

Reconhecimento de Atividade Humana Usando Sinais de Redes Wi-Fi

Egberto Caballero, Iandra Galdino, Julio C. H. Soto, Taiane C. Ramos
Raphael Guerra, Débora Muchaluat-Saade, Célio Albuquerque

¹Laboratório MidiaCom, Instituto de computação
Universidade Federal Fluminense (UFF)– Niteroi – RJ – Brazil

{egbertocr, igaldino, jsoto, taiane, debora, celio}@mediacom.uff.br

rrguerra@ic.uff.br

Abstract. *Wi-Fi signals were originally developed with a focus on communication. However, beyond communication applications, Wi-Fi signals have recently been studied as a possible powerful tool for human sensing applications. In this sense, in this paper, we present an original approach for obtaining human activity recognition (HAR) through the use of commercial Wi-Fi devices. Using our proposal, it is possible to infer the position of a monitored person in an indoor environment. To achieve this, we process the channel state information (CSI) data collected from the Wi-Fi channel. We selected and evaluated five different classification algorithms to infer the position of subjects and compare their performance. The proposed method was evaluated on a dataset of CSI signals collected from 125 participants.*

Resumo. *Os sinais de Wi-Fi foram originalmente desenvolvidos com foco em comunicação. No entanto, os sinais Wi-Fi têm sido avaliados como ferramenta para sensoriamento humano. Nesse sentido, neste artigo apresenta uma proposta para reconhecimento de atividade humana (HAR - Human Activity Recognition) utilizando dispositivos Wi-Fi. Com essa proposta, é possível inferir a posição de uma pessoa monitorada em um ambiente interno. Para isso, o sinal Wi-Fi que contém a Informação do Estado do Canal (CSI) é processado. Foram selecionados e avaliados cinco algoritmos de classificação diferentes para inferir a posição dos indivíduos e comparar o desempenho. O método proposto foi avaliado em um conjunto de dados de sinais CSI coletados de 125 participantes.*

1. Introdução

É consenso que a população mundial está envelhecendo, tornando a demanda por monitoramento de saúde mais urgente. Desta forma, o monitoramento de pessoas idosas ou fisicamente debilitadas durante o desenvolvimento de atividades básicas em casa, como dormir e sentar, tem despertado grande interesse, principalmente quando se discute tecnologias de inteligência ambiental.

Um dos tópicos mais proeminentes em relação às tecnologias de casa inteligente é o sensoriamento humano. Existem inúmeras aplicações que podem utilizar o sensoriamento humano para monitorar condições das pessoas, como detecção de quedas, monitoramento de sinais vitais, detecção de identidade e reconhecimento de atividades humanas

(HAR - *Human Activity Recognition*), por exemplo. Sistemas HAR geralmente podem utilizar tecnologias baseadas em visão computacional [Kim et al. 2019, Beddiar et al. 2020], tecnologias baseadas em sensores vestíveis [Uddin et al. 2020, Wang et al. 2019], ou radiofrequência [Hsieh et al. 2020, Wang et al. 2017].

Sistemas baseados em visão computacional têm sua aplicação limitada e necessitam de visada direta (LoS - *Line-of-Sight*) do ambiente, sem mencionar que os usuários geralmente os desaprovam devido a preocupações com privacidade. Além disso, seu desempenho pode variar em diferentes condições de iluminação. Tecnologias HAR baseadas em sensores são menos amigáveis ao usuário, já que exigem que os usuários carreguem ou usem sensores, o que pode ser desconfortável ou desagradável, especialmente para idosos e pessoas com deficiência física [Loncar-Turukalo et al. 2019].

Recentemente, muitos estudos têm mostrado que os sinais de Wi-Fi podem detectar comportamentos humanos devido à interferência do corpo humano na propagação do sinal [Soto et al. 2022]. A utilização da Informação do Estado do Canal (CSI - *Channel State Information*) proveniente do sinal Wi-Fi [Ma et al. 2019], que representa como os sinais sem fio se propagam do transmissor para o receptor, é uma tecnologia promissora para a detecção de presença humana e uma alternativa à vigilância por vídeo e às tecnologias baseadas em sensores. Sistemas HAR baseados em dados CSI de dispositivos Wi-Fi (Wi-Fi CSI) podem aproveitar a ampla implantação de dispositivos Wi-Fi comerciais e a ubiquidade dos sinais de Wi-Fi.

Este artigo propõe uma metodologia HAR baseada em Wi-Fi CSI capaz de identificar quando um indivíduo está estático em posições como: em pé, sentado e deitado; ou quando está em movimento realizando atividades como: andando, correndo e varrendo e em ambientes indoor. Para tanto utilizamos um conjunto de dados de sinais CSI coletados de diversos participantes da base de dados eHealth CSI [Galdino et al. 2023], disponível para a comunidade científica. Os resultados obtidos apresentam o algoritmo Random Forest com o melhor desempenho, alcançando uma acurácia do 99% para todas as atividades consideradas.

As principais contribuições deste trabalho podem ser resumidas da seguinte forma:

- Proposição de uma metodologia simplificada de Reconhecimento de Atividade Humana (HAR) baseado em Wi-Fi CSI.
- Realização de uma análise sobre uma grande quantidade de dados coletados, em comparação com trabalhos relacionados encontrados na literatura.
- Comparação de cinco algoritmos de classificação de aprendizado de máquina (ML) para avaliar o desempenho da metodologia proposta para o reconhecimento de atividade humana.

