

MARINHA DO BRASIL
DIRETORIA DE ENSINO DA MARINHA
CENTRO DE INSTRUÇÃO ALMIRANTE ALEXANDRINO

CURSO DE APERFEIÇOAMENTO AVANÇADO EM
GUERRA ELETRÔNICA

TRABALHO DE CONCLUSÃO DE CURSO

SISTEMAS INTELIGENTES PARA CLASSIFICAÇÃO DE SINAIS: estudo e
implementação de redes neurais convolucionais



PRIMEIRO-TENENTE EVERTON ALVARINHO DE OLIVEIRA

Rio de Janeiro
2025

PRIMEIRO-TENENTE EVERTON ALVARINHO DE OLIVEIRA

SISTEMAS INTELIGENTES PARA CLASSIFICAÇÃO DE SINAIS: estudo e
implementação de redes neurais convolucionais

Monografia apresentada ao Centro de Instrução
Almirante Alexandrino como requisito parcial à
conclusão do Curso de Aperfeiçoamento Avançado
em Guerra Eletrônica.

Orientadores:

Remulo Manuel Caminha Gomes, Capitão-Tenente
Arthur Pinheiro de Araujo Costa, Capitão-Tenente


Rio de Janeiro
2025

SISTEMAS INTELIGENTES PARA CLASSIFICAÇÃO DE SINAIS: estudo e
implementação de redes neurais convolucionais


Primeiro-Tenente Everton Alvarinho de Oliveira

MONOGRAFIA APRESENTADA AO CENTRO DE INSTRUÇÃO ALMIRANTE
ALEXANDRINO COMO REQUISITO PARCIAL À CONCLUSÃO DO CURSO DE
APERFEIÇOAMENTO AVANÇADO EM GUERRA ELETRÔNICA.


Aprovada por:



CT (EN) Remulo Manuel Cominha Gomes – CGAEM



CT Arthur Pinheiro de Araujo Costa, MSc – CIAA



Prof. Dr. Marco Antonio Grivet Mattoso Maia – PUC Rio

RIO DE JANEIRO, RJ – BRASIL
NOVEMBRO DE 2025

Oliveira, Everton Alvarinho de

Sistemas Inteligentes para Classificação de Sinais: estudo e implementação de redes neurais convolucionais / Everton Alvarinho de Oliveira – Rio de Janeiro: MB/CIAA, 2025.

XIV, 50 p.: il.,; 29,7 cm.

Orientador: Remulo Manuel Caminha Gomes; Arthur Pinheiro de Araujo Costa

Trabalho de Conclusão de Curso – MB/CIAA/Curso de Aperfeiçoamento Avançado em Guerra Eletrônica, 2025.

Referências Bibliográficas: p. 47-48.

1. Classificação automática de modulação. 2. Redes neurais convolucionais. I. Gomes, Remulo Manuel Caminha, *et al.* II. Marinha do Brasil, CIAA, Curso de Aperfeiçoamento Avançado em Guerra Eletrônica. III. Título.

Dedico esse trabalho a minha esposa que me apoia e fortalece todos os dias e aos meus pais que sempre estiveram ao meu lado em toda minha carreira.

AGRADECIMENTOS

Agradeço, primeiramente, aos meus orientadores, Capitão-Tenente Caminha e Capitão-Tenente Arthur Costa, pela orientação segura, o apoio técnico, a paciência e a confiança depositada em meu trabalho para a condução e a qualidade desta pesquisa.

Aos meus pais, dedico um agradecimento repleto de amor e gratidão. Vocês foram o alicerce de toda a minha formação, com seu apoio incondicional, sacrifício e incentivo constante. Por acreditarem em mim desde o início e por todo o suporte ao longo desta jornada, esta conquista também é de vocês.

Aos professores do curso de Guerra Eletrônica, meu muito obrigado. Os conhecimentos transmitidos e a dedicação de cada um de vocês foram cruciais para construir a base teórica que permitiu o desenvolvimento deste trabalho.

Por fim, e de forma muito especial, agradeço à minha esposa, Mayara. Seu amor, paciência infinita e compreensão foram meu porto seguro e a principal fonte de motivação. Agradeço por todo o apoio inabalável, por entender minhas ausências durante as longas horas de estudo e por ser a força que me impulsionou nos momentos de cansaço. Esta vitória não é apenas minha, é nossa.

“Não existe caminho para a
felicidade, a felicidade é o
caminho.”

Mahatma Gandhi

Resumo do Trabalho de Conclusão de Curso apresentado ao CIAA/MB como requisito parcial para a conclusão do Curso de Aperfeiçoamento Avançado para Oficiais da Armada

SISTEMAS INTELIGENTES PARA CLASSIFICAÇÃO DE SINAIS: estudo e
implementação de redes neurais convolucionais

Everton Alvarinho de Oliveira

Novembro/ 2025

Orientadores: CT (EN) Remulo Manuel Caminha Gomes
CT Arthur Pinheiro de Araujo Costa

Curso de Aperfeiçoamento Avançado em Guerra Eletrônica

A Classificação Automática de Modulação (AMC) é uma tarefa essencial em sistemas de comunicação não cooperativos, onde os métodos tradicionais enfrentam desafios em ambientes com ruído. Este trabalho aborda o problema por meio do aprendizado profundo, com o objetivo de desenvolver, implementar e avaliar um sistema de AMC baseado em uma Rede Neural Convolucional (CNN). A metodologia emprega o dataset de referência RadioML2016.10a, processando diretamente as amostras brutas em fase e quadratura (I/Q) com uma arquitetura de CNN modular. A análise de desempenho é focada na robustez do modelo sob diferentes níveis de Relação Sinal-Ruído (SNR). Os resultados demonstram que a performance do classificador é fortemente dependente do SNR, atingindo uma acurácia global de aproximadamente 80% em cenários de alto SNR (acima de +4 dB), mas com degradação severa em baixo SNR (abaixo de -8 dB). Foram identificados padrões de erro consistentes, como a dificuldade em distinguir modulações da família QAM e as analógicas (WBFM e AM-DSB). O estudo valida a CNN como uma abordagem viável para AMC e analisa seus limites práticos frente ao ruído.

Palavras-chave: Classificação Automática de Modulação. Redes Neurais Convolucionais. Relação Sinal-Ruído.

Abstract of the Undergraduate Final Work presented to CIAA/MB as a partial fulfillment of the requirements for the conclusion of the Advanced Improvement Course for Navy Officers

INTELLIGENT SYSTEMS FOR SIGNAL CLASSIFICATION: study and
implementation of convolutional neural networks

Everton Alvarinho de Oliveira

November/ 2025

Advisors: Remulo Manuel Caminha Gomes
Arthur Pinheiro de Araujo Costa

Advanced Improvement Course in Electronic Warfare

Automatic Modulation Classification (AMC) is an essential task in non-cooperative communication systems, where traditional methods face challenges in noisy environments. This work addresses the problem through deep learning, aiming to develop, implement, and evaluate an AMC system based on a Convolutional Neural Network (CNN). The methodology employs the RadioML2016.10a benchmark dataset, directly processing raw in-phase and quadrature (I/Q) samples with a modular CNN architecture. The performance analysis is focused on the model's robustness under different Signal-to-Noise Ratio (SNR) levels. The results demonstrate that the classifier's performance is strongly dependent on the SNR, reaching a global accuracy of approximately 80% in high-SNR scenarios (above +4 dB), but with severe degradation in low-SNR conditions (below -8 dB). Consistent error patterns were identified, such as the difficulty in distinguishing between modulations of the QAM family and analog ones (WBFM and AM-DSB). The study validates the CNN as a viable approach for AMC and analyzes its practical limits in the presence of noise.

Keywords: Automatic Modulation Classification. Convolutional Neural Networks. Signal-to-Noise Ratio.

LISTA DE TABELAS

Tabela 1 - Resumo do Banco de dados RadioML2016.10a.	20
Tabela 2 - Codificação one-hot dos dados de entrada.	29
Tabela 3 - Resumo da arquitetura da CNN.....	32

LISTA DE FIGURAS

Figura 1 - Representação simplificada de um neurônio matemático.....	9
Figura 2 - Comparação Rede Neural Simples e Rede Neural Profunda.....	10
Figura 3 - Exemplo simplificado de uma CNN.	11
Figura 4 - Exemplo de Camada de Convolução.....	13
Figura 5 - Representação camada de convolução.....	13
Figura 6 - Exemplo de operação de max pooling.....	14
Figura 7 - Exemplo de operação de zero <i>padding</i>	15
Figura 8 - Diagrama de Constelação para SNR= -20 dB.	23
Figura 9 - Diagrama de Constelação para SNR= 0 dB.....	24
Figura 10 - Diagrama de Constelação para SNR= 10 dB.....	24
Figura 11 - Diagrama de Constelação para SNR= 18 dB.....	25
Figura 12 - Diagrama de Constelação para modulação AM-DSB.	26
Figura 13 - Diagrama de Constelação para modulação QAM64.....	26
Figura 14 - Curva de acurácia e de perda.	37
Figura 15 - Desempenho por SNR: Acurácia, Precisão, Recall e F1-score.	38
Figura 16 - Desempenho da Acurácia por SNR.	39
Figura 17 - Desempenho do Grupo de Modulações por SNR.	40
Figura 18 - Matriz de Confusão.....	41

LISTA DE SIGLAS E ABREVIATURAS

Símbolo	Termo em Inglês	Termo em Português
8PSK	8-Phase Shift Keying	-
AM-DSB	Amplitude Modulation – Double Sideband	-
AM-SSB	Amplitude Modulation – Single Sideband	-
AMC	Automatic Modulation Classification	Classificação Automática de Modulação
ANN	Artificial Neural Network	Rede Neural Artificial
BPSK	Binary Phase Shift Keying	-
CPFSK	Continuous Phase Frequency Shift Keying	-
CNN	Convolutional Neural Network	Rede Neural Convolucional
DL	Deep Learning	Aprendizado Profundo
DT	Decision Tree	Árvore de Decisão
ELINT	Electronic Intelligence	Inteligência Eletrônica
GFSK	Gaussian Frequency Shift Keying	-
IA	Artificial Intelligence	Inteligência Artificial
I/Q	In-phase / Quadrature	Fase / Quadratura
KNN	k-Nearest Neighbors	-
LSTM	Long Short-Term Memory	-
ML	Machine Learning	Aprendizado de Máquina
PAM4	Pulse Amplitude Modulation (4-level)	-
PSK	Phase Shift Keying	-
QAM	Quadrature Amplitude Modulation	-

QAM16	16-Quadrature Amplitude Modulation	-
QAM64	64-Quadrature Amplitude Modulation	-
QPSK	Quadrature Phase Shift Keying	-
RadioML2016.10a	RadioML 2016.10a dataset	Conjunto de dados RadioML 2016.10a
ResNet	Residual Network	-
RF	Radio Frequency	Radiofrequência
RWR	Radar Warning Receiver	Receptor de Alerta Radar
SDR	Software-Defined Radio	Rádio Definido por Software
SNR	Signal-to-Noise Ratio	Relação Sinal-Ruído
TFR	Time-Frequency Representation	Representação Tempo-Frequência

SUMÁRIO

1 INTRODUÇÃO	1
1.1 Apresentação do Problema	1
1.2 Justificativa e Relevância	1
1.3 Pergunta de Pesquisa e Hipótese	3
1.4 Objetivos.....	3
1.4.1 Objetivo Geral	3
1.4.2 Objetivos Específicos	4
1.5 Organização do Trabalho	4
2 REFERENCIAL TEÓRICO	6
2.1 Sinais e Modulação: Os Pilares da Comunicação.....	6
2.1.1 Conceitos Básicos.....	6
2.2 Rádio Definido por Software	7
2.3 Métodos de Classificação de Modulação	7
2.4 Inteligência Artificial e Redes Neurais	8
2.4.1 Conceitos Básicos.....	8
2.4.2 Redes Neurais Artificiais.....	9
2.4.3 Redes Neurais Profundas.....	10
2.4.4 Redes Neurais Convolucionais.....	11
2.4.4.1 Operação de Convolução.....	12
2.4.4.2 Camada Convolucional.....	13
2.4.4.3 Camadas de <i>Pooling</i>	14
2.4.4.4 Funções de <i>Padding</i>	15
2.4.4.5 Camada de Vetorização	16
2.4.4.6 Aplicação em Sinais de RF.....	16
2.5 Trabalhos Relacionados	17
3 METODOLOGIA.....	19
3.1 O Conjunto de Dados RadioML2016.10a.....	19
3.2 Visualização.....	21
3.2.1 Visualização inicial.....	22
3.2.2 Visualização escalonada	25
3.3 Preparação dos Dados	27

3.3.1 Consolidação e estruturação do <i>Dataset</i>	27
3.3.2 Particionamento em Conjuntos de Treino, Validação e Teste.....	28
3.3.3 Codificação dos Rótulos de Saída	28
3.4 Arquitetura da Rede proposta.....	29
3.4.1 Camada de Entrada e Blocos Convolucionais	30
3.4.2 Camada de Vetorização	31
3.4.3 Bloco de Classificação e Camada de Saída	31
3.4.4 Resumo da Arquitetura.....	32
3.5 Configuração do Treinamento e Avaliação.....	33
3.5.1 Função de Custo e Otimizador	33
3.5.2 Processo de Treinamento e Hiperparâmetros	33
3.5.3 Mecanismos de Controle e Regularização.....	34
3.5.4 Métricas de Avaliação de Desempenho.....	34
4 DESCRIÇÃO DOS RESULTADOS.....	36
4.1 Análise do Processo de Treinamento e Convergência do Modelo.....	36
4.2 Avaliação Quantitativa do Desempenho em Função do SNR.....	38
4.2.1 Resultados Globais por SNR	38
4.2.2 Acurácia Global por SNR.....	39
4.2.3 Desempenho das Modulações por SNR	40
4.3 Análise Qualitativa dos Padrões de Classificação	41
4.4 Síntese dos Resultados.....	42
5 DISCUSSÃO	44
5.1 Interpretação da Influência do SNR.....	44
5.2 Comparação com os Resultados da Literatura.....	45
5.3 Limitações do Estudo	46
6 CONCLUSÃO.....	47

1 INTRODUÇÃO

No mundo atual, a Classificação Automática de Modulações¹ (AMC) é uma tarefa essencial que deve ser realizada quando o receptor não dispõe previamente das configurações dos sinais recebidos (Harper *et al.*, 2023). Essa classificação trata-se de um processo que tem por objetivo identificar, de forma automática, a configuração de modulação empregada na transmissão do sinal, e a partir dessa identificação, é possível o sistema receptor configurar seus processos internos, permitindo a correta demodulação e posterior extração da informação transmitida (Abd-Elaziz *et al.*, 2023).

