

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

JOÃO FELIPE FRANKIU CORSO

MATHEUS MANFREDINE TRINDADE FRAGA

NIKOLAS LAFIS FORMIGA

**DETECÇÃO DE PRESENÇA HUMANA BASEADA EM WI-FI UTILIZANDO
APRENDIZADO DE MÁQUINA**

CURITIBA

2026

**JOÃO FELIPE FRANKIU CORSO
MATHEUS MANFREDINE TRINDADE FRAGA
NIKOLAS LAFIS FORMIGA**

**DETECÇÃO DE PRESENÇA HUMANA BASEADA EM WI-FI UTILIZANDO
APRENDIZADO DE MÁQUINA**

**HUMAN PRESENCE DETECTION BASED ON WI-FI USING MACHINE
LEARNING**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Engenharia Elétrica do
curso de Engenharia Elétrica da Universidade
Tecnológica Federal do Paraná (UTFPR).
Orientador(a): Prof. Glauber Gomes de Oliveira
Brante

**CURITIBA
2026**



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

**JOÃO FELIPE FRANKIU CORSO
MATHEUS MANFREDINE TRINDADE FRAGA
NIKOLAS LAFIS FORMIGA**

**DETECÇÃO DE PRESENÇA HUMANA BASEADA EM WI-FI UTILIZANDO
APRENDIZADO DE MÁQUINA**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Engenharia Elétrica do
curso de Engenharia Elétrica da Universidade
Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 22/Junho/2026

Glauber Gomes de Oliveira Brante
Doutorado
Universidade Tecnológica Federal do Paraná

Jamil de Araujo Farhat
Doutorado
Universidade Tecnológica Federal do Paraná

Guilherme Luiz Moritz
Doutorado
Universidade Tecnológica Federal do Paraná

**CURITIBA
2026**

RESUMO

A detecção de presença humana em ambientes internos é fundamental para sistemas de automação residencial, segurança predial e monitoramento não invasivo de saúde, sendo que os métodos tradicionais baseados em sensores infravermelhos e câmeras de vigilância apresentam limitações relacionadas à privacidade e à detecção de indivíduos imóveis. Este trabalho tem como objetivo desenvolver e validar um sistema para detecção de presença humana em ambientes internos utilizando sinais Wi-Fi e aprendizado de máquina, aproveitando a infraestrutura de rede já existente e utilizando apenas um módulo ESP32 como *hardware* de captura. O microcontrolador ESP32 captura a informação de estado do canal, grandeza que descreve como o sinal Wi-Fi se propaga pelo ambiente, e o algoritmo *Random Forest*, implementado em MATLAB, para classificação binária entre presença e ausência humana. A metodologia compreende a extração de 30 características estatísticas normalizadas de janelas temporais de 3 segundos, um protocolo de coleta intercalada desenvolvido para mitigar o viés temporal nos dados de treinamento, e duas frentes de validação. A primeira consiste em experimentos individuais e combinados realizados em ambiente residencial com *hardware* próprio, enquanto a segunda utiliza o *dataset* público WiMANS como referência externa. Os experimentos individuais alcançaram acurácias entre 90,4% e 98,1%, e a validação com o WiMANS atingiu 99,2% no *dataset* completo, 100% em testes dentro de um mesmo ambiente e entre 72,3% e 74,6% em cenário *cross-environment* com ambientes distintos entre treino e teste. O *drift* temporal do canal Wi-Fi foi identificado como a principal limitação do sistema. O modelo combinado de dois experimentos alcançou 98,1% de acurácia em teste ao vivo sem calibração, valor que degradou para entre 66,7% e 69,2% após a inclusão de um terceiro experimento coletado em momento temporalmente mais distante. A implementação de um mecanismo de calibração adaptativa do limiar de decisão, baseado em 30 segundos de dados com o ambiente vazio imediatamente antes do uso, elevou a acurácia do modelo combinado dos três experimentos para 94,4% sem necessidade de retreinamento do modelo. Os resultados obtidos demonstram que o sistema desenvolvido atendeu satisfatoriamente à função de sensor de presença, abrindo caminho para futuras investigações em aplicações como automação residencial, segurança predial e monitoramento não invasivo de saúde.

Palavras-chave: detecção de presença; sensoriamento Wi-Fi; aprendizado de máquina; *random forest*; ESP32; informação de estado do canal.

ABSTRACT

Human presence detection in indoor environments is essential for home automation, building security, and non-invasive health monitoring systems. Traditional methods based on infrared sensors and surveillance cameras present limitations related to privacy and the detection of stationary individuals. This work aims to develop and validate a system for human presence detection in indoor environments using Wi-Fi signals and machine learning, leveraging the existing network infrastructure and using only a ESP32 module as capture hardware. The ESP32 microcontroller captures the Channel State Information (CSI), a metric that describes how the Wi-Fi signal propagates through the environment, and the Random Forest algorithm, implemented in MATLAB, for binary classification between human presence and absence. The methodology comprises the extraction of 30 normalized statistical features from 3-second temporal windows, an interleaved data collection protocol designed to mitigate temporal bias in the training data, and two validation approaches. The first consists of individual and combined experiments conducted in a residential environment using the developed hardware, while the second uses the public WiMANS dataset as an external reference. The individual experiments achieved accuracies between 90.4% and 98.1%, while validation with WiMANS reached 99.2% on the complete dataset, 100% in same-environment tests, and between 72.3% and 74.6% in cross-environment scenarios with different environments for training and testing. Temporal drift of the Wi-Fi channel was identified as the main limitation of the system. The combined model of two experiments achieved 98.1% accuracy in live testing without calibration, a value that degraded to between 66.7% and 69.2% after the inclusion of a third experiment collected at a more temporally distant moment. The implementation of an adaptive decision threshold calibration mechanism, based on 30 seconds of empty-room data collected immediately before use, increased the accuracy of the combined model of the three experiments to 94.4% without requiring model retraining. The results demonstrate that the developed system satisfactorily fulfilled the role of a presence sensor, paving the way for future investigations in applications such as home automation, building security, and non-invasive health monitoring.

Keywords: presence detection; Wi-Fi sensing; machine learning; random forest; ESP32; channel state information.

LISTA DE FIGURAS

Figura 1 – Canais Wi-Fi na banda 2,4 GHz mostrando sobreposição espectral.....	19
Figura 2 – Distribuição das 64 subportadoras em sistema OFDM IEEE 802.11a/g/n mostrando subportadoras de guarda (cinza), DC (cinza), pilotos (vermelho) e dados (azul).	19
Figura 3 – Amplitude do CSI para três antenas sob movimento humano.	20
Figura 4 – Módulo ESP32-DevKitC V4 utilizado nos experimentos.....	22
Figura 5 – Diagrama de blocos do sistema de detecção de presença via Wi-Fi com ESP32.	25
Figura 6 – Diagrama de blocos geral do sistema de detecção de presença.	31
Figura 7 – Sistema de captura de sinais Wi-Fi para detecção de presença usando ESP32.	33
Figura 8 – Fluxograma do processamento de sinais Wi-Fi no MATLAB.	34
Figura 9 – <i>Layout</i> do ambiente de teste com posicionamento do roteador e do ESP32.	41
Figura 10 – Mapa de calor da fase por subportadora ao longo do monitoramento contínuo de 4h14min.	52
Figura 11 – Valor absoluto da correlação de cada uma das 30 <i>features</i> do <i>pipeline</i> com o tempo decorrido.	53

LISTA DE TABELAS

Tabela 1 – Especificações técnicas do ESP32 DevKit CH9102X.	22
Tabela 2 – Parâmetros da configuração experimental	24
Tabela 3 – Scripts desenvolvidos e suas funções	35
Tabela 4 – Parâmetros do ambiente de teste	41
Tabela 5 – Parâmetros do protocolo de coleta intercalada	42
Tabela 6 – Composição detalhada do <i>dataset</i> experimental.....	43
Tabela 7 – Separabilidade entre classes por componente CSI: <i>Cohen's d</i> para amplitude e fase	46
Tabela 8 – Resultados do <i>pipeline</i> aplicado ao <i>dataset</i> WiMANS: <i>dataset</i> completo.	47
Tabela 9 – Resultados por ambiente: mesmo ambiente e <i>cross-environment</i> (WiMANS)	48
Tabela 10 – Acurácia por número de usuários presentes no ambiente (WiMANS)	48
Tabela 11 – Resultados consolidados dos experimentos individuais	49
Tabela 12 – Desempenho detalhado por rodada de teste nos experimentos individuais	49
Tabela 13 – Resultados do modelo combinado sem calibração: duas tentativas	50
Tabela 14 – Relação das métricas do canal Wi-Fi com o tempo durante monitoramento contínuo	53
Tabela 15 – Variação das métricas entre os primeiros e últimos 30 minutos do monitoramento.....	54
Tabela 16 – Dados da calibração adaptativa do <i>threshold</i>	55
Tabela 17 – Comparação direta entre teste sem calibração e com calibração adaptativa	55
Tabela 18 – Resumo comparativo de todos os cenários avaliados com o ESP32	56

LISTA DE SÍMBOLOS

$X[k]$	Sinal transmitido na subportadora k
$Y[k]$	Sinal recebido na subportadora k
$H[k]$	Coefficiente complexo do canal (CSI) na subportadora k
$N[k]$	Ruído aditivo (AWGN) na subportadora k
$ H[k] $	Amplitude do CSI na subportadora k
$\text{Re}[k]$	Componente real do CSI na subportadora k
$\text{Im}[k]$	Componente imaginária do CSI na subportadora k
λ	Comprimento de onda do sinal Wi-Fi
z_i	Vetor de características (<i>feature vector</i>) do exemplo i
c_i	Classe verdadeira do exemplo i
$f_i(z)$	Predição da i -ésima árvore para a entrada z
K	Número total de árvores da <i>Random Forest</i>
N	Número total de exemplos no conjunto de treinamento
n	Número total de atributos disponíveis
m	Número de atributos selecionados aleatoriamente em cada divisão
d	Tamanho de efeito de Cohen para separabilidade entre classes
μ_1, μ_2	Médias das amostras das classes 1 e 2
s_p	Desvio padrão combinado (<i>pooled</i>) das classes
s_1^2, s_2^2	Variâncias das classes 1 e 2
n_1, n_2	Tamanhos das amostras das classes 1 e 2
Acc	Acurácia do classificador
Precisão	Fração de positivos preditos que são corretos
Recall	Sensibilidade (fração de positivos reais detectados)
F_1	<i>F1-score</i> (média harmônica entre precisão e recall)
TP	Verdadeiros positivos (<i>true positives</i>)
TN	Verdadeiros negativos (<i>true negatives</i>)
FP	Falsos positivos (<i>false positives</i>)
FN	Falsos negativos (<i>false negatives</i>)

SUMÁRIO

1	INTRODUÇÃO	10
1.1	DELIMITAÇÃO DO TEMA	11
1.2	PROBLEMATIZAÇÃO	11
1.3	OBJETIVOS	12
1.3.1	OBJETIVO GERAL	12
1.3.2	OBJETIVOS ESPECÍFICOS	12
1.4	JUSTIFICATIVA	13
2	MÉTODOS DE SENSORIAMENTO PARA DETECÇÃO DE PRESENÇA HUMANA	14
2.1	SENSORIAMENTO POR INFRAVERMELHO	14
2.2	SISTEMAS BASEADOS EM CÂMERAS	15
2.3	SENSORIAMENTO POR RADAR E LIDAR	16
2.4	Wi-Fi PARA SENSORIAMENTO DE PRESENÇA HUMANA	17
2.4.1	JUSTIFICATIVA DA ESCOLHA DO Wi-Fi	17
2.4.2	FUNDAMENTOS TÉCNICOS DO Wi-Fi	18
2.4.3	CHANNEL STATE INFORMATION (CSI)	20
2.5	ESP32 PARA CAPTURA DE SINAIS Wi-Fi	21
2.5.1	INTRODUÇÃO AO ESP32 E AO SDK ESP-CSI	21
2.5.2	HARDWARE E ESPECIFICAÇÕES TÉCNICAS	22
2.5.3	REPOSITÓRIO ESP-CSI E ECOSSISTEMA ESPRESSIF	22
2.5.4	FIRMWARE E ACESSO AO CSI	23
2.5.5	CONFIGURAÇÃO DA REDE Wi-Fi E DO AMBIENTE DE TESTES	24
2.5.6	INTERFACE SERIAL E INTEGRAÇÃO COM MATLAB	24
2.5.7	DIAGNÓSTICO DO CSI	25
2.6	CONSIDERAÇÕES SOBRE A TRANSIÇÃO PARA APRENDIZADO DE MÁQUINA	26
3	APRENDIZADO DE MÁQUINA	27
3.1	INTRODUÇÃO AO APRENDIZADO DE MÁQUINA	27
3.2	APRENDIZADO SUPERVISIONADO E CLASSIFICAÇÃO	27
3.3	FLORESTAS ALEATÓRIAS (RANDOM FORESTS)	28
3.3.1	FUNDAMENTOS E CONSTRUÇÃO	28
3.3.2	VANTAGENS E RESISTÊNCIA AO OVERFITTING	29
3.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	29
4	SISTEMA DE MEDIÇÃO PROPOSTO	31
4.1	VISÃO GERAL DO SISTEMA	31
4.2	COMPONENTES DO SISTEMA	32
4.2.1	INFRAESTRUTURA Wi-Fi EXISTENTE	32
4.2.2	SISTEMA DE CAPTURA ESP32	32
4.2.3	PLATAFORMA DE PROCESSAMENTO MATLAB	33
4.3	PIPELINE DO SISTEMA	35
4.3.1	ENGENHARIA DE CARACTERÍSTICAS	36
4.3.2	FASE DE TREINAMENTO	36
4.3.3	FASE DE OPERAÇÃO	37
4.4	MÉTRICAS DE DESEMPENHO	37
4.5	CONSIDERAÇÕES PRÁTICAS DE IMPLEMENTAÇÃO	37
5	METODOLOGIA EXPERIMENTAL	39

5.1	VALIDAÇÃO COM DATASET WiMANS	39
5.1.1	DESCRIÇÃO DO <i>DATASET</i>	39
5.1.2	ADAPTAÇÕES REALIZADAS	39
5.1.3	CENÁRIOS DE TESTE	40
5.2	AMBIENTE E CONDIÇÕES DE TESTE	40
5.3	PROTOCOLO DE COLETA INTERCALADA	41
5.3.1	JUSTIFICATIVA DO PROTOCOLO INTERCALADO	42
5.4	EXPERIMENTOS REALIZADOS	43
5.5	ESTRATÉGIA DE VALIDAÇÃO	44
5.5.1	<i>LEAVE-ONE-ROUND-OUT</i> (LORO)	44
5.5.2	VALIDAÇÃO CRUZADA <i>K-FOLD</i>	44
5.5.3	TESTE AO VIVO	44
5.6	MONITORAMENTO DE <i>DRIFT</i> TEMPORAL	44
6	RESULTADOS E DISCUSSÃO	46
6.1	DIAGNÓSTICO DA FASE DO CSI	46
6.2	RESULTADOS DA VALIDAÇÃO COM WiMANS	47
6.2.1	<i>DATASET</i> COMPLETO	47
6.2.2	RESULTADO POR AMBIENTE	47
6.2.3	RESULTADO POR NÚMERO DE USUÁRIOS	48
6.3	RESULTADOS DOS EXPERIMENTOS INDIVIDUAIS	48
6.3.1	DESEMPENHO GERAL	48
6.3.2	DETALHAMENTO POR RODADA	49
6.4	MODELO COMBINADO	50
6.4.1	VALIDAÇÃO CRUZADA <i>K-FOLD</i>	50
6.4.2	TESTE AO VIVO SEM CALIBRAÇÃO	50
6.4.3	CONTEXTO: MODELO DE DOIS EXPERIMENTOS SEM CALIBRAÇÃO	51
6.5	ANÁLISE DE <i>DRIFT</i> TEMPORAL	51
6.5.1	CORRELAÇÕES DAS MÉTRICAS COM O TEMPO	53
6.5.2	VARIAÇÃO ENTRE INÍCIO E FIM DO MONITORAMENTO	54
6.5.3	IMPACTOS NAS <i>FEATURES</i> DE CLASSIFICAÇÃO	54
6.6	TESTE AO VIVO COM CALIBRAÇÃO ADAPTATIVA	54
6.7	RESUMO COMPARATIVO DOS CENÁRIOS	55
6.8	DISCUSSÃO GERAL	55
7	CONCLUSÃO	57
	REFERÊNCIAS	59

1 INTRODUÇÃO

O desenvolvimento da Internet das Coisas (*Internet of Things*, IoT) e o avanço tecnológico das últimas décadas têm proporcionado mudanças significativas na maneira como residências, edifícios comerciais e até instituições de saúde são monitorados e automatizados.

