

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE ENGENHARIA ELÉTRICA**

FELIPE VINÍCIUS STEIN

**DETECÇÃO DE PRESENÇA DE OBJETOS UTILIZANDO SENSORIAMENTO
WI-FI COM *CHANNEL STATE INFORMATION***

**São Leopoldo
2023**

FELIPE VINÍCIUS STEIN

**DETECÇÃO DE PRESENÇA DE OBJETOS UTILIZANDO SENSORIAMENTO
WI-FI COM *CHANNEL STATE INFORMATION***

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica, pelo Curso de Engenharia Elétrica da Universidade do Vale do Rio dos Sinos (UNISINOS).

Orientador: Prof. Me. Armando Leopoldo Keller

São Leopoldo

2023

Aos meus queridos pais, Nelson Stein e Marlene Augusta Stein, dedico este trabalho de conclusão. Nem todas as páginas que aqui se encontram seriam capazes de registrar a gratidão que tenho por todo apoio, incentivo e amor que sempre me proporcionaram e foram fundamentais em toda a caminhada até aqui. Mas, mais do que isso, grato sou por me instruírem no temor do Senhor que é o princípio da sabedoria (Provérbios 9:10).

Amo vocês!

AGRADECIMENTOS

Aos professores Rodrigo Marques de Figueiredo e Ana Paula Mallmann por terem tornado a Universidade um ambiente familiar para mim. Grato sou pela amizade, conselhos e pelas caronas. A Unisinos é um lugar melhor com vocês.

Ao professor Armando Leopoldo Keller, meu grande orientador, agradeço pelas ideias malucas e geniais, pela paciência com as mesóclises e por ser um esplêndido professor dentro e fora da sala de aula. RTFM!

Por último, aproveito para registrar meu agradecimento e admiração ao professor Rubem Sprenger Dreger, por ter dado início ao curso de Eletrônica na Fundação Liberato Salzano Vieira da Cunha e ao curso de Engenharia Elétrica na Unisinos. A ele devo minha formação e capacidade de polarizar transistores.

“Tudo o que temos de decidir é o que fazer com o tempo que nos é dado.”

Gandalf

RESUMO

O presente trabalho aborda a temática do sensoriamento Wi-Fi através do processamento do sinal *Channel State Information* (CSI), ao analisar os trabalhos mais significativos entre os poucos publicados nesta linha de estudo e propor uma aplicação de detecção de presença de diversos tipos de corpos, sejam orgânicos ou metálicos, de tamanhos e massas variados em um ambiente fechado. São utilizados dois microcontroladores ESP32 como transceptores e os algoritmos de aprendizado *k-Nearest Neighbors* (kNN), *Random Forrest*, *Multi Layer Perceptron* (MLP) e *Support Vector Classifier* (SVC) como ferramentas de processamento de dados e predição. Neste trabalho é possível verificar que é possível a detecção de objetos - tanto orgânicos como metálicos - em ambientes fechados através do sensoriamento Wi-Fi com sinal CSI. Outrossim, é exposto o impacto de variáveis climáticas neste tipo de aplicação bem como as limitações das técnicas de *fingerprinting* quanto à estas variações e também às mudanças de ambiente. A pesquisa tem como premissa realizar um experimento cuja reprodução seja factível para outros pesquisadores, por este motivo utilizou-se de equipamentos e ferramentas de software de baixo custo e fácil acesso. Além disso, são disponibilizados todos os parâmetros, tanto da montagem física do *setup* de teste como da etapa de processamento, a fim de que o experimento seja facilmente replicado.

Palavras-chave: *Channel State Information*; sensoriamento Wi-Fi; *fingerprinting*; algoritmo de aprendizado; ESP32.

LISTA DE FIGURAS

Figura 1 - Contextualização da temática	28
Figura 2 - Mapa da área de testes	33
Figura 3 - Zona 1	34
Figura 4 - Zona 2.....	35
Figura 5 - Objetos da primeira coleta	36
Figura 6 - Objetos da segunda coleta	36
Figura 7 - Composição do frame de dados CSI	37
Figura 8 - Etapas de pré-processamento	38
Figura 9 - Demonstrativo do processo de <i>fingerprinting</i>	39
Figura 10 - Mapa auxiliar para escolha de algoritmo.....	40

LISTA DE QUADROS

Quadro 1 - Trabalhos correlatos.....	26
Quadro 2 - Busca de artigos no Mendeley	29
Quadro 3 - Resultados do teste na Zona 1 com objetos mistos.....	42
Quadro 4 - Resultados do teste na Zona 2 com objetos mistos.....	43
Quadro 5 - Resultados do primeiro teste do <i>fingerprinting</i>	44
Quadro 6 - Resultados do segundo teste do <i>fingerprinting</i>	44
Quadro 7 - Resultados do teste com o indivíduo na Zona 1	45
Quadro 8 - Resultados do teste com a bobina na Zona 1	45
Quadro 9 - Resultados do teste com o indivíduo na Zona 2	46
Quadro 10 - Resultados do teste com a bobina na Zona 2.....	46
Quadro 11 - Resultados do teste de diferenciação de ambientes	47
Quadro 12 - Teste com o melão - Zona 1	48
Quadro 13 - Teste com o <i>nobreak</i> na Zona 1.....	49
Quadro 14 - Teste com o melão na Zona 2.....	49
Quadro 15 - Teste com o <i>nobreak</i> na Zona 2.....	50
Quadro 16 - Média dos resultados	50

LISTA DE TABELAS

Tabela 1 - Comparativo de dispositivos Wi-Fi	31
--	----

LISTA DE SIGLAS

AUC	<i>Area Under the Curve</i>
CNN	<i>Convolutional Neural Network</i>
CSI	<i>Channel State Information</i>
DNN	<i>Dense Neural Network</i>
kNN	<i>k-Nearest Neighbors</i>
MLP	<i>Multilayer Perceptron</i>
ROC	<i>Receiver Operating Characteristic</i>
RSSI	<i>Received Signal Strenght Indication</i>
SVC	<i>Support Vector Classifier</i>
SVM	<i>Support Vector Machines</i>

SUMÁRIO

1 INTRODUÇÃO	12
1.1 OBJETIVOS	12
1.1.1 Objetivo geral	13
1.1.2 Objetivos específicos.....	13
2 FUNDAMENTAÇÃO TEÓRICA	14
2.1 CONCEITOS BÁSICOS	14
2.1.1 Sensoriamento <i>device-free</i>	14
2.1.2 Sensoriamento Wi-Fi	15
2.1.2.1 <i>Received Signal Strenght Indicator</i> (RSSI).....	15
2.1.2.2 <i>Channel State Information</i> (CSI)	16
2.1.2.3 <i>Fingerprinting</i>	18
2.1.3 Algoritmos de aprendizado de máquina de filosofia de classificação	19
2.1.3.1 <i>Support Vector Machines</i> (SVM).....	19
2.1.3.2 <i>k-Nearest Neighbors</i> (kNN)	19
2.1.3.3 <i>Ensemble Classifiers</i>	20
2.1.3.4 <i>Random Forest</i>	20
2.1.3.5 <i>Convolutional Neural Network</i> (CNN).....	21
2.1.3.6 <i>Multi Layer Perceptron</i> (MLP).....	21
2.2 TRABALHOS CORRELATOS	22
2.2.1 <i>Lightweight and Standalone IoT based WiFi Sensing for Active Repositioning and Mobility</i>	22
2.2.2 <i>Adversarial Occupancy Monitoring using One-Sided Through- Wall Wifi Sensing</i>	23
2.2.3 <i>Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information</i>	24
2.2.4 <i>WmFall: WiFi-based multistage fall detection with channel state information</i>	24
2.2.5 <i>Device-free Pedestrian Count Estimation Using Wi-Fi Channel State Information</i>	25
2.3 LISTA COM RESUMO DOS TRABALHOS	26
3 METODOLOGIA	28
3.1 SELEÇÃO DA LITERATURA UTILIZADA	28

3.2 ESCOLHA DO HARDWARE A SER USADO.....	30
3.3 ESCOLHA DO FIRMWARE A SER USADO	32
3.4 COLETA DE DATASETS	33
3.5 ETAPA DE PRÉ-PROCESSAMENTO	37
3.6 ESCOLHA DE BIBLIOTECA E DO TIPO DE ALGORITMO DE APRENDIZADO DE MÁQUINA PARA O PROCESSAMENTO DE DADOS.....	39
3.7 PARÂMETROS DE PROCESSAMENTO.....	40
3.8 MÉTODOS DE ANÁLISE DOS TESTES.....	41
4 ESTUDO DE CASO	42
4.1 RESULTADOS DOS TESTES	42
4.1.1 Teste na Zona 1 com objetos mistos - primeira coleta	42
4.1.2 Teste na Zona 2 com objetos mistos - primeira coleta	43
4.1.3 Primeiro teste do <i>fingerprinting</i>.....	43
4.1.4 Segundo teste do <i>fingerprinting</i>.....	44
4.1.5 Teste na Zona 1 com objeto orgânico - primeira coleta.....	45
4.1.6 Teste na Zona 1 com objeto metálico - primeira coleta	45
4.1.7 Teste na Zona 2 com objeto orgânico - primeira coleta.....	46
4.1.8 Teste na Zona 2 com objeto metálico - primeira coleta	46
4.1.9 Diferenciação entre ambientes vazios em circunstâncias diferentes	47
4.1.10 Teste na Zona 1 com objeto orgânico - segunda coleta	48
4.1.11 Teste na Zona 1 com objeto metálico - segunda coleta.....	48
4.1.12 Teste na Zona 2 com objeto orgânico - segunda coleta	49
4.1.13 Teste na Zona 2 com objeto metálico - segunda coleta.....	49
4.2 MÉDIA DOS RESULTADOS E COMPARAÇÃO COM TRABALHOS CORRELATOS.....	50
4.3 AVALIAÇÃO DO DESEMPENHO DOS ALGORITMOS DE APRENDIZADO UTILIZADOS	52
5 CONCLUSÃO	53
REFERÊNCIAS.....	55

1 INTRODUÇÃO

De acordo com Hsieh, Chen e Nien (2019), os métodos de sensoriamento convencionais para detecção de presença ou movimentação humana, que fazem uso de dispositivos anexados ao corpo dos indivíduos à serem monitorados, possuem desvantagens em relação aos métodos *device-free*. Entre elas, destaca-se justamente a necessidade de o indivíduo carregar consigo um dispositivo junto ao corpo, o que pode gerar desconforto e ser um fator limitante, uma vez que se deve ter um elemento de sensoriamento para cada indivíduo. Por este motivo, em aplicações em que se deseja monitorar mais de um corpo, a tendência é que os métodos de sensoriamento *device-free* acabem se mostrando mais baratos uma vez que a quantidade de dispositivos utilizados é menor.

Além de oferecerem maior pervasividade aos processos, os métodos *device-free* também permitem realizar o monitoramento de múltiplos alvos simultaneamente em uma determinada área (HERNANDEZ; BULUT, 2020). Entre estes métodos, pode-se destacar o uso do sensoriamento Wi-Fi, radar e sistemas de visão. O uso de radares comumente se mostra inacessível pelo seu alto custo e os sistemas de visão ficam à mercê das condições de iluminação e são afetados pela eventual intrusão de algum objeto no campo de visão (SANDARUWAN *et al.*, 2021). Já o sensoriamento Wi-Fi além de ser relativamente barato, não depende das condições de iluminação e seu funcionamento não é afetado pela eventual intrusão de algum objeto no campo de atuação.

O sensoriamento Wi-Fi pode ser realizado utilizando dois tipos de sinais, o *Received Signal Strength Indication* (RSSI) e o *Channel State Information* (CSI) (WANG *et al.*, 2021), sendo que a técnica de sensoriamento que utiliza o sinal CSI é relativamente recente e, por isso, presente em poucos estudos se comparado à outros métodos de sensoriamento.

1.1 OBJETIVOS

Nesta subseção serão descritos os objetivos gerais e específicos que o trabalho almeja atingir.

1.1.1 Objetivo geral

O presente trabalho tem como objetivo realizar a experimentação de detecção de presença dentro de um ambiente fechado fazendo uso da técnica de sensoriamento com sinal CSI.