O restante do artigo está estruturado da seguinte forma. A Seção 2 fornece uma visão geral sobre dados CSI. A Seção 3 apresenta uma revisão de trabalhos relacionados relevantes. A coleta de dados, etapas de processamento, treinamento dos modelos e o reconhecimento de atividades humanas da metodologia proposta são descritas na Seção 4. Na Seção 5, os resultados de desempenho obtidos por diferentes algoritmos de aprendizado de máquina são discutidos. Por fim, a Seção 6 traz as considerações finais e aponta direções para trabalhos futuros.

2. CSI

As propriedades básicas do canal de comunicação Wi-Fi podem ser representadas pelos dados CSI. Os dados CSI descrevem como um sinal é modificado enquanto se propaga do transmissor até o receptor. Essas modificações representam o efeito combinado de, por exemplo, dispersão devido a múltiplos caminhos, desvanecimento, decaimento de potência com a distância, etc.

Na especificação IEEE 802.11ax [IEEE 802.11 Working Group 2021], a camada física das redes Wi-Fi utiliza a técnica de multiplexação por divisão de frequência ortogonal (OFDM) para as faixas de frequência de 2.4 GHz e 5 GHz. OFDM é uma técnica de modulação que divide a largura de banda disponível em vários subcanais ortogonais [Weinstein and Ebert 1971]. Ao fazer isso, as informações podem ser transmitidas de forma independente em diferentes símbolos OFDM. As características do OFDM o tornam uma boa solução para canais de múltiplos caminhos e também para sistemas de Múltiplas Entradas e Múltiplas Saídas (MIMO - *Multiple Input Multiple Output*) [Lee et al. 2018]. Além disso, uma vez que a transmissão em cada subportadora é ortogonal e independente, cada subportadora pode ser vista como um sensor capaz de coletar dados CSI.

Para capturar os dados CSI, o transmissor Wi-Fi envia Campos de Treinamento Longo (LTFs - *Long Training Fields*), que contêm informações predefinidas em cada subportadora, no preâmbulo do quadro. O receptor Wi-Fi estima o CSI usando o sinal recebido e os LTFs predefinidos. A quantidade de dados coletados depende da largura de banda do canal, que determina o número de subportadoras, e do número de antenas utilizadas.

Considerando um sistema Wi-Fi MIMO operando sob a especificação IEEE 802.11n, e com P antenas de transmissão e Q antenas de recepção, o sinal que contém os dados CSI estimado de cada fluxo de dados pode ser expresso matematicamente da seguinte forma

$$h_{p,q} = |h|e^{j\theta}, \quad (1)$$

onde $h_{p,q}$ representa a CSI entre a p -ésima antena de transmissão e a q -ésima antena de recepção; $|h|$ é o módulo do sinal CSI e está relacionada à atenuação do sinal na propagação pelo canal sem fio; $e^{j\theta}$ representa a fase do sinal CSI e está relacionada com as mudanças de fase do sinal na propagação pelo canal sem fio.

Uma vez que na modulação OFDM o canal é dividido em um número de subportadoras, a representação do sinal recebido se tornará um vetor. Por exemplo, seja c o número de subportadoras, então a informação do estado do canal estabelecido entre um par de antenas (p, q) pode ser representada matematicamente por um vetor com c elementos. Assim, temos:

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

Os dados de CSI podem ser utilizados para fornecer informações sobre o ambiente e estimar mudanças e fenômenos que ocorrem ao longo do tempo, como detecção de presença humana, movimentos do corpo e até mesmo sinais vitais.

3. Revisão da literatura

O Reconhecimento de Atividade Humana baseado em Wi-Fi CSI tem despertado grande interesse nos últimos anos. Como resultado, na literatura podem se encontrar vários estudos nessa área. Esta seção revisa os trabalhos mais recentes encontrados na literatura relacionados a sistemas de HAR baseados em Wi-Fi CSI.

Wang et al. [Wang et al. 2016] desenvolveram um sistema chamado Wi-Fall principalmente para detectar quedas usando dados de Wi-Fi CSI. Eles analisaram diferentes atividades realizadas em três locais diferentes: uma câmara, um laboratório e um dormitório. Os dados foram coletados usando três antenas de transmissão e três antenas de recepção. Como os três primeiros autovalores da matriz de decomposição de valor singular (SVD) descrevem a maioria das características de toda a matriz, eles foram usados para a classificação. Dois algoritmos de classificação diferentes foram usados, e uma máquina de vetores de suporte (SVM) de classe única foi utilizada para detectar quedas. Além disso, para detectar outras atividades além das quedas, foi utilizado o algoritmo Random Forest (RF).

Ding et al. [Ding and Wang 2019] sugeriram o uso de uma Rede Neural Recorrente Profunda (DRNN) para identificar posições humanas. A ideia era extrair características para o treinamento da RNN e reconhecer a atividade. Duas características foram extraídas, a saber, a variação de potência do canal no domínio do tempo e a análise tempo-frequência no domínio da frequência. Em seguida, um modelo LSTM (Memória Longa de Curto Prazo) treinado com características extraídas é usado para reconhecer uma atividade.

Outro sistema de HAR baseado em Wi-Fi CSI, chamado Wi-Motion, foi proposto em [Li et al. 2019], que pode reconhecer sensivelmente 5 atividades humanas pré-definidas. Eles utilizaram conjuntamente as informações de amplitude e fase da sequência de CSI coletada com dispositivos Wi-Fi com três antenas. O algoritmo SVM também foi usado para construir dois classificadores de acordo com informações de amplitude e fase. Quando uma amostra de atividade desconhecida é coletada, consultando os resultados de previsão de ambos os classificadores, o Wi-Motion realiza um método de fusão baseado na probabilidade posterior para produzir o reconhecimento final.