Uma parte essencial desse progresso envolve tecnologias capazes de detectar com precisão a presença de pessoas em ambientes internos, aplicação fundamental para diversos cenários práticos. Em sistemas de automação residencial, a detecção de presença permite o controle inteligente de iluminação, climatização e dispositivos eletrônicos, resultando em economia de energia e maior conforto aos usuários. Em ambientes comerciais, essa tecnologia possibilita a otimização do uso de espaços, o controle de acesso e a gestão eficiente de recursos. Na área da saúde, a detecção de presença é particularmente crítica para o monitoramento não invasivo de idosos e pessoas com necessidades especiais, permitindo identificar situações de emergência, como quedas ou períodos prolongados de inatividade. Adicionalmente, em contextos de segurança predial, a capacidade de detectar intrusos ou ocupação não autorizada em áreas restritas representa uma camada importante de proteção patrimonial. Todas essas aplicações dependem de sensores confiáveis e precisos para detecção de presença humana (Yousefi *et al.*, 2017).

Embora amplamente difundidos, os sensores infravermelhos apresentam limitações claras, especialmente no que diz respeito à detecção de indivíduos parados ou realizando movimentos mínimos, o que frequentemente resulta em falsos negativos. Para garantir eficiência, geralmente são necessárias múltiplas unidades distribuídas, aumentando custos e complexidade de instalação (Liu *et al.*, 2017).

Por outro lado, as câmeras de vigilância oferecem dados detalhados e são eficientes em diversos cenários, mas introduzem questões significativas de privacidade, dado que capturam imagens que muitas vezes vão além do essencial para o monitoramento, gerando preocupações éticas e legais. Além disso, sistemas baseados em visão podem ter seu desempenho prejudicado por variações de iluminação e oclusões causadas por móveis, portas ou outros objetos presentes no ambiente (Gutiérrez; Rodríguez; Martín, 2021).

Uma alternativa inovadora e recente que está ganhando destaque em pesquisas acadêmicas é o sensoriamento baseado em sinais Wi-Fi. O estudo de Yousefi *et al.* (2017) sobre reconhecimento de atividades humanas utilizando informações do estado do canal (*Channel State Information*, CSI) demonstra que é possível alcançar altos níveis de acurácia na detecção de presença, em cenários controlados de linha de visada. O trabalho de Wu *et al.* (2017) também evidenciou o potencial do Wi-Fi em ambientes internos, utilizando técnicas de aprendizado de máquina para identificar padrões de movimentação e presença. O grande atrativo dessa abordagem é o aproveitamento da infraestrutura já existente de redes Wi-Fi, eliminando a necessidade de instalação de equipamentos adicionais.

O princípio básico dessa técnica é que a presença de pessoas causa alterações detectáveis na propagação do sinal Wi-Fi entre um transmissor, geralmente um roteador, e um

receptor conectado a um computador. Essas alterações, embora sutis, são suficientes para determinar se alguém está presente em um ambiente. Trabalhos recentes, como o de Huang *et al.* (2024), apresentam conjuntos de dados (*datasets*) extensivos para sensoriamento de múltiplos usuários baseado em Wi-Fi, demonstrando a maturidade crescente dessa tecnologia e sua aplicabilidade em cenários complexos.

Dentro desse contexto, este trabalho situa-se na área da Engenharia Elétrica, integrando conhecimentos de telecomunicações e de inteligência artificial. Utilizando o microcontrolador ESP32, os sinais Wi-Fi foram capturados e analisados através de técnicas de aprendizado de máquina, com o objetivo de validar a eficácia dessa solução.

1.1 DELIMITAÇÃO DO TEMA

Este trabalho concentra-se no desenvolvimento e validação de um método de detecção de presença humana em ambientes internos fechados utilizando sinais Wi-Fi captados por microcontrolador ESP32 e processados através de técnicas de aprendizado de máquina no MATLAB. O sistema baseia-se na extração de características estatísticas do CSI e na classificação binária, presença ou ausência, por meio do algoritmo *Random Forest*. A solução é projetada como uma alternativa de baixo custo e não invasiva, aproveitando a infraestrutura Wi-Fi já existente nos ambientes monitorados e utilizando apenas um módulo ESP32 como *hardware* de captura.

1.2 PROBLEMATIZAÇÃO

Com o crescimento acelerado da automação residencial e dos sistemas de segurança inteligentes, identificar com eficácia a presença humana em ambientes fechados tornou-se um desafio essencial. Entretanto, os métodos atualmente disponíveis para essa tarefa apresentam limitações significativas. Sensores infravermelhos, apesar do baixo custo e da simplicidade de operação, frequentemente falham na detecção de indivíduos imóveis ou com movimentos sutis, exigindo múltiplas unidades para cobrir adequadamente uma única área, o que aumenta os custos operacionais. Sistemas de vigilância por câmeras, embora mais precisos, levantam sérias preocupações de privacidade e também sofrem degradação de desempenho em ambientes com baixa iluminação ou com obstruções físicas.

Além disso, a evolução dos sistemas de comunicação além do 5G, já conhecida como 6G e ainda em estágio de pesquisa científica, prevê cenários em que detectar a presença humana em ambientes é fundamental para configurar a forma como os dispositivos se comunicam. Técnicas de concentração de feixes (*beamforming*) permitem aumentar consideravelmente a taxa de dados em uma localização específica onde um usuário esteja presente. Alternativamente, ao detectar presença humana, também é possível reduzir níveis de radiação eletromagnética, algo particularmente importante em sistemas de transferência de energia sem fio de alta potência. Dessa forma, explorar técnicas de localização que utilizam a infraestrutura de comuni-

cações já existente, como os roteadores Wi-Fi, torna-se uma alternativa relevante e promissora (Andrews; Humphreys; Ji, 2024).

Este trabalho propõe como objeto de pesquisa a utilização do sensoriamento por sinais Wi-Fi, capturados por um microcontrolador ESP32 conectado a um computador via porta serial. A detecção foi feita através de uma estratégia de aprendizado de máquina supervisionado: o ESP32 coletou dados de amplitude do sinal CSI com e sem a presença humana para treinar um classificador do tipo *Random Forest*. Este modelo foi empregado para prever a ocupação de espaços em tempo real. A técnica destaca-se por sua precisão e pelo baixo custo de implementação, o módulo ESP32 pode ser adquirido por valores entre R\$ 30 e R\$ 50, preservando a privacidade dos ocupantes. Assim, o estudo visa avaliar a eficiência e viabilidade dessa abordagem em termos de precisão e acurácia na identificação da presença humana, focando em desenvolver uma solução prática, acessível e replicável.

1.3 OBJETIVOS

1.3.1 OBJETIVO GERAL

Desenvolver e validar um sistema capaz de detectar a presença humana em ambientes internos por meio de sinais Wi-Fi utilizando aprendizado de máquina.

1.3.2 OBJETIVOS ESPECÍFICOS

Para atingir o objetivo geral, foram definidos os seguintes objetivos específicos:

- a) Coletar informações e referências bibliográficas referentes ao tema;
- b) Analisar os bancos de dados existentes referentes à presença de pessoas através do sinal Wi-Fi;
- c) Definir a base de dados a ser utilizada para o treinamento do modelo;
- d) Analisar as diferentes abordagens de aprendizado de máquina possíveis;
- e) Configurar o microcontrolador ESP32 com *firmware* dedicado para captura de CSI via sinal Wi-Fi;
- f) Desenvolver o código do aprendizado de máquina;
- g) Treinar o modelo utilizando banco de dados selecionado;
- h) Testar a eficiência do modelo utilizando dados de validação;
- i) Utilizar o ESP32 para capturar dados de CSI em ambiente controlado;

- j) Analisar os dados de CSI coletados pelo ESP32, incluindo o comportamento de *drift* temporal do canal;
- k) Testar a eficiência do modelo com dados reais coletados pelo ESP32, com e sem calibração adaptativa do *threshold* de decisão.

1.4 JUSTIFICATIVA

A importância deste trabalho reside na busca por alternativas tecnológicas que sejam não apenas eficazes, mas também economicamente viáveis e socialmente responsáveis para a detecção de presença humana em ambientes internos. A solução proposta, baseada no sensoriamento de sinais Wi-Fi aliado a técnicas avançadas de aprendizado de máquina, destaca-se por oferecer benefícios significativos em relação aos métodos tradicionais.

Primeiro, a utilização de redes Wi-Fi já existentes dispensa a instalação de equipamentos adicionais, reduzindo drasticamente os custos iniciais e facilitando a implementação da tecnologia em larga escala. Em segundo lugar, por não depender de sistemas baseados em câmeras, a abordagem preserva a privacidade dos usuários, sendo adequada inclusive para ambientes sensíveis, como hospitais, casas de repouso e residências particulares.

Além disso, este trabalho apresenta contribuições acadêmicas relevantes ao explorar a integração entre as áreas de telecomunicações e inteligência artificial, ambas fundamentais dentro do escopo da Engenharia Elétrica. Do ponto de vista prático, espera-se que os resultados obtidos possam ser aplicados para aprimorar sistemas de automação residencial e segurança predial, bem como contribuir para soluções de monitoramento não invasivo da saúde de idosos e pessoas com necessidades especiais.

Em resumo, este projeto não apenas propõe uma solução tecnológica inovadora e eficaz, mas também oferece um impacto positivo significativo ao proporcionar segurança, comodidade e privacidade de forma integrada e sustentável.

2 MÉTODOS DE SENSORIAMENTO PARA DETECÇÃO DE PRESENÇA HUMANA

A detecção de presença humana em ambientes internos pode ser realizada por meio de diferentes tecnologias de sensoriamento, cada uma com características, vantagens e limitações específicas. Este capítulo apresenta uma revisão das principais técnicas utilizadas para essa finalidade, com foco em quatro abordagens: sensoriamento por infravermelho, sistemas baseados em câmeras, tecnologias de radar/LiDAR e sensoriamento por sinais de radiofrequência, incluindo Wi-Fi.

A compreensão das características técnicas de cada modalidade é essencial para justificar a escolha do Wi-Fi como tecnologia principal deste trabalho, conforme será detalhado nas seções seguintes.

2.1 SENSORIAMENTO POR INFRAVERMELHO

O sensoriamento por infravermelho para detecção de presença humana fundamenta-se na detecção da radiação térmica naturalmente emitida pelo corpo humano. Em razão de sua temperatura, próxima de 36–37 °C, o corpo humano emite radiação eletromagnética na região do infravermelho, sendo a faixa do infravermelho de onda longa (*long-wave infrared*, LWIR), aproximadamente entre 8 e 14 µm, particularmente relevante para aplicações de imageamento e detecção térmica. Essa característica permite a identificação da presença humana por sensores capazes de responder a variações de radiação térmica no ambiente.

Os sensores infravermelhos passivos (*Passive Infrared*, PIR) constituem uma das tecnologias mais comuns para detecção de presença em aplicações residenciais e comerciais. Esses dispositivos não emitem radiação, mas detectam variações na radiação infravermelha incidente, geralmente causadas pelo deslocamento de pessoas em seu campo de visão. Liu *et al.* (2017) destacam que sensores PIR são amplamente empregados como detectores de presença devido à sua simplicidade, baixo custo e baixo consumo energético.

Câmeras térmicas representam uma abordagem mais avançada de sensoriamento infravermelho, pois capturam imagens bidimensionais associadas à radiação térmica emitida pelas superfícies. Diferentemente dos sensores PIR convencionais, essas câmeras podem identificar assinaturas térmicas mesmo na ausência de movimento significativo, o que amplia sua aplicabilidade em sistemas de monitoramento. No entanto, seu uso tende a envolver maior custo, maior complexidade de processamento e maior volume de dados quando comparado aos sensores PIR simples.

Apesar de suas vantagens, o sensoriamento por PIR apresenta limitações importantes para a detecção contínua de presença. Como o elemento piroelétrico responde principalmente a variações na radiação térmica incidente, sensores PIR convencionais são mais adequados à detecção de movimento do que à identificação de indivíduos imóveis. Assim, pessoas sentadas, deitadas ou realizando movimentos muito sutis podem não ser detectadas adequadamente, gerando falsos negativos. Essa limitação motivou o desenvolvimento de estratégias para tornar

sensores PIR capazes de detectar tanto ocupantes em movimento quanto ocupantes estacionários, como a utilização de mecanismos de modulação da radiação incidente proposta por Liu *et al.* (2017).

2.2 SISTEMAS BASEADOS EM CÂMERAS

Sistemas de vigilância baseados em câmeras representam uma abordagem amplamente utilizada para detecção e monitoramento de presença humana em ambientes internos e externos. Estes sistemas capturam imagens do ambiente, processando-as através de algoritmos de visão computacional para identificar, rastrear e analisar a presença e movimentação de pessoas.

Câmeras RGB convencionais operam na faixa do espectro visível, capturando imagens coloridas similares à visão humana. Em aplicações de segurança predial, essas câmeras são combinadas com algoritmos de detecção de movimento e reconhecimento de padrões para identificar pessoas em áreas monitoradas. Sistemas mais avançados incorporam técnicas de aprendizado profundo (*deep learning*) para classificação automática de eventos, distinguindo entre presença humana, animais e objetos inanimados.

Em aplicações de monitoramento residencial e cuidados em saúde, abordagens tradicionais frequentemente recorrem a dispositivos vestíveis e sistemas baseados em câmeras para acompanhar atividades humanas. Entretanto, essas soluções podem apresentar limitações relacionadas ao conforto do usuário, à necessidade de uso contínuo de dispositivos e a preocupações com privacidade. Nesse contexto, Tan *et al.* (2018) apontam o sensoriamento baseado em Wi-Fi como uma alternativa promissora para o monitoramento não intrusivo de atividades em ambientes internos.

Apesar da eficácia comprovada, sistemas baseados em câmeras apresentam limitações significativas que motivam a busca por alternativas. A principal preocupação é a privacidade: câmeras capturam imagens detalhadas que podem ser consideradas invasivas, especialmente em ambientes residenciais, quartos de hospital ou banheiros. Essa preocupação é particularmente relevante em aplicações de monitoramento contínuo de saúde e bem-estar, nas quais a presença de câmeras pode limitar a aceitação da tecnologia pelos usuários (Gutiérrez; Rodríguez; Martín, 2021).

Adicionalmente, o desempenho de câmeras RGB degrada significativamente em condições de baixa luminosidade ou escuridão total, exigindo iluminação auxiliar ou câmeras infravermelhas especializadas. Obstáculos físicos como móveis, portas fechadas e paredes podem bloquear a linha de visão, criando zonas cegas onde a detecção não é possível. Dessa forma, ambientes residenciais com múltiplos cômodos podem exigir múltiplas câmeras para ampliar a cobertura, aumentando os custos de instalação e as preocupações relacionadas à privacidade (Gutiérrez; Rodríguez; Martín, 2021).

2.3 SENSORIAMENTO POR RADAR E LIDAR

Tecnologias de sensoriamento ativo baseadas em radar (*Radio Detection and Ranging*) e detecção e determinação de alcance por luz (*Light Detection and Ranging*, LiDAR) representam abordagens que emitem sinais e analisam os ecos refletidos por objetos no ambiente para detectar presença e movimento humano. Diferentemente de sistemas passivos como câmeras e sensores PIR, essas tecnologias não dependem de condições de iluminação ou variações térmicas, oferecendo robustez em condições ambientais adversas.

Sistemas radar para detecção de presença humana operam tipicamente em frequências de micro-ondas, emitindo pulsos eletromagnéticos e medindo o tempo de retorno e a variação Doppler dos sinais refletidos. Radares de curto alcance na banda de 24 GHz ou 60 GHz têm sido utilizados em aplicações de monitoramento vital, capazes de detectar movimentos respiratórios e batimentos cardíacos através de paredes e roupas. Sistemas de radar FMCW (*Frequency-Modulated Continuous Wave*) podem detectar micro-movimentos com precisão milimétrica, permitindo monitoramento de sinais vitais sem contato físico, como demonstrado por Adib *et al.* (2015) em sistema capaz de monitorar respiração e batimentos cardíacos através de paredes.

Em aplicações comerciais, sistemas radar são empregados para contagem de pessoas em ambientes de varejo, detecção de presença em veículos e monitoramento de ocupação em edifícios inteligentes. A capacidade de operar através de materiais não-metálicos permite instalações discretas, com sensores embutidos em tetos ou paredes sem linha de visada direta.

LiDAR utiliza pulsos de laser, tipicamente no infravermelho próximo, para mapeamento tridimensional de ambientes. Cada pulso emitido retorna ao sensor após reflexão em superfícies, permitindo o cálculo preciso de distâncias e a construção de nuvens de pontos tridimensionais. Em aplicações de detecção de presença, sistemas LiDAR podem identificar e rastrear pessoas com alta precisão espacial, diferenciando múltiplos indivíduos e detectando gestos e posturas.

Aplicações práticas de LiDAR incluem sistemas de segurança perimetral, onde feixes laser criam zonas virtuais de proteção, acionando alarmes quando atravessadas. Em ambientes industriais, LiDAR é utilizado para garantir segurança ao redor de maquinário pesado, detectando presença humana e interrompendo operações perigosas automaticamente.

Apesar das vantagens técnicas, radar e LiDAR apresentam limitações que restringem sua adoção em larga escala para detecção de presença residencial. O custo é o principal fator limitante: sistemas radar comerciais custam tipicamente entre R\$ 500 e R\$ 5.000, enquanto sensores LiDAR podem exceder R\$ 10.000 dependendo da resolução e alcance. Essa barreira econômica contrasta significativamente com sensores PIR (R\$ 20–100) e a infraestrutura Wi-Fi já existente na maioria dos ambientes.

