

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

ESTUDO DA CLASSIFICAÇÃO DE MODULAÇÃO INTRAPULSO A PARTIR DE
REDES NEURAIIS CONVOLUCIONAIS



PRIMEIRO-TENENTE THIAGO FERREIRA MOREIRA LIMA

Rio de Janeiro

2025

PRIMEIRO-TENENTE THIAGO FERREIRA MOREIRA LIMA

Estudo da Classificação de Modulação Intrapulso a partir 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:

D.Sc Rodrigo da Silva Moreira

D.Sc Aline de Oliveira Pinto Silva

Rio de Janeiro

2025

FOLHA DE APROVAÇÃO

PRIMEIRO-TENENTE THIAGO FERREIRA MOREIRA LIMA


Estudo da Classificação de Modulação Intrapulso a partir de Redes Neurais
Convolucionais


Primeiro-Tenente Thiago Ferreira Moreira Lima


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

Aprovada por:


Rodrigo da Silva Moreira, D.Sc - IPqM


Aline de Oliveira Pinto Silva, D.Sc - IPqM


Jorge Costa Pires Filho, D.Sc - IPqM


Prof., Guilherme Ribeiro Colen, D.Sc - CIAA

RIO DE JANEIRO, RJ – BRASIL

NOVEMBRO DE 2025

FICHA CATALOGRÁFICA

Ferreira Moreira Lima, Thiago
Estudo da Classificação da Modulação Intrapulso a partir de Redes
Neurais Convolucionais.

da Marinha do Brasil. – Rio de Janeiro: MB/CIAA, 2025.

[1], [71] p.: il.; 29,7 cm.

Orientador: DSc Rodrigo da Silva Moreira e DSc Aline de
Oliveira Pinto Silva

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

Referências Bibliográficas: p. [70 e 71].

1.radar. 2.classificação. 3.rede neural. I. da Silva Moreira,
Rodrigo. II. Marinha do Brasil, CIAA, Curso de Aperfeiçoamento
Avançado em Guerra Eletrônica. III. Estudo da Classificação da
Modulação Intrapulso a partir de Redes Neurais Convolucionais.

Dedico este trabalho à minha noiva, cuja dedicação, amor e companheirismo foram essenciais ao longo desta caminhada; aos meus pais e aos meus irmãos, pelo amparo e incentivo incondicionais durante minha trajetória na Marinha do Brasil; e principalmente à Deus, pela saúde, pela sabedoria e pela inspiração que me sustentam diariamente.

AGRADECIMENTOS

À Deus, por me conceder força, sabedoria e serenidade ao longo de toda esta jornada, guiando-me em todos os momentos da minha vida.

À minha noiva, Renata Brandes Fernandes, pelo amor, paciência e apoio incondicional. Sua compreensão e incentivo foram essenciais para que eu mantivesse o foco e a motivação durante cada etapa deste trabalho.

Aos meu orientador, Doutor Rodrigo da Silva Moreira, pela orientação precisa, dedicação, disponibilidade e confiança depositada em mim. Seu conhecimento e suas valiosas contribuições foram fundamentais para o desenvolvimento deste trabalho e para o meu crescimento acadêmico e profissional. Agradeço também pelas aulas ministradas durante o Curso de Aperfeiçoamento para Oficiais em Guerra Eletrônica (CApA-GE).

Agradeço também à Doutora Aline de Oliveira Pinto Silva e ao Senhor Jorge Costa Pires Filho por terem abdicado de seu tempo, aceitado compor a banca deste trabalho e pelas orientações iniciais.

Por fim, aos integrantes da Turma Almirante Saboia, em especial aos grandes amigos Vitor Melo, Gustavo Aquino, Fernando Companhone, João Alvarenga, Guilherme Villaça, Daniel Scorzello, Lucas Mendonça, Guilherme Júnior e Lucas Matos, companheiros em todas as etapas, desde os tempos de Colégio Naval.

RESUMO

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

Estudo da Classificação de Modulação Intrapulso a partir de Redes Neurais Convolucionais

Thiago Ferreira Moreira Lima

Novembro/2025

Orientador(es): DSc Rodrigo da Silva Moreira e DSc Aline de Oliveira Pinto Silva

Curso de Aperfeiçoamento Avançado em Guerra Eletrônica

No contexto dos conflitos modernos, a Capacidade de Guerra Eletrônica (CGE) emerge como um elemento essencial para garantir o domínio do teatro de operações navais. Essa capacidade confere vantagem tática e estratégica, tornando-se um fator decisivo na superioridade tecnológica dos meios navais. Com base nesse cenário, o presente trabalho busca contribuir para o aprimoramento das Medidas de Apoio à Guerra Eletrônica (MAGE) da Marinha do Brasil. Para isso, realiza-se uma análise da eficiência de três algoritmos classificadores de modulação intrapulso em sinais de radar, servindo como etapa inicial de um estudo mais amplo sobre o tema. A pesquisa propõe uma comparação entre três arquiteturas de Redes Neurais Convolucionais (CNN) aplicadas à classificação de sinais radar. Esses sinais podem apresentar modulação linear em frequência (LFM) ou modulação em fase baseada em códigos Barker, polifásicos ou politemporais. A classificação precisa do tipo de modulação desempenha papel crucial na detecção e identificação dos sinais radar, permitindo respostas mais rápidas e eficazes dos sistemas de combate. Assim, a correta classificação dos sinais radar modulados pode representar um avanço tático significativo, incrementando as capacidades de Guerra Eletrônica dos meios da Marinha do Brasil.

Palavras-chave: classificação; radar; sinais; modulação; Inteligência Artificial; Redes Neurais Convolucionais.

ABSTRACT

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

Study of Intrapulse Modulation Classification Using Convolutional Neural Networks

Thiago Ferreira Moreira Lima

November/2025

Advisor(s): DSc Rodrigo da Silva Moreira e DSc Aline de Oliveira Pinto Silva

Advanced Improvement Course in Electronic Warfare

In the context of modern conflicts, the Electronic Warfare Capability (EWC) emerges as an essential element for ensuring dominance in the naval theater of operations. This capability provides both tactical and strategic advantages, becoming a decisive factor in the technological superiority of naval assets.

Based on this scenario, the present study seeks to contribute to the enhancement of the Electronic Warfare Support Measures (ESM) of the Brazilian Navy. To this end, an analysis of the efficiency of three intrapulse modulation classification algorithms for radar signals is conducted, serving as an initial stage of a broader investigation on the subject. The research proposes a comparison among three Convolutional Neural Network (CNN) architectures applied to the classification of radar signals. These signals may exhibit linear frequency modulation (LFM) or phase modulation based on Barker, polyphase, or polytime codes. The accurate identification of the modulation type plays a crucial role in the detection and classification of radar signals, enabling faster and more effective responses from combat systems. Thus, the correct classification of modulated radar signals can represent a significant tactical advancement, strengthening the Electronic Warfare capabilities of the Brazilian Navy.

Keywords: classification; radar; signals; modulations; artificial intelligence; Convolutional Neural Networks.

LISTA DE FIGURAS

Figura 1- Estrutura de Guerra Eletrônica na MB	6
Figura 2 - Efeito da minimização dos lóbulos laterais (sidelobes).....	12
Figura 3 - Sequências de Códigos de Barker e seus respectivos níveis de lóbulo lateral em decibéis (dB).....	12
Figura 4 - Modelo de um neurônio artificial (direita), inspirado na estrutura de um neurônio biológico (esquerda).....	17
Figura 5 - Estrutura de uma rede neural artificial, mostrando a camada de entrada, as camadas ocultas de processamento e a camada de saída.....	19
Figura 6 - Exemplo de operação de convolução, onde o filtro é aplicado aos dados de entrada para gerar o mapa de características (feature map).....	21
Figura 7 - Exemplo de extração de características, onde a imagem de entrada é processada por filtros convolucionais que geram diferentes mapas de características (feature maps).....	22
Figura 8 - Exemplo da operação de max pooling, que reduz a dimensão do mapa de características selecionando o maior valor em cada região da matriz.....	23
Figura 9 - Estrutura básica de uma rede neural convolucional (CNN), composta pelas etapas de extração de características (feature extraction), com camadas de convolução e pooling, e pela etapa de classificação com camadas totalmente conectadas (fully connected).....	24
Figura 10 - Classificador baseado na Rede Neural CNN	27
Figura 11 - Gráficos das amplitudes x tempo das amostras analisadas por tipo de modulação com SNR-15dB	32
Figura 12 – Gráficos de amplitude x tempo com SNR -15 dB.....	33
Figura 13 - Gráficos após aplicação da STFT SNR 15 dB.....	34
Figura 14 - Gráficos após aplicação da STFT	35
Figura 15- Matriz de Confusão (Conjunto de Treinamento) $SNR \geq 0dB$	36
Figura 16 - Matriz de Confusão (Conjunto de Treinamento) $-10dB \leq SNR \leq 0dB$	37
Figura 17 - Matriz de Confusão (Conjunto de Treinamento) $-SNR \leq -10dB$	38
Figura 18 - Matriz de Confusão (Conjunto de Teste) $SNR \geq 0dB$	39
Figura 19 - Matriz de Confusão (Conjunto de Teste) $-10dB \leq SNR \leq 0dB$	40
Figura 20 - Matriz de Confusão (Conjunto de Teste) $-SNR \leq -10dB$	41
Figura 21- Matriz de Confusão (Conjunto de Treinamento) $SNR \geq 0dB$	42

Figura 22 - Matriz de Confusão (Conjunto de Treinamento) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$	43
Figura 23 - Matriz de Confusão (Conjunto de Treinamento) $-\text{SNR} \leq -10\text{dB}$	44
Figura 24 - Matriz de Confusão (Conjunto de Teste) $\text{SNR} \geq 0\text{dB}$	45
Figura 25 - Matriz de Confusão (Conjunto de Teste) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$	46
Figura 26 - Matriz de Confusão (Conjunto de Teste) - $\text{SNR} < -10\text{dB}$	47
Figura 27 - Matriz de Confusão (Conjunto de Treinamento) $\text{SNR} \geq 0\text{dB}$	48
Figura 28 - Matriz de Confusão (Conjunto de Treinamento) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$	49
Figura 29 - Matriz de Confusão (Conjunto de Treinamento) $\text{SNR} \leq -10\text{dB}$	50
Figura 30 - Matriz de Confusão (Conjunto de Teste) $\text{SNR} \geq 0\text{dB}$	51
Figura 31- Matriz de Confusão (Conjunto de Teste) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$	52
Figura 32 - Matriz de Confusão (Conjunto de Teste) $-\text{SNR} \leq -10\text{dB}$	53
Figura 33- Matriz de Confusão (Conjunto de Teste) da CNN1 - 2 épocas de treinamento	54
Figura 34 Matriz de Confusão (Conjunto de Teste) da CNN1 - 6 épocas de treinamento	55
Figura 35 Matriz de Confusão (Conjunto de Teste) da CNN2 - 2 épocas de treinamento	56
Figura 36 Matriz de Confusão (Conjunto de Teste) da CNN2 - 6 épocas de treinamento	56
Figura 37 - Matriz de Confusão (Conjunto de Teste) da CNN3 - 2 épocas de treinamento	57
Figura 38 - Matriz de Confusão (Conjunto de Teste) da CNN3 -6 épocas de treinamento	58
Figura 39 - Comparação entre as CNN's (Gráfico Acurácia x SNR)	59
Figura 40 - Gráfico do processo de treinamento CNN1	64
Figura 41 - Gráfico do processo de treinamento CNN2	66
Figura 42 - Gráfico do processo de treinamento CNN3	67

Tabela 1 - Taxas de FP das CNNs ($\text{SNR} \geq 0\text{dB}$)	60
Tabela 2- Taxas de FP das CNNs ($-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$)	61
Tabela 3 - Taxas de FP das CNNs ($\text{SNR} \leq -10\text{dB}$)	61
Tabela 4 – Resultado das Métricas de Avaliação.....	63

AGE	Atividades de Guerra Eletrônica
AWGN	<i>Additive White Gaussian Noise</i>
CGE	Capacidade de Guerra Eletrônica
CNN	Rede Neural Convolucional
CW	Onda Contínua
CWR	Radar de Onda Contínua
EEM	Espectro Eletromagnético
ELINT	<i>Electronic Intelligence</i>
FFT	<i>Fast Fourier Transform</i>
FMCW	<i>Frequency Modulation Continuous Wave</i>
FMOP	<i>Frequency Modulation on Pulse</i>
GE	Guerra Eletrônica
IA	Inteligência Artificial
IPqM	Instituto de Pesquisas da Marinha
LFM	<i>Linear Frequency Modulation</i>
LPI	<i>Low Probability of Intercept</i>
MAGE	Equipamentos de Medidas de Apoio a Guerra Eletrônica
MATLAB	<i>Software de computação numérica da empresa Mathworks Inc</i>
MB	Marinha do Brasil
MGE	Medidas de Guerra Eletrônica
MOP	<i>Modulation on Pulse</i>
PMOP	<i>Phase Modulation on Pulse</i>
PR	<i>Pulsed Radar</i>
PRF	Frequência de Repetição de Pulsos
PRI	<i>Pulse Repetition Interval</i>
PW	Largura de Pulso
ReLU	<i>Rectified Linear Unity</i>
RETRON	Reconhecimento Eletrônico
RF	Radiofrequência
SNR	Razão Sinal-Ruído
STFT	<i>Short-Time Fourier Transform</i>

LISTA DE SÍMBOLOS

A	Amplitude
B	Largura de banda
dB	Decibéis
e	Número de Euler ou neperiano
exp	Função exponencial natural (base e o número de Euler)
f_c	Frequência da portadora
$f(x)$	Função definida por x
FP	Quantidade de falsos-positivos
FN	Quantidade de falsos-negativos
L	Representação da ordem do código P1 e P2
M	Razão de compressão
N	Número de estados ou mudanças de fase
PW	Largura de pulso
Rect (t/τ)	Função retangular com PW igual a τ
$s(t)$	Sinal no domínio do tempo
t	Tempo
t_s	Período de amostragem
T	Período do código
VP	Quantidade de verdadeiros-positivos
VN	Quantidade de verdadeiros-negativos
[]	Função <i>floor</i>
$\emptyset_k$	Fase do sinal ($\emptyset_{Frank}, \emptyset_{P1}, \emptyset_{P2}, \emptyset_{P3}, \emptyset_{P4}, \emptyset_{T1}, \emptyset_{T2}, \emptyset_{T3}, \emptyset_{T4}$)

SUMÁRIO

1 INTRODUÇÃO	1
1.1 Contextualização.....	1
1.2 Apresentação do Problema	2
1.3 Justificativa e Relevância	4
1.4 Objetivos.....	4
1.4.1 Objetivo Geral	4
1.4.2 Objetivo Específico	5
1.5 Estruturação do trabalho.....	5
2 REFERENCIAL TEÓRICO	5
2.1 Guerra Eletrônica.....	6
2.1.1 MAGE	6
2.1.2 MAGE com Receptor Digital	7
2.1.3 Reconhecimento Eletrônico (RETRON)	7
2.2 RADAR.....	8
2.2.1 Radar CW	8
2.2.2 Radar Pulsado	9
2.3 Modulação Intrapulso	9
2.3.1 Modulação Linear em Frequência (LFM – <i>Linear Frequency Modulation</i>).....	10
2.3.2 Códigos Barker	11
2.3 Polifásicos: P1, P2, P3, P4 e Frank.....	12
2.3.4 Códigos Politemporais: T1, T2, T3 e T4	15
2.4 Inteligência artificial	16
2.4.1 Rede Neural	18
2.4.2 CNN (Convolutional Neural Network) - Rede Neural Convolucional	19
2.4.3 Camada de Convolução	20
2.4.4 Camada de Pooling	22
2.4.5 Fully Connected Layer	23
3 METODOLOGIA.....	24
3.1 Quanto aos fins	25
3.2 Quanto aos meios.....	25
3.3 Quanto à natureza do método	26
3.4 Limitações do método.....	26

3.5 Coleta e tratamento dos dados	26
4 ALGORITMO DE CLASSIFICAÇÃO UTILIZADO	27
4.1 Classificador baseado na Rede Neural CNN.....	27
4.2 Rede Neural - CNN1.....	28
4.3 Rede Neural - CNN2.....	30
4.4 Rede Neural - CNN3.....	30
4.5 Comparação das Arquiteturas	31
5 SIMULAÇÕES E ANÁLISE DOS RESULTADOS	31
5.1 Resultados do Classificador baseado na Rede Neural CNN1.....	35
5.2 Resultados do Classificador baseado na Rede Neural CNN2.....	41
5.3 Resultados do Classificador baseado na Rede Neural CNN3.....	47
5.4 Resultados do Classificador para CNN com 6 (seis) épocas de treinamento	53
5.5 Comparação entre as CNN's - Acurácia x SNR	58
5.6 Comparação entre as CNN – Taxa de Falso Positivo (FP)	60
5.7 Métricas de avaliação	62
5.8 Processo de treinamento	63
6 CONCLUSÃO.....	68
6.1 Sugestões para trabalhos futuros	69
REFERÊNCIAS	71

1 INTRODUÇÃO

Este trabalho aborda o contexto da Guerra Eletrônica (GE), destacando sua evolução histórica desde os primeiros conflitos em que o espectro eletromagnético passou a ser explorado como meio de vantagem tática e estratégica. Tal abordagem permite compreender a crescente importância da GE no cenário militar contemporâneo. Um dos principais desafios enfrentados atualmente é a classificação eficiente de sinais radar modulados, especialmente devido à crescente complexidade e sofisticação dos radares modernos. Nesse contexto, destaca-se o papel da Inteligência Artificial (IA), cuja aplicação tem se mostrado promissora para aprimorar as capacidades das Medidas de Apoio à Guerra Eletrônica (MAGE) da Marinha do Brasil (MB), podendo oferecer soluções mais precisas e adaptativas para a classificação de sinais modulados. Nas seções subsequentes serão delineados os objetivos desta pesquisa, bem como suas etapas.

