada a análise de sinais contendo a atividade respiratória simultânea de duas pessoas. A partir do espectro final obtido após a junção das subportadoras selecionadas, foram identificados os dois maiores picos dentro da faixa respiratória (5–45 cpm), correspondendo às frequências estimadas para cada indivíduo.

A avaliação da acurácia foi feita comparando as estimativas com os valores reais de referência. Para isso, foram considerados os dois valores reais correspondentes às frequências respiratórias dos participantes (maior e menor valor), e os erros foram calculados subtraindo o maior valor real do maior valor estimado e subtraindo o menor valor real do menor valor estimado. Com isso foi feito a comparação utilizando as métricas isoladamente e utilizando a junção das métricas.

As Figuras 2 e 3 apresentam as funções de distribuição empírica acumulada (CDF) do erro absoluto na estimação da respiração, utilizando, respectivamente, os dados de magnitude e fase do CSI. Em cada figura, são exibidos dois subgráficos:

- **CDFs dos Erros Máximos:** representa o erro na estimação do indivíduo com a maior frequência respiratória.
- **CDFs dos Erros Mínimos:** detalha o erro na estimação do indivíduo com a menor frequência respiratória.

Dentro de cada subgráfico, as curvas coloridas comparam o desempenho da proposta baseada na junção das métricas com o uso das métricas individuais c1, c2 e c3. A linha tracejada horizontal indica a mediana dos erros para cada curva.

Na análise da magnitude do CSI (Figura 2), tanto para os erros máximos quanto mínimos, a abordagem de junção demonstrou um desempenho melhor que as outras métricas, em que concentrou-se a maioria dos erros em valores baixos, com mediana inferior a 1,5 cpm, indicando alta precisão. A métrica c1 ficou ligeiramente abaixo e as métricas c2 e c3 resultaram em erros um pouco mais elevados neste cenário.

Para a fase do CSI (Figura 3), a métrica c1 apresentou os menores erros, com destaque para os erros mínimos, onde sua mediana foi próxima de 1 cpm. A abordagem de junção seguiu com desempenho competitivo. Contudo, de forma geral, os




Fig. 2. CDF do erro de estimativa – magnitude.




Fig. 3. CDF do erro de estimativa – fase.

erros ao utilizar a fase foram maiores e mais dispersos em comparação com a magnitude, para as métricas avaliadas.

De modo geral, os resultados indicam que a magnitude do CSI proporcionou maior precisão na estimação da frequência respiratória. A abordagem de junção de métricas mostrou-se superior a todas as métricas isoladas.

REFERÊNCIAS

- [1] LIU, H. et al. Recent development of respiratory rate measurement technologies. *Physiological Measurement*, v. 40, n. 7, p. 07TR01, 2 ago. 2019.
- [2] MASSARONI, C. et al. Contactless Methods For Measuring Respiratory Rate: A Review. *IEEE Sensors Journal*, p. 1–1, 2020.
- [3] ABOAJEILA MILAD ASHLEIBTA et al. Non-Invasive RF Sensing for Detecting Breathing Abnormalities Using Software Defined Radios. *IEEE Sensors Journal*, v. 21, n. 4, p. 5111–5118, 15 fev. 2021.
- [4] WANG, X.; YANG, C.; MAO, S. PhaseBeat: Exploiting CSI Phase Data for Vital Sign Monitoring with Commodity WiFi Devices. 2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS), jun. 2017.
- [5] ZENG, Y. et al. FullBreathe. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, v. 2, n. 3, p. 1–19, 18 set. 2018.
- [6] LI, S. et al. ComplexBeat: Breathing Rate Estimation from Complex CSI. *arXiv (Cornell University)*, p. 217–222, 1 out. 2021.
- [7] PATIL, P. et al. A Review on MIMO OFDM Technology Basics and More. Disponível em: <<https://ieeexplore.ieee.org/document/8455114>>.
- [8] MA, Y.; ZHOU, G.; WANG, S. WiFi Sensing with Channel State Information. *ACM Computing Surveys*, v. 52, n. 3, p. 1–36, 27 jul. 2019.
- [9] OSSI KALTIOKALLIO et al. Non-invasive respiration rate monitoring using a single COTS TX-RX pair. *CiteSeer X (The Pennsylvania State University)*, 1 abr. 2014.
- [10] JIANG, Z. et al. Eliminating the Barriers: Demystifying Wi-Fi Baseband Design and Introducing the PicoScenes Wi-Fi Sensing Platform. Disponível em: <<https://arxiv.org/abs/2010.10233>>.
- [11] WANG, X.; GAO, L.; MAO, S. CSI Phase Fingerprinting for Indoor Localization With a Deep Learning Approach. *IEEE Internet of Things Journal*, v. 3, n. 6, p. 1113–1123, dez. 2016.