Recentemente, Redes Neurais Convolucionais (CNNs) também foram aplicadas junto com LSTM bidirecional (Bi-LSTM) para a classificação de atividades humanas, incluindo detecção de quedas [Sheng et al. 2020]. Também, em [Forbes et al. 2020], é apresentada uma proposta de HAR que utiliza um Raspberry Pi e firmware Nexmon para extrair os dados CSI a serem usados no reconhecimento de atividades. O único passo de pré-processamento realizado nesse trabalho foi um filtro passa-baixa. Adicionalmente, um modelo de classificação DeepConvLSTM foi implementado em Python usando a API Keras de aprendizado profundo.

Outro trabalho focado no HAR em cenários indoor de LoS foi publicado em [Schäfer et al. 2021]. Nesse trabalho também foi usado o Nexmon na coleta de dados CSI. As atividades foram classificadas aplicando algoritmos de ML, SVM e LSTM. Outliers foram removidos usando o filtro de Hampel, em seguida, a Transformada Discreta de Wavelet (DWT) foi aplicada para limpar o sinal e Análise de componentes principais (PCA) para reduzir a dimensão da informação. Características foram extraídas dos dados pré-processados para usar em SVM e LSTM para classificar as atividades.

Bocus et al. [Bocus et al. 2021] analisaram o reconhecimento de posição humana usando a tecnologia Ultra-Wideband (UWB). Eles apresentaram as técnicas e abordaram a viabilidade de usar sinais UWB. Eles extraíram Respostas de Impulso de Canal (CIRs) de alta resolução de módulos UWB e as usaram como características em algoritmos de ML para classificar diferentes atividades humanas. Eles também compararam o desempenho da classificação de atividades usando CSI de Wi-Fi de alta granularidade no mesmo layout físico.

Yang et al. [Yang et al. 2021] exploraram três questões para o reconhecimento de atividades humanas: (i) com base na sensibilidade de diferentes antenas às ações, foi proposta uma abordagem de seleção ativa de antenas para reduzir a quantidade de dados necessários para análise; (ii) duas abordagens de aprimoramento de sinal foram apresentadas para fortalecer o intervalo de sinais ativos e enfraquecer o impacto de sinais inativos; e, finalmente, (iii) um algoritmo de segmentação de atividade foi fornecido para detectar os tempos de início e fim de uma atividade, o que pode eliminar sinais inativos e reter o intervalo de sinal ativo.

Muaaz et al. [Muaaz et al. 2022] usaram uma CNN para reconhecer atividades a partir de impressões digitais micro-Doppler variantes no tempo independentes do ambiente, extraídas dos dados de Wi-Fi CSI. Eles também usaram informações de amplitude e fase dos dados CSI. Primeiro, processaram os dados de CSI para remover o ruído. Depois, foram usados para calcular o espectrograma correspondente a diferentes atividades humanas. Os espectrogramas foram armazenados como imagens em formato PNG e usados para treinar uma CNN profunda. A CNN utilizada foi capaz de extrair automaticamente características discriminativas das imagens PNG e classificar atividades humanas.

Uma abordagem recente foi proposta com base no efeito Doppler [Meneghello et al. 2022]. Primeiramente, uma limpeza original de fase foi realizada para extrair rastros micro-Doppler dos dados CSI. O deslocamento Doppler revela as velocidades dos pontos de dispersão durante os eventos de transmissão e não é afetado por objetos estáticos, permitindo a medição das características dinâmicas da posição humana. Os rastros micro-Doppler foram utilizados como entrada para uma arquitetura de rede neural treinada para reconhecer as atividades de interesse. É importante observar que esse trabalho focou no reconhecimento de atividades dinâmicas. A identificação de atividades estáticas, como sentar e deitar, estava fora do escopo desse trabalho.

Esses trabalhos encontrados na literatura demonstram a sensibilidade dos dados CSI a pequenos movimentos corporais, permitindo a identificação de atividades realizadas por pessoas. No entanto, esses trabalhos apresentam propostas em ambientes controlados e com um número limitado de pessoas. Como diferença, nosso trabalho considera o reconhecimento de atividade humana usando um conjunto de dados com informações coletadas de mais de 125 pessoas, formando um grupo muito heterogêneo, com diferentes idades, gêneros e características físicas. Com base nos trabalhos existentes, este artigo propõe uma abordagem simplificada para identificar a posição e/ou movimento humano com base nas informações CSI. Além disso, a metodologia proposta foi avaliada com uma grande quantidade de dados coletados disponíveis no conjunto de dados eHealth CSI. Em [Galdino et al. 2023], podem ser encontrados mais detalhes sobre o processo de coleta de dados utilizados e a construção da base de dados eHealth CSI.

4. Metodologia Proposta

Antes do reconhecimento da atividade, é necessário tratar o sinal coletado para permitir seu uso em algoritmos de Aprendizado de Máquina (ML) para o HAR. Esta seção descreve os passos da metodologia proposta para o reconhecimento da atividade. O diagrama de blocos apresentado na Figura 1, descreve a metodologia proposta para o treinamento dos modelos. Então, os modelos treinados são utilizados no reconhecimento de atividades conforme apresentado na Figura 2. A seguir, cada etapa da metodologia proposta é descrita, tanto na fase de treinamento quanto de teste.