1.1 Contextualização

O contexto contemporâneo da Guerra Eletrônica tem suas raízes consolidadas no início do século XX, período em que o espectro eletromagnético foi efetivamente explorado como meio de obter vantagem tática em operações militares. A necessidade de detectar, interferir e proteger sistemas de comunicação e sensores impulsionou o desenvolvimento de tecnologias capazes de explorar o ambiente eletromagnético. Equipamentos como o sistema de radar *Chain Home*, desenvolvido pelos britânicos, e os sistemas de interferência eletrônica utilizados pelos alemães durante a Segunda Guerra Mundial marcaram o início da sistematização da GE como ferramenta essencial no combate aéreo e naval (Skolnik, 2008).

O avanço tecnológico ocorrido durante a Segunda Guerra Mundial não apenas consolidou a importância da GE como uma vantagem nos conflitos, mas também promoveu o surgimento de métodos mais refinados de coleta, análise e interpretação de sinais eletromagnéticos. Com a intensificação das tensões geopolíticas durante a Guerra Fria, observou-se uma rápida evolução dos sistemas de radar, que deixaram de atuar apenas como sensores de detecção para integrar redes complexas de vigilância e orientação de armamentos. As técnicas utilizadas nesses sistemas tornaram-se cada vez mais sofisticadas, exigindo constante inovação tecnológica para garantir superioridade tática e estratégica no campo de batalha diante de sinais cada vez mais complexos e furtivos (Jarpa, 2002).

No contexto da IA, ocorreu em 1956, a histórica Conferência de *Dartmouth*, na qual o termo “Inteligência Artificial” foi formalmente introduzido por cientistas como Minsky, Nathaniel Rochester, Claude E. Shannon e John McCarthy. A proposta central da conferência estabelecia que todo aspecto do aprendizado ou qualquer outra característica da inteligência pode, em princípio, ser descrito com tanta precisão que uma máquina pode ser feita para simulá-lo. Esse evento inaugurou oficialmente a busca por métodos computacionais capazes de replicar comportamentos inteligentes (Minsky, 1974).

Com o aprimoramento dos computadores com elevada capacidade de processamento e armazenamento de grandes volumes de dados, abriu-se caminho para a aplicação de algoritmos de IA em diversos setores da sociedade, inclusive no campo militar. De forma especial, técnicas de *Machine Learning* vêm sendo empregadas na GE para tarefas como reconhecimento de padrões, classificação de sinais e apoio à decisão automatizada em ambientes de ameaças múltiplas (Melvin; Scheer, 2013).

Neste contexto de acelerada evolução tecnológica e crescente complexidade do ambiente eletromagnético, o presente trabalho propõe a aplicação de técnicas de IA para a classificação de sinais de radar modulados. Tal abordagem visa contribuir para o desenvolvimento de soluções mais robustas, adaptativas e inteligentes no domínio da GE, contribuindo especialmente para as MAGE.

1.2 Apresentação do Problema

A guerra moderna tem como característica a integração entre os domínios físico, comunicativo e eletromagnético, sendo a GE o elemento de suma importância nessa configuração tática. A GE atua em todos os ambientes de combate, seja operações terrestres, navais, aéreas e espaciais. Estruturalmente, a GE é dividida em três áreas: Ataque Eletrônico (*Electronic Attack* – EA), Proteção Eletrônica (*Electronic Protection* – EP) e Apoio Eletrônico (*Electronic Support* – ES), conforme definido por Skolnik (2008). Na MB as Medidas de GE são divididas em três ramos: MAGE, Medidas de Ataque Eletrônico (MAE) e Medidas de Proteção Eletrônica (MPE) (Brasil, 2017). Essas áreas operam de forma interdependente ou conjunta para negar, explorar ou proteger o uso do espectro eletromagnético, sendo essencial para a superioridade tática. Em ambientes saturados por diversos sensores, a capacidade de interceptar, identificar, perturbar ou enganar sinais eletromagnéticos pode definir o êxito das missões. Nesse cenário, a superioridade na guerra moderna é diretamente proporcional ao domínio do

campo eletromagnético, na qual a GE atua como vetor de dissuasão, inteligência e controle, sendo cada vez mais potencializada por IA, através do uso de algoritmos de reconhecimento de padrões, principalmente contra radares de baixa probabilidade de interceptação.

Os radares de Baixa Probabilidade de Interceptação (LPI – *Low Probability of Intercept*) representam um grande desafio para os sistemas passivos, como os receptores MAGE, devido à sua capacidade de operar de maneira furtiva no espectro eletromagnético (Pace, 2009). Esses radares são projetados para reduzir ao máximo sua detectabilidade, empregando técnicas como agilidade em frequência, modulações complexas, baixa densidade de potência espectral, formas de onda não repetitivas e transmissão direcional com feixes estreitos. Essas características dificultam a detecção passiva, pois o sinal emitido se encontra mascarado em meio ao ruído de fundo, exigindo receptores de alta sensibilidade, ampla largura de banda e capacidade de processamento em tempo real (Melvin; Scheer, 2013). Para os sistemas MAGE, cuja missão é buscar, interceptar, classificar e identificar sinais de radar, os radares LPI impõem limitações significativas, especialmente nas fases de detecção e de classificação de sinais. A baixa relação sinal-ruído (SNR), a aleatoriedade espectral e o comportamento dinâmico dos emissores dificultam a estimação precisa de parâmetros como frequência, largura de pulso e repetição de pulso. Como destacam Melvin e Scheer (2013), enfrentar esse tipo de ameaça demanda o uso de técnicas avançadas de recepção, como detecção coerente assistida por IA, *deinterleaving* adaptativo e algoritmos de identificação baseados em *fingerprinting* eletromagnético. Assim, os radares LPI exigem MAGE cada vez mais sofisticados, sendo a aplicação de IA uma realidade praticamente mandatória. Um classificador eficiente para sinais de radar modulados pode ser desenvolvido utilizando Redes Neurais Convolucionais (CNNs – *Convolutional Neural Networks*), cuja arquitetura é adequada para a extração automática de características intrapulso (Pace, 2009).

Ao contrário dos métodos tradicionais de classificação, que dependem de pré-processamento, as CNNs são capazes de identificar padrões relevantes, a fim de melhorar a capacidade MAGE. Este trabalho emprega sinais radar simulados com diversos tipos de modulação em fase: o bifásico Barker; os Polifásicos P1, P2, P3, P4 e Frank; e os Politemporais T1, T2, T3 e T4. Além desses, um tipo muito empregado de modulação em frequência, a Linear Frequency Modulation (LFM), também incluído no estudo, que visa proporcionar informações sobre a eficácia desses algoritmos em cenários desafiadores

com baixa SNR. Outrossim, neste trabalho serão utilizadas três arquiteturas de CNN distintas, com o objetivo de comparar seus desempenhos na classificação de sinais radar modulados. A escolha por três arquiteturas visa avaliar a acurácia de diferentes configurações na extração de características relevantes dos sinais simulados. Por meio dessa abordagem comparativa, pretende-se identificar qual rede apresenta melhor eficiência na classificação dos sinais simulados, a fim de se obter um classificador com elevada acurácia.

1.3 Justificativa e Relevância

A crescente complexidade dos conflitos modernos, marcados pela integração entre os domínios dos ambientes territorial, informacional e eletromagnético, torna a elevada capacidade de GE indispensável para garantir a superioridade tática e estratégica. Em especial, o domínio da tecnologia de radares LPI por outras nações, amigas ou inimigas, representam um desafio crítico para os sistemas de recepção passiva, como os receptores MAGE, uma vez que esses emissores empregam técnicas avançadas de ocultação espectral para dificultar sua classificação e identificação. Essa ameaça crescente exige a adoção de soluções tecnológicas inovadoras que superem as limitações dos métodos de classificação de sinais mais difundidos na literatura.

Sendo assim, a aplicação de IA, com destaque para o uso CNNs, surge como uma abordagem promissora. As CNN's são capazes de extrair automaticamente padrões eletromagnéticos de sinais radar modulados. A utilização dessas técnicas pode representar uma importante evolução para os sistemas MAGE, conferindo-lhes maior eficiência e eficácia em operações navais.

A relevância deste tema está no desafio tecnológico enfrentado pela Marinha do Brasil frente ao nível de tecnologia cada vez mais sofisticado e inovador no teatro de operações navais. Além disso, contribui para o avanço de soluções de defesa mais eficazes, eficientes e inteligentes.

1.4 Objetivos

Os objetivos gerais e específicos são apresentados nas Subseções 1.4.1 e 1.4.2 a fim de fornecer uma visão específica do propósito e do foco desta pesquisa.

1.4.1 Objetivo Geral

Contribuir para a compreensão das aplicações de técnicas de IA na classificação de sinais radar modulados, abrindo novos horizontes para o avanço das MAGE na Marinha do Brasil ao conduzir uma análise comparativa da eficácia de um algoritmo de classificação baseado em Aprendizado de Máquina.

1.4.2 Objetivo Específico

Testar a implementação de um algoritmo de classificação de sinais radar modulados que utilizam as técnicas de CNN, sendo utilizado três tipos de arquitetura, chamadas neste trabalho de CNN1, CNN2 e CNN3. Os resultados obtidos a partir de simulações realizadas com o *software* MATLAB, serão analisados para determinar qual das três CNN's utilizadas neste trabalho é a mais adequada para identificar as classes dos sinais modulados testados a partir de uma base de dados simulada. Ao final, com base na acurácia, pretende-se apresentar um classificador de sinais radar modulados eficiente, contribuindo para a possível aplicação dessas técnicas em cenários reais.

1.5 Estruturação do trabalho

Este trabalho está dividido em seis capítulos. O primeiro introduziu o contexto do cenário da Guerra Eletrônica ao longo de sua história até os dias atuais e apresenta a motivação da abordagem do tema e o propósito do estudo. O capítulo 2 aborda o embasamento teórico dos conteúdos necessários para a compreensão do tema, como as definições de Guerra Eletrônica e MAGE, e explicações sobre radar, dos problemas encontrados na classificação de sinais, Inteligência Artificial e dos tipos de modulação de sinais abordados. No capítulo 3, a metodologia do trabalho é abordada, sendo apresentada a maneira como foram realizados a coleta e o tratamento dos dados utilizados. O quarto capítulo apresenta uma explicação detalhada do classificador utilizado no estudo. No capítulo 5, estão dispostas as análises das simulações realizadas no *software* MATLAB por meio dos resultados obtidos com as matrizes de confusão de cada Rede Neural. Ao final, o sexto capítulo apresenta uma conclusão e apresenta sugestões para futuros trabalhos relacionados ao assunto.

2 REFERENCIAL TEÓRICO

Neste capítulo serão apresentados conceitos teóricos relevantes e que norteiam a elaboração do referido trabalho.


2.1 Guerra Eletrônica

De acordo com o Ministério da Defesa, a GE é o conjunto de ações coordenadas que têm como objetivo explorar as emissões eletromagnéticas do inimigo, em toda a extensão do espectro, para obter informações sobre sua ordem de batalha, intenções e capacidades. Ao mesmo tempo, envolve o emprego de medidas destinadas a impedir o uso eficaz dos sistemas adversários, garantindo, de forma discreta e eficiente, o funcionamento e a utilização dos sistemas próprios.

Segundo Brasil (2017), a eficácia da GE está diretamente ligada à Capacidade de Guerra Eletrônica (CGE), esta é a soma de todos os meios e recursos, humanos, tecnológicos e logísticos, que possibilitam ao poder naval, terrestre e aéreo conduzirem, de maneira integrada e eficiente, ações de GE. Quando bem estruturada, essa capacidade assegura que a força militar possa explorar o espectro eletromagnético em favor das operações de guerra, obtendo vantagens táticas e estratégicas.

A CGE é dividida em Atividades de Guerra Eletrônica (AGE) e Medidas de Guerra Eletrônica (MGE), conforme apresentado na Figura 1.

Figura 1- Estrutura de Guerra Eletrônica na MB.



Fonte: (Brasil, 2003).

O foco deste trabalho está nas técnicas de MAGE, que é um ramo das MGE.

2.1.1 MAGE

MAGE são descritas como o conjunto de ações visando à busca, interceptação e localização das fontes de energia eletromagnética irradiada no ambiente eletrônico de

uma Força ou Unidade, a fim de permitir a análise, o imediato reconhecimento de uma ameaça ou sua posterior exploração (MB, 2016a).

Os principais parâmetros intrapulso medidos pelo MAGE são: frequência, fase, largura de banda, amplitude máxima, presença de modulação, ângulo de chegada e largura de pulso (Pace, 2009). Com exceção do MAGE Defensor Mk3 que estima de maneira simples o tipo de modulação intrapulso através do seu receptor digital, os demais MAGE da MB não realizam a estimação do tipo de modulação intrapulso, sendo esse parâmetro um dado importante a mais para auxiliar a identificação de radares inimigos.

A MB emprega os sistemas MAGE em diversas plataformas, incluindo navios escolta, como as fragatas e corvetas, navios-patrolha oceânicos, e submarinos. Um exemplo de sistema empregado é o MAGE Defensor, com tecnologia nacional e projetado pelo Instituto de Pesquisas da Marinha (IPqM). O MAGE Defensor Mk3 possui receptor digital com capacidade de detecção de sinais radar do tipo LPI e gravação de Inteligência Eletrônica (ELINT), que é a Inteligência decorrente de transmissões eletromagnéticas de não comunicações, tais como as produzidas por radares, por sistemas de orientação de mísseis, *lasers*, dispositivos infravermelhos ou qualquer outro equipamento que produza emissões no espectro eletromagnético, ao comparar informações sobre os parâmetros da emissão que foi interceptada com assinaturas de equipamentos armazenados em uma base de dados, pode ser obtido valioso conhecimento sobre o equipamento, seu operador e detecção de sinais radar do tipo LPI (MB, 2003).

2.1.2 MAGE com Receptor Digital

Os sistemas MAGE que possuem receptores digitais (DRX) se destacam por sua capacidade de realizar funções ELINT intrapulso, devido à sua conversão analógico digital de alta velocidade permite a aplicação de processamento de sinais digitais para extrair mais características dos sinais radar e montar uma biblioteca de emissores mais singular em informação. Essa combinação permite uma performance superior na detecção de sinais com baixa SNR, tornando esses sistemas ideais para a interceptação de sinais radares LPI e radares com modulações intrapulso de fase e de frequência (Pace, 2009).

Este trabalho irá testar a classificação de sinais de baixa potência, de forma semelhante aos sinais dos radares LPI.

2.1.3 Reconhecimento Eletrônico (RETRON)

O RETRON, integrante das AGE, tem como finalidade principal fornecer apoio à fase de planejamento das operações, através da coleta e análise de dados dos sensores e equipamentos radar do inimigo, obtidas principalmente através do sistema MAGE (MB, 2003). De acordo com Brasil (2017), o RETRON assume caráter estratégico quando empregado para orientar o planejamento e o controle da CGE, e caráter tático quando utilizado diretamente no planejamento de uma operação naval, situação em que o valor das informações obtidas está diretamente relacionado ao teatro de operações navais. A classificação do tipo de modulação intrapulso é mais uma informação que pode ser acrescentada e utilizada pela MAGE da MB.

2.2 RADAR

O RADAR, acrônimo de *Radio Detection and Ranging*, é um sistema que utiliza ondas eletromagnéticas para detectar, localizar e rastrear objetos à distância, mesmo sob condições adversas de visibilidade. Seu princípio de funcionamento baseia-se na emissão de um sinal de radar que, ao encontrar um obstáculo ou alvo, é refletido de volta para o sistema, permitindo a medição de parâmetros como distância, velocidade e marcação do objeto. O radar mede o tempo de ida e volta do pulso eletromagnético e, conhecendo a velocidade da luz, é possível calcular a distância do alvo com alta precisão (Skolnik 2008).

Além da detecção convencional, os radares atuais operam em múltiplas bandas de frequência, com diferentes formas de onda e modos de operação, pulsado, onda contínua (CW), Doppler, entre outros, adaptando-se muito bem as plataformas navais. Melvin e Scheer (2013) explicam que os radares de varredura eletrônica ativa (AESA), por exemplo, utilizam arranjos de antenas com controle digital de fase, eliminando partes móveis e permitindo rastreamento simultâneo de múltiplos alvos com agilidade e precisão, esse tipo de radar é empregado nos navios das marinhas de guerra mais desenvolvidas.

A evolução dos sistemas radar foi impulsionada por avanços em processamento digital e o uso de IA nos sistemas radar pode ser promissor, o domínio dessas tecnologias incrementam a Capacidade de Guerra Eletrônica dos meios navais.

