

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

CLASSIFICAÇÃO DE SINAIS RADAR COM INTELIGÊNCIA ARTIFICIAL
APLICADA A IMAGENS: uma análise de aplicabilidade de redes neurais profundas no
aprimoramento da Guerra Eletrônica



PRIMEIRO-TENENTE WILLIAM DOUGLAS SABOIA ELOY

Rio de Janeiro
2025

PRIMEIRO-TENENTE WILLIAM DOUGLAS SABOIA ELOY

CLASSIFICAÇÃO DE SINAIS RADAR COM INTELIGÊNCIA ARTIFICIAL
APLICADA A IMAGENS: uma análise de aplicabilidade de redes neurais profundas no
aprimoramento da Guerra Eletrônica

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

Orientadores:

SCNS Rodrigo da Silva Moreira

SCNS Aline de Oliveira Pinto Silva

Rio de Janeiro

2025

CLASSIFICAÇÃO DE SINAIS RADAR COM INTELIGÊNCIA
ARTIFICIAL APLICADA A IMAGENS: Uma Análise de Aplicabilidade de
Redes Neurais Profundas no Aprimoramento da Guerra Eletrônica


Primeiro-Tenente William Douglas Saboia Eloy

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


Aprovada por:



Aline de Oliveira Pinto Silva, SCNS – IPqM



Rodrigo da Silva Moreira, SCNS – IPqM



Rodolfo Araujo de Azevedo Lima, SCNS – IPqM

RIO DE JANEIRO, RJ – BRASIL
NOVEMBRO DE 2025

Eloy, William Douglas Saboia

Classificação de Sinais Radar com Inteligência Artificial Aplicada a Imagens: Uma Análise de Aplicabilidade de Redes Neurais Profundas no Aprimoramento da Guerra Eletrônica/ William Douglas Saboia Eloy – Rio de Janeiro: MB/CIAA, 2025.

XIII, 95 p.: IL,; 29,7 cm.

Orientador: Rodrigo da Silva Moreira; Aline de Oliveira Pinto Silva

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

Referências Bibliográficas: p. 84-87.

1. Modulação. 2. Redes neurais convolucionais. 3. Classificação. I. Moreira, Rodrigo da Silva, et al. II. Marinha do Brasil, CIAA, Curso de Aperfeiçoamento Avançado em Guerra Eletrônica. III. Título.

Dedico este trabalho a Deus, por Sua graça e direção em todos os meus caminhos, e à minha esposa, por seu amor, apoio e companheirismo ao longo da minha jornada.

Agradecimento

Agradeço, primeiramente, a Deus, pela dádiva do fôlego de vida, pela salvação e pela paz concedida mesmo em tempos de tantos desafios. Foi Sua presença constante no barco da vida que me sustentou e fortaleceu durante toda esta jornada.

Expresso minha profunda gratidão à minha amada esposa Rubya, mulher virtuosa e companheira incansável, que me apoiou com amor, respeito e consideração. Sua paciência e compreensão foram fundamentais para que eu superasse os momentos mais difíceis deste período.

Agradeço, de forma especial, à minha mãe, pelo amor incondicional e pela compreensão diante das minhas muitas ausências, necessárias ao cumprimento das etapas deste curso.

Dirijo também meus sinceros agradecimentos aos meus amigos da Turma Almirante Saboia, que tornaram esta caminhada mais leve e prazerosa, contribuindo com companheirismo e incentivo ao longo dessa derrota.

Por fim, manifesto minha gratidão ao meu Mestre e Orientador, Senhor Rodrigo da Silva Moreira, cuja sabedoria, paciência e dedicação foram essenciais para a conclusão deste trabalho. Suas orientações e ensinamentos foram determinantes para o desenvolvimento desta pesquisa e para o meu crescimento acadêmico e profissional. Muito Obrigado!

“Se você conhece o inimigo e conhece a si mesmo, não precisa temer o resultado de cem batalhas”

Sun Tzu

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

CLASSIFICAÇÃO DE SINAIS RADAR COM INTELIGÊNCIA
ARTIFICIAL APLICADA A IMAGENS: Uma Análise de Aplicabilidade de
Redes Neurais Profundas no Aprimoramento da Guerra Eletrônica

William Douglas Saboia Eloy

Novembro/ 2025

Orientadores: Aline de Oliveira Pinto Silva

Rodrigo da Silva Moreira

Curso de Aperfeiçoamento Avançado em Guerra Eletrônica

Diante dos avanços tecnológicos da guerra moderna, o sucesso de uma operação militar está diretamente relacionado à superioridade no controle do espectro eletromagnético. Paralelamente, nas últimas décadas, observam-se significativos progressos no campo da Inteligência Artificial, impulsionados pelo aumento da capacidade computacional e pela consolidação de algoritmos de aprendizado profundo. Nesse contexto, este trabalho busca contribuir para a modernização da capacidade de Guerra Eletrônica da Marinha do Brasil, em especial no âmbito das Medidas de Apoio à Guerra Eletrônica (MAGE). O estudo tem como objetivo analisar a aplicabilidade de redes neurais profundas na solução do problema de classificação de sinais radar, a partir de suas representações em imagens tempo-frequência. Para isso, foram avaliadas duas arquiteturas de Redes Neurais Convolucionais (CNN): a GoogLeNet e a rede proposta por Kong *et al.* (2018), aplicadas à classificação de diferentes modulações intrapulso em sinais radar, sob distintas condições de razão sinal-ruído (SNR) e épocas de treinamento. As modulações consideradas englobam a modulação em frequência (LFM), as modulações em fase, incluindo os códigos Barker e Frank, as polifásicas (P1–P4), as politemporais (T1–T4), além de sinais não modulados. A classificação precisa dos sinais radar permite uma identificação mais eficiente das emissões eletromagnéticas, favorecendo processos de tomada de decisão de uma Força militar. Assim, a aplicação de novas tecnologias de Inteligência Artificial para a classificação de sinais radar modulados mostra-se promissora para o êxito das operações militares contemporâneas.

Palavras- chave: classificação; modulação; inteligência artificial; radar; sinais.

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

RADAR SIGNAL CLASSIFICATION USING ARTIFICIAL INTELLIGENCE
APPLIED TO IMAGES: An Analysis on the Applicability of Deep Neural Networks to
Enhance Electronic Warfare Capabilities

William Douglas Saboia Eloy

November/ 2025

Advisors: Aline de Oliveira Pinto Silva
Rodrigo da Silva Moreira

Advanced Improvement Course in Electronic Warfare

Given the technological advances of modern warfare, the success of a military operation is directly related to superiority in the control of the electromagnetic spectrum. In parallel, recent decades have witnessed significant progress in the field of Artificial Intelligence, driven by increased computational capacity and the consolidation of deep learning algorithms. In this context, this study aims to contribute to the modernization of the Electronic Warfare capability of the Brazilian Navy, particularly within the scope of Electronic Support Measures (ESM). The objective of this research is to analyze the applicability of deep neural networks in solving the problem of radar signal classification, based on their representations as time–frequency images. To this end, two Convolutional Neural Network (CNN) architectures were evaluated: GoogLeNet and the network proposed by Kong *et al.* (2018), applied to the classification of different intrapulse radar modulations under varying signal-to-noise ratio (SNR) conditions and training epochs. The modulations considered include Linear Frequency Modulation (LFM), phase modulations such as Barker and Frank codes, polyphase modulations (P1–P4), polytemporal modulations (T1–T4), as well as unmodulated signals. Accurate radar signal classification enables more efficient identification of electromagnetic emissions, thus supporting improved decision-making processes within military forces. Therefore, the application of Artificial Intelligence technologies to the classification of modulated radar signals proves to be promising for the success of contemporary military operations.

Keywords: classification; modulation; Artificial Intelligence; radar; signals.

LISTA DE TABELAS

Tabela 1 – Códigos Barkes conhecidos	14
Tabela 2 – Faixa interpretativa de Landis e Koch.	36
Tabela 3 – Comparação geral sobre Acurácia por SNR.	61
Tabela 4 – Escala do nível de concordância (kappa).....	62
Tabela 5 – Verificação do nível de concordância em diferentes SNR	63

LISTA DE FIGURAS

Figura 1- Faixas do espectro eletromagnético.....	6
Figura 2 - Divisão de Capacidade Eletrônica.....	7
Figura 3 - Representação de onda continua.....	10
Figura 4 - Representação de onda pulsada.....	11
Figura 5 - Comparativo entre radar de pulso e LPI.....	12
Figura 6 - Diagrama de transmissão de pulso no código barker 7	14
Figura 7 - Representação de uma triangulação.....	18
Figura 8 – O MAGE MK3.....	19
Figura 9 - unidade de recepção e processamento.....	20
Figura 10 – Representação comparativa do neurônio biológico e sua representação matemática.....	22
Figura 11- Representação de convolução.....	23
Figura 12 - Representação de CNN básica.....	24
Figura 13 - Representação da camada convolucional.....	24
Figura 14 - Processo completo dando origem ao mapa de ativação.....	25
Figura 15 – Representação de um processo de max pooling.....	26
Figura 16 – Representação da CNN proposta por Kong.....	30
Figura 17 - Arquitetura de rede GoogleNet.....	32
Figura 18 - Gráficos após aplicação da STFT	33
Figura 19 - Gráficos após aplicação da STFT com SNR -25dB e 0 db para Frank e Barker 13	33
Figura 20 – Representação da Matriz de confusão.....	35
Figura 21 - Matriz de confusão geral de 2 épocas com os dados de treinamento (CNN proposta por KONG et al.).....	37
Figura 22 - Representação do progresso da CNN proposta por KONG et al. em 2 épocas.....	37
Figura 23 - Matriz de confusão geral de 6 épocas com os dados de treinamento (CNN proposta por KONG et al.).....	38
Figura 24 - Representação do progresso da CNN proposta por KONG et al em 6 épocas.....	39
Figura 25 - Matriz de confusão geral de 2 épocas com os dados de treinamento, SNR<-10 dB (CNN proposta por KONG et al.).....	40
Figura 26 - Matriz de confusão geral de 2 épocas com os dados de treinamento, -10dB<=SNR<0 dB (CNN proposta por KONG et al.).....	41
Figura 27 - Matriz de confusão de 2 épocas com os dados de treinamento, SNR >= 0 dB (CNN proposta por KONG et al.).....	41
Figura 28 - Matriz de confusão geral de 6 épocas com os dados de treinamento, SNR<-10 dB (CNN proposta por KONG et al.).....	42
Figura 29 – Matriz de confusão geral de 6 épocas com os dados de treinamento, -10dB<=SNR<0 dB (CNN proposta por KONG et al.).....	42
Figura 30 Matriz de confusão de 6 épocas com os dados de treinamento, SNR >= 10 dB (CNN proposta por KONG et al.).....	43
Figura 31-Matriz de confusão geral de 2 épocas com os dados de teste (CNN proposta por KONG et al.).....	44
Figura 32 – Gráfico de acurácia de 2 épocas com os dados de teste (CNN proposta por KONG et al.).....	44
Figura 33- Matriz de confusão geral de 2 épocas com os dados de teste para SNR>=0dB (CNN proposta por KONG et al.).....	45
Figura 34– Matriz de confusão geral de 2 épocas com os dados de teste, -10dB<=SNR<0 dB (CNN proposta por KONG et al.).....	45

Figura 35 - Matriz de confusão geral de 2 épocas com os dados de teste, SNR<-10 dB (CNN proposta por KONG et al.).....	46
Figura 36- Matriz de confusão geral de 6 épocas com os dados de teste (CNN proposta por KONG et al.).	47
Figura 37 – Gráfico de acurácia de 6 épocas com os dados de teste (CNN proposta por KONG et al.).....	47
Figura 38 - Matriz de confusão geral de 6 épocas com os dados de teste para SNR >= 0 dB (CNN proposta por KONG et al.).....	48
Figura 39 – Matriz de confusão de 6 épocas com os dados de teste, para -10dB<=SNR<0 dB (CNN proposta por KONG et al.).....	48
Figura 40 - Matriz de confusão de 6 épocas com os dados de teste, SNR < -10 dB (CNN proposta por KONG et al.)	49
Figura 41 - Matriz de confusão geral de 2 épocas com os dados de teste (GoogLeNet).	50
Figura 42 - Representação do progresso da CNN GoogLeNet em 2 épocas.....	50
Figura 43- Matriz de confusão de 2 épocas com os dados de treinamento, SNR < -10 dB (GoogLeNet).....	51
Figura 44 - Matriz de confusão de 2 épocas com os dados de treinamento, -10dB<=SNR < 0 dB (GoogLeNet).....	51
Figura 45 - Matriz de confusão de 2 épocas com os dados de treinamento, SNR >= 0 dB (GoogLeNet).....	52
Figura 46 – Matriz de confusão geral de 6 épocas com os dados de treinamento (GoogLeNet).....	52
Figura 47 - Matriz de confusão de 6 épocas com os dados de treinamento, SNR <-10 dB (GoogLeNet).....	53
Figura 48 - Matriz de confusão de 6 épocas com os dados de treinamento, -10 dB<=SNR <0 dB (GoogLeNet).....	54
Figura 49- Matriz de confusão de 6 épocas com os dados de treinamento, SNR >= 0 dB (GoogLeNet).....	54
Figura 50 - Matriz de confusão geral treinada em 2 épocas com os dados de teste (GoogLeNet).....	55
Figura 51- Matriz de confusão geral treinada em 2 épocas com os dados de teste SNR < -10dB (GoogLeNet).....	56
Figura 52 - Matriz de confusão geral treinada em 2 épocas com os dados de teste -10 dB <= SNR < 0 dB (GoogLeNet).....	56
Figura 53- Matriz de confusão treinada em 2 épocas com os dados de teste SNR >=0 dB (GoogLeNet).....	57
Figura 54 – Gráfico de acurácia por SNR com dados de teste 2 épocas.	57
Figura 55 – Matriz de confusão geral treinada em 6 épocas com os dados de teste (GoogLeNet).....	58
Figura 56 – Gráfico de acurácia por SNR com dados de teste 6 épocas.	58
Figura 57- Matriz de confusão treinada em 6 épocas com os dados de teste SNR < -10 dB (GoogLeNet).	59
Figura 58 - Matriz de confusão treinada em 6 épocas com os dados de teste -10 dB<= SNR < 0 dB (GoogLeNet).	59
Figura 59 - Matriz de confusão treinada em 6 épocas com os dados de teste SNR ≥ 0 dB (GoogLeNet).....	60
Figura 60 – Comparação de Acurácia entre GoogLeNet e a CNN proposta por Kong et al.com 6 épocas.....	61

LISTA DE SIGLAS E ABREVIATURAS

Síglas	Termo em Inglês	Termo em Português
AGE		Atividades de Guerra Eletrônica
BPSK	<i>Binary Shift Keying</i>	Chaveamento por Deslocamento de Fase Binário
CGAEN		Centro de Guerra Acústica e Eletrônica da Marinha
CGE		Capacidade de Guerra Eletrônica
CNN	Convolutional Neural Network	Rede Neural Convolucional
COC		Centro de Operações de Combate
CW	Continuous Wave	Onda Contínua
CWR	Continuous Wave Radar	Radar de Onda Contínua
DL	<i>Deep Learning</i>	Aprendizagem profunda
EEM		Espectro Eletromagnético
ELINT	<i>Electronic Intelligence</i>	Inteligência Eletrônica
FMOP	<i>Frequency Modulation on Pulse</i>	Pulso Modulado em Frequência
FI		Frequência Instantânea
FN		Falso-Negativo
FP		Falso-Positivo
FSK	<i>Frequency Shift Keying</i>	Chaveamento por Deslocamento de Frequência
GE		Guerra Eletrônica
IA		Inteligência Artificial
IFM	<i>Instantaneous Frequency Measurement</i>	Medição Instantânea em Frequência
IPqM		Instituto de Pesquisas da Marinha
LFM	<i>Linear Frequency Modulation</i>	Modulação linear em Frequência
LP		Largura de Pulso
LPI	<i>Low Probability of Intercept</i>	Baixa Probabilidade de Intercepção

LPID	<i>Low Probability of Intercept/ Detection</i>	Baixa Probabilidade de Intercepção/Detecção
LRN		Rede Neural Profunda
MAE		Medidas de Ataque Eletrônico
MAGE		Equipamentos de Medidas de Apoio à Guerra Eletrônica
MATLAB		<i>Software</i> de computação numérica da empresa Mathworks
MGE		Medidas de Guerra Eletrônica
ML	<i>Machine Learning</i>	Aprendizado de Máquina
MPE		Medidas de Proteção Eletrônica
PDW	Pulse Descriptor Word	Palavra descritora de Pulso
PMOP	<i>Phase Modulation on Pulse</i>	Pulso Modulado em Fase
PR	<i>Pulsed Radar</i>	Radar Pulsado
PRF	<i>Pulse Repetition Frequency</i>	Frequência de Repetição de Pulsos
PRI	<i>Pulse Repetition Interval</i>	Período de Repetição de Pulso
PSL	<i>Peak SideLobe</i>	Nível do Lóbulo Lateral
RCS	<i>Radar Cross Section</i>	Seção Reta Radar
ReLU	<i>Rectified Linear Unity</i>	Unidade Linear Retificada
RETRON		Reconhecimento Eletrônico
RF		Radiofrequência
SNR	<i>Signal-to-noise ratio</i>	Razão Sinal-Ruído
TDW	<i>Time Descriptor Word</i>	Palavra Descritora de Pulso
VN		Verdadeiro Negativo
VP		Verdadeiro Positivo
WGN	<i>White Gaussian Noise</i>	Ruido Branco Guassiano