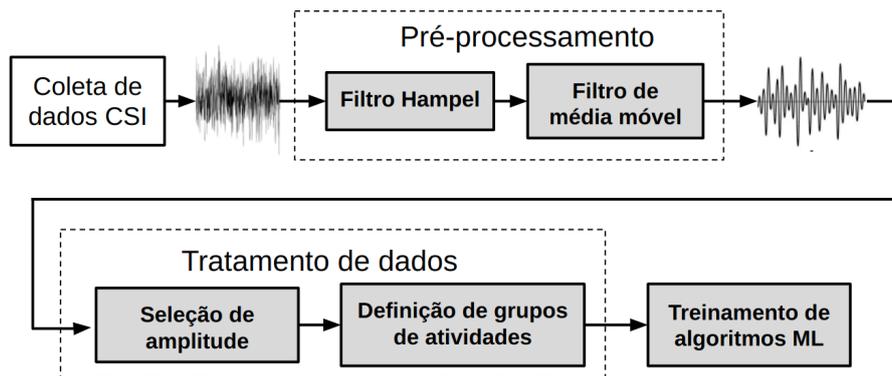


Figura 1. Diagrama em blocos da metodologia proposta para o treinamento dos modelos.

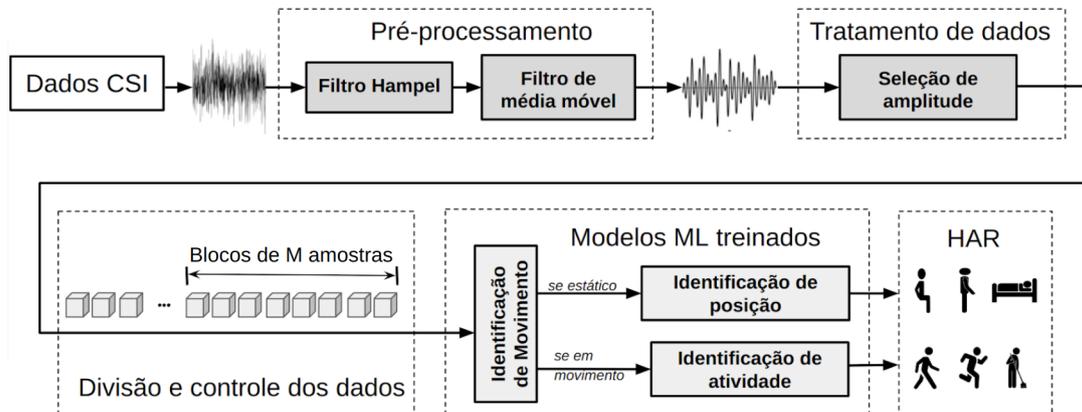


Figura 2. Diagrama em blocos da metodologia proposta para o HAR.

4.1. Coleta de dados CSI

Para a aquisição de dados, utilizamos o firmware NEXMON [Gringoli et al. 2019]. Este firmware opera em um Raspberry Pi 4B. O NEXMON modifica o firmware da placa sem fio do Raspberry e permite a captura de dados CSI em uma transmissão sem fio entre dois dispositivos em uma rede Wi-Fi. A coleta de dados foi realizada em um ambiente comum, sem isolamento eletromagnético. Utilizamos uma rede Wi-Fi tradicional para recriar um ambiente o mais realístico possível.

A Figura 3(a) mostra o cenário de coleta de dados. A rede Wi-Fi foi configurada na faixa de frequência de 5 GHz, usando um canal com largura de banda de 80 MHz.

Como o Wi-Fi faz uso da tecnologia OFDM, com a configuração utilizada, obtêm-se dados CSI de 234 subportadoras em cada coleta, após descartar as subportadoras piloto e nulas. A duração de cada coleta em cada posição foi de 60 segundos por participante, obtendo 500 amostras com 234 subportadoras em cada coleta. Mais informações sobre a funcionalidade do NEXMON e outros firmwares podem ser encontradas em [Soto et al. 2022].

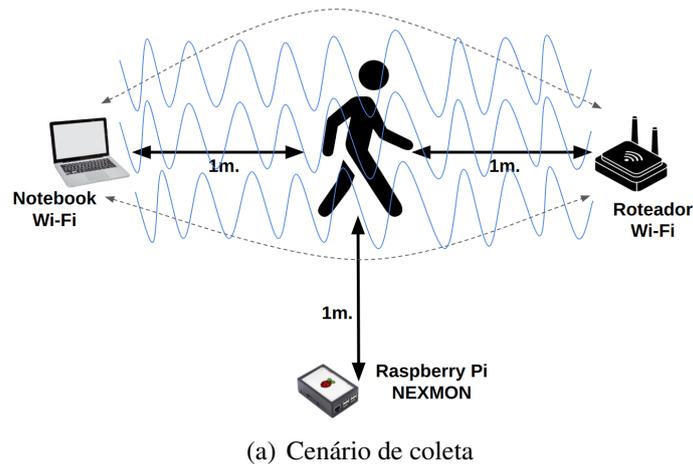


Figura 3. (a) Cenário de coleta de dados. (b) Posições estáticas e atividades em movimento usadas no conjunto de dados.

