

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO DE JOINVILLE
CURSO DE ENGENHARIA MECATRÔNICA

THOMAS HEITMANN

DESENVOLVIMENTO DE UM PROTÓTIPO PARA DETECÇÃO DE MOVIMENTAÇÃO
E CLASSIFICAÇÃO DE MATERIAL UTILIZANDO RADAR ATIVO SDR E
INTELIGÊNCIA ARTIFICIAL

Joinville
2026

THOMAS HEITMANN

DESENVOLVIMENTO DE UM PROTÓTIPO PARA DETECÇÃO DE MOVIMENTAÇÃO
E CLASSIFICAÇÃO DE MATERIAL UTILIZANDO RADAR ATIVO SDR E
INTELIGÊNCIA ARTIFICIAL

Trabalho apresentado como requisito parcial para obtenção do título de bacharel em Engenharia Mecatrônica, no Curso de Engenharia Mecatrônica, do Centro Tecnológico de Joinville, da Universidade Federal de Santa Catarina.

Orientador: Dr. Ricardo José Pfitscher

Joinville
2026

À minha família.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por estar sempre ao meu lado, tanto nos momentos de alegria quanto nos períodos mais desafiadores da minha vida acadêmica, iluminando meu caminho ao longo desta jornada.

Agradeço também aos meus pais, Sandra e Marc, pelo amor, apoio e incentivo ao longo de toda a minha trajetória acadêmica e pessoal. Seus ensinamentos, dedicação e confiança foram fundamentais para que eu pudesse superar os desafios encontrados durante esse percurso.

À minha irmã, Sabrina, pelo companheirismo, apoio e compreensão em todos os momentos, contribuindo de forma especial para minha formação e crescimento pessoal.

Ao meu orientador, Prof. Dr. Ricardo José Pfitscher, pela orientação, disponibilidade, paciência e pelos valiosos ensinamentos compartilhados durante o desenvolvimento deste trabalho.

Por fim, agradeço aos meus amigos e colegas, que estiveram presentes ao longo dessa caminhada, compartilhando conhecimentos, experiências, desafios e momentos de descontração, tornando essa trajetória mais leve e enriquecedora.

“Nunca, jamais desanimeis, embora venham ventos contrários.”

Santa Paulina

RESUMO

A detecção de movimentações e a classificação de características de objetos constituem desafios relevantes em aplicações de monitoramento remoto e sensoriamento geotécnico. Nesse contexto, sistemas de radar baseados em Rádio Definido por Software (*Software Defined Radio* – SDR) têm se destacado como alternativas promissoras devido à sua flexibilidade, baixo custo e capacidade de adaptação a diferentes cenários experimentais. Considerando esse contexto, este trabalho apresenta o desenvolvimento e a avaliação de um radar ativo baseado em SDR para detecção de movimentação e classificação de objetos por meio de técnicas de inteligência artificial. O sistema foi implementado utilizando o dispositivo ADALM-PLUTO, uma antena helicoidal direcional e o ambiente GNU Radio para transmissão, recepção e processamento dos sinais Doppler refletidos pelos objetos presentes no ambiente monitorado. A metodologia adotada baseou-se na aquisição de sinais experimentais em diferentes condições de distância, velocidade e material dos objetos analisados, seguida da geração de espectrogramas por meio da Transformada Rápida de Fourier (*Fast Fourier Transform* – FFT) e do treinamento de modelos de aprendizado de máquina para classificação dos dados. Os resultados demonstraram a viabilidade da utilização de um radar ativo SDR de baixo custo para tarefas de detecção e classificação, alcançando acurácia aproximada de 82% na diferenciação entre ausência de objeto, objeto parado e objeto em movimento, 91% na classificação de distância e 83% na classificação de velocidade. Para a classificação dos materiais analisados, foram obtidos resultados mais modestos, com acurácia próxima de 65%, indicando maior dificuldade na diferenciação entre assinaturas espectrais de materiais distintos. De modo geral, os resultados evidenciam o potencial da combinação entre radares SDR e técnicas de inteligência artificial para aplicações de sensoriamento remoto, monitoramento geotécnico e detecção de movimentações em áreas sujeitas a instabilidades.

Palavra-chave: radar ativo; software defined radio; inteligência artificial.

ABSTRACT

The detection of movement and the classification of object characteristics are important challenges in remote monitoring and geotechnical sensing applications. In this context, radar systems based on Software Defined Radio (SDR) have emerged as promising alternatives due to their flexibility, low cost, and adaptability to different experimental scenarios. Considering this context, this work presents the development and experimental evaluation of an SDR-based active radar for movement detection and object classification using artificial intelligence techniques. The proposed system was implemented using the ADALM-PLUTO device, a directional helical antenna, and the GNU Radio environment for the transmission, reception, and processing of Doppler signals reflected by objects present in the monitored environment. The adopted methodology consisted of acquiring experimental signals under different object distance, velocity, and material conditions, followed by spectrogram generation through the Fast Fourier Transform (FFT) and the training of machine learning models for data classification. The results demonstrated the feasibility of using a low-cost SDR active radar for detection and classification tasks, achieving approximately 82% accuracy in distinguishing between the absence of an object, a stationary object, and a moving object, 91% accuracy in distance classification, and 83% accuracy in velocity classification. Material classification presented more modest results, reaching an accuracy of approximately 65%, indicating greater difficulty in distinguishing the spectral signatures of different materials. Overall, the results highlight the potential of combining SDR-based radar systems with artificial intelligence techniques for remote sensing, geotechnical monitoring, and movement detection in areas susceptible to instability.

Keywords: active radar; software defined radio; artificial intelligence.

LISTA DE FIGURAS

Figura 1 – Diagrama de bloco simplificado de um radar de onda contínua . . .	15
Figura 2 – Pluto SDR	17
Figura 3 – Representação gráfica de uma antena transmissora	21
Figura 4 – Representação de uma antena helicoidal	23
Figura 5 – Padrões de radiação da antena helicoidal	24
Figura 6 – IA vs Machine Learning	26
Figura 7 – Exemplo gráfico de overfitting e underfitting	27
Figura 8 – Como identificar na curva de perda se há ou não over- ou underfitting	28
Figura 9 – Exemplo de uma Matriz de Confusão	29
Figura 10 – Relação de trabalhos por área de estudo	31
Figura 11 – Etapas para a validação do projeto	36
Figura 12 – Fluxograma do funcionamento básico do radar ativo desenvolvido .	37
Figura 13 – Diagrama do radar ativo	38
Figura 14 – Variáveis e auxiliares do fluxo	39
Figura 15 – Fluxo de transmissão	39
Figura 16 – Fluxo de recepção	40
Figura 17 – Blocos de saídas e tratamento do sinal	41
Figura 18 – Antena utilizado no trabalho	43
Figura 19 – Objetos utilizados na análise experimental	44
Figura 20 – Configuração do ambiente	45
Figura 21 – Rampa utilizada no trabalho	46
Figura 22 – Exemplos de ruídos capturados pelo GNU Radio	48
Figura 23 – Tabua com as dimensões	49
Figura 24 – Interface do radar no GNU Radio em execução	52
Figura 25 – Espectrogramas gerados para velocidade lenta e distância curta . .	53
Figura 26 – Gráficos de treinamento e perda por época para classificar presença	54
Figura 27 – Matriz confusão para classificar presença	55
Figura 28 – Gráficos de treinamento e perda por época para classificar o material	56
Figura 29 – Matriz confusão para classificar o material	57
Figura 30 – Matriz confusão para classificar a distância	59
Figura 31 – Gráficos de treinamento e perda por época para classificar a distancia	60
Figura 32 – Matriz confusão para classificar a velocidade	61
Figura 33 – Matriz de confusão para classificar a velocidade do plástico	62
Figura 34 – Curvas de treinamento e validação para a classificação da velocidade	63

LISTA DE QUADROS

Quadro 1 – <i>String</i> de busca	30
Quadro 2 – Critérios de inclusão e exclusão	32
Quadro 3 – Material para referência	33
Quadro 4 – Classes geradas para cada captura do material	47

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVOS	12
1.1.1	Objetivo geral	12
1.1.2	Objetivos Específicos	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	SISTEMA DE DETECÇÃO E DISTANCIOMETRIA POR RÁDIO (RADAR)	13
2.1.1	Radar Passivo	13
2.1.2	Radar Ativo	14
2.1.2.1	Radar de onda contínua	15
2.1.3	Software Defined Radio (SDR)	16
2.1.3.1	Hardware SDR	17
2.1.3.2	Software SDR	18
2.1.4	Efeito Doppler	18
2.1.5	Transformada Rápida de Fourier	19
2.1.6	Processamento Digital De Sinais	20
2.2	ANTENAS	20
2.2.1	Antenas Omnidirecionais	22
2.2.2	Antenas Direcionais	22
2.2.2.1	Antena Helicoidal	22
2.3	INTELIGÊNCIA ARTIFICIAL	25
2.3.1	Métricas de Avaliação de Modelos de Classificação	26
2.4	TRABALHOS RELACIONADOS	30
2.4.1	Discussão dos trabalhos relacionados	34
3	METODOLOGIA	36
3.1	PREPARAÇÃO DO AMBIENTE EXPERIMENTAL	37
3.1.1	Configuração do radar ativo	37
3.1.2	Antena transmissora	42
3.1.3	Materiais dos objetos analisados	43
3.2	DESCRIÇÃO DOS TESTES	44
3.2.1	Preparação do ambiente experimental	44
3.2.2	Coleta e geração dos dados	46
3.3	GERAÇÃO DO MODELO DE IA	48
3.4	DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL	50
4	RESULTADOS	51
4.1	TESTE DE FUNCIONALIDADE	51

4.2	CLASSIFICAÇÃO DE ESPECTROGRAMAS COM IA	53
4.2.1	Classificação da Presença dos Objetos	54
4.2.2	Classificação do Material dos Objetos	56
4.2.3	Classificação da Distancia dos Objetos	58
4.2.4	Classificação da velocidade dos objetos	60
4.3	LIMITAÇÕES DO PROJETO	64
5	CONCLUSÃO	65
	REFERÊNCIAS	67

1 INTRODUÇÃO

A detecção e classificação de materiais é uma atividade fundamental em aplicações como testes não destrutivos, triagem e automação (Nongpromma *et al.*, 2025). Nesse contexto, os radares têm se destacado por apresentarem menor sensibilidade a condições climáticas, luminosidade e oclusões quando comparados a abordagens baseadas em visão computacional e laser (Singh *et al.*, 2021). Além disso, a utilização de Software Defined Radio (SDR – Rádio Definido por Software) tem ampliado a flexibilidade e reduzido os custos de implementação desses sistemas (Feng; Mughees; Wollesen, 2020).

A detecção de movimentos e a classificação de materiais podem ser aplicadas em diferentes contextos, dentre os quais se destaca o monitoramento de encostas. Alguns trabalhos têm investigado o uso de SDR para o desenvolvimento de radares (Bornhausen, 2025). Contudo, a caracterização do solo é dificultada por seu comportamento dielétrico, que influencia a propagação dos sinais eletromagnéticos em função da umidade, condutividade e mineralogia (Banaseka *et al.*, 2021). Esse fator impõe desafios adicionais ao monitoramento de deslizamentos, especialmente em ambientes com elevada presença de matéria orgânica.

No monitoramento de encostas, tecnologias como o Synthetic Aperture Radar (SAR – Radar de Abertura Sintética) e o Light Detection and Ranging (LiDAR) são amplamente empregadas. O SAR possibilita a detecção e o mapeamento de deslizamentos em condições adversas de clima e luminosidade (Mondini *et al.*, 2021), enquanto o LiDAR permite a geração de modelos digitais de elevação de alta resolução e a caracterização detalhada da morfologia do terreno (Pirasteh; Li, 2017). Além disso, soluções baseadas em radares passivos implementados em SDR, como a proposta por Bornhausen (2025), utilizam fontes de rádio já presentes no ambiente, constituindo uma alternativa de baixo custo e alta portabilidade.

Apesar de suas vantagens, essas tecnologias apresentam limitações. O SAR exige processamento complexo e elevada capacidade computacional (Mondini *et al.*, 2021); o LiDAR sofre restrições associadas à vegetação densa, sombras topográficas e grande volume de dados (Pirasteh; Li, 2017); e o radar passivo de Bornhausen (2025) depende de fontes emissoras externas e apresenta menor sensibilidade à detecção de movimentações. Por outro lado, esse trabalho observou respostas espectrais distintas para diferentes materiais, sugerindo o potencial da aplicação de inteligência artificial na classificação automática dos sinais.

Diante dessas limitações, propõe-se neste trabalho a adaptação do radar passivo desenvolvido por Bornhausen (2025) para um radar ativo, proporcionando maior controle sobre a fonte emissora. Para aumentar a precisão das medições, foram em-

pregadas antenas direcionais e técnicas de inteligência artificial para classificação automática dos sinais captados. A análise experimental busca avaliar a viabilidade da integração entre radares SDR e algoritmos de aprendizado de máquina na detecção de movimentações e classificação de materiais, contribuindo para aplicações de monitoramento geotécnico e mitigação de desastres naturais.

Dessa forma, os resultados obtidos demonstraram a viabilidade da utilização de um radar ativo baseado em SDR aliado a técnicas de inteligência artificial para detecção de movimentação e classificação de características dos objetos presentes no ambiente monitorado. O sistema desenvolvido foi capaz de diferenciar condições de presença, velocidade e distância com elevados índices de acerto e, em menor grau, propriedades relacionadas aos materiais analisados, atendendo ao objetivo geral proposto. Além disso, os resultados evidenciam o potencial da combinação entre processamento de sinais Doppler e aprendizado de máquina para aplicações futuras envolvendo monitoramento geotécnico, análise de movimentações e detecção de instabilidades em áreas de risco.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Adaptar o sistema de radar passivo SDR, projetado por Bornhausen (2025), para um radar ativo integrado com Inteligência Artificial (IA) para detectar movimentos e classificar o tipo de material aplicáveis a monitoramento de encostas.

1.1.2 Objetivos Específicos

- Adaptar o sistema de radar passivo SDR para o modo ativo;
- Integrar antenas direcionais para melhorar o isolamento do sinal e a qualidade da captura de dados;
- Coletar dados de reflexão de matéria orgânica e componentes metálicos;
- Desenvolver um algoritmo de IA para classificar movimentos e materiais;
- Avaliar a precisão e confiabilidade da classificação obtida com o sistema proposto.

2 FUNDAMENTAÇÃO TEÓRICA

Para avaliar a viabilidade de adaptar o radar passivo em SDR, proposto por Bornhausen (2025), para um radar ativo, é necessário compreender os conceitos técnicos relacionados ao funcionamento do radar. Além disso, busca-se integrá-lo com um algoritmo de classificação usando IA, com a finalidade de identificar o tipo de material em movimento. Desse modo, neste capítulo, serão abordados os fundamentos físicos, hardwares e softwares necessários para a concepção do radar e os princípios por trás do funcionamento das antenas, assim como os conceitos elementares de algoritmos e técnicas de IA.