LISTA DE SÍMBOLOS

A	Amplitude
B	Largura de banda
$b_{(k)}$	Bias
dB	Decibéis
f_c	Frequência da portadora
FP	Quantidade de falsos-positivos no cálculo do índice $kappa$
FN	Quantidade de falsos-negativos no cálculo do índice $kappa$
$K_{(x,y)}$	<i>Kernel</i> polinomial
$kappa$	Índice para cálculo do nível de concordância ou eficiência do classificador
L	Representação da ordem do código P1 e P2
M	Razão de compressão
$\text{Max}\{0, x\}$	Função que retorna 0 para valores negativos e repete valores positivos
$\text{mod}(x)$	Operação matemática que resulta o resto da divisão (aritmética modular)
n	Número de estados ou mudanças de fase
P_T	Potência do eco recebida pelo radar
P_{Mage}	Potência recebida pelo MAGE
P_o	Proporção de concordância observada
P_e	Proporção de concordância estimada
$\text{Rect}(t/\tau)$	Função retangular com PW igual a τ
R_T	Alcance de um sistema MAGE
R_R	Alcance do Radar
t	Tempo
T	Período de duração do código
VP	Quantidade de verdadeiros-positivos no cálculo do índice $kappa$

VN	Quantidade de verdadeiros-negativos no cálculo do índice <i>kappa</i>
$\text{INT} [\]$	Função <i>floor</i>
$\emptyset_k$	Fase do sinal ($\emptyset_{Frank}, \emptyset_{P1}, \emptyset_{P2}, \emptyset_{P3}, \emptyset_{P4}, \emptyset_{T1}, \emptyset_{T2}, \emptyset_{T3}, \emptyset_{T4}$)
Σ	Somatório

SUMÁRIO

1 INTRODUÇÃO.....	1
1.1 Contextualização	1
1.2 Apresentação do Problema	3
1.3 Justificativa e Relevância.....	3
1.4 Objetivo Geral	4
1.4.1 Objetivos Específicos	4
1.5 Estruturação do Trabalho	4
2 REFERENCIAL TEÓRICO	5
2.1 Guerra Eletrônica	6
2.2 O Radar	9
2.2.1 Radares de Onda Contínua e Radares Pulsados	9
2.2.2 Radares LPI	11
2.2.3 Modulação de Pulsos	12
2.2.4 Código Barker	13
2.2.5 Polifásicos (P1, P2, P3, P4 e Frank)	14
2.2.6 Politemporais (T1, T2, T3 e T4)	16
2.3 Sistema MAGE	17
2.4 A Inteligência Artificial	21
2.4.1 Rede Neural	21
2.4.2 A Convolução	22
2.4.3 Rede Neural Convolucional.....	23
2.4.4 A Camada de Convolução.....	24
2.4.5 Camada de Pooling.....	25
2.4.6 Camada Totalmente Conectada	26
2.5 A Classificação de Sinais	26
3 METODOLOGIA	27
3.1 Quanto aos Fins.....	27
3.2 Quanto aos Meios.....	27
3.3 Quanto à natureza do método	28
3.4 Limitações do Método.....	28
3.5 Coleta de Dados e Treinamento	28
3.6 Os Algoritmos de Classificação Baseados em CNN.....	29
3.6.1 Rede Neural Convolucional Proposta por Kong <i>et al.</i> (2018).....	29

3.6.2 GoogLeNet.....	31
4 SIMULAÇÕES E ANÁLISE DOS RESULTADOS	32
4.1 Resultados da CNN Proposta por Kong <i>et al.</i> (2018)	36
4.1.1 Treinamento da CNN em 2 Épocas	36
4.1.2 Treinamento da CNN em 6 Épocas	38
4.1.3 Treinamento da CNN em 2 Épocas para Diferentes Intervalos de SNR.....	39
4.1.4 Treinamento da CNN em 6 Épocas para Diferentes Intervalos de SNR	41
4.1.5 Teste da CNN Treinada em 2 Épocas.....	43
4.1.6 Treinamento da CNN em 2 Épocas para Diferentes Intervalos de SNR.....	44
4.1.7 Teste da CNN Treinada em 6 Épocas.....	46
4.1.8 Testes da CNN Treinada em 6 Épocas para Diferentes Intervalos de SNR.....	47
4.2 Resultados da CNN GoogLeNet	49
4.2.1 Treinamento da CNN GoogLeNet em 2 Época	49
4.2.2 Treinamento da CNN GoogLeNet em 2 Épocas para Diferentes Intervalos de SNR.....	50
4.2.3 Treinamento da CNN GoogLeNet em 6 Época	52
4.2.4 Treinamento da CNN em 6 Épocas para diferentes intervalos de SNR	53
4.2.5 Teste da CNN GoogLeNet Treinada em 2 Épocas.....	54
4.2.6 Teste da CNN GoogLeNet treinada em 2 Épocas para Diferentes Intervalos de SNR	55
4.2.7 Testes da GoogLeNet Treinada em 6 Épocas.....	57
4.2.8 Testes da GoogLeNet Treinada em 6 Épocas para Diferentes Intervalos de SNR	58
5 COMPARAÇÃO ENTRE OS 2 CLASSIFICADORES	60
6 CONCLUSÃO.....	64
6.1 Sugestão para Trabalhos Futuros	65
REFERÊNCIAS.....	66
APÊNDICE A – RESULTADO DA SIMULAÇÃO GOOGLINET TREINADA COM 6 ÉPOCAS	70
APÊNDICE B – RESULTADO DA SIMULAÇÃO GOOGLINET TREINADA COM 2 ÉPOCAS	72
APÊNDICE C – RESULTADO DA SIMULAÇÃO CNN PROPOSTA POR KONG ET AL. (2018) TREINADA COM 6 ÉPOCAS	74
APÊNDICE D – RESULTADO DA SIMULAÇÃO CNN PROPOSTA POR KONG ET AL. (2018) TREINADA COM 2 ÉPOCAS	76

1 INTRODUÇÃO

Este capítulo visa contextualizar o tema Classificação de Sinais Radar com Inteligência Artificial Aplicada a Imagens, iniciando com um sucinto panorama histórico da evolução tecnológica dos sistemas que utilizam o espectro eletromagnético (EEM) para fins militares. São apresentados, também, o problema da pesquisa, sua justificativa, os objetivos e as etapas de desenvolvimento do trabalho.

1.1 Contextualização

As guerras são travadas em diversos ambientes e teatros de operações. Fragatas, corvetas e submarinos atuam no ambiente naval; tanques, lançadores múltiplos de foguetes e tropas de infantaria, no ambiente terrestre; caças, helicópteros e aeronaves de patrulha, no ambiente aéreo. Entretanto, há um ambiente que permeia todos os demais: o eletrônico. Na Guerra Eletrônica, a superioridade no uso pelas suas forças e na negação do EEM pelo inimigo garante uma vantagem estratégica decisiva para qualquer força militar.

Nos séculos XIX e XX, com as descobertas no campo do eletromagnetismo por James Clerk Maxwell (1831–1879), no âmbito teórico, e por Heinrich Rudolph Hertz (1857–1894), no campo experimental, lançaram-se as bases para que Guglielmo Marconi, em 1900, desenvolvesse o rádio. A criação da “telegrafia sem fio”, ou radiocomunicação, foi rapidamente incorporada pelas principais marinhas do mundo, tendo seu primeiro uso em combate ocorrido na Batalha Naval de Tsushima, em 1905, entre a Rússia e o Japão (Siston, 2023).

A Batalha de Tsushima, ocorrida entre 1904 e 1905, durante a Guerra Russo-Japonesa, destacou-se por ser o primeiro relato documentado do emprego de Guerra Eletrônica (GE). Nessa ocasião, as forças navais russas, ao realizarem o trânsito pelo Estreito de Tsushima, restringiram a intensidade das luzes de navegação e suas emissões telegráficas, de modo a evitar a detecção pelos japoneses. Entretanto, a força naval foi avistada por um navio japonês, que, por sua vez, utilizou amplamente a telegrafia para transmitir as coordenadas da Armada Russa, enquanto os russos tentaram interferir na troca de mensagens. A livre utilização do EEM possibilitou uma vantagem decisiva, que culminou na vitória japonesa (Leite Junior, 2021).

Contudo, foi na Primeira Guerra Mundial que o uso de interferência e bloqueios em sistemas de comunicação passou a ser amplamente explorado. Nesse episódio, destaca-se a interferência causada por franceses e ingleses nos sinais eletromagnéticos

utilizados pelos zepelins para a navegação dos bombardeiros alemães. O domínio sobre as comunicações tornou-se uma vantagem tática evidente no campo de batalha.

Durante a Segunda Guerra Mundial, houve o desenvolvimento efetivo do *radio detection and ranging* — o radar. Essa tecnologia proporcionou significativa vantagem às forças aliadas, com destaque para o alarme aéreo antecipado e a detecção de submarinos alemães navegando na superfície, além do desenvolvimento de contramedidas eletrônicas eficazes, no que ficou conhecido por Winston Churchill como a “Batalha do Feixe” (Spreckelsen, 2018).

Com o objetivo de detectar esses novos sensores, foram projetados equipamentos de Medida de Apoio Guerra Eletrônica (MAGE), que permite detectar, localizar, classificar e identificar, por meio de um banco de dados, de forma passiva, ou seja, sem emissão, as emissões eletromagnéticas do inimigo, como por exemplo a operação de um radar.

Ao longo dos mais diversos conflitos armados, os sistemas eletrônicos têm sido continuamente aperfeiçoados, com destaque para os radares de baixa probabilidade de interceptação (LPI), plataformas *stealth* e veículos não tripulados (drones). Além disso, os cenários de operação tornam-se cada vez mais saturados e variáveis no quesito *clutter*. Dessa forma, cresce também a necessidade de desenvolvimento de sistemas mais eficientes para a classificação e análise de sinais eletromagnéticos, visando uma identificação e classificação mais rápida e precisa.

Nesse contexto, a Inteligência Artificial, por meio de técnicas como Redes Neurais Convolucionais (CNN), Redes Neurais Recorrentes, como a rede de Elman, e o método *Support Vector Machine*, tem se destacado em aplicações militares. Essas tecnologias possibilitam a detecção e classificação rápida e precisa de emissões radar por uma análise tempo-frequência, contribuindo para a compilação do quadro tático e assessoramento à tomada de decisão (Benecase Junior, 2023).

Dessa forma, esta monografia tem como objetivo examinar a aplicabilidade de redes neurais nos sistemas MAGE embarcados nos meios operativos da Marinha do Brasil. Embora seu uso esteja diretamente relacionado ao aprimoramento das capacidades em Guerra Eletrônica, tais ferramentas também conferem vantagens táticas significativas aos Sistemas de Combate, com impactos relevantes nas operações de guerra de superfície e antiaérea. Além disso, contribuem para uma navegação mais segura, ao oferecer soluções mais eficientes para os problemas de classificação e identificação de emissores radar.

1.2 Apresentação do Problema

Diante das contínuas inovações tecnológicas no âmbito da Guerra Eletrônica, especialmente no campo das Medidas de Apoio à Guerra Eletrônica, a identificação eficiente de sinais radar permanece sendo um desafio constante. Os métodos tradicionais de classificação e identificação de imagens espectrais resultantes de uma transformada tempo-frequência apresentam limitações significativas quanto ao processamento dos dados recebidos e à sensibilidade aos ruídos presentes nas informações coletadas em um cenário cada vez mais saturado.

Também é importante destacar o acelerado avanço das armas de natureza sintética. Drones aéreos e marítimos, mísseis balísticos e táticos hipersônicos, além de caças *stealth*, compõem hoje um conjunto de ameaças enfrentadas por diversas Marinhas em conflitos ao redor do mundo. Esses emissores, devido às novas tecnologias empregadas pelos seus radares, dificultam sua detecção e classificação pelos equipamentos MAGE, prejudicando diretamente a compilação do quadro tático e comprometendo a consciência situacional.

Nesse sentido, o emprego de redes neurais profundas, como as CNNs, apresenta soluções promissoras para superar as limitações dos sistemas tradicionais aprimorando a precisão e a eficiência das análises dos sinais radar. Este aprimoramento pode ocorrer por meio da seleção do classificador do tipo de modulação intrapulso aplicado à imagens no domínio tempo-frequência mais eficiente.

Neste trabalho, serão simulados sinais com modulação em frequência, como a *Linear Frequency Modulation* (LFM), e com modulação em fase, incluindo os sinais polifásicos (P1, P2, P3, P4 e Frank), os politemporais (T1, T2, T3 e T4) e o bifásico Barker.

Esses sinais serão classificados por meio da rede GoogLeNet proposta Szegedy *et al.* (2015), e de uma rede CNN adaptada proposta por Kong *et al.* (2018). Após a realização das classificações, os resultados obtidos serão analisados e comparados quanto à sua eficiência.

1.3 Justificativa e Relevância

Este trabalho visa contribuir com a literatura nacional, especialmente no contexto da guerra naval pela Marinha do Brasil, ao propor uma abordagem comparativa entre diferentes arquiteturas de redes neurais aplicadas à classificação do tipo de modulação intrapulso em imagens resultantes da transformada tempo-frequência, descrevendo suas características, diferenças e possíveis integrações aos sistemas MAGE presentes nos

navios da Marinha do Brasil.

A relevância deste trabalho está associada ao aprimoramento da capacidade de Guerra Eletrônica da Marinha do Brasil, por meio da incorporação de tecnologias baseadas em processamento por Inteligência Artificial, assessorando o operador que guarnece o Centro de Operações de Combate (COC). Os resultados obtidos poderão subsidiar futuras aquisições e fomentar o desenvolvimento nacional de equipamentos e sistemas de MAGE, sejam embarcados em navios, aeronaves ou instalados em veículos terrestres destinados à defesa costeira, contribuindo significativamente para a efetiva aplicação do Poder Naval.

1.4 Objetivo Geral

Avaliar a aplicabilidade de técnicas de inteligência artificial para a classificação de sinais radar com modulação intrapulso em sistema MAGE na Marinha do Brasil ao conduzir uma análise comparativa da eficiência de duas Redes Neurais Convolucionais (CNN).

1.4.1 Objetivos Específico

Analisar e comparar o desempenho de Redes Neurais Convolucionais (CNN), como a GoogLeNet desenvolvida por Szegedy *et al.* (2015), e uma arquitetura adaptada da rede CNN proposta por Kong *et al.* (2018), na classificação de sinais radar, visando sua aplicação em sistemas MAGE voltados para a Guerra Eletrônica, sendo diretamente aplicáveis aos navios da Marinha do Brasil.

Descrever as principais características dos sinais radar empregados na guerra naval moderna, investigando os fundamentos das arquiteturas CNN selecionadas e sua aplicação na classificação de sinais radar por meio de imagens espectrais resultantes de transformadas tempo-frequência.

1.5 Estruturação do Trabalho

Este trabalho está dividido em seis capítulos. O primeiro capítulo apresenta uma introdução geral ao tema, abordando a evolução histórica da Guerra Eletrônica, desde os primeiros conflitos até os conflitos mais recentes, marcada pelo desenvolvimento tecnológico e pelo emprego crescente da Inteligência Artificial. Nesse contexto, são apresentados o propósito da pesquisa, o problema de classificação enfrentado nos sistemas MAGE, os objetivos e a relevância do estudo para o campo da defesa.

O segundo capítulo trata do embasamento teórico necessário para a compreensão do tema. São apresentadas as definições e subdivisões a respeito da Guerra Eletrônica, com foco em Medidas de Apoio à Guerra Eletrônica (MAGE), além de explicações sobre o funcionamento do radar, os diferentes tipos de modulação intrapulso e os desafios existentes na classificação e identificação de sinais. Também são introduzidos os conceitos de Inteligência Artificial, Aprendizado Profundo e Redes Neurais Convolucionais, com destaque para as arquiteturas GoogLeNet e a proposta por Kong *et al.* (2018), que fundamentam as simulações desenvolvidas.

No terceiro capítulo, é descrita a metodologia aplicada. São detalhados os procedimentos de simulação e coleta dos dados, a geração das imagens tempo-frequência no MATLAB, a estrutura de cada classificador, bem como as métricas utilizadas para avaliar o desempenho — incluindo a matriz de confusão, a acurácia e o índice Kappa, segundo o método de Landis e Koch (1977).

O quarto capítulo apresenta os resultados obtidos nas simulações realizadas, tanto para a CNN proposta por Kong *et al.* quanto para a GoogLeNet. São analisados os desempenhos em diferentes condições de razão sinal-ruído (SNR) e épocas de treinamento, evidenciando a eficiência de cada modelo de classificação frente à variação dos parâmetros.