2.2.1 Radar CW

O radar de onda contínua, conhecido como radar CW (*Continuous Wave*), é um tipo de sistema de radar que transmite sinais eletromagnéticos de forma constante, sem

interrupções, diferentemente dos radares pulsados que operam alternando entre transmissão e recepção. Essa característica permite ao radar CW detectar variações de frequência nos ecos recebidos, possibilitando a medição precisa da velocidade radial dos alvos com base no efeito *Doppler*, e sua posição angular, mas não permite, por si só, a determinação da distância ao alvo, já que não há uma referência temporal clara do início do pulso (Skolnik, 2008).

Para superar essa limitação, foi desenvolvido o radar CW modulado em frequência, também chamado de FMCW (*Frequency Modulated Continuous Wave*). De acordo com Skolnik (2008), o radar FMCW transmite um sinal cuja frequência varia continuamente com o tempo, normalmente de forma linear como um *chirp*, sinal cuja frequência varia continuamente ao longo do tempo. A diferença de frequência entre o sinal transmitido e o recebido permite calcular o tempo de atraso, e, portanto, a distância ao alvo.

2.2.2 Radar Pulsado

Os radares pulsados são sistemas que operam transmitindo pulsos curtos e intermitentes de ondas eletromagnéticas, seguidos por períodos de escuta em que o receptor aguarda o eco refletido por um alvo. Esse tipo de operação permite a medição precisa da distância ao alvo, com base no tempo decorrido entre a emissão do pulso e o recebimento de seu reflexo. Essa técnica é fundamental para a maioria dos radares de vigilância, controle de tráfego aéreo e aplicações militares, por possibilitar a cobertura de grandes distâncias e a determinação da localização tridimensional do alvo (alcance, azimute e elevação), chamados de radares 3D (Skolnik 2008).

O desempenho de um radar pulsado depende de parâmetros como largura de pulso, frequência de repetição de pulsos e potência de pico. Pulsos mais longos fornecem maior energia, possibilitando o aumento do alcance radar, mas comprometem a resolução. Para contornar essa limitação, são utilizadas técnicas como compressão de pulso, que permitem aliar alta energia transmitida com boa resolução em distância, por meio de modulações intrapulso (Skolnik, 2008).

2.3 Modulação Intrapulso

A modulação intrapulso é uma técnica na operação de radares pulsados, consistindo na aplicação de uma modulação ao sinal transmitido com o objetivo de melhorar o desempenho do radar em termos de resolução de distância e resiliência a ruído.

Ao invés de transmitir um pulso de envoltória constante e frequência fixa, o radar modula parâmetros como frequência e fase ao longo da duração do pulso. Essas modulações permitem aumentar a largura de banda efetiva do sinal sem mudar a energia total transmitida, melhorando estimativa da distância do alvo (Barbosa *et al.*, 2022).

Entre as técnicas mais utilizadas destacam-se a modulação linear em frequência, que gera um *chirp* com variação progressiva da frequência, as modulações codificadas em fase, como os códigos de Barker, Frank e os polifásicos P1–P4. Essas técnicas possibilitam a compressão do pulso no receptor por meio de filtros casados, o que resulta em uma resposta impulsiva mais estreita e com menor nível de lóbulos laterais, aumentando a capacidade de discriminar alvos próximos. Ademais, a modulação intrapulso também pode dificultar a interceptação, a classificação e a identificação do sinal por receptores passivos quando a SNR é baixa (Ghadimi *et al.*, 2020).

2.3.1 Modulação Linear em Frequência (LFM – *Linear Frequency Modulation*)

A modulação linear em frequência, LFM, é uma das técnicas utilizadas em sistemas de radar devido à sua capacidade de melhorar significativamente a resolução em distância sem modificar a energia total do pulso transmitido. Essa técnica consiste na variação linear da frequência instantânea de um sinal em relação ao tempo durante a transmissão de um único pulso, gerando um sinal *chirp*. Essa variação contínua permite que um pulso relativamente longo no tempo seja comprimido no receptor por meio de um filtro casado, produzindo uma resposta estreita no domínio temporal, o que equivale a uma resolução em distância semelhante à de um pulso curto (Wang; He, 2018).

Em radares tradicionais sem modulação intrapulso, há um compromisso entre resolução e energia: pulsos curtos proporcionam boa resolução, mas transportam menos energia, enquanto pulsos longos têm mais energia, mas baixa resolução. A LFM resolve esse dilema ao permitir que o pulso seja longo e, portanto, com alta energia, mas ainda assim comprimido na recepção, alcançando alta resolução. Essa compressão pode ser realizada com o auxílio de técnicas de processamento digital, baseadas na correlação entre o sinal recebido e uma réplica do sinal transmitido, ou com o uso de um filtro casado (Patel *et al.*, 2012).

A modelagem matemática da LFM envolve um sinal cuja frequência instantânea varia linearmente com o tempo, gerando uma largura de banda proporcional à taxa de varredura da frequência. A resolução em distância obtida é inversamente proporcional à

largura de banda efetiva do sinal, de modo que quanto maior a é banda, melhor é a capacidade de resolução em distância (Chilukuri, Kakarla e Subbarao, 2020).

O Pulso LFM é definido pela equação 1:

$$x(t) = A \cdot \text{rect}\left(\frac{1}{T}\right) \cdot \cos(2\pi f_0 t + \pi \alpha t^2) \quad (1)$$

Tal que a função *rect* define a duração do pulso, sendo f_0 a frequência da portadora, “A” a amplitude do pulso e “ α ” é o *slope* do *chirp*, que é a taxa de variação da frequência instantânea em função do tempo. A frequência instantânea varia linearmente com o tempo, conforme apresentado na equação 2:

$$f_i(t) = f_0 \pm \alpha t = f_0 \pm \frac{B}{T} t, |t| \leq \frac{T}{2} \quad (2)$$

Tal que B é a largura de banda instantânea do sinal, e $\frac{B}{T}$ a taxa de variação da frequência.

2.3.2 Códigos Barker

Os códigos Barker são sequências binárias utilizadas na modulação de fase de sinais de radar com o objetivo de melhorar a compressão de pulso, reduzindo os lóbulos laterais na resposta do filtro casado. Essas sequências são formadas por números -1 e +1 que representam, respectivamente, saltos de fase de 0° e 180°, aplicados na transição entre os subpulsos (componente interno de um pulso de radar que resulta da aplicação de técnicas de modulação intrapulso), também denominados *chirps*, de um sinal codificado em fase. A principal propriedade dos códigos Barker é que sua função de autocorrelação apresenta o menor valor máximo de lóbulos laterais fora do lóbulo principal, o que resulta em uma maior capacidade de separação entre alvos próximos e menor interferência entre retornos consecutivos, como apresentado na figura 2 (Rohde Schwarz, 2020).

Figura 2 - Efeito da minimização dos lóbulos laterais (sidelobes).



Fonte: ROHDE SCHWARZ (2020).

De acordo com Rohde Schwarz (2020), os códigos Barker são particularmente úteis em sistemas de radar de curto alcance, radares táticos e sensores que operam em ambientes ruidosos, justamente por sua simplicidade de implementação e desempenho satisfatório. O autor observa ainda que essas sequências existem apenas para alguns comprimentos específicos, sendo o maior código Barker conhecido o de comprimento 13, conforme representado na figura 3.

Figura 3 - Sequências de Códigos de Barker e seus respectivos níveis de lóbulo lateral em decibéis (dB).

Code Length	Code sequence	Sidelobe level (dB)
2	$++$ or $+-$	-6.0
3	$++-$	-9.5
4	$++-+$ or $++++-$	-12.0
5	$++++-$	-14.0
7	$++++--+-$	-16.9
11	$++++--+-$	-20.8
13	$+++++--+-$	-22.3

Fonte: ROHDE SCHWARZ (2020).

2.3 Polifásicos: P1, P2, P3, P4 e Frank

Os sinais polifásicos distinguem-se dos bifásicos pelo fato de apresentarem mais de dois estados possíveis de fase. De maneira semelhante ao que ocorre nos códigos Barker, o pulso transmitido é segmentado em intervalos de tempo de mesma duração. Dentro de cada segmento, a fase permanece constante, mas pode assumir valores diferentes ao passar de um intervalo para outro. Esses valores de fase são definidos por uma sequência discreta, que constitui o código polifásico responsável por caracterizar o sinal. Uma vez estabelecido esse código, ele é aplicado na modulação da fase de uma onda senoidal contínua (Vanhoy; Schucker; Bose, 2017).

No âmbito deste trabalho, as modulações polifásicas empregadas são descritas conceitualmente e, matematicamente, pelas Equações 3 a 7, conforme apresentado por Bektaş e Ergezer (2020, p. 138-139) e Ghadimi et al. (2020, p. 1181). Nessas equações, a fase ($\emptyset$) é expressa como função de parâmetros específicos, que determinam o comportamento da modulação.

Frank: O código Frank é o primeiro dentre os códigos polifásicos apresentados nesse trabalho, sendo construído a partir de uma aproximação em etapas de uma forma de onda do tipo LFM. Esse método consiste em dividir o pulso em segmentos discretos, nos quais são atribuídas fases específicas que reproduzem, de forma aproximada, a variação contínua de frequência característica da modulação linear em frequência. A fase de cada elemento do código é determinada pela equação 3:

$$\emptyset_{Frank} = \emptyset_{i,j} = \frac{2\pi}{M}(i-1)(j-1) \quad (3)$$

Tal que, M representa a ordem do código, i corresponde ao índice da linha e j ao índice da coluna da matriz de fases, i e j variam de 1 até $\sqrt{M}$. Essa formulação garante a distribuição sistemática das fases, possibilitando que o sinal gerado apresente propriedades de compressão temporal semelhantes às de um LFM contínuo.

- a) P1: O código P1 integra a família de códigos polifásicos derivados do LFM, sendo desenvolvido com o objetivo de superar algumas limitações do código Frank, sobretudo no que se refere à redução de lóbulos laterais e à melhoria das propriedades de compressão do pulso. Assim como no Frank, o P1 baseia-se na discretização de uma onda LFM, mas emprega uma formulação distinta para a atribuição das fases, introduzindo maior uniformidade espectral e desempenho aprimorado em aplicações radar. A fase de cada elemento do código P1 é definida pela equação 4:

$$\phi_{P1} = \phi_{i,j} = -\frac{\pi}{L}[L - (2j - 1)][(j - 1)L + (i - 1)] \quad (4)$$

Tal que, L representa a ordem do código, i corresponde ao índice da linha e j ao índice da coluna da matriz de fases, ambos possuem valor máximo igual a 1, isso ocorre porque o código foi desenvolvido com o objetivo de produzir baixos lóbulos laterais na autocorrelação. Essa formulação gera um arranjo sistemático de fases que assegura boa relação de compressão e maior robustez frente a ruídos e interferências, quando comparado ao código Frank.

b) P2:

$$\begin{aligned} \phi_{P2} = \phi_{i,j} &= \left[-\frac{\pi(L-1)}{2L} - \frac{\pi}{L}(i-1) \right] (L+1-2j) \\ &= -\frac{\pi}{2L} \cdot (2i-1-L) \cdot (2j-1-L) \end{aligned} \quad (5)$$

Em P2, também representa a ordem do código, porém deve-se atentar para o fato de que, neste caso, deve ser um número par [2,4,6...]. Isso ocorre porque o código foi desenvolvido com o objetivo de produzir baixos lóbulos laterais na autocorrelação.

c) P3:

$$\phi_{P3} = \phi_k = \frac{\pi}{M} \cdot (k-1)^2 \quad (6)$$

O código P3 representado pela equação 6, apresenta M como a razão de compressão, assim como em Frank. Já a variável k significa o número do segmento, que varia de 1 até M . Adicionalmente, $M = 64$ foi o valor escolhido tanto em P3 quanto em P4 nesta pesquisa.

d) P4:

$$\phi_{P4} = \phi_k = \frac{\pi}{M} \cdot (k-1)^2 - \pi(k-1) \quad (7)$$

A equação 7 define P4, que é gerado de forma semelhante a P3, mas faz uso de outra regra para determinar os estados de fase. As variáveis k e M possuem o mesmo significado explicado na modulação P3.

2.3.4 Códigos Politemporais: T1, T2, T3 e T4

Os sinais Politemporais são semelhantes aos sinais polifásicos no sentido de que são gerados a partir de um código que se assemelha a uma forma de onda em degraus ou com modulação linear em frequência. No caso dos códigos politemporais, existe um número fixo de estados de fase, e o tempo gasto em cada estado é variado ao longo do pulso. Os códigos implementados são os códigos T1, T2, T3 e T4, descritos a seguir de acordo com Choi e Willians (1989).

a) T1: O código T1 é gerado pela aproximação da forma de onda de frequência escalonada, onde o segmento inicial é zero (Equação 8). A operação $\text{mod}(x,P)$ faz parte de uma área da matemática denominada aritmética modular. Essa operação gera como resultado o resto obtido com a divisão de x por P . Outrossim, os símbolos “[]” representam a função *floor*, isto é, uma operação matemática de arredondamento que retorna o maior número inteiro menor que o valor obtido na resposta. A variável N é a quantidade de fases e T é o período do código (que é igual à largura de pulso). Adicionalmente, $j \in [0, k-1]$ e é o resultado da operação $j = \left\lfloor \frac{i \cdot t_s}{PW} \cdot k \right\rfloor$, em que PW é a largura de pulso em segundos e t_s e o período de amostragem. A variável k , presente nas Equações 8 e 9, é o número de segmentos. Além disso, o número de mudanças de fase depende de k , tal que $k = 4$ representam 12 mudanças de fase.

$$\phi_{T1}(t) = \text{mod} \left\{ \frac{2\pi}{n} \left\lfloor (kt - jt) \cdot \frac{jn}{T} \right\rfloor, 2\pi \right\} \quad (8)$$

b) T2: O código T2 é gerado de forma semelhante ao código T1, por meio da aproximação de uma forma de onda com frequência em degraus. Quando se utiliza um número ímpar de segmentos k , a frequência zero corresponde ao segmento central; quando k é par, a frequência zero estará entre os dois segmentos centrais. A equação 9 descreve a fase do código T2 da seguinte forma:

$$\phi_{T2}(t) = \text{mod} \left\{ \frac{2\pi}{n} \left\lfloor (kt - jt) \cdot \frac{2j - k + 1}{T} \cdot \frac{n}{2} \right\rfloor, 2\pi \right\} \quad (9)$$

c) T3: O código T3 é gerado de maneira diferente dos dois códigos politemporais anteriores. É obtido por meio da aproximação de uma forma de onda com modulação linear em frequência, que possui batimento zero em sua borda inicial, ao invés de utilizar uma forma de onda com frequência em degraus. Conforme representado pela equação 10.

$$\phi_{T3}(t) = \text{mod} \left\{ \frac{2\pi}{n} \left\lfloor \frac{nBt^2}{2T_p} \right\rfloor, 2\pi \right\} \quad (10)$$

Tal que, B a largura de banda da modulação e T_p é o período da modulação.

d) T4: O código T4 é gerado de forma conceitualmente semelhante ao código T3, foi projetado para minimizar os lóbulos laterais. A equação 11 descreve a fase do código T4.


$$\phi_{T4}(t) = \text{mod} \left\{ \frac{2\pi}{n} \left\lfloor \frac{nBt^2}{2T_p} - \frac{nBt}{2} \right\rfloor, 2\pi \right\} \quad (11)$$

2.4 Inteligência artificial

O termo “Inteligência Artificial” foi cunhado em 1956 por John McCarthy, durante o *Dartmouth Summer Research Project on Artificial Intelligence*, evento que marcou oficialmente o início da área. A partir disso, ocorreram alguns avanços, como aprendizado de máquina, demonstração de teoremas, reconhecimento de padrões, resolução de problemas preditivos, sistemas especialistas e processamento de linguagem (Awari, 2023).

Em 1957, o psicólogo americano Frank Rosenblatt apresentou o modelo do “*Perceptron*”, capaz de realizar reconhecimento por meio de “neurônios” artificiais. Essa capacidade de aprendizagem influenciou fortemente o desenvolvimento posterior das redes neurais e seus mecanismos de conexão (Awari, 2023).

Figura 4 - Modelo de um neurônio artificial (direita), inspirado na estrutura de um neurônio biológico (esquerda).



Fonte: Faceli *et al.* (2021).

A figura 4 apresenta uma analogia entre o neurônio biológico e o neurônio artificial utilizado em redes neurais. À esquerda, observa-se a estrutura de um neurônio biológico, composto por dendritos, responsáveis por receber os sinais de entrada; núcleo, que processa as informações; e axônio, que conduz o sinal de saída para outros neurônios. À direita, essa estrutura é representada de forma computacional: os inputs ($x_1, x_2, \dots, x_n$) correspondem aos estímulos recebidos pelos dendritos, cada um associado a um peso ($w_1, w_2, \dots, w_n$) que define sua importância. A soma ponderada dessas entradas mais o termo de *bias* (b) resulta em uma função linear (z), que é então transformada por uma função de ativação (f) para gerar a saída (y). Assim, o neurônio artificial busca imitar o comportamento do neurônio biológico, aprendendo a responder a padrões de entrada de forma adaptativa (Faceli *et al.*, 2021).