Com a crescente demanda por espectro de frequência, a busca por formas mais eficientes de alocação no espectro se tornou uma necessidade, impulsionando o desenvolvimento de tecnologias flexíveis, como o Rádio Definido por Software (SDR) e a Inteligência Artificial (IA) (Valadão *et al.*, 2020).

No contexto de ambientes ruidosos, o AMC, se aplicado de forma eficiente, pode garantir a utilização do espectro e permitir a correta previsão do esquema de modulação (Harper *et al.*, 2023). Dessa forma, o estudo aplicado a Classificação Automática de Sinais tem ganhado notável espaço nos campos de pesquisa, principalmente quando realizado com aprendizado de máquina e sistemas de comunicação (Pina *et al.*, 2020).

1.1 Apresentação do Problema

O problema central abordado por este trabalho refere-se à aplicação do AMC em distinguir os diferentes tipos de modulação, observando os padrões únicos e técnicas específicas de detecção e classificação de sinais, por meio do uso de IA aplicada a arquitetura de Redes Neurais Convolucionais ou *Convolutional Neural Network* (CNN).

1.2 Justificativa e Relevância

A relevância da Classificação Automática de Modulação reside na sua capacidade de viabilizar a comunicação e a inteligência de sinais em cenários não cooperativos, nos quais um receptor deve processar uma transmissão sem conhecimento prévio de seus parâmetros. A sua importância em aplicações de comunicações e segurança, como a inteligência eletrônica (ELINT), é documentada na literatura:

¹ Classificação Automática de Modulações, ou do inglês *Automatic Modulation Classification*, é um procedimento inicial fundamental para demodular o sinal para receptores, especialmente para a análise de sinais de radiofrequência e em Rádios Definidos por Software.

[As técnicas de AMC] são úteis em várias aplicações civis e militares, incluindo monitoramento de espectro, Radares Biestáticos Passivos, Suporte Eletrônico (ES), Inteligência Eletrônica (ELINT) e Receptores de Alerta Radar (RWRs). Por exemplo, em sistemas ELINT/ES, o reconhecimento prévio da modulação facilita a desentrelaçamento de trens de pulso originados de diferentes emissores e o reconhecimento do tipo específico de radar entre os inúmeros tipos existentes (Milczarek *et al.*, 2023, p. 1, tradução nossa).

Este processo, portanto, pode ser considerado um pilar para a consciência situacional no espectro eletromagnético.

Tradicionalmente, este problema é abordado por métodos baseados em verossimilhança (*Likelihood-Based*) e em extração de características (*Feature-Based*). Conforme apontado na literatura, existe um compromisso fundamental entre essas abordagens: enquanto os métodos de verossimilhança são capazes de "entregar resultados muito precisos, sob o custo de serem utilizados cálculos complexos" (Milléo *et al.*, 2019, p. 1), a análise por características permite obter "resultados próximos [...] com a vantagem de que a complexidade computacional envolvida para a sua execução seja menor" (Milléo *et al.*, 2019, p. 1). Contudo, a robustez de ambas as técnicas é desafiada em ambientes com forte influência de ruído.

Diante desses desafios, as Redes Neurais Convolucionais surgem como uma alternativa promissora, representando a abordagem moderna para o problema. Conforme apontado:

[...] a tendência predominante no desenvolvimento da AMC é utilizar as mais recentes técnicas de aprendizado profundo, ou seja, usar a imagem relacionada à representação tempo-frequência (TFR) do sinal como uma característica que alimenta um classificador de rede neural convolucional (CNN)" (Milczarek *et al.*, 2023, p. 1, tradução nossa).

No entanto, o sucesso dessa abordagem não é trivial, pois conforme relatado por Pina *et al.* (2020), as CNNs são sensíveis à escolha de hiperparâmetros, exigindo uma densa análise e adaptação para que os resultados alcancem patamares satisfatórios. Dessa forma, o trabalho busca a necessidade de realizar uma validação da arquitetura de CNN para a tarefa de AMC.

Utilizando um *dataset* sintético, a pesquisa foca na análise crítica do desempenho do modelo em um ambiente simulado e sob diferentes condições de sinal-ruído. A contribuição não reside na criação de uma arquitetura inédita, mas em aprofundar o entendimento de uma abordagem moderna, fornecendo uma base para futuras aplicações práticas e contextualizando seus resultados com a literatura da área.

1.3 Pergunta de Pesquisa e Hipótese

Considerando a crescente necessidade de sistemas robustos e a evolução das técnicas de inteligência artificial, o trabalho é guiado pela seguinte pergunta:

Qual é o desempenho das CNN na classificação automática de modulações em ambientes não cooperativos, quando submetidos a diferentes níveis de ruído?

A escolha por investigar esta questão se baseia no fato de que o aprendizado profundo de máquina, especificamente as Redes Neurais Convolucionais, surgem como uma alternativa moderna, capaz de trabalhar diretamente com dados brutos do sinal.

1.4 Objetivos

Para responder à pergunta de pesquisa formulada e guiar o desenvolvimento deste trabalho, foram definidos um objetivo geral, que estabelece o propósito central da investigação, e um conjunto de objetivos específicos, que detalham as etapas a serem cumpridas. Juntos, eles norteiam o caminho metodológico a ser percorrido, desde a fundamentação teórica até a análise dos resultados.

1.4.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver, implementar e avaliar um sistema para a classificação automática de modulações digitais utilizando CNNs, com ênfase na análise de seu desempenho em cenários simulados que mimetizam condições operacionais realistas, sujeitos a diferentes níveis de ruído e interferência.

Para alcançar este objetivo, será utilizado um banco de dados sintético (RadioML2016.10a) que será explorado no item 3.1, que permite a exploração e visualização dos dados, o pré-processamento para adequação à entrada da CNN e a validação do modelo em um ambiente controlado. Embora essa abordagem garanta a reprodutibilidade e o controle sobre as variáveis, como a Relação Sinal-Ruído (SNR), os resultados, por se tratar de um ambiente simulado, irão apresentar uma limitação inerente a este estudo, devendo ser interpretados como uma aproximação do desempenho para cenários reais, que podem introduzir degradações não modeladas.

Para a análise do trabalho, é destacado que a CNN proposta é simplificada, logo não é objetivo atingir o estado da arte, e sim o estudo e a aplicabilidade desta tecnologia moderna.

1.4.2 Objetivos Específicos

Para alcançar o objetivo geral proposto, e considerando o escopo do trabalho, foram definidos os seguintes objetivos específicos:

- **Fundamentação do Estudo:** Realizar uma revisão bibliográfica para construir uma base teórica sobre os fundamentos de modulações digitais, a arquitetura de Rádios Definidos por Software e os princípios de funcionamento das Redes Neurais e Redes Neurais Convolucionais.
- **Implementação de um Classificador:** Implementar uma arquitetura de CNN simplificada para a tarefa de AMC, baseada em modelos de referência da literatura, utilizando como entrada os dados brutos do banco de dados.
- **Treino e Teste do Modelo:** Utilizar o conjunto de dados sintético RadioML2016.10a para realizar as etapas de treinamento, validação e teste do modelo de CNN implementado.
- **Análise do Desempenho:** Avaliar a performance do classificador por meio de métricas quantitativas, analisando sua variação em função da Relação Sinal-Ruído (SNR) disponível no *dataset*.
- **Contextualização dos Resultados:** Comparar o desempenho do modelo implementado com os resultados reportados na literatura para o mesmo conjunto de dados, a fim de posicionar e discutir as conclusões do presente estudo no contexto da área, destacando suas potencialidades e limitações.

1.5 Organização do Trabalho

Este trabalho está estruturado em seis capítulos, de forma crescente da fundamentação teórica até a análise final dos resultados obtidos.

O **Capítulo 2** apresenta o referencial teórico, abordando os conceitos essenciais sobre modulação de sinais, SDR e os princípios de funcionamento das Redes Neurais Convolucionais. Além disso, revisa alguns trabalhos relacionados que contextualizam a pesquisa.

No **Capítulo 3** será detalhada a metodologia empregada, descrevendo o conjunto de dados RadioML2016.10a, as etapas de pré-processamento dos dados, a arquitetura da CNN que será implementada, a configuração do ambiente de treinamento e os critérios de avaliação de desempenho.

O **Capítulo 4** é dedicado à apresentação e descrição dos resultados experimentais. Nele, serão exibidas as métricas de desempenho do modelo em níveis de Relação Sinal-Ruído, bem como as matrizes que ilustram a performance do classificador.

No **Capítulo 5** é realizada a discussão dos resultados. O desempenho do modelo é comparado com os modelos da literatura, interpretando os achados e abordando as limitações do estudo.

Por fim, o **Capítulo 6** apresenta a conclusão do trabalho, resumindo as principais contribuições, respondendo diretamente à pergunta de pesquisa e aos objetivos propostos, e sugerindo direções para trabalhos futuros.

2 REFERENCIAL TEÓRICO

Este capítulo estabelece conceitos teóricos que são o alicerce para o trabalho. Primeiramente serão apresentados os conceitos iniciais de Sinais e Modulação para situar a AMC no contexto de comunicações. Em seguida, será introduzido o conceito do Rádio Definido por Software como uma ferramenta flexível para aquisição e processamento dos dados, e será revisado de forma breve os métodos de classificação *Likelihood-Based*, *Feature-Based*. Finalmente, será abordado o ponto central do estudo, com a apresentação de Inteligência Artificial e *Deep Learning*, Redes Neurais e Redes Neurais Convolucionais, fechando assim a proposta do porquê tais ferramentas se mostram adequadas à AMC em cenários não cooperativos e com baixa SNR, fato esse que constitui o núcleo desta pesquisa.

2.1 Sinais e Modulação: Os Pilares da Comunicação

A transmissão de informação é a tarefa central de qualquer sistema de comunicação. Conforme definido na literatura, o desafio fundamental da área pode ser assim resumido:

O problema básico em um sistema de comunicação se resume em transmitir a informação através de um meio de transmissão (possivelmente ruidoso), de modo a proporcionar no receptor, a recuperação do sinal com fidelidade ou confiabilidade aceitável (Oliveira, 2012, p. 20).

Assim, para superar esse desafio, é necessário manipular ondas eletromagnéticas por meio da criação de um sinal portador e da sua alteração, para que esta possa carregar os dados de interesse.

2.1.1 Conceitos Básicos

Em telecomunicações, um sinal é uma grandeza que se propaga através de ondas e que pode transportar informações. A sua análise e classificação pode ser feita através de seus atributos ou características que o distinguem (Oliveira, 2012). A análise dos atributos de um sinal “[...] pode levar em conta diferentes medidas estatísticas, como a amplitude instantânea, fase, frequência, densidade espectral de potência” (Milléo *et al.*, 2019, p.1), e essas quando combinadas com algoritmos de classificação, buscam entender o comportamento e o desempenho em diferentes condições de SNR (*Signal-to-noise Ratio*).

2.2 Rádio Definido por Software

O Rádio Definido por Software representa um avanço significativo nas aplicações de estudo dos sinais e uma quebra de paradigma. Enquanto os rádios convencionais são construídos com componentes dedicados de hardware, projetados para operar em determinadas frequências e modulações específicas, onde qualquer alteração exige uma mudança física no circuito, o SDR transfere tarefas como modulação, demodulação, filtragem e detecção para o domínio do software. Isso garante flexibilidade e atualização rápida, aspectos cada vez mais valorizados em contextos de defesa e comunicações.

Um exemplo de programa que demonstra a relevância e interesse no SDR, é o Programa europeu ESSOR, que elaborou a especificação de uma arquitetura para SDR, a qual foi submetida a processos de portabilidade e qualificação em um conjunto de plataformas distintas, facilitando a interoperabilidade entre forças armadas europeias (Thales Group, 2021). Esse fato reforça a importância estratégica do conceito de SDR, destacando sua capacidade de oferecer flexibilidade e adaptabilidade indispensáveis para os avanços tecnológicos.