Adicionalmente, a instalação desses sistemas requer conhecimento técnico para calibração adequada e posicionamento otimizado, aumentando custos de implementação. Regu-

lamentações de segurança também limitam a potência de emissão de sinais radar e laser em ambientes ocupados, restringindo alcance e sensibilidade em aplicações residenciais.

2.4 Wi-Fi PARA SENSORIAMENTO DE PRESENÇA HUMANA

2.4.1 JUSTIFICATIVA DA ESCOLHA DO Wi-Fi

A transição das modalidades ópticas e térmicas para radiofrequência representa uma evolução natural no sensoriamento de presença humana, conforme estabelecido nas seções anteriores. Neste contexto, a tecnologia Wi-Fi emerge como solução privilegiada para detecção de presença por múltiplos fatores que convergem para sua superioridade técnica e prática sobre alternativas tradicionais.

A escolha do Wi-Fi fundamenta-se primeiramente em sua ubiquidade infraestrutural. Como destacam Yousefi *et al.* (2017), praticamente todos os ambientes residenciais e comerciais modernos já possuem roteadores Wi-Fi instalados, eliminando a necessidade de hardware dedicado para sensoriamento. Esta característica representa uma vantagem econômica significativa quando comparada aos sensores PIR, que exigem múltiplas unidades para cobertura adequada, ou sistemas de câmeras, que demandam infraestrutura complexa e custosa.

Outro fator relevante é a maior preservação da privacidade em comparação com sistemas baseados em câmeras. Enquanto câmeras capturam imagens diretas dos indivíduos monitorados, o sensoriamento por Wi-Fi utiliza variações nos sinais de radiofrequência para inferir presença e atividade humana, sem depender da aquisição de imagens do ambiente. Essa característica torna a abordagem menos intrusiva para aplicações residenciais e de monitoramento em saúde, conforme discutido por Tan *et al.* (2018).

A robustez operacional do Wi-Fi em condições adversas constitui o terceiro pilar desta escolha. Enquanto sensores infravermelhos podem falhar na detecção de pessoas imóveis e câmeras são afetadas por condições de iluminação e oclusão visual, sinais Wi-Fi apresentam menor dependência de linha de visada direta, podendo atravessar obstáculos como paredes e móveis. Essa característica permite explorar cenários de sensoriamento sem contato e sem aquisição de imagens, inclusive em condições de oclusão visual (Yousefi *et al.*, 2017; Wu *et al.*, 2017).

Adicionalmente, como apontado por Andrews, Humphreys e Ji (2024), a evolução dos sistemas de comunicação além do 5G já considera o sensoriamento integrado como funcionalidade nativa. Esta convergência entre comunicação e sensoriamento posiciona o Wi-Fi como tecnologia estratégica, onde a mesma infraestrutura serve simultaneamente para conectividade e monitoramento ambiental, maximizando o retorno sobre investimentos já realizados.

2.4.2 FUNDAMENTOS TÉCNICOS DO Wi-Fi

O Wi-Fi opera segundo os padrões IEEE 802.11, utilizando técnicas de modulação digital para transmissão de dados através de ondas eletromagnéticas. O padrão mais relevante para sensoriamento é o IEEE 802.11n, que adotou o conceito de MIMO (*Multiple Input Multiple Output*), e permite acessar a informação de CSI, fundamental para aplicações de sensoriamento (Du *et al.*, 2025).

A arquitetura básica de um sistema Wi-Fi consiste em pontos de acesso (*Access Points*, APs) que se comunicam com dispositivos clientes através de canais específicos nas bandas ISM (*Industrial, Scientific and Medical*). A banda de 2,4 GHz opera na faixa de 2,400 a 2,4835 GHz e é organizada em 14 canais de 20 MHz. No Brasil, são autorizados pela Agência Nacional de Telecomunicações (ANATEL) os canais 1 a 13, enquanto o canal 14 não é permitido no país (BRASIL. AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES, 2017). Sob regulação da Comissão Federal de Comunicações dos Estados Unidos (*Federal Communications Commission*, FCC), são autorizados apenas 11 canais (1 a 11) (UNITED STATES. FEDERAL COMMUNICATIONS COMMISSION, 2024). A banda de 5 GHz oferece maior largura de banda e menor interferência, operando entre 5,150 e 5,850 GHz com canais de 20, 40, 80 ou 160 MHz (Du *et al.*, 2025).

As bandas de 2,4 GHz e 5 GHz oferecem características complementares para sensoriamento:

- **2,4 GHz:** comprimento de onda $\lambda \approx 12,5$ cm; oferece melhor penetração através de obstáculos e maior alcance, porém apresenta maior suscetibilidade a interferências de dispositivos Bluetooth, micro-ondas e outras redes Wi-Fi.
- **5 GHz:** comprimento de onda $\lambda \approx 6$ cm; proporciona maior resolução espacial, largura de banda de até 160 MHz e menor interferência, embora apresente alcance reduzido e maior atenuação por paredes.

A Figura 1 ilustra os canais Wi-Fi na banda de 2,4 GHz, que será utilizada neste trabalho, em função do microcontrolador escolhido operar apenas nesta banda.

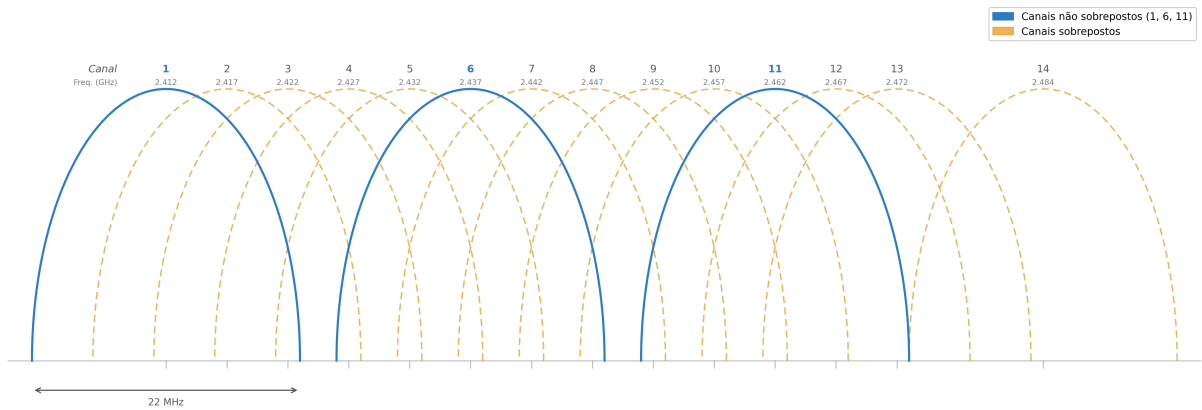


Figura 1 – Canais Wi-Fi na banda 2,4 GHz mostrando sobreposição espectral.

Fonte: Adaptado de Coleman e Westcott (2017).

O padrão Wi-Fi IEEE 802.11n utiliza multiplexação por divisão de frequência ortogonal (*Orthogonal Frequency Division Multiplexing*, OFDM) como técnica de modulação fundamental. Em vez de transmitir dados em uma única portadora de banda larga, o OFDM divide o canal em múltiplas subportadoras ortogonais de banda estreita, transmitindo dados simultaneamente em todas elas. Esta abordagem oferece robustez contra interferência seletiva em frequência e multipercurso, fenômenos comuns em ambientes internos.

Para o padrão IEEE 802.11n com largura de banda de 20 MHz, o canal é dividido em 64 subportadoras espaçadas por 312,5 kHz. Destas, 48 são utilizadas para transmissão de dados, 4 são pilotos (utilizadas para sincronização e correção de fase), 11 permanecem nulas nas extremidades para criar bandas de guarda, e 1 subportadora central de corrente contínua (*Direct Current*, DC) permanece inativa. Cada subportadora individual pode ser modulada independentemente usando esquemas como BPSK, QPSK, 16-QAM ou 64-QAM, permitindo adaptação dinâmica às condições do canal. A Figura 2 ilustra a distribuição das subportadoras em um sistema OFDM IEEE 802.11a/g/n¹.




Figura 2 – Distribuição das 64 subportadoras em sistema OFDM IEEE 802.11a/g/n mostrando subportadoras de guarda (cinza), DC (cinza), pilotos (vermelho) e dados (azul).

Fonte: Adaptado de Wireless Training Solutions (2018).

¹ A figura ilustra a distribuição de subportadoras do campo L-LTF (*legacy*) do padrão IEEE 802.11a/g, apresentada para fins didáticos. No padrão IEEE 802.11n HT20 efetivamente utilizado pelo ESP32, o campo HT-LTF emprega 52 subportadoras de dados, 4 pilotos, 7 nulas de guarda e 1 DC, totalizando igualmente 64 subportadoras.

2.4.3 CHANNEL STATE INFORMATION (CSI)

O CSI representa a resposta ao impulso do canal de comunicação sem fio entre transmissor e receptor ou, de forma equivalente, a resposta em frequência obtida por meio da Transformada de Fourier, capturando como o sinal se propaga através do ambiente. Em sistemas OFDM utilizados no padrão IEEE 802.11n, o CSI fornece informações de amplitude e fase para cada subportadora, criando uma “impressão digital” detalhada do canal de propagação (Yousefi *et al.*, 2017).

Matematicamente, a relação entre o sinal transmitido e o sinal recebido em sistemas OFDM, no domínio da frequência, pode ser expressa como:

$$Y[k] = H[k] \cdot X[k] + N[k] \quad (1)$$

onde:

- $Y[k]$ é o sinal recebido na k -ésima subportadora;
- $H[k]$ é o coeficiente complexo do canal (CSI) para a k -ésima subportadora;
- $X[k]$ é o sinal transmitido na k -ésima subportadora;
- $N[k]$ representa o ruído aditivo.

A Figura 3 ilustra a amplitude do CSI para três antenas receptoras como função do tempo (índice de pacote) durante duas atividades distintas: caminhar (*walk*) e sentar (*sit down*). Observa-se que durante períodos de movimento humano a amplitude varia drasticamente entre as três antenas, enquanto em momentos estacionários o sinal permanece relativamente estável. Esse comportamento ilustra como o movimento humano altera o padrão de propagação multi-percurso, gerando assinaturas no CSI que podem ser exploradas para detecção de presença.




Figura 3 – Amplitude do CSI para três antenas sob movimento humano.

Fonte: Yousefi *et al.* (2017).

O CSI captura múltiplos fenômenos de propagação simultaneamente. Quando uma pessoa está presente no ambiente, seu corpo, composto aproximadamente por 60% de água, interage com os sinais Wi-Fi através de três mecanismos principais: reflexão, em que o sinal é rebatido pela superfície do corpo; absorção, na qual parte da energia eletromagnética é dissipada nos tecidos; e difração, onde o sinal contorna o corpo, criando zonas de sombra. Como representado na Figura 3, essas interações modificam os valores complexos de $H[k]$, gerando padrões característicos que podem ser detectados e classificados.

A sensibilidade do CSI é notável: estudos demonstram que pequenas alterações no ambiente, incluindo movimentos corporais sutis, podem produzir variações detectáveis no sinal recebido. Essa sensibilidade deriva da natureza multipercurso do canal Wi-Fi, em que pequenas modificações no ambiente provocam mudanças construtivas e destrutivas na interferência entre diferentes caminhos de propagação (Yousefi *et al.*, 2017; Wu *et al.*, 2017).

2.5 ESP32 PARA CAPTURA DE SINAIS Wi-Fi

2.5.1 INTRODUÇÃO AO ESP32 E AO SDK ESP-CSI

O ESP32 é um microcontrolador de duplo núcleo desenvolvido pela *Espressif Systems*, amplamente utilizado em aplicações de IoT devido ao seu baixo custo, conectividade Wi-Fi e *Bluetooth* nativas e extensa comunidade de desenvolvedores. Diferentemente de plataformas de rádio definido por software como o USRP-2922, o ESP32 não opera como receptor de propósito geral programável em radiofrequência, mas sim como um dispositivo Wi-Fi completo capaz de acessar internamente as informações de estado do canal durante a recepção de pacotes segundo o padrão IEEE 802.11n.

A escolha do ESP32 em detrimento de plataformas SDR de laboratório fundamenta-se em critérios práticos e científicos complementares. Do ponto de vista de custo, um módulo ESP32 DevKit pode ser adquirido por valores entre R\$30 e R\$50, contrastando com equipamentos SDR profissionais que alcançam valores de milhares de dólares. Do ponto de vista de controle experimental, o ESP32 permite a realização dos experimentos em ambiente residencial próprio, com controle total das condições de teste, eliminando a dependência de laboratórios compartilhados e redes Wi-Fi institucionais com múltiplos usuários e pontos de acesso *enterprise*. Do ponto de vista de replicabilidade, a solução baseada em ESP32 pode ser reproduzida por qualquer pesquisador ou desenvolvedor, ampliando o potencial de impacto do trabalho. Por fim, a *Espressif* disponibiliza o SDK oficial `esp-csi`, um repositório aberto com *firmware* dedicado à captura de CSI, detalhado na Seção 2.5.3. Sem esse *SDK*, o acesso ao CSI exigiria desenvolvimento de baixo nível, isto é, a programação direta contra as APIs do *driver* Wi-Fi do *framework* `ESP-IDF`: registrar manualmente as funções de *callback* acionadas a cada recepção de pacote, configurar a camada física (PHY) do rádio para expor os coeficientes das subportadoras OFDM, tratar os *buffers* brutos de dados I/Q e gerenciar a temporização e a

memória da recepção em nível de registrador. O `esp-csi` abstrai toda essa complexidade, entregando o CSI já formatado via porta serial.

2.5.2 HARDWARE E ESPECIFICAÇÕES TÉCNICAS

O hardware utilizado neste trabalho é o ESP32 DevKit com chip conversor USB-serial CH9102X, fabricado pela *Caef Electronics*. A Figura 4 apresenta o módulo utilizado nos experimentos, destacando a antena PCB integrada e o conector USB responsável tanto pela alimentação quanto pela comunicação serial com o computador hospedeiro. As especificações técnicas relevantes para a aplicação de sensoriamento são apresentadas na Tabela 1.




Figura 4 – Módulo ESP32-DevKitC V4 utilizado nos experimentos.

Fonte: Espressif Systems (s.d.).

Tabela 1 – Especificações técnicas do ESP32 DevKit CH9102X.

Componente	Especificação
Processador	<i>Dual-core Xtensa LX6, 240 MHz</i>
Memória	4 MB <i>Flash</i> , 520 KB RAM
Conectividade Wi-Fi	IEEE 802.11 b/g/n, banda de 2,4 GHz
Antena	PCB integrada
Interface com computador	Serial USB via CH9102X, 921600 <i>baud</i>
Alimentação	USB 5V

Fonte: Autoria própria

A antena PCB integrada, embora ofereça menor sensibilidade em comparação a antenas externas do tipo IPEX, mostrou-se suficiente para a detecção de presença humana no ambiente de testes, conforme demonstrado pelos resultados experimentais. A taxa de amostragem de CSI obtida com este hardware foi de aproximadamente 92 a 110 *frames* por segundo, valor adequado para a extração das características estatísticas utilizadas no processo de classificação.

2.5.3 REPOSITÓRIO ESP-CSI E ECOSSISTEMA ESPRESSIF

O acesso às informações de estado do canal em dispositivos ESP32 é viabilizado pelo repositório oficial `espressif/esp-csi`, mantido pela *Espressif Systems* e disponível publicamente em <https://github.com/espressif/esp-csi>. Este repositório constitui o principal recurso

da comunidade para desenvolvimento de aplicações de sensoriamento baseadas em CSI com a família ESP32, reunindo exemplos práticos, documentação técnica e ferramentas de análise.

O repositório está organizado em algumas pastas principais. A principal para este trabalho é `examples/`, que contém os *firmwares* prontos para compilação e gravação no dispositivo. Dentro dela, o exemplo `get-started/csi_recv_router` é o mais relevante para aplicações de sensoriamento passivo, pois configura o ESP32 para operar simultaneamente como estação Wi-Fi conectada a um roteador e como coletor de CSI. Na pasta `examples/get-started/tools/` estão disponíveis *scripts* Python para visualização e análise dos dados recebidos via serial, úteis durante o desenvolvimento e depuração do sistema. O repositório também inclui a pasta `docs/` com documentação técnica complementar sobre os fundamentos de OFDM, propagação sem fio e aplicações de CSI.

A escolha do exemplo `csi_recv_router` em detrimento dos demais exemplos disponíveis no repositório fundamenta-se em dois critérios. Primeiro, este *firmware* opera no modo de recepção passiva, capturando o CSI dos pacotes Wi-Fi transmitidos pelo roteador sem necessidade de um segundo ESP32 como transmissor dedicado, o que simplifica a infraestrutura necessária e aproveita a rede Wi-Fi já existente no ambiente. Segundo, o formato de saída serial do `csi_recv_router` é bem documentado e amplamente utilizado pela comunidade, facilitando o desenvolvimento do *parser* de dados no MATLAB.