Desde os primeiros estudos em IA até os tempos atuais, houve uma grande evolução na capacidade de processamento dos computadores e na capacidade de armazenamento dos *datas centers*, os quais contribuíram para o aumento significativo da quantidade de informações produzidas e processadas. Além disso, a melhoria das técnicas, tanto em arquitetura de *hardware*, quanto em algoritmos de *software*, permitiu reduzir o tempo do processo de treinamento que duravam meses e passaram a ser concluídos em poucos dias ou até minutos. Classificação é o processo de atribuição de rótulos ou categorias predefinidas a instâncias de dados com base em suas características ou

atributos. No contexto de aprendizado de máquina supervisionado, um modelo de classificação é treinado a partir de um conjunto de dados rotulado, aprendendo a relação entre as entradas (características) e as saídas (classes). Após o treinamento, o modelo é capaz de inferir a classe de novas amostras desconhecidas. Em aplicações de Guerra Eletrônica, por exemplo, a classificação pode ser utilizada para identificar o tipo de modulação de um sinal radar a partir de representações no domínio tempo-frequência, permitindo distinguir entre modulações como Barker, Frank, LFM, P1, entre outras (Ghadimi *et al.*, 2020).

Em trabalhos que utilizam IA, diversas definições e métricas são utilizadas para avaliar o desempenho e a confiabilidade dos modelos desenvolvidos. Essas métricas permitem quantificar o grau de acerto, erro e generalização das soluções propostas, sendo fundamentais para a comparação entre diferentes abordagens (Ghadimi *et al.*, 2020).

O Verdadeiro Positivo (VP) representa as instâncias corretamente classificadas como pertencentes à classe positiva. Em suma, ocorre quando o modelo identifica corretamente um evento que realmente pertence à classe em questão (Ghadimi *et al.*, 2020).


O Falso Positivo (FP) ocorre quando o modelo classifica erroneamente uma classe como positiva quando, na realidade, ela pertence à classe negativa. O Falso Negativo (FN), por sua vez, ocorre quando o modelo não reconhece uma instância que de fato pertence à classe positiva (Ghadimi *et al.*, 2020).

A acurácia é uma métrica global de desempenho que quantifica a proporção de classificações corretas realizadas pelo modelo em relação ao total de amostras analisadas (Ghadimi *et al.*, 2020).

2.4.1 Rede Neural

Uma rede neural artificial é composta por uma camada de entrada de neurônios, também chamados de nós, uma ou mais camadas ocultas de neurônios e uma camada final de saída (JEONG *et al.*, 2024). A Figura 5 apresenta uma arquitetura típica, na qual também são mostradas as linhas que conectam os neurônios. Cada conexão está associada a um valor numérico chamado peso.

Figura 5 - Estrutura de uma rede neural artificial, mostrando a camada de entrada, as camadas ocultas de processamento e a camada de saída.



Fonte: Rafael Sakurai (2021).

Uma rede neural construída dessa forma pode aproximar muitas funções não lineares com precisão. Os valores fornecidos aos neurônios da camada de entrada são as variáveis independentes, enquanto os valores produzidos pelos neurônios da camada de saída são as variáveis dependentes da função que a rede neural está aproximando. As entradas e saídas de uma rede neural podem ser binárias (como “sim” ou “não”) ou até símbolos (como “verde”, “vermelho”, etc.), desde que os dados sejam devidamente codificados. Essa característica garante uma ampla gama de aplicações para as redes neurais (Walencykowska; Kawalec; Krenc, 2023).

2.4.2 CNN (Convolutional Neural Network) - Rede Neural Convolucional

Poucas ideias tiveram tanto impacto quanto as redes neurais convolucionais. Essas redes foram introduzidas na década de 1990, quando os primeiros modelos foram desenvolvidos para reconhecer dígitos manuscritos e apresentaram resultados promissores (LeCun *et al.*, 1998).

No entanto, o grande potencial dessas redes só chamou a atenção da comunidade científica em 2012, durante o evento *ImageNet Large Scale Visual Recognition Challenge* (também conhecido como “competição *ImageNet* (LeCun *et al.*, 1998).

Naquele ano, Alex Krizhevsky, da Universidade de Toronto, foi pioneiro na aplicação desse tipo de rede a um desafio complexo, envolvendo a classificação de 1,2 milhão de imagens de alta resolução distribuídas em 1000 categorias, por exemplo, abelha, tucano, *beagle* etc.

O modelo de CNN, chamado AlexNet, conquistou o primeiro lugar com uma taxa de erro de 16,4%, enquanto o segundo colocado apresentou desempenho significativamente inferior, com 26,2% de erro. Esse resultado colocou a CNN em evidência e provocou uma mudança de paradigma no campo da visão computacional (LeCun *et al.*, 1998).

Desde então, as pesquisas com CNNs cresceram exponencialmente. Em apenas três anos, os pesquisadores avançaram do AlexNet, com 8 camadas, para as redes residuais (*residual networks*) com 152 camadas, reduzindo a taxa de erro do desafio *ImageNet* para menos de 4%, refletindo a crescente sofisticação das arquiteturas de CNN (LeCun *et al.*, 1998).

A eficácia no processamento de imagem está relacionada a sua estrutura básica, dividida em Camadas Convolucionais, Camadas de *Pooling* e Camadas Completamente Conectadas (*Fully Connected*) (Walencykowska; Kawalec; Krenc, 2023).

2.4.3 Camada de Convolução


O componente essencial de uma CNN é a camada convolucional, responsável pela maior parte do processamento computacional. A camada convolucional contém um conjunto de filtros e sua função é realizar a operação de convolução entre esses filtros e a entrada da camada, gerando mapas de características (*feature maps*) (Li *et al.*, 2022).

Um filtro é uma matriz de números discretos e geralmente, possui formato quadrado. Seus parâmetros, os valores dessa matriz são ajustados durante o treinamento da rede e, quando aplicados a matriz de entrada, produzem os mapas de características, que são as características extraídas da matriz de entrada (Li *et al.*, 2022).

Inicialmente a CNN posiciona o filtro sobre a região superior esquerda da imagem e realiza um produto elemento a elemento entre os valores do filtro e os valores correspondentes na entrada, somando os resultados para obter um único valor, ou seja, executa um produto escalar (*dot product*) (Li *et al.*, 2022). Esse valor indica a presença

ou ausência de um padrão específico procurado pelo filtro naquela região da imagem, conforme apresentado na figura 6.

Figura 6 - Exemplo de operação de convolução, onde o filtro é aplicado aos dados de entrada para gerar o mapa de características (feature map).




Fonte: Li et al. (2022).

Em seguida, a convolução desliza o filtro para a direita e repete o cálculo do produto escalar na nova posição. Esse deslizamento do filtro (*filter sliding*) é realizado da esquerda para a direita e de cima para baixo sobre toda a matriz de entrada, permitindo aplicar o filtro em todas as posições da imagem. Matematicamente, a combinação do deslizamento do filtro e dos produtos escalares define a operação de convolução (Li et al., 2022).

Por fim, o mapa de características (*feature map*) armazena o resultado da operação de convolução, ou seja, o conjunto de valores obtidos em todos os produtos escalares. Esse armazenamento é feito em uma estrutura de grade espacial, preservando as relações espaciais presentes na entrada. Essa preservação é fundamental, pois as operações de convolução das camadas seguintes dependem diretamente dessas relações espaciais (Li et al., 2022).

Figura 7 - Exemplo de extração de características, onde a imagem de entrada é processada por filtros convolucionais que geram diferentes mapas de características (feature maps).




Fonte: Li et al. (2022).

A Figura 7 mostra mapas de características empilhados. Neste exemplo, a operação de convolução é aplicada à imagem de entrada várias vezes utilizando filtros diferentes, verde e vermelho, e cinza e cinza-claro na versão impressa. Cada filtro gera um mapa de características distinto, capaz de detectar diferentes padrões na imagem. Os mapas de características resultantes são então empilhados para formar a saída da camada (Li et al., 2022).

2.4.4 Camada de Pooling

O objetivo da camada de *pooling* é reduzir o tamanho espacial da representação capturada pela camada convolucional. Ela basicamente simplifica as informações coletadas e cria uma versão condensada dessas mesmas informações. A forma mais comum de *pooling* é o *max pooling*. A camada de *max pooling* desliza uma janela sobre sua entrada e seleciona o valor máximo dentro dessa janela, descartando todos os outros valores. De forma semelhante à camada convolucional, especifica-se o tamanho da janela (análogo ao tamanho do filtro) e o *stride*, que é o valor do deslocamento da janela sobre a matriz de entrada (Li et al., 2022).

Figura 8 - Exemplo da operação de max pooling, que reduz a dimensão do mapa de características selecionando o maior valor em cada região da matriz.




Fonte: Couvillle, Aaron. Deep Learning (2018).

A figura 8 ilustra a operação de *Max Pooling*, utilizada em CNNs para reduzir a dimensão dos mapas de características, mantendo apenas as informações mais relevantes. Nesse exemplo, uma janela de (2×2) percorre a matriz original com *stride* 2, e em cada região o maior valor é selecionado, resultando em uma nova matriz menor, onde cada elemento representa o valor máximo de sua região correspondente (Li et al., 2022).

2.4.5 Fully Connected Layer

A *Fully Connected Layer* (camada totalmente conectada) representa a etapa final das Redes Neurais Convolucionais, responsável por integrar as informações extraídas pelas camadas anteriores e realizar a classificação ou predição. Nessa camada, cada neurônio é conectado a todos os neurônios da camada anterior, o que possibilita a combinação global das características obtidas durante o processo de convolução e *pooling*. A operação em cada neurônio é realizada por meio de uma transformação linear, seguida de funções de ativação, permitindo que o modelo aprenda relações complexas entre os padrões extraídos e, assim, produza a saída final da rede, geralmente associada a categorias ou valores numéricos específicos (Li et al., 2022).

Figura 9 - Estrutura básica de uma rede neural convolucional (CNN), composta pelas etapas de extração de características (feature extraction), com camadas de convolução e pooling, e pela etapa de classificação com camadas totalmente conectadas (fully connected).



Fonte: SuperDataScience.

A figura 9 representa a estrutura básica de uma CNN, dividida em suas etapas principais: extração de características e classificação. Na última etapa, os dados extraídos são enviados para a *Fully Connected Layer*, responsável por combinar as características aprendidas e produzir a saída final, que corresponde à classe atribuída ao objeto analisado (Li et al., 2022).

3 METODOLOGIA

Este trabalho propõe a realização de uma análise comparativa entre três algoritmos de classificação baseados em técnicas de IA. A adoção da IA como suporte aos classificadores justifica-se por sua capacidade de generalização, que possibilita a eficiência classificatória mesmo em cenários de baixa SNR. Outrossim, a ampla literatura existente reforça a eficácia da IA na classificação de tipos de modulação em sinais de radar, consolidando a relevância da escolha metodológica deste estudo. O número de trabalhos nessa área evidencia a aptidão dessas técnicas para lidar com o problema específico da classificação de modulações.

Outro aspecto que fundamenta o uso de algoritmos de IA é o fato de que os modelos resultantes são de natureza estatística, construídos a partir dos dados observados, em contraste com os modelos teóricos, que geralmente assumem comportamentos físicos

ou idealizados. Assim, técnicas de *Machine Learning* e *Deep Learning* tendem a gerar modelos mais robustos frente a variações não previstas teoricamente.

Convém destacar que, nos três classificadores analisados, os sinais são previamente processados digitalmente para a extração de características antes da aplicação das técnicas de IA. Como exemplo, pode-se citar o uso do janelamento aplicado às amostras digitalizadas do sinal, etapa anterior ao cálculo da Transformada de Fourier de Tempo Curto (STFT), conforme detalhado na seção 4.1.

Em síntese, tais técnicas foram aplicadas não apenas para aprimorar a SNR do sinal recebido pela antena do radar, mas também para assegurar a adequada extração de informações relevantes.

Por fim, no que se refere aos classificadores utilizados neste trabalho, foram implementadas três arquiteturas distintas de Redes Neurais Convolucionais. Para alcançar os objetivos propostos, foram realizadas simulações no *software* MATLAB, aplicadas a uma base de dados composta por diferentes sinais de radar simulados, de modo a permitir a análise comparativa entre os algoritmos.

3.1 Quanto aos fins

Para a elaboração deste trabalho, foram empregados dois tipos distintos de pesquisa quanto aos fins. Em primeiro lugar, a pesquisa exploratória teve papel na definição dos conceitos relacionados à GE com foco em MAGE, bem como na caracterização das técnicas de IA utilizadas e dos sinais analisados. Em complemento, a pesquisa explicativa possibilitou uma descrição dos modelos e sistemas classificadores empregados, de modo a evidenciar as diferenças entre eles no processo de classificação dos sinais segundo os tipos de modulação considerados neste estudo.

3.2 Quanto aos meios

Em relação aos meios, os métodos de pesquisa adotados englobaram tanto a pesquisa experimental quanto a pesquisa bibliográfica. A pesquisa experimental consistiu na utilização do *software* MATLAB para a modelagem e análise do problema em questão, permitindo a realização de simulações e a avaliação dos classificadores propostos. Já a pesquisa bibliográfica envolveu a consulta e a análise de documentos, incluindo artigos científicos e publicações especializadas, os quais forneceram o embasamento teórico necessário para o desenvolvimento deste trabalho.

3.3 Quanto à natureza do método

Nesse contexto, foi adotada a pesquisa quantitativa, a qual se caracterizou pela definição das hipóteses a serem testadas, representadas pelas diferentes classes correspondentes aos tipos de sinais analisados, e pela execução de procedimentos sistemáticos de análise, utilizando algoritmos de classificação implementados no *software* MATLAB. Além disso, foi feita a análise da acurácia de cada algoritmo, obtida a partir das matrizes de confusão geradas.

3.4 Limitações do método

Ressalta-se que os sinais empregados neste estudo foram obtidos a partir de simulações, uma vez que não há disponibilidade em fonte aberta de informações detalhadas sobre radares militares estrangeiros.

Dessa forma, este estudo fundamenta-se em suposições a respeito das possíveis capacidades dos radares de diversas nações. Em virtude dessa limitação, optou-se por contemplar uma variedade de modulações de sinais pulsados já conhecidas. Isso implica que alguns dos tipos de modulação considerados não possuem confirmação de uso prático em radares estrangeiros, mas foram incluídos para fins de análise comparativa no contexto deste trabalho.

3.5 Coleta e tratamento dos dados

O método de análise apresentado neste trabalho envolve sinais radar com modulação de fase no pulso, *Phase Modulated On Pulse* (PMOP), Frank e sinais de modulação em frequência do tipo LFM, além de pulsos radar sem nenhum tipo de modulação. Quanto aos PMOP, a investigação se estendeu para o código Barker13, que é empregado no radar RTN-30X das Fragatas Classe “Niterói”, bem como para as modulações polifásicas (Frank, P1, P2, P3 e P4) e politemporais (T1, T2, T3 e T4). Além disso, este trabalho se apoia em três algoritmos diferentes desenvolvidos no MATLAB, que determinam, como saída, a classe do sinal de entrada.

Nas simulações, o número de amostras são 528.000. Ademais, os valores adotados para SNR foram os seguintes: [-25dB, -20dB, -18dB, -15dB, -13dB, -10dB, -8dB, -5dB, -3dB, 0dB, 3dB, 5dB, 10dB, 15dB]

Além disso, o ruído considerado foi um Ruído Gaussiano Branco Aditivo (AWGN, do inglês, *Additive White Gaussian Noise*). A densidade espectral de potência

do ruído é constante e a função densidade de probabilidades é uma distribuição normal. Ademais, para gerar sinais com diferentes valores de SNR, a potência do sinal é modificada e a potência do ruído é mantida constante. Para a largura de pulso (LP), foi adotado o valor de $10\mu s$. Para a frequência de amostragem, que é o inverso do período de amostragem, foi considerado 2.4GHz. Já a banda de frequências analisada foi de 120MHz a 200MHz e a f_c , frequência central dos pulsos simulados, igual a 160MHz.

Ressalta-se que o conjunto de dados é dividido em conjunto de treinamento e conjunto de testes. O primeiro, formado por 70% dos dados. O segundo, formado pelos dados restantes, 30% dos dados, são usados para verificar a eficiência de cada classificador (conjunto de testes). A divisão dos dados entre 70% e 30% é realizada para cada LP e cada SNR do conjunto de dados.

Outrossim, 33% dos dados do conjunto de treinamento formam o conjunto de validação, que não é utilizado para o ajuste de pesos, mas como um dos critérios de parada do treinamento. Os 67% restantes do conjunto de dados de treinamento são utilizados para o ajuste dos pesos das redes.

4 ALGORITMO DE CLASSIFICAÇÃO UTILIZADO

Neste estudo, o modelo de algoritmo empregado na tarefa de classificação dos sinais de radar modulados, previamente mencionados, será apresentado nas seções subsequentes.

4.1 Classificador baseado na Rede Neural CNN

Figura 10 - Classificador baseado na Rede Neural CNN.



Fonte: Elaborado pelo autor (2025).