2.1 SISTEMA DE DETECÇÃO E DISTANCIOMETRIA POR RÁDIO (RADAR)

O radar pode ser definido como um sensor eletromagnético utilizado para rastrear, detectar e localizar objetos de diferentes tipos a distâncias consideráveis (Skolnik, 2008). A capacidade do radar de detectar com precisão alvos como aeronaves, navios, veículos e alvos pequenos, como pássaros e insetos, até em condições climáticas adversas é um fator vantajoso quando comparado com dispositivos de detecção óptica e infravermelha (Skolnik, 2008).

Outro fator favorável ao uso de radares, quando se trata em monitorar e mapear regiões de risco, como encostas, é a capacidade de operar de forma contínua e em ambientes remotos, onde levantamentos tradicionais, como os baseados em geomorfologia, não são economicamente viáveis nem logisticamente práticos (Casagli *et al.*, 2016). Considerando isso, é importante apresentar as diferenças entre o radar passivo e o ativo, além de explicar o funcionamento do mesmo, para entender como a implementação de um sistema desses em SDR possa ser eficiente na detecção de deslocamentos.

De forma resumida, o radar opera emitindo ondas eletromagnéticas que, quando em contato com um alvo, serão refletidas pelo objeto e, com base na quantidade de energia retornada e o tempo que levou para voltar ao radar, é possível estimar a distância em que o alvo se encontra (Skolnik, 2008). Dependendo da fonte de sinal utilizada, os radares podem ser classificados como passivo, quando o sinal proveniente depende de uma fonte externa, ou ativo, quando o impulso é gerado pelo próprio sensor (Skolnik, 2008).

2.1.1 Radar Passivo

O radar passivo pode ser definido como um sistema que realiza a detecção e o rastreamento de alvos sem a necessidade de emitir energia eletromagnética própria,

utilizando, em vez disso, sinais de fontes emissoras já existentes no ambiente, como transmissões de rádio, televisão ou comunicações móveis (Griffiths; Baker, 2017). Diferente do radar ativo, a fonte transmissora e o emissor estão localizados em lugares diferentes, caracterizando-o como um radar biestático (World, 2025).

Essa característica o torna uma solução de baixo custo e difícil de ser detectada, por não emitir radiação própria (World, 2025). Griffiths e Baker (2017) complementam ainda que outras vantagens do radar passivo destacam-se a ampla cobertura e baixo custo de implementação, mas também destacam que, devido ao fato de depender de fontes externas, essas mesmas podem ser não otimizadas para fins de radar. Outras desvantagens relacionadas ao radar passivo é o fato de necessitar técnicas avançadas de processamento para suprimir o sinal direto e o multipercurso, além de apresentar limitação na resolução de alcance e Doppler em alvos próximos à linha entre transmissor e receptor (Griffiths; Baker, 2017).

2.1.2 Radar Ativo

O radar ativo é um sistema de detecção eletromagnético que opera emitindo ondas de rádio e analisando o eco refletido pelos alvos, permitindo determinar sua posição, distância e velocidade relativa (Skolnik, 1980). O princípio fundamental consiste na transmissão de um sinal eletromagnético por uma antena emissora e na recepção da energia refletida por um objeto, sendo o tempo de retorno do pulso usado para calcular a distância do alvo (Skolnik, 1980).


Como o radar ativo gera o próprio sinal, o sensor apresenta maior controle sobre os parâmetros de operação, como frequência, potência e forma de onda, possibilitando ajustar o sistema conforme o tipo de alvo e as condições do ambiente. Apesar de apresentar uma estrutura mais complexa e consumir mais energia, quando comparado com a configuração passiva, o radar ativo é amplamente empregado em aplicações civis e militares, especialmente em aplicações que demandam medição de alcance e rastreamento contínuo de alvos, pois além de ser capaz de detectar objetos a longa distâncias, fornece medições precisas e detalhadas sobre o alvo (World, 2025).

Atualmente existem diversos tipos de radares ativos e, apesar de não existir uma única forma de classificar um radar, autores como Skolnik (2008) geralmente os classificam pela característica principal que distingue um radar do outro. Entre os principais tipos podem ser listados o radar de pulso, que irradia uma série de pulsos retangulares, o CW – Onda Contínua (Continuous Wave) radar, que emite uma onda senoidal de forma contínua e o FMCW – Onda Contínua Modulada em Frequência (Frequency-Modulated Continuous Wave) radar, que aplica sobre a onda técnicas de modulação de frequência (Skolnik, 2008).

2.1.2.1 Radar de onda contínua

Skolnik (1980) descreve a estrutura de um radar de onda contínua conforme o diagrama simplificado representado pela Figura 1, em que um transmissor gera uma oscilação de frequência f_0 que será irradiado por uma antena. Parte dessa energia será coletada pela antena emissora, quando interceptado por um alvo e, caso o alvo se encontra em movimento a uma velocidade v_r relativa ao radar, o sinal recebido terá sua frequência deslocada em relação à f_0 em uma quantidade $\pm f_d$, que representa a variação de frequência pelo efeito Doppler.

Figura 1 – Diagrama de bloco simplificado de um radar de onda contínua



Fonte: Adaptado de Skolnik (1980, p. 70).

A equação que define f_d , pode ser descrito pela Equação 1, onde λ representa o comprimento da onda que está sendo transmitido pelo radar (Skolnik, 1980).

$$f_d = \frac{2v_r}{\lambda} \quad (1)$$

De forma geral, o desempenho do radar pode ser descrito pela Equação 2, que expressa a potência recebida P_r em função dos parâmetros do sistema e das propriedades do alvo.

$$P_r = \frac{P_t G A_e \sigma}{(4\pi)^2 S_{min}} \quad (2)$$

P_t é a potência transmitida, G o ganho das antenas, A_e a abertura efetiva da antena, σ a seção transversal do radar e S_{min} o sinal mínimo detectável (Skolnik, 1980).

Tomando a raiz quarta da Equação 2, obtém-se a expressão que determina a distância máxima entre o radar e um alvo detectável, R_{max} , representada pela Equação 3 (Skolnik, 1980).

$$R_{max} = \sqrt[4]{\frac{P_t G A_e \sigma}{(4\pi)^2 S_{min}}} \quad (3)$$

Apesar do nome, a seção transversal do radar (RCS, do inglês radar Cross Section) não apresenta relação com o próprio aparelho, mas sim com o objeto que está sendo observado (Weber, 2019). A RCS é medida em unidades de área e indica a quantidade de sinal que o alvo reflete de volta para o radar, podendo variar conforme o tamanho, material e o formato que o objeto apresenta (Weber, 2019). Segundo Skolnik (2008) superfícies metálicas planas, quando expostas de forma perpendicular ao feixe da fonte emissora do radar, apresentam maiores valores de RCS, quando comparado com alvos que apresentam superfícies rugosas ou compostas por materiais dielétricos.

Como o transmissor emite continuamente uma onda senoidal, parte dessa energia pode se acoplar ao receptor, ocasionando saturação e mascarar o eco proveniente do alvo (Skolnik, 1980), logo, é necessário adotar medidas de isolamento entre o sinal do transmissor da fonte emissora, que podem incluir o emprego de dispositivos de isolamento e filtragem, como circuladores ou duplexadores (Skolnik, 1980). Entre esses métodos, Skolnik (1980) afirma que a implementação de duas antenas separadas fisicamente apresenta o método mais eficaz, podendo alcançar isolamento de até 80 dB ou mais com antenas de alto ganho e feixes altamente diretivos.

Dado que o sistema apresenta uma simplicidade construtiva, baixo custo de implementação e alta precisão na medição de velocidade, é uma solução amplamente utilizado no monitoramento de velocidade, controle de tráfego e sensores industriais de movimento (Skolnik, 1980), indicando uma alternativa viável para o monitoramento e detecção de movimentação de encostas. Diante dessas características, a aplicação da tecnologia Software Defined Radio (SDR) surge como uma alternativa promissora para aprimorar as funcionalidades dos sistemas de radar, especialmente em aplicações de monitoramento.

2.1.3 Software Defined Radio (SDR)

Collins *et al.* (2018) definem SDR como um rádio no qual algumas ou todas as funções da camada física são definidas por software. Em essência, o SDR substitui componentes tradicionalmente implementados em hardware, como filtros, moduladores e conversores, por módulos de software, executados em um computador ou processador embarcado (Heunis; Paichard; Inggs, 2011). Isso oferece ao usuário uma arquitetura flexível e de fácil adaptação, características atraentes para projetistas que lidam com diferentes padrões e aplicações de comunicação e sensoriamento (Sadiku; Akujuobi, 2004).

No contexto de radares, a incorporação de SDRs tem impulsionado o desenvolvimento de sistemas mais versáteis, compactos e de menor custo, permitindo a reconfiguração de parâmetros operacionais, como forma de onda e largura de banda, apenas por meio de software (Feng; Mughees; Wollesen, 2020). A integração do SDR com dispositivos como o Pluto SDR (Analog Devices, 2021) e os algoritmos de proces-

samento, desenvolvidos via Matrix Laboratory (MATLAB) ou GNU is Not Unix (GNU) Radio, oferece uma ampla gama de aplicações na área de sistemas de comunicação (Collins *et al.*, 2018).

2.1.3.1 Hardware SDR

O Analog Devices Learning Module (ADALM)-Pluto, ou simplesmente Pluto SDR, representado na Figura 2, é um transceptor de SDR desenvolvido pela Analog Devices, educacionais e de pesquisa em comunicações sem fio e processamento de sinais. O dispositivo permite operar em frequências que variam aproximadamente de 325 MHz a 3,8 GHz e possui um canal de transmissão (TX) e um de recepção (RX) que podem operar em modo full duplex. Além disso apresenta uma largura de banda ajustável de até 20 MHz e tem a capacidade de trabalhar a até 61,44 Msps (Analog Devices, 2021).

Figura 2 – Pluto SDR



Fonte: Analog Devices (2021).

O ADALM-Pluto, portanto, representa uma solução acessível e versátil para o desenvolvimento de sistemas de rádio definidos por software, permitindo realizar experimentos práticos de transmissão e recepção de sinais em tempo real.

2.1.3.2 Software SDR

Conforme descrito anteriormente por Collins *et al.* (2018), o SDR depende de módulos de software para realizar tarefas como filtragem, modulação, entre outros. Essa abordagem exige um processo de desenvolvimento em duas etapas (Collins *et al.*, 2018):

1. **Desenvolvimento dos algoritmos:** Os algoritmos de modulação e processamento de sinais são projetados e testados inicialmente em um computador host, que oferece maior facilidade de depuração, visualização e ajustes de parâmetros;
2. **Implementação embarcada:** Adaptação dos algoritmos validados para execução no hardware, considerando restrições de tamanho, energia e custo.

A primeira etapa requer um mecanismo conveniente para capturar dados e realizar a análise dos sinais, bem como para desenvolver os algoritmos que irão processá-los. Para isso, é necessário um software baseado em PC que permita implementar e testar as funções de transmissão de dados e processamento de sinais digitais em um sistema de comunicações sem fio (Collins *et al.*, 2018).

Nesse contexto entram os software SDR, como o GNU Radio¹, que é uma plataforma de software livre e de código aberto voltada ao desenvolvimento de sistemas de SDR e processamento de sinais. O framework oferece uma ampla coleção de blocos de processamento que permitem criar aplicações de rádio por meio de fluxogramas visuais ou scripts em Python. Compatível com diversos hardwares, como o Pluto SDR, o GNU Radio é amplamente usado em pesquisa e ensino pela sua flexibilidade, modularidade e facilidade de integração com sistemas de comunicação e radar (GNU Radio Project, 2025). Dessa forma, após a apresentação dos principais componentes de hardware e software que compõem o sistema SDR, é possível abordar os fenômenos físicos envolvidos na detecção de movimento por radar, como o efeito Doppler.

2.1.4 Efeito Doppler

O efeito Doppler, proposto em 1842 pelo físico austríaco Johann Christian Doppler, descreve a variação na frequência observada de uma onda em função do movimento relativo entre a fonte emissora e o observador (Halliday; Resnick; Walker, 2016). Quando ambos se aproximam, a frequência percebida é maior do que a emitida; quando se afastam, é menor (Halliday; Resnick; Walker, 2016). Esse fenômeno ocorre em diferentes tipos de ondas, como as sonoras e as eletromagnéticas, sendo

¹ Projeto oficial disponível em: <https://www.gnuradio.org/>. Acesso em: 6 jul. 2026.

de grande importância em aplicações de radar. A Equação 4 representa a equação geral do efeito Doppler (Halliday; Resnick; Walker, 2016).

$$f' = f \frac{v \pm v_D}{v \pm v_F} \quad (4)$$

Onde f' representa a frequência detectada, f a frequência da fonte, v a velocidade do som no meio, v_D e v_F são a velocidade do detector e a velocidade da fonte, respectivamente. Caso o detector estiver se direcionando à fonte, o sinal no numerador será positivo, caso contrário, o sinal deve ser negativo. Já no denominador, quando a fonte estiver se movendo em direção ao detector, o sinal fica positivo e negativo caso a fonte se afaste (Halliday; Resnick; Walker, 2016). Essa característica é fundamental em radares como os de onda contínua, nos quais a detecção de movimento e a estimativa de velocidade dependem diretamente da análise desse desvio de frequência (Skolnik, 1980).

2.1.5 Transformada Rápida de Fourier

A Fast Fourier Transform (FFT - Transformada Rápida de Fourier) é um algoritmo eficiente para o cálculo da Discrete Fourier Transform (DFT - Transformada Discreta de Fourier). A DFT permite representar um sinal discreto no domínio da frequência, sendo amplamente utilizada em aplicações de análise espectral, filtragem digital e processamento de sinais (Lathi, 2008). Lathi (2008) descreve a DFT de uma sequência x_n de comprimento N_0 na Equação 5.

$$X_r = \sum_{n=0}^{N_0-1} x_n W_{N_0}^{nr} \quad 0 \leq r \leq N_0 - 1 \quad (5)$$

A transformada inversa é dada pela Equação 6.

$$x_n = \frac{1}{N_0} \sum_{r=0}^{N_0-1} X_r W_{N_0}^{-nr} \quad (6)$$

Em que a Equação 7.

$$W_{N_0} = e^{-j\frac{2\pi}{N_0}} = e^{-j\Omega_0} \quad (7)$$

A FFT explora as propriedades de simetria e periodicidade dos termos exponenciais complexos para reduzir o número de operações necessárias de N^2 , pela DFT, para $N \log_2 N$, aproximadamente, tornando o algoritmo computacionalmente econômico (Lathi, 2008). O princípio básico da FFT está na decomposição recursiva da

sequência original em subsequências menores, cujas transformadas podem ser calculadas separadamente e combinadas posteriormente. Segundo Lathi (2008), essa estratégia não introduz aproximações, implicando que os resultados obtidos pela FFT são idênticos aos da DFT.