O quinto capítulo reúne a análise comparativa entre as arquiteturas estudadas, destacando o desempenho geral de cada rede, o grau de concordância entre as classificações e a eficiência dos resultados. Por fim, no sexto capítulo são apresentadas as considerações finais e sugestões para futuras pesquisas sobre a aplicação de Inteligência Artificial em sistemas de guerra eletrônica da Marinha do Brasil.

2. REFERENCIAL TEÓRICO


Este capítulo estabelece os conceitos teóricos que servem de alicerce para o desenvolvimento deste trabalho. Inicialmente, serão apresentados os fundamentos da Guerra Eletrônica (GE) e das Medidas de Apoio à Guerra Eletrônica (MAGE), destacando sua importância para a detecção, identificação e classificação de emissões eletromagnéticas no cenário de guerra. Em seguida, serão abordados os conceitos sobre Radar e suas principais modulações intrapulso, que constituem a base para a formação dos sinais que serão analisados na simulação. Na sequência, será apresentado o sistema MAGE e suas capacidades frente ao Radar, apresentando a análise tempo-frequência utilizada no processamento dos sinais radar responsáveis pela geração das imagens tempo-frequência empregadas nesta pesquisa. Por fim, será introduzido o ponto central

do estudo, com a apresentação dos fundamentos da Inteligência Artificial, do Aprendizado Profundo (*Deep Learning*) e das Redes Neurais Convolucionais, evidenciando o motivo pelo qual tais ferramentas se mostram adequadas à classificação de sinais radar em variados cenários de razão sinal-ruído.

2.1 Guerra Eletrônica

No cenário da guerra moderna, são constantes as interações entre irradiações eletromagnéticas das forças adversárias, uma vez que grande parte dos sistemas de armas e de Comando e Controle depende do uso de equipamentos eletrônicos. É nesse campo de batalha eletromagnético que se insere a Guerra Eletrônica (GE). A GE é definida como o conjunto de ações que visa explorar as emissões do inimigo em toda a faixa do espectro eletromagnético (Figura 1) — desde os raios gama até as ondas de rádio de maior comprimento — abrangendo, inclusive, as faixas visível, infravermelha e ultravioleta. Com base nessas informações, é possível identificar as intenções, capacidades e até a ordem de batalha do oponente. Além disso, a GE permite à força empregadora adotar medidas destinadas a negar, reduzir ou impedir o uso eficaz dos equipamentos eletrônicos inimigos.

Figura 1- Faixas do espectro eletromagnético.




Fonte: CESAD/UFS (2013, p.10).

A doutrina de Guerra Eletrônica é dinâmica, acompanhando os constantes avanços tecnológicos, e exige dedicação contínua à Ciência, à Tecnologia e à Inovação, inclusive em tempos de paz. Nesse período, mantém-se ativa a atividade de inteligência, com o objetivo de atualizar as capacidades tanto das forças inimigas quanto das aliadas,

além de promover o treinamento para o emprego adequado dos equipamentos, a modernização dos sistemas de combate e a busca constante pelo desenvolvimento tecnológico (Marinha do Brasil, 2023).

Na Marinha do Brasil, a doutrina adotada tem como um dos conceitos básicos a Capacidade de Guerra Eletrônica (CGE). A CGE corresponde ao somatório de recursos que a Marinha pode efetivamente empregar em suas operações envolvendo a Guerra Eletrônica, sendo dividida em Atividades de Guerra Eletrônica (AGE) e Medidas de Guerra Eletrônica (MGE). Neste trabalho, dá-se atenção especial a AGE em sua ramificação – Reconhecimento Eletrônico (RETRON) e MGE em sua ramificação – Medida de Apoio de à Guerra Eletrônica (MAGE).

Figura 2 - Divisão de Capacidade Eletrônica.



Fonte: Elaborada pelo autor (2025).

Atividades de GE são as atividades de caráter estratégico, operacional, tático, logístico ou de pesquisa que contribuem para o estabelecimento, para a exploração, para a reformulação ou verificação da capacidade de GE e para o apoio ao planejamento do seu emprego em operações (Ministério da Defesa, 2023).

O RETRON consiste em um conjunto de atividades, de natureza estratégica e operacional, voltadas à identificação de sinais emitidos por forças inimigas, bem como à aquisição e ao processamento de informações sobre as capacidades de Guerra Eletrônica do oponente, com o objetivo de proteger a Força e assegurar o uso EEM. Essas atividades envolvem a inteligência de comunicações, a inteligência eletrônica e a inteligência de imagens, as quais buscam obter parâmetros técnicos e subsidiar as ações de Guerra Eletrônica e o processo de tomada de decisão (Marinha do Brasil, 2023).

No âmbito da Marinha do Brasil, informações técnicas coletadas — como, por exemplo, tipos de modulação intrapulso — podem ser gravadas e incorporadas à Biblioteca Fênix, mantida pelo Centro de Guerra Acústica e Eletrônica da Marinha

(CGAEN). Esse procedimento contribui para o enriquecimento da base de dados de sinais, permitindo maior precisão na classificação e identificação de emissores hostis, bem como na elaboração de contramedidas adequadas. Dessa forma, o RETRON torna-se fundamental para ampliar o conhecimento sobre as intenções, capacidades, localização, limitações e disposições das fontes emissoras, fortalecendo a capacidade de resposta e a superioridade no uso do EEM.

As Medidas de Apoio da Guerra Eletrônica são responsáveis por garantir a consciência situacional imediata do ambiente eletromagnético. Essas medidas consistem em coletar informações de GE, que são as características das emissões radar, por meio dos seguintes procedimentos sistemáticos: busca, detecção, localização, extração das características e análise das emissões, após comparar com informações contidas em bancos de dados, a identificação do emissor. A classificação da modulação intrapulso faz parte do processo de extração de características. Por meio dessas informações, a força naval pode construir a compilação do quadro tático das unidades inimigas, reconhecer ameaças como mísseis e radares de tiro, vulnerabilidades dos sistemas eletromagnéticos adversários, para subsidiar possível ataque eletrônico (MAE), e também úteis para contramedidas das forças amigas, em medidas de proteção MPE.

Apesar da similaridade, as MAGE têm como finalidade apoiar as Forças Navais durante as operações, auxiliando o processo decisório em caráter tático diante de emissões provenientes de radares ou sistemas de comunicações. Por sua vez, o RETRON, em caráter estratégico, realiza levantamentos por meio das próprias MAGE para subsidiar ações futuras, encaminhando os dados obtidos ao CGAEN, responsável pela atualização da biblioteca. (Marinha do Brasil, 2023)

A *Electronic Intelligence*, traduzido por Inteligência Eletrônica (ELINT), está relacionada à inteligência estratégica, sendo responsável pela coleta, interceptação, processamento e análise de sinais eletromagnéticos, tendo como missão a obtenção de informações acerca das capacidades inimigas no campo da Guerra Eletrônica (GE). (Neri, 2018)

O objetivo da ELINT é identificar sistemas radar inimigos por meio da detecção e análise de parâmetros de pulsos, tais como largura de banda de frequências, frequência, PRI, largura de pulso, tipo de modulação, entre outros. Além disso, visa localizar e identificar padrões de operação das forças adversárias, bem como realizar estudos sobre Medidas de Ataque Eletrônico (MAE), modulações e formas de onda. Esses estudos possibilitam a criação de corredores seguros para aproximação e ataque, reduzindo a probabilidade de detecção por radares inimigos; a execução de ataques eletrônicos; a

atualização de bibliotecas de guerra eletrônica, como a Fênix da Marinha do Brasil; o monitoramento de áreas de interesse; e o aprimoramento da classificação e identificação de imagens de radar nos sistemas MAGE aliados (Neri, 2018).

Tais sistemas podem ser empregados como ferramentas ELINT ao realizar a gravação de sinais de radar — como, por exemplo, o MAGE desenvolvido pelo IPqM, denominado MAGE MK3, que registra TDW – o comportamento temporal de um conjunto de pulso, PDW – que descreve um conjunto de informações digitalizadas do pulso e outros parâmetros. Contudo, esse equipamento apresenta a limitação de não efetuar a análise ELINT, a qual é realizada no CGAEM.

2.2 O Radar

Radar é um acrônimo do inglês *Radio Detection and Ranging*, formado pelos termos “detecção” e “medição de distância”. Esse sistema opera por meio da emissão de ondas eletromagnéticas e de sua posterior recepção após a reflexão em um alvo. As ondas refletidas indicam a presença do alvo e, a partir do processamento do sinal, é possível extrair diversos parâmetros. Desde a sua criação, os principais parâmetros obtidos são a detecção, a localização e a determinação da direção e velocidade de deslocamento dos alvos. O desenvolvimento do radar representou uma inovação tanto na esfera militar quanto na civil, devido à vantagem de operar em condições climáticas adversas ou quando o alvo se encontra a distâncias além do alcance visual. (Serra, 2019)

O princípio básico de funcionamento do radar é constituído por um conjunto de subsistemas principais, tais como transmissor, receptor e processador. O transmissor é responsável por gerar a onda eletromagnética e atribuir-lhe uma forma específica, a qual é irradiada por meio de uma antena. Após a transmissão, parte da energia da onda é refletida pelo alvo e retorna ao sistema em intensidade atenuada, sendo captada pela antena do subsistema receptor. Nesse estágio, o sinal é amplificado, o ruído (interferência indesejada) é atenuado e, em seguida, o processamento do sinal permite a detecção da presença do alvo, bem como a extração de outros parâmetros de interesse (Skolnik, 2001).

Os radares são classificados e empregados, em geral, de acordo tanto com a forma de onda utilizada quanto com a banda de operação. Conforme suas características, podem ser divididos em radares de onda contínua ou radares pulsados.

2.2.1 Radares de Onda Contínuas e Radares Pulsados

Os radares de onda contínua (CWR) emitem sinais de forma ininterrupta, mantendo a frequência constante. Nesse tipo de sistema, as antenas de transmissão e

recepção encontram-se separadas, caracterizando os chamados sistemas biestáticos. Por não utilizarem pulsos, os CWR não fornecem diretamente a informação de distância do alvo; entretanto, podem ser empregados em conjunto com outros radares ou sistemas ópticos para suprir essa limitação. (Figueirêdo, 2019)


A principal aplicação dos radares de onda contínua é a medição da velocidade de alvos em movimento, uma vez que, por meio do Efeito Doppler, também é possível determinar a posição angular do alvo. Esses sistemas emitem uma forma de onda senoidal com amplitude e frequência constantes, conforme ilustrado na Figura 3.

Além disso, os radares pulsados podem operar por meio da transmissão de ondas pulsadas. Nesse caso, trens de pulsos são irradiados em um feixe eletromagnético estreito e de formato retangular, geralmente utilizando apenas uma antena para transmissão e recepção, caracterizando os chamados sistemas monostáticos, conforme ilustrado na Figura 4.

Os principais parâmetros de uma forma de onda de radar pulsado podem ser divididos em parâmetros interpulso e parâmetros intrapulso. Entre os parâmetros interpulso, destacam-se: o Intervalo de Repetição de Pulso (PRI), a Frequência de Repetição de Pulso (PRF), o padrão de varredura e a taxa de varredura. Já entre os parâmetros intrapulso, incluem-se: a frequência da portadora, a largura de pulso (LP), a amplitude e a modulação interna de pulso. Ressalta-se que $PRI = 1/PRF$. (Figueirêdo, 2019)


Segundo Serra (2019), a forma de onda representada na Figura 4 permite visualizar esses elementos de forma integrada, evidenciando a relação inversa entre PRI e PRF, bem como a LP, que possui papel operacional prático ao determinar a distância mínima de detecção do radar e a discriminação de alvos em diferentes distâncias.

Figura 3 - Representação de onda contínua.



Fonte: Figueirêdo (2019).

Figura 4 - Representação de onda pulsada.



Fonte: Figueirêdo (2019).


2.2.2 Radares LPI

No contexto atual, com a constante evolução dos equipamentos eletrônicos de processamento, sobretudo aplicados em sistemas de detecção, os sistemas MAGE acompanham esse desenvolvimento em ritmo equivalente. Os radares LPI (Low Probability of Intercept) representam um avanço tecnológico significativo no campo da Guerra Eletrônica, configurando-se como um desafio para os novos sistemas MAGE, uma vez que dispõem de recursos e características específicas que os tornam mais discretos quanto à detecção, classificação e identificação por sistemas de ELINT.

Entre essas características, destacam-se: antenas com lóbulos laterais reduzidos, que minimizam emissões em setores indesejados; padrões variados de varredura, que dificultam a classificação do radar; transmissão em banda larga; gerenciamento de potência; baixa potência de pico, que assegura maior discrição; e técnicas de compressão de pulso. Dessa forma, um radar LPI ou LPID (Low Probability of Detection)¹ é capaz de detectar um alvo sem que um sistema passivo, localizado no próprio alvo ou em sua proximidade, consiga detectá-lo ou, caso o faça, não tenha condições de classificá-lo ou identificá-lo. Conforme ilustrado na Figura 5, o radar LPI também apresenta vantagens táticas em condições de baixa razão sinal-ruído, ao emitir a forma de onda em uma larga faixa de frequências, mantendo-a no mesmo nível do ruído do receptor. Essa característica dificulta sobremaneira a detecção por receptores convencionais. (Silva Junior, 2018)

¹ Um radar LPID é uma variação de radar LPI cuja forma de onda dificulta a correta estimação dos parâmetros (LP, frequência, modulação, PRI, entre outros), bem como a classificação e a identificação do radar por receptores passivos.

Figura 5 - Comparativo entre radar de pulso e LPI.



Fonte: Silva Junior (2018).

2.2.3 Modulação de Pulsos

Segundo Alves *et al.* (2021), com a evolução dos radares modernos LPI/LPID e o desenvolvimento das técnicas de compressão de pulso, tornou-se possível modular o sinal em fase (PMOP, do inglês modulation on pulse) ou em frequência (FMOP, do inglês frequency modulation on pulse), de acordo com um padrão determinado. Dessa forma, ocorre uma quebra de paradigma, pois o sinal do radar não se limita a uma senoide pura, em uma única frequência, o que possibilita a estimação de parâmetros importantes do alvo com maior precisão. Além disso, tais técnicas comprometem a eficácia dos processos de detecção e identificação executados pelos sistemas MAGE.

A técnica de compressão de pulso permite conciliar pulsos longos — necessários para melhor detecção devido à elevada energia transmitida — com a precisão em distância obtida por pulsos curtos. Isso é realizado mediante a aplicação de modulação em frequência (FM) a um pulso longo na transmissão e pela utilização de um filtro casado na recepção, que “comprime” o pulso no tempo sem perda de energia, aumentando sua amplitude de pico e reduzindo sua duração. O resultado é um ganho simultâneo em alcance de detecção e resolução em distância. Contudo, o processo gera lóbulos laterais que podem confundir alvos próximos, sendo controlados por filtros específicos (Peebles Junior, 1998).

A utilização dessas técnicas de modulação traz uma série de outras vantagens relevantes para o desempenho dos sistemas de radar. Entre elas, destaca-se o aumento da razão sinal-ruído, que possibilita ao radar reduzir a influência das interferências ambientais — o ruído — e, conseqüentemente, melhorar a qualidade do sinal (Neri, 2018).

Outra vantagem crucial relaciona-se à capacidade operacional com menores potências do sinal transmitido, característica essencial em radares LPI/LPID, que

conseguem reduzir a potência ao utilizarem sinais contínuos (CW). Nos casos de FMOP, há o espalhamento da energia do sinal no espectro, o que dificulta a detecção por sistemas MAGE, que podem identificar sinais pelo nível de magnitude no domínio da frequência. Por fim, o uso da modulação intrapulso de fase pseudoaleatória confere maior discríção ao radar LPI (Neri, 2018).

Neste trabalho, serão apresentadas as seguintes modulações que participarão das simulações no software MATLAB: LFM, Barker, Frank, P1, P2, P3, P4, T1, T2, T3 e T4.

A modulação Linear de Frequência (LFM), também conhecida como chirp, é descrita por Richter (2019) como uma técnica bastante comum em radares LPI. Ela se baseia na variação linear da frequência da portadora do pulso, resultando em melhor resolução em distância com menor energia do sinal transmitido. A forma de onda LFM, ou chirp, é um sinal passa-banda representado pela expressão (1), em que T corresponde à largura de pulso, A é a amplitude, α à inclinação – expressão (3), f_c à frequência da portadora e a função rect pela expressão 2.

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

$$\text{rect}(x) = \begin{cases} 1, & |x| < \frac{1}{2} \\ 0, & |x| > \frac{1}{2} \end{cases} \quad (2)$$

$$\alpha = \pm \frac{B}{T} \quad (3)$$

Melo (2023) descreveu a largura de banda representada por B, que expressa a medida da extensão em frequência de um sinal, correspondente à faixa de frequência na qual suas componentes são distribuídas. O sinal “+” na equação 3 indica uma inclinação LFM positiva (up-chirp) e o sinal “-” corresponde a uma inclinação LFM negativa (down – chirp).

2.2.4 Código Barker

Dentro das possibilidades de modulação intrapulso bifásica, com o objetivo de melhorar a resolução em distância por meio da determinação do atraso do eco recebido em radares com compressão de pulso, destaca-se a contribuição de Ronald Hugh Barker. Em 1953, ao analisar cerca de 60.000 polinômios distintos, Barker chegou à formulação

de uma lista composta por nove códigos, atualmente conhecidos como códigos Barker. Esses códigos consistem em sequências numéricas de diferentes comprimentos, formadas por valores de $+1$ e -1 , que satisfazem a condição de autocorrelação em que a magnitude dos lóbulos laterais gerados é menor ou igual a 1 (Wolff, 2023).