1.1.2 Objetivos específicos

Ao realizar as experimentações de sensoriamento com CSI, é almejado:

- a) realizar a obtenção de dados CSI;
- b) realizar o tratamento desse tipo de dado;
- c) testar a aplicabilidade da técnica do *fingerprinting*;
- d) validar o sistema de identificação de presença em ambiente fechado com o uso de dados CSI;
- e) verificar se há diferença na qualidade de detecção entre corpos orgânicos e metálicos;
- f) verificar a influência da área de um corpo na qualidade da sua respectiva detecção em zonas de diferentes tamanhos;
- g) analisar as dificuldades e limitações deste tipo de aplicação.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos básicos da temática do trabalho, bem como os trabalhos correlatos e as características ímpares de cada um.

2.1 CONCEITOS BÁSICOS

Esta subseção apresenta alguns conceitos fundamentais para o desenvolvimento do projeto, partindo do conceito mais amplo (sensoriamento *device-free*), limitando o assunto para sensoriamento Wi-Fi e expondo dois tipos de sinais usados para este fim (*Received Signal Strength Indicator* e *Channel State Information*) que serão profusamente citados no desenvolvimento do trabalho e uma técnica que pode ser aplicada a ambos os sinais. Por fim, será apresentada uma filosofia de algoritmo de aprendizado - e alguns exemplos desta filosofia que são significativos para o trabalho - que pode ser usada com a finalidade de processar os dados provenientes de sistemas de sensoriamento Wi-Fi.

2.1.1 Sensoriamento *device-free*

Na literatura pesquisada, os autores se referem aos métodos de sensoriamento que não precisam que o sensor esteja junto ao corpo a ser monitorado ou detectado como *device-free*. Já o sensoriamento convencional, em que há a necessidade de o indivíduo carregar o dispositivo consigo, é chamado de *device-based*.

Conforme Wang *et al.* (2021), para realizar o sensoriamento sem a necessidade do usuário portar o elemento sensor, pode-se usar diversos tipos de sinais, tais como a luz, o som e a rádio frequência. Sandaruwan *et al.* (2021), citam alguns métodos que usam estes tipos de sinais, como sistemas de visão, radar e Wi-Fi. Ainda segundo Sandaruwan *et al.* (2021), o uso de radar tende a ser caro devido à complexidade do processamento de sinais requerido para uso desta técnica. Já os sistemas de visão são limitados, pois sua funcionalidade é afetada pelas condições de iluminação ou pela eventual intrusão de um obstáculo. Além disso, os sistemas de visão são caros e podem comprometer a privacidade pessoal (YANG *et al.*, 2018). O sensoriamento Wi-Fi, por sua vez, além de não depender das condições de iluminação e poder atuar

mesmo com obstáculos no percurso do sinal, mostra-se um método não-intrusivo (MA; ZHOU; WANG, 2019).

Por outro lado, um revés que o sensoriamento Wi-Fi pode sofrer é a influência de condições climáticas, pois é conhecido que o campo magnético pode sofrer um ligeiro aumento conforme aumento da temperatura e uma diminuição conforme aumento da umidade relativa do ar (DIKUN *et al.*, 2015).

Na próxima subseção serão descritos os tipos de sinais, com os quais é possível realizar aplicações de sensoriamento Wi-Fi.

2.1.2 Sensoriamento Wi-Fi

De acordo com Wang *et al.* (2021), os dispositivos Wi-Fi podem fornecer dois tipos de sinais, com os quais pode-se realizar o sensoriamento: *Received Signal Strength Indicator* (RSSI) e *Channel State Information* (CSI). Nas próximas subseções, é discorrido a respeito destes dois sinais, e suas particularidades serão destacadas.

2.1.2.1 Received Signal Strength Indicator (RSSI)

Em português, indicador de força do sinal recebido, é a medida de potência de um sinal de rádio recebido e pode ser usado para avaliar a atenuação que o sinal teve ao longo do trajeto (HSIEH; CHEN; NIEN, 2019). E, através da medição deste parâmetro, é possível realizar vários tipos de sensoriamentos, inclusive reconhecer a presença e gestos humanos (WANG *et al.*, 2021).

Segundo Wang *et al.* (2021), este tipo de sinal tem sido amplamente usado em sistemas que visam realizar a localização de um objeto de interesse em ambientes internos, podendo fornecer uma acurácia na escala de metros em ambientes simples. Porém, ainda conforme Wang *et al.* (2021), o RSSI não é capaz de entregar resultados robustos em ambientes internos complexos, já que este sinal sofre de uma drástica perda de performance devido a efeitos causados por múltiplos caminhos e dinâmica temporal.

Conforme Hsieh, Chen e Nien (2019) a medida do RSSI depende de dois fatores: da potência com a qual o sinal é emitido e a distância entre o transmissor e o

receptor. Tendo estes dois elementos, o sinal RSSI pode ser descrito como apresentado na Equação (1).

$$RSSI_{(dbm)} = 10 \cdot \log \frac{P_r}{P_{ref}} \quad (1)$$

Onde P_{ref} é a potência de referência e P_r é a potência do sinal que é recebido e pode ser calculado pela relação apresentada na Equação (2).

$$P_r = P_t \cdot G_t \cdot G_r \cdot \left(\frac{\lambda}{4\pi d} \right)^2 \quad (2)$$

Onde, P_t é a potência do sinal transmitido, G_t representa o ganho da antena do transmissor, G_r a potência da antena do receptor, λ é o comprimento de onda do sinal transmitido e d é a distância entre o transmissor e o receptor.

É nítido que as operações matemáticas usadas para calcular do valor do RSSI são simples e de fácil compreensão. Este é um contraste notável do uso do sinal RSSI em comparação ao outro tipo de sinal Wi-Fi com o qual pode ser realizado sensoriamento - o CSI - que será descrito subseção seguinte.

2.1.2.2 Channel State Information (CSI)

Em português, “informação do estado do canal” é um sinal Wi-Fi regulado pela norma IEEE 802.11n (INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO); INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC); INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS (IEEE), 2012), que permite a coleta de múltiplos dados em um mesmo *frame* - ao contrário do sinal RSSI em que é coletado apenas um dado por *frame*. Esta múltipla coleta de dados simultânea é possível através do uso da Multiplexação de Divisão de Frequência Ortogonal - do inglês *Orthogonal Frequency-Division Multiplexing* (OFDM) – que é uma técnica de transmissão de dados que faz uso de sua banda dividida em múltiplas portadoras ortogonais, que são chamadas de subportadoras (HERNANDEZ; BULUT, 2021). Estas subportadoras são chamadas “ortogonais” pelo fato de não possuírem sobreposição de frequência e, conseqüentemente, não interferem umas nas outras (PACELLI; LUCENA, 2019).

Segundo Ma, Zhou e Wang (2019), o CSI é descrito através de uma matriz tridimensional de valores complexos que representam a amplitude da atenuação e a mudança de fase que o sinal vem a sofrer ao longo do caminho percorrido. E, de acordo com Hernandez, Erdag e Bulut (2021), esta matriz possui dimensão $M \times N$, em que M é o número de antenas e N é a quantidade de subportadoras. Em cada *frame* recebido (por antena), são recebidas 64 subportadoras das quais 52 contém informações do CSI (HERNANDEZ; BULUT, 2021).

Ainda segundo Hernandez, Erdag e Bulut (2021), a fim de identificar o valor desta matriz, deve ser considerada a Equação (3).

$$y_i = H_i x_i + \eta_i \quad (3)$$

Em que, i é o índice da subportadora, y_i corresponde aos atributos do sinal recebido, x_i é o sinal transmitido e η_i é um vetor que representa o ruído do próprio ambiente. Já o vetor H , consiste nos números complexos que representam as características do sinal recebido. A natureza complexa do vetor H fica clara na exposição das Equações (4) e (5), que descrevem a amplitude e fase, respectivamente.

A amplitude do sinal CSI pode ser calculada pela Equação (4).

$$A^{(i)} = \sqrt{(H_r^{(i)})^2 + (H_{im}^{(i)})^2} \quad (4)$$

Já, a fase do sinal pode ser calculada pela Equação (5).

$$\phi^{(i)} = \text{atan2}(H_{im}^{(i)}, H_r^{(i)}) \quad (5)$$

Onde, $H_r^{(i)}$ é a componente real e $H_{im}^{(i)}$ é a componente imaginária de cada subportadora (i).

Conforme Hsieh *et al.* (2019), por causa desta particularidade de lidar com múltiplas subportadoras, o CSI consegue caracterizar como um sinal se propaga, desde o transmissor até o receptor, representando o efeito combinado de vários fenômenos que ocorrem durante a propagação, como por exemplo, o espalhamento, o desvanecimento e o decaimento da potência ao longo do tempo. Em virtude disso,

o CSI permite uma variedade de aplicações como detectar movimento humano e até determinar a localização de algo.

Na literatura pesquisada há um consenso de que o CSI é mais avançado do que o RSSI. Yang, Zhou e Liu (2013), afirmam que as principais diferenças entre estes dois sinais dizem respeito as camadas de rede, resolução de tempo e frequência, estabilidade e acessibilidade. E, por causa destas diferenças, há um avanço significativo do CSI em relação ao RSSI, justamente por causa da capacidade de resolver a questão dos múltiplos caminhos pela diversidade de frequências. Por causa disso, o CSI fornece uma fonte de dados muito mais rica que RSSI, o que possibilita uma percepção mais detalhada das características do ambiente analisado (HERNANDEZ; BULUT, 2020).

Na literatura pesquisada, é notável o uso do RSSI e do CSI para uma funcionalidade específica em aplicações de localização. Tal funcionalidade é chamada de *fingerprinting* - que em português seria o ato de retirar a impressão digital - que é descrita na subseção seguinte.

2.1.2.3 *Fingerprinting*

De acordo com Hsieh *et al.* (2019), o *fingerprinting* é uma técnica popular em aplicações que se utilizam de rádio frequência para fins de localização em ambientes internos. Esta técnica é dividida em duas fases: online e offline. Na fase offline, é realizado um levantamento das características do ambiente afim de criar uma base de dados. Já na fase online, são realizadas medições em tempo real que são comparadas com a base de dados previamente coletada, a fim de analisar as disparidades e realizar as conclusões cabíveis.

Segundo Yang, Zhou e Liu (2013), a principal dificuldade no uso desta técnica está na complexidade de construir e atualizar um banco de dados para, posteriormente, servir de referência para as medições em tempo real.

É notável que, nos trabalhos pesquisados, algoritmos de aprendizado foram amplamente usados com a finalidade de processar os dados provenientes do dispositivo que realiza o sensoriamento. Por isso, na próxima seção é apresentada uma das filosofias de algoritmos de aprendizado - e algumas técnicas específicas que fazem uso desta filosofia - que pode ser usada para processar este tipo de dados.

2.1.3 Algoritmos de aprendizado de máquina de filosofia de classificação

Neste tópico são brevemente descritos os algoritmos de aprendizado de máquina que utilizam a filosofia de classificação que eventualmente poderiam ser utilizados para o processamento dos dados adquiridos na etapa de sensoriamento Wi-Fi previamente citada em 2.1.2.

Os quatro primeiros algoritmos citados nesta seção utilizam da filosofia de classificação, que são um tipo de algoritmo supervisionado e seu objetivo é verificar e classificar a qual grupo ou categoria um determinado dado pertence de acordo com as características observadas pelo supervisor (ZHANG *et al.*, 2017). Os dois últimos algoritmos utilizam o modelo de rede neural que, segundo Russel e Norvig (2013) é um método inspirado no funcionamento do cérebro humano para processar dados através de nós (também chamados de neurônios) conectados por ligações direcionadas.

2.1.3.1 *Support Vector Machines* (SVM)

De acordo com Russel e Norvig (2013), O *Support Vector Machines* – em português, Máquina de Vetor de Suportes – é um algoritmo cujo princípio de funcionamento é construir separadores, como se fossem margens, entre determinados grupos de pontos. Segundo os autores, os SVMs podem criar tanto uma separação linear em um hiperplano, como também realizar este tipo de separação em um espaço de dimensão superior.

Conforme Hu (2013), este tipo de algoritmo tem demonstrado funcionar muito bem em problemas de classificação e previsão, além de ser muito usado para reconhecimento de padrões. Contudo, encontra dificuldades em lidar com um conjunto de dados excessivamente grande e a fase de aprendizado cresce substancialmente conforme o número de pontos de treinamento é incrementado.