No contexto deste trabalho, a FFT foi utilizada no projeto da Bornhausen (2025) para analisar os sinais captados pelas interfaces de recepção, permitindo a perceber mudanças na densidade espectral que acontecem quando objetos estão presentes ou se movem. Ao visualizar esses dados no domínio da frequência, fica mais fácil identificar reflexões e efeitos de deslocamento Doppler, o que permite detectar movimentos mesmo em ambientes mais complicados. Por isso, a FFT é uma ferramenta fundamental para interpretar os resultados e validar a nova proposta do radar de onda contínua.

2.1.6 Processamento Digital De Sinais

O Processamento Digital de Sinais (PDS), consiste no conjunto de métodos destinados à representação, transformação e manipulação de sinais em formato digital. Sua aplicação é fundamental em sistemas modernos de radar, telecomunicações, controle e instrumentação, permitindo o tratamento eficiente de sinais provenientes de sensores e transdutores (Oppenheim; Schafer, 2014).

Entre as principais ferramentas de PDS podem ser citados os filtros, que, num sentido amplo, modificam certas frequências de um sinal de entrada para a saída como por exemplo permitir a passagem de certas faixas de frequências e rejeitar outras completamente (Oppenheim; Schafer, 2014). No trabalho da Bornhausen (2025), um filtro passa-baixa foi implementado com o intuito de conservar as frequências relevantes e eliminar ruídos e componentes indesejados de alta frequência após a captura do sinal FM.


Outra técnica empregada no projeto foi a utilização de uma janela de Hamming, para aumentar a eficiência do filtro e diminuir efeitos como as ondulações na faixa de passagem e a perda na faixa de rejeição (Bornhausen, 2025). Essa função reduz as descontinuidades nas bordas do sinal amostrado, minimizando o vazamento espectral e proporcionando uma transição mais controlada entre as bandas de frequência (Oppenheim; Schafer, 2014).

2.2 ANTENAS

Balanis (2005) define antena como uma estrutura de transição entre o espaço livre e um dispositivo de guia de ondas e pode ser usado para transmitir energia eletromagnética de uma fonte para o espaço, representado pela Figura 3 ou vice-versa. Dependendo da aplicação as antenas são também responsáveis por otimizar ou acen-

tuar a energia irradiada em algumas direções e suprimir essa mesma em outras, atuando como um dispositivo direcional e, para atender às necessidades específicas, o dispositivo pode assumir diversos formatos (Balanis, 2005).

Figura 3 – Representação gráfica de uma antenna transmissora



Fonte: Adaptado de Balanis (2005, p. 2).

No contexto de radares, Skolnik (2008) lista diversas funções que as antenas devem desempenhar, sendo:

1. Concentrar a energia irradiada na transmissão;
2. Coletar a energia do eco recebido do alvo;
3. Fornecer uma medição da direção angular para o alvo;
4. Fornecer resolução espacial para resolver ou separar alvos em ângulo;
5. Permitir que o volume de espaço desejado seja observado.

Além disso, a antena confere ao sistema três propriedades, sendo essas ganho, direcionalidade e polarização (Systems, 2007). O ganho representa a quantidade de energia que uma antena adiciona a um sinal, enquanto a direcionalidade refere-se ao formato do padrão de transmissão (Systems, 2007).

Existem diversos tipos de antenas e cada uma possui suas vantagens e limitações (Skolnik, 2008), fazendo com que seja crucial conhecer os tipos de antenas existentes assim como o funcionamento dos mesmos, para poder implementar o modelo que melhor cumpre os requisitos do projeto. De forma geral, as antenas podem ser classificadas como omnidirecional e direcional, dependendo da sua direcionalidade Systems (2007).

2.2.1 Antenas Omnidirecionais

As antenas omnidirecionais irradiam energia de forma uniforme no plano horizontal, cobrindo 360° ao redor de seu eixo, o que as torna ideais para aplicações que exigem comunicação em todas as direções, como redes Wi-Fi, estações base de telefonia celular e sistemas de transmissão (Systems, 2007; Wireless, 2024). No estudo de Bornhausen (2025), essas antenas foram utilizadas para captar tanto o sinal de referência quanto o sinal refletido por objetos, demonstrando sua adequação em sistemas de radar passivo. No entanto, em radares ativos, seu uso apresenta limitações, pois a energia é distribuída igualmente em todas as direções, resultando em menor ganho e em maior interferência entre as antenas transmissora e receptora, o que reduz a sensibilidade e a qualidade da detecção (Skolnik, 1980).

2.2.2 Antenas Direcionais

As antenas direcionais, diferentemente das omnidirecionais, apresentam a propriedade de irradiar ou receber ondas eletromagnéticas de forma mais eficaz em algumas direções do que em outras (Balanis, 2005). Esse padrão de radiação permite concentrar a energia em um ponto específico, proporcionando maior distância de cobertura à medida que o ganho da antena aumenta (Systems, 2007). Por esse motivo, as antenas direcionais são ideais para aplicações ponto a ponto ou em sistemas que requerem alcance ampliado como em provedores de internet para interligar redes de Wi-Fi ou em operações de busca e salvamento, com o intuito de rastrear sinais de socorro de transmissores de emergência (Mikac, 2024).

Skolnik (2008) afirma que na maioria das aplicações são utilizados antenas direcionais nos radares, uma vez que a concentração do feixe em uma direção específica permite determinar com maior precisão a posição e a distância dos alvos. Essa característica possibilita não apenas uma isolamento adequada entre transmissor e receptor mas também melhora a resolução angular e facilita na distinção de múltiplos objetos próximos entre si (Skolnik, 1980).


Dentro da classe de antenas direcionais, existem diferentes tipos que se distinguem por suas características construtivas e pelos princípios físicos utilizados para irradiar ou receber energia eletromagnéticas (Balanis, 2005). No contexto de radares, entre os tipos que são comumente implementados podem ser listados as antenas de abertura, em arranjo ou refletoras (Skolnik, 2008).

2.2.2.1 Antena Helicoidal

A antena helicoidal, criada no final da década de 40 por John Kraus, é uma estrutura condutora formada por um fio condutor enrolado em forma de hélice ao longo de um eixo (Balanis, 2005). Este fio é acoplado a um disco refletor ou plano de terra

como representado na Figura 4. Devido à sua geometria, a antena pode apresentar dois modos de operações distintas que dependem diretamente de seus parâmetros construtivos, como o diâmetro da hélice, o espaçamento entre as espiras, o número de voltas e o comprimento total do fio (Balanis, 2005).

Figura 4 – Representação de uma antena helicoidal



Fonte: Balanis (2005, p. 569).

Segundo (Balanis, 2005), quando o comprimento total do fio for muito menor do que o comprimento de onda, a antena opera no modo normal e seu padrão de radiação é semelhante a uma omnidirecional, como visto pela Figura 5a. Já o modo de operação axial ocorre quando o diâmetro de uma única espira (D) e o espaçamento entre uma espira e outra (S) respeite a Equação 8 e a Equação 9


$$\frac{4\lambda}{3} > \pi D > \frac{3\lambda}{4} \quad (8)$$

$$S \approx \frac{\lambda}{4} \quad (9)$$


Onde λ representa o comprimento de onda (Balanis, 2005). Neste modo de operação, a antena apresenta um comportamento de radiação diretivo, como visto pela Figura 5b.

Figura 5 – Padrões de radiação da antena helicoidal

(a) Modo normal



(b) Modo axial



Fonte: Balanis (2005, p. 568).

Entre as principais propriedades da antena helicoidal em modo axial, destacam-se o ganho direcional, a razão axial e a impedância de entrada, fundamentados em fórmulas empíricas por Balanis (2005). O ganho direcional, que aumenta proporcionalmente ao número de espiras (N) e ao espaçamento (S), é definido pela Equação 10.

$$G = 15N \frac{(\pi D)^2 S}{\lambda^3} \quad (10)$$

A razão axial descreve a proporção entre os eixos maior e menor da elipse de polarização. Para a geometria helicoidal, essa relação é expressa pela Equação 11 (Balanis, 2005).

$$AR = \frac{2N + 1}{2N} \quad (11)$$

Conforme o número de espiras aumenta, a razão axial aproxima-se de 1, caracterizando uma polarização circular. Essa condição é vantajosa por permitir a comunicação com fontes de polarização linear em qualquer orientação, além de mitigar perdas causadas pela rotação de Faraday ao atravessar a atmosfera (Balanis, 2005).

Além disso, a impedância de entrada é quase puramente resistiva e pode ser expressa pela Equação 12 (Balanis, 2005):

$$Z_{in} \approx R_{in} \approx 140 \left(\frac{\pi D}{\lambda} \right) \quad (12)$$

Substituindo πD pela faixa de valores permitidos na Equação 8 pode-se concluir que R_{in} pode assumir valores entre $100 \, \Omega$ e $200 \, \Omega$.


A combinação entre ganho direcional, ampla largura de banda e polarização circular faz com que as antenas helicoidais sejam amplamente utilizadas em sistemas de comunicação e sensoriamento (Modern Physics, 2026). Entre suas principais aplicações destacam-se as comunicações via satélite, enlaces em micro-ondas, sistemas de radioamadorismo e radares operando em diferentes faixas de frequência. Em aplicações de radar, a capacidade de concentrar a energia irradiada em uma direção específica contribui para o aumento da intensidade dos ecos refletidos pelos alvos, favorecendo a detecção e a análise dos objetos monitorados (Modern Physics, 2026).

2.3 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial representa um campo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de executar tarefas que normalmente exigiram inteligência humana, como percepção, raciocínio, aprendizado e tomada de decisão. Segundo Russell e Norvig (2009), a IA pode ser compreendida como o estudo de agentes inteligentes, ou seja, entidades que percebem o ambiente e agem de forma racional para atingir objetivos específicos. Essa definição abrange desde algoritmos simples de tomada de decisão até sistemas complexos baseados em redes neurais profundas, destacando-se pela capacidade de aprender e adaptar-se a partir de dados e experiências.

Embora frequentemente usados como sinônimos, Inteligência Artificial, Machine Learning (Aprendizado de Máquina) e Deep Learning (Aprendizado Profundo) representam conceitos distintos dentro de uma hierarquia, como visto na Figura 6. A IA é o campo mais abrangente, englobando todas as técnicas que visam criar comportamento inteligente. O Machine Learning é um subcampo da IA focado em algoritmos que aprendem padrões e realizam previsões a partir de dados, sem necessidade de programação explícita. Já o Deep Learning é uma vertente do aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas, chamados de redes neurais profundas, capazes de extrair representações hierárquicas e complexas dos dados (IBM Data and AI Team, 2025). Essa abordagem impulsionou avanços significativos em reconhecimento de imagem, processamento de linguagem natural e sistemas autônomos.

Figura 6 – IA vs Machine Learning



Fonte: Min (2020).


Nos sistemas de radar, algoritmos de Deep Learning, como CNN – Redes Neurais Convolucionais (Convolutional Neural Networks) e RNNs – Redes Neurais Recorrentes (Recurrent Neural Networks) são empregados para reconhecimento automático de alvos, supressão de interferências, estimativa de movimento e otimização de formas de onda (Geng *et al.*, 2021). Além disso, abordagens baseadas em aprendizado por reforço vêm sendo exploradas para o projeto adaptativo de antenas e síntese de formas de onda em radares cognitivos, evidenciando o potencial da IA para tornar sistemas de radar mais autônomos, precisos e resilientes.

2.3.1 Métricas de Avaliação de Modelos de Classificação

No escopo de aprendizado de máquina, os modelos de classificação compreendem uma categoria de algoritmos, cujo objetivo é atribuir uma amostra de entrada a uma ou mais classes previamente definidas, como por exemplo diferenciar e-mails de spam de e-mails regulares (Murel; Kavlakoglu, 2024). O principal formato de aprendizado deste modelo se baseia no supervisionado, no qual o algoritmo é treinado através de dados rotulados, ou seja, amostras que na entrada já estão associadas às suas respectivas saídas esperadas. Durante o treinamento, o modelo analisa esses pares de entrada e saída, buscando identificar padrões e relações que permitam diferenciar as classes existentes. À medida que o processo de treinamento avança, seus parâmetros internos são ajustados para reduzir os erros de classificação e aumentar sua capacidade de generalização, possibilitando a classificação correta de novos dados que não participaram do aprendizado (Carvalho, 2025).


Após a etapa de aprendizado, o modelo passa pela fase de classificação, em que o classificador é submetido a um conjunto de dados que não participou do treinamento, denominado conjunto de teste. A utilização de dados não vistos anteriormente permite avaliar a capacidade de generalização do modelo e verificar se os padrões aprendidos durante o treinamento podem ser aplicados corretamente a novas amostras (Murel; Kavlakoglu, 2024). Além disso, é importante validar se não há presença de overfitting ou underfitting no modelo, condições que ocorrem quando o modelo se ajusta excessivamente aos dados ou não consegue aprender adequadamente os padrões existentes nas amostras, respectivamente (Honório, 2025). Um modelo com underfitting apresenta baixo desempenho tanto no conjunto de treinamento, quanto no conjunto de teste, já um modelo com overfitting, apresenta um elevado desempenho no treinamento, mas demonstra baixa capacidade de generalização para novas amostras (Honório, 2025). Um exemplo gráfico de como seria um modelo de overfitting e underfitting pode ser visto na Figura 7 e a Figura 8 mostra como identificar se o modelo apresenta overfitting ou underfitting a partir da curva de perda por época de treinamento.

Figura 7 – Exemplo gráfico de overfitting e underfitting



Fonte: AprendeIA (2018).

Figura 8 – Como identificar na curva de perda se há ou não over- ou underfitting



Fonte: Elaborado pelo autor (2026).


Para verificar a qualidade das classificações realizadas, utilizam-se métricas de avaliação que quantificam o desempenho do modelo, organizando as amostras em quatro grupos (Murel; Kavlakoglu, 2024):

- **Verdadeiros Positivos (VP):** Casos em que o modelo previu corretamente a presença da classe alvo;
- **Verdadeiros Negativos (VN):** Casos em que o modelo previu corretamente a ausência da classe alvo;
- **Falsos Positivos (FP):** Erros de classificação nos quais o modelo previu a presença da classe alvo em uma amostra que, na realidade, pertencia a outra categoria;
- **Falsos Negativos (FN):** Erros de classificação nos quais o modelo negligenciou a presença da classe alvo, classificando-a incorretamente como ausente.