Tabela 1 – Códigos Barks conhecidos

Tamanho do código	Sequência do Código	PSL(dB)
Barker 2	++,+-	-6.0
Barker 3	++-	-9.5
Barker 4	+++-,++-+	-12.0
Barker 5	+++--+	-14.0
Barker 7	+++--+-	-16.9
Barker 11	+++---+--+--	-20.8
Barker 13	+++++---++-+-+	-22.3

Fonte: próprio autor (2025)

Na modulação, o pulso é dividido em intervalos de tempo iguais, denominados segmentos. A fase mantém-se constante dentro de cada segmento, podendo variar de um segmento para outro, assumindo valores de 0° ou 180° . Na figura 6, é possível analisar um sinal Barker 7.

Figura 6 - Diagrama de transmissão de pulso no código barker 7



Fonte: radartutorial

O sinal refletido que chega ao receptor passa por um processo de filtragem por meio de um filtro casado, o qual realiza a correlação entre o sinal transmitido e o recebido. Essa operação evidencia o grau de semelhança entre ambos os sinais. O padrão de inversões de fase é projetado de modo a maximizar o valor de pico do lóbulo principal da autocorrelação e minimizar os valores máximos dos lóbulos secundários.

2.2.5 Polifásicos (P1,P2 ,P3, P4 e Frank)

Conforme explica Alves (2024), diferentemente da codificação binária, como a Barker, que se baseia em valores de +1 e -1 correspondentes aos ângulos de 180° e 0°, as codificações polifásicas assumem outros valores de fase, obtidos a partir de aproximações discretas da modulação linear em frequência (LFM). O objetivo é aprimorar a compressão de pulso, reduzir os lóbulos laterais e apresentar boa tolerância ao efeito Doppler.

A codificação Frank divide o pulso em M subpulsos de igual duração, como ocorre no código Barker; contudo, atribui valores de fase distintos a cada subpulso. A Equação 4 define a fase dos subpulsos do código.

$$\phi(i, j) = \frac{2\pi}{L} (i - 1)(j - 1) \quad (4)$$

A Equação 4 forma uma matriz quadrada $M \times M$, que resulta em M^2 subpulsos que representa a sequência do código Frank.

$$A = \begin{bmatrix} 0 & 0 & 0 & \dots & 0 \\ 0 & 1 & 2 & \dots & (L - 1) \\ 0 & 2 & 4 & \dots & 2(L - 1) \\ 0 & 3 & 6 & \dots & 3(L - 1) \\ \dots & \dots & \dots & \dots & \dots \\ 0 & (L - 1) & 2(L - 1) & \dots & (L - 1)^2 \end{bmatrix}$$

Os códigos P1, P2, P3 e P4, desenvolvidos por Lewis e Kretschmer, são alguns dos tipos de códigos polifásicos. As versões P1 e P2 são derivadas do código Frank, resultando, portanto, em uma forma de onda semelhante à de uma com modulação linear em frequência (LFM). Já os códigos P3 e P4 podem ser compreendidos como a conversão da forma de onda LFM para a banda base (Sustelo, 2021).

O código P1 possui L^2 subpulsos, representados pela Equação 5, em que i e j variam de 1 a L .

$$\phi_{P1} = -\left(\frac{\pi}{L}\right) [L - (2j - 1)][(j - 1)L + (i - 1)] \quad (5)$$

Na codificação P2, observam-se os mesmos incrementos de fase em grupos, assim como ocorre no P1; entretanto, as fases iniciais são distintas. Outro aspecto de exclusividade está no fato de que o valor de L deve ser par, com o objetivo de reduzir os lóbulos laterais. O código é representado pela Equação 6, sendo constituído por L^2 subpulsos, nos quais i e j variam de 1 a L .

$$\phi_{P2} = -\left(\frac{\pi}{2L}\right) [L - (2j - 1)][L - 2j + 1] \quad (6)$$

O código P3, segundo Benecase (2023), possui L como razão de compressão, assim como ocorre no código Frank, sendo que o índice i varia de 1 até L. Essa relação dada pela Equação 7.

$$\phi_{P3} = \frac{\pi}{L}(i - 1)^2 \quad (7)$$

Observa-se que o código P3 apresenta uma proporção de lóbulos laterais em relação ao pico superior àquela encontrada nos códigos Frank, P1 e P2. Essa característica decorre do fato de os maiores incrementos de fase se localizarem na região central do código. Como consequência, o P3 demonstra menor eficiência frente às limitações de largura de banda na pré-compressão; entretanto, apresenta significativa tolerância ao efeito Doppler quando comparado aos códigos Frank, P1 e P2 (Alves, 2024).

Derivado conceitualmente da mesma forma de onda da codificação P3, o código P4 adota uma regra distinta para a determinação dos estados de fase, conforme expresso na Equação 8, na qual i e L obedecem às mesmas condições estabelecidas para a codificação P3.

$$\phi_{P4} = \frac{\pi}{L}(i - 1)(i - L - 1) \quad (8)$$

2.2.6 Politemporais (T1, T2, T3 e T4)

Os códigos de Frank e P1 a P4 aproximam uma modulação de frequência linear com tempo de permanência constante em cada estado de fase. Uma técnica alternativa para essa aproximação é a codificação politemporal, a qual utiliza estados de fase com períodos variáveis para representar a forma de onda. As codificações T1 e T2 são baseadas no modelo de radiofrequência escalonada, enquanto as codificações T3 e T4 constituem aproximações subjacentes de uma forma de onda LFM (Moreira; Pires; Oliveira, 2025).

A Equação 9 apresenta a representação da codificação T1 gerada a partir de uma forma de onda de frequência estacionária. A operação mod, denominada aritmética modular, gera como resultado o resto da divisão. Exemplo: $\text{mod}(8,3) = 2$, pois 8 dividido por 3, sobra o resto 2.

$$\phi_{T1}(t) = \text{mod} \left\{ \frac{2\pi}{n} \text{INT} \left[(kt - jT) \frac{jn}{T} \right], 2\pi \right\} \quad (9)$$

Onde k é o número de segmentos na sequência do código - é; t representa o tempo; T corresponde à duração total do código; n é o índice, e $j = [0, 1, \dots, k - 1]$ indica o número do segmento na forma de onda de frequência escalonada e k é o número de segmentos na sequência de código T1. A função INT remove a parte decimal e mantém apenas a parte inteira – e com isso, identificar o subpulso. (Alves, 2024)

De modo semelhante ao código T1, cuja geração baseia-se em uma forma de onda de frequência estacionária, o código T2, por sua vez, é definido pela Equação 10.

$$\phi_{T2}(t) = \text{mod}\left\{\frac{2\pi}{n} \text{INT}\left[\frac{(kt - jT)\left(\frac{2j - k + 1}{T}\right)n}{2}\right], 2\pi\right\}. \quad (10)$$

Diferentemente da forma de geração dos códigos T1 e T2, o código T3 é construído a partir da aproximação de uma forma de onda LFM, apresentando o batimento zero em sua borda principal. Sua formulação é expressa pela Equação 11, na qual t_m representa o tempo total de modulação da forma LFM de referência.

$$\phi_{T3}(t) = \text{mod}\left\{\frac{2\pi}{n} \text{INT}\left[\frac{(kt - jT)\left(\frac{2j - k + 1}{T}\right)n}{2t_m}\right], 2\pi\right\} \quad (11)$$

O código T4 segue o mesmo conceito do código T3, sendo representado pela Equação 12. Ele é gerado quando o batimento é nulo em seu centro e quantificado em n estados de fase discretos. O ΔF representa a largura de banda da modulação. (Alves, 2024)

$$\phi_{T4}(t) = \text{mod}\left\{\frac{2\pi}{n} \text{INT}\left[\frac{n\Delta F t^2}{2t_m} - \frac{n\Delta F t}{2}\right], 2\pi\right\} \quad (12)$$

2.3 Sistema MAGE


Na observância das Medidas de Apoio da Guerra Eletrônica, existe o sistema MAGE, dispositivo passivo, pois não emite ondas EEM e destina-se, entre outras funções, à detecção de sinais eletromagnéticos captados. Dessa forma, a utilização desse sistema preserva o silêncio eletrônico da força, uma vez que intercepta e processa exclusivamente as radiações emitidas por sensores adversários (Siston, 2023).

O objetivo do MAGE é a busca, interceptação, identificação e localização das fontes eletromagnéticas, bem como o encaminhamento dessas informações ao sistema de combate da unidade ou a sua posterior exploração para subsidiar decisões táticas. A partir dos dados obtidos, é possível promover reação oportuna à ameaça identificada — por exemplo, a execução de uma Medida de Ataque Eletrônico ou o engajamento por meio de armamento — e realizar análises detalhadas dos sinais registrados, permitindo avaliar a capacidade da força adversária e comparar esses resultados com as próprias capacidades operacionais. (Andrade; Siu; Marins, 2024).

A localização da fonte pode ser obtida por meio do ângulo de chegada do sinal ou, em outros casos, por localização geográfica completa, empregando múltiplas

plataformas (naval e terrestre) ou uma única plataforma aérea em movimento. Esse procedimento, denominado triangulação, está ilustrado na Figura 7.

Figura 7 - Representação de uma triangulação.



Fonte: Schwerz (2023).

Segundo a Apostila de Guerra Eletrônica do CIAW, o estágio inicial do processamento é a detecção do sinal, seguindo para a extração dos parâmetros de cada pulso para formar a PDW. Após isso, é realizado o denominado *deinterleaving* — ou desembaralhamento, em português —, procedimento que consiste em isolar o trem de pulsos de um radar observado dos demais sinais de radiofrequência (RF) presentes no campo de cobertura do MAGE. Em seguida, durante o processamento, são extraídos os parâmetros do pulso e realizada a classificação do tipo de radar, destacando-se o padrão de varredura, as técnicas MPE (por exemplo, agilidade em frequência e em PRI) e as modulações empregadas. Por fim, com as informações de classificação e os demais parâmetros da emissão, é possível consultar a biblioteca de missão — como a base de dados Fênix, provida pelo CGAEM na Marinha do Brasil, visando identificar o radar e, se necessário, designar o sistema de armas (Marinha do Brasil, 2002).

O sistema MAGE apresenta vantagens táticas significativas, além de preservar o silêncio eletrônico por ser passivo, quando comparado ao radar. A principal vantagem está relacionada ao alcance: enquanto o radar necessita emitir uma onda cuja reflexão em um objeto permite mensurar parâmetros, essa onda sofre atenuações causadas por fatores atmosféricos, pela absorção do próprio objeto e, sobretudo, pela distância. Em contrapartida, o MAGE recebe a energia diretamente do emissor, sem depender da reflexão, o que geralmente lhe confere superioridade em alcance. Essa vantagem pode ser ilustrada por meio da comparação entre as expressões de potência que descrevem a

distância de detecção de um radar (expressão 13) e R_T o alcance de um sistema MAGE (expressão 14) (Moreira, 2025)².

$$P_T = \frac{(P_T G_T \sigma G_R \lambda^2)}{(4\pi)^2 R_T^2 R_R^2} \quad (13)$$

$$P_{MAGE} = \frac{(P_T G_T G_R \lambda^2)}{(4\pi)^2 R_T^2} \quad (14)$$

A variável P_T representa a potência recebida pelo radar pelo eco do alvo, já P_{MAGE} é a potência recebida pelo MAGE. G_T é o ganho da antena que está transmitindo, enquanto G_R é o ganho da antena receptora do radar e λ é o comprimento de onda. O σ representa a seção reta radar do alvo.

O MAGE mais recente desenvolvido pela Marinha do Brasil, com os pesquisadores e engenheiros da área de Guerra Eletrônica do Instituto de Pesquisas da Marinha (IPQM), é o MAGE ET/SLR-1, denominado Defensor MK3. Esse sistema está presente em diversos meios da Esquadra brasileira, como, inicialmente, na Fragata Defensora, no Navio Doca Multipropósito Bahia, no Navio-Escola Brasil e na Corveta Barroso, encontrando-se também em processo de incorporação nas novas fragatas da Classe Tamandaré (Andrade; Siu; Marins, 2024). O equipamento é composto por um radome, uma antena omnidirecional e um conjunto de antenas direcionais fixas, conforme apresentado na Figura 8.

Figura 8 – O MAGE MK3.



Fonte: Poder Naval (2018).

Além do conjunto de antenas, o sistema dispõe de uma unidade de processamento do sinal recebido, que pode ser composta por um receptor de célula Bragg acústico-óptico, receptor cristal-vídeo, receptores super-heteródinos, receptores *Instantaneous*

² Informação verbal fornecida pelo Mestre Moreira durante a aula sobre Dispositivos de Detecção Passivos, ministrada em 11 out. 2025, no CIAA

Frequency Measurement (IFM), receptores canalizados ou, como no caso do MAGE brasileiro, um receptor digital (Marinha do Brasil, 2022).

Figura 9 - unidade de recepção e processamento.



Fonte: Andrade;Siu,Marins,(2024).

Em relação à recepção digital no MAGE Defensor MK3, a antena exerce a função de captar os sinais de radar, que são encaminhados a um conversor de frequências responsável pela down-conversão e pelo pré-processamento analógico. Nesse estágio, destacam-se alguns elementos fundamentais: o amplificador de baixo ruído, cuja finalidade é amplificar o sinal inserindo o mínimo de ruído possível; o filtro passa-faixa analógico, utilizado para a remoção de componentes indesejados; o amplificador de RF, empregado para reforçar o nível do sinal; e, por fim, o mixer, que converte o sinal de radiofrequência em uma frequência intermediária (FI), mais adequada ao processo de digitalização (Moreira, 2025).

No receptor digital, o sinal já convertido em FI é digitalizado por meio de um conversor analógico-digital de alta velocidade e elevado número de níveis de quantização. Em seguida, aplica-se o processamento digital de sinais com o objetivo de gerar a PDW. No caso específico do receptor digital do MAGE Defensor MK3, esse processamento é realizado em uma unidade central de processamento, onde são executadas funções como a detecção dos sinais recebidos, a estimação de parâmetros intrapulso e a classificação do tipo de modulação intrapulso. Nesse tipo de processamento, destacam-se diversas vantagens, dentre elas: maior sensibilidade e estimação de mais parâmetros tanto interpulsos, quanto intrapulsos. (Moreira, 2025)

Todavia, com os avanços tecnológicos dos radares de baixa probabilidade de interceptação (*Low Probability of Intercept – LPI*), estes têm se configurado como os maiores desafios para os receptores do MAGE. Essa realidade impõe a necessidade de aprimoramento da sensibilidade dos sensores, o que, entretanto, pode acarretar o aumento

de falsos alarmes, interferências e da quantidade de pulsos detectados (Silva Júnior, 2018).

Dentre os avanços empregados para fazer frente aos radares de baixa probabilidade de interceptação, destacam-se a utilização de receptores canalizados, o aprofundamento do conhecimento em guerra eletrônica e a crescente aplicação de técnicas de inteligência artificial — tema central deste estudo.

2.4 A Inteligência Artificial


De acordo com Xu *et al.* (2021), o início das pesquisas modernas relacionadas à inteligência artificial consolidou-se com a criação do próprio termo “inteligência artificial” em 1956, durante uma conferência realizada no Dartmouth College, por John McCarthy. A partir desse marco, diversos pesquisadores passaram a aprofundar os estudos na área, buscando desenvolver métodos capazes de resolver problemas matemáticos complexos. Contudo, à época, ainda não existiam recursos computacionais suficientes para enfrentar os desafios emergentes.

Na década de 1980, alguns institutos de pesquisa desenvolveram sistemas de IA baseados em conjuntos de regras fundamentais de conhecimento especializado, com o objetivo de auxiliar a tomada de decisões. Entretanto, tais sistemas apresentavam limitações quanto à flexibilidade, versatilidade e custos de implementação. Em 2006, Geoffrey Hinton propôs a construção de redes neurais profundas, marco que consolidou os algoritmos de aprendizagem profunda (*deep learning* – DL), um subconjunto do aprendizado de máquina (*machine learning* – ML), estruturado em múltiplas camadas de redes neurais. Paralelamente, os avanços nas tecnologias de Big Data e no poder computacional tornaram a estrutura da IA mais eficiente, possibilitando conquistas significativas em diversas áreas da sociedade, como saúde, educação, negócios e aplicações militares (Xu *et al.*, 2021).

2.7.1 Rede Neural

Cunha (2020) explica que as redes neurais artificiais são sistemas computacionais que operam de maneira análoga aos neurônios biológicos presentes no cérebro humano. Por meio de algoritmos, essas redes são capazes de identificar padrões, realizar classificações, efetuar predições e estabelecer correlações a partir de dados brutos, modelando relações complexas entre variáveis de entrada e de saída.

Figura 10 – Representação comparativa do neurônio biológico e sua representação matemática.



Fonte: Deep learning book (2025).