Do ponto de vista acadêmico, o SDR viabiliza os estudos para diversas aplicações. Hu *et al.* (2021) descreve a utilização da plataforma Pluto SDR em testes práticos, ressaltando que a sua devida aplicação permite utilizar classificadores de AMC, combinados com redes de aprendizado profundo, em diferentes condições de SNR. Essa característica o torna não apenas uma ferramenta de pesquisa, mas também um meio de transição entre teoria e prática.

2.3 Métodos de Classificação de Modulação

As abordagens para a Classificação Automática de Modulação podem ser divididas em duas categorias principais, métodos baseados em *Likelihood-Based* e métodos baseados em *Feature-Based* (Abd-Elaziz *et al.*, 2023; Milléo *et al.*, 2019).

Nos métodos LB, a decisão é tomada com base em modelos estatísticos que calculam a probabilidade de um conjunto de amostras corresponder a uma hipótese de modulação. Essa abordagem é considerada teoricamente ótima, mas seu uso prático é limitado devido à alta complexidade computacional, especialmente em cenários onde não se conhece os parâmetros do sinal, conforme apontam as revisões recentes (Abd-Elaziz *et al.*, 2023).

Os métodos *Feature-Based* (FB), fundamentam-se na extração de atributos do sinal, que podem incluir características estatísticas e espectrais, tanto no domínio do tempo quanto na frequência. O processo começa com a extração das características que

irão influenciar diretamente o desempenho do classificador. As características mais usadas nessa etapa são “características instantâneas, cumulantes de ordem superior (HOCs), características cicloestacionárias e características *wavelet* (Abd-Elaziz *et al.*, 2023, p.2, tradução nossa)”. Em seguida, na etapa de classificação, são usados classificadores clássicos, como a árvore de decisão (*decision tree* - DT) e o *Knearest neighbor* (KNN). Entretanto o desempenho desse método é afetado pelo modo de extração manual das características, limitando significativamente o desempenho em um sistema de comunicação sem fio complexo (Abd-Elaziz *et al.*, 2023).

Dessa forma, dados esses desafios complexos, as técnicas de aprendizado de máquina, combinado com o uso de algoritmos de Redes Neurais tem ganhado destaque, surgindo como uma poderosa alternativa de automação para extração das características e posterior classificação.

2.4 Inteligência Artificial e Redes Neurais

No âmbito da Ciência e para a evolução dos conceitos utilizados no trabalho, é fundamental estabelecer uma distinção entre as definições abrangentes de IA e ANN (Redes Neurais Artificiais), que embora apresentem conceitos interligados, possuem escopos e especificidades distintas.

2.4.1 Conceitos Básicos

O termo IA constitui uma concepção ampla que se dedica ao desenvolvimento de máquinas capazes de simular habilidades cognitivas humanas, como aprendizado, generalização e abstração. Conforme apresentado por Benecase (2023), a IA pode ser considerada a convergência entre as ideias de *Big Data*, Processamento Paralelo e Modelos de Aprendizado de Máquina.

Dentro desse vasto campo, o Aprendizado de Máquina (*Machine Learning – ML*) é uma subárea da IA dedicada a fazer com que sistemas aprendam a partir de dados e construam modelos matemáticos. Sem serem programados explicitamente para cada tarefa específica, esses sistemas passam a resolver problemas de classificação e de regressão. (Benecase, 2023). De acordo com Data Science Academy (2022), existem diversos algoritmos que permitem a aplicação do conceito de ML, porém um que tem ganhado notório destaque no cenário moderno são as Redes Neurais Artificiais.


2.4.2 Redes Neurais Artificiais

As Redes Neurais Artificiais representam modelos matemáticos inspirados na complexa arquitetura e funcionamento dos neurônios biológicos e do cérebro humano. A sua ideia de projeto é baseada na capacidade cerebral de aprender por experiência, conforme é abordado na literatura:

O desenvolvimento do cérebro humano ocorre principalmente nos dois primeiros anos de vida, mas se arrasta por toda a vida. Inspirando-se neste modelo, diversos pesquisadores tentaram simular o funcionamento do cérebro, principalmente o processo de aprendizagem por experiência, a fim de criar sistemas inteligentes capazes de realizar tarefas como classificação, reconhecimento de padrões, processamento de imagens, entre outras atividades. (Data Science Academy, 2022, p.2)

Assim como os neurônios do cérebro, os “neurônios matemáticos” foram pensados para “adaptar-se a novas situações e adquirir conhecimento com experiências passadas” (Benecase, 2023, p.27). Assim, o projeto desse componente tem como objetivo, receber diversos dados através de sinais de entrada, atribuir neles diferentes pesos (sinapses), aplicar uma soma de acordo com os pesos distribuídos (soma ponderada), aplicar uma função (função de ativação) no resultado dessa soma, e transmitir na saída um resultado que será levado adiante.

Figura 1 - Representação simplificada de um neurônio matemático.



Fonte: Data Science Academy (2022, p. 4, tradução nossa).

A Figura 1 é a representação de um neurônio matemático, na qual o corpo celular pode ser descrito em duas etapas principais. Na primeira, ocorre a soma ponderada, em que cada sinal de entrada é multiplicado por um peso (sinapse) e, em seguida, todos esses valores são somados. Depois, essa soma passa por uma função, que define a saída (resultado) do neurônio.

Assim como no cérebro humano, os estímulos podem ser excitatórios (pesos positivos) ou inibitórios (pesos negativos). Além disso, o modelo inclui uma polarização (*bias*), que permite gerar uma saída mesmo quando todas as entradas são iguais a zero, aumentando a flexibilidade do neurônio.


Adicionalmente, a ativação ou não do neurônio fica a cargo da função de ativação, que recebe como base um limiar de excitação (*threshold*), como nível que deve ser atingido. Assim, quando o resultado das somas ponderadas for maior que o *threshold* definido, a função de ativação é acionada e o resultado sai do neurônio (Benecase, 2023).

Dessa forma, os neurônios matemáticos podem receber um ou mais sinais de entrada, que por sua vez apresentam apenas uma saída, que podem ser uma nova entrada de um ou vários neurônios de uma camada posterior, e assim por diante, formando assim a Rede Neural Artificial (Data Science Academy, 2022).

2.4.3 Redes Neurais Profundas

Como uma abordagem mais avançada, as Redes Neurais baseadas no Aprendizado Profundo (*Deep Learning* ou DL) emergem como um aperfeiçoamento do ML, caracterizada por modelos computacionais mais complexos que empregam múltiplas camadas de processamento, capazes de extrair características hierarquizadas e de forma automática, demandando grandes volumes de dados para replicar a capacidade de processamento do cérebro humano (Alves, 2024).

Figura 2 - Comparação Rede Neural Simples e Rede Neural Profunda.



Fonte: Data Science Academy (2022, p. 3, tradução nossa).

Na Figura 2 é apresentada a diferença entre as Redes Neurais Simples e as Redes Neurais Profundas. A ilustração resume onde a informação passa por cada camada, sendo a saída da camada anterior virando a entrada da próxima camada. Os círculos vermelhos são as camadas de entrada, os círculos amarelos as camadas ocultas e os azuis as de saída. Cada camada é constituída por um algoritmo simples, contendo um tipo de função de ativação.

Esse avanço foi impulsionado pelo desenvolvimento de algoritmos como o *backpropagation*, técnica que treina redes neurais ajustando seus pesos ao propagar o gradiente do erro da camada de saída para a de entrada (Data Science Academy, 2022). Junto a isso, somam-se o aumento do poder de processamento e ao aumento exponencial


da quantidade de informações disponíveis, conhecido como *Big Data*, que fornecem a base para treinar modelos cada vez mais sofisticados (Data Science Academy, 2022). Nesse contexto, o *deep learning* ganhou destaque no cenário moderno. Hoje, ele é uma das principais forças por trás dos avanços recentes em diferentes campos tecnológicos, incluindo visão computacional, reconhecimento de fala, processamento de linguagem natural e análise de áudio.

Dentre as diversas arquiteturas de aprendizado profundo, as CNNs se destacam como uma classe especializada de Redes Neurais Artificiais, particularmente eficaz para a interpretação de dados com estrutura espacial, como imagens e sinais de radiofrequência (RF) (Hu *et al.*, 2021), fato esse que será detalhado no próximo item.

2.4.4 Redes Neurais Convolucionais

As Redes Neurais Convolucionais são uma classe de redes neurais cuja arquitetura é inspirada no funcionamento do córtex visual (Alves, 2024, p. 113). As CNNs têm sua estrutura, assim como outras redes neurais, composta por uma camada de entrada, camadas de saída e as camadas ocultas. Como diferencial, as camadas ocultas são compostas por sequência de camadas convolucionais, que são as mais significativas da CNN possuindo diversos filtros (*kernels*), e sequencias de camadas de *pooling* (Abd-Elaziz *et al.*, 2023), conforme exemplificação simplificada apresentada na Figura 3.

Figura 3 - Exemplo simplificado de uma CNN.



Fonte: Souza (2023, p. 12).

A Figura 3 ilustra as fases de uma CNN: a entrada que é processada por camadas de convolução, nas quais filtros aprendem padrões locais e geram mapas de características. Em seguida, as camadas de *pooling* que reduzem a dimensão espacial e tornam as características mais robustas a pequenas variações (Cunha, 2020). A repetição de camadas convolucionais seguidas de camadas de *pooling*, o que aprofunda a extração de traços de maior nível. Por fim, os resultados são vetorizados e enviados às camadas totalmente conectadas, que combinam as características e produzem a classificação.

Embora tenham se consolidado posto que sua arquitetura é bem adaptada na classificação e reconhecimento de imagens (Data Science Academy, 2022), sua aplicação

tem sido estendida com significativa relevância para o processamento de sinais de radiofrequência (RF) (O'Shea; Corgan; Clancy, 2016).

A principal vantagem que impulsionou a adoção de CNNs para a tarefa de AMC é sua capacidade de realizar a extração de características de forma automática. Essa abordagem não apenas simplifica o processamento, mas também permite que a rede descubra padrões sutis que poderiam não ser evidentes para um humano, tornando o classificador mais adaptável.

Atualmente, o uso de CNNs para classificação de sinais de RF segue diversas tendências. Uma abordagem comum é a transformação do sinal de RF em uma representação bidimensional, como um diagrama de constelação, que será abordado no item 3.2, ou ainda um espectrograma ou uma imagem de distribuição tempo-frequência, para que a CNN possa processá-lo de maneira análoga a uma imagem convencional (Khalid; Karim; Rahnavard, 2022).

Por fim, a pesquisa nessa área tem evoluído de arquiteturas iniciais mais simples para modelos mais profundos e complexos, como as *Residual Networks* (ResNets), que buscam melhorar a performance através do aumento da profundidade da rede (West; O'Shea, 2017).

2.4.4.1 Operação de Convolução


Entendido como elemento essencial de uma CNN, a camada convolucional é primordial para a extração de características dos dados de entrada. Diferentemente de uma rede neural profunda comum, onde todas as camadas estão densamente conectadas e cada neurônio se interliga a todos os neurônios da camada anterior, os neurônios de uma camada convolucional, que realizam operações de convolução, demonstram uma conectividade localizada.

A operação de convolução é um método para extrair informações. Conforme Souza (2023) “A convolução pode ser interpretada como uma função que atribui pesos distintos para cada uma das regiões da entrada”. Como uma analogia, essa operação funciona como uma lupa em uma imagem, passando por todas as regiões do sinal de entrada. Em cada posição são atribuídos diferentes níveis de importância (pesos) às partes do sinal. Dessa forma, ao combinar os pesos com os valores do sinal de entrada e utilizando diferentes filtros (*kernels*), cria-se um valor, que ao serem juntos formam o que chamamos de mapa de caracteres (*feature maps*) (Souza, 2023).

2.4.4.2 Camada Convolutacional

As camadas convolucionais são blocos constituintes da Rede Neural que funcionam aplicando várias operações de convolução sobre sua entrada, conforme ilustrado pela Figura 3.

Figura 4 - Exemplo de Camada de Convolução.




Fonte: Souza (2023, p. 11).

A Figura 4 representa uma entrada dividida em pesos e em cada divisão são aplicados filtros. Essa operação tem como produto um resultado, que ao serem combinados formam a saída (mapa de características).

O funcionamento dessas camadas permite a identificação de padrões específicos. Na primeira camada convolutacional, os neurônios se conectam diretamente aos pixels da imagem de entrada correspondentes aos seus campos receptivos. De forma análoga, a segunda camada convolutacional não acessa a imagem original, mas apenas os pixels resultantes da primeira camada que estejam dentro de sua própria janela receptiva (Alves, 2024), conforme demonstrado na Figura 5.

Figura 5 - Representação camada de convolução.




Fonte: Géron, 2022 *apud* Alves (2024, p. 116).

Nessa etapa, os *kernels* com pesos aprendíveis percorrem os dados de entrada, deslocando-se posição a posição (*stride*) para identificar padrões locais. Cada filtro se especializa na detecção de uma característica específica (Alves, 2024). Ao empilhar múltiplas camadas convolucionais, a rede é capaz de combinar padrões simples detectados inicialmente em estruturas mais complexas (O'Shea; Corgan; Clancy, 2016).