4.2. Pré-processamento do sinal

Na etapa de pré-processamento dos dados CSI, foram utilizadas técnicas para limpar o sinal de fatores externos. Esses fatores perturbam o sinal, tornando-o mais difícil de interpretar. Após a coleta dos dados, eles passam primeiro por um filtro Hampel, que remove ruídos do sinal. O filtro Hampel utiliza uma janela deslizante de 30 e 3 desvios padrão. Os dados então passam por outro filtro de Média Móvel, eliminando outliers e suavizando o sinal. O filtro de Média Móvel utiliza uma janela deslizante de tamanho 10. Esses parâmetros foram definidos com base na literatura. Com esses dois procedimentos, garante-se a limpeza dos sinais coletados por cada subportadora e que estão prontos para o tratamento de dados.

4.3. Tratamento dos dados

Neste trabalho foi utilizado o conjunto de dados eHealth CSI, detalhado em trabalho anterior [Galdino et al. 2023]. O conjunto de dados contém as posições estáticas sentado, em pé e deitado, bem como atividades em movimento, como andar, correr e varrer, de mais de 125 pessoas, com diferentes idades, gêneros, pesos e alturas.

Na etapa de tratamento de dados, foram utilizados como entrada os dados CSI limpos da etapa de pré-processamento. Primeiramente, utilizou-se a amplitude do sinal de cada subportadora. Em seguida, foram criados três conjuntos de dados que serão utilizados posteriormente no treinamento de modelos de ML. O primeiro grupo de dados é formado por posições estáticas: sentado, em pé, deitado; o segundo é formado por atividades em movimento como: caminhar, correr e varrer. Um terceiro grupo é formado tanto por posições estáticas quanto atividades em movimento.

No conjunto de dados eHealth CSI, as coletas são realizadas em 17 posições diferentes de cada participante. Cada coleta das diferentes atividades contém 500 amostras. Dentre essas, há diferentes atividades realizadas na posição sentada, em pé e deitada. Portanto, para formar o grupo de posições sentadas, foram consideradas as posições em que o participante está sentado de frente e sentado de costas para o dispositivo de coleta. Para formar o grupo de posições em pé, também foram consideradas as posições em que o participante está de frente e de costas para o dispositivo de coleta. Para o grupo de posição deitada, foram consideradas as posições deitadas de costas e de bruços. Dessa forma, foi obtido um conjunto de dados com diferentes variações para cada tipo de posição, mais próximo de um cenário real. Portanto, cada participante possui 6 atividades, como mostrado na Figura 3(b).

4.4. Treinamento dos algoritmos

Uma vez que os dados de amplitude do sinal CSI são classificados em grupos de atividades, eles foram analisados com cinco algoritmos de Aprendizado de Máquina (ML) diferentes para realizar o treinamento de cada modelo. Durante o treinamento, cada modelo ajusta seus parâmetros para minimizar a diferença entre as previsões do modelo e os rótulos reais. Os algoritmos usados são: Random Forest (RF), Máquina de Vetores de Suporte (SVM), Árvore de Decisão J48 (DT-J48), Perceptron de Múltiplas Camadas (MLP) e Naive Bayes Gaussiano (GNB). Na análises da proposta foi utilizada a biblioteca scikit-learn da linguagem Python.

O modelo usando RF, foi gerado usando 100 estimadores; "gini" como critério para avaliar a qualidade de uma divisão. Para SVM foi especificado um kernel linear. Para o classificador DT-J48 foi usado a "Entropia" como a função para medir a qualidade de uma divisão. A profundidade máxima da árvore de decisão foi definida como 10. Para MLP o número máximo de iterações durante o treinamento foi especificada em 500 iterações; e como função de ativação para as camadas ocultas foi usada a função "relu".

Por sua parte o classificador GNB não possui hiperparâmetros para ajuste. Ele é uma implementação simples do classificador Naive Bayes, que assume uma distribuição gaussiana (normal) para cada classe. Portanto, na biblioteca scikit-learn, não há parâmetros para configurar ao criar uma instância do GNB. Ele usa os valores padrão internos para realizar a classificação com base na distribuição gaussiana dos dados de treinamento.

Para cada algoritmo de ML analisado, foram treinados três modelos: um modelo binário para a identificação de movimento e dois modelos de múltiplas classes para o reconhecimento de posições estáticas e atividade em movimento. Os conjuntos de dados correspondentes a cada tipo de atividade são gerados de forma a garantir o uso de conjuntos de dados balanceados para a classificação.

4.5. Reconhecimento de atividade

Uma vez que os modelos foram treinados, estes são usados para o reconhecimento de atividade humana. Segundo apresentado na Figura 2, após o pre-processamento dos dados CSI; estes passam por um bloco de divisão e controle de dados. Nesse bloco, é aplicada uma divisão dos dados em blocos de tamanho M .

Assim, são entregues blocos de M amostras de amplitude para o modelo binário encarregado de identificar se a pessoa está em movimento ou não. Seguidamente, se a pessoa está em movimento, o bloco de M amostras é passado como entrada no modelo multiclasse treinado para o reconhecimento de atividades em movimento; ou em caso contrário, o bloco de M amostras é passado como entrada no modelo multiclasse treinado para o reconhecimento de posições estáticas. Dessa forma, pode ser reconhecida a atividade realizada pela pessoa.

Em cada um dos modelos, a classificação é realizada sequencialmente sobre os dados de cada bloco. Os dados de cada bloco são avaliados individualmente e atribuído como rótulo da amostra o rótulo que foi atribuído mais vezes na classificação dos dados de cada bloco.