Observa-se, na Figura 10 (à esquerda), que o corpo celular e os dendritos compõem a superfície responsável pela recepção dos sinais no neurônio biológico, os quais podem ser percebidos com diferentes intensidades — também denominadas pesos. Nessa região ocorre a soma das entradas, enquanto, na extremidade oposta, as ramificações terminais do axônio correspondem à saída do fluxo de informação. As setas em vermelho indicam o sentido da informação transmitida, ou seja, o impulso elétrico que percorre o neurônio. A partir desse funcionamento, McCulloch e Pitts (1943) propuseram o modelo matemático do neurônio biológico.

No modelo de representação artificial, x_1 a x_n são os sinais de entrada correspondentes aos impulsos elétricos provenientes de outros neurônios. Na sinapse, representada por w_{kj} , encontram-se os pesos, em que k representa o índice do neurônio e j o terminal de entrada da sinapse. O modelo também é constituído por um somatório dos estímulos recebidos, ponderados pelos respectivos fatores excitatórios, seguido da aplicação de uma função de ativação. Por fim, obtém-se a saída (*output*) resultante dessa função, que corresponde ao axônio da célula (Gonçalves, 2008).

O processo de aprendizado pode ocorrer, entre outras formas, por meio do treinamento supervisionado, no qual são ajustados os pesos atribuídos a cada ligação entre neurônios e entre os bias e seus neurônios, com o objetivo de reduzir os erros entre a saída obtida e a saída esperada. No contexto do processamento de imagens, destacam-se as redes neurais convolucionais (CNNs), que apresentam resultados expressivos na classificação e no reconhecimento de padrões (Cunha, 2020).


2.4.2 A Convolução

Conforme explica Rodrigues (2018), a convolução, representada matematicamente pela expressão 15, ilustrada pela Figura 11, corresponde a um operador que recebe duas funções de entrada, X e K , e gera uma função de saída h . Em se tratando de matrizes, o resultado é o somatório das multiplicações ponto a ponto entre a matriz

que representa uma imagem por exemplo e a segunda matriz, denominada kernel, também conhecida como filtro convolucional. A matriz resultante é obtida deslocando-se o kernel sobre a primeira matriz e obtendo os valores resultantes das multiplicações.

$$(X * K)(m) = h(m) = \sum_{i=0}^k f(i) * g(m - i) \quad (15)$$

Figura 11- Representação de convolução.



Fonte: Souza (2020).


2.4.3 Rede Neural Convolucional

Em 1989, Yann LeCun propôs uma arquitetura de rede composta por camadas convolucionais e totalmente conectadas, treinada por meio do algoritmo de *backpropagation* e aplicada ao reconhecimento de dígitos manuscritos. Essa rede alcançou um erro de classificação de aproximadamente 5%, utilizando duas camadas convolucionais e duas totalmente conectadas (LeCun *et al.*, 1989).

Anos mais tarde, em 1998, LeCun e seus colaboradores consolidaram esse avanço ao desenvolver um classificador voltado especificamente ao reconhecimento de dígitos manuscritos, que se tornaria conhecido como rede neural convolucional (CNN) (LeCun *et al.*, 1989). A arquitetura proposta, denominada LeNet-5, foi considerada revolucionária para a época e amplamente empregada no reconhecimento de números em cheques manuscritos.

O modelo LeNet-5 é composto por camadas convolucionais e de pooling, seguidas por camadas totalmente conectadas, conforme ilustrado na Figura 12 (Alves, 2024). A cada nova camada, a rede aumenta em complexidade, permitindo o reconhecimento progressivo de regiões mais amplas e padrões mais complexos das imagens de entrada.

Figura 12 - Representação de CNN básica.




Fonte: Alves (2024).

2.4.4 A Camada de Convolução

A primeira camada do modelo de CNN é responsável pela maior parte do esforço computacional, tendo como um dos objetivos reduzir a quantidade de conexões realizadas pelas camadas completamente conectadas da rede. Nessa etapa, os neurônios são associados a regiões específicas da camada anterior — denominadas campos receptivos —, possibilitando a extração das características locais da entrada (Flausino, 2024). Esse processo é realizado por meio do *kernel*, representado matematicamente como um filtro convolucional de dimensões reduzidas, geralmente 3×3 , que percorre os dados de entrada em largura, altura e profundidade, efetuando a operação de convolução. À medida que os filtros são aplicados sucessivamente, a rede é capaz de extrair características cada vez mais complexas e gerar um número maior de mapas de ativação a partir da entrada (Rodrigues, 2018).

Figura 13 - Representação da camada convolucional.




Fonte: Cunha (2020).

A Figura 13 ilustra o funcionamento do processo de convolução em uma rede neural convolucional. Nesse procedimento, a matriz de entrada, com dimensão 6×6 , é percorrida por um *kernel* de tamanho 3×3 , que se desloca com *stride* igual a 1 — ou seja, movendo-se uma posição por vez ao longo dos eixos horizontal e vertical. Em cada posição, realiza-se o produto elemento a elemento entre os valores do kernel e os pixels cobertos no campo receptivo da imagem, seguido da soma desses produtos. O resultado

dessa operação é um valor único que expressa o grau de ativação daquela região em relação ao filtro aplicado. Esses valores são organizados em um novo arranjo denominado mapa de ativação, ou *feature map*, o qual representa as características extraídas pela convolução (Cunha, 2020).

Figura 14 - Processo completo dando origem ao mapa de ativação.



Fonte: Cunha (2020).

Nota-se, no processo ilustrado na Figura 14, que a matriz original de dimensão 6x6 foi reduzida para uma matriz 4x4. O resultado obtido é uma redução direta da dimensão da matriz, consequência da aplicação sucessiva do *kernel*. Quando essa redução não é desejada, utiliza-se o recurso denominado padding, que consiste no preenchimento de valores nas bordas da matriz, geralmente iguais a zero ou repetindo o valor mais próximo da matriz, de modo a preservar suas dimensões originais (Benecase, 2023).


Desse modo, a Figura 14 demonstra como o filtro *kernel*, ao deslizar sobre a imagem como um feixe de luz ponderado por pesos, constrói mapas de características (*feature maps*) que permitem à CNN extrair padrões relevantes e progressivamente mais complexos em diferentes níveis de abstração.

2.4.5 Camada de Pooling

A camada de *pooling*, seja do tipo *max pooling* (Figura 15) ou *average pooling*, tem como objetivo reduzir a quantidade de valores presentes nos mapas de características, sem causar prejuízo significativo à eficiência da CNN, além de diminuir o tempo de processamento. Seu funcionamento é semelhante ao de uma camada convolucional; contudo, enquanto na convolução o *stride* normalmente assume valor igual a 1, no *pooling* ele costuma ser equivalente ao tamanho do filtro. Essa característica faz com que os campos receptivos não se sobreponham, resultando em uma redução de 75% na

dimensão dos mapas de características quando o pooling utiliza uma máscara de tamanho 2x2 (Ebermam; Krohling, 2018).

Figura 15 – Representação de um processo de max pooling.



Fonte: Ebermam,E.,Krohling,R (2018).

2.4.6 Camada Totalmente Conectada

Após a entrada passar pelas camadas convolucionais e de *pooling*, e após a extração das características de alto nível da imagem, são gerados os mapas de características. Esses mapas, que possuem mais de uma dimensão, são redimensionados em um vetor por meio do processo denominado *flattening*, no qual os valores da matriz são organizados linearmente para servir de entrada à camada totalmente conectada (Ebermam; Krohling, 2018).

De forma semelhante a uma rede neural convencional, que utiliza funções de ativação do tipo *softmax* em sua última camada, a camada de saída, a camada totalmente conectada realiza a classificação da imagem em diversas classes, com base no conjunto de dados de treinamento (Guimarães *et al.*, 2025).

2.5 A Classificação de Sinais

O objetivo de um algoritmo de classificação consiste em gerar um modelo capaz de receber um conjunto de dados de entrada e associá-los a uma das classes previamente definidas. Esse modelo, denominado classificador, tem como função principal determinar a categoria à qual cada dado apresentado deve ser atribuído.

Esta pesquisa tem por objetivo comparar duas arquiteturas de Redes Neurais Convolucionais — a GoogLeNet e a proposta por Kong *et al.* (2018) — quanto à sua eficiência na classificação do tipo de modulação intrapulso. Os classificadores são responsáveis por identificar o tipo de modulação dos sinais, representados pelas características extraídas no domínio do tempo-frequência, distribuídos entre as

modulações LFM, Barker, P1, P2, P3, P4, Frank, T1, T2, T3, T4 e sinais sem modulação, formando 12 classes de saída.

3. METODOLOGIA

A presente pesquisa tem como objetivo realizar uma análise comparativa entre dois algoritmos de classificação baseados em Redes Neurais Convolucionais — a GoogLeNet e o modelo proposto por Kong *et al.* (2018). Para isso, foram conduzidas simulações no software MATLAB, com o propósito de avaliar o desempenho dos classificadores na identificação de diferentes tipos de pulsos simulados presentes em uma base de dados previamente estruturada.

3.1 Quanto aos Fins

Para a realização desta pesquisa, foram empregados dois tipos de pesquisa quanto aos fins. A pesquisa exploratória teve papel relevante ao estabelecer as bases conceituais de Guerra Eletrônica e de radares, bem como ao apresentar as técnicas de Inteligência Artificial aplicadas e os sinais analisados, com suas respectivas características. A pesquisa explicativa, por sua vez, permitiu a descrição detalhada dos modelos e sistemas classificadores empregados, demonstrando de que forma cada um atua no processo de classificação dos sinais de radar e na distinção entre os diferentes tipos de modulação.

3.2 Quanto aos Meios

Este trabalho emprega a pesquisa bibliográfica, que consiste no levantamento, análise e interpretação de referências teóricas já publicadas em livros, artigos científicos, teses, dissertações, documentos governamentais, doutrinas militares e páginas da internet relacionadas a assuntos militares. Seu objetivo é fundamentar o estudo a partir de conhecimentos já consolidados por outros autores, possibilitando a compreensão de diferentes perspectivas sobre o tema proposto.

Também é utilizada a pesquisa experimental, realizada por meio do software MATLAB, que, segundo a MathWorks (2025), é uma plataforma de computação voltada para aplicações em engenharia, como análise de dados, processamento de sinais e de imagens, entre outros. O software dispõe ainda do Simulink, um ambiente gráfico que permite a criação de diagramas de blocos para a simulação de sistemas e ambientes complexos.

3.3 Quanto à Natureza do Método

Neste trabalho, a abordagem quantitativa foi aplicada a partir da formulação de hipóteses relacionadas às categorias de sinais a serem reconhecidas e da execução de procedimentos sistemáticos de análise. Para tanto, empregou-se o software MATLAB na implementação dos algoritmos de classificação. Complementarmente, recorreu-se a ferramentas estatísticas, como o índice kappa e a avaliação da acurácia de cada modelo por meio da matriz de confusão resultante.

3.4 Limitações do Método

Neste estudo, foram selecionados dois classificadores baseados em redes neurais convolucionais (CNN) para análise, embora existam diversos algoritmos de aprendizado de máquina que poderiam, igualmente, ser aplicados ao problema de classificação de imagens de radar.

Outro aspecto relevante a ser mencionado refere-se à origem dos sinais empregados, os quais foram obtidos por meio de simulações realizadas no próprio software MATLAB. Essa escolha decorreu da ausência de acesso a um banco de dados reais completo, contendo informações sobre radares militares estrangeiros, uma vez que tais dados são naturalmente protegidos por questões de segurança.

Dessa forma, a pesquisa fundamenta-se em hipóteses referentes às possíveis capacidades tecnológicas de radares adversários. Considerando tal limitação, optou-se por contemplar diferentes formas de modulação em sinais pulsados já conhecidas. Assim, parte das modulações analisadas não possui comprovação de uso em sistemas militares de outras nações, mas foi incorporada ao estudo com o propósito de enriquecer a avaliação comparativa.

3.5 Coleta de Dados e Treinamento

O método de análise adotado neste trabalho contempla doze classes de sinais de radar com modulação FMOP e PMOP, além de pulsos não modulados. No caso dos FMOP, restringiu-se à modulação LFM, empregada, por exemplo, no radar AN/FPS-118, *Over – the – Horizon Radar*, radar além do horizonte, utilizado em missões de detecção de navios e aeronaves a longas distâncias (Melvin, 2014). Quanto aos PMOP, a investigação abrangeu o código Barker 13, aplicado, por exemplo, no radar móvel de busca aérea AN/TPS-43E (Matheson et al., 1982), bem como as modulações polifásicas (Frank, P1, P2, P3 e P4) e politemporais (T1, T2, T3 e T4).

Os sinais foram simulados considerando a frequência da portadora em 160 MHz (FI), valor assumido como frequência central ideal do receptor digital. A janela total de aquisição foi de 220 microssegundos, com taxa de amostragem de 2,4 GHz, resultando em 580.000 amostras por pulso. O ruído foi adicionado por meio do próprio software MATLAB, utilizando o comando White Gaussian Noise (WGN), o que possibilitou a geração de diferentes valores de SNR. Foram simulados quatorze valores distintos de SNR, variando de -25 dB a 15 dB.

Para o treinamento da rede, os dados foram particionados da seguinte forma: 70% destinados ao conjunto de treinamento — subdivididos em 52,5% para ajuste de pesos e 17,5% para validação — e os 30% restantes reservados ao conjunto de teste. Essa divisão assegura a consistência metodológica e a eficiência estatística dos resultados obtidos.

3.6 Os Algoritmos de Classificação Baseados em CNN

Neste trabalho, o estudo comparativo dos modelos de algoritmos de classificação de sinais modulados oriundos de radares consistirá na análise da rede neural convolucional proposta por Kong *et al.* (2018) e da GoogLeNet.

3.6.1 Rede Neural Convolucional proposta por Kong *et al.* (2018)


O trabalho de Kong *et al.* (2018) teve como objetivo solucionar o mesmo desafio proposto nesta pesquisa: o reconhecimento rápido e eficiente de formas de onda de radares de baixa probabilidade de interceptação (*Low Probability of Intercept* – LPI) por sistemas de recepção MAGE, utilizando classificadores baseados em redes neurais convolucionais. Para isso, os autores também realizaram testes com códigos polifásicos e politemporais, como LFM, FSK, BPSK, Frank, P1, P2, P3, P4, T1, T2, T3 e T4.

A CNN proposta é dividida em duas partes principais: extração de características, realizada pelas camadas convolucionais e de *pooling*; e classificação, executada pelas camadas totalmente conectadas e pela função *softmax*. Sua estrutura básica é composta pelas seguintes etapas: camada de entrada, camada de convolução, *ReLU* (*Rectified Linear Unit*) — na qual os valores negativos são transformados em nulos, com o objetivo de aumentar a não linearidade da rede e acelerar o processo de treinamento —, camada de *pooling*, nova camada de convolução, seguida por outra camada *ReLU*, uma segunda camada de *pooling*, camada totalmente conectada e, por fim, a camada softmax e a saída.

Sendo a mais utilizada atualmente em Redes Neurais (RASAMOELINA; ADJAILIA; SINČÁK, 2020), a função *ReLU*, do inglês Rectified Linear Unit, se popularizou devido à sua alta performance e simplicidade. Esta função pode ser definida como: $\text{ReLU}(x) = \max\{0, x\}$. (2.3) Nota-se que a ligação do neurônio só é ativada caso o valor de entrada seja maior do que zero; do contrário, a função retorna o valor nulo. (Flauzino, 2024, p. 26).

Devido à própria eficiência das redes neurais convolucionais frente a distorções geométricas e à presença de ruídos nas imagens, torna-se dispensável o uso de funções externas de extração de características. Esse processo é realizado internamente pela própria rede, por meio das operações de convolução.

Figura 16 – Representação da CNN proposta por Kong.



Fonte: Kong *et al.* (2018).

A estrutura da CNN projetada é apresentada na Figura 16. Na entrada, utiliza-se uma imagem tempo-frequência redimensionada para uma matriz de 128×128 pixels, em escala de cinza. A primeira camada convolucional contém 30 filtros de tamanho 7×7 , enquanto a segunda camada convolucional adota 60 filtros de tamanho 3×3 , ambas com *stride* igual a 1 e com *padding* aplicado para completar a matriz com zeros, preservando suas dimensões originais. Essas camadas geram os mapas de características que alimentam a camada seguinte (Kong *et al.*, 2018).

Após cada operação de convolução, é aplicada uma camada de *pooling* — do tipo *max pooling* 2×2 e *stride* 2 —, responsável por reduzir a dimensão dos mapas de características, tornando o sistema mais resistente a ruídos e diminuindo o custo computacional.

Ao final do processo, são gerados 60 mapas de características com dimensões 32×32 . Esses mapas passam pelo processo de *flattening* (achatamento), que converte as matrizes bidimensionais resultantes das camadas de convolução e *pooling* em um vetor unidimensional. Nesse caso, o resultado de $60 \times 32 \times 32$ gera 61.440 valores organizados

em um único vetor, que é então encaminhado às camadas totalmente conectadas, iniciando pela camada totalmente conectada denominada FC-1, correspondente ao início da fase de classificação.