O ecossistema *Espressif* que suporta este repositório é composto por três camadas interdependentes. A camada de hardware é o próprio módulo ESP32, com suporte nativo ao padrão IEEE 802.11n e acesso interno às subportadoras OFDM. A camada de *firmware* é o ESP-IDF, *framework* oficial de desenvolvimento da *Espressif* que fornece as APIs de baixo nível para acesso ao CSI, compilação cruzada e gravação no dispositivo. A camada de aplicação é o repositório `esp-csi`, que abstrai a complexidade do ESP-IDF e disponibiliza exemplos prontos para uso em pesquisa e desenvolvimento. Esta arquitetura em camadas permite que pesquisadores sem experiência em sistemas embarcados de baixo nível consigam capturar dados CSI com mínimo esforço de configuração, contribuindo diretamente para a replicabilidade e acessibilidade da solução proposta neste trabalho.

2.5.4 FIRMWARE E ACESSO AO CSI

Conforme descrito na Seção 2.5.3, o *firmware* utilizado foi o exemplo `csi_recv_router` do repositório `espressif/esp-csi`. Este *firmware* configura o ESP32 para operar simultaneamente como estação Wi-Fi, conectado a um roteador convencional na banda de 2,4 GHz segundo o padrão IEEE 802.11n HT20, e como coletor de CSI, enviando os dados capturados via porta serial no formato texto.

O *firmware* não requereu modificações em seu código-fonte. Apenas os parâmetros de conexão Wi-Fi (SSID e senha) foram configurados antes da compilação. O processo de compilação e gravação utilizou o *framework* ESP-IDF versão 5.5.3, seguindo a documentação oficial da *Espressif*, com gravação no dispositivo por meio do comando `idf.py flash`.

Cada *frame* CSI é transmitido como uma linha de texto contendo o marcador `CSI_–DATA` seguido de metadados e um vetor de 128 valores inteiros entre colchetes. Esses 128 valores representam 64 pares de parte real e parte imaginária das subportadoras OFDM do canal Wi-Fi. A amplitude de cada subportadora é então calculada por:

$$|H[k]| = \sqrt{\text{Re}[k]^2 + \text{Im}[k]^2} \quad (2)$$

onde $\text{Re}[k]$ e $\text{Im}[k]$ são, respectivamente, as componentes real e imaginária da k -ésima subportadora. Este procedimento é equivalente ao módulo do coeficiente complexo $H[k]$ da equação (1) apresentada na Seção 2.4.3, extraindo a informação de amplitude do CSI para cada uma das 64 subportadoras OFDM disponíveis no padrão IEEE 802.11n HT20.

2.5.5 CONFIGURAÇÃO DA REDE Wi-Fi E DO AMBIENTE DE TESTES

Os experimentos foram realizados em ambiente residencial, com o ESP32 conectado a uma rede doméstica operando na banda de 2,4 GHz com protocolo IEEE 802.11n HT20. Os parâmetros da configuração experimental são apresentados na Tabela 2.

Tabela 2 – Parâmetros da configuração experimental

Parâmetro	Valor
Banda	2,4 GHz
Protocolo	IEEE 802.11n HT20
Subportadoras OFDM	64 (128 valores I/Q por <i>frame</i>)
Taxa de CSI medida	92 a 110 <i>frames</i> /segundo
Ambiente	Apartamento residencial
Cômodo	Quarto
Condição de teste	Porta fechada em todas as fases

Fonte: Autoria própria

A escolha do ambiente residencial como cenário de testes oferece duas vantagens metodológicas relevantes. Primeiro, garante controle total das condições experimentais, especialmente quanto ao tráfego da rede Wi-Fi e à ausência de outros ocupantes durante as coletas. Segundo, representa um cenário de aplicação prático e realista para as principais aplicações visadas pelo sistema, como automação residencial e monitoramento não invasivo.

2.5.6 INTERFACE SERIAL E INTEGRAÇÃO COM MATLAB

A comunicação entre o ESP32 e o computador hospedeiro é realizada via porta serial a 921600 *baud*. No MATLAB, a função `serialport()` é utilizada para abrir a conexão, com *timeout* configurado em 3 segundos. Após a abertura da porta serial, o sistema aguarda 12 segundos para que o ESP32 complete a conexão com a rede Wi-Fi e estabilize o canal antes de iniciar qualquer captura. Um teste preliminar de 2 segundos verifica se dados CSI estão sendo recebidos corretamente, esperando-se no mínimo 10 *frames* para prosseguir.

A Figura 5 apresenta o diagrama de blocos do sistema de detecção de presença humana baseado em sinais Wi-Fi com ESP32. O sistema utiliza um roteador Wi-Fi convencional operando em 2,4 GHz como fonte de sinal, cujas transmissões são capturadas pelo ESP32. Internamente, o ESP32 processa os pacotes recebidos segundo o padrão IEEE 802.11n, extrai os valores I/Q das 64 subportadoras OFDM e transmite os dados via serial USB para o computador hospedeiro. No MATLAB, as amplitudes são calculadas a partir dos pares I/Q, as características estatísticas são extraídas e o algoritmo *Random Forest* classifica o estado do ambiente como presença ou ausência humana.

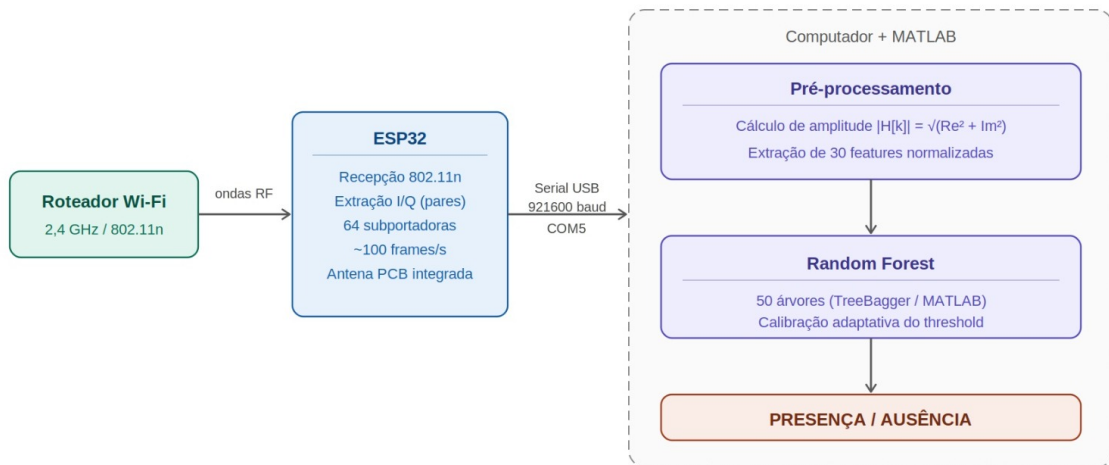


Figura 5 – Diagrama de blocos do sistema de detecção de presença via Wi-Fi com ESP32.

Fonte: Autoria própria

2.5.7 DIAGNÓSTICO DO CSI

Durante o desenvolvimento do sistema, investigou-se se a informação de fase das subportadoras contribuiria para a detecção de presença além da amplitude. Embora o CSI contenha informações de amplitude e fase do canal, a fase bruta obtida por dispositivos Wi-Fi comerciais tende a ser mais sensível a imperfeições de hardware e sincronização, exigindo frequentemente etapas adicionais de calibração e processamento. Zhuo *et al.* (2017) demonstram a necessidade de calibração do ruído de fase em dispositivos Wi-Fi comerciais, enquanto Diaz *et al.* (2023) destacam que a fase do CSI é frequentemente subutilizada em sensoriamento sem fio devido à sua sensibilidade a erros de sincronização.

Dessa forma, neste trabalho, a fase foi avaliada de maneira exploratória e comparada à amplitude das subportadoras por meio do tamanho de efeito de Cohen's d , conforme detalhado na Seção 6.1.

2.6 CONSIDERAÇÕES SOBRE A TRANSIÇÃO PARA APRENDIZADO DE MÁQUINA

A complexidade dos sinais CSI, com múltiplas subportadoras variando em amplitude e fase devido a efeitos de multipercurso, reflexões e presença humana, dificulta a formulação de modelos analíticos determinísticos para detecção de presença. A variabilidade dos ambientes internos, a diversidade de padrões de movimento e a influência de fatores como disposição de mobiliário e materiais construtivos tornam o espaço de soluções suficientemente complexo para motivar o uso de abordagens baseadas em dados.

Neste contexto, o aprendizado de máquina emerge como abordagem natural, capaz de extrair características discriminativas diretamente dos dados CSI através de algoritmos de classificação supervisionada. Técnicas como *Support Vector Machines*, árvores de decisão e métodos *ensemble* demonstraram eficácia em mapear padrões de variação espectral para classes discretas (presença ou ausência), aprendendo automaticamente as relações não-lineares entre medições de CSI e estado do ambiente.

A preparação adequada dos dados CSI, incluindo normalização, redução de dimensionalidade e engenharia de características, constitui etapa fundamental antes da aplicação de algoritmos de aprendizado de máquina. O próximo capítulo detalha os fundamentos teóricos do algoritmo de classificação selecionado para este trabalho, o *Random Forest*, bem como o contexto dos demais métodos considerados durante o desenvolvimento.

3 APRENDIZADO DE MÁQUINA

3.1 INTRODUÇÃO AO APRENDIZADO DE MÁQUINA

O aprendizado de máquina (*machine learning*) representa um paradigma fundamental da inteligência artificial no qual sistemas computacionais melhoram seu desempenho através da experiência, construindo modelos baseados em dados observados (Russell; Norvig, 2020). Conforme estabelecido no Capítulo 2, a complexidade inerente dos sinais CSI, com múltiplas subportadoras variando dinamicamente em amplitude e fase, torna impraticável a definição de regras determinísticas para detecção de presença. Neste contexto, o aprendizado de máquina emerge como abordagem natural para extrair características discriminativas sem necessidade de modelagem física explícita.

No contexto de detecção de presença humana através de sinais Wi-Fi, o aprendizado de máquina opera observando dados de CSI coletados em diferentes estados de ocupação (presença e ausência), construindo um modelo capaz de classificar novos dados não vistos. Este modelo funciona simultaneamente como uma hipótese sobre o mundo, a relação entre padrões CSI e presença humana, e como um componente de *software* que resolve o problema de detecção (Russell; Norvig, 2020).

3.2 APRENDIZADO SUPERVISIONADO E CLASSIFICAÇÃO

Existem três tipos principais de aprendizado de máquina, diferenciados pelo tipo de *feedback* disponível durante o treinamento: aprendizado supervisionado, não-supervisionado e por reforço. Para o problema de detecção de presença humana, utiliza-se o aprendizado supervisionado, onde o conjunto de treinamento fornece a resposta correta (presença ou ausência) para cada exemplo de entrada (dados CSI).

No aprendizado supervisionado, a tarefa é aprender uma função $c = f(z)$ que mapeia exemplos de entrada z para saídas c . Quando a saída pertence a um conjunto finito de valores categóricos, como no caso de “presença” ou “ausência”, o problema é denominado classificação. Formalmente, dado um conjunto de treinamento de N exemplos $\{(z_1, c_1), (z_2, c_2), \dots, (z_N, c_N)\}$, onde cada z_i representa um vetor de características extraídas do CSI e c_i é o rótulo correspondente, o objetivo é encontrar uma hipótese f que minimize o erro de predição em novos exemplos não vistos durante o treinamento (Russell; Norvig, 2020).

Um aspecto fundamental do aprendizado supervisionado é o equilíbrio entre adequação aos dados de treinamento e capacidade de generalização. Modelos excessivamente complexos podem memorizar os dados de treinamento (*overfitting*), apresentando baixo desempenho em novos dados, enquanto modelos muito simples podem ser incapazes de capturar os padrões relevantes (*underfitting*). Este equilíbrio é particularmente relevante para dados CSI, que apresentam alta dimensionalidade e variabilidade devido a fatores ambientais.

Para este trabalho, foi selecionado o algoritmo *Random Forest* como classificador supervisionado, por apresentar características adequadas ao problema de detecção de presença através de CSI, conforme detalhado na Seção 3.3. Durante o desenvolvimento, outros algoritmos foram avaliados como referência comparativa, incluindo regressão logística, porém o *Random Forest* demonstrou o melhor equilíbrio entre desempenho e capacidade de generalização entre sessões temporais distintas.

3.3 FLORESTAS ALEATÓRIAS (RANDOM FORESTS)

As *Random Forests* constituem um método de conjunto que aborda as limitações das árvores de decisão individuais através da combinação de múltiplas árvores construídas com elementos de aleatoriedade. Esta técnica representa uma evolução do conceito de *bagging* (*bootstrap aggregating*), introduzindo aleatoriedade adicional na seleção de atributos durante a construção de cada árvore (Russell; Norvig, 2020).

3.3.1 FUNDAMENTOS E CONSTRUÇÃO

O algoritmo de *Random Forest* opera gerando K árvores de decisão distintas, cada uma treinada em uma amostra diferente dos dados de treinamento. Para cada árvore, os dados de treinamento são amostrados com reposição (*bootstrap sampling*), permitindo que alguns exemplos apareçam múltiplas vezes enquanto outros podem não aparecer. Este processo gera conjuntos de treinamento ligeiramente diferentes para cada árvore.

A inovação crucial das *Random Forests* reside na introdução de aleatoriedade na seleção de atributos. Em cada ponto de divisão durante a construção de uma árvore, ao invés de considerar todos os atributos disponíveis, seleciona-se aleatoriamente um subconjunto de m atributos dentre os n totais. Para problemas de classificação, tipicamente utiliza-se $m = \sqrt{n}$, enquanto para regressão usa-se $m = n/3$. Calcula-se então o ganho de informação apenas para estes m atributos selecionados, escolhendo aquele com maior ganho para realizar a divisão (Russell; Norvig, 2020).

Para classificação, a predição final é obtida por votação majoritária entre as K árvores. Para regressão, a saída é a média das predições individuais:

$$f(z) = \frac{1}{K} \sum_i f_i(z) \quad (3)$$

onde $f_i(z)$ representa a predição da i -ésima árvore.

3.3.2 VANTAGENS E RESISTÊNCIA AO OVERFITTING

As *Random Forests* apresentam propriedades notáveis que as tornam particularmente adequadas para o problema de detecção de presença humana a partir de CSI:

- **Redução de variância:** a seleção aleatória de atributos produz árvores altamente diversificadas. Quando combinadas, essa diversidade reduz a variância do modelo geral, tornando-o mais robusto a variações nos dados de entrada. Essa característica é fundamental para dados de CSI, que apresentam variabilidade significativa devido a fatores ambientais.
- **Resistência ao *overfitting*:** diferentemente de árvores individuais, *Random Forests* demonstram forte resistência ao sobreajuste. Estudos teóricos indicam que, na maioria dos casos, à medida que se adicionam mais árvores à floresta, o erro converge sem crescer. Assim, não é necessário realizar poda nas árvores individuais, pois o conjunto compensa o *overfitting* de árvores específicas.
- **Eficiência computacional:** embora a construção de múltiplas árvores possa parecer custosa, a seleção reduzida de atributos em cada divisão ($m \ll n$) acelera o treinamento e dispensa passos adicionais de poda. Além disso, as árvores podem ser construídas em paralelo, aproveitando arquiteturas *multicore* de forma eficiente.
- **Capacidade de lidar com alta dimensionalidade:** a seleção aleatória de subconjuntos de atributos torna as *Random Forests* naturalmente adequadas para problemas com grande número de características, como é o caso dos dados de CSI, onde cada combinação antena–subportadora resulta em múltiplos atributos contínuos.

Yousefi *et al.* (2017) avaliaram *Random Forest* com 100 árvores aplicado a *features* de (*Short-Time Fourier Transform*, STFT) para reconhecimento de seis atividades humanas, obtendo desempenho razoável em atividades com movimento intenso, com 81% para caminhar e 88% para correr, embora com limitações para atividades estáticas. Em seu estudo comparativo, HMM e LSTM superaram o desempenho do *Random Forest*, indicando que a escolha do classificador é sensível ao tipo de tarefa. Para classificação binária de presença, como no presente trabalho, o *Random Forest* se mostra mais adequado por sua simplicidade, resistência ao *overfitting* e capacidade de fornecer probabilidades de classificação Russell e Norvig (2020).

3.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

A seleção do *Random Forest* como algoritmo de classificação para este trabalho fundamenta-se em suas características complementares e adequação ao problema de detecção de presença através de CSI. O algoritmo destaca-se por sua robustez a *outliers* e ruído nos dados, por não requerer normalização dos dados de entrada e por fornecer probabilidades de

classificação, propriedade essencial para o mecanismo de calibração adaptativa do *threshold* implementado no sistema. A resistência ao *overfitting* e a capacidade de lidar com alta dimensionalidade tornam o método particularmente adequado para dados CSI brutos, sem necessidade de seleção manual rigorosa de características. A combinação de múltiplas árvores através de votação majoritária tem se mostrado eficaz em diversos domínios de aprendizado de máquina, consolidando o *Random Forest* como uma abordagem robusta para problemas de classificação complexos (Russell; Norvig, 2020). Adicionalmente, a implementação disponível nativamente no MATLAB através da função *TreeBagger* facilita a integração com o *pipeline* de processamento de sinais desenvolvido neste trabalho, permitindo treinamento, validação e inferência em tempo real dentro do mesmo ambiente de desenvolvimento.