2.4.4.3 Camadas de *Pooling*

A camada de *pooling*, ou também denominada camada de agrupamento, é um componente utilizado em arquiteturas CNN, inserido após as camadas convolucionais. Sua principal função é simplificar as informações contidas na saída da camada convolucional, resultando na síntese ao agrupar um conjunto de componentes vizinhos em um único componente, acarretando diminuição da dimensão espacial da representação da imagem (Souza, 2023). Este processo, também conhecido como *downsampling*, visa reduzir drasticamente o número de parâmetros da rede, o que reduz os custos computacionais, minimiza o uso de memória e, conseqüentemente, atenua o risco de sobreajuste (*overfitting*) (Cunha, 2020).

Dentre os modelos usuais de *pooling*, é possível destacar o *max pooling* e o *average pooling*. O *max pooling* retorna o maior valor dentro da janela, enfatizando ativações mais intensas e atenuando variações locais de menor magnitude. Já o *average pooling* retorna a média dos valores na janela, produzindo uma suavização controlada (Souza, 2023). Na Figura 6 é ilustrada uma operação de *max pooling*.



Fonte: Adaptado de Souza (2023, p. 11).

Na Figura 6 apresentada, a matriz de entrada possui dimensão 5x5. Essa matriz é percorrida por janelas de 2x2, e em cada uma dessas janelas o valor máximo é identificado e retornado como saída. Assim, por exemplo, na primeira região superior esquerda, o maior valor encontrado é 7; na região superior direita, o valor máximo é 5; na inferior esquerda, o valor máximo é 8; e na inferior direita, o valor máximo é 2. O resultado desse

processo é uma nova matriz reduzida, com dimensão 2x2, que mantém apenas os valores mais representativos de cada região da entrada.


Assim, essa configuração faz as com que camadas convolucionais subsequentes tenham um campo receptivo maior em relação à entrada original, possibilitando a detecção de padrões em escalas mais amplas.

2.4.4.4 Funções de *Padding*

A camada de *Padding* (preenchimento com zeros) é uma técnica empregada em arquiteturas de CNN para gerenciar as dimensões espaciais dos mapas de características ao longo da rede.

Esse processo é fundamental por duas razões principais. Primeiro, ele permite um controle preciso sobre as dimensões do mapa de características resultante da operação de convolução (Cunha, 2020). Sem o *padding*, cada camada convolucional reduziria progressivamente a altura e a largura da representação, o que poderia limitar a profundidade da rede. Em segundo, o *padding* garante que os filtros (*kernels*) possam ser aplicados integralmente aos elementos das bordas do sinal de entrada, evitando a perda de informações que, embora localizadas nas extremidades, podem ser relevantes para a classificação (Alves, 2024).

Figura 7 - Exemplo de operação de zero *padding*.



Fonte: Cunha (2023, p. 20).

A Figura 7 ilustra o mecanismo de *Zero Padding* seguido de uma operação de convolução. Nela, a camada de entrada é circundada por uma borda de zeros, construindo uma moldura de zeros, em seguida é realizada a operação de convolução que consegue calcular valores para todos os pixels, inclusive os de canto. Assim essa técnica não

acrescenta informação nova, ele só evita que a imagem encolha e perca características a cada camada.

Em conjunto, essas camadas não alteram a informação contida no sinal, mas realizam uma transformação estrutural necessária, preparando os dados brutos para serem processados eficientemente pelo bloco de extração de características da rede.

2.4.4.5 Camada de Vetorização

A camada de vetorização (*Flatten*) é um componente essencial na arquitetura da maioria das Redes Neurais Convolucionais, atuando como a ponte entre a etapa de extração de características e a etapa de classificação.

As camadas convolucionais e de *pooling* operam com respostas multidimensionais que preservam a estrutura espacial ou temporal dos dados. Em contrapartida, o bloco classificador, tipicamente composto por camadas densas (*Dense*), requer como entrada um vetor unidimensional, onde cada elemento representa uma característica aprendida (Cunha, 2020).

A função da camada *Flatten* é, portanto, realizar essa conversão dimensional. A operação consiste “em colocar os valores de cada linha da matriz lado a lado, formando um vetor” (Benecase, 2023, p. 38), reorganizando seus elementos em uma única linha contínua, sem alterar os valores numéricos, apenas sua estrutura. Este processo serve para que as características extraídas pelas camadas convolucionais possam ser processadas para a tarefa de classificação final (Cunha, 2020).

2.4.4.6 Aplicação em Sinais de RF

A aplicação de Redes Neurais Profundas na classificação de sinais RF representa uma tendência em relação às abordagens tradicionais. A principal justificativa para o uso de CNNs reside em sua “enorme capacidade de aprendizagem de características” (Abd-Elaziz *et al.*, 2023, p. 3, tradução nossa) diretamente dos dados do sinal, com a ressalva de adaptações na arquitetura para o uso dos sinais brutos, contornando a necessidade de uma etapa de extração manual (Abd-Elaziz *et al.*, 2023). Os mecanismos de convolução e *pooling*, descritos nos itens 2.4.4.2 e 2.4.4.3, são precisamente o que permitem essa extração automática de forma eficiente.

Entretanto a aplicação das CNN para a AMC depende fundamentalmente da transformação do sinal de entrada. A arquitetura da CNN proposta neste trabalho será explorada tratando a representação do sinal de RF como uma estrutura bidimensional que preserva informações essenciais de fase (I) e amplitude (Q).

Para a entrada na CNN, há vários métodos de aprendizagem de características e visualização, mas vamos utilizar o método que trata o sinal como uma janela de N amostras temporais consecutivas estruturadas como uma matriz de valores reais com dimensão $2 \times N$. Nessa matriz, a primeira linha contém as N amostras da componente I e a segunda linha contém as N amostras da componente Q. Essa representação é análoga a uma rede convolucional 2D estreita, formato ideal para a operação dos filtros convolucionais (O'Shea; Corgan; Clancy, 2016).

Assim, com o sinal no formato I/Q é possível formar o Diagrama de Constelação, onde os eixos horizontal e vertical representam, os componentes I e Q, respectivamente. Esses dados podem ser plotados em um gráfico de dispersão, permitindo a visualização de como a SNR impacta a clareza e a distinção dos padrões de cada modulação. Entretanto, mesmo o diagrama de constelação sendo uma ferramenta interessante para a visualização de modulações digitais, sua utilidade pode ser limitada em determinadas condições, onde não é possível verificar um padrão de inteligibilidade que varia conforme a intensidade SNR do sinal.

2.5 Trabalhos Relacionados

Inspiradas pelo sucesso em campos como Visão Computacional e Processamento de Linguagem Natural, as CNNs têm sido amplamente estudadas para o processamento de sinais de radiofrequência (Khalid; Karim; Rahnavard, 2022).

Estudos recentes indicam que os métodos tradicionais de reconhecimento de modulação, como *Likelihood-Based* e *Feature-Based*, não são robustos e tendem a falhar em cenários com baixa SNR (West; O'Shea, 2017; Ke; Vikalo, 2021). Como solução, os métodos baseados em *Deep Learning*, em especial as CNN, demonstram uma capacidade superior para a identificação de sinais de RF em ambientes não cooperativos, consolidando-se como uma alternativa moderna com relativo potencial (Harper *et al.*, 2023; Khalid; Karim; Rahnavard, 2022).

Dessa forma, com tais avanços e reconhecendo os desafios de implementação, este trabalho tem como proposta reproduzir e avaliar um classificador de modulação baseado em uma arquitetura simplificada de CNN, utilizando o banco de dados público RadioML2016-10a. Assim, a contribuição deste estudo reside na análise de uma abordagem consolidada, verificando seu desempenho em diferentes condições de SNR para a arquitetura da CNN proposta.

Um trabalho padrão nesta área é o de O'Shea, Corgan e Clancy (2016), que foi um dos primeiros a aplicar com sucesso uma arquitetura de CNN diretamente sobre os

dados brutos I/Q para a tarefa de AMC. Além de propor uma arquitetura de base, o estudo introduziu o *dataset* RadioML2016.10a, estabelecendo um patamar a ser seguido no que tange a comparação de novos modelos. O principal resultado desse trabalho foi que a CNN superou os métodos tradicionais, demonstrando a capacidade da rede de aprender características discriminativas de forma autônoma.

Dando continuidade a essa linha de pesquisa, West e O'Shea (2017) exploraram o impacto da profundidade e da complexidade da arquitetura, avaliando modelos mais avançados como as ResNets sobre o mesmo conjunto de dados. Seus resultados indicaram que, embora arquiteturas mais profundas pudessem oferecer melhorias de desempenho, havia um limite para os ganhos obtidos apenas com o aumento do número de camadas.

Estudos mais recentes continuam a evoluir sobre esse tema, propondo modelos que incorporam mecanismos modernos para refinar ainda mais a capacidade de classificação (Abd-Elaziz *et al.*, 2023; Harper *et al.*, 2023).

Dessa forma, com tais avanços e reconhecendo os desafios de implementação, o modelo proposto adota uma estrutura de módulos, composta por blocos sequenciais para extração de características, amostragem e classificação. A estrutura segue inspiração na estrutura apresentada por Souza (2023), onde são usados quatro blocos convolucionais, e na combinação de princípios consolidados: utilizando a abordagem de O'Shea, Corgan e Clancy (2016) para aplicar CNNs a dados de RF, adotando o princípio de profundidade através do empilhamento de blocos explorado por West e O'Shea (2017) e empregando blocos de convolução seguidos de camadas de *pooling* abordado por Alves (2024).

3 METODOLOGIA

Este capítulo apresenta o roteiro seguido para o desenvolvimento e avaliação do classificador proposto. A abordagem foi estruturada em etapas sequenciais, partindo da análise do conjunto de dados até a avaliação final do modelo, garantindo uma reprodução fidedigna do código desenvolvido e ideia base do trabalho, de forma a demonstrar a clareza do experimento.

Inicialmente, será descrito o conjunto de dados RadioML2016.10a, detalhando sua estrutura e conteúdo; em seguida, será apresentada a etapa de visualização dos sinais por meio de diagramas de constelação, fundamental para a compreensão dos desafios impostos pelas diferentes condições de SNR; subsequentemente, será detalhada a fase de preparação dos dados, que abrange o particionamento dos conjuntos de treino e teste e a codificação dos rótulos; e, por fim, serão descritas a arquitetura da CNN implementada e as métricas utilizadas para a configuração do treinamento e a avaliação de seu desempenho.

3.1 O Conjunto de Dados RadioML2016.10a

O RadioML2016.10a é um conjunto de dados sintético, sendo uma referência consolidada e publicamente disponível para a pesquisa em AMC. Este conjunto de dados foi gerado artificialmente por meio de SDR, com o objetivo de “emular degradações do mundo real, incluindo [...] desvios do oscilador local e desvanecimento seletivo em frequência” (IEEE Dataport, 2016, p. 1, tradução nossa).

A consolidação deste *dataset* como uma referência de estudo na área se deve à sua adoção pela comunidade científica desde sua introdução por O’Shea, Corgan e Clancy (2016). O *dataset* tem sido consistentemente utilizado como uma base para a avaliação e comparação de novas arquiteturas de aprendizado profundo. Trabalhos subsequentes ao mencionado, como o de West e O’Shea (2017), utilizaram-no para avaliar o desempenho de arquiteturas mais profundas, como as *Residual Networks* (ResNets). Outros estudos, como o de Rajendran *et al.* (2018), continuaram a empregá-lo para validar a eficácia de modelos de DL. Para este trabalho, o uso deste *dataset* não consistirá em implementar uma arquitetura inédita como os trabalhos citados, mas sim em demonstrar sua relevância e longevidade como uma ferramenta padrão para a pesquisa em AMC.

A estrutura do *dataset* é organizada em formato de dicionário, onde cada conjunto de amostras é associado a uma etiqueta única de identificação (chave-valor). Assim, cada chave corresponde a uma tupla que combina um tipo de modulação com um nível específico de Relação Sinal-Ruído (SNR). O conjunto ao todo possui 11 tipos de

modulação, sendo oito digitais (BPSK, QPSK, 8PSK, PAM4, QAM16 e QAM64, GFSK, CPFSK) e três analógicas (WBFM, AM-DSB e AM-SSB), sendo organizadas em valores de SNR que variam em etapas de 2 dB, em que dB é o nível em decibéis, cobrindo uma faixa de -20 dB a 18 dB, totalizando 220 combinações distintas.

Para cada uma dessas combinações, o *dataset* fornece 1.000 amostras de sinais, totalizando 220 mil exemplos. Cada amostra é representada por um vetor com dimensão de 2x128.

Tabela 1 - Resumo do Banco de dados RadioML2016.10a.