2.1.3.2 *k-Nearest Neighbors* (kNN)

Conforme Zhang *et al.* (2017), o algoritmo *k-Nearest Neighbors* - em português, k-Vizinhos Mais Próximos - busca encontrar um número predefinido de amostras de

treinamento que estejam na menor distância possível de um novo ponto e, a partir disso, classificá-lo.

Ainda conforme Zhang *et al.* (2017), é possível determinar o número de conjuntos de amostras – como uma constante pré-definida – ou ainda permitir que este valor varie conforme a densidade de pontos. Além disso, pode-se usar as mais diversas métricas para calcular a distância entre um ponto e os seus vizinhos, tais como Euclidiana, Mahalanobis e Minkowsky.

2.1.3.3 *Ensemble Classifiers*

Em português, classificadores de conjunto, é um algoritmo cujo preceito é utilizar mais de um tipo de classificador, simultaneamente, a fim de obter um desempenho melhor do que usando apenas um classificador isoladamente (JAN; VERMA, 2019).

Os autores Jan e Verma (2019) esclarecem que os classificadores em conjunto conseguem oferecer um resultado mais satisfatório que classificadores isolados pois, mesmo que um determinado tipo de classificador funcione bem para um determinado tipo de dado, não necessariamente ele vai funcionar bem para outros tipos de dados. Por causa disso, a ideia por trás de usar mais classificadores diferentes, de maneira combinada, é que eles cheguem a uma decisão unânime entre si.

2.1.3.4 *Random Forest*

Segundo Mbaabu (2020), *Random Forest* - em português, floresta aleatória - é um tipo de Ensemble Classifier, pois usa o princípio de usar um conjunto combinado de algoritmos. Neste caso, ele faz uso de várias árvores de decisão e por isso é denominada de “floresta”. Ainda, conforme o autor, uma árvore de decisão é uma técnica de suporte à tomada de decisão que consiste em uma estrutura semelhante a uma árvore, e pode ser usado tanto para aplicações de classificação quanto de regressão, podendo lidar com *datasets* grandes com eficiência.

Mbaabu (2020) afirma que o algoritmo *Random Forrest* é mais preciso do que uma árvore de decisão individualmente e lida muito bem com o problema de *overfitting*, que é uma adversidade muito comum nas árvores de decisão. De acordo com o autor, este tipo de algoritmo tem sido utilizado em vários tipos de aplicação,

incluindo diagnóstico de doenças, análises financeiras e predição de preferência de consumidores em *e-commerces*. Por outro lado, o autor também esclarece que este algoritmo não é indicado em aplicações em que existe extrapolação de dados ou quando os dados são muito esparsos.

2.1.3.5 *Convolutional Neural Network (CNN)*

Em português, rede neural convolucional, a *Convolutional Neural Network* é um tipo de algoritmo que foi criado a partir do estudo do córtex visual do cérebro e tem sido usado para identificação de imagens desde a década de 1980, mas ultimamente tem ganhado várias funcionalidades em áreas diversas, como alimentar serviços de busca de imagens, classificação de vídeos, e até mesmo nos sistemas de controle de carros autônomos (GÉRON, 2019).

De acordo com Géron (2019), o ponto fundamental de uma rede neural convolucional é a camada de convolução, que possui um diferencial em relação à outros tipos de rede neural: os neurônios da primeira camada de convolução não ficam conectados a cada pixel na camada de entrada, apenas aos pixels em seus campos receptivos. Já os neurônios presentes na segunda camada convolucional ficam conectados apenas a neurônios localizados dentro de um pequeno retângulo na primeira camada. Conforme o autor, este tipo de arquitetura permite que a rede se concentre em pequenos recursos de baixo nível na primeira camada oculta para, na sequência, juntar e montar em recursos maiores de níveis superiores, e assim por diante. Ainda, segundo o autor, o motivo pelo qual essa rede funciona tão bem para reconhecimento de imagens, é que as imagens do mundo real utilizam esta mesma estrutura hierárquica.

2.1.3.6 *Multi Layer Perceptron (MLP)*

De acordo com Mishra, Yadav e Singh (2013), o *Multi Layer Perceptron* é uma rede neural não-linear que se utiliza de várias camadas de entrada, uma ou mais camadas ocultas e uma camada de saída. Segundo os autores, como função de ativação - ou seja, o elemento que decide se um neurônio vai ser ativado ou não - de cada *layer* oculto são utilizadas funções não lineares, tais como o sigmóide ou tangente hiperbólica.

Conforme Géron (2019), este algoritmo pode ser usado tanto para fins de classificação quanto para regressão. No caso da regressão, não é desejável usar função de ativação para os neurônios de saída. Caso se deseje apenas prever um valor, deve-se usar apenas um neurônio de saída. Já, se a situação envolver a previsão de vários valores ao mesmo tempo, deve-se ter um neurônio de saída por dimensão de saída. Já no caso de sistemas que exigem a filosofia de classificação, pode-se realizar uma classificação binária com um único neurônio usando a função de ativação logística, ou ainda realizar uma classificação binária multirótulo com dois neurônios de saída com ambos usando a função de ativação logística. De acordo com o autor, essa classificação binária multirótulo é muito utilizada para prever a categoria de e-mails (*spam*, urgente, etc.).

2.2 TRABALHOS CORRELATOS

Na sequência, são relacionados e brevemente descritos os trabalhos correlatos dentro da temática de sensoriamento Wi-Fi, bem como os respectivos resultados obtidos. Consequente, é apresentado um quadro listando os trabalhos e em que se pode verificar um resumo das principais informações destas pesquisas.

2.2.1 Lightweight and Standalone IoT based WiFi Sensing for Active Repositioning and Mobility

No artigo de Hernandez e Bulut (2020), foi desenvolvido um sistema de sensoriamento Wi-Fi, utilizando a técnica do CSI, através do microcontrolador ESP32. Os autores ainda desenvolveram uma ferramenta de software para adquirir os dados de CSI coletados do microcontrolador que pode, inclusive ser lida em smartphones. Para este fim, também foi desenvolvido um aplicativo para que dispositivos Android possam coletar e processar os dados em tempo real.

Com este sistema, foram realizados experimentos em um ambiente fechado e retangular, em três circunstâncias: com os dois dispositivos estáticos, com realocação do receptor em quatro posições diferentes, e com o receptor móvel (acoplado ao indivíduo em movimento). O objetivo desta experimentação é detectar movimentação humana, quanto à direção e a distância do deslocamento. Na primeira situação, foi concluído que ao posicionar os dispositivos nos cantos do ambiente, se obtém uma

acurácia maior do que se posicionados nos centros (87,5% contra 81,6% para detecção de profundidade do movimento e 89,4% contra 58,2% para detecção de direção). Na segunda situação foram testadas quatro posições distintas para o receptor em que, na pior das hipóteses, se conseguiu 70% de acurácia e, na melhor, 95,6% para detecção de movimento. Já na terceira situação foi averiguado que o receptor móvel permite uma compreensão tridimensional sobre as atividades realizadas no ambiente, além de fornecer um aumento de até 28,2% de acurácia em relação às medições com receptor estático. Para todos os experimentos, Hernandez e Bulut (2020) usaram entre 100 e 200 *frames*. Para processar os dados, foi usada a rede neural *Dense Neural Network* (DNN), através da biblioteca Keras do *Tensor Flow*. Os pesquisadores utilizaram um range de (10, 200) neurônios por camada oculta e encontraram 25 neurônios para executar de forma mais consistente. Além disso, foram usadas camadas de *dropout* para que 50% das conexões ponderadas entre camadas densas fossem removidas com o intuito de evitar *overfitting*. Já a otimização foi feita usando gradiente descendente estocástico com taxa de aprendizado de 0,1.

Outra contribuição deste artigo é a comparação de características da ESP32 com outras plataformas que permitem a coleta de dados CSI, entre elas o chip Intel 5300, a plataforma Atheros e a Nexmon.

2.2.2 Adversarial Occupancy Monitoring using One-Sided Through-Wall Wifi Sensing

No artigo Hernandez e Bulut (2021), os pesquisadores valeram-se da plataforma de sensoriamento Wi-Fi utilizando CSI cujo desenvolvimento foi descrito no artigo de autoria própria "*Lightweight and Standalone IoT based WiFi Sensing for Active Repositioning and Mobility*" apresentando em 2.2.1, para demonstrar como esta tecnologia pode ser utilizada para usos maliciosos que envolvam o monitoramento de ambientes alheios, devido à pervasividade e acessibilidade desta técnica.

Hernandez e Bulut (2021) realizaram experimentações que mostraram a capacidade do sistema desenvolvido, de detectar e realizar a contagem de pessoas, através de paredes. Partindo dos resultados obtidos, estes pesquisadores acreditam que conseguirão, inclusive, detectar a direção do movimento dos alvos ao passarem pelo corredor. Visando isto, eles propõem realizar o rastreamento de múltiplos alvos

em um ambiente e estudar o efeito de outros parâmetros nas medições, como por exemplo, a velocidade de locomoção.

Motivados pelas constatações alcançadas a respeito da capacidade de realizar sensoriamentos com altíssima pervasividade, Hernandez e Bulut (2021) também destacam a necessidade de se desenvolver mecanismos de defesa para prevenir usos maliciosos deste tipo de tecnologia.

2.2.3 Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information

Na publicação Hsieh, Chen e Nien (2019), os autores descrevem a experimentação de usar um roteador como transmissor e um cartão de interface de rede para coletar dados CSI e RSSI para sensoriamento de um ambiente interno. Foram implementadas quatro redes neurais: MLP-RSSI e CSI; CNN-RSSI e CSI. Estes algoritmos foram usados para processar os dados coletados e estimar a localização de uma pessoa dentro do ambiente analisado. Foi concluído que os métodos que fazem uso dos sinais CSI apresentam acurácia consideravelmente maior do que aqueles usam RSSI (99,98% contra 82,32% no método CNN e 99,93% contra 80,29% no método MLP). As arquiteturas selecionadas para usar foram 960-860-560-460-360 para redes MLP, tanto a RSSI quanto a CSI e função de ativação Relu. Já no método CNN, a arquitetura escolhida foi a 16-32-32 com *kernel* de tamanho 16 para RSSI e 26 para CSI.

Além disso, Hsieh, Chen e Nien (2019) perceberam que a rede neural 1-D CNN-CSI apresenta melhor performance e exige menos complexidade de rede em comparação com outras redes, incluindo o 2-D CNN-CSI.

2.2.4 WmFall: WiFi-based multistage fall detection with channel state information

Na publicação Yang *et al.* (2018), foi realizada a detecção do movimento de queda humana através do sensoriamento Wi-Fi utilizando sinal CSI. Os pesquisadores explicam que tradicionalmente este tipo de detecção requer o uso de sensores ou sistemas de visão que podem se mostrar inconvenientes e trazer consigo problemas de privacidade. Em contrapartida, o sensoriamento Wi-Fi traz a vantagem de

conseguir realizar este tipo de sensoriamento sem o inconveniente de exigir um sensor acoplado ao corpo ou de gerar problemas de privacidade que a coleta de imagens pode causar.

O estudo foi motivado pelo fato de que diferentes tipos de ações causam diferentes efeitos nos sinais Wi-Fi. No entanto, é notável que os movimentos de queda e o de se sentar são semelhantes entre si. Por isso, foi o objetivo de Yang *et al.* (2018) realizar a diferenciação entre estes dois tipos de ações, que foi alcançado com os percentuais de 89% de acurácia e 8% de falso alarme.

2.2.5 Device-free Pedestrian Count Estimation Using Wi-Fi Channel State Information

Em Sandaruwan *et al.* (2021), é descrita a experimentação de contagem de pedestres esperando para atravessar a rua, mediante sensoriamento Wi-Fi com sinal CSI, através da plataforma ESP32. Os pesquisadores fizeram uso de duas redes neurais para serem treinadas com os dados coletados: uma rede MLP e uma 1D-ConvNet.

As experimentações foram realizadas em três locais diferentes - todas em ambientes externos -, com quatro *datasets* para treinar as redes neurais. Foram realizados um total de sete experimentos (três em uma localização e dois experimentos em cada um dos outros dois locais) com combinações distintas de *datasets*.