4 SISTEMA DE MEDIÇÃO PROPOSTO

Este capítulo apresenta a arquitetura proposta para o sistema de detecção de presença humana baseado em sinais Wi-Fi, integrando os conceitos de sensoriamento por radiofrequência discutidos no Capítulo 2 com as técnicas de aprendizado de máquina apresentadas no Capítulo 3. O sistema proposto é composto por quatro componentes principais: infraestrutura Wi-Fi existente, hardware de captura ESP32, plataforma de processamento MATLAB e algoritmo de classificação *Random Forest*.

4.1 VISÃO GERAL DO SISTEMA

O sistema opera em duas fases distintas: treinamento e operação. Durante a fase de treinamento, dados CSI são coletados em cenários controlados com e sem presença humana e utilizados para treinar o classificador de aprendizado de máquina. Na fase de operação, o sistema captura continuamente sinais Wi-Fi, extrai características CSI e aplica o modelo treinado para classificar o estado atual do ambiente como presença ou ausência.

A Figura 6 apresenta o diagrama de blocos completo do sistema proposto, ilustrando o fluxo de dados desde a emissão dos sinais Wi-Fi até a decisão final de classificação.

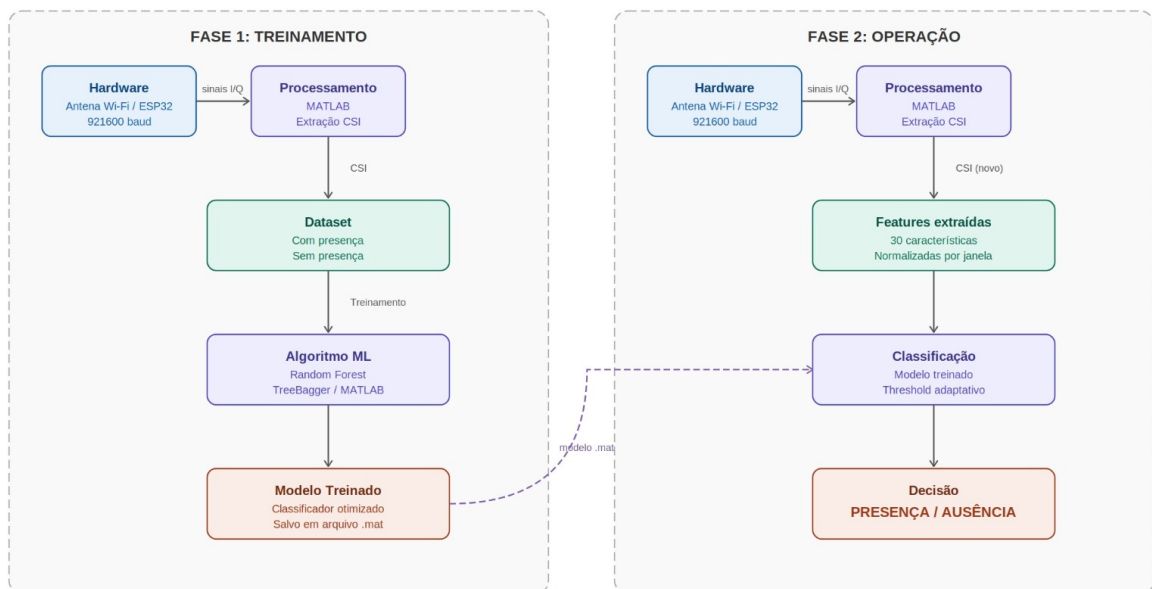


Figura 6 – Diagrama de blocos geral do sistema de detecção de presença.

Fonte: Autoria própria

4.2 COMPONENTES DO SISTEMA

4.2.1 INFRAESTRUTURA Wi-Fi EXISTENTE

O sistema aproveita a infraestrutura Wi-Fi já instalada no ambiente monitorado, não requerendo equipamentos dedicados adicionais para transmissão. Um roteador Wi-Fi convencional opera continuamente, transmitindo pacotes de dados na banda de 2,4 GHz seguindo o padrão IEEE 802.11n. Estes pacotes podem ser de dois tipos: tráfego de dados convencional, gerado naturalmente pela comunicação de dispositivos conectados à rede, como *smartphones*, *laptops* e *tablets*, e pacotes *beacon*, transmitidos periodicamente pelo roteador a cada 100 ms aproximadamente para anunciar a presença da rede, mesmo quando não há dispositivos conectados.

A vantagem de utilizar infraestrutura existente é dupla: elimina custos de instalação de hardware dedicado e garante que o sistema de sensoriamento não interfira nas operações normais de comunicação da rede.

4.2.2 SISTEMA DE CAPTURA ESP32

O ESP32 constitui o elemento de hardware principal do sistema de medição, responsável por capturar os sinais Wi-Fi transmitidos pelo roteador após sua interação com o ambiente. Como detalhado na Seção 2.5, o ESP32 é um microcontrolador de duplo núcleo que opera nativamente no padrão IEEE 802.11n, acessando internamente as informações de estado do canal sem necessidade de processamento externo de radiofrequência.

O *firmware* `csi_recv_router`, disponível no repositório oficial `espressif/esp-csi`, configura o dispositivo para capturar os valores I/Q das 64 subportadoras OFDM e transmiti-los continuamente via porta serial ao computador hospedeiro. A taxa de captura obtida foi de aproximadamente 92 a 110 *frames* por segundo, suficiente para a extração das características estatísticas utilizadas na classificação.

A interface serial opera a 921600 *baud*, com o ESP32 conectado ao computador via USB. Após a abertura da conexão, o sistema aguarda 12 segundos para a estabilização do canal Wi-Fi antes de iniciar qualquer captura. Um teste preliminar de 2 segundos verifica se os dados CSI estão sendo recebidos corretamente, esperando-se no mínimo 10 *frames* para prosseguir.

A Figura 7 apresenta o diagrama de blocos completo do sistema de captura baseado no ESP32, ilustrando o fluxo de processamento desde a transmissão Wi-Fi até a decisão de classificação.

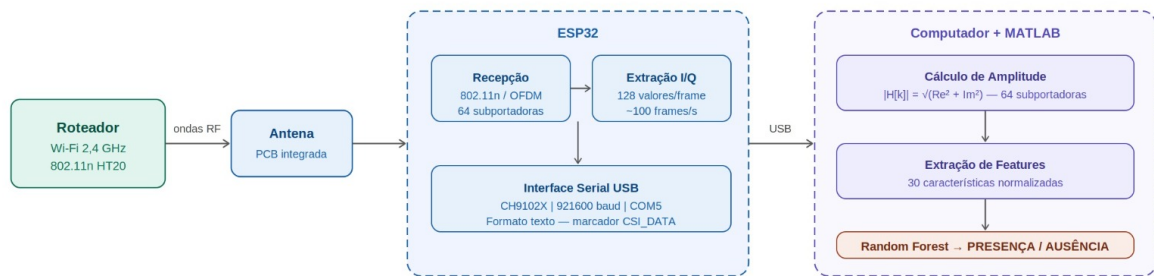


Figura 7 – Sistema de captura de sinais Wi-Fi para detecção de presença usando ESP32.

Fonte: Autoria própria

4.2.3 PLATAFORMA DE PROCESSAMENTO MATLAB

O MATLAB constitui a plataforma central de processamento, responsável por três funções principais: aquisição de dados do ESP32, pré-processamento e extração de CSI, e interface com o algoritmo de aprendizado de máquina.

Aquisição de Dados: A interface entre o ESP32 e o MATLAB é realizada via porta serial, utilizando a função `serialport()` do MATLAB com `timeout` configurado em 3 segundos. Os dados CSI chegam como *strings* de texto contendo os 128 valores I/Q por *frame*, que são convertidos em amplitudes pela função `ler_csi_buffer`, implementada especificamente para o formato de saída do *firmware* `csi_recv_router`. A amplitude de cada subportadora é calculada conforme a (2), apresentada na Seção 2.5.4, onde $\text{Re}[k]$ e $\text{Im}[k]$ são as componentes real e imaginária da k -ésima subportadora.

Pré-processamento e Extração de CSI: O pré-processamento implementado em MATLAB inclui as seguintes etapas sequenciais:

1. Recepção e *parsing* dos dados seriais: leitura do *buffer* serial e identificação das linhas contendo o marcador `CSI_DATA`;
2. Cálculo de amplitude: conversão dos pares I/Q em amplitudes para cada uma das 64 subportadoras;
3. Normalização intra-janela: aplicação de *z-score* por *frame*, removendo a dependência de amplitude absoluta do canal e tornando as características relativas ao estado momentâneo do sinal;
4. Extração de características: cálculo de 30 *features* estatísticas organizadas em sete grupos, conforme detalhado na Seção 4.3;
5. Organização dos dados: armazenamento das características em matriz estruturada para classificação.

A Figura 8 apresenta o fluxograma do processamento de sinais Wi-Fi no MATLAB, detalhando as etapas desde a entrada dos dados seriais até a geração do vetor de características para classificação.

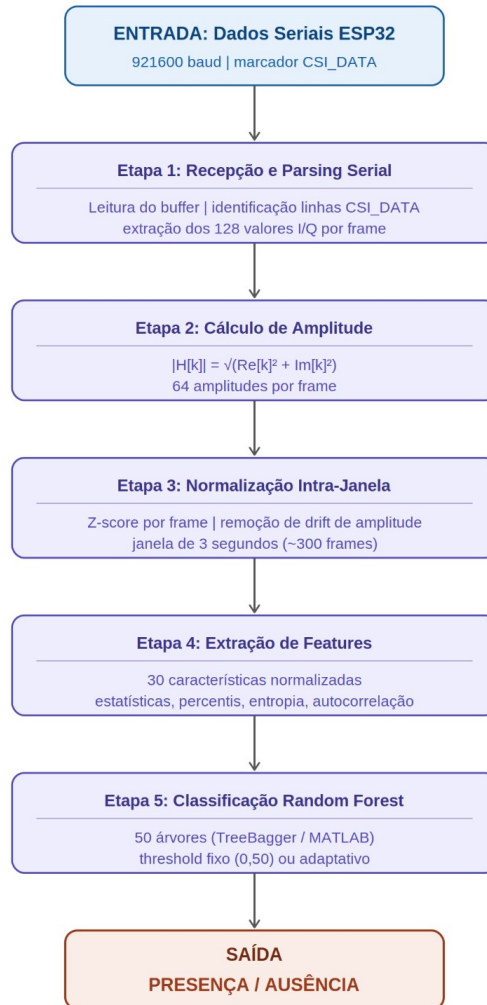


Figura 8 – Fluxograma do processamento de sinais Wi-Fi no MATLAB.

Fonte: Autoria própria

Scripts Implementados

O *pipeline* de processamento e classificação foi integralmente implementado em MATLAB, organizado em oito *scripts* distribuídos em uma estrutura de pastas dedicada ao projeto. Cada *script* possui responsabilidade bem definida dentro do fluxo de dados, desde a leitura dos dados seriais até a análise de diagnóstico do canal. A Tabela 3 apresenta os *scripts* desenvolvidos e suas respectivas funções.

Tabela 3 – Scripts desenvolvidos e suas funções

Script	Função
<code>ler_csi_buffer.m</code>	Converte os <i>bytes</i> brutos recebidos via serial em matriz de amplitudes CSI, realizando o <i>parsing</i> das linhas com marcador <code>CSI_DATA</code> e o cálculo de amplitude a partir dos pares I/Q
<code>extrair_features.m</code>	Extrai as 30 <i>features</i> normalizadas de uma janela de amostras CSI, aplicando normalização intra-janela por <i>z-score</i> e calculando os sete grupos de características descritos na Seção 4.3
<code>experimento_novo.m</code>	Executa um experimento completo de forma sequencial e automatizada, incluindo aquecimento, coleta intercalada, treinamento com validação LORO e teste imediato
<code>experimento_testar.m</code>	Realiza testes em tempo real com modelo já treinado, suportando modelo individual ou combinado de múltiplos experimentos, com opção de calibração adaptativa do <i>threshold</i>
<code>monitorar_drift.m</code>	Captura dados CSI continuamente por horas com o ambiente vazio e analisa a variação temporal das métricas do canal, gerando estatísticas de correlação com o tempo para comprovação do <i>drift</i>
<code>preparar_WiMANS.m</code>	Converte os arquivos do <i>dataset</i> WiMANS do formato <i>NumPy</i> para o formato <code>.mat</code> do MATLAB, realizando as adaptações necessárias para simular as condições do ESP32
<code>extrair_features_WiMANS.m</code>	Adapta o <i>pipeline</i> de extração de <i>features</i> para o <i>dataset</i> WiMANS, que possui 30 subportadoras em vez das 64 do ESP32, mantendo a mesma lógica de normalização intra-janela
<code>validar_WiMANS.m</code>	Aplica o <i>pipeline</i> completo de classificação ao <i>dataset</i> WiMANS, gerando resultados por <i>dataset</i> completo, por ambiente e por número de usuários

Fonte: Autoria própria

Os códigos completos de cada *script* estão disponíveis publicamente no repositório GitHub do projeto: <https://github.com/joaofelipecorso/tcc-wifi-csi-esp32>, permitindo a reprodução integral do sistema por outros pesquisadores.

4.3 PIPELINE DO SISTEMA

O módulo de aprendizado de máquina foi implementado utilizando a função `TreeBagger` da *Statistics and Machine Learning Toolbox* do MATLAB, responsável por transformar os dados brutos de CSI em decisões de classificação. O sistema opera em duas fases, treinamento e operação, cujo fluxo geral é ilustrado na Figura 8.

4.3.1 ENGENHARIA DE CARACTERÍSTICAS

Antes do treinamento, são extraídas 30 *features* discriminativas dos dados CSI, organizadas nos seguintes grupos:

- *Estatísticas globais normalizadas (3 features)*: variabilidade média, variabilidade máxima e *spread* entre subportadoras;
- *Variação média por frame (1 feature)*: nível médio de desvio padrão de cada *frame*, calculado sobre amplitude bruta sem normalização intra-janela;
- *Razões entre grupos de subportadoras (4 features)*: razões entre grupos de frequências sensíveis, baixas, altas e a razão entre altas e baixas, calculadas sobre a amplitude bruta para capturar a distribuição relativa de energia;
- *Desvio padrão temporal por grupo (9 features)*: desvio padrão temporal de 8 grupos de subportadoras mais o bloco sensível correspondente às subportadoras 45 a 53;
- *Variabilidade inter-frame (5 features)*: MAD médio, desvio padrão das diferenças, subportadora com maior variação, autocorrelação *lag-1* e *spread* da autocorrelação;
- *Percentis da distribuição (5 features)*: percentis 10, 25, 50, 75 e 90;
- *Forma da distribuição (3 features)*: *skewness*, *kurtosis* e entropia de Shannon.

4.3.2 FASE DE TREINAMENTO

Os dados CSI são coletados em dois cenários controlados, ambiente vazio e ambiente com pessoa parada, e as 30 *features* são extraídas para cada janela de 3 segundos, correspondendo a aproximadamente 300 *frames* CSI. O roteador Wi-Fi transmite pacotes continuamente, o ESP32 captura os valores I/Q das subportadoras OFDM e os transmite via porta serial ao MATLAB, que calcula as amplitudes, aplica a normalização intra-janela e constrói o *dataset* rotulado com os rótulos “presença” e “ausência”.

A validação é feita pelo método *leave-one-round-out* (LORO): para cada rodada de coleta, o modelo é treinado nas demais e testado naquela, avaliando a capacidade de generalização entre momentos temporais distintos. Rodadas com acurácia LORO inferior a 70% são automaticamente descartadas do treinamento final. O classificador é então treinado com as rodadas válidas usando *Random Forest* com 50 árvores, `MinLeafSize` igual a 5 e `MaxNumSplits` igual a 20, e o modelo resultante é salvo em arquivo `.mat`.

4.3.3 FASE DE OPERAÇÃO

Em operação, o sistema captura CSI em janelas de 3 segundos, extrai as mesmas 30 *features* e aplica o modelo treinado, que retorna tanto a classe predita quanto a probabilidade de presença. A decisão final utiliza *threshold* padrão de 0,50 ou, quando ativada, um *threshold* calibrado adaptativamente: capturando 30 segundos de dados com o ambiente vazio imediatamente antes do teste, o sistema calcula o novo limiar como a média mais dois desvios padrão das probabilidades observadas, restrito ao intervalo entre 0,30 e 0,80. Este mecanismo compensa o *drift* temporal do canal sem necessidade de retreinamento do modelo. O sistema então reporta “presença” ou “ausência” e pode acionar ações automatizadas conforme necessário.