Modulação	Tipo	Combinações SNR	Faixa de SNR (dB)	Amostras por Combinação	Total de Amostras	Dimensão da Amostra
8PSK	Digital	20	-20 a 18	1.000	20.000	2x128
AM-DSB	Analógica	20	-20 a 18	1.000	20.000	2x128
AM-SSB	Analógica	20	-20 a 18	1.000	20.000	2x128
BPSK	Digital	20	-20 a 18	1.000	20.000	2x128
CPFSK	Digital	20	-20 a 18	1.000	20.000	2x128
GFSK	Digital	20	-20 a 18	1.000	20.000	2x128
PAM4	Digital	20	-20 a 18	1.000	20.000	2x128
QAM16	Digital	20	-20 a 18	1.000	20.000	2x128
QAM64	Digital	20	-20 a 18	1.000	20.000	2x128
QPSK	Digital	20	-20 a 18	1.000	20.000	2x128
WBFM	Analógica	20	-20 a 18	1.000	20.000	2x128
TOTAL	8 Digitais, 3 Analógicas	220	-20 a 18	11.000	220.000	2x128

Fonte: Elaborado pelo autor.

Na Tabela 1, cada exemplo de sinal consiste em 128 amostras complexas, favorecendo tanto a análise visual, como os diagramas de constelação por SNR que serão realizados na seção 3.2, quanto o treinamento de modelos de aprendizado profundo. Neste trabalho, será mantido o uso dos dados sem transformações espectrais adicionais, adotando apenas a codificação *one-hot* dos rótulos para fins de treinamento e avaliação.

Os sinais disponibilizados no *dataset* estão representados no domínio do tempo, em banda base complexa (I/Q). Por se tratar de um conjunto sintético gerado via SDR, o material não define uma taxa de amostragem absoluta em Hertz, mas utiliza uma relação normalizada baseada em uma taxa de símbolos, representando uma janela temporal suficiente para capturar as características essenciais de cada esquema de modulação.

Por fim, é fundamental ressaltar como os sinais de RF oriundos desse *dataset* serão analisados por uma arquitetura de CNN, tradicionalmente condicionada a processamento de imagens. A resposta reside em entender como a camada convolucional opera, visto

que não precisa necessariamente ser aplicada a uma imagem no sentido visual, e sim em uma estrutura espacial, como um sinal RF, que pode ser representado em sequências de tempo ou múltiplos canais (Peng *et al.*, 2018).

Logo, para a entrada na CNN, será adicionada uma dimensão nos dados, de forma que terão o formato (N, 2, 128, 1), onde:

- N: representa o número de amostras;
- 2: reconhecida pela CNN como uma dimensão espacial, sendo representada pelos dados I e Q;
- 128: reconhecida pela CNN como a outra dimensão espacial, representando os 128 pontos no tempo por cada canal; e
- 1: reconhecida como a dimensão de canal de entrada, representada por uma escala em cinza, onde tem-se apenas um valor para indicar a intensidade do sinal naquele ponto.

Dessa forma, os dados de sinais RF do *dataset* podem ser reconhecidos pela CNN como uma imagem com 2x128 pixels, onde cada pixel tem apenas 1 valor de intensidade do sinal naquele ponto do tempo em um canal específico. Essa abordagem, trabalhada por Peng *et al.* (2018), permite a entrada dos dados em modelos DL sem que ocorra a perda de informações, preservando a consistência original dos dados.

Portanto, embora não seja uma imagem visual, os dados de sinais RF possuem uma estrutura dimensional (2 canais x 128 pontos) que, com adaptações, as CNNs são capazes de processar eficientemente, tratando essas dimensões como se fossem espaciais para extrair características relevantes para a tarefa de AMC.

3.2 Visualização

A etapa de visualização é um componente essencial da análise de dados, pois permite compreender as características e os desafios inerentes ao conjunto de dados (Data Science Academy, 2022). Antes de proceder com o treinamento de qualquer modelo, é fundamental inspecionar a estrutura e o conteúdo dos dados para garantir sua consistência, confirmar sua estrutura e comportamento para guiar as decisões subsequentes.

Uma ferramenta poderosa e fundamental para a visualização de modulações digitais é o diagrama de constelação (Milléo *et al.*, 2019). Trata-se de uma representação gráfica do sinal no plano complexo, onde o eixo horizontal representa a componente em fase e o eixo vertical representa a componente em quadratura. Cada ponto plotado no diagrama, corresponde a uma combinação única de amplitude e fase que o sinal pode

assumir para transmitir um conjunto específico de bits. A coleção de todos os pontos de símbolo possíveis forma a chamada constelação da modulação (Oliveira, 2012).

A geometria formada por esses pontos revela diretamente as características essenciais da modulação. Por exemplo, o número de pontos na constelação indica a ordem da modulação (16 para QAM16), enquanto a sua disposição no plano define as amplitudes e fases utilizadas para codificar a informação (Oliveira, 2012). Dessa forma, o diagrama de constelação não é apenas um instrumento para a análise visual, mas uma representação fundamental para a compreensão e a demodulação de sinais em sistemas de comunicação.

No contexto deste trabalho, o diagrama de constelação foi utilizado para uma análise exploratória de dados com o objetivo de compreender a natureza do *dataset* e as dificuldades da tarefa de classificação. Ao plotar os diagramas para diferentes níveis de SNR, foi possível obter uma percepção visual de como o ruído afeta a estrutura de cada modulação, uma abordagem de visualização também empregada em estudos de referência na área (Peng *et al.*, 2018).


Esta pré-análise é fundamental para projetar o comportamento esperado da CNN, antecipando as classes que podem apresentar maior incompatibilidade para a classificação. A dificuldade em distinguir visualmente os padrões, especialmente em baixo SNR, se mostra diretamente como um grande desafio, visto que o modelo de DL precisará aprender a generalizar características que vão além da inspeção humana (Harper *et al.*, 2023).

3.2.1 Visualização inicial

Como etapa preliminar, foi realizada uma verificação da estrutura do *dataset*. Confirmou-se que cada uma das 220 chaves do dicionário continham um vetor no formato esperado de (1000, 2, 128). Esta validação garantiu que cada exemplo individual consistia em duas séries temporais de 128 pontos, correspondentes às componentes I e Q, assegurando a consistência dos dados antes da análise visual, conforme resumido na Tabela 1.

Em seguida, utilizando de forma semelhante ao método já trabalhado na literatura (Peng *et al.*, 2018) para a pré-análise visual, a ferramenta utilizada foi o diagrama de constelação. As figuras a seguir ilustram as constelações para diferentes níveis de SNR, evidenciando a complexidade da tarefa de classificação.

Figura 8 - Diagrama de Constelação para SNR= -20 dB.




Fonte: Elaborado pelo autor.

A Figura 8, resultante da plotagem das componentes I/Q no gráfico de dispersão na condição de SNR= -20, apresenta os gráficos de dispersão para as onze modulações presentes no banco de dados utilizado. Para essa determinada condição de SNR, visualmente não é humanamente possível nenhuma análise. O diagrama apresenta-se sem um padrão geométrico, visto que em condições de baixo SNR, a dispersão dos pontos, causada pelo ruído, é severa.


À medida que o SNR aumenta para 0 dB (Figura 9) e 10 dB (Figura 10), padrões definidos emergem para certas modulações, como a estrutura anelar do GFSK e a distribuição linear do AM-DSB.

Figura 9 - Diagrama de Constelação para SNR= 0 dB.



Fonte: Elaborado pelo autor.

Figura 10 - Diagrama de Constelação para SNR= 10 dB.




Fonte: Elaborado pelo autor.

A Figura 9 e 10 representam, respectivamente, os diagramas de constelação para as modulações com as condições de SNR= 0 dB e SNR= 10 dB.

Entretanto, analisando as demais plotagens, mesmo em condições favoráveis, algumas modulações, como a QAM64 e AM-SSB, continuam a apresentar uma dispersão considerável.

Figura 11 - Diagrama de Constelação para SNR= 18 dB.



Fonte: Elaborado pelo autor.

A Figura 11 representa o diagrama de constelação para as modulações com as mesmas condições de SNR= 18 dB. Essa figura, que apresenta a melhor condição de SNR (SNR=18 dB) disponível no banco de dados, tem, ainda assim, algumas modulações, como o AM-SSB e QAM16, sem um padrão perceptível.


3.2.2 Visualização escalonada

Analisando separadamente as modulações com a plotagem escalonada e crescente das condições de SNR, é possível verificar em determinadas modulações algumas tendências que revelam padrões geométricos claros e distintos, porém em outras ocorre uma dispersão sem uma inteligibilidade visual.

Um exemplo é a modulação AM-DSB (Figura 12), representada abaixo, em que a plotagem evolui de uma nuvem de pontos dispersa, em baixo SNR (-20 dB), para uma estrutura anelar nítida, em condições de alto SNR (18 dB), mostrando um agrupamento dos pontos e revelando uma tendência conforme ocorre a melhoria do SNR.


A modulação AM-DSB não possui componente em quadratura em sua definição teórica. Entretanto, no *dataset*, a representação em banda base complexa incorpora variações de fase que geram componentes imaginárias. Assim, o diagrama de constelação resultante apresenta uma distribuição circular e contínua no plano I/Q, em vez de uma linha fixa.

Figura 12 - Diagrama de Constelação para modulação AM-DSB.



Fonte: Elaborado pelo autor.

Figura 13 - Diagrama de Constelação para modulação QAM64.



Fonte: Elaborado pelo autor.

A Figura 12 e 13 representam respectivamente o diagrama de constelação para a modulação AM-DSB e QAM64, com as diferentes condições de SNR, avançando de forma ordenada e crescente de -20 dB até 18 dB.

Analisando as figuras, foi observado que as modulações de maior complexidade não apresentam a mesma inteligibilidade visual, mesmo em cenários com alta SNR. Esse é o caso da Figura 13, em que a modulação QAM64, mesmo com SNR de 18 dB, continua a se apresentar como uma nuvem de pontos densa e de difícil distinção, sem revelar uma estrutura regular esperada.

Portanto, a inconsistência na clareza dos padrões visuais evidencia a limitação de classificação baseada em características geométricas extraídas manualmente. Assim, o desafio não reside apenas em sinais com baixo SNR, mas também na complexidade inerente a certas modulações que não produzem constelações visualmente óbvias. Dessa forma é possível observar a dificuldade acentuada em interpretar corretamente determinadas modulações em um ambiente com muito ruído.

Logo, é evidente a necessidade de um classificador mais robusto e adaptativo, como uma CNN, que pode ser capaz de aprender características discriminativas diretamente dos dados brutos em I/Q, incluindo padrões estatísticos e temporais sutis que não são aparentes através da simples inspeção dos diagramas.

3.3 Preparação dos Dados

Para a classificação das modulações, é possível utilizar diferentes representações do sinal, como imagens espectrais. No entanto, a obtenção dessas imagens pode demandar informações adicionais do *dataset*, como a frequência central e a taxa de amostragem. Entretanto, com a linha de proposta deste trabalho, utilizando abordagens que priorizam o aprendizado de características diretamente dos dados brutos, optou-se por utilizar as amostras originais no domínio do tempo. Assim, a única transformação aplicada aos dados de entrada foi a codificação dos rótulos para um formato numérico adequado ao treinamento da CNN.

3.3.1 Consolidação e estruturação do *Dataset*

A primeira etapa da preparação consistiu em adaptar as amostras do *dataset* para o formato de entrada da CNN. Cada amostra do sinal foi estruturada como uma matriz de dimensão 2x128, onde essa representação trata a série temporal complexa como uma imagem estreita de dois canais, permitindo que a rede aprenda características discriminativas diretamente dos dados brutos. Juntamente com cada matriz de sinal, os

rótulos correspondentes de modulação e SNR foram preservados para as etapas subsequentes.

3.3.2 Particionamento em Conjuntos de Treino, Validação e Teste

Uma etapa crucial para o desenvolvimento de modelos de aprendizado de máquina é o particionamento do *dataset* em subconjuntos independentes. O objetivo nessa etapa é garantir que a avaliação de desempenho da CNN seja realizada em dados não vistos durante a fase de aprendizado, medindo assim sua capacidade de generalização (Benecase, 2023).

Para este trabalho, o conjunto total do *dataset* foi dividido em três subconjuntos distintos: treino, validação e teste. A divisão foi realizada seguindo uma proporção de 70% para o conjunto de treino, 15% para o de validação e 15% para o de teste.

Para garantir a integridade e a imparcialidade da avaliação, o particionamento foi realizado de forma estratificada. A aplicação da estratificação é uma técnica essencial, pois previne que o modelo seja treinado com uma representação desbalanceada das amostras, o que poderia levar a um desempenho irregular e a uma avaliação de pouco confiável (Harper *et al.*, 2023; Data Science Academy, 2022).

Assim, serão gerados conjuntos de treino, validação e teste, juntamente com os seus respectivos vetores de rótulos e valores de SNR. Essa aplicação visou deixar os dados devidamente preparados para as fases de treinamento do modelo e sua posterior avaliação de desempenho.

3.3.3 Codificação dos Rótulos de Saída

Os rótulos de modulação, originalmente no formato textual, foram codificados através da técnica *one-hot encoding* para torná-los compatíveis com a tarefa de classificação multiclasse, pois no problema do estudo existem múltiplas classes, visto que há 11 modulações distintas para classificar. Este procedimento converte cada rótulo em um vetor binário de comprimento igual ao número total de classes. No vetor resultante, a posição correspondente à classe da amostra é marcada com o valor 1 (um), enquanto todas as outras posições recebem o valor 0 (zero).

A Tabela 2 ilustra como cada uma das 11 modulações é representada por um vetor binário único.

Tabela 2 - Codificação one-hot dos dados de entrada.