Este foi o primeiro protótipo de sensoriamento usando CSI (com 51 subportadoras) para contagem de pessoas em ambiente externo, implementado em plataforma de baixo custo. Sandaruwan *et al.* (2021) conseguiram realizar a contagem de até doze pessoas com uma acurácia mínima de 69% (na pior das hipóteses) e de 98% (na melhor das hipóteses) com o algoritmo de aprendizado de máquina 1D-ConvNet. Já usando MLP, os resultados se mostraram inferiores (55% no pior dos casos e 97% no melhor deles). Eles ainda puderam concluir que embora o modelo 1D-ConvNet apresente maior acurácia e precisão, o outro que usa a rede MLP requer menos treino e períodos de inferência.

2.3 LISTA COM RESUMO DOS TRABALHOS

Na sequência é apresentado o Quadro 1 que lista e resume as principais informações dos trabalhos correlatos previamente apresentados.

Quadro 1 - Trabalhos correlatos

Título do Trabalho	Ano de Publicação	Autores	Objetivo/Aplicação do Trabalho
<i>Lightweight and Standalone IoT based WiFi Sensing for Active Repositioning and Mobility</i>	2020	Steven M. Hernandez e Eyuphan Bulut	Realizar uma ferramenta de software para coletar os dados CSI da plataforma ESP32
<i>Adversarial Occupancy Monitoring using One-Sided Through-Wall Wifi Sensing</i>	2021	Steven M. Hernandez e Eyuphan Bulut	Demonstrar que sistemas de sensoriamento WI-Fi usando CSI conseguem realizar detecção e contagem de pessoas, mesmo através de paredes e alertando para o potencial uso malicioso da tecnologia
<i>Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information</i>	2019	Chaur-Heh Hsieh, Jen-Yang Chen e Bo-Hong Nien	Análise e comparação das acurácias entre sistemas de localização para ambiente interno que usem CSI e RSSI
<i>WmFall: WiFi-based multistage fall detection with channel state information</i>	2018	Xu Yang, Fangyuan Xiong, Yuan Shao e Qiang Niu	Realizar a detecção do movimento humano de queda, diferenciando-o do movimento de sentar
<i>Device-free Pedestrian Count Estimation Using Wi-Fi Channel State Information</i>	2021	Roshan Sandaruwan, Isuru Algiyawanna, Sameera Sandeepa, Suyama Dias e Dileeka Dias	Realizar identificação e contagem de pedestres esperando para atravessar a rua usando CSI através da plataforma ESP32

Fonte: Elaborado pelo autor.

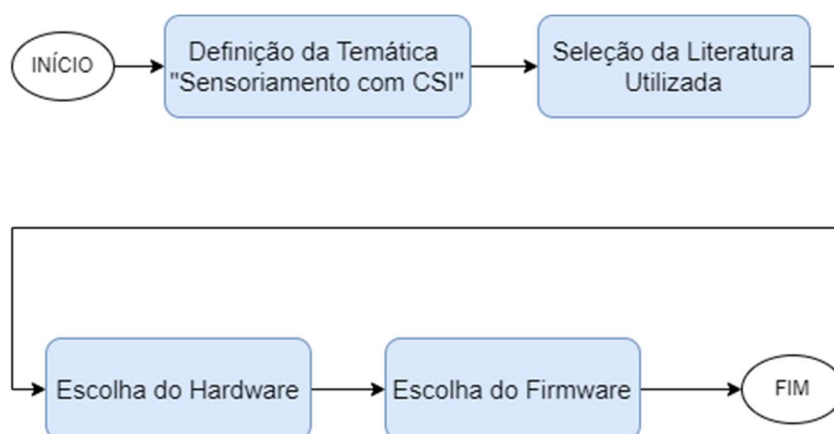
É perceptível uma notória presença do autor Steven Hernandez na relação dos trabalhos correlatos, pela sua ampla contribuição ao tema – que até então é pouco explorado – a partir da sua ferramenta de software para aquisição dos dados CSI pela plataforma ESP32 e pelos estudos desenvolvidos sobre a capacidade, limitações e possibilidades de uso do sistema. Também é possível verificar na relação de trabalhos a ampla possibilidade de aplicações para este tipo de sensoriamento, como contagem de pedestres (SANDARUWAN *et al.*, 2021) e detecção do movimento de queda humano (YANG, X. *et al.*, 2018). Além disso é listado um trabalho (HSIEH; CHEN; NIEN, 2019) que explana com clareza as diferenças entre os sinais Wi-Fi CSI e RSSI, as suas principais características e limitações. Através de comparativos como este, é possível decidir com maior propriedade e embasamento sobre qual dos sinais é mais indicado usar para determinada aplicação.

3 METODOLOGIA

Neste capítulo são descritas as etapas do desenvolvimento do trabalho e ilustradas através de fluxogramas que explana visualmente a sequência e a relação entre as etapas.

A primeira etapa, ilustrada pelo fluxograma demonstrado na Figura 1, constitui uma contextualização da temática da pesquisa, seleção da literatura de interesse e conseguinte escolha do hardware e do respectivo *firmware* a serem usados. Esta primeira etapa abrange os primeiros três subtópicos da metodologia.

Figura 1 - Contextualização da temática



Fonte: Elaborada pelo autor.

3.1 SELEÇÃO DA LITERATURA UTILIZADA

Pelo fato de a temática do trabalho ser relativamente nova - como pode ser observado na listagem de trabalhos relacionados em 2.3 - não foi encontrada uma literatura acessível em formato de livro que mostre aplicações práticas, apenas os conceitos básicos. Por este motivo, a literatura de consulta baseou-se em trabalhos publicados em forma de artigos e da própria norma respectiva a temática de Wi-Fi (ISO; IEC; IEEE, 2012).

Para realizar a consulta, leitura e o próprio referenciamento dos artigos para embasamento do trabalho, foi utilizada a plataforma Mendeley. Foram pesquisados

por artigos com três focos distintos através de três respectivas *strings* de busca que são apresentadas no Quadro 2.

Quadro 2 - Busca de artigos no Mendeley

Assunto	String de Busca	Título dos Artigos Selecionados	Ano de Publicação
Relação do CSI com RSSI	<i>csi and rssi</i>	<i>From RSSI to CSI: Indoor Localization via Channel Response</i>	2013
		<i>Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information</i>	2019
Revisão sistemática sobre CSI	<i>csi survey</i>	<i>CSI-based human sensing using model-based approaches: a survey</i>	2021
		<i>WiFi Sensing with Channel State Information: A Survey</i>	2019
Aplicações de sensoriamento usando CSI	<i>csi sensing</i>	<i>WmFall: WiFi-based multistage fall detection with channel state information</i>	2018
		<i>Towards Dense and Scalable Soil Sensing Through Low-Cost WiFi Sensing Networks</i>	2021
		<i>Performing WiFi Sensing with Off-the-shelf Smartphones</i>	2020
		<i>Lightweight and Standalone IoT based WiFi Sensing for Active Repositioning and Mobility</i>	2020
		<i>Device-free Pedestrian Count Estimation Using Wi-Fi Channel State Information</i>	2021

Fonte: Elaborado pelo autor.

O critério primário de escolha foi a ordenação por relevância que o próprio Mendeley fornece à primeira vista. Em um segundo momento, foi realizada uma seleção heurística com base nos resumos, ao mesmo tempo que foram visados trabalhos publicados nos últimos quatro anos. A única exceção ao critério da atualidade de publicação foi o artigo “*From RSSI to CSI: Indoor Localization via Channel Response*” - que foi publicado no ano de 2013 -, mas optou-se por usá-lo

devido à grande riqueza de material comparativo entre os dois tipos de sinais. Não obstante, também é possível verificar comparações práticas entre os dois tipos de sinais em alguns dos trabalhos que realizaram experimentação de sensoriamento.

Baseado nos trabalhos correlatos lidos, foi possível verificar os hardwares atuais com os quais é possível realizar a aquisição dos dados CSI e visualizar comparativos entre eles. Através disto, foi realizada a escolha do dispositivo Wi-Fi a ser usado no trabalho que é descrito na seção 3.3.

Pelo fato de grande parte da literatura utilizada ser de procedência estrangeira, o idioma no qual os trabalhos foram escritos é o inglês. Portanto, ao descrever, citar e parafrasear os trabalhos correlatos, foi utilizada tradução livre para o idioma português.

3.2 ESCOLHA DO HARDWARE A SER USADO

Ao analisar a literatura selecionada é possível verificar que não são muitos os dispositivos Wi-Fi que fornecem o acesso aos dados CSI. E dentre os que possibilitam o acesso a este sinal, destaca-se o microcontrolador ESP32 que se mostra uma plataforma versátil ao permitir seu uso como *access point* e *active station* (HERNANDEZ; BULUT, 2020). Além do mais, o ESP32 é um dispositivo muito acessível e facilmente encontrada nas lojas de eletrônicos, além de ser uma solução mais barata do que usar roteadores convencionais. Ao realizar uma rápida pesquisa no *market place* Mercado Livre, é possível encontrar um ESP32 por menos de cinquenta reais. Já o kit usado por Hsieh, Chien e Nien (2019) que inclui um chip Intel 5300 e um roteador TP-Link WA901-ND não é encontrado no mesmo *market place* por menos de 300 reais.

O ESP32 se mostra inferior em alguns aspectos em relação a outros dispositivos Wi-Fi, daí também o seu menor custo. Segundo Hernandez e Bulut (2020) uma das limitações mais visíveis do ESP32 está na velocidade de obtenção de dados pela interface serial que é limitada até 650 amostragens por segundo, enquanto outros dispositivos facilmente conseguem realizar 1.000 amostragens no mesmo período de tempo. Mas esta limitação não impacta o objetivo do presente trabalho, uma vez que pretende-se identificar a presença de objetos e não a identificação de movimentos. Na Tabela 1, adaptada de Hernandez e; Bulut (2020), é possível verificar o comparativo entre alguns hardwares que possibilitam a aquisição de dados CSI.

Tabela 1 - Comparativo de dispositivos Wi-Fi

	Intel 5300 (+Laptop)	Atheros (+Laptop)	Nexmon	ESP32
Trabalhos utilizando esta ferramenta para CSI	92,5%	6,8%	<1%	N/A
Acoplável em Smartphones	NÃO	NÃO	Apenas com mudanças no Firmware	SIM
Pode coletar dados CSI sozinho	NÃO	NÃO	Apenas com mudanças no Firmware	SIM
Tamanho	> 30 cm x 20 cm	> 30 cm x 20 cm	> 15 cm x 7,5 cm	5,0 cm x 3,0 cm
Peso	> 1 kg	> 1 kg	> 100 g	< 10 g
Pode ser alimentado com bateria	NÃO	NÃO	SIM	SIM
Custo	US\$ 10 + Laptop	US\$ 10 +Laptop	> US\$ 100	< US\$ 10
Número de Subportadoras	30	56	128	64
Resolução	8	11	32	8
Nível de Implementação	Kernel	Kernel	WiFi Chip Firmware	Usuário
Tamanho do Código Fonte (Quantidade de Linhas)	2 M	2 M	1 M, 60 k Especifico para CSI	1 k
Amostragem (Frames por segundo)	Até 1.000	Até 1.000	Até 1.000	Até 650
RAM	8 GB+	8 GB+	1 – 4 GB	500 k – 4 MB
Antenas	3	3	1	1 (2 – 16 através de chave)
TensorFlow	Full	Full	Lite	Full/Lite

Fonte: Adaptada de Hernandez e Bulut (2020, p. 3).

Neste comparativo, exposto na Tabela 1, é possível ver que a ESP32 leva vantagem em relação aos demais hardwares citados nos quesitos tamanho e peso (a ESP32 é menor e mais leve), nível de implementação, custo e possibilidade de coletar dados CSI sem o uso conjunto de um computador. Por outro lado, o ESP32 possui menos memória RAM e menor velocidade de obtenção de dados pela interface serial (HERNANDEZ; BULUT, 2020).

Um dado exposto em Hernandez e Bulut (2020) que também foi fundamental para a escolha da ESP32 foi o fato de que até o ano de publicação do artigo, não tinha sido possível encontrar trabalhos publicados que usassem este dispositivo, o que consequentemente acaba atribuindo uma relevância em termos de inovação a trabalhos que venham a usar esta plataforma.