Devido ao elevado número de neurônios na primeira camada totalmente conectada, a fim de evitar o sobreajuste (*overfitting*) aos dados de treinamento, foi empregada uma camada de *dropout* com taxa de 50% entre as camadas FC-1 e FC-2, o que resultou em melhor desempenho. Na camada de saída (*output layer*), são utilizados 12 neurônios, correspondentes às classes de formas de onda moduladas dos radares LPI. Cada neurônio de saída está associado a uma classe de modulação específica, como LFM, P1 ou T1. Por fim, com a aplicação da função softmax, cada neurônio fornece a probabilidade de o sinal de radar de entrada possuir a modulação correspondente à classe apontada pela rede neural.

O trabalho de Kong *et al.* (2018) concluiu que essa arquitetura de rede neural apresenta eficiência para o propósito proposto, configurando-se como uma solução eficiente e prática para a detecção e classificação de sinais modulados de radares LPI por sistemas de recepção, sem elevação significativa do custo computacional.

3.6.2 GoogLeNet

Em 2014, uma nova arquitetura foi proposta por Szegedy *et al.* (2015), conhecida como *GoogLeNet*, a qual venceu o *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) de 2014 e passou a ser considerada o estado da arte em classificadores de imagens. Essa rede é composta por 22 camadas profundas — ou 27, se incluídas as camadas de *max pooling* —, formadas pelo empilhamento de nove módulos *Inception*. Esse novo conceito consiste em permitir que a saída de uma camada passe por diferentes caminhos em paralelo, utilizando convoluções de tamanhos 1×1 , 3×3 e 5×5 , além de uma camada de *max pooling*. A arquitetura pode ser dividida em três seções principais, que descrevem cada bloco, conforme ilustrado na Figura 17 (Godinho, 2019).


Segundo Alves (2024), na rede de entrada, onde ocorre a primeira paralelização de caminhos, há blocos azuis que realizam as convoluções, blocos vermelhos correspondentes ao *max pooling* — responsáveis pela redução das dimensões espaciais — e, por fim, blocos verdes, que representam os reguladores *Local Response Normalization* (LRN) (Utsch, 2018).

Na parte central da rede, observa-se uma sequência de blocos *Inception* conectados em cascata, além dos mesmos blocos azuis, vermelhos (agora sem redução das dimensões espaciais) e verdes. Nessa região, destacam-se os classificadores

auxiliares, compostos por blocos azuis — inicialmente uma convolução 1×1 , seguida por duas camadas totalmente conectadas —, blocos vermelhos de *max pooling*, responsáveis pela redução das dimensões, e blocos amarelos, que representam os módulos *softmax*, destinados ao cálculo das funções de perda (Utsch, 2018).

Na parte final da rede — classificador final, tem-se bloco azul, com camadas totalmente conectadas; blocos vermelhos *average pooling* de todos os neurônios de cada canal; e blocos amarelos — *softmax* (Utsch, 2018).

Figura 17 - Arquitetura de rede GoogleNet.



Fonte: Szegedy *et al.*, (2015).


O módulo *Inception* combina as saídas de múltiplas operações de convolução com filtros de tamanhos 1×1 , 3×3 e 5×5 , além de uma operação de *max pooling* executada em paralelo, sendo essencial para manter a invariância a pequenas variações e distorções na imagem. No entanto, as convoluções com filtros de 5×5 tornaram o processo computacionalmente oneroso. Para mitigar esse problema, o *Inception* utiliza filtros de 1×1 — computacionalmente mais simples — para realizar a redução de dimensionalidade antes das convoluções maiores e mais custosas, como as de 3×3 e 5×5 . Essa técnica de redução é fundamental para que a rede alcance 22 camadas de profundidade, com grande largura de filtros, sem aumento significativo no número de parâmetros, preservando, assim, a viabilidade computacional e a elevada acurácia da arquitetura *GoogLeNet* (Szegedy *et al.*, 2015;)(Godinho, 2019).

4. SIMULAÇÕES E ANÁLISE DOS RESULTADOS

A utilização da Transformada Curta de Fourier (STFT) nos classificadores tem como finalidade realçar o sinal em relação ao ruído e gerar representações no domínio tempo $\times$ frequência, facilitando o processo de classificação. A Figura 18 demonstra esse

efeito ao apresentar mapas tempo-frequência de sinais simulados com SNR de 15 dB, nos quais é possível identificar com maior clareza a estrutura intrapulso das modulações.


Figura 18 - Gráficos após aplicação da STFT



Fonte: BENECAE (2023)

De maneira complementar, a Figura 19 apresenta os resultados da STFT aplicada às modulações Barker13 e Frank em condições de SNR igual a 0 dB e -25 dB. Observa-se que, à medida que a SNR diminui, as matrizes resultantes tornam-se progressivamente mais ruidosas, dificultando a identificação dos padrões característicos de cada modulação e, conseqüentemente, a tarefa de classificação dos algoritmos.

Figura 19 - Gráficos após aplicação da STFT com SNR -25dB e 0 db para Frank e Barker 13



Fonte: BENECAE (2023)

Considerando-se as 14 SNR distintas utilizadas nas simulações, os capítulos subsequentes apresentam o desempenho (acertos e erros) obtido por cada classificador. Ressalta-se, ainda, que o banco de dados empregado é balanceado, contendo a mesma quantidade de amostras para cada modulação, para cada SNR e para cada largura de pulso, garantindo uma avaliação consistente entre os modelos.

As simulações dos classificadores GoogLeNet e a CNN proposta por Kong *et al.* (2018) conduzidas no software MATLAB — frente aos diferentes intervalos da razão sinal-ruído já estabelecida e as codificações abordadas nesta pesquisa teve o seu desempenho avaliado baseado em três parâmetros: acurácia; matriz de confusão e índice kappa.


A acurácia representa a proporção de previsões corretamente realizadas pelo classificador em relação ao total de amostras avaliadas, sendo uma das métricas mais utilizadas para medir o desempenho global de um modelo. É expressa pela relação entre a soma dos acertos verdadeiros — positivos (VP) e negativos (VN) — e o total de amostras avaliadas, que são os VP, os VN, os falsos positivos (FP) e os falsos negativos (FN), conforme a Equação 16: (Dutra, 2023)

$$Acurácia = \frac{VP+VN}{VP+VN+FP+FN} \quad (16)$$

A acurácia é uma métrica derivada da matriz de confusão — que será abordada posteriormente — obtida pela razão entre os valores presentes na diagonal principal da matriz e o total de amostras avaliadas (Dutra, 2023).

A matriz de confusão pode ser compreendida como uma representação tabular que relaciona as classes previstas pelo modelo com as classes reais. Conforme ilustrado na Figura 20, as classes reais estão representadas nas linhas horizontais – divididas em primeira linha positiva e segunda negativa; e as classes previstas, representadas nas colunas. Nesse exemplo ilustrativo da Figura 20, onde tem-se 2 classes, a classe positiva e a negativa, 100 dados de teste foram classificados como positivos; contudo, apenas 70 deles pertenciam de fato à classe positiva, enquanto os 30 restantes foram classificados incorretamente.

Figura 20 – Representação da Matriz de confusão.



Fonte: Ruback (2021).

Os verdadeiros negativos correspondem aos dados de teste previstos e corretamente classificados como negativos, ao passo que os falsos negativos indicam aqueles que foram previstos como negativos, mas pertenciam à classe positiva. No exemplo apresentado na Figura 20, 60 dados de teste foram previstos como negativos, sendo 50 corretamente classificados e 10 incorretamente.

Por último, o índice Kappa foi desenvolvido por Landis e Koch (1977) como uma medida estatística destinada a avaliar o grau de concordância entre observadores — ou, no contexto desta pesquisa, entre 2 classificadores, o classificador perfeito que representa o gabarito e o classificador em análise — em avaliações realizadas sobre categorias nominais. Exemplos dessas categorias podem ser “detecção” e “não detecção”; entretanto, neste estudo, o índice está relacionado à eficiência do classificador.

Matematicamente, o índice é calculado pela expressão:

$$K(\kappa) = \frac{P_o - P_e}{1 - P_e} \quad (17)$$

Na expressão a variável P_o representa a proporção de concordância observada, equivalente à acurácia total obtida a partir da matriz de confusão, e P_e corresponde à proporção de concordância esperada ao acaso, calculada com base nas probabilidades marginais das classes.

$$P_o = \frac{VP + VN}{VP + FN + FP + VN} \quad (18)$$

$$P_e = \frac{(VP + FN)(VP + FP)(FP + VN)(FN + VN)}{(VP + FN + FP + VN)^2} \quad (19)$$

Na simulação realizada neste trabalho, o índice Kappa foi utilizado para avaliar o desempenho global dos classificadores — CNN proposta por Kong e GoogLeNet — sobre o conjunto de testes, fornecendo uma métrica mais eficiente que a acurácia isoladamente. Um valor de kappa = 1 indica concordância perfeita entre as previsões e as classes verdadeiras; kappa = 0 indica que a concordância não é melhor que o acaso, ou seja, as decisões coincidem apenas por probabilidade aleatória; e valores negativos de kappa apontam para um desempenho inferior ao aleatório.

O estudo original de Landis e Koch (1977) foi desenvolvido no contexto da bioestatística, com o objetivo de mensurar a concordância entre observadores em diagnósticos clínicos categóricos, como no caso da esclerose múltipla. A partir desse trabalho, foi estabelecida uma tabela de interpretação dos valores de Kappa (Tabela 2), que permite classificar o nível de concordância. No presente estudo, essa mesma estrutura foi adaptada para a avaliação dos classificadores de pulsos codificados, mantendo a equivalência conceitual entre observadores humanos e classificadores automáticos.

Tabela 2 – Faixa interpretativa de Landis e Koch.

<i>Kappa Statistic</i>	<i>Strength of Agreement</i>
<0.00	Poor
0.00–0.20	Slight
0.21–0.40	Fair
0.41–0.60	Moderate
0.61–0.80	Substantial
0.81–1.00	Almost Perfect

Fonte: Landis e Koch (1977).

4.1 Resultados da CNN Proposta por Kong *et al.* (2018)

4.1.1 Treinamento da CNN em 2 Épocas

A CNN proposta por Kong *et al.* (2018) foi implementada no MATLAB, seguindo a estrutura exposta no capítulo anterior, com duas e seis épocas³ de treinamento e taxa de aprendizado 0,01. A avaliação dos classificadores foi conduzida sobre 8.820 imagens do conjunto treinamento distribuídas entre as dozes classes de sinais, e 5.040 do conjunto de teste e 2.940 imagens do conjunto de validação.


O primeiro resultado apresentado, ilustrado na Figura 21, corresponde à matriz de confusão obtida com os dados do conjunto de treinamento utilizando duas épocas,

³ Cada época representa uma passagem completa de todo o conjunto de treinamento pela rede neural

apresentada de forma geral, abrangendo todas as classes de sinais e níveis de SNR. A análise de desempenho sobre o conjunto de sinais de treinamento permite verificar se o modelo do classificador apresenta coerência e eficiência. Uma vez treinada, a CNN deve ser capaz de classificar corretamente os sinais do conjunto de treinamento, com o objetivo de também identificar adequadamente os sinais do conjunto de teste — que contém amostras não utilizadas durante o treinamento.


Nesse modelo, observa-se o período inicial de aprendizado, no qual ainda não há iterações suficientes para o refinamento dos filtros convolucionais, diferentemente do que ocorre em treinamentos com seis épocas, que resultam em maior acurácia e índice Kappa. Deve-se destacar que Unmod refere-se a pulsos sem modulação, e as células em branco da matriz indicam erro zero.

Figura 21 - Matriz de confusão geral de 2 épocas com os dados de treinamento (CNN proposta por KONG *et al.*).



Fonte: Elaborado pelo autor (2025).

Figura 22 - Representação do progresso da CNN proposta por KONG *et al.* em 2 épocas.




Fonte: Elaborado pelo autor (2025).

Conforme ilustrado na Figura 22, a acurácia apresentou evolução significativa nas primeiras iterações, ultrapassando 90% antes do término da primeira época. Ao final da segunda época, o modelo alcançou acurácia de validação de 94,59%, evidenciando rápida convergência e ausência de *overfitting*⁴, uma vez que as curvas de *loss* (erro) e *accuracy* (acurácia) mantiveram comportamento constante de convergência ao valor final ao longo do processo de treinamento. O tempo total de treinamento foi de 1 minuto e 49 segundos, demonstrando boa eficiência computacional do modelo.

4.1.2 Treinamento da CNN em 6 Épocas.

A Figura 23 apresenta a matriz de confusão geral obtida após seis épocas de treinamento. O aumento do número de épocas proporcionou um refinamento mais aprofundado dos parâmetros internos da rede convolucional, resultando em maior precisão do modelo. As taxas de acurácia em cada tipo de modulação apresentaram melhora perceptível, com destaque para Unmod (100%), LFM (99,6%) e T4 (99,9%). Além disso, observou-se avanço expressivo em classificações mais críticas, como P1 (87%) e P3 (81,3%), que haviam apresentado desempenho inferior no treinamento com apenas duas épocas.


Figura 23 - Matriz de confusão geral de 6 épocas com os dados de treinamento (CNN proposta por KONG et al.).



Fonte: Elaborado pelo autor (2025).

⁴ Overfitting é quando o modelo aprende excessivamente os dados de treinamento, inclusive os ruídos, perdendo a capacidade de generalização para novos dados.

Figura 24 - Representação do progresso da CNN proposta por KONG *et al.* em 6 épocas.



Fonte: Elaborado pelo autor (2025).

Pode-se observar, na Figura 24, o progresso do treinamento da CNN ao longo das seis épocas. A acurácia evoluiu gradualmente até atingir 96,63%, em um processo com maior número de iterações — 408 no total —, o que implicou um aumento no tempo de treinamento, totalizando 5 minutos e 30 segundos. Esse comportamento evidencia que o prolongamento do treinamento contribuiu para o refinamento dos pesos e filtros convolucionais, resultando em melhor desempenho global do classificador.

4.1.3 Treinamento da CNN em 2 Épocas para Diferentes Intervalos de SNR

Nas Figura 25 a 27 são apresentadas as matrizes de confusão obtidas com os sinais do conjunto de treinamento, em 2 épocas, porém agora relativo a um intervalo de SNR ($\text{SNR} > 0 \text{ dB}$; $-10 \text{ dB} \leq \text{SNR} \leq 0 \text{ dB}$; $\text{SNR} < -10 \text{ dB}$).

Figura 25 - Matriz de confusão geral de 2 épocas com os dados de treinamento, SNR<-10 dB (CNN proposta por KONG *et al.*).

Matriz de Confusão (Conjunto de Treinamento: SNR < -10dB)															
Classes dos Sinais	Barker 13	89.8%	3.6%		0.7%	0.4%	0.4%		4.0%	1.1%			89.8%	10.2%	
	Frank	0.4%	79.1%	0.7%	1.1%	1.5%	1.5%	11.2%	3.4%	0.4%	0.4%		0.4%	79.1%	20.8%
	LFM		2.9%	93.8%			0.8%	1.7%			0.4%	0.4%		93.8%	6.2%
	Unmod	0.4%			98.1%						1.5%			98.1%	1.9%
	P1		4.7%	0.4%	0.8%	64.6%	7.8%	6.2%	11.3%	0.4%	3.1%		0.8%	64.6%	35.4%
	P2		2.7%		0.8%		88.3%	5.4%	0.8%	1.2%	0.4%		0.4%	88.3%	11.7%
	P3	0.8%	15.7%	3.8%	0.4%	2.3%	6.1%	54.0%	15.3%		0.8%	0.4%	0.4%	54.0%	46.0%
	P4		4.7%	0.4%	0.4%	6.2%	2.2%	1.4%	82.2%	0.4%	1.1%	0.4%	0.7%	82.2%	17.8%
	T1	1.5%	1.5%		0.4%		1.1%	1.1%	0.4%	91.8%	0.4%	1.5%	0.4%	91.8%	8.2%
	T2	0.8%	2.5%		0.8%	1.6%	0.4%			0.8%	93.0%			93.0%	7.0%
	T3	1.1%						0.7%		2.6%		95.6%		95.6%	4.4%
	T4		0.4%				0.7%	1.1%	0.7%				97.0%	97.0%	3.0%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
Classificação gerada pela CNN															


Fonte: Elaborado pelo autor (2025).

Conforme apresentado na Figura 25, em condições de baixa SNR (<-10 dB), os sinais sofrem degradação, o que dificulta a distinção entre as modulações. Dentre os sinais mais afetados, destacam-se os de modulação P3 (54%), P1 (64,6%) e, com desempenho um pouco superior, Frank (79,1%).

O desempenho na classificação melhora substancialmente quando a SNR é maior que -10 dB e menor que 0 dB, conforme observado na Figura 27. As modulações Frank, LFM, Unmod, P1, P2, P4, T1, T2 e T3 foram corretamente classificadas, alcançando quase 100% das amostras, sendo que apenas P3 apresentou uma taxa de FN mais elevada, com 8%.


Nos sinais com SNR positivo, apresentados na Figura 27, observa-se uma classificação praticamente perfeita, com acurácia superior a 98,5% em todas as classes e apenas pequenos erros, próximos de 1,5%, em algumas modulações.

Figura 26 - Matriz de confusão geral de 2 épocas com os dados de treinamento, $-10\text{dB} \leq \text{SNR} < 0\text{ dB}$ (CNN proposta por KONG *et al.*).