Modulação	Vetor Binário (<i>one-hot</i>)
GFSK	[1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]
BPSK	[0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0]
CPFSK	[0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0]
QPSK	[0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0]
AM-SSB	[0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0]
8PSK	[0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0]
QAM16	[0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0]
PAM4	[0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0]
WBFM	[0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0]
AM-DSB	[0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0]
QAM64	[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1]

Fonte: Elaborado pelo autor.

Essa representação é fundamental para o treinamento da rede, pois o vetor *one-hot* serve como gabarito para a camada de saída do modelo, que utiliza a função de ativação *softmax*, apresentada na seção 3.4, para gerar uma distribuição de probabilidades sobre as classes.

Nenhuma outra transformação, como a extração de características ou a conversão para o domínio da frequência, foi realizada, mantendo a fidelidade aos dados temporais originais do sinal.

3.4 Arquitetura da Rede proposta

A arquitetura de aprendizado profundo implementada neste trabalho é uma Rede Neural Convolucional e o modelo proposto foi projetado para processar diretamente as amostras de 2x128 do sinal I/Q.

O modelo proposto adota uma estrutura de módulos, composta por blocos sequenciais para extração de características, amostragem e classificação. A estrutura segue inspiração na estrutura apresentada por Souza (2023), onde são usados quatro blocos convolucionais, e na combinação de princípios consolidados: utilizando a abordagem de O'Shea, Corgan e Clancy (2016), para aplicar CNNs a dados de RF, adotando o princípio de profundidade através do empilhamento de blocos, explorado por West e O'Shea (2017) e empregando blocos de convolução seguidos de camadas de *pooling* abordado por Alves (2024).

A construção da CNN segue uma sequência específica de camadas, que podem ser agrupadas nos seguintes blocos funcionais, detalhados nas seções subsequentes.

3.4.1 Camada de Entrada e Blocos Convolucionais

A primeira camada da arquitetura, podendo ser considerada também como uma etapa de pré-processamento, ajusta o formato da matriz de entrada 2x128 para torná-la compatível com as camadas convolucionais da biblioteca *Keras* (biblioteca de alto nível para construir e treinar redes neurais em Python). Essa é uma etapa de pré-processamento interno necessária para o correto funcionamento do *framework*, pois as camadas convolucionais do *Keras* funcionam por um formato de imagem, como coordenadas de altura, largura e canais de cor (Benecase, 2023).

Então, a primeira camada será uma camada de *Reshape*, e vai funcionar reformulando a matriz de entrada, adicionando uma dimensão na matriz (2, 128), deixando-a em um formato compatível de (2, 128, 1), como se fosse uma imagem em escala de cinza. Essa modificação é um requisito técnico para que as camadas convolucionais 2D possam operar corretamente sobre os dados, interpretando-os como uma imagem de altura 2, largura 128 e 1 canal.

Após a camada de entrada, o modelo emprega uma sequência de quatro blocos convolucionais bidimensionais, responsáveis pela extração hierárquica de características. A repetição de blocos permite que a rede aprenda uma hierarquia de padrões: as camadas iniciais tendem a identificar características de baixo nível, enquanto as camadas mais profundas combinam essas informações para reconhecer estruturas mais complexas e abstratas, essenciais para a distinção entre as modulações.

Cada um desses blocos é composto pela seguinte sequência de camadas:

1. Camada Convolucional (Conv2D): Esta é a camada principal para a extração de características. Sua operação é dividida em três partes fundamentais:
 - a. Filtros (*Kernels*): A camada utiliza 64 filtros de dimensão 3x3. Cada filtro funciona como um detector de padrões, aprendendo a identificar características locais e específicas do sinal, como gradientes de fase ou variações de amplitude;
 - b. Preenchimento (*Padding*): A opção `padding="same"` instrui a camada a adicionar zeros nas bordas do mapa de entrada antes de aplicar os filtros, atuando como a função *Zero padding*; e
 - c. Função de Ativação (ReLU): Após a operação de convolução, a função de ativação ReLU é aplicada a cada elemento do mapa de características. Ela introduz não-linearidade no modelo ao zerar todos os valores negativos e manter os positivos. Essa etapa é essencial para que a rede possa aprender

e modelar as relações complexas e não-lineares presentes nos dados das modulações (Abd-Elaziz *et al.*, 2023).

2. Camada de *MaxPooling*: Após a extração de características pela camada convolucional, uma operação de *max pooling* é aplicada para realizar o *downsampling*. A função desta camada é reduzir as dimensões espaciais do mapa de características, e ao mesmo tempo, torna a representação dos padrões aprendidos mais robusta a pequenas variações.
3. Camada de Regularização (*Dropout*): Inserida ao final de cada bloco, esta camada é uma técnica de regularização para combater o *overfitting*. Ela funciona durante o treinamento, desativando aleatoriamente uma fração dos neurônios, forçando a rede a aprender representações mais robustas e generalizáveis, pois impede que o modelo dependa excessivamente de um pequeno conjunto de neurônios para a tomada de decisão.

Em conjunto, essas camadas iniciais realizam uma transformação estrutural, preparando os dados brutos para serem processados eficientemente pelo bloco de extração de características da rede.

3.4.2 Camada de Vetorização

Após a etapa de extração de características, a camada *flatten* atua como a transição para o bloco classificador. Sua função é converter o mapa de características multidimensional, resultante do último bloco convolucional, em um vetor unidimensional, formato exigido pelas camadas densas.

Na arquitetura implementada, o tensor de dimensões (1, 8, 64) é transformado em um vetor de 512 elementos, que consolida todas as características aprendidas para serem processadas pela etapa de classificação.

3.4.3 Bloco de Classificação e Camada de Saída

Após a vetorização dos mapas de características, o sinal processado é direcionado ao bloco de classificação. Esta etapa final da arquitetura é composta por camadas totalmente conectadas (*Dense*), cuja função é interpretar as características extraídas na fase convolucional e realizar a classificação final (Cunha, 2020).

O bloco é constituído por duas camadas densas ocultas, cada uma com 128 neurônios. Essas camadas recebem o vetor de 512 elementos e aprendem a combinar de forma não-linear as características para mapeá-las em um espaço que seja mais facilmente separável.

Cada camada densa utiliza a função de ativação ReLU, que permite ao modelo aprender decisões complexas entre as diferentes classes de modulação. Para promover a generalização e evitar o *overfitting*, uma camada de *Dropout* é aplicada após cada camada densa.

E então dispõe-se a camada de saída, que consiste em uma camada *Dense* final com 11 neurônios, correspondendo diretamente às 11 classes de modulação do problema. Sobre esta camada é aplicada a função de ativação *softmax*, um componente padrão para tarefas de classificação multiclasse (Abd-Elaziz *et al.*, 2023).

A *softmax* converte os valores brutos de saída da rede em uma distribuição de probabilidade, onde a soma de todas as saídas é igual a 1. O resultado é um vetor onde cada elemento representa a confiança do modelo de que o sinal de entrada pertence à classe correspondente, sendo a predição final a classe com a maior probabilidade.

3.4.4 Resumo da Arquitetura

Para fornecer uma visão geral e técnica da rede completa, a Tabela 3 apresenta o resumo da arquitetura implementada. A Tabela detalha o tipo de cada camada, o formato de saída resultante de sua operação e as funções resumidas de cada camada.

Tabela 3 - Resumo da arquitetura da CNN.

Camada (Tipo)	Formato de Saída	Função
Entrada	(2, 128, 1)	Adiciona uma dimensão ao sinal de entrada I/Q.
Conv2D + ReLU	(2, 128, 64)	Extrai 64 mapas de características iniciais e aplica não-linearidade.
MaxPooling2D	(1, 64, 64)	Reduz a dimensão espacial (subamostragem) e o custo computacional.
Dropout	(1, 64, 64)	Aplica regularização (30%) para prevenir sobreajuste.
Conv2D + ReLU	(1, 64, 64)	Extrai 64 mapas de características de nível mais alto.
MaxPooling2D	(1, 32, 64)	Realiza a segunda subamostragem.
Dropout	(1, 32, 64)	Aplica regularização (30%).
Conv2D + ReLU	(1, 32, 64)	Extrai 64 mapas de características ainda mais complexos.
MaxPooling2D	(1, 16, 64)	Realiza a terceira subamostragem.
Dropout	(1, 16, 64)	Aplica regularização (30%).
Conv2D + ReLU	(1, 16, 64)	Extrai os 64 mapas de características finais.
MaxPooling2D	(1, 8, 64)	Realiza a última subamostragem.
Dropout	(1, 8, 64)	Aplica regularização (30%).

Flatten	(512)	Converte os mapas 2D em um vetor 1D para a classificação.
Dense + ReLU	(128)	Primeira camada de classificação para combinar as características.
Dropout	(128)	Aplica regularização (30%) no bloco classificador.
Dense + ReLU	(128)	Segunda camada de classificação para refinar a combinação de características.
Dropout	(128)	Aplica regularização (30%).
Dense (Saída)	(11)	Camada final com 11 neurônios, um para cada classe de modulação.
Softmax	(11)	Converte as saídas em uma distribuição de probabilidades.

Fonte: Elaborado pelo autor.

A arquitetura resultante é uma rede profunda composta numa estrutura modular, com a repetição de blocos convolucionais que permitem uma extração hierárquica e eficiente de características. Essa estrutura, foi projetada para ser suficientemente robusta para a tarefa de classificação, ao mesmo tempo em que mantém um custo computacional aceitável.

3.5 Configuração do Treinamento e Avaliação

Este processo consiste em ajustar os parâmetros da rede para que ela aprenda a mapear os dados de entrada para as saídas como classes de modulação. Esta seção detalha a configuração do ambiente de treinamento, os mecanismos de otimização e controle empregados e, também, os critérios utilizados para avaliar o desempenho.

3.5.1 Função de Custo e Otimizador

Para guiar o aprendizado da rede, foi utilizada a função de custo entropia cruzada categórica, que mede a diferença entre duas distribuições de probabilidade, por ser a métrica padrão para quantificar o erro em problemas de classificação com múltiplas classes (Diniz; Calazan, 2022). A minimização desse erro foi realizada pelo otimizador Adam, escolhido por sua eficiência computacional e capacidade de adaptar a taxa de aprendizado, mostrando-se uma alternativa eficiente para o treinamento de redes neurais profundas.

3.5.2 Processo de Treinamento e Hiperparâmetros

O treinamento foi conduzido por um total máximo de 150 épocas e os dados de treinamento foram apresentados ao modelo em lotes (*batches*) de 384 amostras. Ao final de cada época, o modelo foi avaliado com o conjunto de validação para obter uma

estimativa imparcial de generalização, sendo esta avaliação usada nos mecanismos de controle descritos no item 3.5.3.

3.5.3 Mecanismos de Controle e Regularização

Para garantir um treinamento confiável, foram implementados alguns mecanismos de controle. Para isso o processo era interrompido automaticamente se a acurácia de validação não melhorasse por 20 épocas (*Early Stopping*), evitando o *overfitting*. Apenas a versão do modelo com o melhor desempenho de validação será salva (*Model Checkpoint*) para garantir que a avaliação final utilizasse a rede mais confiável.

Adicionalmente, foi implementado um redutor de aprendizado, onde a taxa de aprendizado é reduzida pela metade caso a perda de validação se mantiver por 7 épocas, permitindo que o modelo realize ajustes mais finos para convergir a uma solução otimizada.

3.5.4 Métricas de Avaliação de Desempenho

Após o término do treinamento, a próxima etapa é quantificar sua eficácia, o resultado do modelo e analisar seu comportamento. Para isso o conjunto é submetido a uma análise criteriosa utilizando o conjunto de teste. Para essa avaliação, foram empregadas as seguintes métricas quantitativas e qualitativas:

1. Acurácia: A acurácia é a principal métrica utilizada para medir o desempenho geral do classificador. Ela representa a proporção de predições corretas em relação ao número total de amostras avaliadas. O desempenho do modelo será analisado em função da Relação Sinal-Ruído, permitindo aferir a robustez do classificador em diferentes níveis de ruído e de modulação.
2. Matriz de Confusão: a matriz de confusão proporciona uma análise qualitativa detalhada dos erros de classificação. Trata-se de uma tabela que visualiza o desempenho do modelo, onde as linhas representam as classes verdadeiras (*True Label*) e as colunas representam as classes preditas pelo modelo (*Predicted Label*).

Os elementos na diagonal principal da matriz indicam as classificações corretas, enquanto os elementos fora da diagonal mostram os erros, revelando quais classes são frequentemente confundidas entre si (Harper *et al.*, 2023). A análise da matriz de confusão se mostra essencial para identificar as limitações específicas do classificador, como a dificuldade em distinguir modulações de uma mesma

família (por exemplo, QAM16 e QAM64), especialmente em cenários de baixo SNR.

3. Curvas de Treinamento: O processo de aprendizado do modelo é monitorado visualmente através das curvas de treinamento. Estes gráficos plotam os valores da função de perda e da acurácia ao final de cada época, tanto para o conjunto de treino quanto para o de validação.