A partir do balanço dessas quatro variáveis elementares, as principais métricas de avaliação de modelos preditivos são definidas e calculadas conforme descrito a seguir (Murel; Kavlakoglu, 2024):

- (A) **Matriz de Confusão:** Consiste em uma estrutura de tabela que correlaciona de forma cruzada as classes reais observadas experimentalmente com as classes previstas pelo modelo de inteligência artificial, como indicado na Figura 9. Essa matriz organiza visualmente os acertos posicionados na diagonal principal e os erros distribuídos fora dela, servindo como uma ferramenta para compreender quais categorias estão sofrendo sobreposição ou confusão mútua.

Figura 9 – Exemplo de uma Matriz de Confusão



Fonte: Ruback, Avila e Cantero (2021, p. 3).

- (B) **Precisão (Precision):** Mede a exatidão das previsões positivas realizadas pelo classificador. Em termos práticos, indica qual a proporção de amostras rotuladas sob uma determinada classe que de fato pertenciam àquela categoria no cenário real. É expressa pelo cálculo contido na Equação 13:

$$Precision = \frac{VP}{VP + FP} \quad (13)$$

- (C) **Sensibilidade (Recall):** Quantifica a capacidade do modelo de Inteligência Artificial em mapear, identificar e resgatar todas as instâncias reais pertencentes a uma determinada classe contidas no banco de dados. Um indicador de recall baixo aponta para uma alta incidência de falsos negativos. Seu cálculo é determinado pela Equação 14:

$$Recall = \frac{VP}{VP + FN} \quad (14)$$

- (D) **F1-Score:** Compreende a média harmônica estabelecida entre os indicadores de precisão e sensibilidade. O índice F1-Score fornece uma métrica de equilíbrio mais robusta e realista para avaliar o classificador de forma integrada, variando em um intervalo decimal entre 0 e 1, onde valores próximos à unidade representam um modelo robusto, que consegue ser simultaneamente preciso e sensível na tarefa de discriminação de padrões. Sua formulação é dada pela Equação 15:

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (15)$$

2.4 TRABALHOS RELACIONADOS

O mapeamento de pesquisa, também denominado mapeamento sistemático da literatura, consiste em um método que permite estruturar um tema de investigação por meio da classificação e análise das publicações existentes. Esse processo possibilita identificar a cobertura do campo de estudo e as lacunas que motivam novas pesquisas (Rocha; Nascimento; Nascimento, 2018). Nesse contexto, foram levantados trabalhos similares ao tema de uso de radares para detecção e classificação de materiais, com o intuito de validar academicamente a pesquisa apresentada.

Para tanto, realizou-se uma busca entre os dias 8 e 9 de Novembro de 2025 na base de dados Scopus, selecionado pelo destaque no meio acadêmico. A fim de realizar uma pesquisa eficiente, elaborou-se uma *string* de busca, contendo as principais palavras-chaves relacionados ao trabalho, conforme indicado no Quadro 1.

Quadro 1 – *String* de busca

<i>String</i> de busca
TITLE-ABS-KEY(((“SDR-Based” OR “Software-Defined radar”) AND “Classification”) OR (“radar” AND “Material Classification”) OR ((“SDRadar” OR “Software-Defined radar”) AND (“Machine Learning” AND (“Material Classification” OR “Target Classifica- tion”)))) OR ((“SDRadar” OR “Software-Defined radar”) AND “radar” AND (“Machine Learning” AND “Material Classification”)))

Fonte: Elaborado pelo autor (2025).

O atributo TITLE-ABS-KEY no começo da *string* garante que os termos estejam pelo menos presentes no título, resumo ou nas palavras-chaves, assegurando assim que os resultados obtidos estejam diretamente relacionados ao escopo temático da pesquisa. Além da *string* de busca, foram aplicados também critérios de inclusão e exclusão para refinar os resultados e garantir a qualidade e pertinência dos estudos selecionados. Os critérios de inclusão foram:

- a) **Data de publicação:** O documento deve ter sido publicado entre 2015 e 2025, garantindo que os estudos analisados estejam atualizados e reflitam os avanços mais recentes nas respectivas áreas de pesquisa;


- b) **Idioma:** Foram considerados somente trabalhos escritos em português, alemão, inglês ou espanhol, pois são os idiomas que o autor tem pleno domínio, evitando possíveis ambiguidades de tradução e interpretação de conceitos técnicos;
- c) **Tipo de documento:** Optou-se pelo uso exclusivo de artigos científicos, devido ao seu caráter revisado por pares e maior confiabilidade metodológica em comparação com outros tipos de publicações, como anais de conferências ou relatórios técnicos.

Como critérios de exclusão, foram desconsiderados:

- a) **Data de publicação:** Trabalhos anteriores a 2015 foram desconsiderados, pois podem estar desatualizados quanto às abordagens e tecnologias atuais nas respectivas áreas de pesquisa;
- b) **Idioma:** Foram excluídos documentos redigidos em idiomas diferentes do português, alemão, inglês ou espanhol, para não haver interpretações imprecisas;
- c) **Tipo de documento:** Documentos que não eram artigos científicos foram excluídos por não passarem, necessariamente, por processo de revisão por pares.

Com a *string* de busca foram encontrados 114 documentos e, aplicando os critérios de inclusão e exclusão, este número reduziu para 31 artigos. A Figura 10 ilustra a distribuição dos trabalhos selecionados por área de estudo, conforme classificação realizada pela base de dados Scopus.

Figura 10 – Relação de trabalhos por área de estudo



Fonte: Scopus (2025).

Observa-se que a maior concentração de publicações está na área de Engenharia, representando aproximadamente 30,9% dos trabalhos, seguida de Física e Astronomia, com 23,5%. Essa predominância evidencia o caráter técnico e experimental das pesquisas envolvendo radares e seus sistemas de detecção. A área de Ciência da Computação também apresenta relevância expressiva (17,6%), refletindo o avanço do uso de algoritmos de machine learning e técnicas de processamento digital de sinais aplicadas a dados de radar.

Para restringir a seleção dos documentos, delimitou-se como áreas de foco: Engenharia e Ciências da Computação, por serem os campos que mais se relacionam ao escopo desta pesquisa, especialmente no que tange ao desenvolvimento de sistemas de radar baseados em *software* e à aplicação de técnicas de aprendizado de máquina na classificação de alvos e materiais. O Quadro 2 apresenta de forma resumida os critérios de inclusão e exclusão dos trabalhos relacionados

Quadro 2 – Critérios de inclusão e exclusão

Critérios para inclusão	Critérios para exclusão
Pesquisas publicadas entre 2015 e 2025	Pesquisas com mais de 10 anos de publicação
Pesquisas publicadas nos idiomas português, alemão, inglês ou espanhol	Pesquisas publicadas em outros idiomas
Disponíveis de forma gratuita ou em acessos fornecidos pela UFSC	Acesso restrito ou que requerem pagamento para leitura integral
Estudo com temática alinhada ao objetivo deste trabalho	Estudos que se distanciam do escopo temático proposto
Estudos divulgados sob a forma de artigo científico	Estudos divulgados em formatos como teses, dissertações, livros, anais de eventos, relatórios técnicos e publicações afins.
Pesquisas que estejam relacionadas às áreas de Engenharia ou Ciências da Computação	Pesquisas que não estejam relacionadas às áreas da Engenharia, Ciência da Computação.

Fonte: Elaborado pelo autor (2025).

Com esses parâmetros, foram selecionados 5 entre as 31 publicações que melhor se encaixaram nos critérios estabelecidos. Os artigos escolhidos para a fundamentação teórica estão listados no Quadro 3.

Quadro 3 – Material para referência

	Título da pesquisa	Autores	Periódico	Ano	Objetivo da pesquisa
1	Intelligent Material Classification and Identification Using a Broadband Millimeter-Wave Frequency Comb Receiver	Jamali, B., Ramalingam, D., Babakhani, A.	IEEE Sensors Letters	2020	Desenvolver um sistema de classificação de materiais com receptor em ondas milimétricas baseado em <i>frequency comb</i> e aprendizado supervisionado.
2	radar-Based Materials Classification Using Deep Wavelet Scattering Transform: A Comparison of Centimeter vs. Millimeter Wave Units	Khushaba, R. N., Hill, A. J.	IEEE Robotics and Automation Letters	2022	Investigar o uso de radares centimétricos e milimétricos na identificação de materiais com a <i>Wavelet Scattering Transform</i> para classificação em tempo real.
3	Deep Learning-Based Material Characterization Using FMCW radar With Open-Set Recognition Technique	Abouzaid, S., Jaeschke, T., Kueppers, S., Barowski, J., Pohl, N.	IEEE Transactions on Microwave Theory and Techniques	2023	Desenvolver um método com radar FMCW e aprendizado de máquina para caracterizar materiais dielétricos e identificar amostras desconhecidas.
4	Machine-Learning Methods for Material Identification Using mmWave radar Sensor	Skaria, S., Hendy, N., Al-Hourani, A.	IEEE Sensors Journal	2023	Desenvolver um framework de aprendizado de máquina para identificar e classificar materiais a partir de sinais refletidos por um radar FMCW em ondas milimétricas.
5	SDR-Based Metal Classification Using Spectrogram Images from Micro-Doppler Signatures	Liaquat, S., Butt, F. A., Nasir, F. A., Naqvi, I. H., Mahyuddin, N. M., Muqaibel, A. H., Alawsh, S. A.	IEEE Instrumentation and Measurement Magazine	2025	Desenvolver um método de classificação de metais usando assinaturas micro-Doppler obtidas por radar SDR e analisadas por redes neurais convolucionais.

Fonte: Elaborado pelo autor (2025).

Com base nos trabalhos listados, realizou-se uma análise comparativa a fim de identificar as principais abordagens, técnicas e limitações presentes nas pesquisas

recentes sobre classificação de materiais por radar. Essa análise permitiu compreender as tendências atuais do campo, como o uso crescente de aprendizado profundo e de radares em faixas milimétricas, além de evidenciar oportunidades para aprimorar a precisão e a eficiência dos métodos existentes. A partir dessas observações, delinear-se os fundamentos que orientam o desenvolvimento da proposta deste trabalho, apresentada nas seções seguintes.

2.4.1 Discussão dos trabalhos relacionados

Os trabalhos analisados apresentam abordagens complementares para a classificação e caracterização de materiais utilizando radares de diferentes faixas de frequência e métodos de aprendizado de máquina. Em conjunto, evidenciam a evolução das técnicas de sensoriamento e o potencial da inteligência artificial para aprimorar a precisão e a automação desses processos.

O estudo de Khushaba e Hill (2022) comparou radares centimétricos e milimétricos aplicados à classificação de materiais, empregando a WST – Transformada de espalhamento wavelet (Wavelet Scattering Transform) para extrair características invariantes dos sinais refletidos. Os autores observaram desempenho semelhante entre as faixas, com maior robustez do radar centimétrico frente a ruídos. Como sugestão, apontaram o uso combinado de múltiplas frequências e métodos híbridos de aprendizado para maior generalização em ambientes industriais.

Skaria, Hendy e Al-Hourani (2023) exploraram um radar milimétrico FMCW com diferentes algoritmos de aprendizado – CNN, k -NN e DTW – para identificação não invasiva de materiais. A CNN apresentou acurácia superior a 98% na classificação de seis tipos de materiais e volumes distintos. O trabalho destacou, contudo, a necessidade de calibração frequente e maior robustez frente a variações de orientação das amostras.

O estudo de Jamali, Ramalingam e Babakhani (2020) propôs um sistema em tecnologia Complementary CMOS – Metal-Óxido-Semicondutor Complementar (Metal-Oxide-Semiconductor) com receptor *frequency comb* (75 – 110 GHz) para classificação inteligente de materiais. O método consistiu em registrar a potência transmitida através de diferentes materiais e treinar classificadores supervisionados – Support Vector Machines (SVM), Multilayer Perceptron (MLP) e Gaussian Process Classifier – para prever o tipo e a espessura do material. O sistema alcançou acurácia superior a 96% para identificação e 88% para espessura, demonstrando o potencial da abordagem para aplicações portáteis e industriais. Como limitações, os autores ressaltaram a necessidade de compensar variações estruturais e ambientais, bem como de expandir o conjunto de materiais analisados.

Abouzaid *et al.* (2023) propuseram um método de caracterização de materiais dielétricos utilizando radar FMCW calibrado e aprendizado profundo, como alterna-

tiva de baixo custo aos Vector Network Analyzers (VNAs – Analisadores Vetoriais de Rede). A metodologia combinou medições de coeficientes de reflexão com uma rede neural treinada para estimar parâmetros físicos – como espessura, constante dielétrica e tangente de perda e implementou um sistema de Open-Set Recognition (OSR – Reconhecimento de Conjunto Aberto capaz de rejeitar classes desconhecidas. O modelo obteve resultados comparáveis aos de um VNA, com maior simplicidade de operação e custo reduzido. Apesar do desempenho satisfatório, os autores indicam a necessidade de ampliar a base de dados e validar o modelo em materiais com propriedades dielétricas variáveis e ambientes industriais.

Liaquat *et al.* (2025) apresentaram uma proposta de classificação de metais baseada em assinaturas micro-Doppler obtidas por radar em SDR. O estudo foi motivado pela busca de soluções acessíveis para a identificação remota de materiais metálicos, explorando a conversão das assinaturas micro-Doppler em espectrogramas tratados como imagens de entrada para uma CNN. A metodologia utilizada por Liaquat *et al.* (2025) demonstrou dados com acurácia superior a 95% na distinção entre latão, cobre e alumínio, comprovando que os padrões vibracionais podem ser utilizados como características discriminantes. Como limitações, foram apontadas a necessidade de ampliar a variedade de materiais testados e a realização de testes em condições ambientais menos controladas.

De modo geral, os trabalhos revisados demonstram que a combinação de radares de alta frequência com técnicas de aprendizado de máquina representa uma tendência consolidada na classificação e caracterização de materiais. Enquanto as soluções milimétricas oferecem alta resolução e precisão, os sistemas baseados em SDR mantêm a vantagem de menor custo e maior flexibilidade. Dessa forma, o desenvolvimento proposto neste trabalho que adapta um sistema SDR para operação ativa e integra algoritmos de inteligência artificial busca unir essas vantagens, explorando um equilíbrio entre acessibilidade experimental e rigor científico na análise e classificação de materiais.

3 METODOLOGIA

Tendo em vista o problema da detecção da movimentação de deslizamentos em encostas, este capítulo apresenta os materiais e métodos utilizados na análise experimental da detecção de objetos por meio de um sistema de radar ativo implementado via SDR, bem como na classificação de suas propriedades cinemáticas e as características materiais utilizando técnicas de IA. A intuição é propor um método para avaliar o quanto os movimentos de diferentes materiais é detectável pelo par de tecnologias empregadas. Assim, depender dos resultados, esses materiais poderiam ser utilizados em cenários de monitoramento.