4.4 MÉTRICAS DE DESEMPENHO

O desempenho do sistema foi avaliado através das seguintes métricas:

- Validação LORO (*Leave-One-Round-Out*): proporção de acertos ao remover uma rodada de coleta por vez do treinamento, métrica primária por avaliar a capacidade de generalização entre momentos temporais distintos;
- Acurácia: proporção de classificações corretas sobre o total de amostras;
- Precisão: proporção de verdadeiros positivos sobre o total de positivos preditos, relevante para minimizar falsos alarmes;
- *Recall* (Sensibilidade): proporção de verdadeiros positivos sobre o total de positivos reais, relevante para garantir que presenças não sejam perdidas;
- *F1-Score*: média harmônica entre precisão e *recall*;
- Tempo de Resposta: latência entre mudança de estado real e detecção pelo sistema.

4.5 CONSIDERAÇÕES PRÁTICAS DE IMPLEMENTAÇÃO

A implementação prática do sistema proposto requer atenção a diversos aspectos operacionais.

Posicionamento de Equipamentos:

O roteador e o ESP32 devem estar posicionados de forma a maximizar a cobertura da área de interesse. Recomenda-se evitar posicionamento muito próximo, a menos de 1 metro, pois pode saturar o receptor, e muito distante, a mais de 10 metros, pois reduz a relação sinal-ruído. O ESP32 deve ser conectado ao computador hospedeiro via cabo USB, garantindo alimentação estável e comunicação serial confiável.

Calibração Inicial:

O sistema deve passar por fase de coleta controlada onde as características do ambiente vazio e ocupado são estabelecidas. Recalibração periódica pode ser necessária se o *layout* do ambiente mudar significativamente. Para compensar o *drift* temporal do canal Wi-Fi, o mecanismo de calibração adaptativa do *threshold* permite ajustar o ponto de decisão em 30 segundos antes de cada sessão de teste.

Robustez a Interferências:

A presença de outras redes Wi-Fi no mesmo canal pode afetar a qualidade do CSI. Dispositivos *Bluetooth* e fornos de micro-ondas, que operam na banda de 2,4 GHz, podem causar interferência. A normalização intra-janela implementada no *pipeline* de extração de características ajuda a mitigar os efeitos de variações de amplitude absoluta do sinal. Adicionalmente, recomenda-se que a rede Wi-Fi esteja relativamente ociosa durante a operação, pois uso intenso de *streaming* ou *downloads* pode alterar o canal e degradar a classificação.

5 METODOLOGIA EXPERIMENTAL

Este capítulo descreve os procedimentos adotados para a coleta de dados, treinamento e validação do sistema de detecção de presença humana proposto. A metodologia é apresentada em três partes: o protocolo de coleta experimental com o ESP32 em ambiente residencial, a estratégia de validação com o *dataset* público WiMANS e os critérios de avaliação de desempenho adotados.

5.1 VALIDAÇÃO COM DATASET WiMANS

5.1.1 DESCRIÇÃO DO DATASET

O WiMANS (*WiFi-based Multi-user Activity Sensing*) é um *dataset* de referência publicado pelo *Imperial College London* (Huang *et al.*, 2024). O *dataset* contém 11.286 amostras CSI coletadas em banda dual com zero a cinco usuários por amostra em três ambientes distintos: sala de aula, sala de reunião e sala vazia. O *hardware* utilizado na coleta foi uma placa Intel 5300 NIC com configuração 3x3 MIMO e 30 subportadoras, operando a 1000 Hz de taxa de CSI.

Esta validação tem por objetivo verificar se a abordagem de aprendizado de máquina adotada neste trabalho, composta pelo *pipeline* de *features* normalizadas e pelo classificador *Random Forest*, consegue separar presença de ausência em dados de referência da literatura, independentemente do *hardware* de captura utilizado. Trata-se, portanto, de uma validação da abordagem metodológica e não de uma comparação direta entre o ESP32 e o *Intel 5300*.

5.1.2 ADAPTAÇÕES REALIZADAS

Para aplicar o *pipeline* desenvolvido neste trabalho ao *dataset* WiMANS, foram realizadas as seguintes adaptações:

1. Seleção de um único par de antenas (TX1-RX1) dos nove disponíveis, simulando a condição de antena única do ESP32;
2. Subamostragem de aproximadamente 2.800 *frames* para 300 *frames* por amostra, simulando a taxa de aproximadamente 100 Hz do ESP32. A subamostragem foi realizada por seleção uniforme de *frames*, sem aplicação de filtro *anti-aliasing* prévio, o que constitui uma simplificação metodológica reconhecida;
3. Adaptação da função de extração de *features* para 30 subportadoras, em vez das 64 do ESP32, mantendo a mesma lógica de normalização intra-janela;
4. Utilização exclusiva da banda de 2,4 GHz, resultando em 5.643 amostras;

5. Classificação binária, com zero usuários correspondendo à classe “ausência” e um ou mais usuários correspondendo à classe “presença”;
6. Balanceamento do *dataset* por subamostragem da classe presença para proporção de 1:3 em relação à ausência, resultando em 1.188 amostras totais. A proporção 1:3 foi adotada para preservar maior representatividade da classe presença, que naturalmente domina o *dataset* original (297 amostras de ausência contra 5.346 de presença), evitando descarte excessivo de amostras informativas.

5.1.3 CENÁRIOS DE TESTE

Foram definidos três cenários de teste para avaliação abrangente da capacidade de generalização da abordagem:

O primeiro cenário é o *dataset* completo com *split* 80/20 aleatório, onde o modelo é treinado em 80% das amostras e testado nos 20% restantes, com amostras de todos os ambientes em ambos os conjuntos. Este cenário avalia o desempenho *in-distribution*.

O segundo cenário é o teste por ambiente, onde o modelo é treinado e testado dentro do mesmo ambiente, avaliando o desempenho quando as condições de propagação são homogêneas.

O terceiro cenário é o *cross-environment*, onde o modelo é treinado em dois ambientes e testado no terceiro, nunca visto durante o treinamento. Este cenário é o mais relevante para avaliar a capacidade de generalização real da abordagem, sendo diretamente comparável ao impacto do *drift* temporal observado nos experimentos com o ESP32.

5.2 AMBIENTE E CONDIÇÕES DE TESTE

Todos os experimentos com o ESP32 foram realizados em ambiente residencial, especificamente em um quarto de apartamento com morador único. A escolha deste ambiente fundamenta-se em dois critérios complementares: a possibilidade de controle total das condições experimentais, especialmente quanto ao tráfego da rede Wi-Fi e à ausência de outros ocupantes durante as coletas, e a representatividade do cenário para as aplicações práticas visadas pelo sistema, como automação residencial e monitoramento não invasivo.

O roteador Wi-Fi e o ESP32 foram posicionados em cômodos distintos durante todos os experimentos. A porta do quarto permaneceu fechada em todas as fases de coleta e teste, garantindo consistência das condições de propagação do sinal entre as sessões. Os parâmetros do ambiente de teste são apresentados na Tabela 4. A Figura 9 ilustra o *layout* do apartamento, indicando o posicionamento do roteador na sala e do ESP32 no quarto utilizados nos experimentos.

Tabela 4 – Parâmetros do ambiente de teste

Parâmetro	Valor
Tipo de ambiente	Quarto de apartamento residencial
Ocupação	Morador único
Posicionamento do roteador	Sala
Condição da porta	Fechada em todas as fases
Estado de ausência	Pessoa fora do quarto, em outro cômodo
Estado de presença	Pessoa dentro do quarto, em pé, parada

Fonte: Autoria própria




Figura 9 – Layout do ambiente de teste com posicionamento do roteador e do ESP32.

Fonte: Autoria própria

5.3 PROTOCOLO DE COLETA INTERCALADA

O protocolo de coleta foi desenvolvido para eliminar o viés de sessão, ou seja, evitar que o modelo aprenda o estado temporal do canal em vez da presença humana propriamente dita. Para isso, as coletas de ausência e presença foram intercaladas em rodadas curtas dentro de uma mesma sessão, garantindo que ambas as classes estejam representadas em condições temporais similares do canal Wi-Fi.

Cada experimento segue uma sequência fixa de quatro etapas, executadas de forma contínua e automatizada pelo *script* `experimento_novo.m`, sem interrupções entre as fases.

Etapa 1 – Aquecimento (60 segundos): Com o usuário dentro do quarto, o ESP32 captura e descarta dados durante 60 segundos para estabilizar o canal Wi-Fi após a abertura da porta serial e a conexão com a rede.

Etapa 2 – Coleta intercalada (3 rodadas): Cada rodada consiste em quatro fases sequenciais. Primeiro, 20 segundos de transição para o usuário sair do quarto. Em seguida, 45 segundos de coleta de ausência, com o usuário fora do quarto e a porta fechada. Depois, 20 segundos de transição para o usuário retornar. Por fim, 45 segundos de coleta de presença, com o usuário dentro do quarto e com a porta fechada. Cada amostra individual corresponde a uma janela de 3 segundos, equivalente a aproximadamente 300 *frames* CSI. O intervalo de 20 segundos de transição entre as fases de ausência e presença foi dimensionado para cobrir dois efeitos: o tempo físico necessário para o deslocamento do usuário até o cômodo de destino e o fechamento da porta, e uma margem adicional para que o canal multipercurso convirja para o novo estado estacionário antes do início da coleta rotulada.

Etapa 3 – Treinamento automático: Imediatamente após a coleta, o sistema extrai as *features*, avalia cada rodada pela validação LORO, descarta rodadas com acurácia inferior a 70% e treina o modelo final com as rodadas válidas.

Etapa 4 – Teste imediato (2 rodadas): Com a mesma estrutura da coleta, porém utilizando o modelo recém-treinado para classificar cada amostra em tempo real. O teste ocorre imediatamente após o treinamento, sem intervalo, para garantir máxima estabilidade do canal.

Os parâmetros do protocolo são resumidos na Tabela 5.

Tabela 5 – Parâmetros do protocolo de coleta intercalada

Parâmetro	Valor
Rodadas de coleta	3
Rodadas de teste	2
Duração por classe por rodada	45 segundos
Duração por amostra	3 segundos (~ 300 <i>frames</i> CSI)
Transição entre fases	20 segundos
Aquecimento inicial	60 segundos
Amostras por experimento (coleta)	~ 39 ausência + ~ 39 presença = ~ 78
Amostras por experimento (teste)	~ 26 ausência + ~ 26 presença = ~ 52
Tempo total por experimento	~ 12 minutos

Fonte: Autoria própria

5.3.1 JUSTIFICATIVA DO PROTOCOLO INTERCALADO

Coletar todos os dados de uma classe de forma contínua antes de iniciar a coleta da outra introduziria um viés sistemático no treinamento: o *drift* temporal do canal Wi-Fi tornaria as condições de propagação durante a coleta de ausência estruturalmente diferentes das condições durante a coleta de presença, comprometendo a capacidade do modelo de generalizar para novos dados. A alternância entre as classes em janelas curtas de 45 segundos garante

que ambas sejam representadas em condições temporais similares do canal, neutralizando o efeito do *drift* como fator de confundimento no treinamento do modelo.

5.4 EXPERIMENTOS REALIZADOS

Foram realizados três experimentos independentes, em momentos diferentes, seguindo o protocolo descrito na Seção 5.3. Cada experimento gerou um modelo individual treinado exclusivamente com seus próprios dados e testado imediatamente após o treinamento. Adicionalmente, os *datasets* dos três experimentos foram combinados para treinar um modelo unificado, avaliando a capacidade de generalização entre sessões coletadas em momentos temporalmente distintos. A Tabela 6 apresenta a composição detalhada do *dataset* utilizado em cada etapa.

Tabela 6 – Composição detalhada do *dataset* experimental

Experimento	Origem	Ausência	Presença	Total	Uso
Exp 1	Coleta (3 rodadas × 45s)	39	39	78	Treino individual
Exp 1	Teste (2 rodadas × 45s)	26	26	52	Teste individual e <i>dataset</i> combinado*
Exp 2	Coleta (3 rodadas × 45s)	39	39	78	Treino individual
Exp 2	Teste (2 rodadas × 45s)	26	26	52	Teste individual
Exp 3	Coleta (3 rodadas × 45s)	39	39	78	Treino individual
Exp 3	Teste (2 rodadas × 45s)	26	26	52	Teste individual
TOTAL	Coleta	117	117	234	—
TOTAL	Coleta + dados adicionais	143	143	286	Treino combinado

Fonte: Autoria própria

O *dataset* combinado totaliza 286 amostras: 234 provenientes das coletas dos três experimentos, sendo 78 de cada experimento, e 52 amostras adicionais oriundas do conjunto de teste do Experimento 1, incorporadas ao treinamento para aumentar a diversidade temporal. A diferença essencial entre os experimentos é temporal: o Exp. 1 e o Exp. 2 foram realizados em momentos próximos entre si, enquanto o Exp. 3 foi coletado em um instante significativamente mais distante. Essa distância temporal é o fator central para os resultados da 6.4, em que o modelo combinado de Exp. 1 e Exp. 2 generalizou bem, atingindo 98,1% de acurácia, mas apresentou degradação ao incorporar o Exp. 3. Quanto à composição, apenas o conjunto de teste do Exp. 1 pôde ser reaproveitado no treinamento combinado, pois o *script* responsável por persistir os dados de teste foi atualizado somente após a execução do Exp. 2 e do Exp. 3, cujos testes, portanto, não foram salvos em formato compatível. O modelo combinado foi sempre avaliado com capturas ao vivo nunca vistas durante o treinamento.

5.5 ESTRATÉGIA DE VALIDAÇÃO

5.5.1 LEAVE-ONE-ROUND-OUT (LORO)

A validação primária utilizada neste trabalho é o LORO. Neste procedimento, cada rodada de coleta é removida uma vez do conjunto de treinamento e utilizada como conjunto de teste, avaliando a capacidade real de generalização do modelo entre momentos temporais diferentes dentro de uma mesma sessão. Esta métrica é mais rigorosa que a validação cruzada *k-fold* tradicional, pois respeita a estrutura temporal dos dados e simula de forma mais fiel o comportamento do modelo em dados futuros não vistos.

Rodadas com acurácia LORO inferior a 70% são automaticamente descartadas do treinamento final. Esta decisão é reconhecida como um ponto de discussão: descartar rodadas com baixo desempenho pode inflar os resultados ao remover dados difíceis. Para transparência, todas as rodadas descartadas são reportadas nos resultados.

5.5.2 VALIDAÇÃO CRUZADA *K-FOLD*

A validação cruzada *k-fold* com k igual a 5 é utilizada como métrica complementar. Por embaralhar amostras de diferentes rodadas nos *folds*, esta métrica tende a superestimar o desempenho real, pois mistura momentos temporais distintos no treinamento e no teste. Os resultados *k-fold* são reportados em paralelo aos resultados LORO para permitir comparação com a literatura, porém o LORO é considerado a métrica primária de desempenho neste trabalho.

5.5.3 TESTE AO VIVO

Além das validações internas, o sistema foi avaliado por meio de testes ao vivo com dados nunca vistos pelo modelo, capturados em tempo real após o treinamento. Para o modelo combinado, foram realizados testes sem calibração e com calibração adaptativa do *threshold*, conforme descrito na Seção 4.3, reportando ambos os resultados separadamente para transparência.

5.6 MONITORAMENTO DE *DRIFT* TEMPORAL

Para investigar o fenômeno de *drift* temporal do canal Wi-Fi e seu impacto no desempenho do sistema, foi realizado um experimento de monitoramento contínuo por 4 horas e 14 minutos com o ambiente completamente vazio. Durante todo o período, nenhuma pessoa esteve no quarto ou no apartamento. O sistema capturou amostras a cada 13 segundos aproximadamente, totalizando 1.104 amostras, registrando amplitude, fase, variância, autocorrelação, ener-

gia e as 30 *features* do *pipeline* de classificação. Os resultados desta análise são apresentados no Capítulo 6.

6 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados obtidos nos experimentos realizados com o sistema de detecção de presença humana baseado em sinais Wi-Fi e ESP32. Os resultados estão organizados em quatro partes: validação com o *dataset* público WIMANS, experimentos individuais com o modelo treinado e testado na mesma sessão, modelo combinado com dados de múltiplas sessões e análise de *drift* temporal do canal Wi-Fi.

6.1 DIAGNÓSTICO DA FASE DO CSI

Conforme antecipado na Seção 2.5.7, antes da definição do *pipeline* final foi realizado um diagnóstico para determinar se a informação de fase das subportadoras contribuiria para a detecção de presença além da amplitude. Para isso, foram capturadas 10 amostras de 3 segundos de cada classe e calculado o tamanho de efeito de Cohen's d para cada componente, métrica que quantifica a separabilidade entre as distribuições das duas classes (Cohen, 1988). Formalmente, o Cohen's d é definido como:

$$d = \frac{|\mu_1 - \mu_2|}{s_p} \quad (4)$$

onde μ_1 e μ_2 são as médias das duas classes (presença e ausência) e s_p é o desvio padrão *pooled*, calculado por:

$$s_p = \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}} \quad (5)$$

sendo s_1^2 e s_2^2 as variâncias e n_1, n_2 os tamanhos das amostras de cada classe (Cohen, 1988).

Para cada uma das 64 subportadoras, calculou-se Cohen's d para a amplitude e separadamente para a fase, totalizando 128 análises, utilizando as médias e o desvio padrão *pooled* conforme as equações acima. Os valores médio e máximo de d , bem como a contagem de *features* acima dos limiares de 0,8 e 1,5, são apresentados na Tabela 7.