5. Resultados obtidos

Na análise, foi realizada uma classificação para identificar se a pessoa está em movimento ou estática. Além disso, foi analisada a classificação para as posições de ficar em pé, sentar e deitar; e para as atividades de caminhar, correr e varrer, isso usando a metodologia apresentada na Seção 4. Para cada caso foram usados os respectivos conjunto de dados mencionados na Seção 4.3.

Como features para a classificação foi usada a amplitude do sinal CSI, tendo um total de 234 features, que correspondem ao número de subportadoras para a configuração da rede Wi-Fi usada. 70% dos dados foram utilizados para treinamento e 30% para teste. Como métrica de avaliação, foi considerada a acurácia, para analisar o desempenho de cada classificador.

A proposta foi avaliada usando os dados de 125 pessoas. Para avaliar a confiabilidade dos resultados, cada classificação foi realizada 30 vezes para cada pessoa, e em cada rodada foram escolhidos aleatoriamente diferentes conjuntos de treinamento e teste. Resultando um total de 3750 rodadas para cada classificação. Foi gerado um modelo para cada pessoa, e calculada a média dos 125 modelos gerados com um intervalo de confiança de 95%.

Em [Caballero et al. 2023] foi apresentado um estudo prévio que mostra que, para nosso conjunto de dados, as classificações binárias obtêm melhor desempenho que as classificações de múltiplas classes. Além disso, o aumento do número de classes em uma classificação de múltiplas classes, diminui o desempenho das métricas de avaliação. Por exemplo, na classificação multiclasse de 6 atividades (ficar em pé, sentar, deitar, caminhar, correr e varrer), o algoritmo Random Forest apresentou a melhor classificação, atingindo uma acurácia de 86,65% e uma precisão entre 85,68% e 88,35% para cada classe. No entanto a classificação binária atinge acurácia entre 90% e 94% dependendo da classe.

Com base nesses resultados e com o objetivo de melhorar os resultados da classificação, a metodologia proposta na Figura 2 considera primeiramente realizar uma

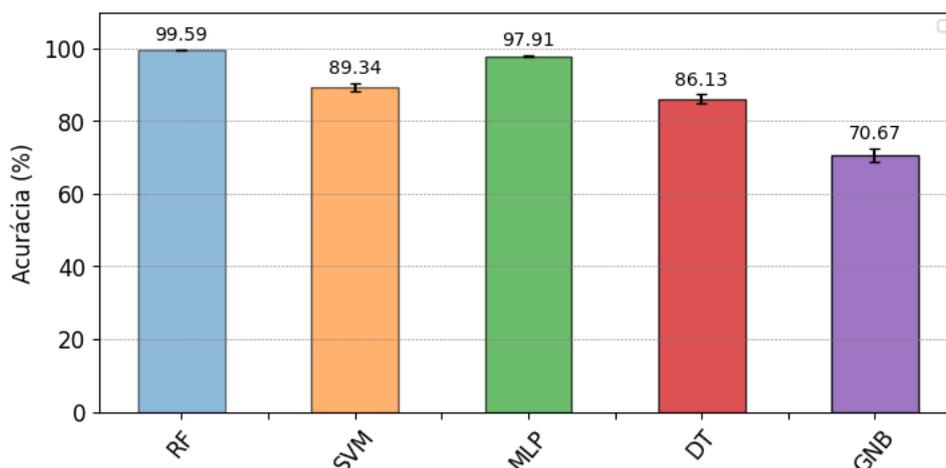


Figura 4. Acurácia da classificação movimento vs estático.

classificação binária para identificar se a pessoa está em movimento ou não e depois identificar que tipo de atividade está realizando. Isso conjuntamente com um sistema de votação, que divide o dados da entrada em blocos; estes são avaliados individualmente e atribuí como rótulo da amostra o rótulo que foi atribuído mais vezes na classificação dos dados de cada bloco. Para a classificação são usados blocos de dados de tamanho $M=9$ que corresponde com o número de amostras por um segundo.

Seguindo essa ideia, para avaliar o desempenho da proposta primeiramente foi realizada a classificação binária, desta vez considerando posições estáticas e atividade em movimento. Para este cenário, o grupo de atividades em movimento foi formado por coletas de cada pessoa caminhando, correndo e varrendo, e o grupo de posições estáticas contém uma mistura de posições sentadas, em pé e deitadas. A Figura 4 mostra os resultados alcançados para este cenário. O melhor desempenho é alcançado pelo Random Forest, atingindo uma acurácia de 99,59%.