A abordagem metodológica foi estruturada de forma a garantir a reprodutibilidade dos experimentos e a consistência dos resultados adquiridos. A Figura 11 apresenta o fluxo das etapas executadas ao longo do desenvolvimento do projeto, sendo que cada uma dessas fases é detalhada nas seções seguintes.

Figura 11 – Etapas para a validação do projeto



Fonte: Elaborado pelo autor com auxílio do ChatGPT (modelo GPT-5.5, OpenAI, 2026).

A seção está estruturada em três partes principais: inicialmente, descreve-se a preparação do ambiente experimental, incluindo a revisão dos trabalhos correlatos; em seguida, detalha-se a etapa de aquisição dos sinais, especificando as condições de coleta, os critérios de seleção das amostras e o processamento aplicado aos dados; por fim, apresenta-se o processo de construção e validação do modelo de IA utilizado para a classificação dos sinais obtidos ao longo do experimento.

3.1 PREPARAÇÃO DO AMBIENTE EXPERIMENTAL


3.1.1 Configuração do radar ativo

Para o desenvolvimento do diagrama do radar ativo no GNU Radio, utiliza-se como base o esquemático do radar passivo desenvolvido por Bornhausen (2025), disponível no GitHub¹. Adicionalmente, emprega-se como referência o diagrama de radar Doppler apresentado por Gallicchio (2022), utilizado como suporte para a implementação do radar de onda contínua adotado neste trabalho.

O sistema proposto por Bornhausen (2025) baseia-se na utilização de sinais provenientes de fontes externas de radiofrequência, dispensando a necessidade de transmissão própria. Nesse arranjo, o dispositivo RTL-SDR atua como receptor responsável pela captura dos sinais refletidos pelos alvos, enquanto o ADALM-PLUTO é empregado para a aquisição do sinal de referência proveniente da fonte transmissora. A partir da correlação entre o sinal de referência e os ecos recebidos, torna-se possível identificar alterações causadas pelo movimento dos objetos no ambiente, permitindo a detecção de alvos sem a emissão ativa de sinais eletromagnéticos. Os dados adquiridos durante os experimentos são armazenados em arquivos no formato CSV, possibilitando o registro das amostras capturadas.

Antes da descrição detalhada dos blocos implementados no GNU Radio, a Figura 12 apresenta o fluxograma simplificado do funcionamento do radar ativo desenvolvido. O fluxograma fornece uma visão geral das etapas de transmissão, recepção, processamento e armazenamento dos sinais.

Figura 12 – Fluxograma do funcionamento básico do radar ativo desenvolvido



Fonte: Elaborado pelo autor (2026).


Conforme ilustrado na Figura 12, o sistema inicia com a geração de um sinal

¹ Projeto oficial disponível em: https://github.com/mbornhausen/TCC_RadarPassivo. Acesso em: 7 jul. 2026.

de onda contínua (CW), transmitido pelo ADALM-PLUTO na frequência de 2,4 GHz. Após a reflexão nos objetos presentes no ambiente, os ecos são recebidos pela antena receptora e submetidos às etapas de filtragem e ajuste de ganho. Por fim, os sinais processados são utilizados para visualização gráfica, monitoramento auditivo das componentes Doppler e armazenamento em arquivos `.dat`, que posteriormente servem como entrada para a geração dos espectrogramas e treinamento do modelo de inteligência artificial.

Para a adaptação do radar passivo para um modelo ativo, torna-se necessária a remoção do fluxo de captura com o RTL-SDR, bem como das variáveis associadas a esse fluxo, uma vez que somente o ADALM-PLUTO é empregado neste trabalho. Além disso, o sistema incorpora uma fonte emissora no ADALM-PLUTO e modifica o fluxo de captura do PlutoSDR, de modo que o dispositivo passe a receber os sinais refletidos pelos objetos presentes no ambiente, em vez de adquirir sinais de referência provenientes de transmissores externos. O diagrama final desenvolvido no GNU Radio para o radar ativo é apresentado na Figura 13 e encontra-se disponível no repositório `codigos.ufsc.br` (Heitmann, 2026b).


Figura 13 – Diagrama do radar ativo



Fonte: Elaborado pelo autor (2026).

A configuração inicial do sistema é realizada por meio de blocos auxiliares e variáveis, representados na Figura 14. Esses elementos são responsáveis pelo controle dos principais parâmetros de operação do radar ativo. O bloco *Options* define as configurações gerais do projeto, incluindo o tipo de aplicação gerada e a interface gráfica empregada durante a execução. Já a variável *samp_rate* define a taxa de amostragem utilizada no sistema, configurada em 2,4 MHz, influenciando diretamente a resolução temporal e espectral dos sinais adquiridos.

Figura 14 – Variáveis e auxiliares do fluxo




Fonte: Elaborado pelo autor (2026).

No sistema desenvolvido, o sinal Doppler de interesse encontra-se concentrado em frequências inferiores a aproximadamente 500 Hz após o processamento em banda-base. Assim, uma taxa de amostragem de 2,4 MHz mostrou-se suficiente para a aquisição dos sinais, permitindo sua posterior decimação para 48 kHz sem perda das informações relevantes.

Além disso, são empregados blocos do tipo *QT GUI Range*, utilizados para o ajuste dinâmico de parâmetros durante a execução do radar. O parâmetro *tone_freq* controla a frequência do sinal senoidal transmitido pelo ADALM-PLUTO, enquanto *tx_attenuation* permite ajustar a atenuação aplicada à transmissão do sinal, evitando a saturação do receptor. O parâmetro *rx_gain* controla o ganho da recepção, influenciando diretamente a sensibilidade do radar na detecção dos ecos refletidos pelos objetos. Por fim, a variável *audio_gain* ajusta a amplitude do sinal reproduzido no monitoramento em áudio do sistema. Esses parâmetros podem ser ajustados dinamicamente durante a aquisição dos sinais.

O fluxo de transmissão do radar, indicado na Figura 15, é implementado por meio de blocos responsáveis pela geração e emissão contínua do sinal de radio-frequência. Inicialmente, o bloco *Signal Source* gera um sinal senoidal em banda base, configurado com frequência definida pela variável *tone_freq*, amplitude unitária e taxa de amostragem estabelecida pela variável *samp_rate*. Esse sinal representa o tom base utilizado na transmissão do radar.

Figura 15 – Fluxo de transmissão




Fonte: Elaborado pelo autor (2026).

Em seguida, o sinal gerado é encaminhado ao bloco *PlutoSDR Sink*, responsável pela transmissão por meio do ADALM-PLUTO. Nesse bloco, são definidos parâmetros como a frequência de operação (*LO Frequency*), configurada em 2,4 GHz, e a atenuação aplicada à transmissão. A frequência de operação é estabelecida nesse valor, uma vez que a antena direcional utilizada no experimento opera especificamente nessa faixa, garantindo maior eficiência na irradiação do sinal. O dispositivo realiza a conversão digital-analógica do sinal e sua transmissão pela antena emissora, permitindo a recepção dos ecos refletidos pelos objetos.

Khushaba e Hill (2022) destacam que a combinação de múltiplas frequências pode contribuir para aumentar a capacidade de generalização dos sistemas de classificação de materiais. Entretanto, o presente trabalho teve como foco a avaliação da viabilidade de um radar ativo baseado em SDR de baixo custo para aplicações de classificação utilizando inteligência artificial. Por essa razão, optou-se por operar o sistema em uma única frequência de 2,4 GHz, reduzindo a complexidade de implementação, processamento e calibração do experimento. Considerou-se que a validação da metodologia proposta em uma única frequência constitui uma etapa inicial necessária antes da investigação de arquiteturas multifrequenciais, as quais poderão ser exploradas em trabalhos futuros visando aumentar a robustez do sistema em diferentes cenários de operação.

O fluxo de recepção, indicado na Figura 16, é responsável pela aquisição e pelo processamento dos sinais refletidos pelos objetos presentes no ambiente experimental. Inicialmente, o bloco *PlutoSDR Source* realiza a recepção dos ecos captados pela antena receptora conectada ao ADALM-PLUTO. Nesse bloco, são configurados parâmetros como a frequência de operação em 2,4 GHz, a taxa de amostragem de 2,4 MHz e o ganho manual de recepção, utilizado para ajustar a sensibilidade do sistema durante os experimentos. Para esta aplicação, a frequência de operação e a taxa de amostragem devem ser iguais às configuradas no bloco *PlutoSDR Sink*, garantindo a sincronização entre transmissão e recepção e permitindo a adequada detecção das variações Doppler produzidas pelos objetos em movimento.

Figura 16 – Fluxo de recepção



Fonte: Elaborado pelo autor (2026).


Após a aquisição, o sinal recebido passa por um bloco *Low Pass Filter*, responsável pela atenuação de componentes de alta frequência e pela redução de ruídos indesejados presentes no sinal Doppler. O filtro utiliza frequência de corte igual ao dobro da frequência transmitida, largura de transição de 250 Hz e fator de decimação igual a 50, reduzindo a taxa de amostragem de 2,4 MHz para 48 kHz.

Em seguida, emprega-se um bloco *Band Reject Filter*, utilizado para minimizar a componente espectral fixa próxima de 500 Hz, proveniente do vazamento direto entre os canais de transmissão e recepção do sistema. Define-se como banda de rejeição o intervalo entre 495 Hz e 505 Hz, com largura de transição de 5 Hz, resultando em uma filtragem mais estreita e seletiva. Esse filtro reduz interferências associadas ao sinal transmitido e permite destacar com maior clareza as componentes Doppler relacionadas ao movimento dos objetos detectados pelo radar.

Por fim, o bloco *Multiply Const* realiza o ajuste da amplitude do sinal por meio da multiplicação pelo fator definido na variável *audio_gain*. Dessa forma, o sinal é adequadamente condicionado para as etapas de visualização gráfica, reprodução em áudio e armazenamento dos dados, possibilitando sua posterior utilização na geração de espectrogramas e nos processos de classificação por inteligência artificial.

Após o processamento do sinal recebido, o fluxo de saída do radar, indicado na Figura 17, é responsável pela visualização, pelo monitoramento e pelo armazenamento dos dados utilizados nos experimentos. Os blocos *Skip Head* e *Head* descartam os três segundos iniciais de aquisição e limitam cada captura a três minutos (8,64 milhões de amostras), padronizando os sinais utilizados na base de dados.

Figura 17 – Blocos de saídas e tratamento do sinal



Fonte: Elaborado pelo autor (2026).

Posteriormente, o bloco *File Sink* armazena os sinais processados em arquivos no formato *.dat*. Esses arquivos contêm os dados do sinal Doppler captado pelo radar e são posteriormente utilizados na geração dos espectrogramas empregados nas etapas de treinamento, validação e classificação por inteligência artificial.

Além do armazenamento dos sinais, o sistema utiliza blocos gráficos para o monitoramento em tempo real do comportamento espectral do radar. O bloco *QT GUI Waterfall Sink* permite a visualização temporal da distribuição espectral do sinal, possibilitando a observação de variações associadas ao movimento dos objetos. Já o bloco *QT GUI Frequency Sink* é utilizado para a análise do espectro em frequência do sinal processado. Para esta aplicação, adota-se uma redução do tamanho da Transformada Rápida de Fourier (*FFT*) de 32768 para 8192 pontos, em comparação ao radar desenvolvido por Bornhausen (2025). Essa redução tem como principal objetivo diminuir o custo computacional do processamento em tempo real e proporcionar maior fluidez na visualização gráfica dos sinais.

Por fim, o bloco *Complex to Real* converte os dados complexos recebidos pelo SDR em um sinal real, tornando possível sua reprodução pelo bloco *Audio Sink*. Dessa forma, o sistema permite o monitoramento auditivo das componentes Doppler associadas ao movimento dos objetos durante os experimentos.

Diferentemente do radar passivo utilizado como referência, o sistema desenvolvido neste trabalho não realiza uma comparação explícita entre o sinal de referência e o sinal recebido por meio de um bloco *Multiply Conjugate*. O radar implementado explora a capacidade de operação em modo *full duplex* do ADALM-PLUTO, que permite a transmissão e a recepção simultânea de sinais de radiofrequência. Dessa forma, as componentes Doppler são obtidas a partir dos ecos refletidos pelos objetos presentes no ambiente e captados pelo receptor do PlutoSDR, após as etapas de filtragem e processamento espectral do sinal. Com isso, torna-se desnecessária a utilização explícita dos blocos de correlação empregados no radar passivo de referência.

3.1.2 Antena transmissora

Para a realização do experimento, utiliza-se uma antena direcional do tipo helicoidal conectada ao canal TX do ADALM-PLUTO, ilustrada na Figura 18. A antena é empregada com o objetivo de concentrar a energia irradiada em uma região específica do ambiente, aumentando a intensidade dos ecos refletidos pelos objetos analisados e reduzindo interferências provenientes de outras direções. Em contrapartida, o canal RX do PlutoSDR utiliza a antena omnidirecional fornecida juntamente com o dispositivo.

Figura 18 – Antena utilizado no trabalho



Fonte: Elaborado pelo autor (2026).

A antena helicoidal utilizada neste trabalho é construída de forma artesanal, empregando uma chapa circular de aço galvanizado com aproximadamente 12 cm de raio como refletor. O elemento helicoidal é confeccionado a partir de um fio de cobre enrolado sobre um tubo de PVC DN40 com aproximadamente 25 cm de comprimento. A antena é projetada com sete espiras e espaçamento entre voltas próximo de 3 cm, operando na frequência de 2,4 GHz e apresentando ganho estimado entre 7 e 9 dBi. Além disso, com o objetivo de proporcionar maior fixação mecânica e estabilidade estrutural ao conjunto, o elemento helicoidal é revestido com tubo termo retrátil.

3.1.3 Materiais dos objetos analisados

Assim como no trabalho de Bornhausen (2025), selecionam-se três objetos confeccionados com materiais que apresentam propriedades eletromagnéticas distintas: madeira, metal e plástico, conforme ilustrado na Figura 19. O metal é escolhido devido à sua elevada capacidade de reflexão de sinais eletromagnéticos (Bornhausen, 2025), enquanto os objetos de madeira e plástico tendem a apresentar respostas mais atenuadas em razão de suas características dielétricas.

Figura 19 – Objetos utilizados na análise experimental



Fonte: Elaborado pelo autor (2026).

Dessa forma, busca-se verificar se as diferenças presentes nos ecos refletidos pelos materiais são suficientes para permitir sua classificação automática. Para isso, modelos de inteligência artificial são treinados utilizando os dados obtidos experimentalmente, a fim de avaliar sua capacidade de identificar padrões associados aos diferentes materiais. Adicionalmente, os objetos são analisados sob diferentes condições de distância e velocidade de deslocamento, contribuindo para a construção de uma base de dados diversificada e representativa, utilizada no treinamento e na validação dos modelos.