Tabela 7 – Separabilidade entre classes por componente CSI: Cohen's d para amplitude e fase

Componente	Cohen's d médio	Cohen's d máximo	Features $d > 0,8$	Features $d > 1,5$
Amplitude	0,78	3,63	57 de 128	18 de 128
Fase	0,32	0,63	0 de 128	0 de 128

Fonte: Autoria própria

A amplitude apresentou Cohen's d máximo de 3,63, indicando separabilidade excelente em determinadas subportadoras, com 57 das 128 *features* com d superior a 0,8. A fase, por outro lado, não apresentou nenhuma *feature* com d superior a 0,8, com valor máximo de apenas 0,63. Segundo Cohen (1988), valores de d acima de 0,8 indicam efeito grande, confirmando a superioridade discriminativa da amplitude sobre a fase neste experimento. Com base nes-

tes resultados, a fase foi excluída do *pipeline* de classificação, utilizando-se exclusivamente a amplitude das subportadoras como entrada para a extração de características.

6.2 RESULTADOS DA VALIDAÇÃO COM WiMANS

6.2.1 DATASET COMPLETO

O *pipeline* de classificação foi aplicado ao *dataset* WiMANS com *split* 80/20 aleatório, conforme descrito na Seção 5.1.3. O conjunto de treinamento conteve 950 amostras e o conjunto de teste 238 amostras.

A Tabela 8 apresenta os resultados obtidos.

Tabela 8 – Resultados do *pipeline* aplicado ao *dataset* WiMANS: *dataset* completo

Métrica	Valor
Acurácia (<i>split</i> 80/20)	99,20%
Validação cruzada <i>5-fold</i>	99,7% ± 0,4%
TN	59
FP	2
FN	0
TP	177
Precisão Presença	0,99
<i>Recall</i> Presença	1
F1 Presença	0,99
Precisão Ausência	1
<i>Recall</i> Ausência	0,97
F1 Ausência	0,98

Fonte: Autoria própria

A acurácia de 99,2% confirma que o *pipeline* de *features* normalizadas combinado com o classificador *Random Forest* consegue separar presença de ausência com alta precisão quando as condições de treinamento e teste são homogêneas, validando a abordagem metodológica adotada neste trabalho independentemente do hardware de captura utilizado.

6.2.2 RESULTADO POR AMBIENTE

A Tabela 9 apresenta os resultados para cada ambiente do WiMANS, tanto no cenário de treino e teste no mesmo ambiente quanto no cenário *cross-environment*.

O desempenho de 100,0% em todos os ambientes no cenário de mesmo ambiente confirma a alta separabilidade das classes quando as condições são homogêneas. O desempenho *cross-environment*, entre 72,3% e 74,6%, é particularmente relevante pois representa a generalização para um ambiente nunca visto durante o treinamento.

Tabela 9 – Resultados por ambiente: mesmo ambiente e cross-environment (WiMANS)

Cenário	Treino	Teste	Acurácia
Mesmo ambiente	<i>Classroom</i>	<i>Classroom</i>	100,00%
Mesmo ambiente	<i>Meeting Room</i>	<i>Meeting Room</i>	100,00%
Mesmo ambiente	<i>Empty Room</i>	<i>Empty Room</i>	100,00%
<i>Cross-environment</i>	<i>Meeting + Empty</i>	<i>Classroom</i>	74,30%
<i>Cross-environment</i>	<i>Classroom + Empty</i>	<i>Meeting Room</i>	72,30%
<i>Cross-environment</i>	<i>Classroom + Meeting</i>	<i>Empty Room</i>	74,60%

Fonte: Autoria própria

6.2.3 RESULTADO POR NÚMERO DE USUÁRIOS

A Tabela 10 apresenta a acurácia por número de usuários presentes no ambiente durante a coleta, validando o comportamento do sistema como classificador binário de presença e ausência.

Tabela 10 – Acurácia por número de usuários presentes no ambiente (WiMANS)

Usuários	Amostras de Teste	Acurácia
0 (ausência)	61	96,70%
1	55	100,00%
2	29	100,00%
3	35	100,00%
4	26	100,00%
5	32	100,00%

Fonte: Autoria própria

Todos os cenários com um ou mais usuários foram classificados corretamente como presença, confirmando que o sistema detecta a ocupação independentemente do número de pessoas presentes. A acurácia de 96,7% para a ausência é consistente com os dois falsos positivos observados na matriz de confusão geral.

6.3 RESULTADOS DOS EXPERIMENTOS INDIVIDUAIS

Cada um dos três experimentos foi treinado e testado de forma independente, utilizando exclusivamente seus próprios dados. O teste imediato ocorreu segundos após o treinamento, dentro da mesma sessão, garantindo máxima estabilidade do canal Wi-Fi entre as fases.

6.3.1 DESEMPENHO GERAL

A Tabela 11 apresenta os resultados consolidados dos três experimentos individuais.

Tabela 11 – Resultados consolidados dos experimentos individuais

Métrica	Exp 1	Exp 2	Exp 3
Amostras treino	78 (39+39)	78 (39+39)	78 (39+39)
Amostras teste	52 (26+26)	52 (26+26)	52 (26+26)
Acurácia	98,1%	90,4%	90,4%
TN	26	21	22
FP	0	5	4
FN	1	0	1
TP	25	26	25
Precisão Presença	1,00	0,84	0,86
Recall Presença	0,96	1,00	0,96
F1 Presença	0,98	0,91	0,91
Precisão Ausência	0,96	1,00	0,96
Recall Ausência	1,00	0,81	0,85
F1 Ausência	0,98	0,89	0,90

Fonte: Autoria própria

O Experimento 1 obteve a maior acurácia, de 98,1%, com zero falsos positivos e apenas um falso negativo. Os Experimentos 2 e 3 obtiveram acurácia de 90,4%, com falsos positivos concentrados na segunda rodada de teste. Este padrão indica que mesmo dentro de uma sessão de aproximadamente 12 minutos, o *drift* temporal já começa a afetar a classificação da classe ausência nas rodadas mais distantes do treinamento.

6.3.2 DETALHAMENTO POR RODADA

A Tabela 12 apresenta o desempenho detalhado por rodada de teste para cada experimento, evidenciando o padrão de degradação temporal.

Tabela 12 – Desempenho detalhado por rodada de teste nos experimentos individuais

Experimento	Rodada	Classe	Acertos/Total	Acurácia	Prob. Média
Exp 1	R1	Ausência	13/13	100,0%	0,020
Exp 1	R1	Presença	13/13	100,0%	0,758
Exp 1	R2	Ausência	13/13	100,0%	0,037
Exp 1	R2	Presença	12/13	92,3%	0,836
Exp 2	R1	Ausência	12/13	92,3%	0,291
Exp 2	R1	Presença	13/13	100,0%	0,804
Exp 2	R2	Ausência	9/13	69,2%	0,476
Exp 2	R2	Presença	13/13	100,0%	0,889
Exp 3	R1	Ausência	13/13	100,0%	0,267
Exp 3	R1	Presença	12/13	92,3%	0,748
Exp 3	R2	Ausência	9/13	69,2%	0,314
Exp 3	R2	Presença	13/13	100,0%	0,992

Fonte: Autoria própria

Observa-se um padrão consistente nos Experimentos 2 e 3: a segunda rodada de ausência caiu para 69,2% de acurácia, com a probabilidade média de presença subindo de aproximadamente 0,27 na primeira rodada para valores entre 0,31 e 0,48 na segunda rodada. A classe

presença, por outro lado, manteve alto desempenho em todas as rodadas dos três experimentos, com *recall* de 100% em cinco das seis rodadas avaliadas. Este comportamento assimétrico indica que o *drift* temporal afeta predominantemente o *baseline* de ausência, tornando-o progressivamente mais similar ao padrão de presença ao longo do tempo.

6.4 MODELO COMBINADO

Os *datasets* dos três experimentos foram combinados em um único modelo para avaliar a capacidade de generalização entre sessões coletadas em momentos temporalmente distintos. O *dataset* combinado totalizou 286 amostras, conforme descrito na Seção 5.4.

6.4.1 VALIDAÇÃO CRUZADA *K-FOLD*

A validação cruzada *k-fold* com *k* igual a 5 aplicada ao *dataset* combinado resultou em acurácia de 94,4%. Conforme discutido na Seção 5.5.2, este valor tende a superestimar o desempenho real por misturar amostras de diferentes sessões temporais nos *folds* de treinamento e teste. Os resultados dos testes ao vivo, apresentados a seguir, refletem o desempenho real do modelo em dados nunca vistos.

6.4.2 TESTE AO VIVO SEM CALIBRAÇÃO

O modelo combinado foi testado ao vivo em duas tentativas consecutivas, sem nenhuma calibração prévia, com dados nunca vistos durante o treinamento.

A Tabela 13 apresenta as matrizes de confusão e métricas das duas tentativas.

Tabela 13 – Resultados do modelo combinado sem calibração: duas tentativas

Métrica	Tentativa 1	Tentativa 2
Acurácia	69,20%	66,70%
TN	10	9
FP	16	18
FN	0	0
TP	26	27
Precisão Presença	0,62	0,60
<i>Recall</i> Presença	1,00	1,00
F1 Presença	0,76	0,75
Precisão Ausência	1,00	1,00
<i>Recall</i> Ausência	0,38	0,33
F1 Ausência	0,56	0,50
Prob. média ausência	0,477	0,600
Prob. média presença	0,929	0,892

Fonte: Autoria própria

Os resultados evidenciam duas observações importantes. Primeiro, o *recall* de presença foi perfeito em ambas as tentativas, indicando que o modelo nunca deixou de detectar a pre-

sença humana. Segundo, o *recall* de ausência foi de apenas 38,5% e 33,3% respectivamente, com 16 e 18 amostras de ausência classificadas incorretamente como presença. Vale destacar que, na Tentativa 2, a janela de coleta de 45 s gerou 27 amostras por classe (54 no total) em vez das 26 previstas pelo protocolo, em razão de variações na taxa de captura do CSI, mantendo a acurácia de $66,7\% = 36/54$ matematicamente consistente. A probabilidade média de ausência subiu de 0,477 na primeira tentativa para 0,600 na segunda, realizada poucos minutos depois, enquanto a probabilidade de presença permaneceu estável. Este comportamento constitui evidência direta de *drift* temporal contínuo no *baseline* de ausência entre as duas tentativas.

6.4.3 CONTEXTO: MODELO DE DOIS EXPERIMENTOS SEM CALIBRAÇÃO

Para fins de referência, antes da adição do terceiro experimento ao *dataset* combinado, o modelo treinado com apenas dois experimentos alcançou 98,1% de acurácia no teste ao vivo sem calibração, com probabilidade média de ausência de 0,025 e probabilidade média de presença de 0,863. A inclusão do terceiro experimento, coletado em momento temporalmente mais distante, degradou significativamente o *baseline* de ausência, elevando sua probabilidade média de 0,025 para 0,477. Este resultado demonstra que a generalização entre sessões próximas é excelente, mas se deteriora progressivamente com o aumento do intervalo temporal entre as sessões de coleta.

6.5 ANÁLISE DE DRIFT TEMPORAL

O fenômeno de *drift* temporal do canal Wi-Fi é reconhecido na literatura como limitação fundamental de sistemas baseados em CSI. Em estudo conduzido com ESP32-S2 ao longo de mais de três semanas em ambiente controlado, Brunello *et al.* (2025) demonstraram empiricamente que fatores temporais impactam significativamente as amostras de CSI mesmo na ausência de modificações físicas do ambiente, com degradação acumulando-se progressivamente ao longo do tempo. Os resultados obtidos no presente trabalho são consistentes com essas observações.

Para fornecer evidência quantitativa do *drift* temporal, foi realizado um monitoramento contínuo de 4 horas e 14 minutos com o ambiente completamente vazio, conforme descrito na Seção 5.6. As Figuras 10 e 11 apresentam os resultados obtidos durante essa sessão, na qual nenhuma pessoa esteve presente no ambiente, garantindo que qualquer variação observada seja atribuível exclusivamente a fatores externos à presença humana.

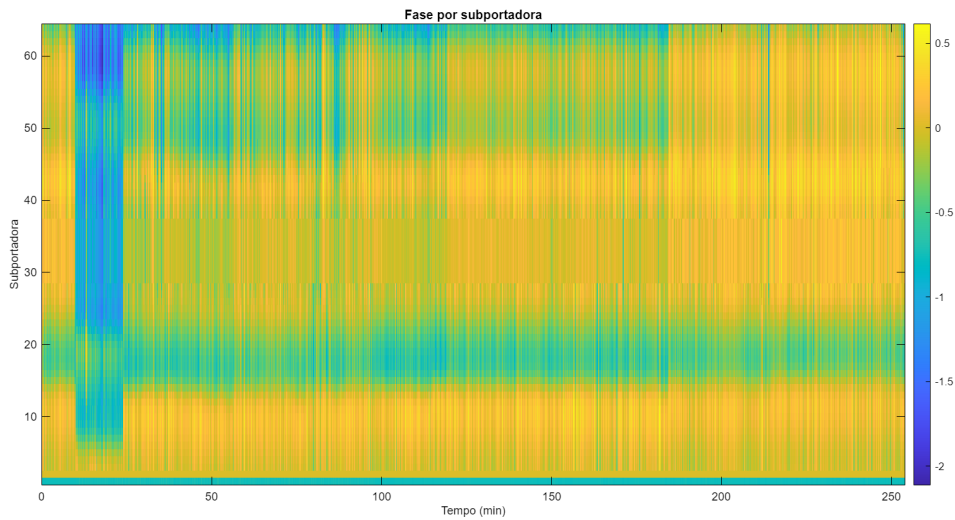


Figura 10 – Mapa de calor da fase por subportadora ao longo do monitoramento contínuo de 4h14min.

Fonte: Autoria própria

A Figura 10 exibe o mapa de calor da fase por subportadora ao longo do tempo. Nos primeiros minutos da sessão, a fase apresenta valores predominantemente negativos e instáveis, especialmente nas subportadoras de índice mais baixo, evidenciando um período de transiente inicial. Ao longo do restante da sessão, o canal estabiliza parcialmente, mas a coloração não permanece uniforme: regiões ciano e verde persistem nas subportadoras inferiores (índices 1 a 20, aproximadamente), enquanto as demais tendem ao amarelo, indicando que diferentes subportadoras convergem para estados de fase distintos. Esse comportamento heterogêneo entre subportadoras, mesmo em ambiente vazio, é uma manifestação direta do *drift* temporal acumulado pelo hardware ao longo do tempo.

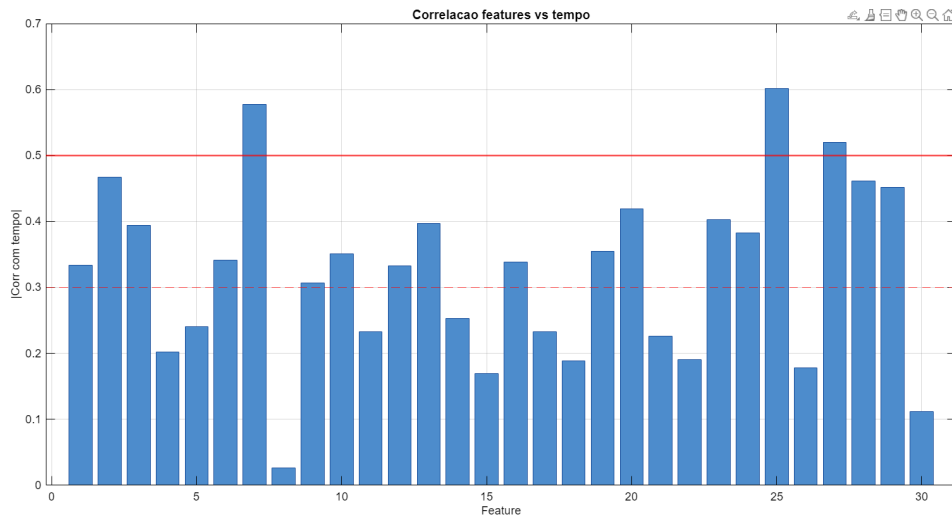


Figura 11 – Valor absoluto da correlação de cada uma das 30 *features* do *pipeline* com o tempo decorrido.

Fonte: Autoria própria

A Figura 11 sintetiza a intensidade do *drift* sob a perspectiva das *features* extraídas pelo *pipeline*, apresentando o valor absoluto da correlação de cada uma das 30 *features* com o tempo decorrido. As linhas de referência tracejada ($|\text{corr}| = 0,30$) e contínua ($|\text{corr}| = 0,50$) delimitam faixas de correlação moderada e forte, respectivamente. Observa-se que a grande maioria das *features* apresenta correlação não desprezível com o tempo: apenas uma delas situa-se próxima de zero, enquanto diversas ultrapassam o limiar de 0,30 e três chegam a superar 0,50, com destaque para as *features* de índices aproximados 7, 25 e 26, que atingem valores entre 0,57 e 0,61. Esses resultados confirmam que o canal Wi-Fi deriva sistematicamente ao longo do tempo mesmo na ausência de qualquer atividade humana, o que representa um desafio concreto para sistemas de detecção baseados em CSI e reforça a necessidade de estratégias de compensação ou coleta periódica de dados de referência.