Fonte: Elaborado pelo autor (2025).

Figura 27 - Matriz de confusão de 2 épocas com os dados de treinamento, $\text{SNR} \geq 0\text{ dB}$ (CNN proposta por KONG *et al.*)




Fonte: Elaborado pelo autor (2025).

4.1.4 Treinamento da CNN em 6 Épocas para Diferentes Intervalos de SNR

A matriz de confusão para seis épocas para diferentes intervalos de SNR é apresentada nas Figuras 28, 29 e 30. Observa-se que o classificador baseado em CNN obteve excelente desempenho após seis épocas de treinamento, alcançando resultados próximos da perfeição em quase todas as classes. Na Figura 28, que representa um cenário mais desafiador para o classificador, correspondente ao conjunto de treinamento com


SNR < -10 dB, apenas três modulações apresentaram taxas de FN superior a 10%: Frank (12,3%), P1 (11,1%) e P4 (10,9%).

Figura 28 - Matriz de confusão geral de 6 épocas com os dados de treinamento, SNR<-10 dB (CNN proposta por KONG *et. al*).



Fonte: Elaborado pelo autor (2025).


Figura 29 – Matriz de confusão geral de 6 épocas com os dados de treinamento, -10dB<=SNR<0 dB (CNN proposta por KONG *et. al*).



Fonte: Elaborado pelo autor (2025).

Na faixa intermediária ($-10 \text{ dB} \leq \text{SNR} < 0 \text{ dB}$), representada pela Figura 29, a rede manteve acurácia superior a 99,5% em todas as classes, demonstrando eficiência na extração de padrões tempo-frequências, mesmo sob condições de ruído moderado. Para $\text{SNR} \geq 0 \text{ dB}$, na Figura 30, a rede alcançou 100% de acurácia em todas as modulações, evidenciando total capacidade de generalização diante de baixos níveis de ruído.

Figura 30 Matriz de confusão de 6 épocas com os dados de treinamento, SNR ≥ 10 dB (CNN proposta por KONG *et al.*).



Fonte: Elaborado pelo autor (2025)

4.1.5 Teste da CNN Treinada em 2 Épocas.


Nessa fase, a rede neural não está voltada para aprender os padrões dos dados, como ocorreu na etapa de treinamento, mas sim para avaliar o desempenho do modelo. Os dados de teste não foram apresentados durante o treinamento e, portanto, são completamente novos para a rede. Dessa forma, é possível verificar se o modelo generaliza adequadamente e consegue reconhecer pulsos desconhecidos. Essa etapa permite avaliar se o classificador é realmente capaz de identificar novos sinais ou se apenas memorizou o conjunto de dados de treinamento.

Com base nos resultados apresentados nas matrizes de confusão (Figura 31) e na curva de acurácia por SNR (Figura 32), observa-se que a CNN obteve desempenho satisfatório na identificação das doze classes de sinais de radar sob diferentes razões sinal-ruído (SNR). A acurácia global obtida com o conjunto de testes foi de aproximadamente 94,0%, conforme demonstrado no relatório do APÊNDICE D, indicando que a rede foi capaz de generalizar de forma eficiente, mesmo com poucas épocas de treinamento.

Figura 31-Matriz de confusão geral de 2 épocas com os dados de teste (CNN proposta por KONG *et al.*)

		Matriz de Confusão (Conjunto de Teste)													
Classes dos Sinais	Barker 13	93.8%	0.5%				0.5%	0.2%		2.1%	2.1%	0.7%		93.8%	6.2%
	Frank	0.2%	92.6%	0.2%	0.5%	0.7%	0.7%	3.3%	0.7%	1.0%				92.6%	7.4%
	LFM		0.5%	97.4%			0.7%	0.5%	0.2%	0.2%	0.5%			97.4%	2.6%
	Unmod				99.0%						1.0%			99.0%	1.0%
	P1		1.7%			88.6%	1.7%	2.4%	5.5%		0.2%			88.6%	11.4%
	P2	0.5%	0.5%		0.2%		94.5%	2.4%		0.5%	0.5%	0.2%	0.2%	94.5%	5.5%
	P3		10.2%	1.0%	0.2%	1.4%	1.0%	80.2%	5.7%	0.2%				80.2%	19.8%
	P4		1.2%	0.5%	0.2%	2.6%	0.5%	1.7%	91.9%		0.5%	0.2%	0.7%	91.9%	8.1%
	T1	1.2%	0.7%			0.2%	0.2%			96.0%		1.7%		96.0%	4.0%
	T2	0.5%	0.7%		0.2%	0.7%					97.9%			97.9%	2.1%
	T3							0.2%		2.4%		97.4%		97.4%	2.6%
	T4						0.7%		0.2%		0.2%		98.8%	98.8%	1.2%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
		Classificação gerada pela CNN													

Fonte: Elaborado pelo autor (2025)

Figura 32 – Gráfico de acurácia de 2 épocas com os dados de teste (CNN proposta por KONG *et al.*)


Fonte: Elaborado pelo autor (2025)

4.1.6 Treinamento da CNN em 2 Épocas para Diferentes Intervalos de SNR

Nos cenários de SNR elevados (≥ 0 dB), na Figura 33, o classificador apresentou 100% de acurácia em quase todas as classes, evidenciando excelente desempenho do modelo quando os sinais estão menos degradados pelo ruído. Para os valores intermediários de SNR ($-10 \text{ dB} \leq \text{SNR} < 0 \text{ dB}$), na Figura 34, a taxa média de acurácia


manteve-se superior a 98%, com exceção da modulação P3, que apresentou erro de 7,5%.

Figura 33- Matriz de confusão geral de 2 épocas com os dados de teste para SNR>=0dB (CNN proposta por KONG et al.)



Fonte: Elaborado pelo autor (2025)

Figura 34- Matriz de confusão geral de 2 épocas com os dados de teste, -10dB<=SNR<0 dB (CNN proposta por KONG et al.)



Fonte: Elaborado pelo autor (2025)

Nos cenários mais críticos, na Figura 35, com SNR < -10 dB, o desempenho reduziu-se de forma esperada, em razão da deterioração da qualidade dos pulsos eletromagnéticos, que tornam as imagens menos distinguíveis para a CNN. As classes P3, P1, P4 e Frank foram as que apresentaram maior índice de erros, com acurácia de

50,7%, 69,3%, 78,7% e 79,3%, respectivamente. Ainda assim, classes com padrões espectrais mais simples e bem definidos — como LFM e Unmod — mantiveram acurácia acima de 90%, demonstrando que o modelo apresenta boa acurácia em determinadas modulações.

Figura 35 - Matriz de confusão geral de 2 épocas com os dados de teste, SNR<-10 dB (CNN proposta por KONG *et al.*).

Matriz de Confusão (Conjunto de Teste: SNR < -10dB)													
Classes dos Sinais	Barker 13	84.7%	1.3%				1.3%	0.7%		6.0%	4.0%	2.0%	
	Frank	0.7%	79.3%	0.7%	1.3%	2.0%	2.0%	9.3%	2.0%	2.7%			
	LFM		1.3%	92.7%			2.0%	1.3%	0.7%	0.7%	1.3%		
	Unmod				97.3%						2.7%		
	P1		4.7%			69.3%	4.7%	6.7%	14.0%		0.7%		
	P2	1.3%	1.3%		0.7%	1.3%	64.7%	6.7%		1.3%	1.3%	0.7%	0.7%
	P3		25.3%	2.7%	0.7%	4.0%	2.7%	50.7%	13.3%	0.7%			
	P4		2.0%	1.3%	0.7%	7.3%	1.3%	4.7%	78.7%		1.3%	0.7%	2.0%
	T1	3.3%	2.0%			0.7%	0.7%			88.7%		4.7%	
	T2	1.3%	2.0%		0.7%	2.0%					94.0%		
	T3							0.7%		6.7%		92.7%	
	T4						1.3%		0.7%		0.7%		97.3%
Classificação gerada pela CNN													

Fonte: Elaborado pelo autor (2025)


4.1.7 Testes da CNN Treinada em 6 Épocas

Comparando-se os resultados obtidos com seis épocas de treinamento, agora na fase de testes, observa-se, na Figura 36, perde de estabilidade na curva de acurácia — evidenciado na Figura 37 — e uma queda na acurácia geral para 96,66%, conforme apresentado no APÊNDICE C. Entretanto, em relação a CNN treinada em duas épocas, também na fase de teste, observa-se maior estabilidade na curva de acurácia, e uma acurácia geral maior. Esse aprimoramento é atribuído ao maior número de iterações sobre o conjunto de treinamento, o que possibilitou à rede ajustar melhor os pesos.

Figura 36- Matriz de confusão geral de 6 épocas com os dados de teste (CNN proposta por KONG *et al.*).

		Matriz de Confusão (Conjunto de Teste)													
Classes dos Sinais	Barker 13	97.4%			0.7%		0.2%	0.2%	0.2%	0.7%	0.2%	0.2%		97.4%	2.6%
	Frank	0.7%	92.1%			1.0%	0.2%	5.0%	0.7%			0.2%		92.1%	7.9%
	LFM			98.1%		0.2%	0.2%	0.7%	0.5%		0.2%			98.1%	1.9%
	Unmod				99.3%						0.7%			99.3%	0.7%
	P1		0.2%			93.3%	1.0%	2.1%	3.3%					93.3%	6.7%
	P2		0.5%				96.9%	1.7%	0.7%				0.2%	96.9%	3.1%
	P3		1.9%			0.5%	0.2%	95.2%	1.4%	0.2%	0.5%			95.2%	4.8%
	P4		0.2%		0.2%	1.4%	0.2%	2.4%	95.2%				0.2%	95.2%	4.8%
	T1	1.9%	0.5%				0.7%	0.7%		96.0%		0.2%		96.0%	4.0%
	T2					0.7%	0.2%	0.2%	0.5%		98.3%			98.3%	1.7%
	T3							0.2%		1.2%		98.6%		98.6%	1.4%
	T4						0.2%		0.2%				99.5%	99.5%	0.5%
		Barker 13	Frank	LFM	Unmod	P1	P2	P3	P4	T1	T2	T3	T4		
		Classificação gerada pela CNN													

Fonte: Elaborado pelo autor (2025).


Figura 37 – Gráfico de acurácia de 6 épocas com os dados de teste (CNN proposta por KONG *et al.*).

Fonte: Elaborado pelo autor (2025).

4.1.8 Testes da CNN Treinada em 6 Épocas para Diferentes Intervalos de SNR.


No conjunto de testes, a CNN treinada por seis épocas apresentou, para $\text{SNR} \geq 0$ dB, acurácia de 100% em todas as classes, com exceção da classe Barker, que apresentou uma taxa de FN de apenas 0,7% (Figura 38). Para o intervalo $-10 \text{ dB} \leq \text{SNR} < 0 \text{ dB}$ (Figura 39), a rede também apresentou acurácia próxima de 99%, com uma pequena taxa de FN, 1,7%, na classe Barker.

Figura 38 - Matriz de confusão geral de 6 épocas com os dados de teste para $\text{SNR} \geq 0$ dB (CNN proposta por KONG *et al.*).



Fonte: Elaborado pelo autor (2025)

Figura 39 – Matriz de confusão de 6 épocas com os dados de teste, para $-10\text{dB} \leq \text{SNR} < 0$ dB (CNN proposta por KONG *et al.*)



Fonte: Elaborado pelo autor (2025)

A principal diferença é observada nos cenários de SNR mais baixos ($\text{SNR} < -10$ dB), na Figura 40, nos quais a rede treinada por seis épocas apresentou menores taxas de FN em relação a rede treinada por 2 épocas, apresentando melhor capacidade de distinção entre as modulações, especialmente entre as classes sem modulação, T4, T3 e T2.

Figura 40 - Matriz de confusão de 6 épocas com os dados de teste, SNR < -10 dB (CNN proposta por KONG *et al.*)

Matriz de Confusão (Conjunto de Teste: SNR < -10dB)												
Classes dos Sinais	Barker 13	94.7%					0.7%	0.7%	0.7%	2.0%	0.7%	0.7%
	Frank	2.0%	78.0%			2.7%	0.7%	14.0%	2.0%			0.7%
	LFM			94.7%		0.7%	0.7%	2.0%	1.3%		0.7%	
	Unmod				98.0%					2.0%		
	P1		0.7%			81.3%	2.7%	6.0%	9.3%			
	P2		1.3%				91.3%	4.7%	2.0%			0.7%
	P3		5.3%			1.3%	0.7%	86.7%	4.0%	0.7%	1.3%	
	P4		0.7%		0.7%	4.0%	0.7%	6.7%	86.7%			0.7%
	T1	5.3%	1.3%				2.0%	2.0%		88.7%		0.7%
	T2					2.0%	0.7%	0.7%	1.3%		95.3%	
	T3							0.7%		3.3%		96.0%
	T4						0.7%		0.7%			98.7%
Classificação gerada pela CNN												

Fonte: Elaborado pelo autor (2025)

Portanto, o aumento de épocas contribuiu para o refinamento dos parâmetros da CNN, reduzindo o impacto da baixa SNR nas classificações incorretas. Assim, a comparação demonstra que o modelo de seis épocas é mais eficiente em termos de acurácia, sobretudo sob condições de SNR adversas.


4.2 Resultados da CNN GoogLeNet

Da mesma forma que os resultados foram analisados na seção 4.1, nesta seção as matrizes de confusão baseadas na CNN GoogLeNet foram geradas e analisadas com sinais do conjunto treinamento e teste abrangendo as modulações FMOP, PMOP, e os sinais não modulados, considerando as perdas por ruído.

4.2.1 Treinamento da CNN GoogLeNet em 2 Épocas


Iniciando pelo conjunto de treinamento com duas épocas de forma geral (Figura 41), a matriz apresenta desempenho excelente na correlação dos sinais modulados. O maior erro de classificação não ultrapassou 0,5%. Conforme ilustrado no gráfico de progresso de treinamento da Figura 42, a acurácia ultrapassou 90% já na primeira época, nas iterações iniciais, encerrando a segunda época com 98,27% de acurácia, em um tempo total de 4 segundos, conforme o relatório no Apêndice B.

Figura 41 - Matriz de confusão geral de 2 épocas com os dados de teste (GoogLeNet).



Fonte: Elaborado pelo autor (2025).

Figura 42 - Representação do progresso da CNN GoogLeNet em 2 épocas.




Fonte: Elaborado pelo autor (2025).

4.2.2 Treinamento da CNN GoogLeNet em 2 Épocas em Diferentes Intervalos de SNR

Na faixa de SNR inferior a -10 dB, na Figura 43, que representa condições de maior adversidade na distinção do sinal em relação ao ruído, o modelo apresentou desempenho bem satisfatório, com acurácia superior a 99%. As classes Barker, Frank, LFM, P4, T2, T3 e T4 obtiveram 100% de acurácia, enquanto ocorreram pequenos desvios nas classes P2, P3, T1 e P1, sendo esta última a que apresentou o maior erro entre as quatro, com 1,5%.

Figura 43- Matriz de confusão de 2 épocas com os dados de treinamento, SNR < -10 dB (GoogLeNet).




Fonte: Elaborado pelo autor (2025).

Na faixa entre -10 dB e 0 dB, na Figura 44, a acurácia atingiu 99,7%, com a maioria das classes apresentando 100% de acurácia na classificação, incluindo Barker 13, Frank, LFM, Unmod, P1, P3, T1, T2 e T3. As pequenas confusões, inferiores a 1%, concentraram-se nas modulações P2 (99,0%), P4 (99,5%) e T4 (99,5%). Essas pequenas taxas de FN são consideradas estatisticamente irrelevantes, indicando eficiência no reconhecimento das modulações, mesmo sob condições de SNR intermediária.


Na faixa de $\text{SNR} \geq 0$ dB, o classificador atingiu 100% de acurácia em todas as classes, conforme apresentado na Figura 45.

Figura 44 - Matriz de confusão de 2 épocas com os dados de treinamento, $-10\text{dB} \leq \text{SNR} < 0$ dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).

Figura 45 - Matriz de confusão de 2 épocas com os dados de treinamento, SNR ≥ 0 dB (GoogLeNet).




Fonte: Elaborado pelo autor (2025).

4.2.3 Treinamento da CNN GoogLeNet em 6 Épocas

Essa seção apresenta os resultados obtidos com o treinamento realizado com um total de seis épocas, quantidade suficiente para a completa efetividade do processo de aprendizado, sem indícios de *overfitting*. A matriz de confusão geral demonstra um desempenho muito próximo do ideal, com acurácia média de 99,94%, conforme indicado no relatório gerado pelo MATLAB, apresentado no APÊNDICE A.

Conforme ilustrado na Figura 46, a classe P3 apresentou o único erro residual (0,7%), decorrente de confusão com a classe P4, uma modulação com estrutura de fase semelhante. Todas as demais classes (Barker 13, Frank, LFM, Unmod, P1, P2, P4, T1, T2, T3 e T4) atingiram 100% de acurácia.

Figura 46 – Matriz de confusão geral de 6 épocas com os dados de treinamento (GoogLeNet).



Fonte: Elaborado pelo autor (2025).