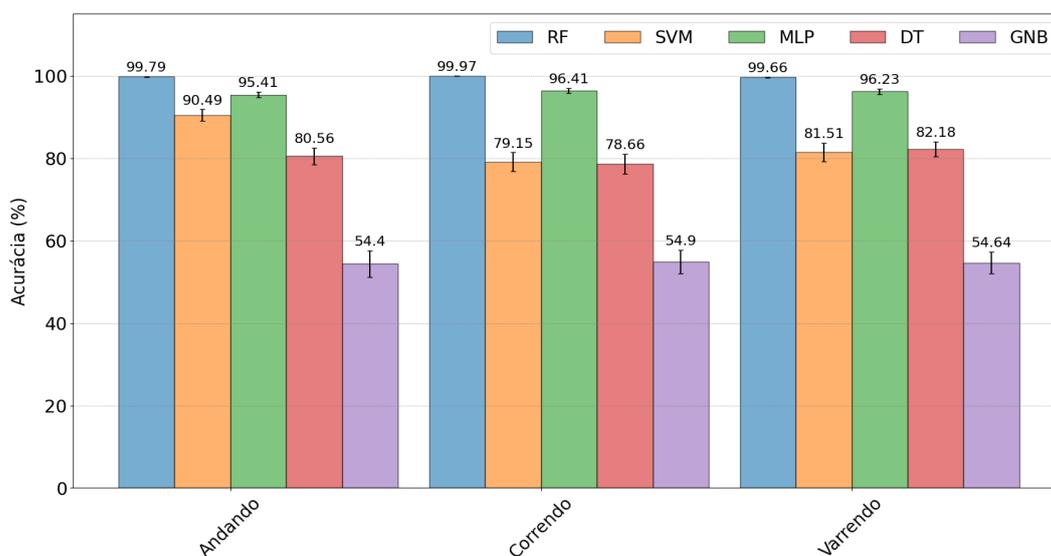


Figura 5. Acurácia para classificação multiclasse de atividades em movimento.

A Figura 5 apresenta os valores de acurácia obtidos para a classificação das atividades de movimento: andando, correndo e varrendo. O algoritmo Random Forest, foi identificado como o melhor classificador; e pode-se observar que, em todos os casos, a acurácia alcança valores superiores a 99%. É interessante notar que a classificação do indivíduo correndo atingiu a maior acurácia, 99,97%.

Foi analisada também a classificação das posições estáticas: sentado, em pé e deitado. Na Figura 6, a classificação atingiu acurácia superior a 99% em todos os casos. Por sua vez, a classificação da posição deitado alcançou a maior acurácia, com 99,94%.

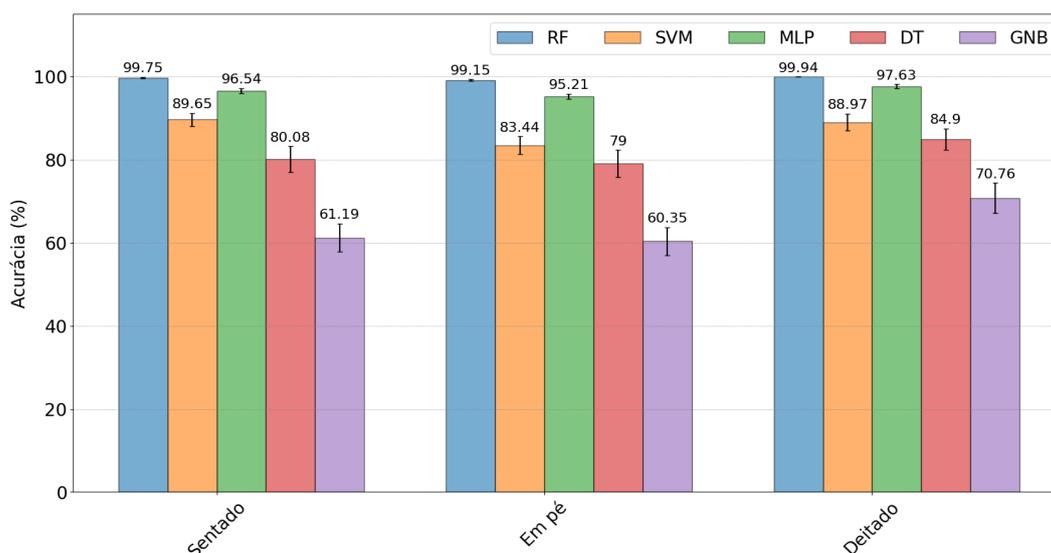


Figura 6. Acurácia para classificação multiclasse de posições estáticas.

Ao que percebemos, os melhores resultados são alcançados na identificação das posições correndo e deitado, o que já era de se esperar comparando aos resultados iniciais obtidos em [Caballero et al. 2023]. Em particular, na classificação da posição deitado, a acurácia foi de quase 100%. Isso se deve à maior diferença nas posições horizontal e vertical do corpo, o que influencia na propagação das ondas de rádio no ambiente e, consequentemente, se reflete nos dados CSI coletados.

6. Conclusões

Este trabalho propôs uma metodologia baseada na análise de dados CSI e modelos de aprendizado de máquina para reconhecer posições e atividades de uma determinada pessoa em um ambiente indoor. Para tanto, a técnica de divisão dos dados e o sistema de votação usado na classificação se mostrou essencial no aprimoramento dos resultados obtidos. Isso é especialmente relevante em cenários nos quais uma pessoa em isolamento precisa ser monitorada remotamente. A proposta apresentada foi avaliada usando o conjunto de dados da base eHealth CSI considerando 125 pessoas, de diferentes idades, gêneros, pesos e alturas. Os resultados consolidam o algoritmo Random Forest como o melhor classificador para esta aplicação, obtendo a maior acurácia, com resultados superiores a 99%.

Os resultados para classificação multiclasse mostram que, para atividades nas quais as pessoas realizam mais movimentos corporais, o Random Forest alcança a me-

lhor acurácia, com 99,97% para correr e 99,79% para andar. Além disso, os resultados mostraram que a disposição horizontal ou vertical do corpo influencia a propagação das ondas de rádio de maneira diferente e isso se reflete nos dados CSI coletados, permitindo melhores resultados de classificação para a posição deitada. A proposta apresentada neste trabalho alcança um aumento de mais de 10% na acurácia dependendo do tipo de atividade, quando comparada com os resultados preliminares obtidos em trabalhos anteriores. E para todas as posições analisadas, a acurácia mostra valores superiores a 99%.