- a. Curva de Perda (*Loss Curve*): Representa o erro do modelo, calculado pela função de custo (*categorical cross-entropy*). O objetivo do treinamento é minimizar esse valor. A análise da curva de perda de treino em conjunto com a curva de validação é fundamental para diagnosticar a convergência do modelo e identificar a ocorrência de *overfitting*, que se manifesta quando a perda de treino continua a diminuir enquanto a de validação estagna ou aumenta (Ibrahim, 2023).
- b. Curva de Acurácia: Demonstra a evolução da acurácia do modelo ao longo das épocas. Espera-se que ambas as curvas, de treino e validação, convirjam para um valor alto e estável, indicando que o modelo está aprendendo e generalizando corretamente (Ibrahim, 2023).

Assim, a aplicação conjunta dessas métricas proporciona uma avaliação robusta. Essa abordagem permite não apenas quantificar a performance geral do modelo, mas também diagnosticar o processo de treinamento e analisar qualitativamente os padrões de erro.

4 DESCRIÇÃO DOS RESULTADOS

Este capítulo é dedicado a apresentar os resultados obtidos com a Rede Neural Convolutacional implementada, com o objetivo de expor de forma objetiva o desempenho do classificador. As métricas e visualizações aqui detalhadas fornecem a base para a interpretação e a discussão que serão aprofundadas no capítulo subsequente, conectando assim o desfecho do modelo proposto.


A análise será estruturada de forma sequencial para construir uma avaliação completa do desempenho do classificador. Na primeira seção será apresentada a validação do processo de treinamento, por meio das curvas de aprendizado, para assegurar que o modelo convergiu adequadamente. Na segunda seção será realizada uma avaliação quantitativa da acurácia em função da SNR, para medir a robustez do modelo em diferentes cenários. Na terceira seção será exibido uma análise qualitativa, com base nas matrizes de confusão, permitindo uma investigação detalhada dos padrões de erro e acerto para cada classe de modulação. E por final, será apresentada uma síntese para fechar o capítulo.

4.1 Análise do Processo de Treinamento e Convergência do Modelo

A primeira etapa na avaliação dos resultados consiste em verificar se o modelo de CNN foi treinado de forma eficaz. Para isso, são analisadas as curvas de aprendizado, que ilustram a evolução da função de perda ao longo das épocas de treinamento, tanto para o conjunto de dados de treino quanto para o de validação.

Por meio das representações das curvas de acurácia e perda, é possível avaliar a convergência, a estabilidade do aprendizado e identificar padrões de erro que não são aparentes quando observado apenas valores numéricos (Ibrahim, 2023). E, o acompanhamento das curvas ao longo das épocas de treinamento serve como uma ferramenta para verificar se o modelo está aprendendo de forma eficaz e generalizando o conhecimento para dados não vistos.

Figura 14 - Curva de acurácia e de perda.



Fonte: elaborado pelo autor.

A Figura 14 exibe as curvas de desempenho do modelo ao longo do processo de treinamento. O resultado é composto por dois gráficos: a curva de acurácia, que mede a proporção de classificações corretas, e a curva de perda, que quantifica o erro do modelo. Ambas as métricas são plotadas tanto para o conjunto de dados de treinamento (em azul) quanto para o de validação (em laranja), permitindo uma análise comparativa.

É possível observar no gráfico que ambas as curvas, apresentam uma aproximação acentuada nas épocas iniciais, com uma queda acentuada na curva de perda e um aumento acentuado na curva de acurácia, indicando que o modelo está aprendendo e ajustando seus pesos para minimizar o erro de classificação. Com o avanço das épocas, ambas as curvas tendem a se estabilizar em um patamar próximo, o que demonstra a convergência do modelo.

A análise da relação entre as duas curvas é fundamental para diagnosticar a capacidade de generalização da rede. Conforme aponta a literatura, um cenário ideal de treinamento ocorre quando a curva de perda de validação segue de perto a curva de perda de treinamento, sem divergir significativamente (Ibrahim, 2023).

Nos gráficos da Figura 14, a proximidade entre as duas curvas sugere que o modelo generaliza bem para dados não vistos e que as técnicas de regularização, como o *Dropout*, foram eficazes em mitigar o *overfitting*. A ausência de uma divergência


crescente entre as curvas confirma a estabilidade do aprendizado, validando que o modelo final, que foi salvo ao término do processo, é robusto e adequado para a avaliação de desempenho.

4.2 Avaliação Quantitativa do Desempenho em Função do SNR

Após a validação do processo de treinamento, a análise quantitativa do desempenho do classificador é realizada em função da SNR. Esta avaliação é crucial para determinar a robustez do modelo, pois mede sua capacidade de classificar corretamente os sinais sob diferentes níveis de ruído, um dos principais desafios em ambientes de comunicação não cooperativos. A análise foi dividida em duas partes: uma avaliação do desempenho geral do modelo e uma análise detalhada por classe de modulação.

4.2.1 Resultados Globais por SNR

Inicialmente, avalia-se o comportamento do classificador como um todo. A Figura 15 exibe as principais métricas de desempenho do modelo (Acurácia, Precisão, *Recall* e *F1-Score*) plotadas para cada nível de SNR.



Fonte: elaborado pelo autor.

A Figura 15 apresenta, para cada nível de SNR, as curvas de Acurácia, Precisão, Recall e F1-score do classificador. O eixo x mostra os valores de SNR de -20 a $+18$ dB e o eixo y o *score* obtido em cada métrica. As médias são feitas por média aritmética das métricas calculadas por classe, de modo a ponderar igualmente todas as classes.


A análise do gráfico da Figura 15 pode ser organizada em 3 etapas:

1. Baixo SNR (-20 dB a -8 dB): Nesta fase, o desempenho é baixo. As quatro métricas permanecem reduzidas, evidenciando a dificuldade do modelo em extrair características em um regime dominado por ruído.
2. Faixa de Transição (-8 dB a $+2$ dB): Um crescimento acentuado das métricas é observado. Há um ganho de performance a cada incremento de SNR, indicando que o modelo consegue explorar melhor as características dos sinais à medida que o SNR melhora.
3. Alto SNR ($+2$ dB a $+18$ dB): As métricas entram em uma fase de constância, com pequenas variações, sugerindo um equilíbrio entre precisão nas classificações.

4.2.2 Acurácia Global por SNR

Enquanto a análise anterior apresentou uma visão conjunta das métricas, um exame focado na curva de acurácia permite uma interpretação mais clara do comportamento geral da classificação. Isolar esta métrica facilita a identificação precisa do ponto em que o modelo atinge seu limite de desempenho.

Figura 16 - Desempenho da Acurácia por SNR.



Fonte: elaborado pelo autor.

A Figura 16 mostra a acurácia de classificação do modelo em função da SNR no conjunto de teste. O eixo x é escalonado pelos valores de SNR (-20 a $+18$ dB) e o eixo y o *score* da classificação da acurácia.


De forma semelhante ao restante das métricas do item 4.2.1, o comportamento dos valores da acurácia também se divide em 3 grupos. No baixo SNR (-20 a -8 dB) a acurácia cresce lentamente, refletindo a forte influência do ruído. Entre -8 dB e 0 dB há

uma faixa de transição com ganho rápido de desempenho. A partir de +4 dB a curva entra em um canal de ganho de +80%, com pequenas oscilações até atingir +18 dB.

Esse patamar então delimita o limite para o modelo, indicando que aumentos adicionais de SNR acima desse valor podem produzir poucos acréscimos de acurácia.

4.2.3 Desempenho das Modulações por SNR

Enquanto a análise das métricas globais oferece uma visão geral, a avaliação da acurácia por classe de modulação é fundamental para entender o comportamento específico do classificador. A Figura 17 detalha a performance para cada uma das 11 modulações em toda a faixa de SNR.



Fonte: elaborado pelo autor.

A Figura 17 representada por quatro gráficos, divididos por grupo de modulação (Analógicas, PSK, PAM/QAM e FSK), evidenciam a acurácia de classificação do modelo em função do SNR (-20 a +18 dB). Cada curva é a acurácia da respectiva modulação no conjunto de teste, permitindo comparar em qual condição de SNR a acurácia melhora e em qual condição ela satura.

A análise do gráfico da Figura 17 concorda com as observações dos demais itens da atual seção 4.2, onde o desempenho do modelo é heterogêneo entre as classes, mas segue padrões consistentes. Novamente é possível identificar três regimes bem marcados na maioria das curvas, sendo um de baixo SNR, com acurácias próximas de zero, o

segundo numa faixa de transição, caracterizada por um crescimento acentuado da acurácia, e o terceiro uma convergência em alto SNR, onde a performance se estabiliza, com pequenas oscilações.


Com a análise observa-se que modulações mais simples e robustas, como BPSK e as da família FSK, saturam mais cedo e atingem uma estabilidade de alta performance. Em contraste, modulações digitais, como 8PSK e QAM64, que precisam de um SNR um pouco maior para estabilizar. Entretanto, a modulação WBFM, aparece como um desafio para o classificador mesmo em SNR alto, nunca atingindo uma acurácia elevada.

No conjunto, a Figura 17 confirma que o modelo generaliza bem para a maioria das modulações em cenários de SNR médio e alto. Os principais desafios de classificação se concentram na modulação analógica WBFM e na modulação QAM16, que limitam o desempenho global do sistema.

4.3 Análise Qualitativa dos Padrões de Classificação

A análise qualitativa desta seção utilizará a matriz de confusão, permite uma investigação detalhada dos erros e acertos do classificador para cada classe específica. Esta abordagem é importante para identificar as peculiaridades do modelo, revelando quais modulações são classificadas com sucesso e quais são frequentemente confundidas.

A Figura 18 apresenta a matriz de confusão normalizada, que resume o desempenho do modelo em todo o conjunto de teste.



Fonte: elaborado pelo autor.

A Figura 18 representa a matriz de confusão que exibe a proporção de predições para cada uma das 11 classes de modulação do *dataset*. As linhas representam as classes verdadeiras e as colunas as classes preditas. Os valores na diagonal principal indicam a classificação correta para cada classe individual, enquanto os valores fora da diagonal representam os erros de classificação.

A análise da matriz revela um desempenho heterogêneo para cada classe de modulação. É evidenciado alta eficácia para certas classes, como AM-DSB (72%), PAM4 (66%), AM-SSB (97%), indicando que a CNN aprendeu características altamente discriminativas para essas modulações. A forte concentração de valores na diagonal para essas classes confirma a robustez da classificação.

Entretanto, a análise dos elementos fora da diagonal expõe os principais desafios do modelo. Um dos erros mais significativos ocorre com a modulação WBFM, que é corretamente classificada apenas 20% das vezes e confundida com AM-DSB em 49% dos casos. Essa dificuldade em distinguir modulações analógicas é um comportamento esperado e documentado na literatura, dada a similaridade de suas características no domínio do tempo (Silva; Pinho, 2023).

Outro padrão de erro notável é a confusão entre as modulações digitais QAM16 e QAM64. O modelo classifica incorretamente 58% das amostras de QAM16 como QAM64, o que evidencia a dificuldade em distinguir entre constelações de uma mesma família, mas com densidades diferentes.

Essa análise qualitativa complementa os achados da seção anterior, confirmando que, embora o modelo seja eficaz para diversas classes, sua performance geral é impactada por desafios específicos em subconjuntos de modulações.

4.4 Síntese dos Resultados

Os resultados apresentados neste capítulo confirmam que o modelo foi treinado com sucesso, com uma clara consistência e sem *overfitting* significativo, validando a robustez do aprendizado.

A análise quantitativa estabeleceu a forte dependência do desempenho com o SNR, identificando o limite de performance da arquitetura em cenários de alto SNR. Por fim, a análise qualitativa, por meio da matriz de confusão, revelou os padrões de erro específicos do classificador, como a dificuldade em distinguir modulações analógicas e as de alta ordem da família QAM.

Estes resultados o fundamento necessário para a análise crítica a ser desenvolvida no capítulo subsequente, onde as implicações destas respostas serão exploradas e interpretados com a literatura.

5 DISCUSSÃO

Após a apresentação dos resultados no capítulo anterior, este capítulo é focado na sua interpretação. O objetivo aqui é interpretar a descrição dos dados para analisar o significado e as suas implicações, os relacionando com o referencial teórico e os trabalhos relacionados que fundamentaram esta pesquisa. Serão discutidas as razões por trás do desempenho observado do modelo, os padrões de erro identificados e, por fim, as limitações inerentes ao escopo e à metodologia deste estudo, fornecendo uma análise crítica e contextualizada dos resultados obtidos.

5.1 Interpretação da Influência do SNR

A forte dependência do desempenho do classificador em relação à relação Sinal-Ruído, observada no Capítulo 4, é um comportamento esperado e alinhado com os princípios fundamentais de sistemas de comunicação.

Em cenários de baixo SNR, o ruído se sobrepõe às características do sinal, tornando a tarefa de extração de padrões discriminativos pela CNN extremamente desafiadora. A performance próxima da aleatoriedade nesta faixa indica que a rede não consegue identificar características robustas o suficiente para distinguir as modulações. E esse é um limite fundamental não apenas para abordagens de aprendizado profundo, mas para qualquer método de classificação (West; O'Shea, 2017).

A análise aprofundada da matriz de confusão (Figura 18) revela limitações específicas do modelo. A confusão entre as modulações analógicas WBFM e AM-DSB pode ser atribuída à similaridade de suas envoltórias no domínio do tempo. Para a CNN, que opera diretamente sobre as amostras temporais I/Q, a ausência de uma estrutura de fase bem definida, como a encontrada em modulações digitais, dificulta a extração de características únicas (West; O'Shea, 2017).