Busca-se verificar se as diferenças entre os ecos refletidos permitem a classificação automática dos materiais por modelos de inteligência artificial. Para isso, os objetos são avaliados em diferentes condições de distância e velocidade, compondo a base de treinamento e validação.

3.2 DESCRIÇÃO DOS TESTES


3.2.1 Preparação do ambiente experimental

Os experimentos são realizados em um ambiente interno não controlado, buscando aproximar as condições de operação do sistema de cenários reais de monitoramento de encostas, nos quais interferências ambientais e variações do meio estão

naturalmente presentes. O arranjo experimental é composto por um computador executando o GNU Radio, um módulo ADALM-PLUTO responsável pela transmissão e recepção dos sinais de radiofrequência e uma antena helicoidal direcional empregada no canal transmissor do radar, conforme ilustrado nas Figuras 20a e 20b.

Figura 20 – Configuração do ambiente

(a) Vista frontal



(b) Vista traseira



Fonte: Elaborado pelo autor (2026).

Durante os experimentos, o radar é posicionado próximo ao solo e orientado diretamente para a região de movimentação dos objetos analisados. Busca-se manter constante o posicionamento do sistema de radar, da antena transmissora e das condições do ambiente ao longo de todas as aquisições, reduzindo variações experimentais que possam influenciar os sinais Doppler coletados.

Para simular os movimentos dos objetos durante os experimentos, utiliza-se uma tábua inclinada como rampa, sobre a qual os alvos são deslocados manualmente. A estrutura apresenta dimensões aproximadas de 50 cm × 30 cm. Na condição de menor inclinação, indicada na Figura 21a, o ponto mais elevado da rampa encontra-se a aproximadamente 20 cm do solo, enquanto na condição de maior inclinação, ilustrada na Figura 21b, a altura máxima atinge cerca de 25 cm. Essa abordagem permite realizar aquisições em diferentes velocidades de deslocamento dos objetos, possibilitando avaliar a capacidade do modelo de inteligência artificial em distinguir diferentes comportamentos cinemáticos a partir dos sinais Doppler captados pelo radar.

A utilização da rampa não busca reproduzir fielmente um deslizamento de encosta, mas gerar deslocamentos controlados para avaliar a sensibilidade do radar às diferentes condições de movimento. Assim, os experimentos constituem uma prova

de conceito do potencial da metodologia para futuras aplicações de monitoramento de encostas.

Figura 21 – Rampa utilizada no trabalho

(a) Rampa na configuração menos inclinada (b) Rampa na configuração mais inclinada



Fonte: Elaborado pelo autor (2026).

Além disso, a rampa é posicionada em diferentes distâncias em relação à antena helicoidal transmissora. Para parte das aquisições, adota-se uma distância aproximada de 20 cm entre a extremidade da antena e a rampa, enquanto em outros experimentos essa distância é ampliada para aproximadamente 40 cm. Essa variação tem como objetivo avaliar a capacidade do sistema em distinguir diferentes distâncias entre os objetos e o radar.

Embora os experimentos sejam realizados em um ambiente não controlado, busca-se minimizar alterações significativas no cenário durante as coletas, evitando a movimentação de pessoas e objetos externos nas proximidades do sistema. Essa abordagem tem como objetivo reduzir possíveis interferências e reflexões indesejadas nos sinais captados pelo radar.

3.2.2 Coleta e geração dos dados

Com o radar em operação no GNU Radio, os sinais experimentais foram coletados por meio do deslocamento manual dos objetos ao longo da rampa inclinada, do topo até sua extremidade inferior. Esse procedimento foi repetido em intervalos aproximados de 5 segundos até o encerramento automático da aplicação, resultando na geração de arquivos .dat contendo os sinais Doppler processados pelo radar.

Após a aquisição, utilizou-se um *script* em Python para gerar os espectrogramas empregados na construção da base de dados, disponível no Zenodo (Heitmann, 2026a). O código, disponível no mesmo repositório do radar ativo (Heitmann, 2026b), divide cada aquisição em intervalos de tempo iguais, permitindo a geração de múlti-

plos espectrogramas a partir de uma única captura. Foram geradas 30 imagens para cada material em cada condição de velocidade e distância.

O Quadro 4 apresenta as configurações experimentais utilizadas na composição das classes. Considerou-se como movimento lento a condição de menor inclinação da rampa e como movimento rápido a condição de maior inclinação. Da mesma forma, foram definidos os cenários perto e longe, correspondentes a distâncias aproximadas de 20 cm e 40 cm da antena transmissora, respectivamente.

Quadro 4 – Classes geradas para cada captura do material

Material	Velocidade	Distância	Qtd.	Rótulo
Vazio	-	-	180	Vazio
Madeira	Parado	Perto (20 cm)	30	MaPP
		Longe (40 cm)	30	MaPL
	Lento (menos inclinado)	Perto (20 cm)	30	MaLeP
		Longe (40 cm)	30	MaLeL
	Rápido (mais inclinado)	Perto (20 cm)	30	MaRaP
		Longe (40 cm)	30	MaRaL
Metal	Parado	Perto (20 cm)	30	MePP
		Longe (40 cm)	30	MePL
	Lento (menos inclinado)	Perto (20 cm)	30	MeLeP
		Longe (40 cm)	30	MeLeL
	Rápido (mais inclinado)	Perto (20 cm)	30	MeRaP
		Longe (40 cm)	30	MeRaL
Plástico	Parado	Perto (20 cm)	30	PIPP
		Longe (40 cm)	30	PIPL
	Lento (menos inclinado)	Perto (20 cm)	30	PILeP
		Longe (40 cm)	30	PILeL
	Rápido (mais inclinado)	Perto (20 cm)	30	PIRaP
		Longe (40 cm)	30	PIRaL

Fonte: Elaborado pelo autor (2026).


Além dos materiais avaliados, foram realizadas aquisições sem a presença de objetos, representando a condição de ausência de alvo. Para manter o balanceamento

da base de dados, foram geradas 180 imagens de espectrogramas para essa classe.

Embora os experimentos sejam realizados em um ambiente não controlado, opta-se por não incluir na base de dados capturas contendo surtos de interferência e níveis excessivos de ruído, como os ilustrados na Figura 22a e na Figura 22b. Essa decisão tem como objetivo delimitar o escopo do experimento e evitar que interferências externas comprometam excessivamente a qualidade dos dados utilizados no treinamento e na validação dos modelos de inteligência artificial. A inclusão dessas amostras poderia introduzir padrões não relacionados aos materiais e às condições experimentais avaliadas, dificultando o processo de aprendizado e reduzindo a capacidade do modelo de identificar corretamente as características Doppler associadas às classes de interesse.

Figura 22 – Exemplos de ruídos capturados pelo GNU Radio

- (a) Ruído gerado por um aparelho eletrônico (b) Picos de energia captados pelo radar



Fonte: Elaborado pelo autor (2026).


Essas interferências podem estar relacionadas à presença de dispositivos eletrônicos próximos ao sistema, como telefones celulares e equipamentos de rede sem fio, uma vez que a antena utilizada opera na faixa de 2,4 GHz, amplamente compartilhada por tecnologias de comunicação sem fio, como o Wi-Fi. Adicionalmente, parte dessas ocorrências pode estar associada às características do protótipo desenvolvido, incluindo a construção artesanal da antena helicoidal, possíveis imperfeições de montagem e outras limitações inerentes ao arranjo experimental adotado. Além disso, a presença recorrente dessas interferências poderia levar o modelo a aprender características associadas ao ruído do ambiente em vez das assinaturas dos materiais analisados, comprometendo a avaliação da viabilidade da metodologia proposta.

3.3 GERAÇÃO DO MODELO DE IA

Após a geração da base de dados contendo os espectrogramas obtidos pelo radar, realiza-se a etapa de validação da capacidade de classificação dos sinais por

meio de técnicas de inteligência artificial. Inicialmente, utiliza-se a plataforma *Teachable Machine*², ilustrada na Figura 23, desenvolvida pelo Google, com o objetivo de realizar avaliações preliminares sobre a viabilidade da classificação dos sinais gerados pelo radar. Essa etapa inicial permite verificar, de forma simplificada, se os espectrogramas produzidos apresentam características suficientes para diferenciar os cenários experimentais propostos.

Figura 23 – Tabua com as dimensões



Fonte: Elaborado pelo autor (2026).

Após os testes iniciais, desenvolve-se um *script* em Python para o treinamento, a validação e a análise dos modelos de classificação utilizados neste trabalho. O código completo pode ser encontrado no repositório disponível no `codigos.ufsc.br` (Heitmann, 2026b). Para o desenvolvimento dos modelos, utilizam-se bibliotecas como TensorFlow, Keras, NumPy, Matplotlib e Scikit-Learn, permitindo automatizar as etapas de treinamento, validação e geração das métricas de desempenho, incluindo as matrizes de confusão.

O modelo implementado utiliza como base a arquitetura MobileNetV2, que também corresponde a um dos modelos empregados pelo *Teachable Machine* (Google Creative Lab, 2026). Nesse método, utiliza-se uma rede neural convolucional previamente treinada na base de dados ImageNet, mantendo congeladas as camadas responsáveis pela extração de características visuais. Sobre essa estrutura, adicionam-se novas camadas densas responsáveis pela classificação das imagens de espectrograma geradas pelo radar.

As imagens são carregadas automaticamente a partir da estrutura de diretórios da base de dados e posteriormente divididas em conjuntos de treinamento e teste por meio de uma estratégia de amostragem estratificada. Para os experimentos realizados neste trabalho, define-se a utilização de 70% das imagens para treinamento e

² Projeto oficial disponível em: <https://teachablemachine.withgoogle.com/>. Acesso em: 7 jul. 2026.

30% para validação e teste dos modelos, buscando manter uma representação equilibrada entre as classes avaliadas.

Durante o treinamento, as imagens são redimensionadas para 224×224 pixels e normalizadas utilizando o pré-processamento padrão da MobileNetV2, de forma semelhante ao empregado pelo *Teachable Machine* Google (2026). O treinamento é realizado utilizando o otimizador Adam, a função de perda *sparse categorical crossentropy*, tamanho de lote (*batch size*) de 16 imagens e 50 épocas de treinamento.

Ao final do treinamento, são calculadas métricas de desempenho, incluindo acurácia, perda (*loss*), relatório de classificação e matriz de confusão. Essas métricas permitem avaliar a capacidade de generalização dos modelos e identificar possíveis erros de classificação entre as diferentes classes, possibilitando verificar a eficácia do radar na diferenciação de velocidades de deslocamento, distâncias relativas e materiais presentes no ambiente experimental.

3.4 DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL

Neste trabalho foram utilizadas ferramentas de inteligência artificial baseadas em modelos de linguagem de grande escala, incluindo o ChatGPT (versões GPT-5.x) e o Gemini (versões 3.x), como apoio ao desenvolvimento textual e à prototipação de *scripts* em Python. Sua utilização restringiu-se exclusivamente às seguintes atividades:

- Revisão linguística, ortográfica e gramatical;
- Reformulação de trechos do texto para melhoria da clareza, coesão e fluidez;
- Sugestões para estruturação do texto e organização do trabalho;
- Auxílio na interpretação e explicação de conceitos técnicos previamente pesquisados pelo autor;
- Geração de imagens, utilizados para fins de representação visual de metodologias e fluxos de trabalho apresentados no texto.

Nenhuma parte dos resultados experimentais, análises, cálculos, dados ou conclusões apresentadas neste trabalho foi produzida integralmente pelas ferramentas de inteligência artificial utilizadas. A participação dessas ferramentas limitou-se ao suporte editorial, ao auxílio no desenvolvimento de códigos e à geração de recursos gráficos de caráter ilustrativo. Todas as decisões técnicas, interpretações dos resultados, validações experimentais, elaboração da metodologia e conclusões permaneceram sob responsabilidade do autor, preservando a originalidade, a autoria e a integridade acadêmica do trabalho.

4 RESULTADOS

Neste capítulo são apresentados e discutidos os resultados obtidos a partir dos experimentos realizados com o radar ativo implementado utilizando SDR e técnicas de inteligência artificial. As análises tiveram como objetivo avaliar a capacidade do sistema em identificar diferentes características dos objetos presentes no ambiente experimental, incluindo presença, movimento, distância e tipo de material, a partir dos espectrogramas gerados pelos sinais Doppler capturados pelo radar.


4.1 TESTE DE FUNCIONALIDADE

A Figura 24 apresenta a interface do radar em execução. O quadro A corresponde aos controles de ajuste dinâmico do sistema, permitindo configurar parâmetros como a atenuação aplicada ao canal transmissor, o ganho do canal receptor, a frequência do sinal senoidal em banda base e a amplitude do sinal reproduzido pelo radar. Esses parâmetros fornecem maior flexibilidade para adaptação do sistema conforme as condições experimentais e o ambiente de operação.

O quadro B apresenta o espectrograma do sinal recebido, no qual o eixo X representa a frequência e o eixo Y representa o tempo. Observa-se que a maior concentração de energia ocorre na região central do espectro, enquanto as regiões acima de 1 kHz e abaixo de -1 kHz apresentam baixa intensidade espectral, representadas pela coloração azul escura. Esse comportamento ocorre devido à utilização do filtro passa-baixa com frequência de corte em 1 kHz, limitando a passagem de componentes espectrais fora dessa faixa.

Por fim, o quadro C apresenta o espectro em frequência do sinal processado, exibindo o ganho relativo em decibéis em função da frequência. Essa visualização permite analisar como os objetos presentes no ambiente afetam as componentes espectrais capturadas pelo radar Doppler. Apesar de úteis para monitoramento e análise qualitativa dos sinais durante os experimentos, essas ferramentas gráficas não foram essenciais para a etapa de classificação realizada pela inteligência artificial.


Figura 24 – Interface do radar no GNU Radio em execução



Fonte: Elaborado pelo autor (2026).

A Figura 25 apresenta exemplos de espectrogramas gerados pelo *script* desenvolvido em Python para diferentes materiais na condição com velocidade lenta e distância próxima da antena transmissora do radar. Observa-se que, visualmente, os padrões espectrais apresentam elevada similaridade entre si, dificultando a distinção manual das classes apenas por inspeção visual. Dessa forma, torna-se necessária a utilização de técnicas de inteligências artificial para extração automática de características e classificação dos sinais Doppler capturados pelo radar.

Figura 25 – Espectrogramas gerados para velocidade lenta e distância curta



Fonte: Elaborado pelo autor (2026).