Como trabalho futuro, é interessante considerar novas características extraídas do sinal CSI, que podem melhorar o desempenho do modelo de ML para o reconhecimento de atividades. Além disso, pretende-se considerar outras atividades mais complexas, assim como a transição entre atividades.

Referências

- Beddiar, D. R., Nini, B., Sabokrou, M., and Hadid, A. (2020). Vision-based human activity recognition: a survey. *Multimedia Tools and Applications*, 79(41-42):30509–30555.
- Bocus, M., Piechocki, R., and Chetty, K. (2021). A Comparison of UWB CIR and WiFi CSI for Human Activity Recognition. In *Proceedings of the IEEE Radar Conference (RadarCon)*. IEEE Radar Conference (RadarCon).
- Caballero, E., Galdino, I., Soto, J. C., Ramos, T., Guerra, R., Muchalut-Saade, D., and Albuquerque, C. (2023). Human activity recognition using wi-fi csi. In *Proceedings of the 17th EAI International Conference on Pervasive Computing Technologies for Healthcare*.
- Ding, J. and Wang, Y. (2019). WiFi CSI-based human activity recognition using deep recurrent neural network. *IEEE Access*, 7:174257–174269.
- Forbes, G., Massie, S., and Craw, S. (2020). Wifi-based human activity recognition using Raspberry Pi. In *2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI)*, pages 722–730. IEEE.
- Galdino, I., Soto, J. C., Caballero, E., Ferreira, V., Ramos, T. C., Muchalut-Saade, D., and Albuquerque, C. (2023). eHealth CSI: A Wi-Fi CSI dataset of human activities. *IEEE Access*.
- Gringoli, F., Schulz, M., Link, J., and Hollick, M. (2019). Free your csi: A channel state information extraction platform for modern wi-fi chipsets. In *Proceedings of the 13th International Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization, WiNTECH '19*, page 21–28, New York, NY, USA. Association for Computing Machinery.
- Hsieh, C.-F., Chen, Y.-C., Hsieh, C.-Y., and Ku, M.-L. (2020). Device-free indoor human activity recognition using wi-fi rssi: Machine learning approaches. In *2020 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-Taiwan)*, pages 1–2. IEEE.
- IEEE 802.11 Working Group (2021). Ieee 802.11ax-2021 - ieee standard for information technology–telecommunications and information exchange between systems local and metropolitan area networks–specific requirements part 11: Wireless lan medium access

control (mac) and physical layer (phy) specifications amendment 1: Enhancements for high-efficiency wlan. Technical report, IEEE.

- Kim, K., Jalal, A., and Mahmood, M. (2019). Vision-based human activity recognition system using depth silhouettes: A smart home system for monitoring the residents. *Journal of Electrical Engineering & Technology*, 14:2567–2573.
- 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, 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.
- Loncar-Turukalo, T., Zdravevski, E., da Silva, J. M., Chouvarda, I., Trajkovik, V., et al. (2019). Literature on wearable technology for connected health: scoping review of research trends, advances, and barriers. *Journal of medical Internet research*, 21(9):e14017.
- Ma, Y., Zhou, G., and Wang, S. (2019). Wifi sensing with channel state information: A survey. *ACM Computing Surveys (CSUR)*, 52(3):1–36.
- Meneghello, F., Garlisi, D., Dal Fabbro, N., Tinnirello, I., and Rossi, M. (2022). SHARP: Environment and Person Independent Activity Recognition with Commodity IEEE 802.11 Access Points. *IEEE Transactions on Mobile Computing*.
- Muaaz, M., Chelli, A., Gerdes, M. W., and Pätzold, M. (2022). Wi-Sense: A passive human activity recognition system using Wi-Fi and convolutional neural network and its integration in health information systems. *Annals of Telecommunications*, 77(3-4):163–175.
- Schäfer, J., Barrsiwal, B. R., Kokhharova, M., Adil, H., and Liebehenschel, J. (2021). Human activity recognition using CSI information with nexmon. *Applied Sciences*, 11(19):8860.
- Sheng, B., Xiao, F., Sha, L., and Sun, L. (2020). Deep spatial–temporal model based cross-scene action recognition using commodity WiFi. *IEEE Internet of Things Journal*, 7(4):3592–3601.
- Soto, J. C., Galdino, I., Caballero, E., Ferreira, V., Muchaluat-Saade, D., and Albuquerque, C. (2022). A survey on vital signs monitoring based on wi-fi csi data. *Computer Communications*, 195:99–110.
- Uddin, M. Z., Hassan, M. M., Alsanad, A., and Savaglio, C. (2020). A body sensor data fusion and deep recurrent neural network-based behavior recognition approach for robust healthcare. *Information Fusion*, 55:105–115.
- Wang, W., Liu, A. X., Shahzad, M., Ling, K., and Lu, S. (2017). Device-free human activity recognition using commercial wifi devices. *IEEE Journal on Selected Areas in Communications*, 35(5):1118–1131.
- Wang, Y., Cang, S., and Yu, H. (2019). A survey on wearable sensor modality centred human activity recognition in health care. *Expert Systems with Applications*, 137:167–190.

- Wang, Y., Wu, K., and Ni, L. M. (2016). Wifall: Device-free fall detection by wireless networks. *IEEE Transactions on Mobile Computing*, 16(2):581–594.
- 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.
- Yang, J., Liu, Y., Liu, Z., Wu, Y., Li, T., and Yang, Y. (2021). A framework for human activity recognition based on WiFi CSI signal enhancement. *International Journal of Antennas and Propagation*, 2021:1–18.