Uma vez definido o dispositivo Wi-Fi a ser usado, foi necessário escolher um *firmware* que pudesse acessar os dados coletados e transmiti-los pela porta serial para serem lidos em um computador.

3.3 ESCOLHA DO FIRMWARE A SER USADO

Como o foco da pesquisa não é a obtenção dos dados CSI, mas o processamento deste tipo de dado, procurou-se por ferramentas prontas para realizar a aquisição dos dados. Nesta busca pode-se perceber a notoriedade do pesquisador Steven M. Hernandez da Virginia Commonwealth University, já que o autor recentemente tem focado na pesquisa de sensoriamento Wi-Fi através do uso da plataforma ESP32 e publicado vários trabalhos a este respeito. Por consequência, ele tem alcançado destaque dentro desta temática, até pelo fato de ainda ser um tópico pouco explorado.

Uma das contribuições do autor é um *firmware* que permite a coleta de dados CSI da ESP32 e os escreve na porta serial. O pesquisador disponibilizou o programa denominado CSI Toolkit em uma plataforma de hospedagem de códigos fonte, chamada GitHub, para que outros usuários pudessem utilizar e, conseqüentemente, ajudar a desenvolver novos avanços dentro desta temática de pesquisa (HERNANDEZ, [2022?]).

Não obstante, foi cogitado outro *firmware* para ser usado, o disponibilizado pela própria Espressif, fabricante do ESP32. Contudo, não foi possível encontrar outros trabalhos que usassem este código. Em contrapartida, no próprio GitHub é possível encontrar indivíduos que, não somente usaram o *firmware* desenvolvido por Hernandez ([2022?]), como também produziram códigos que realizam a plotagem gráfica dos dados coletados baseados na sintaxe de escrita dos dados de saída deste algoritmo como Forbes ([2022?]) e o trabalho publicado por Citysu ([2022?]).

Após a definição sobre como os dados CSI são obtidos e a sintaxe utilizada, prossegue-se para a etapa de pré-processamento, contemplada no subtópico 3.4.


3.4 COLETA DE DATASETS

O sensoriamento através de CSI, com ESP32, exige – no mínimo – dois dispositivos: um *active station* e um *access point*. Neste enlace, o *access point* funciona como transmissor e o *active station* como receptor, e é a unidade receptora a responsável por transmitir (ou gravar) os dados CSI coletados pela porta serial.

As coletas dos *datasets* usados no trabalho foram realizadas em um corredor entre os pavilhões do prédio C02 da Universidade do Vale do Rio dos Sinos. Este local foi escolhido por oferecer uma área ampla e ter uma calçada com pedras quadradas que foram usadas como uma matriz. Dessa forma, o experimento desenvolvido torna-se facilmente replicável.

No chão do corredor, foi desenhando com giz coordenadas respectivas à cada uma das pedras da calçada, utilizando as letras de “A” a “F” como linhas e os números de “0” a “23”. A área em que foi realizado o experimento foi dividida em duas zonas de largura idêntica: Zona 1 que abrange dez pedras (dez colunas, de 0 a 9) de comprimento e Zona 2 que ocupa toda as 24. O mapa da área de testes pode ser visualizado na Figura 2.

Figura 2 - Mapa da área de testes



Fonte: Elaborada pelo autor.

Considerando que as pedras possuem 46 cm de lado, a Zona 1 possui 2,76 m de largura e 4,6 m de comprimento. Já a Zona 2 possui 2,76 m de largura e 11,04 m de comprimento. Conforme pode ser verificado na Figura 2, os transceptores ficaram

posicionados nas coordenadas C0 (*active station*), C9 (*access point* para Zona 1) e C23 (*access point* para Zona 2). Também na mesma figura é possível verificar os pontos de medição, que foram realizados nas coordenadas F3 e C6 (para Zona 1) e A10, D10, F12, C14, A16, E17, C19 e B21(para Zona 2).

Os transceptores foram posicionados com a ajuda de tripés, de forma que o *active station* ficou posicionado em uma altura de 1,06 m do solo e o *access point* à 0,6 m – parâmetros definidos com base no experimento de Sandaruwan *et al.* (2021). A área de testes, bem como o posicionamento dos transceptores pode ser visualizada na Figura 3 (Zona 1) e Figura 4 (Zona 2).

Figura 3 - Zona 1



Fonte: Elaborada pelo autor.

Na Figura 3, é possível verificar o posicionamento dos tripés que permite a alocação dos transceptores ao longo do seu corpo, de forma que a face das antenas dos dispositivos ESP32 fiquem de frente, uma para outra.

Figura 4 - Zona 2




Fonte: Elaborada pelo autor.

Na Figura 4, fica visível o acoplamento do ESP32 usado com *active station* ao corpo de um dos tripés. Também é possível visualizar a linha divisória entre as zonas de medição estabelecida por uma fita branca e verificar que o *access point* está na margem da Zona 2.

Para medição foram utilizados dois tipos de corpos, que foram posicionados estaticamente nas coordenadas identificadas na Figura 2: corpos orgânicos e metálicos. Na primeira coleta, realizada em 19 de dezembro de 2022, a temperatura máxima registrada pela estação meteorológica IRSSOLEO2 (IRSSOLEO2, 2023) foi de 28°C e a mínima 16°C. Já a umidade máxima foi de 93% e a mínima de 65%. Neste dia foram utilizados, como alvos de aferição, um indivíduo de 1,9 m de altura e 164 kg de massa corporal como corpo orgânico e uma bobina retangular de 0,25 m de lado e 20 kg de massa, apoiada em uma banqueta metálica de 0,9 m de altura, como objeto metálico. Tais objetos podem ser visualizado na Figura 5 (indivíduo à esquerda e bobina à direita).

Figura 5 - Objetos da primeira coleta



Fonte: Elaborado pelo autor

Na segunda e última coleta realizada em 17 de março de 2023, a temperatura máxima registrada pela estação meteorológica IRSSOLEO2 (IRSSOLEO2, 2023) foi de 34°C e a mínima 22°C. Já a umidade máxima foi de 90% e a mínima 49%. Neste dia foram utilizados, como alvos de aferição, um melão com 1 kg de massa e 0,2 m de diâmetro como objeto orgânico e um *nobreak* de, aproximadamente 180 kg, de dimensões 0,9 x 0,8 x 0,5 m como corpo metálico. Estes objetos podem ser visualizados na Figura 6 (melão à esquerda e *nobreak* à direita).

Figura 6 - Objetos da segunda coleta



Fonte: Elaborada pelo autor.

Um algoritmo simples foi criado para ler os dados presentes na serial do computador, que são escritos pelo *active station*. Através dele, é possível gravar um número determinado de frames e salvá-los em um arquivo de extensão “.csv” para na sequência passarem para as etapas de pré-processamento e processamento.

3.5 ETAPA DE PRÉ-PROCESSAMENTO

Os *frames* de dados coletados e salvos nos arquivos de extensão “.csv” vêm no formato apresentado na Figura 7.

Figura 7 - Composição do frame de dados CSI

POSIÇÃO	1	2	3	4	5	6	7	8	9		
DADO	TYPE	ROLE	MAC	RSSI	RATE	SIG_MODE	MCS	BANDWIDTH	SMOOTHING		
POSIÇÃO	10		11		12	13		14	15		16
DADO	NOT_SOUNDING		AGGREGATION		STBC	FEC_CODING		SGI	NOISE_FLOOR		AMPDU_CNT
POSIÇÃO	17		18			19			20	21	
DADO	CHANNEL		SECONDARY_CHANNEL			LOCAL_TIMESTAMP			ANT	SIG_LEN	
POSIÇÃO	22		23		24			25	26 -154		
DADO	RX_STATE		REAL_TIME_SET		REAL_TIME_STAMP			LEN	CSI_DATA		

Fonte: Elaborada pelo autor.

Após serem coletados, os *datasets* passam - individualmente - por uma etapa de rotulagem, através de um algoritmo simples. De forma que os *datasets* correspondentes a leituras em que há obstrução do enlace recebem o *label* “1”. Já os *datasets* que correspondem a leituras com ambiente livre, recebem o *label* “0”. Os *labels* são escritos na última posição de cada frame para posteriormente serem usados como *target* no treinamento de algoritmos de aprendizado.

Conforme pode ser verificado na Figura 5, os dados CSI ocupam apenas as posições de número 26 em diante. Os demais dados não são usados para o sensoriamento. Por este e outros motivos - como a notação dos CSI e posições não utilizadas -, se faz necessário uma etapa de pré-processamento que é contemplada no algoritmo principal.

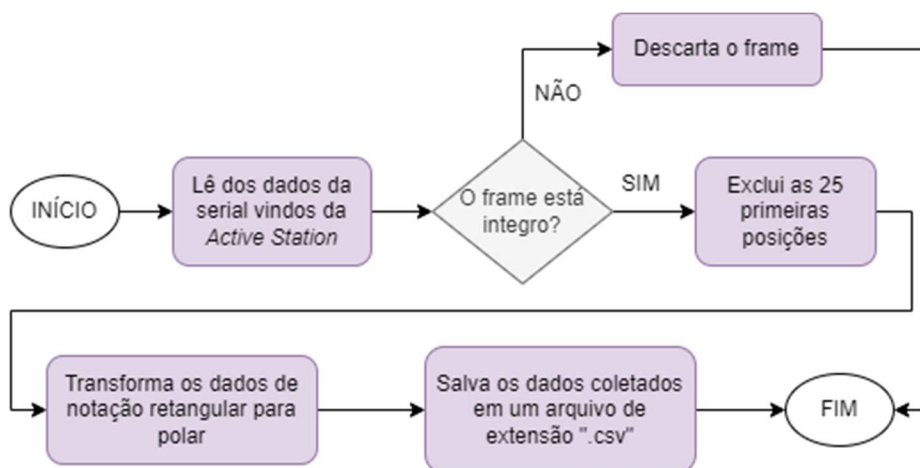
Com a finalidade de tratar os dados que alimentarão a entrada dos algoritmos de aprendizado, são realizadas as seguintes etapas de pré-processamento:

- a) se certificar que os dados estejam íntegros, checando o comprimento do frame. caso o frame não esteja íntegro, ele é ignorado;

- b) deletar os primeiros vinte e cinco dados do frame, pois eles não são relevantes para o processamento dos dados. Apenas o vigésimo sexto dado em diante contém informações de interesse;
- c) realizar a conversão dos dados CSI, de notação retangular para polar;
- d) descartar as posições utilizadas pelas subportadoras não utilizadas pelo CSI, a fim de reduzir processamento na próxima etapa;
- e) realizar operações matemáticas com os *datasets* coletados, tais como mediana e desvio padrão, para realização do *fingerprinting* com a finalidade de remover a influência do ambiente nos sinais coletados com obstrução de enlace;
- f) salvar os *datasets* pré-processados em outros dois arquivos de extensão “.csv”, um para guardar os dados de amplitude e outro de fase.

A sequência lógica de funções realizadas na etapa de pré-processamento é demonstrada na Figura 8.

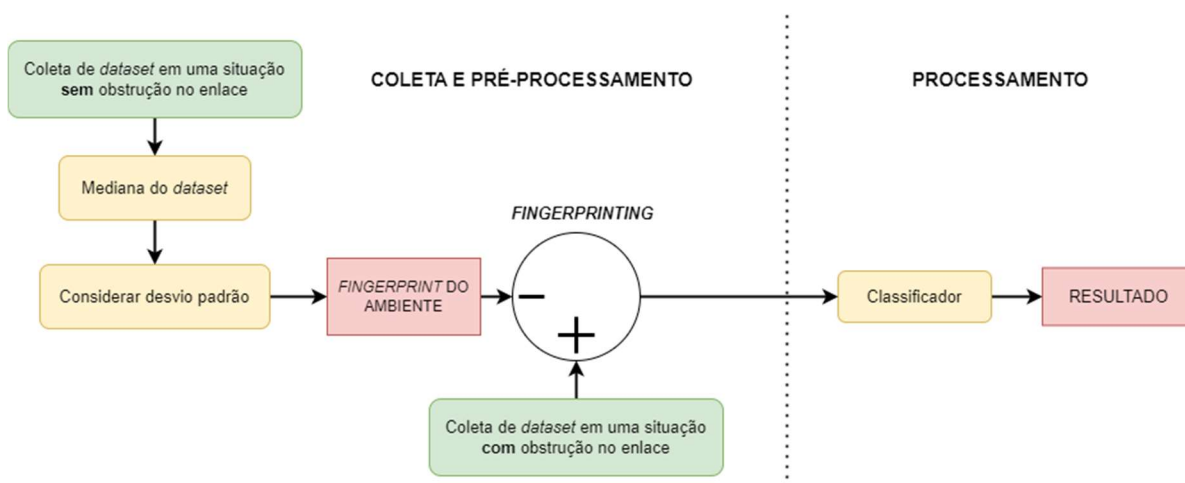
Figura 8 - Etapas de pré-processamento



Fonte: Elaborada pelo autor.