4.2 CLASSIFICAÇÃO DE ESPECTROGRAMAS COM IA

Com o objetivo de avaliar diferentes capacidades de classificação do radar, foram desenvolvidos modelos independentes para os seguintes grupos experimentais:

- Classificação entre ausência de objeto, objeto parado e objeto em movimento;
- Classificação entre materiais madeira, metal e plástico;
- Classificação entre objetos próximos e distantes do radar;
- Classificação entre movimentos parado, lento e rápido considerando todos os materiais;
- Classificação entre movimentos parado, lento e rápido utilizando somente objetos de madeira;
- Classificação entre movimentos parado, lento e rápido utilizando somente objetos metálicos;


- Classificação entre movimentos parado, lento e rápido utilizando somente objetos plásticos.

4.2.1 Classificação da Presença dos Objetos

O primeiro experimento avaliou a capacidade do sistema em diferenciar três condições do ambiente monitorado: ausência de objeto, objeto parado e objeto em movimento. Para isso, foram utilizados 180 espectrogramas por classe, gerados a partir dos sinais capturados pelo radar Doppler ativo.

A Figura 26 apresenta as curvas de acurácia e perda (*loss*) obtidas durante o treinamento do modelo de inteligência artificial. Observa-se que a acurácia de treinamento apresentou crescimento gradual ao longo das épocas, atingindo aproximadamente 88%, enquanto a acurácia de validação estabilizou-se próxima de 82%. Em relação à função de perda, verificou-se redução contínua no conjunto de treinamento, indicando aprendizado progressivo do modelo.

Figura 26 – Gráficos de treinamento e perda por época para classificar presença




Fonte: Elaborado pelo autor (2026).

Apesar de um leve indício de *overfitting*, o modelo conseguiu extrair características relevantes dos espectrogramas, evidenciando que os sinais apresentam padrões suficientes para diferenciação.

A Figura 27 apresenta a matriz de confusão obtida durante os testes. Observa-se que a classe "movimento" apresentou o melhor desempenho, alcançando 54 classificações corretas e nenhuma confusão significativa com as demais classes. Esse resultado indica que os deslocamentos dos objetos geram alterações Doppler suficientemente perceptíveis no espectro do sinal.

Figura 27 – Matriz confusão para classificar presença



Fonte: Elaborado pelo autor (2026).

Por outro lado, verificou-se maior dificuldade na separação entre as classes "nada" e "parado". Parte das amostras classificadas como "parado" foi confundida com "nada", e vice-versa. Esse comportamento pode estar associado ao fato de ambas as condições apresentarem assinaturas espectrais relativamente estáticas, diferenciando-se apenas por pequenas alterações relacionadas à reflexão do sinal no objeto presente no ambiente.

O relatório de classificação apresentado na Tabela 1 demonstra que o modelo atingiu acurácia global de aproximadamente 82%. A classe "movimento" apresentou os melhores indicadores, com precisão de 96%, *recall* de 100% e *F1-score* de 98%. Já as classes "nada" e "parado" apresentaram métricas inferiores, porém ainda satisfatórias para validação inicial da proposta.

Tabela 1 – Relatório final para classificação de presença

Classe	Precisão	Recall	F1-score	Suporte
Movimento	0,96	1,00	0,98	54
Nada	0,73	0,74	0,73	54
Parado	0,76	0,72	0,74	54
Média macro	0,82	0,82	0,82	162
Média ponderada	0,82	0,82	0,82	162
Acurácia global				0,82

Fonte: Elaborado pelo autor (2026).


O elevado desempenho alcançado na identificação da classe “movimento” evidencia que o radar ativo desenvolvido foi capaz de extrair informações Doppler representativas das alterações dinâmicas presentes no ambiente monitorado. Essa característica é particularmente importante para aplicações de monitoramento de encostas, nas quais a identificação de movimentações constitui um dos principais mecanismos para a detecção precoce de possíveis instabilidades. Embora o sistema desenvolvido represente uma prova de conceito e tenha sido validado em condições experimentais controladas, os resultados obtidos indicam o potencial da metodologia para subsidiar o desenvolvimento de sistemas de monitoramento baseados em radar e inteligência artificial.

4.2.2 Classificação do Material dos Objetos

Após validar a detecção de movimento, treinou-se um modelo para classificar os materiais dos objetos. Foram utilizadas apenas imagens correspondentes às classes madeira, metal e plástico, independentemente da velocidade e da distância, totalizando 540 espectrogramas distribuídos de forma balanceada entre as três classes. O objetivo foi avaliar a capacidade do modelo em identificar o material a partir das características presentes nos sinais Doppler.

A Figura 28 apresenta as curvas de acurácia e perda ao longo das épocas de treinamento. Observa-se que a acurácia de treinamento apresentou crescimento gradual, atingindo valores próximos de 82%, enquanto a acurácia de validação estabilizou próxima de 65%. De forma semelhante, a perda do conjunto de treinamento reduziu progressivamente ao longo das épocas, enquanto a perda de validação apresentou oscilações e redução menos significativa. Esse comportamento indica que o modelo foi capaz de aprender padrões associados aos materiais analisados, porém com limitações na capacidade de generalização.


Figura 28 – Gráficos de treinamento e perda por época para classificar o material



Fonte: Elaborado pelo autor (2026).

Os resultados quantitativos finais são apresentados na Figura 29 e no relatório de classificação da Tabela 2. O modelo alcançou uma acurácia global de aproximadamente 65%, demonstrando que a classificação de materiais utilizando sinais Doppler apresenta maior complexidade quando comparada à detecção de movimento. Esse resultado indica que a classificação de materiais é mais complexa devido à maior similaridade entre os espectrogramas dos diferentes materiais.

Figura 29 – Matriz confusão para classificar o material



Fonte: Elaborado pelo autor (2026).

Analisando individualmente as classes, observa-se que o material metálico apresentou os melhores resultados, atingindo uma precisão de 0.78 e *recall* de 0.70. Esse comportamento pode estar relacionado à maior refletividade eletromagnética do metal, produzindo ecos mais intensos e consistentes no radar. O plástico também apresentou desempenho satisfatório, alcançando *recall* de 0.81, embora tenha apresentado algumas confusões com a classe madeira

Tabela 2 – Relatório final para classificação do material

Classe	Precisão	Recall	F1-score	Suporte
Madeira	0,56	0,44	0,49	54
Metal	0,78	0,70	0,74	54
Plástico	0,63	0,81	0,71	54
Média macro	0,65	0,65	0,65	162
Média ponderada	0,65	0,65	0,65	162
Acurácia global				0,65

Fonte: Elaborado pelo autor (2026).

Por outro lado, a madeira apresentou o menor desempenho entre as classes analisadas, com *F1-score* de 0.49. A matriz de confusão evidencia que diversas amostras de madeira foram classificadas incorretamente como plástico. Uma possível justificativa para esse comportamento está relacionada à menor refletividade da madeira em comparação ao metal, além da similaridade dos padrões espectrais gerados pelos materiais não metálicos.

Os resultados obtidos demonstram que, além da detecção de movimento, os sinais Doppler também apresentam informações capazes de distinguir diferentes materiais, ainda que com desempenho inferior ao observado nas demais tarefas de classificação. Embora esta avaliação tenha sido realizada utilizando objetos de referência, ela evidencia o potencial da metodologia para extrair características físicas dos alvos monitorados. Em futuras aplicações voltadas ao monitoramento de encostas, essa capacidade poderá ser investigada para a diferenciação de elementos presentes no ambiente monitorado, complementando as informações de movimentação e contribuindo para uma análise mais abrangente das condições da área.

4.2.3 Classificação da Distância dos Objetos


O próximo modelo avaliado teve como foco a capacidade de classificar a distância dos objetos, que resultou em um dos melhores desempenhos entre todos os modelos avaliados. Os resultados mostram que o modelo apresentou elevada capacidade de diferenciação entre os cenários "perto" e "longe", alcançando acurácia global de 91%, conforme apresentado na Tabela 3 e na matriz de confusão, indicado na Figura 30.

Tabela 3 – Relatório de classificação final para classificação da distância

Classe	Precisão	Recall	F1-score	Suporte
Longe	0,91	0,91	0,91	81
Perto	0,91	0,91	0,91	81
Média macro	0,91	0,91	0,91	162
Média ponderada	0,91	0,91	0,91	162
Acurácia global				0,91

Fonte: Elaborado pelo autor (2026).


Figura 30 – Matriz confusão para classificar a distância



Fonte: Elaborado pelo autor (2026).

A matriz de confusão evidencia equilíbrio entre as duas classes, com 74 acertos para “perto” e “longe” e apenas sete erros em cada uma. As curvas de treinamento, na Figura 31, indicam convergência estável, com acurácias de treinamento e validação próximas e redução consistente da função de perda, sugerindo boa capacidade de generalização.

Figura 31 – Gráficos de treinamento e perda por época para classificar a distancia



Fonte: Elaborado pelo autor (2026).

O elevado desempenho obtido na classificação da distância demonstra que os padrões presentes nos ecos refletidos contêm informações suficientes para diferenciar cenários de aproximação e afastamento em relação ao radar. Embora o sistema desenvolvido não realize a localização precisa dos objetos, esse resultado indica que informações relacionadas à distância podem ser exploradas por técnicas de inteligência artificial. Em aplicações de monitoramento de encostas, essa capacidade pode contribuir para a identificação de movimentações ocorrendo em diferentes regiões monitoradas, complementando outras informações obtidas pelo sistema e auxiliando na detecção de possíveis instabilidades.

4.2.4 Classificação da velocidade dos objetos

Para avaliar a capacidade do sistema em identificar diferentes padrões de movimentação, foram realizados experimentos considerando as classes parado, lento e rápido. Inicialmente, o modelo foi treinado utilizando simultaneamente madeira, metal e plástico e, posteriormente, com cada material de forma independente, permitindo avaliar a influência das propriedades físicas dos alvos.

A Tabela 4 apresenta um resumo dos resultados obtidos para cada cenário analisado.

Tabela 4 – Resumo dos resultados da classificação de velocidade


Cenário	Acurácia	Melhor Classe	Pior Classe
Todos os materiais	83%	Parado (F1 = 0,97)	Lento (F1 = 0,70)
Madeira	96%	Parado (F1 = 1,00)	Lento/Rápido (F1 = 0,94)
Metal	96%	Parado (F1 = 1,00)	Rápido (F1 = 0,94)
Plástico	91%	Parado (F1 = 1,00)	Rápido (F1 = 0,85)

Fonte: Elaborado pelo autor (2026).

Observa-se que o desempenho do modelo melhorou significativamente quando os materiais foram analisados individualmente. Enquanto o treinamento utilizando todos os materiais simultaneamente atingiu acurácia de 83%, os modelos específicos para madeira e metal alcançaram 96%, enquanto o modelo para plástico obteve 91%.

A principal dificuldade observada ocorreu na diferenciação entre as classes lento e rápido quando todos os materiais foram agrupados em uma única base de dados. Conforme apresentado na matriz de confusão da Figura 32, aproximadamente metade das amostras pertencentes à classe lento foi incorretamente classificada como rápido. Esse comportamento sugere que as assinaturas espectrais produzidas por diferentes materiais podem introduzir variações adicionais que dificultam a identificação exclusiva da velocidade de movimentação.

Figura 32 – Matriz confusão para classificar a velocidade




Por outro lado, ao restringir o treinamento para um único material, a influência das propriedades eletromagnéticas dos alvos foi reduzida, permitindo que o modelo concentrasse o aprendizado principalmente nas características associadas ao movimento. Como consequência, observou-se uma redução significativa dos erros de classificação e um aumento expressivo da acurácia.

Em todos os cenários, a classe “parado” apresentou o melhor desempenho ($F1 = 1,00$), devido à maior estabilidade das assinaturas Doppler produzidas por objetos estacionários.

Entre os materiais analisados individualmente, o plástico apresentou o menor desempenho, com acurácia global de 91%. A matriz de confusão, apresentado na Figura 33, indica que parte das amostras classificadas como plástico rápido foi con-

fundida com plástico lento. Uma possível explicação para esse comportamento está relacionada à menor refletividade eletromagnética do plástico em comparação ao metal, resultando em ecos mais fracos e consequentemente em características espectrais menos pronunciadas.


Figura 33 – Matriz de confusão para classificar a velocidade do plástico




Fonte: Elaborado pelo autor (2026).

As curvas de treinamento e validação apresentadas na Figura 34 demonstram convergência satisfatória em todos os cenários analisados. Observa-se ainda que as curvas de perda apresentaram tendência decrescente ao longo das épocas, indicando que o modelo foi capaz de aprender padrões relevantes presentes nos espectrogramas gerados pelo radar.


Figura 34 – Curvas de treinamento e validação para a classificação da velocidade




(a) Geral



(b) Madeira



(c) Metal



(d) Plástico

Fonte: Elaborado pelo autor (2026).

De maneira geral, os resultados demonstram que o sistema é capaz de identificar diferentes velocidades de movimentação utilizando assinaturas Doppler obtidas por um radar SDR ativo de baixo custo. Para aplicações em monitoramento de en-

costas, essa capacidade pode auxiliar na identificação de movimentações anômalas e, futuramente, na obtenção de informações complementares sobre a natureza dos objetos em movimento, contribuindo para uma análise mais abrangente do ambiente monitorado.

4.3 LIMITAÇÕES DO PROJETO

Os resultados demonstraram a viabilidade da metodologia proposta, porém algumas limitações devem ser consideradas, relacionadas às condições experimentais, à base de dados e ao protótipo desenvolvido.

- **Base de dados limitada:** O conjunto de dados foi obtido a partir de um número reduzido de materiais, distâncias e velocidades em um ambiente específico. Assim, o desempenho observado pode não representar completamente o comportamento do sistema em cenários mais variados.
- **Robustez frente a interferências externas:** Embora os experimentos tenham sido realizados em ambiente não controlado, amostras com surtos significativos de interferência foram removidas da base de dados. Dessa forma, o impacto dessas interferências sobre o desempenho dos modelos não foi avaliado, sendo necessários estudos adicionais para verificar a robustez do sistema em condições mais adversas.
- **Características do protótipo:** A antena helicoidal e parte da estrutura do radar foram construídas artesanalmente, podendo apresentar limitações em comparação com sistemas comerciais. Além disso, as classificações foram realizadas apenas para materiais e condições presentes na base de treinamento, restringindo a capacidade de generalização do modelo.
- **Treinamento e validação dos modelos:** Os modelos foram treinados por 50 épocas utilizando uma base reduzida, com aproximadamente 21 amostras por classe. Embora essa configuração tenha permitido validar a metodologia, diferentes números de épocas, técnicas de *early stopping*, ajuste de hiperparâmetros, bases maiores e validação cruzada (*k-fold*) poderão fornecer estimativas mais robustas da capacidade de generalização.