6.5.1 CORRELAÇÕES DAS MÉTRICAS COM O TEMPO

A Tabela 14 apresenta as correlações de cada métrica do canal com o tempo decorrido.

Tabela 14 – Relação das métricas do canal Wi-Fi com o tempo durante monitoramento contínuo

Métrica	Média	Desvio Padrão	Mínimo	Máximo	Corr. com tempo	Classificação
Amplitude média	17,47	0,33	16,22	18,34	-0,254	Leve
Amplitude desvio padrão	15,33	0,19	15,00	16,68	-0,198	Leve
Fase média (rad)	-0,13	0,23	-1,32	0,31	0,556	Forte
Fase desvio padrão	1,86	0,27	1,55	3,19	-0,424	Moderado
Variabilidade inter-frame	2,70	0,35	1,88	4,36	0,126	Leve
Autocorrelação lag-1	0,11	0,14	-0,14	0,50	-0,279	Leve
Energia total	247.534	33.098	69.064	329.115	-0,064	Estável

Fonte: Autoria própria

A fase média apresentou a maior correlação com o tempo, de 0,556, confirmando sua inadequação como *feature* de classificação e corroborando a decisão apresentada na Seção 2.5.7. A amplitude média apresentou correlação leve de $-0,254$, indicando maior estabilidade temporal em comparação à fase, porém ainda sujeita a variações ao longo de sessões longas.

6.5.2 VARIAÇÃO ENTRE INÍCIO E FIM DO MONITORAMENTO

A Tabela 15 compara as métricas entre os primeiros e os últimos 30 minutos do monitoramento, quantificando a magnitude do *drift* ao longo de 4 horas.

Tabela 15 – Variação das métricas entre os primeiros e últimos 30 minutos do monitoramento

Métrica	Primeiros 30 min	Últimos 30 min	Varição
Amplitude média	17,64	17,26	-2,20%
Fase média	-0,44 rad	+0,04 rad	+109,1%
Fase desvio padrão	2,29	1,78	-22,20%
Autocorrelação	0,14	0,06	-53,80%
Energia total	264.321	251.505	-4,80%

Fonte: Autoria própria

6.5.3 IMPACTOS NAS FEATURES DE CLASSIFICAÇÃO

Das 30 *features* utilizadas no modelo de classificação, 3 apresentaram correlação forte com o tempo, com valor absoluto superior a 0,5, e 18 apresentaram correlação moderada, com valor absoluto superior a 0,3. A correlação média foi de 0,323 e a correlação máxima foi de 0,602.

Estes resultados confirmam que o *drift* temporal é um fenômeno real, mensurável e que afeta diretamente as *features* utilizadas na classificação. A degradação observada no modelo combinado sem calibração, de 98,1% para aproximadamente 67%, é consistente com o impacto das 18 *features* com correlação moderada com o tempo. O *drift* ocorre mesmo sem nenhuma pessoa no ambiente, possivelmente causado por fatores como atividade em apartamentos vizinhos, ajustes automáticos do roteador, variações de temperatura do hardware ou interferências eletromagnéticas externas.

6.6 TESTE AO VIVO COM CALIBRAÇÃO ADAPTATIVA

Para compensar o *drift* temporal identificado, foi aplicado o mecanismo de calibração adaptativa do *threshold* descrito na Seção 4.3. O procedimento consistiu em capturar 30 segundos de dados com o ambiente vazio imediatamente antes do teste, calculando o novo *threshold* como a média mais dois desvios padrão das probabilidades observadas durante a calibração. Os dados da calibração são apresentados na Tabela 16.

Tabela 16 – Dados da calibração adaptativa do *threshold*

Parâmetro	Valor
Duração da calibração	30 segundos
Amostras coletadas	9
Probabilidade média	0,76
Desvio padrão	0,134
<i>Threshold</i> calculado	1,028
<i>Threshold</i> aplicado (limite máximo)	0,800

Fonte: Autoria própria

O *threshold* calculado de 1,028 foi truncado para o limite máximo de 0,800, pois quatro das nove amostras de calibração apresentaram probabilidade superior a 0,80, indicando que o *baseline* de ausência estava muito próximo do padrão de presença naquela sessão. O truncamento foi necessário para preservar a capacidade do modelo de detectar presença. A Tabela 17 apresenta os resultados com calibração e a comparação direta com o teste sem calibração.

Tabela 17 – Comparação direta entre teste sem calibração e com calibração adaptativa

Métrica	Sem Calibração	Com Calibração	Diferença
Acurácia	66,70%	94,40%	+27,8 pontos
<i>Recall</i> Ausência	33,30%	92,60%	+59,3 pontos
<i>Recall</i> Presença	100,00%	96,30%	-3,7 pontos
F1 Ausência	0,50	0,94	+0,44
F1 Presença	0,75	0,95	+0,20
<i>Threshold</i>	0,500 (fixo)	0,800 (adaptativo)	—

Fonte: Autoria própria

A calibração elevou a acurácia em 27,8 pontos percentuais, com o *recall* de ausência saltando de 33,3% para 92,6%. O único custo foi uma pequena queda no *recall* de presença, de 100,0% para 96,3%, representando um falso negativo adicional. Para a maioria das aplicações práticas, este compromisso é aceitável, pois um falso negativo ocasional tem impacto menor do que um sistema que classifica sistematicamente o ambiente vazio como ocupado.

É importante ressaltar que o resultado com calibração deve ser interpretado como desempenho adaptativo ao ambiente atual, e não como teste independente equivalente ao sem calibração. Ambos os cenários são reportados para permitir avaliação completa do sistema.

6.7 RESUMO COMPARATIVO DOS CENÁRIOS

A Tabela 18 consolida os resultados de todos os cenários avaliados para o *dataset* ca-seiro com ESP32.

6.8 DISCUSSÃO GERAL

Os resultados obtidos permitem extrair quatro conclusões principais.

Tabela 18 – Resumo comparativo de todos os cenários avaliados com o ESP32

Cenário	Dataset Treino	Tipo de Teste	Acurácia	F1 Presença	F1 Ausência
Exp 1 individual	78 amostras	Imediato	98,10%	0,98	0,98
Exp 2 individual	78 amostras	Imediato	90,40%	0,91	0,89
Exp 3 individual	78 amostras	Imediato	90,40%	0,91	0,90
2 exp combinados	156 amostras	Ao vivo, independente	98,10%	0,98	0,98
3 exp sem cal. (tent. 1)	286 amostras	Ao vivo, independente	69,20%	0,76	0,56
3 exp sem cal. (tent. 2)	286 amostras	Ao vivo, independente	66,70%	0,75	0,50
3 exp com calibração	286 amostras	Ao vivo, adaptativo	94,40%	0,95	0,94

Fonte: Autoria própria

A primeira é a viabilidade técnica da detecção de presença com ESP32. As acurácias entre 90,4% e 98,1% nos experimentos individuais demonstram que o ESP32, com custo inferior a R\$ 50 e antena PCB integrada, é capaz de capturar variações do canal Wi-Fi suficientes para detectar presença humana com desempenho comparável ao reportado na literatura com hardware mais sofisticado.

A segunda é o impacto do *drift* temporal como principal limitação. A queda de 98,1% para aproximadamente 67% no modelo combinado sem calibração evidencia que a generalização entre sessões temporalmente distantes é a principal limitação do sistema, e não a qualidade do hardware ou do modelo de classificação. Esta limitação é inerente ao *Wi-Fi sensing* como tecnologia, conforme confirmado pelos resultados *cross-environment* do WiMANS, que apresentaram desempenho similar de 72% a 74%.

A terceira é a eficácia da calibração adaptativa como solução prática. O mecanismo de calibração de 30 segundos elevou a acurácia do modelo combinado de 66,7% para 94,4%, demonstrando ser uma solução prática e viável para compensar o *drift* temporal em aplicações reais. O procedimento é simples, rápido e não requer modificação do modelo treinado.

A quarta é a validação da abordagem metodológica pelo WiMANS. A acurácia de 99,2% no *dataset* do *Imperial College London* confirma que o *pipeline* de *features* normalizadas e o classificador *Random Forest* constituem uma abordagem metodologicamente sólida para detecção de presença via Wi-Fi CSI, independentemente do hardware de captura utilizado.

7 CONCLUSÃO

Este trabalho apresentou o desenvolvimento e a validação de um sistema de detecção de presença humana em ambientes internos baseado em sinais Wi-Fi, utilizando o microcontrolador ESP32 para captura do CSI e o algoritmo *Random Forest* para classificação. O sistema foi projetado como uma solução de baixo custo, não invasiva e replicável, aproveitando a infraestrutura Wi-Fi já existente nos ambientes monitorados.

Os resultados obtidos demonstram a viabilidade técnica da abordagem. Nos experimentos individuais, onde o modelo foi treinado e testado dentro da mesma sessão, o sistema alcançou acurácias entre 90,4% e 98,1%, com *F1-score* igual ou superior a 0,89 para ambas as classes. Estes resultados são expressivos considerando que o hardware utilizado é um módulo ESP32 com antena PCB integrada adquirido por menos de R\$ 50, em contraste com equipamentos de pesquisa que custam milhares de dólares. A validação com o *dataset* público WiMANS do *Imperial College London* reforçou a solidez da abordagem metodológica, com acurácia de 99,2% em condições homogêneas de treinamento e teste, confirmando que o *pipeline* de *features* normalizadas combinado com o *Random Forest* constitui uma solução tecnicamente robusta para a tarefa de detecção binária de presença via Wi-Fi CSI.

O principal desafio identificado foi o *drift* temporal do canal Wi-Fi, fenômeno que causa degradação progressiva do desempenho do modelo à medida que o intervalo entre as sessões de coleta e teste aumenta. O monitoramento contínuo de 4 horas e 14 minutos com o ambiente vazio confirmou que 21 das 30 *features* utilizadas apresentam correlação moderada ou forte com o tempo, mesmo na ausência de qualquer pessoa no ambiente. Este fenômeno reduziu a acurácia do modelo combinado de 98,1% para aproximadamente 67% em testes ao vivo sem calibração. Importante ressaltar que esta limitação não é específica deste trabalho: Brunello *et al.* (2025) confirmaram, em experimento de longa duração com hardware da família ESP32, que o *drift* temporal afeta o CSI mesmo sem nenhuma pessoa no ambiente, sendo portanto uma característica inerente ao Wi-Fi *sensing* como tecnologia.

Como resposta prática a esta limitação, foi desenvolvido e validado um mecanismo de calibração adaptativa do *threshold* de decisão, que consiste em capturar 30 segundos de dados com o ambiente vazio antes de cada sessão de uso e ajustar automaticamente o ponto de decisão do modelo. Este mecanismo elevou a acurácia do modelo combinado de 66,7% para 94,4%, com o *recall* de ausência saltando de 33,3% para 92,6%, demonstrando ser uma solução prática, rápida e eficaz para uso em aplicações reais.

Do ponto de vista das contribuições acadêmicas, este trabalho integra as áreas de telecomunicações e inteligência artificial dentro da Engenharia Elétrica, demonstrando que técnicas avançadas de sensoriamento por radiofrequência podem ser implementadas com hardware de consumo de massa amplamente acessível. A documentação completa do protocolo experimental, dos *scripts* MATLAB desenvolvidos e das limitações identificadas contribui para a reprodutibilidade da pesquisa e oferece uma base sólida para trabalhos futuros na área.

Como sugestões para trabalhos futuros, destacam-se as seguintes direções. A validação do sistema em múltiplos dias consecutivos com calibração periódica permitiria avaliar a eficácia do mecanismo adaptativo em condições de uso prolongado. A substituição da antena PCB integrada por uma antena externa do tipo IPEX poderia aumentar a sensibilidade do sistema e melhorar o desempenho em ambientes maiores ou com maior atenuação. A randomização da ordem das classes no protocolo de coleta eliminaria o possível confundimento temporal identificado como limitação do protocolo atual. A exploração de modelos com recalibração automática periódica, sem necessidade de intervenção do usuário, tornaria o sistema mais adequado para implantação em ambientes reais de automação residencial. Por fim, a extensão do sistema para detecção de atividades além da presença estática, como quedas ou padrões de movimento, representaria uma evolução natural para aplicações de monitoramento de saúde de idosos e pessoas com necessidades especiais.

Em síntese, os resultados obtidos confirmam que a detecção de presença humana baseada em Wi-Fi CSI com ESP32 e *Random Forest* é uma abordagem tecnicamente viável, economicamente acessível e socialmente responsável, com potencial real de aplicação em sistemas de automação residencial, segurança predial e monitoramento não invasivo de saúde.

REFERÊNCIAS

- ADIB, F. *et al.* Smart homes that monitor breathing and heart rate. *In: PROCEEDINGS OF THE 33RD ANNUAL ACM CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS: Chi '15*. 2015, New York. **Anais [...]** New York: ACM, 2015. p. 837–846. Seoul, 18–23 abr. 2015.
- ANDREWS, J. G.; HUMPHREYS, T. E.; JI, T. 6G takes shape. **IEEE BITS the Information Theory Magazine**, v. 4, n. 1, p. 2–24, 2024.
- BRASIL. AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES . **Resolução nº 680, de 27 de junho de 2017: aprova o Regulamento sobre Equipamentos de Radiocomunicação de Radiação Restrita**. [S.l.], 2017. Disponível em: <https://informacoes.anatel.gov.br/legislacao/resolucoes/2017/936-resolucao-680>. Acesso em: 18 maio 2026.
- BRUNELLO, A. *et al.* Time matters: empirical insights into the limits and challenges of temporal generalization in CSI-based Wi-Fi sensing. **Internet of Things**, v. 30,, p. 101634, 2025.
- COHEN, J. **Statistical Power Analysis for the Behavioral Sciences**. 2. ed. Hillsdale: Lawrence Erlbaum Associates, 1988.
- COLEMAN, D.; WESTCOTT, D. . **Your Go-To-Guide for Channel & Transmit Power on Wi-Fi Networks (Part 2)**. [S.l.], 2017. Disponível em: <https://www.engeniustech.com/go-guide-channel-transmit-power-wi-fi-networks-2/>. Acesso em: 16 nov. 2017.
- DIAZ, G. *et al.* . **Channel Phase Processing in Wireless Networks for Human Activity Recognition**. [S.l.], 2023. 24 100960 p.
- DU, R. *et al.* An overview on IEEE 802.11bf: WLAN sensing. **IEEE Communications Surveys & Tutorials**, v. 27, n. 1, p. 184–217, fev. 2025.
- Espressif Systems . **ESP32-DevKitC V4 Getting Started Guide**. [S.l.], s.d. Disponível em: https://docs.espressif.com/projects/esp-dev-kits/en/latest/esp32/esp32-devkitc/user_guide.html. Acesso em: 02 maio 2026.
- GUTIÉRREZ, J.; RODRÍGUEZ, V.; MARTIN, S. Comprehensive review of vision-based fall detection systems. **Sensors**, v. 21, n. 3, p. 947, 2021.
- HUANG, S. *et al.* . **WiMANS: A Benchmark Dataset for WiFi-Based Multi-User Activity Sensing**. [S.l.], 2024. ArXiv:2402.09430. Disponível em: <https://arxiv.org/abs/2402.09430>. Acesso em: 18 maio 2026.
- LIU, H. *et al.* Turning a pyroelectric infrared motion sensor into a high-accuracy presence detector by using a narrow semi-transparent chopper. **Applied Physics Letters**, v. 111, n. 24, p. 243901, 2017.
- RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 4. ed. Hoboken: Pearson, 2020.
- TAN, B. *et al.* Exploiting wifi channel state information for residential healthcare informatics. **IEEE Communications Magazine**, v. 56, n. 5, p. 130–137, 2018.
- UNITED STATES. FEDERAL COMMUNICATIONS COMMISSION . **Title 47 of the Code of Federal Regulations (CFR), Part 15: Radio Frequency Devices**. [S.l.], 2024. Disponível em: <https://www.ecfr.gov/current/title-47/chapter-I/subchapter-A/part-15>. Acesso em: 18 maio 2026.

WIRELESS TRAINING SOLUTIONS . **Understanding OFDM – Part 2 – Refresh**. [S.l.], 2018. Disponível em: <https://www.wirelesstrainingsolutions.com/understanding-ofdm-part-2-refresh/>. Acesso em: 16 nov. 2024.

WU, D. *et al.* Device-free wifi human sensing: From pattern-based to model-based approaches. **IEEE Communications Magazine**, v. 55, n. 10, p. 91–97, 2017.

YOUSEFI, S. *et al.* A survey on behavior recognition using Wi-Fi channel state information. **IEEE Communications Magazine**, v. 55, n. 10, p. 98–104, 2017.

ZHUO, Y. *et al.* Perceiving accurate CSI phases with commodity WiFi devices. *In*: IEEE INFOCOM 2017 - IEEE CONFERENCE ON COMPUTER COMMUNICATIONS. 2017, Atlanta, GA, USA. **Anais [...]** Atlanta, GA, USA: IEEE, 2017. p. 1–9.