Já as etapas do processo de *fingerprinting* - subtração do *dataset* do ambiente com obstrução pela mediana e desvio padrão do *dataset* com o ambiente vazio - são demonstradas na Figura 9.

Figura 9 - Demonstrativo do processo de *fingerprinting*



Fonte: Elaborada pelo autor.

A premissa da utilização do *fingerprinting* neste trabalho é tentar isolar as características de sinal CSI respectivas aos objetos à serem detectados das características do ambiente, a fim de que o classificador possa ser treinado uma única vez para ser aplicado em qualquer ambiente.

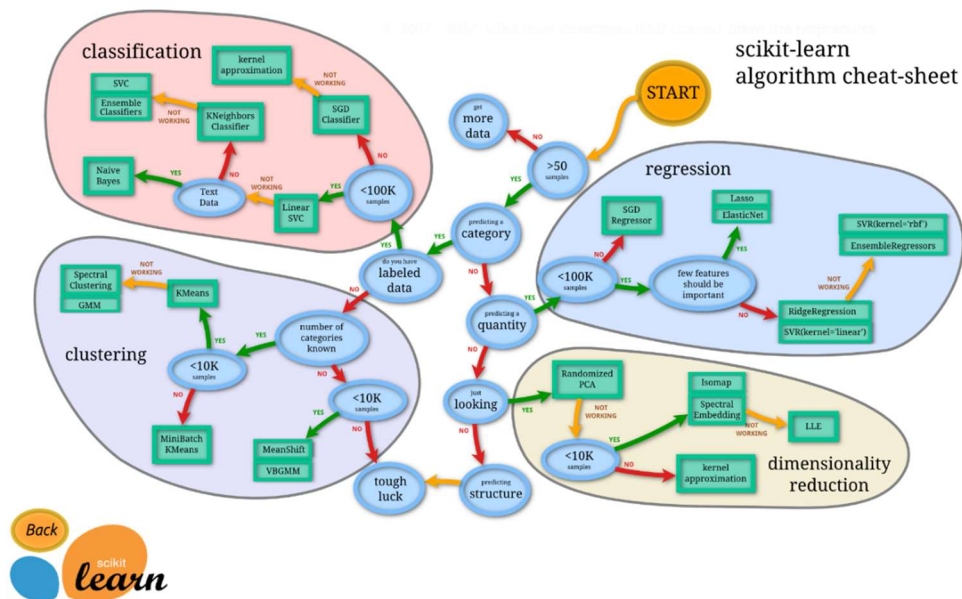
Tendo os dados já tratados pela etapa de pré-processamento, pode-se alimentar o algoritmo de aprendizado para realizar o processamento. No tópico seguinte, apresenta-se o processo de escolha da biblioteca e do tipo de algoritmo de aprendizado.

3.6 ESCOLHA DE BIBLIOTECA E DO TIPO DE ALGORITMO DE APRENDIZADO DE MÁQUINA PARA O PROCESSAMENTO DE DADOS

Nos trabalhos pesquisados, é possível ver uma concordância entre autores de trabalhos diferentes em 2.2.3 e 2.2.5 de que entre os métodos de aprendizado de máquina, as redes neurais de convolução 1D tiveram os resultados mais satisfatórios. Além disso, em unanimidade, os trabalhos pesquisados utilizam a biblioteca Tensor Flow.

Foi decidido utilizar a biblioteca Scikit Learn, pois ela possui uma abordagem mais amigável e um material de apoio extremamente completo. Na própria página da plataforma, também é possível encontrar um mapa para auxiliar - exposto na Figura 10 - na escolha do algoritmo baseado no objetivo almejado e dos tipos de dados.

Figura 10 - Mapa auxiliar para escolha de algoritmo



Fonte: Scikit Learn ([2022?]).

Dentre os tipos de filosofia de aprendizado de máquina apresentados na Figura 10, o objetivo do trabalho se encaixa como “Classificação”, já que se pretende analisar os *frames* de dados CSI e estimar se tal amostra corresponde a um momento em que houve movimento dentro do ambiente ou não. Como são usados menos de cem mil amostras e não são analisados textos, foi escolhido testar os seguintes algoritmos: *Linear SVC*, *KNeighbors Classifiers* e *Ensemble Classifiers*.

Além disso, também é analisado o algoritmo de aprendizado MLP, que foi amplamente usado nos trabalhos citados em 2.2. Foi escolhido testar o algoritmo *Random Forrest* por pertencer a categoria *Ensemble Classifier* proposta no mapa da Figura 10. O algoritmo CNN, apesar de ser também muito citado nos trabalhos relacionados em 2.2, não será testado, uma vez que demanda mais processamento.

3.7 PARÂMETROS DE PROCESSAMENTO

Foi determinada a utilização de 80% dos *datasets* para a parte de treino e 20% para a parte de teste. Além disso, foi feito uso de validação cruzada, com a finalidade de ter uma generalização de padrão.

No algoritmo Random Forrest, foram utilizadas 100 “árvores” ou estimadores. Já no *kNN* foram utilizados cinco vizinhos. A chave de ativação que foi usada no algoritmo MLP foi a “relu” e o *kernel* escolhido para usar no SVC foi o “rbf”.

3.8 MÉTODOS DE ANÁLISE DOS TESTES

São utilizados os métodos tradicionais de análise de performance dos algoritmos como precisão, acurácia, recuperação e F1-score. Além disso, em todas as medições será calculado o coeficiente *kappa* de Cohen para avaliar o nível de concordância entre os resultados da matriz de confusão. Outrossim, em medições de maior relevância, é traçada a curva ROC (*Receiver Operating Characteristic Curve*) a fim de obter o valor de AUC (*Area Under the ROC Curve*) que permite identificar quão bem o modelo usado consegue diferenciar verdadeiros positivos e verdadeiros negativos.

Serão considerados resultados aceitáveis com acurácia maior do que 89%, pois esta é a pior acurácia registrada entre os melhores resultados entre os trabalhos correlatos (melhor acurácia registrada em 2.2.4). Será considerada aceitável a confiabilidade dos dados com valor de *kappa* de Cohen superiores a 0,8.

4 ESTUDO DE CASO

Nesta seção são apresentados os resultados da etapa de processamento com os *datasets* coletados nas duas instâncias relatadas em 3.4 em cada uma das situações de teste realizadas e um placar geral tendo como princípio avaliativo a métrica F1-score que proporciona uma média harmônica entre precisão e recuperação, dando ênfase para os verdadeiros positivos - evitando assim, uma disparidade no caso de um grande volume de verdadeiros negativos em relação aos verdadeiros positivos. Consequente, é realizada uma comparação com os trabalhos correlatos e uma avaliação do desempenho dos algoritmos.

4.1 RESULTADOS DOS TESTES

Nesta subseção são apresentados os resultados em cada situação de teste através de quadros que contemplam – além da matriz de confusão – os resultados de acurácia, precisão, recuperação, F1-score e kappa de Cohen, com uma subsequentemente avaliação respectiva. Ressalta-se que os valores apresentados representam a média da validação cruzada.

4.1.1 Teste na Zona 1 com objetos mistos - primeira coleta

Primeiramente foram realizados testes na Zonas 1 e 2 com objetos mistos da primeira coleta (indivíduo e bobina) nas coordenadas F3 e C6, tentando diferenciá-los do ambiente vazio. Os resultados são apresentados no Quadro 3.

Quadro 3 - Resultados do teste na Zona 1 com objetos mistos

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	820	774	4	0	0,9974	0,9951	1	0,9975	0,9949
KNN	816	695	87	1	0,9449	0,9036	0,9987	0,9488	0,8896
MLP	817	779	3	0	0,9981	0,9963	1	0,9981	0,9962
SVC	820	777	1	0	0,9993	0,9987	1	0,9993	0,9987

Fonte: Elaborado pelo autor.

É notável que os algoritmos de processamento foram capazes de diferenciar o ambiente vazio do ambiente com obstrução do enlace com resultados bem acima do aceitável na Zona 1.

4.1.2 Teste na Zona 2 com objetos mistos - primeira coleta

Em um segundo momento, foram realizados testes na Zona 2 com objetos mistos da primeira coleta (indivíduo e bobina) posicionados em F12, C14, C19 e A16. Neste teste, o objetivo também era diferenciar o ambiente vazio do ambiente com os objetos presentes. Os resultados aferidos podem ser visualizados no Quadro 4.

Quadro 4 - Resultados do teste na Zona 2 com objetos mistos

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	807	776	11	6	0,9893	0,9865	0,9926	0,9895	0,9787
KNN	808	712	75	5	0,95	0,915	0,9938	0,9528	0,8998
MLP	810	771	16	3	0,9881	0,9806	0,9963	0,9884	0,9762
SVC	810	779	8	3	0,9931	0,9902	0,9963	0,9932	0,9862

Fonte: Elaborado pelo autor.

Os resultados demonstrados no Quadro 4 - assim como no Quadro 3 - demonstram que é possível detectar a presença dos objetos no ambiente, à medida que é factível a diferenciação entre o ambiente vazio e o ambiente com objetos posicionados. Além disso, é notável que, nas duas instâncias, o kNN destoou dos demais algoritmos com um desempenho visivelmente inferior - não obstante aceitável. Outrossim, os resultados na Zona 1 (Quadro 3) foram superiores ao da Zona 2 (Quadro 4).

4.1.3 Primeiro teste do *fingerprinting*

Usou-se o arquivo de treinamento gerado em 4.1.1 (Zona 1) para diferenciar o ambiente com objetos posicionados nas coordenadas utilizadas em 4.1.2 (Zona 2) do respectivo ambiente (Zona 2) vazio. Os resultados desta aferição são demonstrados no Quadro 5.

Quadro 5 - Resultados do primeiro teste do *fingerprinting*

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	567	692	95	246	0,7868	0,8564	0,6974	0,7688	0,5749
KNN	753	492	295	492	0,6126	0,7185	0,6048	0,6567	0,2198
MLP	699	231	556	231	0,5416	0,5569	0,7516	0,6398	0,0466
SVC	683	623	164	130	0,8162	0,8063	0,84	0,8228	0,6321

Fonte: Elaborado pelo autor.

Verifica-se que não há nenhum resultado de acurácia considerada aceitável, demonstrando desempenho bem inferior em relação ao teste em 4.1.1, em que se treinou e testou o algoritmo para Zona 1. Além disso, os dados demonstram uma confiabilidade pobre, não aceitável.

4.1.4 Segundo teste do *fingerprinting*

Na sequência, usou-se o arquivo de treinamento gerado em 4.1.2 (Zona 2) para diferenciar o ambiente com objetos posicionados nas coordenadas utilizadas em 4.1.1 (Zona 1) do respectivo ambiente (Zona 1) vazio. A apuração desta aferição é demonstrada no Quadro 6.

Quadro 6 - Resultados do segundo teste do *fingerprinting*

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	817	36	746	0	0,5334	0,5227	1	0,6865	0,0469
KNN	817	11	771	0	0,5178	0,5144	1	0,6794	0,0143
MLP	816	9	773	1	0,5159	0,5135	0,9987	0,6783	0,0105
SVC	817	67	715	0	0,5528	0,5332	1	0,6956	0,0873

Fonte: Elaborado pelo autor.

A partir dos testes realizados para analisar a funcionalidade do *fingerprinting*, verificou-se um péssimo desempenho, se comparado aos outros testes, principalmente quando se usou o treinamento da Zona 2 para aplicar na Zona 1 (Quadro 6). Quando foi utilizando o treinamento da Zona 1 para aplicar na Zona 2

(Quadro 5) obteve-se um resultado pouco melhor. A confiabilidade dos dados, indicado pelo coeficiente kappa de Cohen em 4.1.4 é ainda menor do que em 4.1.3.