A Figura 10 apresenta a arquitetura do classificador baseado em Rede Neural Convolucional. No sistema proposto, a janela de aquisição é formada pelas amostras digitalizadas a partir de um período de $220\mu s$. Sendo a LP do pulso igual a $10\mu s$, a janela

de aquisição será composta por $210\mu s$ de ruído e $10\mu s$ (pulso + ruído). O conjunto de dados é formado por 16.800 arquivos, sendo que cada arquivo contém amostras digitais do ambiente eletromagnético simulado em $220\mu s$. Para o processamento dessas amostras, utiliza-se a *Short-Time Fourier Transform* (STFT) com o *Frame* de 4096 e o *Hop* 1024, que converte o vetor de amplitudes da Janela de Aquisição em uma matriz bidimensional no domínio tempo–frequência. Esse procedimento possibilita visualizar a distribuição espectral do sinal ao longo do tempo, transformando os dados brutos em uma matriz tempo-frequência (Zhang et al., 2016)

Na etapa de extração do *Bounding Box* (caixa delimitadora mínima), realizada após a aplicação da STFT, procede-se a identificação da região de interesse na representação tempo-frequência. Essa região corresponde à área onde o sinal efetivamente se manifesta, caracterizada pelos valores de maior magnitude da transformada (Zhang et al., 2016).

Em seguida, na etapa de redimensionamento (*Resize*), a matriz obtida a partir da extração do *Bounding Box* é ajustada para um tamanho padronizado. Neste trabalho, utilizou-se o método *Nearest-Neighbour* para redimensionar o espectrograma para (128×128) , assegurando que todas as entradas da CNN tenham as mesmas dimensões. Assim, os valores da matriz resultante preservam a correspondência com os pontos mais próximos da matriz original. O método *Nearest-Neighbour* classifica uma nova amostra com base em sua proximidade (geralmente medida por uma distância métrica) em relação às amostras já conhecidas no conjunto de treinamento. A ideia central é que padrões semelhantes estão próximos no espaço de características (Wong; Schaack, 1982). A matriz redimensionada, com dimensão final de (128×128) , constitui a entrada da CNN representada na Figura 10.

Nas seções a seguir estão descritos em mais detalhes a arquitetura das redes CNN (CNN1, CNN2 e CNN3) que foram comparadas.

4.2 Rede Neural - CNN1

A arquitetura da primeira CNN aplica uma camada convolucional com um filtro de dimensão (7×7) , gerando 1 *feature map* na saída, sendo o *stride* utilizado nessa camada igual a 1. Essa etapa é responsável por detectar padrões da imagem, preservando o seu tamanho por meio do *padding same*. O *padding* é a técnica de adicionar bordas artificiais, normalmente preenchidas com zeros, em torno da imagem de entrada antes da aplicação de uma convolução. Essa etapa é amplamente utilizada em redes neurais convolucionais

para controlar o tamanho da saída e preservar informações da imagem (Eberman; Krohling, 2022).

Para melhorar a estabilidade e acelerar o treinamento, é utilizada uma *Batch Normalization Layer* (BNL), que acelera o processo de aprendizado e reduz a sensibilidade em relação à inicialização da rede (Eberman; Krohling, 2018).

A BNL é aplicada entre uma camada de convolução e uma camada não linear, nesse caso a ReLU (*Rectified Linear Unit*), que é uma das funções de ativação em redes neurais. Embora seja linear para todos os valores positivos, a ReLU retorna zero para valores negativos, o que a torna não linear (Eberman; Krohling, 2018).

Essa não linearidade é o que permite que redes neurais com várias camadas aprendam e modelem relações complexas nos dados, algo que uma rede composta apenas por funções lineares não conseguiria realizar (Eberman; Krohling, 2018).

Na sequência, aplica-se uma camada de *max pooling* (2×2) com *stride* igual a 2, que realiza o *down-sampling* do mapa de ativação, reduzindo suas dimensões para (64×64) e, simultaneamente, extraindo as características mais relevantes. O *down-sampling* consiste em manter apenas uma fração das amostras originais de um sinal discreto (Eberman; Krohling, 2018).

A mesma sequência de camadas é repetida: uma camada convolucional com filtros de tamanho (3×3), seguida por uma camada BNL e uma camada ReLU, finalizando com uma camada de *max pooling*.

A saída da camada de *max pooling* será de aproximadamente (32×32). Posteriormente, outra sequência de camadas semelhantes se segue: uma terceira camada convolucional de tamanho (3×3) é aplicada, acompanhada da camada de normalização BNL, de ativação ReLU e de *pooling*, com dimensão igual a camada de *pooling* da sequência anterior.

Na etapa final, uma rede *Fully Connected* é aplicada. Essa rede possui 12 neurônios na camada intermediária e 12 na de saída, onde cada neurônio da camada de saída corresponde a uma das 12 classes de modulação investigadas e testadas neste trabalho. (Barker, Frank, LFM, PW, P1, P2, P3, P4, T1, T2, T3 e T4). Por fim, a camada de normalização Softmax transforma os valores na saída dos 12 neurônios da última camada da rede Full Connected em valores de probabilidades. A camada de classificação, *Classification Layer*, define a classe da imagem de entrada como sendo a classe correspondente ao neurônio que gerou o maior valor de probabilidade.

4.3 Rede Neural - CNN2

A rede CNN2 apresentada nessa seção é semelhante à rede CNN1 detalhada na seção 4.2, porém, diferentemente da rede CNN1 que possui três sequências de camadas de convolução, BNL, ReLU, e *max pooling*, a rede CNN2 possui apenas duas sequências, além do fato de possuir dimensões de convoluções diferentes.

A CNN2 recebe como entrada as mesmas imagens obtidas no pré-processamento. A primeira camada convolucional utiliza um filtro de dimensão (3×3) , aplicado com *stride* de valor igual a 1 e *padding* configurado como *same*. Em seguida, é aplicada a BNL para estabilizar a distribuição dos dados, seguida da função de ativação ReLU.

Na sequência, ocorre a operação de *max pooling* (2×2) com *stride* de valor igual a 2, que realiza o *down-sampling*, resultando em um mapa de características de dimensão (64×64) . A mesma sequência de camadas se repete: uma segunda convolução é realizada, também com filtros de (3×3) , seguida da normalização com a camada BNL, uma camada de ReLU e novamente uma camada de *max pooling* de tamanho (2×2) , reduzindo a dimensão da matriz de entrada para (32×32) .

Na etapa final da CNN, uma rede *Fully Connected* é aplicada. Essa rede possui 12 neurônios na camada intermediária e 12 neurônios na camada de saída, onde cada neurônio da camada de saída corresponde a uma das 12 classes de modulação de fase investigadas e testadas neste trabalho. Por fim, a camada de normalização que transforma os valores na saída dos 12 neurônios da última camada da rede *Fully Connected* em valores de probabilidades. A camada de classificação, *Classification Layer*, define a classe da imagem de entrada como sendo a classe correspondente ao neurônio que gerou o maior valor de probabilidade.

4.4 Rede Neural - CNN3

A rede CNN3 apresentada nessa seção é semelhante as redes CNN1 e CNN2 detalhadas nas seções 4.1 e 4.2, porém, possui apenas uma sequência de camadas de convolução, BNL, ReLU, e *max pooling*. A ideia inicial era criar uma rede CNN mais simples para que o processamento dos cálculos durante o uso da rede fosse mais rápido, mantendo o desempenho de classificação alto.

A rede CNN3 recebe como entrada as mesmas imagens que as outras duas redes descritas nas seções 4.1 e 4.2.

A primeira e única camada convolucional aplica um filtro de tamanho (3×3) . O parâmetro *padding* configurado como *same* garante que a saída dessa convolução

mantenha o tamanho da entrada, evitando a perda de informações nas bordas, resultando em um *feature map* que passa por *Batch Normalization* e pela função de ativação *ReLU*.

Na sequência, aplica-se a operação de *max pooling* de tamanho (2×2) com *stride* igual a 2, que realiza o *downsampling* e reduz as dimensões da matriz de entrada para (64×64) , extraindo apenas as características mais relevantes. Após a etapa convolutiva, a rede conecta o mapa reduzido a uma rede *Fully Connected* com uma camada escondida com 12 neurônios e uma camada de saída com 12 neurônios também.

Por fim, a saída é processada e transforma os valores em probabilidades normalizadas, permitindo que a camada de classificação atribua o sinal de entrada à classe com maior probabilidade.

4.5 Comparação das Arquiteturas

As arquiteturas CNN1, CNN2 e CNN3 foram desenvolvidas para a classificação de 12 classes de modulação a partir de entradas no formato (128×128) , correspondentes às representações tempo-frequência.

A CNN1 caracteriza-se como a mais profunda entre as três, composta por três blocos convolucionais sucessivos, iniciando com um filtro de tamanho (7×7) seguido por dois filtros de tamanho (3×3) , todos com *padding* configurado como *same*. Essa configuração permite desenvolver uma rede que possui um melhor desempenho, entretanto demanda maior complexidade computacional.


A CNN2, por sua vez, apresenta profundidade intermediária, com apenas dois blocos convolucionais de tamanho (3×3) , que reduzem progressivamente as dimensões até (32×32) , proporcionando um equilíbrio entre desempenho e complexidade de processamento.

Já a CNN3 representa a arquitetura mais simples, com apenas uma convolução de tamanho (3×3) seguida de *pooling*, reduzindo as dimensões para (64×64) . Essa é a rede de menor complexidade computacional.

5 SIMULAÇÕES E ANÁLISE DOS RESULTADOS

Os gráficos apresentados na Figura 11 ilustram as amplitudes das amostras obtidas em uma janela de aquisição, nas quais estão presentes tanto o ruído quanto o sinal pulsado correspondente a cada tipo de modulação analisado neste trabalho. Para essa representação, as amostras foram extraídas de um ambiente eletromagnético simulado, configurado com uma relação SNR de 15 dB.


Figura 11 - Gráficos das amplitudes x tempo das amostras analisadas por tipo de modulação com SNR-15dB.



Fonte: Elaborado pelo autor (2025).

A Figura 11 demonstra que todos os sinais pulsados podem ser distinguidos do ruído de fundo, independentemente do tipo de modulação empregado. Contudo, quando o sinal captado pelo sistema MAGE apresenta baixa potência, seja em razão da grande distância em relação ao radar emissor ou em função da técnica de modulação utilizada, a diferenciação entre o pulso e o ruído torna-se mais complexa. Esse efeito é evidenciado na Figura 12, em que as modulações são apresentadas com uma SNR de -15 dB.


Figura 12 – Gráficos de amplitude x tempo com SNR -15 dB.



Fonte: Elaborado pelo autor (2025).

A STFT constitui uma ferramenta relevante para a análise desse tipo de sinal. Diferentemente da Transformada de Fourier clássica, que fornece apenas o espectro de frequências e de fase sem relação com o tempo, a STFT permite observar a evolução das componentes espectrais em frequência ao longo do tempo (Pei Huang, 2022). Essa característica é particularmente importante em aplicações que envolvem pulsos modulados, pois a representação tempo-frequência gerada pela STFT possibilita uma compreensão mais detalhada do comportamento espectral de cada modulação. A representação do sinal é ilustrada na Figura 13.


Figura 13 - Gráficos após aplicação da STFT SNR 15 dB.



Fonte: Elaborado pelo próprio autor (2025).

Além disso, ao fornecer espectrogramas nos quais diferentes modulações apresentam padrões de imagem distintos, a STFT permite extrair características discriminativas. Modulações Intrapulso, como as analisadas neste trabalho, que seriam de difícil distinção apenas nos domínios do tempo ou da frequência, passam a revelar assinaturas visuais próprias quando representadas no domínio tempo-frequência, mesmo em condições de baixa SNR, conforme ilustrado na Figura 14.

Figura 14 - Gráficos após aplicação da STFT.




Fonte: Elaborado pelo próprio autor (2025).

Essa propriedade viabiliza o uso de classificadores baseados em aprendizado de máquina, pois ao transformar sinais unidimensionais complexos em representações bidimensionais tempo-frequência, a STFT permite a aplicação direta de redes neurais convolucionais, convertendo dados temporais em padrões de imagem.

5.1 Resultados do Classificador baseado na Rede Neural CNN1

No classificador fundamentado na CNN1, os resultados obtidos a partir dos sinais utilizados nos conjuntos de treinamento em duas épocas e de teste são apresentados nas Figuras 15 a 20.


Os 16.800 sinais utilizados neste trabalho foram distribuídos em 1.400 para cada classe. Desse total, 8.820 sinais foram destinados ao conjunto de treinamento, 5.040 ao conjunto de teste e 2.940 ao conjunto de validação, para cada CNN. Assegurando uma divisão equilibrada para o processo de aprendizado e avaliação do modelo.

Figura 15- Matriz de Confusão (Conjunto de Treinamento) $\text{SNR} \geq 0\text{dB}$.

Fonte: Elaborado pelo autor (2025).

A Figura 15 apresenta a matriz de confusão dos dados do conjunto de treinamento referente ao cenário de $\text{SNR} \geq 0\text{ dB}$. A maior parte das classes obtiveram 100% de acurácia, incluindo Frank, LFM, Não Modulado, P1, P2, T1, T2 e T3. Os falsos negativos (FN) ficaram restritos às classes P3 (1,6%), P4 (1,9%) e T4 (1,9%), nas quais em sua maioria o classificador associou sinais da classe P3 à classe LFM, sinais da classe P4 à classe Frank e sinais da classe T4 à classe T1.

Figura 16 - Matriz de Confusão (Conjunto de Treinamento) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

A Figura 16 mostra que no cenário intermediário, correspondente a $-10\text{ dB} \leq \text{SNR} < 0\text{ dB}$, observa-se um desempenho global bastante elevado. A maioria das classes, como Frank, LFM, Não Modulado, P1, P2, T1, T2, T3 e T4, atingiram acurácia igual ou próximas a 100% e, um aumento na taxa de FN surgiu na classe P3, que apresentou 93,1% de acurácia, sendo a taxa de FN para essa classe foi de 6,9. A acurácia do classificador CNN1 também não foi de 100% nas classes Barker 13 (FN = 0,5%) e P4 (FN = 1%). O classificador associou sinais da classe P3 como Frank (4,9%) e LFM (2%), bem como sinais da classe T4 foram associados a classe T1 (1,4%).

Figura 17 - Matriz de Confusão (Conjunto de Treinamento) -SNR $\leq$ -10dB.


Matriz de Confusão (Conjunto de Treinamento: SNR < -10dB)												
Classes dos Sinais	Barker 13	91.2%	1.1%			0.4%	1.5%			4.6%	0.4%	0.8%
	Frank		88.5%	0.4%		1.9%	3.3%	4.8%	0.4%			0.7%
	LFM	0.4%		98.1%		1.2%	0.4%					
	Unmod	0.4%			99.2%					0.4%		
	P1	0.4%	1.2%	1.2%		88.0%	3.2%	3.2%	2.8%			
	P2		3.1%			0.8%	95.0%	1.2%				
	P3		10.5%	1.4%		4.7%	2.9%	75.0%	4.0%	0.4%		1.1%
	P4		1.5%	0.4%	0.4%	11.6%	3.4%	1.1%	81.0%			0.7%
	T1	1.2%	2.3%		0.4%	0.4%	0.8%	1.2%		93.4%		0.4%
	T2	0.4%	3.2%			0.8%	1.6%	0.8%	0.4%		92.8%	
	T3	0.8%					1.1%		1.5%		96.6%	
	T4		0.4%	0.4%		0.4%	0.4%	0.7%	0.4%			97.4%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3
		Classificação gerada pela CNN										

Fonte: Elaborado pelo autor (2025).

Por outro lado, na Figura 17, referente a SNR < -10 dB, o desempenho da rede apresentou um aumento significativo na taxa de FN, piorando a acurácia em cada classe, conforme esperado pela teoria, pois quanto menor é a SNR, menos destacado ficam as características dos sinais em relação às do ruído na matriz de entrada da rede, dificultando a classificação. Embora algumas classes ainda tenham apresentado acurácia elevada, como LFM (98,1%), Não Modulado (99,2%), T2 (92,8%), T3 (93,3%) e T4 (97,4%), outras classes revelaram altas taxas de FN. Destacam-se os casos de P3, a acurácia caiu para 75%, e Frank, a acurácia obtida foi de 88,5%. Além disso, P4 e T1 também sofreram impacto considerável, alcançando respectivamente 81% e 93,4% de acurácia. As taxas de FN na classificação observados evidenciam a maior dificuldade da CNN1 em discriminar sinais em baixa SNR. Conforme diz a literatura: quanto menor é a SNR, menos destacado ficam as características dos sinais em relação às do ruído na matriz de entrada da rede, dificultando a detecção de características que evidenciem a classe do sinal. Destaca-se que o sinal P3 continua sendo associado em maior taxa a classe Frank (10,5%). Comparando a Figura 17 com a Figura 16, observa-se que nem sempre o classificador gera mais FN nas mesmas classes. Por exemplo, sinais da classe P4 para SNR menores

se confundem mais com a classe P1, para SNR maiores a classe P4 se confunde mais com as classes Frank e LFM.