5 CONCLUSÃO

Este trabalho apresentou o desenvolvimento e a avaliação experimental de um sistema de radar ativo baseado em Rádio Definido por Software (SDR) para detecção de movimentação e classificação de objetos por meio de técnicas de inteligência artificial. O sistema foi implementado utilizando o dispositivo ADALM-PLUTO e o ambiente GNU Radio, permitindo a transmissão, recepção e processamento de sinais Doppler refletidos por objetos presentes no ambiente. A partir dos sinais adquiridos, foram gerados espectrogramas empregados como entrada para modelos de aprendizado de máquina, possibilitando a realização de diferentes tarefas de classificação.

Os resultados obtidos demonstraram a viabilidade da metodologia proposta. Na classificação entre ausência de objeto, objeto parado e objeto em movimento, o sistema alcançou acurácia próxima de 82%, evidenciando a capacidade do radar em identificar diferentes condições de movimentação. Na análise da distância dos objetos, foram obtidos resultados ainda mais expressivos, com acurácia próxima de 91%, indicando que os espectrogramas gerados a partir dos ecos recebidos apresentam características suficientemente distintas para diferenciar objetos posicionados em diferentes distâncias da antena transmissora.

Os experimentos relacionados à classificação de velocidade também apresentaram resultados promissores. Quando todos os materiais foram considerados simultaneamente, o modelo alcançou acurácia aproximada de 83%, enquanto os experimentos realizados individualmente para madeira, metal e plástico apresentaram desempenhos superiores, próximos ou acima de 90%. Esses resultados indicam que a redução da variabilidade dos dados facilita a identificação das características associadas ao movimento dos objetos. Por outro lado, a classificação simultânea dos materiais apresentou maior grau de dificuldade, atingindo acurácia em torno de 65%, sugerindo que diferentes materiais podem produzir assinaturas espectrais semelhantes nas condições avaliadas. Ainda assim, os resultados obtidos demonstram a existência de padrões detectáveis associados às propriedades dos materiais analisados.

Além dos resultados quantitativos, o trabalho demonstrou que sistemas SDR de baixo custo podem ser empregados em aplicações experimentais envolvendo radar e inteligência artificial. A utilização do GNU Radio proporcionou flexibilidade para o desenvolvimento e ajuste do sistema, enquanto a geração de espectrogramas permitiu explorar técnicas modernas de visão computacional e aprendizado profundo para análise dos sinais Doppler.

Embora os experimentos tenham sido realizados em ambiente de laboratório e com objetos de referência, os resultados obtidos demonstram que a combinação entre radar ativo baseado em SDR e inteligência artificial apresenta potencial para

aplicações de monitoramento remoto. No contexto do monitoramento de encostas, a elevada capacidade de detecção de movimentação e os resultados obtidos na classificação de distância e velocidade indicam que a metodologia proposta constitui uma etapa inicial promissora para o desenvolvimento de sistemas destinados à detecção precoce de possíveis instabilidades. Além disso, a classificação dos materiais sugere a possibilidade de obtenção de informações complementares sobre os objetos em movimento, auxiliando na interpretação dos eventos detectados e ampliando as possibilidades de aplicação do sistema.

Entretanto, algumas limitações foram identificadas ao longo do desenvolvimento do projeto. A base de dados foi construída a partir de um número restrito de materiais, velocidades e distâncias, em um ambiente experimental específico, o que pode limitar a capacidade de generalização dos modelos treinados. Adicionalmente, embora o sistema tenha operado em ambiente não controlado, o impacto de interferências externas sobre o desempenho da classificação não foi avaliado diretamente, uma vez que amostras contendo surtos significativos de ruído foram removidas da base de dados. Aspectos relacionados à construção artesanal da antena helicoidal e às características do protótipo desenvolvido também podem ter influenciado os resultados obtidos.

Como trabalhos futuros, recomenda-se a ampliação da base de dados, incluindo uma maior diversidade de materiais, condições de movimentação e cenários ambientais. Também podem ser investigados métodos de processamento de sinais mais robustos, bem como técnicas de pré-processamento dos espectrogramas, como redução de ruído, normalização e realce de contraste, além de arquiteturas mais avançadas de redes neurais convolucionais, técnicas de aumento de dados e diferentes estratégias de validação dos modelos de inteligência artificial, incluindo a validação cruzada (k-fold cross-validation), de forma a fornecer estimativas mais robustas do desempenho e da capacidade de generalização dos classificadores. Adicionalmente, a realização de experimentos em ambientes externos e em condições mais próximas das aplicações reais de monitoramento poderá contribuir para uma avaliação mais abrangente da metodologia proposta.

Por fim, conclui-se que a adaptação de uma plataforma SDR para operação como radar ativo, combinada à utilização de espectrogramas e técnicas de aprendizado profundo, mostrou-se uma abordagem viável para detecção de movimentação e classificação de objetos. Os resultados obtidos evidenciam o potencial da combinação entre radares SDR e inteligência artificial como uma alternativa de baixo custo para aplicações de sensoriamento remoto e monitoramento de áreas sujeitas a instabilidades, constituindo uma base para o desenvolvimento de pesquisas futuras nessa área.

REFERÊNCIAS

ABOUZAID, S. *et al.* Deep learning-based material characterization using fmcw radar with open-set recognition technique. **IEEE Transactions on Microwave Theory and Techniques**, v. 71, n. 11, p. 4628 – 4638, 2023.

Analog Devices, I. **ADALM-PLUTO overview**. 2021. Disponível em: <https://wiki.analog.com/university/tools/pluto>. Acesso em: 25 out. 2025.

AprendeIA. **Sobreajuste y subajuste en Machine Learning**. 2018. <https://aprendeia.com/2018/11/16/sobreajuste-y-subajuste-en-machine-learning/>. Acesso em: 6 jun. 2026.

BALANIS, C. A. **Antenna theory: Analysis and design**. 3rd ed. Hoboken, New Jersey: John Wiley & Sons, Inc., 2005.

BANASEKA, F. K. *et al.* Signal propagation models in soil medium for the study of wireless underground sensor networks: A review of current trends. **Wireless Communications and Mobile Computing**, Hindawi, v. 2021, p. 1–12, 2021.

BORNHAUSEN, M. L. C. **Análise experimental de detecção de movimentação utilizando radar passivo e SDR**. 2025. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecatrônica) — Centro Tecnológico de Joinville, Universidade Federal de Santa Catarina, Joinville, 2025.

CARVALHO, C. **Modelos de IA: O que são e como funcionam**. 2025. <https://hub.asimov.academy/blog/modelos-de-ia/>. Acesso em: 6 jun. 2026.

CASAGLI, N. *et al.* Landslide mapping and monitoring by using radar and optical remote sensing: Examples from the ec-fp7 project safer. **Remote sensing applications: Society and environment**, v. 4, p. 92–108, 2016.

COLLINS, T. F. *et al.* **Software-Defined Radio for engineers**. Norwood, MA: Artech House, 2018.

FENG, S.; MUGHEES, N.; WOLLESEN, V. Reviewing the application and integration of software defined radios to radar systems. *In: Proceedings of the 2020 IEEE RADAR CONFERENCE (RADARCONF20)*. Florence, Italy: IEEE, 2020. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/document/9266396>. Acesso em: 8 nov. 2025.

GALLICCHIO, C. **Lesson 8b — Pluto Doppler RADAR**. 2022. Disponível em: <https://gallicchio.github.io/learnSDR/lesson08b.html> (Acesso em: 6 maio 2026).

GENG, Z. *et al.* Deep-learning for radar: A survey. **IEEE access**, v. 9, p. 141800–141818, 2021.

GNU Radio Project. **About GNU radio**. 2025. Disponível em: <https://www.gnuradio.org/about/>. Acesso em: 26 out. 2025.

Google. **Teachable Machine**. 2026. <https://teachablemachine.withgoogle.com/train/image>. Acesso em: 21 maio 2026.

Google Creative Lab. **Teachable Machine Community Libraries**. 2026. <https://github.com/googlecreativelab/teachablemachine-community/tree/master/libraries>. Acesso em: 21 maio 2026.

GRIFFITHS, H.; BAKER, C. **An introduction to passive radar**. Norwood, MA, USA: Artech, 2017.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de física: Gravitação, ondas e termodinâmica**. 10th ed. Rio de Janeiro: LTC, 2016. v. 2.

HEITMANN, T. **Radar SDR Dataset**. Zenodo, 2026. Disponível em: <https://doi.org/10.5281/zenodo.20464962>.

HEITMANN, T. **TCC Radar Ativo**. 2026. https://codigos.ufsc.br/thomas.heitmann/tcc_radar_ativo. Acesso em: 28 maio 2026.

HEUNIS, S.; PAICHARD, Y.; INGGIS, M. Passive radar using a software-defined radio platform and opensource software tools. *In: Proceedings of the 2011 IEEE RADARCON (RADAR)*. Kansas City, MO, USA: IEEE, 2011. p. 879–884. Disponível em: <https://ieeexplore.ieee.org/document/5960663>. Acesso em: 7 nov. 2025.

HONÓRIO, R. **Overfitting e Underfitting**: Entenda as diferenças. 2025. <https://hub.asimov.academy/blog/overfitting-e-underfitting/>. Acesso em: 6 jun. 2026.

IBM Data and AI Team. **AI vs. machine learning vs. deep learning vs. neural networks**: What's the difference? 2025. Disponível em: <https://www.ibm.com/think/topics/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>. Acesso em: 4 nov. 2025.

JAMALI, B.; RAMALINGAM, D.; BABAKHANI, A. Intelligent material classification and identification using a broadband millimeter-wave frequency comb receiver. **IEEE Sensors Letters**, v. 4, n. 7, 2020.

KHUSHABA, R. N.; HILL, A. J. Radar-based materials classification using deep wavelet scattering transform: A comparison of centimeter vs. millimeter wave units. **IEEE Robotics and Automation Letters**, v. 7, n. 2, p. 2016–2022, 2022.

LATHI, B. P. **Sinais e sistemas lineares**. 2nd ed. Porto Alegre: Bookman, 2008.

LIAQUAT, S. *et al.* Sdr-based metal classification using spectrogram images from micro-doppler signatures. **IEEE Instrumentation and Measurement Magazine**, v. 28, n. 3, p. 22 – 29, 2025.

MIKAC, E. **What are the most common types of communication antennae?** 2024. Disponível em <https://www.cbttuggets.com/blog/technology/networking/common-communication-antenna-types>. Acesso em: 1 nov. 2025.

MIN, H. **Aplicações de machine learning em marketing e vendas**. 2020. Disponível em: <https://medium.com/@henriqm01/aplica%C3%A7%C3%B5es-de-machine-learning-em-marketing-e-vendas-da4221156ebe>. Acesso em: 6 nov. 2025.

Modern Physics. **Antena Helicoidal**: Ganho, largura de banda e polarização. 2026. Disponível em: <https://modern-physics.org/antena-helicoidal-ganho-largura-de-banda-e-polarizacao/>. Acesso em: 4 jun. 2026.

MONDINI, A. C. *et al.* Landslide failures detection and mapping using synthetic aperture radar: Past, present and future. **Earth-Science reviews**, Amsterdam, v. 216, p. 103574, 2021.

MUREL, J.; KAVLAKOGLU, E. **O que são modelos de classificação?** 2024. Disponível em: <https://www.ibm.com/br-pt/think/topics/classification-models>. Acesso em: 4 jun. 2026.

NONGPROMMA, S. *et al.* An investigation of material classification using 60 ghz mmwave fmcw radar and feature selection-based machine learning. *In*: **Proceedings** of the 22nd INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING/ELECTRONICS, COMPUTER, TELECOMMUNICATIONS AND INFORMATION TECHNOLOGY (ECTI-CON). Bangkok, Thailand: IEEE, 2025. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/abstract/document/11100488>. Acesso em: 8 out. 2025.

OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-Time signal processing**. 3rd ed. Harlow, Essex, England: Pearson Education Limited, 2014.

PIRASTEH, S.; LI, J. Landslides investigations from geoinformatics perspective: quality, challenges, and recommendations. **Geomatics, natural hazards and risk**, v. 8, n. 2, p. 448–465, 2017.

ROCHA, F. G.; NASCIMENTO, B. A. R.; NASCIMENTO, E. F. V.-B. C. d. Um modelo de mapeamento sistemático para a educação. **Cadernos da FUCAMP**, FUCAMP, Monte Carmelo, v. 17, n. 29, p. 1–6, 2018.

RUBACK, L.; AVILA, S.; CANTERO, L. Vieses no aprendizado de máquina e suas implicações sociais: Um estudo de caso no reconhecimento facial. *In*: . [S.l.: s.n.], 2021. p. 90–101.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence**: A modern approach. 3rd ed. Upper Saddle River, NJ, USA: Pearson Education Inc., 2009.

SADIKU, M.; AKUJUOBI, C. Software-defined radio: a brief overview. **IEEE potentials**, v. 23, n. 4, p. 14–15, 2004.

SCOPUS. **Analyze search results**. 2025. Disponível em: <https://www.scopus.com/analyzer>. Acesso em: 9 nov. 2025.

SINGH, A. *et al.* Waldo finds you using machine learning: Wireless adaptive location and detection of objects. *In*: **Proceedings** of the IEEE RADAR CONFERENCE (RADARCONF21). Atlanta, GA, USA: IEEE, 2021. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/document/9455315>. Acesso em: 8 out. 2025.

SKARIA, S.; HENDY, N.; AL-HOURANI, A. Machine-learning methods for material identification using mmwave radar sensor. **IEEE Sensors Journal**, v. 23, n. 2, p. 1471–1478, 2023.

SKOLNIK, M. I. **Introduction to radar systems**. 2nd ed. New York, NY, USA: McGraw-Hill Book Company, 1980.

SKOLNIK, M. I. **Radar handbook**. 3rd ed. New York, NY, USA: McGraw-Hill, 2008.

SYSTEMS, C. **Omni antenna vs. directional antenna**. 2007. Disponível em: <https://www.cisco.com/c/en/us/support/docs/wireless-mobility/wireless-lan-wlan/82068-omni-vs-direct.html>. Acesso em: 30 out. 2025.

WEBER, R. L. **Implementation of a 24 GHz radar combined with accelerometers for detection of passengers in a moving vehicle**. 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia de Controle e Automação) — Centro Tecnológico de Ciências Exatas e Educação, Universidade Federal de Santa Catarina, Blumenau, 2019.

WIRELESS, E. **What are the differences between an omnidirectional antenna and a directional antenna?** 2024. Disponível em: <https://excel-wireless.com/what-are-the-differences-between-an-omnidirectional-antenna-and-a-directional-antenna/>. Acesso em: 31 out. 2025.

WORLD, R. W. **Active vs. passive radar**: Key differences explained. 2025. Disponível em: <https://www.rfwireless-world.com/terminology/active-vs-passive-radar>. Acesso em: 24 out. 2025.