4.1.5 Teste na Zona 1 com objeto orgânico - primeira coleta

Com o objetivo de analisar o impacto dos tipos de material no sensoriamento Wi-Fi, foram realizados testes com objetos orgânico e metálico de maneira individualizada. Novamente posicionou-se o indivíduo nas coordenadas C6 e F3 e os resultados desta aferição podem ser verificados no Quadro 7.

Quadro 7 - Resultados do teste com o indivíduo na Zona 1

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	414	385	0	1	0,9987	1	0,9975	0,9987	0,9974
KNN	414	381	4	1	0,9937	0,9904	0,9975	0,9939	0,9874
MLP	415	385	0	0	1	1	1	1	1
SVC	415	385	0	0	1	1	1	1	1

Fonte: Elaborado pelo autor.

É notável um desempenho quase perfeito dos algoritmos para detectar o indivíduo na Zona 1. Apenas o *Random Forrest* e kNN que falharam em alguma predição.

4.1.6 Teste na Zona 1 com objeto metálico - primeira coleta

Depois de realizar o teste com o objeto orgânico na Zona 1, agora observa-se o desempenho dos algoritmos de detectar a bobina neste ambiente nas coordenadas C6 e F3 que pode ser analisado a partir dos resultados presentes no Quadro 8.

Quadro 8 - Resultados do teste com a bobina na Zona 1

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	428	366	3	2	0,9937	0,993	0,9953	0,9941	0,9874
KNN	430	217	152	0	0,8097	0,7388	1	0,8498	0,6057
MLP	429	366	3	1	0,9949	0,993	0,9976	0,9953	0,9899
SVC	429	369	0	1	0,9987	1	0,9976	0,9988	0,9974

Fonte: Elaborado pelo autor.

Nota-se que também há grande assertividade na detecção da bobina na Zona 1, mas os algoritmos tiveram um desempenho superior ao detectar o indivíduo nesta zona.

4.1.7 Teste na Zona 2 com objeto orgânico - primeira coleta

Na sequência, repetiu-se os testes com os objetos orgânico e metálico de maneira individualizada, mas agora na Zona 2, nas coordenadas C14, D10, A16 e F12. Os resultados deste teste podem ser verificados no Quadro 9.

Quadro 9 - Resultados do teste com o indivíduo na Zona 2

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	788	776	11	25	0,9775	0,9862	0,9692	0,9776	0,955
KNN	809	709	78	4	0,9487	0,912	0,995	0,9517	0,8973
MLP	806	769	18	7	0,9843	0,9781	0,9913	0,9847	0,9687
SVC	807	780	7	6	0,9918	0,9914	0,9926	0,992	0,9837

Fonte: Elaborado pelo autor.

É nítido que os algoritmos de aprendizado tiveram um desempenho melhor na Zona 1 para detectar o indivíduo, não obstante, os algoritmos obtiveram um desempenho bem acima do aceitável na Zona 2.

4.1.8 Teste na Zona 2 com objeto metálico - primeira coleta

Consequente, é possível verificar os resultados do teste de detecção da bobina na Zona 2, nas coordenadas C14, D10, A16 e F12.

Quadro 10 - Resultados do teste com a bobina na Zona 2

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	605	589	2	4	0,995	0,9967	0,9934	0,995	0,9899
KNN	609	588	3	0	0,9975	0,995	1	0,9975	0,9949
MLP	609	588	3	0	0,9975	0,995	1	0,9975	0,9949
SVC	609	590	1	0	0,9991	0,9983	1	0,9991	0,9983

Fonte: Elaborado pelo autor.

Nota-se que na Zona 2 é mais fácil detectar a bobina do que o indivíduo. Inclusive, em termos de acurácia, houve um desempenho melhor na detecção da massa metálica na Zona 2 do que na Zona 1. Por outro lado, foi mais fácil detectar o indivíduo na Zona 1.

4.1.9 Diferenciação entre ambientes vazios em circunstâncias diferentes

Foi realizado um teste para verificar o impacto das variáveis climáticas no sensoriamento Wi-Fi, utilizando sinal CSI. Para isso, rotulou-se a coleta de ambiente vazio realizada no mês de março com *label* “1”, como se fosse uma leitura com obstrução do enlace. Dessa forma, os algoritmos de aprendizado deveriam distinguir o ambiente vazio coletado em dezembro de 2022 com o de março de 2023.

Para o teste, cujos resultados são demonstrados no Quadro 11, usou-se coletas na Zona 1.

Quadro 11 - Resultados do teste de diferenciação de ambientes

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	814	784	0	2	0,9987	1	0,9975	0,9987	0,9974
KNN	814	786	0	0	1	1	1	1	1
MLP	814	786	0	0	1	1	1	1	1
SVC	814	786	0	0	1	1	1	1	1

Fonte: Elaborado pelo autor.

É perceptível que houve uma assertividade quase que perfeita na distinção entre os dois ambientes. Sendo assim, entende-se que há grande impacto das variáveis climáticas neste tipo de sensoriamento em conformidade com Dikun *et al.*(2015) que expõem a influência da umidade relativa do ar e da temperatura em campos magnéticos. Pois, de fato, há diferença de temperatura de 6 °C entre os registros - tanto de temperatura máxima quanto mínima registradas - da coleta de dezembro de 2022 para a coleta realizada em março do ano seguinte, sendo que em março estava mais quente. Outrossim, o ambiente em dezembro estava mais úmido (diferença de 16% de umidade relativa do ar na umidade mínima registrada e 3% na máxima).

Por este ser um teste ímpar para a pesquisa, uma vez que demonstra o impacto na mudança climática para as aferições, foi traçada a curva ROC a fim de evidenciar

a AUC de valor “1,0”. Isso significa que houve grande sensibilidade e especificidade quanto a predição realizada.

4.1.10 Teste na Zona 1 com objeto orgânico - segunda coleta

Em março de 2023 foi realizada uma nova remessa de coletas de dados com novos objetos. Agora, como objeto orgânico, foi escolhido um melão por ter massa e área significativamente menor que o indivíduo (objeto orgânico da primeira coleta) e um *nobreak*, por ser um objeto metálico de massa e área significativamente maior que a bobina (objeto metálico da primeira coleta).

Também foram realizadas coletas dos ambientes vazios, sem nenhuma obstrução de enlace, com a finalidade de formar um *dataset* híbrido de ambiente vazio, misturando a coleta de dezembro de 2022 com a de março de 2023.

Os resultados expostos no Quadro 12 são referentes ao teste com o melão posicionado nas coordenadas C6 e F3, na Zona 1.

Quadro 12 - Teste com o melão - Zona 1

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	415	385	0	0	1	1	1	1	1
KNN	415	385	0	0	1	1	1	1	1
MLP	415	385	0	0	1	1	1	1	1
SVC	415	385	0	0	1	1	1	1	1

Fonte: Elaborado pelo autor.

Percebe-se que, os algoritmos de processamento não erraram nenhuma vez ao diferenciar o ambiente vazio, do ambiente com o melão posicionado.

4.1.11 Teste na Zona 1 com objeto metálico - segunda coleta

Na sequência reproduziu-se o teste de 4.1.10, mas com o objeto metálico - o *nobreak*. Os resultados desta aferição podem ser visualizados no Quadro 13.

Quadro 13 - Teste com o *nobreak* na Zona 1

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	414	384	1	1	0,9975	0,9975	0,9975	0,9975	0,9949
KNN	415	384	1	0	0,9987	0,9975	1	0,9987	0,9974
MLP	415	384	1	0	0,9987	0,9975	1	0,9987	0,9974
SVC	415	385	0	0	1	1	1	1	1

Fonte: Elaborado pelo autor.

É notável o desempenho quase perfeito dos algoritmos de processamento ao realizar a predição da presença do *nobreak*. Contudo, percebe-se que houve maior dificuldade em detectar este objeto metálico do que o melão.

4.1.12 Teste na Zona 2 com objeto orgânico - segunda coleta

Agora são demonstrados os testes com os objetos da segunda coleta na Zona 2. No Quadro 14, apresenta-se os resultados dos testes com o melão nas coordenadas A16 e D10.

Quadro 14 - Teste com o melão na Zona 2

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	415	384	0	0	1	1	1	1	1
KNN	415	384	0	0	1	1	1	1	1
MLP	414	383	1	1	0,9974	0,9975	0,9975	0,9975	0,9949
SVC	415	384	0	0	1	1	1	1	1

Fonte: Elaborado pelo autor.

Verifica-se que na Zona 2 também houve assertividade quase impecável com, no máximo, duas predições erradas no pior dos casos (algoritmo MLP) para predizer a presença do melão no ambiente. Todavia, a assertividade na Zona 1 foi ainda maior.

4.1.13 Teste na Zona 2 com objeto metálico - segunda coleta

Na sequência, foi reproduzido o teste de 4.1.12 com o objeto metálico – o *nobreak*. Os resultados desta aferição são expostos no Quadro 15.

Quadro 15 - Teste com o *nobreak* na Zona 2

Algoritmos	VP	VN	FP	FN	Acurácia	Precisão	Recuperação	F1-score	Kappa de Cohen
Random Forrest	422	378	0	0	1	1	1	1	1
KNN	422	373	5	0	0,9937	0,9882	1	0,9941	0,9874
MLP	422	376	0	2	0,9975	1	0,9952	0,9976	0,9949
SVC	422	378	0	0	1	1	1	1	1

Fonte: Elaborado pelo autor.

Novamente, nota-se grande assertividade (cinco erros no pior dos casos) com a segunda remessa de *datasets* coletados. Ainda assim, é evidente que a pior predição realizada com os *datasets* coletados em dezembro de 2023 foi com o objeto metálico na Zona 2.

4.2 MÉDIA DOS RESULTADOS E COMPARAÇÃO COM TRABALHOS CORRELATOS

Nesta subseção é apresentada o Quadro 16 que contempla o rendimento médio (média aritmética) de cada um dos algoritmos conforme a métrica F1-score.

Quadro 16 - Média dos resultados

Random Forrest	KNN	MLP	SVC
0,9541	0,9248	0,9443	0,9616

Fonte: Elaborado pelo autor.

Considerando os valores apresentados no Quadro 16, observa-se que SVC teve o melhor desempenho, seguido de *Random Forrest*, MLP e kNN.

Apesar de os trabalhos correlatos listados em 2.2 terem propostas de aplicações diferentes e utilizando outros algoritmos de aprendizado, é razoável uma comparação com os resultados da pesquisa aqui proposta. Em 2.2.1, relata-se a ocorrência de 95,6% de acurácia como caso de melhor desempenho na detecção de movimento humano em um ambiente fechado usando o algoritmo DNN. Já em 2.2.3, é verificado o resultado de 99,98% de acurácia na detecção de uma pessoa dentro de um ambiente fechado. No trabalho exposto em 2.2.4 é alcançada a acurácia máxima de 89% para reconhecimento do movimento de queda humana. E, ainda em 2.2.5 o resultado de maior acurácia foi de 98% para contagem de até 12 pessoas com o algoritmo 1D-ConvNet e 97% com MLP.

Na primeira coleta realizada, a pior acurácia registrada na detecção de objetos mistos (3.9.1.1 e 3.9.1.2) foi de 94,49% com o algoritmo kNN enquanto os outros algoritmos demonstraram acurácia superior a 98%.

Os testes do *fingerprinting* (4.1.3 e 4.1.4) demonstraram uma acurácia muito abaixo do aceitável, uma vez que a melhor acurácia registrada foi de 81,62% com o algoritmo SVC.

Ainda na primeira coleta, a pior acurácia contabilizada para detectar o objeto metálico foi de 80,97%, na Zona 1 e com o algoritmo kNN. Os demais algoritmos desempenharam a predição com acurácia superior a 99%. Já na detecção de objetos orgânicos, a menor acurácia aferida foi de 94,87% com o kNN na Zona 2, enquanto os demais algoritmos desempenharam a predição com acurácia de valor superior a 97%.