Figura 18 - Matriz de Confusão (Conjunto de Teste) $\text{SNR} \geq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

A Figura 18, que apresenta a matriz de confusão referente aos dados do conjunto de teste no cenário de $\text{SNR} \geq 0\text{ dB}$, mostra o bom desempenho obtido pela CNN1. A maior parte das classes obteve 100% de acurácia, incluindo Frank, LFM, Não Modulado, P1, P2, T1, T2 e T3. As pequenas taxas de FN ficaram restritos às classes P3 (2,7%), P4 (0,7%) e T4 (0,7%). Com esse conjunto de dados de teste, o classificador se aproxima de uma performance com 100% de acurácia.

Figura 19 - Matriz de Confusão (Conjunto de Teste) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

A Figura 19 apresenta a matriz de confusão obtida com os dados de testes com SNR de valores intermediários, $-10\text{ dB} \leq \text{SNR} < 0\text{ dB}$. Observa-se um bom desempenho. A maioria das classes, como Frank, LFM, Não Modulado, P1, P2, T1, T2, T3 e T4, apresentou acurácia igual ou próxima a 100%. Uma taxa de FN maior surgiu na classe P3, que apresentou 90,8% de acurácia. Também houve taxas de FN nas classes Barker 13 (1,7%) e P4 (0,8%). Esses resultados indicam que, mesmo em condições de SNR menores, a CNN mantém elevada capacidade discriminativa.

Figura 20 - Matriz de Confusão (Conjunto de Teste) -SNR $\leq$ -10dB.

Matriz de Confusão (Conjunto de Teste: SNR < -10dB)															
Classes dos Sinais	Barker 13	90.7%	0.7%			2.7%	2.0%	0.7%	0.7%	1.3%		0.7%	0.7%	90.7%	9.3%
	Frank		83.3%			1.3%	4.7%	5.3%	2.0%	2.0%			1.3%	83.3%	16.7%
	LFM			98.0%		2.0%								98.0%	2.0%
	Unmod				100.0%									100.0%	
	P1		2.7%	2.0%		86.0%	2.7%	2.0%	4.0%				0.7%	86.0%	14.0%
	P2		3.3%			2.0%	91.3%	2.0%	0.7%				0.7%	91.3%	8.7%
	P3		12.7%	2.7%		6.0%	4.0%	68.7%	3.3%	0.7%		0.7%	1.3%	68.7%	31.3%
	P4		2.7%			12.0%	0.7%	3.3%	81.3%					81.3%	18.7%
	T1	2.7%	2.7%			0.7%	2.7%	0.7%		86.0%		3.3%	1.3%	86.0%	14.0%
	T2	1.3%			1.3%	2.7%			0.7%	0.7%	93.3%			93.3%	6.7%
	T3	1.3%					0.7%			4.7%		93.3%		93.3%	6.7%
	T4						0.7%	0.7%					98.7%	98.7%	1.3%
Classificação gerada pela CNN															
	Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4			

Fonte: Elaborado pelo autor (2025).

Entretanto ao observar a Figura 20, que apresenta a matriz de confusão para um cenário mais crítico relativo aos dados do conjunto de testes com SNR < -10 dB, o desempenho da rede apresentou maiores taxas de FN para cada classe. Embora algumas classes ainda tenham mantido valores elevados de acurácia, como LFM (98,0%), Não Modulado (100,0%), T2 (93,3%), T3 (93,3%) e T4 (98,7%), outras apresentaram altas taxas de FN diante de valores menores de SNR. Destacam-se os casos de P3, a acurácia reduziu para 68,7%, e Frank, a CNN1 obteve 83,3% de acurácia. Além disso, as classes P4 e T1 também apresentaram menores valores de acurácia, alcançando respectivamente 81,3% e 86%. As taxas de FN observadas evidenciam que a CNN1 apresenta maior dificuldade em discriminar sinais em cenários de baixa SNR.


As Figuras 18, 19 e 20 demonstram que o classificador obteve maior dificuldade com a classe P3, a associando, em sua maioria, com a classe Frank.

5.2 Resultados do Classificador baseado na Rede Neural CNN2

No classificador fundamentado na CNN2, os resultados obtidos a partir dos sinais utilizados nos conjuntos de treinamento em duas épocas e de teste são apresentados nas Figuras 21 a 26. A distribuição quantitativa de sinais foram as mesmas da CNN1.

A Figura 21 apresenta a matriz de confusão do cenário de $\text{SNR} \geq 0 \text{ dB}$, na qual se observa um desempenho quase ideal da CNN no treinamento, com o classificador obtendo 100% de acurácia em 10 classes de sinais. Esse resultado evidencia que, nessa condição de potência do sinal, a rede foi capaz de aprender de forma quase precisa os padrões associados a cada modulação.


Figura 21- Matriz de Confusão (Conjunto de Treinamento) $\text{SNR} \geq 0 \text{ dB}$.



Fonte: Elaborado pelo autor (2025).

De maneira semelhante, a Figura 22 mostra que quando analisado o intervalo de $-10 \text{ dB} \leq \text{SNR} < 0 \text{ dB}$, o classificador manteve o bom desempenho. Apenas as classes P4 e Barker apresentaram uma taxa de FN de 0,5%, resultando em 99,5% de acurácia para sinais dessas classes. As demais classes obtiveram 100% de acurácia. Esse resultado indica que, mesmo diante de um sinal de menor potência, a CNN mantém boa capacidade de aprendizado.

Figura 22 - Matriz de Confusão (Conjunto de Treinamento) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

Por fim, no cenário mais adverso, correspondente a $\text{SNR} < -10\text{ dB}$, os resultados apresentaram FN em 9 classes, sendo a menor acurácia pertencente a classe P4 (93,1%). Entretanto a acurácia global foi maior que 99%, sendo assim, apesar da baixa SNR durante o treinamento a rede foi capaz de ajustar seus parâmetros de forma eficaz, aprendendo bons padrões discriminativos, conforme apresentando na Figura 23.


Figura 23 - Matriz de Confusão (Conjunto de Treinamento) - $\text{SNR} \leq -10\text{dB}$.

Matriz de Confusão (Conjunto de Treinamento: $\text{SNR} < -10\text{dB}$)											
Classes dos Sinais	Barker 13	99.6%	0.4%								
	Frank		99.2%			0.4%		0.4%			
	LFM			100.0%							
	Unmod				100.0%						
	P1		0.7%		97.8%	0.7%		0.4%		0.4%	
	P2		1.1%			98.5%	0.4%				
	P3		0.8%			0.4%	98.0%			0.8%	
	P4		1.5%		0.4%	0.8%	3.8%	93.1%			0.4%
	T1	0.4%							99.3%	0.4%	
	T2				0.4%			0.4%		99.2%	
	T3	1.2%					0.4%				98.4%
	T4										100.0%
Classificação gerada pela CNN											

Fonte: Elaborado pelo autor (2025).

A Figura 24 apresenta o cenário de $\text{SNR} \geq 0 \text{ dB}$ para os dados do conjunto de teste, os resultados apresentaram 100% de acurácia em 11 classes. Isso demonstra que, nessa condição de SNR, a CNN2 foi capaz de generalizar de maneira satisfatória os padrões aprendidos durante o treinamento.


Figura 24 - Matriz de Confusão (Conjunto de Teste) $\text{SNR} \geq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

Na condição intermediária, correspondente a $-10\text{ dB} \leq \text{SNR} < 0\text{ dB}$, os dados apresentados na Figura 25 evidenciam novamente uma redução na acurácia da classe Frank, e FN nas classes P4 e T2, ambas com 0,8%.

Figura 25 - Matriz de Confusão (Conjunto de Teste) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

Entretanto, no cenário mais adverso, com $\text{SNR} < -10\text{ dB}$, verifica-se na Figura 26 uma degradação no desempenho da CNN. Embora várias classes tenham mantido altas taxas de acurácia, como LFM, Não Modulado, T2, T3 e T4 (acima de 98%), outras apresentaram taxas de acurácia menores. Como as modulações Frank, que alcançou 94,7% de acurácia, e P2, com 88,7%. Houve ainda taxas de FN em P1 e P3, porém, com acurácia acima de 90%. Esses resultados apresentam que, em ambientes nessa SNR, a CNN2 obteve taxas de FN mais altas para a classe P2 (11,3%) e P4 (13,3%).

O classificador obteve menor acurácia com a classe P4, sendo associado, em sua maioria com a classe P3 (4,7%).

Figura 26 - Matriz de Confusão (Conjunto de Teste) - SNR < -10dB.

Matriz de Confusão (Conjunto de Teste: SNR < -10dB)												
Classes dos Sinais	Barker 13	96.0%				0.7%		0.7%		1.3%	0.7%	0.7%
	Frank		94.7%			1.3%	0.7%	2.7%	0.7%			
	LFM			100.0%								
	Unmod				100.0%							
	P1		2.7%			92.0%	1.3%	2.7%	1.3%			
	P2	0.7%	2.0%			2.7%	88.7%	4.0%	0.7%	0.7%		0.7%
	P3		5.3%			1.3%	91.3%	0.7%	0.7%	0.7%		
	P4	0.7%	2.0%			2.0%	4.0%	4.7%	86.7%			
	T1	0.7%	0.7%			0.7%		1.3%		96.0%		0.7%
	T2					1.3%					98.7%	
	T3	1.3%					0.7%					98.0%
	T4	0.7%	0.7%			0.7%			0.7%			97.3%
Classificação gerada pela CNN												

96.0%	4.0%
94.7%	5.3%
100.0%	
100.0%	
92.0%	8.0%
88.7%	11.3%
91.3%	8.7%
86.7%	13.3%
96.0%	4.0%
98.7%	1.3%
98.0%	2.0%
97.3%	2.7%


Fonte: Elaborado pelo autor (2025).

5.3 Resultados do Classificador baseado na Rede Neural CNN3

No classificador fundamentado na CNN3, os resultados obtidos a partir dos sinais utilizados nos conjuntos de treinamento em duas épocas e de teste são apresentados nas Figuras 27 a 33. A distribuição quantitativa de sinais foram as mesmas das CNN1 e CNN2.

Na Figura 27, no cenário de $\text{SNR} \geq 0$ dB, a CNN3 apresentou resultados satisfatórios para a maioria das classes, com acurácia de 100% em modulações como Barker 13, LFM, Não Modulado, P1 e P2. No entanto, a classe P3 apresentou desempenho significativamente inferior, com 71,6% de acurácia e taxas de FN consideráveis, sendo associadas 20,5% com a classe Frank e 8% com a classe LFM.


Figura 27 - Matriz de Confusão (Conjunto de Treinamento) $\text{SNR} \geq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).

A Figura 28 apresenta a condição intermediária, correspondente a $-10\text{ dB} \leq \text{SNR} < 0\text{ dB}$, novamente a classe P3 demonstrou baixa acurácia (78%) e taxas de FN associadas a classes Barker 13 (16,6%), Frank (3,9%) e P1 (1,5%). A classe P4 obteve acurácia de 90,4% e T1 acurácia de 97,7%.

Figura 28 - Matriz de Confusão (Conjunto de Treinamento) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$.



Fonte: Elaborado pelo autor (2025).


No cenário de $\text{SNR} < -10\text{ dB}$, a Figura 29 apresenta uma taxa de acurácia menor para diversas classes. As classes Barker 13 (91,6%), LFM (89,4%), P1 (80,5%) e P2 (86,3%) apresentaram as maiores taxas de acurácia, e as classes Frank (67,2%), P3 (60,1%) e P4 (50,4%), as menores acurácias.

Figura 29 - Matriz de Confusão (Conjunto de Treinamento) $\text{SNR} \leq -10\text{dB}$.

Matriz de Confusão (Conjunto de Treinamento: SNR < -10dB)															
Classes dos Sinais	Barker 13	91.6%	1.5%		0.4%		1.9%	1.1%		1.5%	1.1%	0.8%		91.6%	8.4%
	Frank	0.4%	67.2%	1.5%		9.0%	3.0%	15.3%	1.1%		1.1%		1.5%	67.2%	32.8%
	LFM	0.4%	3.8%	89.4%		0.8%	0.4%	4.2%		0.8%			0.4%	89.4%	10.6%
	Unmod	0.8%			97.7%		0.4%				1.2%			97.7%	2.3%
	P1		0.4%		0.7%	80.5%	4.1%	10.9%	2.2%		0.7%		0.4%	80.5%	19.5%
	P2		3.1%			1.9%	86.3%	6.9%	0.8%		0.8%		0.4%	86.3%	13.7%
	P3		13.6%	2.6%		14.7%	4.4%	60.1%	2.6%	0.4%			1.8%	60.1%	39.9%
	P4		3.1%	0.4%		29.2%	4.2%	10.4%	50.4%	0.4%	0.8%		1.2%	50.4%	49.6%
	T1	6.0%	2.8%				2.0%	4.4%		80.1%		4.4%	0.4%	80.1%	19.9%
	T2	1.1%	2.6%	1.1%		3.0%	0.7%	0.4%		0.4%	90.0%	0.7%		90.0%	10.0%
	T3	2.2%					0.7%	0.4%		1.1%		95.2%	0.4%	95.2%	4.8%
	T4	0.8%	0.4%				0.4%	1.1%	1.1%				96.2%	96.2%	3.8%
Classificação gerada pela CNN															


Fonte: Elaborado pelo autor (2025).

A Figura 30 apresenta a Matriz de Confusão (Conjunto de Teste) $\text{SNR} \geq 0\text{dB}$. Assim como ocorreu no treinamento, a CNN3 obteve acurácia reduzida para a classe P3 (73,3%), sendo a maior taxa de FN da classe P3 (26,7%) e P4 (1,3%). As demais classes obtiveram acurácia acima de 99%, com exceção da P4 (98,7%). A figura demonstra que o terceiro classificador também demonstra dificuldades com a classe P3, sendo associada a classe Frank a uma taxa de 20%.

Figura 30 - Matriz de Confusão (Conjunto de Teste) $\text{SNR} \geq 0\text{dB}$.

Fonte: Elaborado pelo autor (2025).

Na Figura 31 de faixa intermediária de SNR, entre -10 dB e 0 dB, a acurácia global é de 96,4%, com 7 classes alcançando os 100%. Contudo, novamente a modulação P3 apresenta maiores taxas de FN (23,3%), sendo com a classe Frank (15,8%), LFM (9,7%) e P1 (0,8%). Essa tendência reforça a menor acurácia da classe P3. A Matriz de Confusão também evidencia a redução da acurácia das classes Barker (98,3%), Frank (98,3), P4 (90%) e T1 (94,2%).

Figura 31- Matriz de Confusão (Conjunto de Teste) $-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$.

Fonte: Elaborado pelo autor (2025).

Em SNR inferior a -10 dB , Figura 32, a CNN3 reduz a acurácia global de maneira significativa (80,2%). Somente nas classes Não Modulado e T4 a acurácia é maior que 95%. As taxas de FN P3 (46%), P4 (49,3%) e Frank (33,3%), são as maiores. Essas taxas demonstram que a CNN3 não obteve resultados satisfatórios com as classes P3 e P4, principalmente. E, a maioria das classes não obtiveram acurácia acima de 90%. Tal fato sugere a necessidade de técnicas adicionais de pré-processamento ou aumento do número de épocas de treinamento para melhorar a acurácia global da CNN3.

Figura 32 - Matriz de Confusão (Conjunto de Teste) -SNR $\leq$ -10dB.

Matriz de Confusão (Conjunto de Teste: SNR < -10dB)															
Classes dos Sinais	Barker 13	87.3%	1.3%		0.7%		2.0%	1.3%	1.3%	3.3%	0.7%	1.3%	0.7%	87.3%	12.7%
	Frank	0.7%	66.7%			12.7%	2.7%	12.0%	0.7%	1.3%	1.3%		2.0%	66.7%	33.3%
	LFM		2.0%	88.7%				7.3%			0.7%	0.7%	0.7%	88.7%	11.3%
	Unmod				97.3%		1.3%				1.3%			97.3%	2.7%
	P1		1.3%		0.7%	78.7%	4.7%	11.3%	3.3%					78.7%	21.3%
	P2	0.7%	4.7%			2.7%	81.3%	8.0%	0.7%		0.7%		1.3%	81.3%	18.7%
	P3		17.3%	3.3%		16.0%	4.0%	54.0%	5.3%					54.0%	46.0%
	P4	0.7%				32.7%	2.7%	9.3%	50.7%		2.0%	0.7%	1.3%	50.7%	49.3%
	T1	4.0%	3.3%				3.3%	5.3%		80.7%		3.3%		80.7%	19.3%
	T2	0.7%	2.0%			6.7%	0.7%	0.7%		0.7%	88.7%			88.7%	11.3%
	T3	2.7%						0.7%		5.3%		91.3%		91.3%	8.7%
	T4		0.7%			0.7%	0.7%	0.7%	0.7%				96.7%	96.7%	3.3%
Classificação gerada pela CNN															

Fonte: Elaborado pelo autor (2025).

5.4 Resultados do Classificador para CNN com 6 (seis) épocas de treinamento

O número de épocas em uma CNN corresponde à quantidade de vezes que todo o conjunto de dados de treinamento é processado pelo modelo durante o aprendizado. Cada época envolve a apresentação de todas as amostras ao algoritmo, divididas em subconjuntos denominados *batches*, nos quais os pesos da rede são ajustados iterativamente com base no erro calculado. Assim, o término do processamento de todos os *batches* define o encerramento de uma época. A escolha do número de épocas é um fator determinante para o desempenho do modelo, pois um número insuficiente pode resultar em subajuste (*underfitting*), enquanto um número excessivo pode causar sobreajuste (*overfitting*). Na prática, a definição desse parâmetro é realizada de forma empírica, com base na observação das curvas de erro e acurácia nos conjuntos de treinamento e validação, sendo comum o uso de técnicas como *early stopping* para interromper o treinamento automaticamente quando não há mais melhoria significativa no desempenho do modelo (Eberman; Krohling, 2018).