De forma análoga, a confusão entre QAM16 e QAM64 se mostrou um desafio em AMC. Como a constelação de QAM16 é muito semelhante à constelação de QAM64, tanto em níveis de SNR altos, intermediários ou baixos, conforme ilustrado no item 3.2, os pontos da constelação de QAM64 se dispersam devido ao ruído, ocupando uma região no espaço I/Q que se assemelha à de uma constelação QAM16. Essa sobreposição tornou a distinção entre as duas classes intrinsecamente difícil.

Observa-se também a estabilização do desempenho da acurácia em cenários de alto SNR, o que demonstra o limite da capacidade de aprendizado da arquitetura para este conjunto de dados. Uma vez que o ruído deixa de ser o fator limitante, a performance restante é determinada pela arquitetura e organização da rede em discriminar

características, selecionar parâmetros, e modelar e diferenciar as classes. Dessa forma, a acurácia máxima alcançada, reflete a complexidade da tarefa de AMC e a capacidade da arquitetura proposta.

5.2 Comparação com os Resultados da Literatura

Uma análise crítica dos resultados exige que eles sejam posicionados em relação aos achados da literatura, permitindo avaliar a validade da abordagem e contextualizar o desempenho do modelo implementado.

A primeira comparação pode ser realizada entre a análise visual dos diagramas de constelação (Seção 3.2) e os resultados da matriz de confusão (Seção 4.3). Foi observado que, mesmo em alto SNR, modulações como a QAM16 não apresentavam um padrão visualmente claro em sua constelação, aparecendo como uma nuvem de pontos densa. A matriz de confusão corrobora essa dificuldade, mostrando que QAM16 é frequentemente confundida com QAM64. Isso evidencia que a rede aprende características discriminativas que vão além da inspeção visual humana, baseando-se em padrões temporais e estatísticos presentes nos dados brutos I/Q, mas também confirma que a dificuldade visual se traduz em um desafio real para o classificador.

Do ponto de vista quantitativo, o desempenho do modelo deve ser comparado com os resultados de referência que utilizaram o mesmo *dataset*, o RadioML2016.10a. O trabalho pioneiro de O'Shea, Corgan e Clancy (2016) reportou acurácias superiores a 90% em cenários de alto SNR para arquiteturas convolucionais. Trabalhos subsequentes, como o de West e O'Shea (2017), que exploraram arquiteturas mais profundas de DL como as ResNets, e alcançaram performances ainda maiores, aproximando-se de 95% de acurácia nos mesmos cenários.

O modelo implementado neste trabalho atingiu uma acurácia máxima de aproximadamente 80% em alto SNR. Embora este valor seja inferior aos reportados nos estudos de referência, ele é consistente com o comportamento esperado de uma arquitetura de CNN para esta tarefa. A diferença de desempenho pode ser atribuída a múltiplos fatores, incluindo a profundidade da arquitetura da CNN proposta, a ausência de uma otimização exaustiva de hiperparâmetros, um processo que, como aponta a literatura, é complexo e sutil (Pina *et al.*, 2020), e diferenças pontuais na implementação e arranjo da CNN.

Portanto, o desempenho do modelo implementado não representa um novo estado da arte, mas se comporta como uma validação bem-sucedida dos princípios consolidados na literatura. O modelo reproduziu com sucesso os principais desafios da tarefa de AMC,

como a forte dependência do SNR e a confusão e avaliação entre classes complexas, cumprindo o objetivo de analisar e aprofundar o entendimento de uma abordagem moderna para o problema.

5.3 Limitações do Estudo

Esta seção apresenta as limitações do trabalho, explicitando o que orientou o desenvolvimento e, por consequência, delimitou a interpretação dos resultados e o alcance das conclusões.

A principal limitação reside no uso de um *dataset* sintético, o RadioML2016.10a. Embora seja uma referência consolidada para a pesquisa em AMC e permita um ambiente controlado para o treinamento e a avaliação, os sinais gerados podem não representar todas as complexidades e imperfeições encontradas em um ambiente de comunicação real. Fatores como interferências multicanal, efeitos de propagação não-lineares e outras anomalias do mundo real não estão completamente mapeados, o que, de certa forma implica que o desempenho do classificador pode não se reproduzir em cenários reais.

Adicionalmente, a arquitetura de CNN proposta, embora baseada em princípios consolidados, representa um modelo de base. O desempenho do modelo é sabidamente sensível à escolha de hiperparâmetros, e este trabalho não incluiu uma busca exaustiva ou uma otimização sistemática desses valores. Portanto, o desempenho aqui reportado representa uma linha de base para esta arquitetura específica, e não necessariamente o seu potencial máximo.

6 CONCLUSÃO

Este trabalho se propôs a desenvolver, implementar e avaliar um sistema de AMC baseado em uma CNN, com o objetivo de analisar seu desempenho em diferentes níveis de ruído. O objetivo foi alcançado, uma vez que uma arquitetura de CNN foi implementada com sucesso, treinada com o *dataset* de referência RadioML2016.10a e avaliada. A análise dos resultados permitiu não apenas quantificar a performance, mas também contextualizá-la com a literatura, validando a abordagem de DL como uma ferramenta viável para a tarefa de AMC em cenários simulados, cumprindo assim todas as etapas delineadas na introdução.

Os resultados demonstraram que o desempenho do classificador é fortemente dependente do SNR, atingindo uma acurácia global máxima de aproximadamente 80% a partir de +4 dB que continua a melhorar, estabilizando-se em um patamar próximo a 85% nos níveis mais altos de SNR (+18 dB). Entretanto decai para níveis próximos da aleatoriedade em baixo SNR (-8 dB). A implicação deste produto é a confirmação de que existe um limiar de sinal para a operação confiável do modelo. A identificação de padrões de erro específicos, como a dificuldade em distinguir modulações da família QAM e as analógicas, fornecem um diagnóstico sobre as limitações da arquitetura, indicando quais sinais exigiriam modelos mais complexos para uma classificação melhor.

No âmbito de aplicações práticas, são extensas o uso desta tecnologia, podendo beneficiar a sociedade por meio da otimização do espectro eletromagnético e sistemas de comunicação mais eficientes. Para a Marinha do Brasil, a implementação de sistemas de AMC robustos representa uma vantagem estratégica, aprimorando a capacidade de ELINT e a consciência situacional no teatro de operações. Essa capacidade de identificar rapidamente modulações desconhecidas tem potencial para fortalecer as operações de GE, tanto para a interceptação de comunicações de interesse quanto para a garantia da segurança das próprias comunicações e dos aliados.

Por fim, considerando as limitações diagnosticadas e os resultados alcançados, delineiam-se direções para trabalhos futuros visando expandir esta pesquisa. A primeira foca em aprimorar a distinção de classes complexas através de arquiteturas mais robustas, como as ResNets ou redes recorrentes LSTM, capazes de explorar melhor a profundidade e as dependências temporais dos dados. A segunda direção, de cunho prático, propõe a validação experimental com sinais reais capturados via SDR, submetendo o classificador a cenários de transmissão reais para verificar sua generalização diante de distorções de *hardware* e do canal físico não contempladas na simulação.

REFERÊNCIAS

ABD-ELAZIZ, Ola Fekry; ABDALLA, Mahmoud; ELSAYED, Rania A. **Deep learning-based automatic modulation classification using robust CNN architecture for cognitive radio networks**. *Sensors*, v. 23, n. 23, p. 9467, 2023.

ALVES, E. B. **Emprego de técnicas de análise de tempo frequência e de redes neurais convolucionais na classificação automática de sinais radar de baixa probabilidade de interceptação**. 2024. Dissertação (Mestrado em Engenharia de Sistemas e Computação) – Instituto Militar de Engenharia, Rio de Janeiro, 2024.

BENECASE, Antonio Carlos. **Estudo do uso de técnicas simples de inteligência artificial na classificação de sinais radar modulados**. Monografia — Centro de Instrução Almirante Alexandrino (CIAA), Diretoria de Ensino da Marinha. Rio de Janeiro, 2023.

CUNHA, LCD. **Redes neurais convolucionais e segmentacao de imagens: uma revisão bibliográfica**. 2020. Trabalho de Conclusão de Curso (Especialização)-Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2020.

DATA SCIENCE ACADEMY. **Deep Learning Book**. [S. l.], 2022. p. 1–100. Disponível em: <https://www.deeplearningbook.com.br/deep-learning-a-tempestade-perfeita/>. Acesso em: 16 set. 2023.

DINIZ, Pedro Mendes; DE MORAES CALAZAN, Rogério. **Aplicação de redes neurais para a classificação automática de embarcações mercantes usando sinais sonar passivos**. *Revista Pesquisa Naval*, v. 1, n. 34, p. 33-41, 2022.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. " O'Reilly Media, Inc.", 2022.

HARPER, C. A.; THORNTON, M. A.; LARSON, E. C. **Automatic Modulation Classification with Deep Neural Networks**. *Electronics*, v. 12, n. 18, p. 3962, 2023.

HU, Lin *et al.* **Signal classification in real-time based on SDR using convolutional neural network**. In: *2021 IEEE 2nd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA)*. IEEE, 2021. p. 893–898.

IBRAHIM, Mostafa. **A Deep Dive Into Learning Curves in Machine Learning**. *Weights & Biases – Fully Connected*, 9 jun. 2023. Disponível em: <https://wandb.ai/mostafaibrahim17/ml-articles/reports/A-Deep-Dive-Into-Learning-Curves-in-Machine-Learning-Vmllldzo0NjA1ODY0>. Acesso em: 9 out. 2025.

IEEE DATAPORT. **RadioML 2016.10A/10B/10C**: IEEE DataPort, 2016. Disponível em: <https://ieee-dataport.org/documents/radioml201610a10b10c#files>. Acesso em: 24 set. 2025.

KE, Ziqi; VIKALO, Haris. **Real-time radio technology and modulation classification via an LSTM auto-encoder**. *IEEE Transactions on Wireless Communications*, v. 21, n. 1, p. 370-382, 2021.

KHALID, Umar; KARIM, Nazmul; RAHNAVARD, Nazanin. **RF signal transformation and classification using deep neural networks**. In: *Big Data IV: Learning, Analytics, and Applications*. SPIE, 2022. p. 51–57.

MILCZAREK, Hubert *et al.* **Automatic classification of frequency-modulated radar waveforms under multipath conditions**. *IEEE Sensors Journal*, v. 23, n. 16, p. 18349–18361, 2023.

MILLÉO, Ronny S. R.; DE CASTRO, Adenilson F.; LOLIS, Luis Henrique A.; MARIANO, André Augusto. **Análise das características de sinais para Classificação Automática de Modulação**. In: SEMINÁRIOS DE MICROELETRÔNICA DO PARANÁ, 2019, Curitiba. *Anais*. 16–18 out. 2019.

O'SHEA, Timothy J.; CORGAN, Johnathan; CLANCY, T. Charles. **Convolutional radio modulation recognition networks**. In: International conference on engineering applications of neural networks. Cham: Springer International Publishing, 2016. p. 213–226.

OLIVEIRA, H. M. de. **Engenharia de Telecomunicações: Teoria Básica da Comunicação**. 1. ed. Recife: Editora HM, 2012.

PENG, Shengliang *et al.* **Modulation classification based on signal constellation diagrams and deep learning**. *IEEE transactions on neural networks and learning systems*, v. 30, n. 3, p. 718–727, 2018.

PINA, Débora *et al.* **Uma abordagem para coleta e análise de dados de configurações em redes neurais profundas**. In: Simpósio Brasileiro de Banco de Dados (SBBBD). SBC, 2020. p. 187–192.

RAJENDRAN, S. *et al.* **Deep Learning Models for Wireless Signal Classification with Distributed Low-Cost Spectrum Sensors**. *IEEE Transactions on Cognitive Communications and Networking*, v. 4, n. 3, p. 433–445, 2018.

SILVA, Natália Galvão; PINHO, Marcelo da Silva. **Modelos de aprendizado profundo para classificação de modulações de sinais de comunicação wireless**. São José dos Campos: Instituto Tecnológico de Aeronáutica (ITA), 2023. ISSN 1983-7402. Evento no ITA, 26–28 set. 2023.

SOUZA, Vinicius Samy Santana. **Introdução à Interpretabilidade de Redes Neurais Convolucionais**. 2023. Monografia (Bacharelado em Ciência da Computação) – Departamento de Computação, Universidade Federal de Ouro Preto, Ouro Preto, 2023.

THALES GROUP. **a4ESSOR achieves acceptance for its ESSOR HDR Base Waveform**. Paris: Thales Group, 17 maio 2021. Disponível em: <https://www.thalesgroup.com/en/news-centre/press-releases/a4essor-achieves-acceptance-its-essor-hdr-base-waveform>. Acesso em: 02 out. 2025.

VALADÃO, Myke D. M. *et al.* **Classificação Automática de Modulações utilizando Redes Neurais Artificiais com Regularização Bayesiana e Algoritmo de Retropropagação de Levenberg–Marquardt**. *XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT2020)*, p. 1–5, 2020.

WEST, Nathan E.; O'SHEA, Tim. **Deep architectures for modulation recognition**. In: *2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*. IEEE, 2017. p. 1–6.