Na diferenciação entre os ambientes (4.1.9) a pior acurácia aferida foi de 99,87% com o algoritmo kNN, enquanto todos os outros algoritmos apresentaram resultados de 100%. Nos demais testes da segunda coleta (4.1.10, 4.1.11, 4.1.12 e 4.1.13) a pior acurácia registrada foi de 99,37% - um valor altíssimo comparado ao desempenho dos demais testes realizados neste trabalho e com os trabalhos correlatos.

Além disso, nos testes realizados neste trabalho garante-se que houve uma generalização de padrão, pois foi utilizado de validação de cruzada na etapa de processamento. E, através da exposição do coeficiente kappa de Cohen, é demonstrado que os testes que apresentaram grande assertividade de predição contaram com alta concordância entre os resultados da matriz de confusão

Dessa forma, entende-se que a pesquisa proposta demonstrou resultados tão bons ou melhores que as aferições dos trabalhos correlatos, conforme a métrica da acurácia.

4.3 AVALIAÇÃO DO DESEMPENHO DOS ALGORITMOS DE APRENDIZADO UTILIZADOS

Nos resultados apresentados em 4.1, é nítido que - com exceção dos testes de *fingerprinting* (4.1.3 e 4.1.5) – em apenas uma hipótese (algoritmo kNN em 4.1.6) registrou desempenho abaixo do aceitável para detecção de presença de objetos em ambientes fechados. Entende-se, portanto que todos os algoritmos testados apresentaram resultados satisfatórios e podem ser considerados como opções viáveis para processar dados de sensoriamento Wi-Fi com sinal CSI.

5 CONCLUSÃO

O presente trabalho teve êxito em cumprir o objetivo geral proposto em 1.1.1 de detectar presença dentro de um ambiente fechado através do uso do sensoriamento Wi-Fi com o uso do sinal CSI.

Pelos resultados obtidos foi possível verificar que é plenamente factível a detecção de presença de objetos orgânicos e metálicos. Não foi possível verificar alguma discrepância no desempenho de detecção de um em relação ao outro. Nem mesmo a área dos objetos teve um impacto significativo. Contudo, é perceptível a influência da densidade dos materiais neste tipo de sensoriamento já que os objetos com maior densidade (o indivíduo e o *nobreak*) tiveram resultados inferiores na Zona 1 - que foi a menor zona de sensoriamento em relação aos objetos de menor densidade (o melão e a bobina). Provavelmente, isso deve ao fato de que em ambientes menores o enlace tende a ficar poluído e menos estável, e um objeto de maior densidade tende a intensificar este efeito.

Percebeu-se que a técnica de *fingerprinting* é afetada significativamente com a mudança de ambientes. Não foi possível isolar as características das obstruções do enlace e aplicar em ambientes distintos. Além disso, as características climáticas também causam um impacto expressivo neste tipo de sensoriamento. Mesmo planejando um cenário de medições de fácil reprodução, as medições em dias diferentes mostraram grandes discrepâncias.

Através desta pesquisa foi possível identificar algumas limitações deste tipo de sensoriamento, como a necessidade de calibração do *fingerprint* para cada ambiente diferente e, até mesmo, para uso no mesmo ambiente conforme alterações nas condições climáticas. Além disso, é notável que objetos de grande densidade obstruindo o enlace podem causar desorganização no sinal e afetar o desempenho do sensoriamento. Outrossim, o sensoriamento em ambientes muito pequenos pode sofrer perda de desempenho em relação a zonas mais amplas justamente pela tendência de poluir o sinal, devido à proximidade excessiva entre os transceptores.

A pesquisa desenvolvida aborda uma temática escassamente explorada e ainda há poucas publicações explorando este tipo de sensoriamento. Uma grande evidência disso é que, até a data de publicação deste trabalho, não foram encontradas publicações sobre o assunto na América Latina.

O trabalho apresenta uma proposta diferente dos trabalhos correlatos, à medida tenciona identificar uma variedade de materiais e entender as limitações deste tipo aplicação. Além disso traz consigo uma contribuição singular: um *setup* de testes bem dimensionado e documentado, de fácil reprodução, a fim de que outros pesquisadores possam repetir o experimento em outras áreas, mantendo os padrões de medição.

A maneira como os resultados são expostos também é inovadora, em relação aos trabalhos correlatos, uma vez que são utilizadas diversas métricas de avaliação enquanto os outros trabalhos apresentam apenas a matriz de confusão com a acurácia aferida.

Uma outra contribuição relevante do presente trabalho é a avaliação do impacto das condições climáticas - e a documentação das condições no dia da coleta - no sensoriamento Wi-Fi com sinal CSI e o apontamento da necessidade de calibração das medidas conforme mudanças no ambiente e no clima. Além disso, foi avaliado que a técnica de *fingerprinting* é deveras afetada com a mudança de ambiente e não é factível isolar as características do objeto de obstrução do enlace das características do ambiente.

Como continuidade desta pesquisa, elenca-se as seguintes propostas de trabalho:

- a) realizar a calibração automática para verificar melhorias no processo de *fingerprinting*;
- b) identificar a posição de objetos;
- c) identificar tipos de materiais de determinados objetos;
- d) realizar o rastreamento de objetos.

REFERÊNCIAS

- CHOOSING THE RIGHT ESTIMATOR — SCIKIT-LEARN 1.1.2 DOCUMENTATION. [S. l.], [s. d.]. Disponível em: https://scikit-learn.org/stable/tutorial/machine_learning_map/index.html. Acesso em: 8 ago. 2022.
- CITYSU/CSIREAD: A FAST CHANNEL STATE INFORMATION PARSER FOR INTEL, ATHEROS, NEXMON, ESP32 AND PICOSCENES. [S. l.], [s. d.]. Disponível em: <https://github.com/citysu/csiread>. Acesso em: 3 set. 2022.
- DIKUN, Jelena *et al.* Effects of weather conditions on electromagnetic field parameters. *In:* , 2015. **2015 10th International Conference on Ecological Vehicles and Renewable Energies, EVER 2015**. [S. l.: s. n.], 2015. Disponível em: <https://doi.org/10.1109/EVER.2015.7112935>
- FORBES, G. **Gi-z/CSKit: Python CSI processing and visualisation tools for Atheros, Intel, Nexmon, ESP32, and PicoScenes (USRP, etc) formats**. [S. l.], [s. d.]. Disponível em: <https://github.com/Gi-z/CSKit>. Acesso em: 3 set. 2022.
- FORECAST FOR SAO LEOPOLDO, BR. [S. l.], 2023. Disponível em: <https://www.wunderground.com/dashboard/pws/IRSSOLEO2/graph/2023-03-17/2023-03-17/daily>.
- FORECAST FOR SAO LEOPOLDO, BR. [S. l.], 2023. Disponível em: <https://www.wunderground.com/dashboard/pws/IRSSOLEO2/graph/2022-12-19/2022-12-19/daily>.
- GÉRON, Aurélien. **Hands-on Machine Learning**. [S. l.: s. n.], 2017. ISSN 1098-6596.v. 53
- HERNANDEZ, Steven M. **GitHub - StevenMHernandez/ESP32-CSI-Tool: Extract Channel State Information from WiFi-enabled ESP32 Microcontroller. Active and Passive modes available. (https://stevenmhernandez.github.io/ESP32-CSI-Tool/)**. [S. l.], [s. d.]. Disponível em: <https://github.com/StevenMHernandez/ESP32-CSI-Tool>. Acesso em: 3 ago. 2022.
- HERNANDEZ, Steven M.; BULUT, Eyuphan. Adversarial Occupancy Monitoring using One-Sided Through-Wall WiFi Sensing. *In:* , 2021. **IEEE International Conference on Communications**. [S. l.: s. n.], 2021. Disponível em: <https://doi.org/10.1109/ICC42927.2021.9500267>
- HERNANDEZ, Steven M.; BULUT, Eyuphan. Lightweight and Standalone IoT Based WiFi Sensing for Active Repositioning and Mobility. **Proceedings - 21st IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks, WoWMoM 2020**, [s. l.], p. 277–286, 2020. Disponível em: <https://doi.org/10.1109/WoWMoM49955.2020.00056>
- HERNANDEZ, Steven M.; ERDAG, Deniz; BULUT, Eyuphan. Towards dense and scalable soil sensing through low-cost WiFi sensing networks. **Proceedings - Conference on Local Computer Networks, LCN**, [s. l.], v. 2021-Octob, p. 549–556, 2021. Disponível em: <https://doi.org/10.1109/LCN52139.2021.9525003>

HSIEH, Chaur Heh; CHEN, Jen Yang; NIEN, Bo Hong. Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information. **IEEE Access**, [s. l.], v. 7, p. 33256–33267, 2019. Disponível em: <https://doi.org/10.1109/ACCESS.2019.2903487>

HU, Haifeng. Enhanced gabor feature based classification using a regularized locally tensor discriminant model for multiview gait recognition. **IEEE Transactions on Circuits and Systems for Video Technology**, [s. l.], v. 23, n. 7, p. 1274–1286, 2013. Disponível em: <https://doi.org/10.1109/TCSVT.2013.2242640>

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO); INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC); INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS (IEEE). **International Standard ISO/IEC/IEEE: 8802-11**: 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. Geneva: ISO: IEC; New York: IEEE, 2012. Disponível em: <https://standards.ieee.org/ieee/8802-11/11064/>. Acesso em: 5 maio 2023. 8802-11:2012, ISO/IEC/IEEE. INTERNATIONAL STANDARD ISO / IEC / IEEE Telecommunications and information. [s. l.], v. 2012, 2012.

JAN, Muhammad Zohaib; VERMA, Brijesh. A Novel Diversity Measure and Classifier Selection Approach for Generating Ensemble Classifiers. **IEEE Access**, [s. l.], v. 7, 2019. Disponível em: <https://doi.org/10.1109/ACCESS.2019.2949059>

MA, Yongsen; ZHOU, Gang; WANG, Shuangquan. WiFi sensing with channel state information: A survey. **ACM Computing Surveys**, [s. l.], v. 52, n. 3, 2019. Disponível em: <https://doi.org/10.1145/3310194>

MBAABU, Onesmus. **Introduction to Random Forest in Machine Learning**. [S. l.], 2020. Disponível em: <https://www.section.io/engineering-education/introduction-to-random-forest-in-machine-learning/>.

MISHRA, Subhash; N. YADAV, R.; P. SINGH, R. A Survey on Applications of Multi Layer Perceptron Neural Networks in DOA Estimation for Smart Antennas. **International Journal of Computer Applications**, [s. l.], v. 83, n. 17, p. 22–28, 2013. Disponível em: <https://doi.org/10.5120/14670-2998>

PACELLI, Rubem Vasconcelos; LUCENA, Antônio Macilio Pereira de. Sistema OFDM com estimadores de frequência e de fase para sincronização de portadora. **Revista Tecnologia**, [s. l.], v. 40, n. 1, p. 1–16, 2019. Disponível em: <https://doi.org/10.5020/23180730.2019.7506>

RUSSELL, STUART J.; NORVIG, P. **Inteligência Artificial - Uma abordagem Moderna**. [S. l.: s. n.], 2013.

SANDARUWAN, Roshan *et al.* Device-free Pedestrian Count Estimation Using Wi-Fi Channel State Information. **IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC**, [s. l.], v. 2021-Septe, p. 2610–2616, 2021. Disponível em: <https://doi.org/10.1109/ITSC48978.2021.9564725>

WANG, Zhengjie *et al.* CSI-based human sensing using model-based approaches: A survey. **Journal of Computational Design and Engineering**, [s. l.], v. 8, n. 2, p. 510–523, 2021. Disponível em: <https://doi.org/10.1093/jcde/qwab003>

YANG, Xu *et al.* WmFall: WiFi-based multistage fall detection with channel state information. **International Journal of Distributed Sensor Networks**, [s. l.], v. 14, n. 10, 2018. Disponível em: <https://doi.org/10.1177/1550147718805718>

YANG, Zheng; ZHOU, Zimu; LIU, Yunhao. From RSSI to CSI. **ACM Computing Surveys**, [s. l.], v. 46, n. 2, p. 1–32, 2013. Disponível em: <https://doi.org/10.1145/2543581.2543592>

ZHANG, Shichao *et al.* Learning k for kNN Classification. **ACM Transactions on Intelligent Systems and Technology**, [s. l.], v. 8, n. 3, 2017. Disponível em: <https://doi.org/10.1145/2990508>