Ao comparar as Matrizes de Confusão dos Conjuntos de Testes Globais, para cada CNN, figuras 33 a 38, observa-se o que diz a literatura quanto a melhora da acurácia com SNR<- 10dB o treinamento em 6 épocas.

Figura 33- Matriz de Confusão (Conjunto de Teste) da CNN1 - 2 épocas de treinamento.

		Matriz de Confusão (Conjunto de Teste)													
Classes dos Sinais	Barker 13	96.0%	0.2%			1.7%	0.7%	0.2%	0.2%	0.5%		0.2%	0.2%	96.0%	4.0%
	Frank		94.0%			0.5%	1.7%	1.9%	0.7%	0.7%				94.0%	6.0%
	LFM			99.3%		0.7%								99.3%	0.7%
	Unmod				100.0%									100.0%	
	P1		1.0%	0.7%		95.0%	1.0%	0.7%	1.4%					95.0%	5.0%
	P2		1.2%			0.7%	96.9%	0.7%	0.2%					96.9%	3.1%
	P3		6.4%	2.6%		2.1%	1.4%	85.2%	1.2%	0.2%		0.2%	0.5%	85.2%	14.8%
	P4		1.4%			4.3%	0.2%	1.2%	92.9%					92.9%	7.1%
	T1	1.0%	1.0%			0.2%	1.0%	0.2%		95.0%		1.2%	0.5%	95.0%	5.0%
	T2	0.5%			0.5%	1.0%			0.2%	0.2%	97.6%			97.6%	2.4%
	T3	0.5%					0.2%			1.7%		97.6%		97.6%	2.4%
	T4						0.2%	0.2%		0.2%			99.3%	99.3%	0.7%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
		Classificação gerada pela CNN													

Fonte: Elaborado pelo autor (2025).

Figura 34 Matriz de Confusão (Conjunto de Teste) da CNN1 - 6 épocas de treinamento.


		Matriz de Confusão (Conjunto de Teste)													
Classes dos Sinais	Barker 13	98.8%						0.2%		0.7%	0.2%			98.8%	1.2%
	Frank		95.5%			0.5%	1.4%	1.0%	1.2%	0.2%	0.2%			95.5%	4.5%
	LFM			99.3%		0.2%	0.2%	0.2%						99.3%	0.7%
	Unmod				100.0%									100.0%	
	P1		1.2%			96.7%	1.0%	0.5%	0.5%		0.2%			96.7%	3.3%
	P2		2.1%			1.0%	94.5%	1.7%	0.7%					94.5%	5.5%
	P3		1.0%			0.2%	1.7%	96.0%	1.0%				0.2%	96.0%	4.0%
	P4					2.1%	0.7%	1.0%	96.0%		0.2%			96.0%	4.0%
	T1		1.0%				0.2%	0.2%		98.6%				98.6%	1.4%
	T2	0.2%				0.2%	0.2%				99.3%			99.3%	0.7%
	T3											100.0%		100.0%	
	T4					0.2%	0.5%	0.2%					99.0%	99.0%	1.0%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
		Classificação gerada pela CNN													

Fonte: Elaborado pelo autor (2025).

A análise comparativa entre as duas matrizes de confusão evidencia uma melhoria na acurácia da CNN1 quando o número de épocas de treinamento foi ampliado de 2 para 6. Observa-se que, globalmente, houve redução das taxas de FN, refletindo uma aprendizagem melhor.


Após o aumento para 6 épocas, a acurácia se manteve nas classes Sem Modulação (100%) e LFM (99,3%), entretanto, houve um aumento significativo na acurácia da classe P3, cuja taxa de FN reduziu de 14,8% para 4% no treinamento com 6 épocas.

Figura 35 Matriz de Confusão (Conjunto de Teste) da CNN2 - 2 épocas de treinamento.



Fonte: Elaborado pelo autor (2025).

Figura 36 Matriz de Confusão (Conjunto de Teste) da CNN2 - 6 épocas de treinamento.



Fonte: Elaborado pelo autor (2025).

As Figuras 35 e 36 apresentam as matrizes de confusão da CNN2 quando treinada com 2 e 6 épocas. Conforme diz a literatura, observa-se que não houve *overfitting*, pois a taxa de FN global foi reduzida. Sendo a acurácia acima de 98% alcançada por 10 das 12 classes.

Figura 37 - Matriz de Confusão (Conjunto de Teste) da CNN3 - 2 épocas de treinamento.

		Matriz de Confusão (Conjunto de Teste)													
Classes dos Sinais	Barker 13	94.8%	0.5%		1.0%		0.7%	0.5%	0.5%	1.2%	0.2%	0.5%	0.2%	94.8%	5.2%
	Frank	0.2%	87.4%			5.2%	1.0%	4.3%	0.2%	0.5%	0.5%		0.7%	87.4%	12.6%
	LFM		0.7%	96.0%				2.6%			0.2%	0.2%	0.2%	96.0%	4.0%
	Unmod				99.0%		0.5%				0.5%			99.0%	1.0%
	P1		0.5%		0.2%	92.4%	1.7%	4.0%	1.2%					92.4%	7.6%
	P2	0.2%	1.7%			1.0%	93.3%	2.9%	0.2%		0.2%		0.5%	93.3%	6.7%
	P3		17.9%	5.5%		6.0%	1.4%	67.4%	1.9%					67.4%	32.6%
	P4	0.2%				12.6%	1.0%	5.7%	79.0%		0.7%	0.2%	0.5%	79.0%	21.0%
	T1	3.1%	1.2%				1.2%	1.9%		91.4%		1.2%		91.4%	8.6%
	T2	0.2%	0.7%			2.4%	0.2%	0.2%		0.2%	96.0%			96.0%	4.0%
	T3	1.0%						0.2%		1.9%		96.9%		96.9%	3.1%
	T4	0.2%	0.2%			0.2%	0.2%	0.2%	0.2%				98.6%	98.6%	1.4%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
		Classificação gerada pela CNN													

Fonte: Elaborado pelo autor (2025).

Figura 38 - Matriz de Confusão (Conjunto de Teste) da CNN3 -6 épocas de treinamento.

		Matriz de Confusão (Conjunto de Teste)													
Classes dos Sinais	Barker 13	96.9%	0.7%			1.0%	0.2%			0.5%	0.7%			96.9%	3.1%
	Frank	0.2%	93.3%			1.2%	1.9%	1.4%	1.2%	0.2%	0.5%			93.3%	6.7%
	LFM			99.0%		0.7%								99.0%	1.0%
	Unmod				100.0%									100.0%	
	P1		0.2%			96.4%	0.2%	0.7%	2.1%	0.2%				96.4%	3.6%
	P2	0.7%	0.5%			0.5%	95.5%	1.4%	1.0%	0.2%			0.2%	95.5%	4.5%
	P3		2.9%			0.2%	1.4%	91.2%	3.6%	0.7%				91.2%	8.8%
	P4		0.5%			3.1%	0.2%	0.5%	95.2%		0.5%			95.2%	4.8%
	T1	0.2%	0.2%				0.2%			98.6%	0.5%	0.2%		98.6%	1.4%
	T2					0.2%	0.7%	0.2%			98.8%			98.8%	1.2%
	T3									0.5%		99.5%		99.5%	0.5%
	T4								0.2%				99.8%	99.8%	0.2%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
		Classificação gerada pela CNN													


Fonte: Elaborado pelo autor (2025).

As Figuras 37 e 38 apresentam as matrizes de confusão de teste da CNN3, treinada com 2 e 6 épocas, respectivamente. O resultado obtido demonstra que a CNN 3 ao ser treinada com mais épocas pode alcançar uma acurácia global (97,1%) maior que a acurácia da CNN1 quando treinada com 2 épocas (95,7%), e quase similar a acurácia da CNN2 (98%), também quando treinada com 2 épocas.

5.5 Comparação entre as CNN's - Acurácia x SNR

O gráfico da figura 39 apresenta a comparação do desempenho dos três modelos de redes neurais convolucionais (CNN 1, CNN 2 e CNN 3) utilizados, em função da SNR, avaliados sobre o conjunto de teste. A acurácia global, expressa em porcentagem, permite analisar a robustez de cada modelo frente a diferentes condições de razão SNR. O gráfico apresentado é referente ao treinamento com 6 épocas.

Figura 39 - Comparação entre as CNN's (Gráfico Acurácia x SNR).



Fonte: Elaborado pelo autor (2025).

A CNN2 apresenta o melhor desempenho, especialmente em cenários de baixa SNR. Com a SNR de -25 dB, a acurácia supera 85%, valor significativamente superior aos resultados das demais arquiteturas, que ficaram em torno de 75% (CNN1) e 73% (CNN3). A CNN2 obtém desempenho acima de 97% com a SNR de -15 dB, evidenciando alta capacidade de discriminação.

A CNN1 demonstra um comportamento intermediário. Com valores de SNR a partir de -15 dB, atinge valores acima de 95%, aproximando-se do desempenho da CNN 2.

A CNN 3 revela-se como a rede de pior desempenho, obtendo maiores taxas de FN para SNR menores, com 73% de acurácia com SNR de -25 dB, obtendo acurácia semelhante a CNN2 para SNR acima de -10 dB. Ainda que alcance valores próximos de 98% em condições mais favoráveis ($\text{SNR} > 0$ dB), apresenta menor capacidade de classificação da modulação intrapulso em situações de SNR menores.

De modo geral, os resultados indicam que todas as arquiteturas são eficientes em condições de $\text{SNR} \geq -10$ dB. Outrossim, foram realizadas simulações, não apresentadas neste trabalho, com 15 e 30 épocas de treinamento, porém, não houve aumento da acurácia global nessas condições de treinamento.

5.6 Comparação entre as CNN – Taxa de Falso Positivo (FP)

Tabela 1 - Taxas de FP das CNNs (SNR $\geq$ 0dB).

Classe	Taxa de FP - SNR $\geq$ 0dB (2 épocas)			Taxa de FP - SNR $\geq$ 0dB (6 épocas)		
	CNN1	CNN2	CNN3	CNN1	CNN2	CNN3
Barker 13	0%	0%	0,7%	0%	0%	0%
Frank	2%	0%	20%	0%	0%	0%
LFM	1,3%	0%	67%	0%	0%	0%
Unmod	0%	0%	0,7%	0%	0%	0%
P1	0,7%	0%	0,7%	0%	0%	0,7%
P2	0%	0%	0%	0%	0%	0%
P3	0%	0,7%	1,3%	0%	0%	0%
P4	0%	0%	0%	0%	0%	0%
T1	0,7%	0,7%	0%	0,7%	0%	0,7%
T2	0%	0%	0%	0%	0%	0%
T3	0%	0%	0%	0%	0%	0%
T4	0%	0%	0%	0%	0%	0%

Fonte: Elaborado pelo autor (2025).

A Tabela 1 compara as taxas de FP obtidas pelas CNNs utilizadas em duas condições de treinamento, 2 épocas e 6 épocas, considerando os sinais com SNR $\geq$ 0 dB. Observa-se que o aumento do número de épocas resultou em redução nas taxas de FP, evidenciando que o modelo, após maior tempo de aprendizado, aprimorou sua capacidade de distinguir corretamente as classes. Na condição de 2 épocas, a maior taxa de FP foi observada na classe LFM (67%) com a CNN3. Essa taxa de FP foi reduzida para 0% com o treinamento em 6 épocas.

Tabela 2 - Taxas de FP das CNNs ($-10\text{dB} \leq \text{SNR} \leq 0\text{dB}$).

	Taxa de Falso Positivo $-10\text{dB} \leq \text{SNR} < 0\text{dB}$ (2 épocas)			Taxa de Falso Positivo $-10\text{dB} \leq \text{SNR} < 0\text{dB}$ (6 épocas)		
Classe	CNN1	CNN2	CNN3	CNN1	CNN2	CNN3
Barker 13	0%	0%	5,8%	0%	0%	0%
Frank	5,8%	0%	15,8%	0%	0%	0%
LFM	4,2%	0%	6,7%	0%	0%	0%
Unmod	0%	0%	1,7%	0%	0%	0%
P1	1,7%	0%	5,8%	0%	0%	1,7%
P2	0%	0%	0%	0%	0%	0%
P3	0%	3,3%	6,7%	0%	0%	0%
P4	0%	0%	0%	0%	0%	0%
T1	0%	0%	0%	0%	0%	0%
T2	0%	0%	0%	0%	0%	0%
T3	0%	0%	0%	0%	0%	0%
T4	0%	0%	0%	0%	0%	0%

Fonte: Elaborado pelo autor (2025).

A Tabela 2, de SNR entre -10dB e 0dB , demonstra que as taxas de FP foram maiores nas classes Frank (CNN1 e CNN3) e P3 (CNN2). O treinamento em 6 épocas ainda manteve uma taxa global de FP baixa de quase 0%.

Tabela 3 - Taxas de FP das CNNs ($\text{SNR} \leq -10\text{dB}$).

	Taxa de Falso Positivo - $\text{SNR} < -10\text{dB}$ (2 épocas)			Taxa de Falso Positivo - $\text{SNR} < -10\text{dB}$ (6 épocas)		
Classe	CNN1	CNN2	CNN3	CNN1	CNN2	CNN3
Barker 13	5,3%	4,1%	9,5%	0,7%	2%	3,4%
Frank	21,8%	13,4%	32,6%	14,7%	7,3%	14%
LFM	4,7%	0%	3,3%	0%	0%	0%
Unmod	1,3%	0%	1,4%	0%	0%	0%
P1	29,4%	8,7%	71,5%	12,8%	2%	17,4%
P2	18,2%	8%	22,1%	16,8%	7,9%	14,1%
P3	14,7%	16,1%	56,6%	14,2%	6%	12%
P4	11,4%	4,1%	12%	7,3%	6,8%	22,7%
T1	9,4%	2,7%	10,6%	2%	1,3%	6,1%
T2	0%	1,4%	6,7%	2,8%	3,4%	5,9%
T3	4,7%	1,4%	6%	0%	0%	0,7%
T4	6%	0,7%	6%	0,7%	1,4%	1,4%

Fonte: Elaborado pelo autor (2025).

A partir da Tabela 3, nota-se que houve um aumento significativo na taxa de FP referente às classes da família “P”. Sendo a taxa de FP bastante elevada na classe P1 com o classificador que utiliza a CNN3 (71,5%), para treinamento em duas épocas. Com o

treinamento em 6 épocas, a classe P4 obteve o maior índice de taxa de FP, sendo 22,7% na CNN3.

5.7 Métricas de avaliação

Para avaliar o desempenho das CNNs, foram empregadas métricas que possibilitaram uma análise da eficácia dos modelos. As matrizes de confusão oferecem uma visão clara da performance das CNNs ao mostrar as taxas de verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN). A partir dessas matrizes, foi possível calcular métricas importantes como a precisão (*precision*), o *recall* (sensibilidade) e a pontuação F1 (Kota; Munisamy, 2018).

De acordo com (Kota; Munisamy, 2018), a precisão (ou precisão positiva) mede a proporção de verdadeiros positivos em relação ao total de predições positivas realizadas pelo modelo, sendo definida pela equação 12:

$$\text{Precisão} = \frac{TP}{TP+FP} \quad (12)$$

O *recall* (ou sensibilidade) calcula a proporção de verdadeiros positivos em relação ao total de casos que realmente pertencem a classe positiva (Kota; Munisamy, 2018). A fórmula do *recall* é dada pela equação 13:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (13)$$

Uma métrica derivada da precisão e do *recall* é a pontuação F1, que é a média harmônica entre essas duas métricas. A pontuação F1 é útil quando há a necessidade de equilibrar a preocupação entre falsos positivos e falsos negativos (Kota; Munisamy, 2018). Sua fórmula é dada pela equação 14:

$$F1 = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (14)$$

Adicionalmente, foi calculada a acurácia média no conjunto de testes, que é uma métrica geral que mede a proporção de todas as predições corretas (Kota; Munisamy, 2018). A fórmula para a acurácia é a equação 15:

$$\text{Acurácia} = \frac{TP+TN}{TP+TN+FP+FN} \quad (15)$$

Tabela 4 - Resultado das métricas de avaliação.

SNR <-10dB	Arquitetura	Acurácia (%)	Precisão	Recall	Pontuação F1
	CNN1	93,89	0,93	0,93	0,93
	CNN2	96,88	0,96	0,96	0,96
	CNN3	91,95	0,91	0,91	0,91
-10<=SNR<=0dB	Arquitetura	Acurácia (%)	Precisão	Recall	Pontuação F1
	CNN1	100	1	1	1
	CNN2	100	1	1	1
	CNN3	100	1	1	1
SNR >0dB	Arquitetura	Acurácia (%)	Precisão	Recall	Pontuação F1
	CNN1	99,94	0,99	0,99	0,99
	CNN2	100	1	1	1
	CNN3	99	0,99	0,99	0,99

Fonte: Elaborado pelo autor (2025).

A Tabela 4 sintetiza o desempenho das três arquiteturas convolucionais (CNN1, CNN2 e CNN3), treinadas com 6 épocas por ter gerado os melhores resultados, sob diferentes condições de SNR.

Observa-se que, globalmente, todas as arquiteturas apresentaram excelente desempenho, com métricas de acurácia, precisão, *recall* e *F1-Score* superiores a 90 % em todas os intervalos de SNRs analisados.


A CNN2 apresentou a melhor performance em todas as faixas, com acurácia global, que envolvem todos os sinais do conjunto de testes, de 98,96%, superando a CNN1, que obteve 97,94 % e a CNN3, que obteve 96,98 %.

5.8 Processo de treinamento

A convergência de uma CNN refere-se ao processo pelo qual o modelo ajusta iterativamente seus pesos e bias até alcançar um ponto de estabilidade no aprendizado,

isto é, quando as métricas de desempenho, como função de perda (*loss*) e acurácia, deixam de apresentar variações significativas entre as iterações ou épocas. Em termos práticos, a convergência ocorre quando a perda do treinamento diminui e se estabiliza em valores baixos, enquanto a acurácia de validação atinge um platô, indicando que o modelo aprendeu as representações relevantes dos dados sem apresentar *overfitting* (Eberman; Krohling, 2018). A velocidade e a qualidade da convergência dependem de fatores como a taxa de aprendizado (*learning rate*), a quantidade de épocas, o número de camadas e parâmetros da rede, o tamanho do conjunto de dados e as técnicas de regularização aplicadas, como *batch normalization* (Eberman; Krohling, 2018). Em suma, a convergência de uma CNN representa o ponto em que o modelo atinge um equilíbrio entre erro mínimo e capacidade de generalização, sendo fundamental para garantir treinamentos estáveis e resultados confiáveis.

Figura 40 - Gráfico do processo de treinamento CNN1.



Fonte: Elaborado pelo autor (2025).

Digite a equação aqui.


Os gráficos da figura 40 ilustra o processo de convergência do treinamento da CNN1 ao longo das seis épocas, evidenciando a evolução simultânea das métricas de acurácia e função de perda durante o aprendizado supervisionado. Observa-se que, nas primeiras iterações, há um crescimento acentuado da acurácia de treinamento, que ultrapassa 90% ainda na primeira época, atingindo valores próximos a 100% a partir da terceira época, o que indica que o modelo foi capaz de identificar rapidamente os padrões discriminantes presentes nos dados do conjunto de treinamento.

A acurácia de validação acompanha a tendência de crescimento de maneira estável, estabilizando-se em 97,65%, o que demonstra que o modelo não apenas aprendeu as características do conjunto de treinamento, mas também generalizou adequadamente para dados não vistos, sem evidências de *overfitting*.

A curva inferior do gráfico abaixo da figura 40 representa a função de perda, que reflete o erro de predição do modelo em relação às saídas reais. Nota-se uma redução abrupta da perda nas iterações iniciais, com convergência para valores próximos de zero já na segunda época. Essa tendência revela uma eficiência significativa no processo de otimização, impulsionada por uma taxa de aprendizado constante de 0,01, que se mostrou adequada para permitir ajustes rápidos dos pesos. A ausência de oscilações expressivas nas curvas de perda e acurácia evidencia um processo de aprendizado estável e controlado, sugerindo que a arquitetura da rede e os parâmetros adotados foram corretamente dimensionados.

O treinamento foi executado através de um processamento simples (Single CPU), com tempo total de 2 minutos e 1 segundo, abrangendo 408 iterações e 68 iterações por época, o que destaca a eficiência computacional do modelo em alcançar convergência rapidamente. Assim, o processo evidenciado pelo gráfico da figura 40 demonstra que a CNN1 alcançou convergência plena, alta acurácia e baixa perda, refletindo um equilíbrio ideal entre aprendizado e generalização, aspectos essenciais para a robustez e confiabilidade do modelo em aplicações de classificação de sinais.

Figura 41 - Gráfico do processo de treinamento CNN2.



Fonte: Elaborado pelo autor (2025).


O gráfico apresentado na figura 41 descreve de forma detalhada o processo de treinamento e convergência da CNN2 ao longo de seis épocas, também evidenciando o comportamento das métricas de acurácia e função de perda durante o aprendizado. Observa-se que a acurácia de treinamento cresce rapidamente desde as primeiras iterações, também ultrapassando 90% ainda na primeira época e alcançando valores próximos de 100% a partir da segunda, o que demonstra uma rápida assimilação dos padrões característicos do conjunto de dados. De forma coerente, a acurácia do conjunto de validação também apresenta crescimento estável, atingindo 98,91% ao final do treinamento, o que indica boa capacidade de generalização do modelo e ausência de *overfitting*.

A análise da função de perda reforça esse comportamento de convergência estável. Nota-se uma queda abrupta da perda nas iterações iniciais, seguida de estabilização em valores próximos de zero a partir da segunda época, evidenciando que o modelo ajustou eficientemente seus pesos durante o processo de otimização. Esse desempenho está

associado a uma taxa de aprendizado constante de 0,01, a qual proporcionou um equilíbrio adequado entre velocidade de convergência e estabilidade numérica.

Com tempo total de 1 minuto e 31 segundos, alcançando resultados em um intervalo de tempo menor que a CNN1, demonstrando eficiência computacional e robustez no aprendizado.

Figura 42 - Gráfico do processo de treinamento CNN3.



Fonte: Elaborado pelo autor (2025).

Os gráficos da figura 42 ilustram o processo de convergência do treinamento da CNN3 ao longo de seis épocas, destacando a evolução das métricas de acurácia e função de perda (*loss*) tanto para o conjunto de treinamento quanto para o de validação. Observa-se que a acurácia do conjunto de treinamento cresce rapidamente nas iterações iniciais, ultrapassando 90% ainda na primeira época e estabilizando-se próxima a 98–99% nas épocas seguintes. De modo consistente, a acurácia de validação acompanha essa tendência, atingindo 96,80% ao final do processo, o que indica boa capacidade de generalização do modelo, sem sinais evidentes de *overfitting*.

A curva inferior, que representa a função de perda, evidencia uma redução acentuada durante as primeiras iterações, convergindo para valores próximos de zero já nas duas primeiras épocas. Essa rápida diminuição reflete um processo de otimização eficiente, no qual a CNN ajustou seus pesos de forma estável, reduzindo progressivamente o erro de predição ou a função de perda. A taxa de aprendizado constante de 0,01 mostrou-se adequada para garantir uma convergência suave, sem oscilações ou divergências numéricas. O tempo total de treinamento foi o maior das CNNs utilizadas, 5 minutos e 36 segundos.

A análise conjunta dos processos de treinamento das três CNNs demonstra que todas atingiram convergência estável, com boas taxas de acurácia no treinamento acima de duas épocas e baixa função de perda, evidenciando aprendizado eficiente e boa capacidade de generalização. A ausência de *overfitting* e o rápido tempo de convergência indicam que as arquiteturas e hiper parâmetros adotados foram adequadamente dimensionados, assegurando eficiência computacional e confiabilidade na classificação de sinais.

6 CONCLUSÃO

A qualidade superior do classificador baseado na CNN2 na classificação dos tipos de modulação dos sinais analisados torna-se evidente quando comparamos os três classificadores (Tabela 4) com as medidas de Precisão, *Recall*, acurácia e *F1 score*.

Com base nos resultados apresentados na Tabela 4, conclui-se que ao treinar as CNNs com 6 épocas, todos os classificadores apresentam excelente acurácia para SNR maiores que -10dB.

A utilização de classificadores baseados em Redes Neurais Convolucionais nos sistemas MAGE pode representar um avanço significativo na capacidade de classificação automática de modulações intrapulso e, consequentemente, na classificação de emissores radar. Os resultados apresentados neste trabalho foram promissores quanto ao uso da IA a fim de incrementar os sistemas MAGE da MB.

As CNNs demonstraram desempenho eficaz em cenários de SNR baixa, apresentando elevada acurácia. Tal característica é essencial para aumentar a vantagem tática e estratégica no teatro de operações navais, cuja utilização de radares LPI é cada vez mais comum.

Entretanto, a análise dos resultados evidencia que as classes P3, P4 e Frank apresentaram as maiores taxas de falso negativo, isso ocorre devido à similaridade entre

seus espectrogramas. Esses códigos de modulação intrapulso compartilham padrões estruturados, com variações de fase suaves e transições internas regulares, o que produz representações tempo–frequência visualmente próximas. Em condições de baixa SNR, especialmente entre -25 dB e -15 dB, o ruído encobre características essenciais, acarretando uma classificação errônea dessas modulações. Assim, a perda de contraste entre as assinaturas espectrais reduz a discriminação do classificador, ampliando a taxa de falsos negativos.

Além disso, o comportamento das CNNs sugere que as features extraídas automaticamente tendem a se concentrar em padrões dominantes do espectrograma, que, no caso de P3, P4 e Frank, apresentam distribuições de energia muito próximas, dificultando a separação entre elas. Como resultado, parte das amostras verdadeiramente pertencentes a essas classes é atribuída a modulações com estruturas igualmente regulares, como Frank, P3 ou P4. Assim, o aumento de falsos negativos nessas classes é consequência direta da similaridade entre seus espectrogramas, agravada pela interferência do ruído e pela dificuldade de classificar padrões distintivos em condições de baixa SNR.

Uma solução para mitigar o elevado índice de falsos negativos entre essas classes é agrupar inicialmente essas modulações em “classes-mãe”, antes de realizar a classificação específica. Como essas modulações apresentam assinaturas espectro temporal muito próximas, a CNN tem dificuldade em diferenciá-las diretamente, sobretudo em cenários de baixa SNR. Ao criar uma classe-mãe que essas classes, o modelo pode primeiramente aprender a classificar este grupo, reduzindo a taxa de FN entre classes finas.

Em um segundo estágio, após o agrupamento, uma rede mais especializada ou um classificador adicional pode ser responsável por diferenciar as subclasses dentro de cada grupo. Essa abordagem hierárquica tende a melhorar o desempenho, pois reduz a carga de separação de padrões muito próximos em um único passo. Além disso, permite que o primeiro nível da CNN opere com maior robustez ao ruído, enquanto o segundo nível foca nas diferenças mais sutis de cada classe de modulação.

6.1 Sugestões para trabalhos futuros

Com base nos resultados obtidos, recomenda-se que trabalhos futuros amplie a base de dados empregada com o apoio do Centro de Guerra Acústica e Eletrônica da Marinha (CGAEM), cuja biblioteca de sinais pode contribuir com registros reais captados

por sistemas MAGE em operação. Essa integração permitiria validar de forma mais precisa o desempenho das CNNs em condições eletromagnéticas reais e complexas, aproximando os resultados experimentais das situações encontradas em cenários operacionais de Guerra Eletrônica.

REFERÊNCIAS

- AWARI. “**Machine Learning: Quem criou? História e desenvolvimento**”. [S. l.], 2023. Disponível em: <https://awari.com.br/machine-learning-quem-criou-historia>. Acesso em: 12 jul. 2023.
- BARBOSA, M.; PRALON, L.; PAGLIARI, C.; APOLINÁRIO Jr., J. “**Extração de Parâmetros Intrapulso e Interpulso de um Radar com Modulação Aleatória em Frequência**”. In: XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2022), 25–28 set. 2022, Santa Rita do Sapucaí, MG. 2022
- BRASIL. Comando de Operações Navais. ComOpNav-521: **Manual de Guerra Eletrônica**. Rio de Janeiro, 2003. Confidencial.
- BRASIL. Estado Maior da Armada. EMA-305: **Doutrina Militar Naval**. Brasília, 2017.
- CHOI, H.-I. AND WILLIAMS, W. J. (1989). **Improved time-frequency representation of multicomponent signals using exponential kernels**. IEEE Trans on Acoustics, Speech, and Signal Processing, 37(6):862–871.
- EBERMAM, E.; KROHLING, R. A. **Uma Introdução Compreensiva às Redes Neurais Convolucionais: Um Estudo de Caso para Reconhecimento de Caracteres Alfabéticos**. Revista Sistemas de Informação da FSMA, [S. l.], n. 22, p. 49-59, 2018.
- FACELI, K., LORENA, A. C., GAMA, J., ALMEIDA, T. A. D., AND CARVALHO, A. C. P. d. L. F. d. (2021). **Inteligência artificial: uma abordagem de aprendizado de máquina**. LTC.
- GHADIMI, G. et al. “**Deep Learning-Based Approach for Low Probability of Intercept Radar Signal Detection and Classification**”. Journal of Communications Technology and Electronics, Teera, v. 65, n. 10, 2020.
- HEATON, J. IAN GOODFELLOW, YOSHUA BENGIO, AND AARON COURVILLE: **Deep learning**. *Genet Program Evolvable Mach* 19, 305–307 (2018)
- JARPA, P. “**Quantifying the Differences in Low Probability of Intercept Radar Waveforms Using Quadrature Mirror Filtering**”. 2002. Trabalho de Conclusão de Curso (Engenharia Elétrica) – Naval Postgraduate School, Monterey, California, EUA, 2002.
- KOTA, V. R.; MUNISAMY, S. D. “**High accuracy offering attention mechanisms based deep learning approach using CNN**”/bi-LSTM for sentiment analysis.

International Journal of Intelligent Computing and Cybernetics, [S. l.], v. 15, n. 1, p. 61–74, fev. 2022.

K. PATEL, U. NEELAKANTAN, S. GANGELE, J. G. VACCHANI AND N. M. DESAI, "**Linear frequency modulation waveform synthesis**," 2012 IEEE Students' Conference on Electrical, Electronics and Computer Science, Bhopal, India, 2012

LECUN, Y. et al. "**Gradient-Based Learning Applied to Document Recognition**". Proc. of the IEE, 1998. Disponível em: http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf. Acesso em: 15 ago. 2025.

LI, T., LIU, X., SU, S. **Semi-supervised text regression with conditional generative adversarial networks**. 2022.

MELVIN, W.; SCHEER, J. **Principles of Modern Radar**, Vol. II: Advanced Techniques. Edison: SciTech Publishing, 2013.

MINSKY, M. "**A Framework for Representing Knowledge**." [S. l.]: McGraw Hill, 1974. Disponível em: <https://courses.media.mit.edu/2004spring/mas966/Minsky>. Acesso em: 12 ago. 2025.

PACE, P. **Detecting and Classifying Low Probability of Intercept Radar**. 2. ed. Norwood: Artech House, 2009.

RAFAEL SAKURAI. **Implementando a estrutura de uma Rede Neural Convolutacional utilizando o MapReduce do Spark**. Disponível em: <https://www.sakurai.dev.br/cnn-mapreduce/>. Acesso em: 22 ago. 2025.

R. KUMARI CHILUKURI, H. KISHORE KAKARLA, AND S. KAKARLA, '**Estimation of Intra-Pulse Modulation Parameters of Wideband LPI Radar Using Cyclostationary Algorithm**', **Wideband Wave-Propagating Components for Wireless RF Communications**. IntechOpen, Dec. 17, 2020.

ROHDE SCHWARZ. **Understanding Barker Codes**. YouTube, 2 abr. 2020. Vídeo. Disponível em: <https://www.youtube.com/watch?v=ARspKn76TEU>. Acesso em: 11 ago. 2025.

S. -C. PEI AND S. -G. HUANG, "**STFT With Adaptive Window Width Based on the Chirp Rate**," in *IEEE Transactions on Signal Processing*

S. JEONG et al., "**Real-Time CNN Training and Compression for Neural-Enhanced Adaptive Live Streaming**," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 46, no. 9, pp. 6023-6039, Sept. 2024.

SKOLNIK, M. I. **Introduction to Radar Systems**. Maryland: McGraw-Hill, 2008.

S. WANG AND P. HE, "**Research on Low Intercepting Radar Waveform Based on LFM and Barker Code Composite Modulation**," 2018 International Conference on Sensor Networks and Signal Processing (SNSP), Xi'an, China, 2018, pp. 297-301

VANHOY, G.; SCHUCKER, T.; BOSE, T.” **Classification of LPI radar signals using spectral correlation and support vector machines**”. Analog Integr Circ Sig Process, New York: Springer, 2017. p. 305-313.

VENKATESWARA RAO KOTA, SHYAMALA DEVI MUNISAMY; “**High accuracy offering attention mechanisms based deep learning approach using CNN**”/bi-LSTM for sentiment analysis. International Journal of Intelligent Computing and Cybernetics 2 February 2022; 15 (1): 61–74.

WALENCZYKOWSKA, M.; KAWALEC, A.; KRENC, K. **An Application of Analytic Wavelet Transform and Convolutional Neural Network for Radar Intrapulse Modulation Recognition. *Sensors* 2023, 23, 1986.**

WONG, M. A. AND SCHAACK, C. (1982), “**Using the kth Nearest Neighbor Clustering Procedure to Determine the Number of Subpopulations,**” American Statistical Association Proceedings of the Statistical Computing Section, 40–48.

ZHANG, M.; LIU, L.; DIAO, M. “**LPI Radar Waveform Recognition Based on Time-Frequency Distribution. *Sensors***”, Basel, 2016. Disponível em: <https://www.mdpi.com/14248220/16/10/1682>. Acesso em: 13 set. 2025.