Em condições de menor SNR, a GoogLeNet manteve excelente desempenho, com acurácia média de 99,38%. A maioria das classes apresentou 100% de acurácia, com exceção da classe P3, que obteve 98,8%, resultando em 1,2% de erro, decorrente de uma confusão pontual com P4.

O resultado da matriz confusão confirma o desempenho do modelo, mesmo sob níveis de potência do sinal mais baixas que tornam a razão sinal-ruído extremamente desfavorável e os padrões tempo-frequência sofrem distorções parciais. Ainda assim, a rede demonstrou capacidade de reconhecimento mais eficiente, identificando adequadamente as principais modulações e mantendo erro médio inferior a 1%.

4.2.4 Treinamento da CNN GoogLeNet em 6 Épocas com Diferentes Intervalos de SNR

No treinamento com seis épocas, em cenários com menor percentual da potência do sinal com $\text{SNR} < -10$ dB (Figura 47), o modelo demonstrou-se eficiente e apresentou acurácia elevada, alcançando 100% para $\text{SNR} = -25$ dB, conforme indicado no relatório (APÊNDICE A). Na matriz de confusão, observa-se que as 12 classes de sinais foram identificadas corretamente, com exceção de um pequeno erro de 1,2% na modulação P3, mesmo em sinais com potência mais baixas para o classificador.


Figura 47 - Matriz de confusão de 6 épocas com os dados de treinamento, $\text{SNR} < -10$ dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).


Com SNR entre -10 dB e 0 dB, a acurácia foi de 99,93%, com uma pequena taxa de FN na classe P3 (0,9%), enquanto todas as demais apresentaram 100% de acurácia (Figura 48). A partir de $\text{SNR} \geq 0$ dB, o classificador alcançou 100% de acurácia em todas as classes, sem qualquer erro de classificação, conforme ilustrado na Figura 49.

Figura 48 - Matriz de confusão de 6 épocas com os dados de treinamento, $-10 \text{ dB} \leq \text{SNR} < 0 \text{ dB}$ (GoogLeNet).



Fonte: Elaborado pelo autor (2025).

Figura 49- Matriz de confusão de 6 épocas com os dados de treinamento, $\text{SNR} \geq 0 \text{ dB}$ (GoogLeNet).



Fonte: Elaborado pelo autor (2025).

4.2.5 Testes da CNN GoogLeNet Treinada em 2 Épocas

Na fase de testes, o classificador, na análise geral, apresentou acurácia de 97,5%, conforme indicado no relatório (APÊNDICE B). Utilizando a matriz de confusão, observa-se que as classes correspondentes aos sinais LFM e sem modulação obtiveram 100% de acurácia, enquanto as modulações T1, T2, T3, T4 e Barker 13 alcançaram valores superiores a 97%, observando-se apenas uma pequena redução de desempenho nas demais modulações (Figura 50).

Figura 50 - Matriz de confusão geral treinada em 2 épocas com os dados de teste (GoogLeNet).

Matriz de Confusão (Conjunto de Teste)												
Classes dos Sinais	Barker 13	98.3%							0.2%	0.7%	0.7%	
	Frank	0.5%	95.7%	0.2%	0.2%		1.2%	0.5%	0.5%	0.5%	0.5%	0.2%
	LFM			100.0%								
	Unmod				100.0%							
	P1	0.2%	0.2%	1.0%	0.2%	96.0%		1.0%	1.2%	0.2%		
	P2	0.5%	0.2%		1.0%	95.0%	0.2%		0.7%	1.2%	0.2%	1.0%
	P3	0.2%	1.9%	0.5%	1.0%		92.6%	1.7%	0.5%	0.7%	0.5%	0.5%
	P4		0.5%		0.2%	1.4%		96.7%		1.0%		
	T1	1.0%	0.5%				0.2%		97.4%		0.7%	0.2%
	T2					0.7%	0.2%			99.0%		
	T3	0.5%									99.5%	
	T4					0.2%						99.8%
Classificação gerada pela GoogLeNET												


98.3%	1.7%
95.7%	4.3%
100.0%	
100.0%	
96.0%	4.0%
95.0%	5.0%
92.6%	7.4%
96.7%	3.3%
97.4%	2.6%
99.0%	1.0%
99.5%	0.5%
99.8%	0.2%

Fonte: Elaborado pelo autor (2025).

4.2.6 Testes da CNN GoogLeNet Treinada em 2 Épocas com Diferentes Intervalos de SNR

Na faixa de SNR inferior a -10 dB, conforme ilustrado na Figura 51, a rede apresentou maior taxa de erros de classificação, concentrados principalmente entre as modulações polifásicas P2, P3 e P4, que possuem estruturas de fase semelhantes. Apesar da degradação da potência do sinal, a GoogLeNet manteve desempenho aceitável, com acurácia acima de 73% mesmo em -25 dB. Essa faixa representa um limite crítico de classificação, no qual a baixa SNR faz com que as componentes espectrais dos sinais não se sobressaíam em relação às do ruído, comprometendo a capacidade distinção entre as classes. Ainda assim, o desempenho obtido nessa condição evidencia que a rede é capaz de preservar um nível considerável de reconhecimento, mesmo sob intensa degradação da SNR.

Figura 51- Matriz de confusão geral treinada em 2 épocas com os dados de teste SNR < - 10dB (GoogLeNet).




Fonte: Elaborado pelo autor (2025).

Quando submetida a níveis intermediários de SNR, entre -10 dB e 0 dB, a GoogLeNet, conforme ilustrado na Figura 52, apresentou acentuada melhoria de desempenho, atingindo acurácia média próxima de 99%. Nessa faixa, os erros foram mínimos, ocorrendo em pequena proporção, com 0,8% de taxa de FN com sinais da modulação Barker 13. Esse comportamento da CNN demonstra que, ao receber sinais com a potência que se sobressaem significativamente em relação ao ruído, há um aperfeiçoamento da capacidade de diferenciação entre as classes.

A diferença de acurácia entre os diferentes níveis de SNR torna-se mais evidente na Figura 54, na qual observa-se acurácia inferior a 75% para SNR = -25 dB e quase 95% para SNR = -20 dB.


Figura 52 - Matriz de confusão geral treinada em 2 épocas com os dados de teste - 10 dB <= SNR < 0 dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).


Em condições de SNR elevada, conforme é apresentado na Figura 53, a GoogLeNet alcançou desempenho perfeito, atingindo 100% de acurácia em todas as classes.

Figura 53- Matriz de confusão treinada em 2 épocas com os dados de teste SNR ≥ 0 dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).

Figura 54 – Gráfico de acurácia por SNR com dados de teste 2 épocas.



Fonte: Elaborado pelo autor (2025).

4.2.7 Testes da GoogLeNet Treinada em 6 Épocas

A matriz de confusão do conjunto de teste geral (Figura 55), referente ao modelo treinado por seis épocas, demonstra excelente desempenho, com a maioria das classes apresentando taxas superiores a 97% de acurácia e acurácia global de 97,67%. As classes P3 e Frank concentraram a maior parte dos erros de classificação, com destaque para P3, que apresentou 7,1% de erro. Em contrapartida, utilizando os sinais com as modulações Barker 13, LFM, T1 a T4 a GoogLeNet apresentou desempenho superior a 98%, enquanto os sinais sem modulação obtiveram 100% de acurácia.

Figura 55 – Matriz de confusão geral treinada em 6 épocas com os dados de teste (GoogLeNet).


Matriz de Confusão (Conjunto de Teste)												
Classes das Sinais	Barker 13	98.3%			0.2%		0.2%	0.2%		0.7%		0.2%
	Frank	0.2%	95.2%	0.2%			0.7%	1.0%	1.0%	0.2%	0.5%	0.7%
	LFM			99.8%					0.2%			
	Unmod				100.0%							
	P1		0.7%			96.9%	0.2%	1.0%	0.7%		0.2%	0.2%
	P2	0.5%	0.2%			0.2%	96.0%	0.7%		0.7%	0.2%	1.0%
	P3	0.5%	1.7%	0.2%	0.2%	0.2%	0.2%	92.9%	2.1%	0.5%	0.2%	0.7%
	P4					1.2%		1.0%	97.1%		0.7%	
	T1	1.0%	0.2%					0.2%		98.1%		0.5%
	T2					0.7%			0.2%		99.0%	
	T3	0.5%										99.5%
	T4						0.2%		0.5%			99.3%
Classificação gerada pela GoogLeNet												

Fonte: Elaborado pelo autor (2025).

4.2.8 Testes da GoogLeNet Treinada em 6 Épocas para Diferentes Intervalos de SNR

Sob condições em que a potência do sinal é mais baixa em relação ao ruído ($\text{SNR} < -10 \text{ dB}$), o desempenho da GoogLeNet apresentou uma degradação previsível, com queda acentuada da acurácia em SNR inferiores a -20 dB , conforme ilustrado na Figura 56.


Figura 56 – Gráfico de acurácia por SNR com dados de teste 6 épocas.



Fonte: Elaborado pelo autor (2025).

As classes Frank (86,7%) e P3 (80%) foram as mais afetadas, apresentando confusões significativas distribuídas entre modulações de fase semelhantes. Ainda assim, as classes LFM (99,3%), Unmod (100%), T2 (97,3%), T3 (98,7%) e T4 (98%) não tiveram a acurácia significativamente alterada, evidenciando que o modelo preserva alta eficiência para modulações com assinatura espectral mais característica.


Figura 57- Matriz de confusão treinada em 6 épocas com os dados de teste SNR < -10 dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).


Na faixa entre -10 dB e 0 dB, conforme a figura 58 assim como para valores superiores a 0 dB, na figura 59, o classificador atingiu 100% de acurácia em todas as classes, sem qualquer ocorrência de erro de classificação. A ausência de confusões cruzadas indica que a rede alcançou alta acurácia a partir da faixa superior a -10 dB, inclusive nas modulações P1, P2 e P3.

Figura 58 - Matriz de confusão treinada em 6 épocas com os dados de teste -10 dB ≤ SNR < 0 dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).

Figura 59 - Matriz de confusão treinada em 6 épocas com os dados de teste SNR ≥ 0 dB (GoogLeNet).



Fonte: Elaborado pelo autor (2025).


5 COMPARAÇÃO ENTRE OS 2 CLASSIFICADORES

A análise das matrizes de confusão, especialmente aquelas obtidas após o treinamento em duas épocas, caracterizadas por menor tempo de processamento e menor número de interações, evidencia de forma clara que a CNN GoogLeNet apresenta desempenho superior, com maior acurácia em todas as faixas de SNR. Contudo, ressalta-se que a CNN proposta por Kong *et al.* (2018) também apresentou resultados satisfatórios, com diferença pouco significativa em faixas de SNR mais elevadas.

Com fundamento nas análises de desempenho apresentadas no capítulo 4, a Figura 60 ilustra a comparação entre as acurácias de classificação de todas as classes de sinais no conjunto de teste das CNN GoogLeNet e Kong *et al.*, ambas treinadas em seis épocas.

De modo geral, a arquitetura GoogLeNet alcançou maior acurácia na maioria das modulações, com destaque para sinais não modulados que atingiu 100% de acurácia, e também na modulação Frank e P1 – que alcançaram mais diferenciação entre arquiteturas, enquanto a arquitetura proposta por Kong *et al.* (2018) obteve desempenho ligeiramente superior nas modulações P2, P3 e T4, embora sem diferenças expressivas.

Figura 60 – Comparação de Acurácia entre GoogLeNet e a CNN proposta por Kong *et al.* com 6 épocas.



Fonte: Elaborado pelo autor (2025).

Com o propósito de esclarecer de forma mais objetiva as diferenças de desempenho entre os classificadores, e com base nos relatórios do MATLAB apresentados nos APÊNDICE A e C, a Tabela 3 compara, para 14 valores específicos de SNR, o desempenho global de cada arquitetura. Conclui-se, a partir dessa análise, que a GoogLeNet se sobressai como a arquitetura mais eficiente, apresentando maior acurácia em todas as faixas de SNR simuladas.

Tabela 3 – Comparação geral sobre Acurácia por SNR.

SNR	CNN proposta por Kong	GoogLeNet
-25dB	66.6667%	73.8889%
-20dB	92.2222%	96.11%
-18dB:	97.2222%	98.61%
-15dB	98.3333%	99.16
-13dB	99.7222%	99.7222%
-10dB	100%	100%
-8dB	99.7222%	100%
-5dB	99.7222%	100%
-3dB	100%	100%
0dB	100%	100%
3dB	100%	100%
5dB	100%	100%
10dB	100%	100%
15dB	100%	100%

Fonte: Elaborado pelo autor (2025).

Com o objetivo de comparar a eficiência dos classificadores testados de forma quantitativa, adotou-se nesta pesquisa, além da acurácia, a metodologia estatística proposta no estudo clássico de Landis e Koch (1977) — o cálculo do índice Kappa, conforme já explicitado no Capítulo 4.

No trabalho original de Landis e Koch (1977), o índice Kappa foi empregado para avaliar o grau de concordância entre observadores em diagnósticos clínicos. Neste estudo, entretanto, essa metodologia foi adaptada ao contexto da classificação automática de sinais radar, possibilitando quantificar a concordância entre as previsões realizadas pelas CNNs e as classes verdadeiras. Assim, a Tabela 4 apresenta a escala de categorização da força de concordância adotada neste trabalho, adequada ao domínio da Guerra Eletrônica e à avaliação de desempenho dos classificadores.

A Tabela 5 apresenta, de maneira objetiva, os valores do índice Kappa obtidos para cada uma das doze modulações consideradas, tanto nas condições gerais quanto em cada intervalo de SNR, separados por classificador. Além disso, foram incluídos os respectivos níveis de força de concordância, permitindo uma avaliação comparativa mais abrangente entre as arquiteturas.

Tabela 4 – Escala do nível de concordância (kappa)

Índice Kappa	Força da Concordância
0%	Nenhuma
0% - 20,99%	Irrisória
21% - 40,99%	Muito Fraca
41% - 60,99%	Fraca
61% - 80,99%	Regular
81% - 90,99%	Boa
91% - 99,99%	Muito Boa
100%	Perfeita

Fonte: Elaborado pelo autor (2025)

A partir dos resultados apresentados na Tabela 5, observa-se que ambas as CNNs demonstraram níveis de concordância elevados, evidenciando a alta eficiência dos classificadores. Todavia, a GoogLeNet apresentou índices superiores em relação à CNN proposta por Kong *et al.* (2018).

Na condição geral, considerando a força de concordância, a GoogLeNet obteve classificação “Perfeita” em uma categoria a mais que a rede proposta por Kong *et al.* Sob condições de SNR positiva, a GoogLeNet apresentou duas classificações adicionais com nível “Perfeito”, diferença que também se repetiu na faixa de SNR entre 0 e –10 dB.

A discrepância mais acentuada é observada nas condições de SNR inferiores a – 10 dB, em que o sinal se encontra significativamente degradado. Nessa situação, a GoogLeNet manteve maior eficiência e estabilidade, destacando-se pela capacidade de preservar a acurácia mesmo em cenários de menores SNR. Por outro lado, a CNN proposta por Kong *et al.* ainda apresentou desempenho satisfatório e competitivo, especialmente nas condições de SNR mais altas, confirmando sua eficiência na classificação de sinais sob melhores razões sinal-ruído.

Tabela 5 – Verificação do nível de concordância em diferentes SNR

Geral					SNR ≥ 0 dB				
Modulação	GoogLeNet		KONG		Modulação	GoogLeNet		KONG	
	Kappa	Concordância	Kappa	Concordância		Kappa	Concordância	Kappa	Concordância
Barker 13	97.24%	EXCELENTE	95.80%	MUITO BOA	Barker 13	100%	PERFEITA	99.62%	EXCELENTE
Frank	96.08%	MUITO BOA	94.40%	MUITO BOA	Frank	100%	PERFEITA	99.62%	EXCELENTE
LFM	99.56%	EXCELENTE	96.92%	MUITO BOA	LFM	100%	PERFEITA	100%	PERFEITA
Unmod	99.40%	EXCELENTE	98.97%	EXCELENTE	Unmod	100%	PERFEITA	100%	PERFEITA
P1	96.14%	MUITO BOA	91.22%	MUITO BOA	P1	100%	PERFEITA	100%	PERFEITA
P2	96.16%	MUITO BOA	96.25%	MUITO BOA	P2	100%	PERFEITA	100%	PERFEITA
P3	94.97%	MUITO BOA	94.82%	MUITO BOA	P3	100%	PERFEITA	100%	PERFEITA
P4	96.15%	MUITO BOA	93.37%	MUITO BOA	P4	100%	PERFEITA	100%	PERFEITA
T1	97.55%	EXCELENTE	97.45%	EXCELENTE	T1	100%	PERFEITA	100%	PERFEITA
T2	99.02%	EXCELENTE	98.68%	EXCELENTE	T2	100%	PERFEITA	100%	PERFEITA
T3	98.70%	EXCELENTE	99.23%	EXCELENTE	T3	100%	PERFEITA	100%	PERFEITA
T4	98.80%	EXCELENTE	99.51%	EXCELENTE	T4	100%	PERFEITA	100%	PERFEITA

0 dB > SNR > -10 dB					SNR ≤ -10 dB				
Modulação	GoogLeNet		KONG		Modulação	GoogLeNet		KONG	
	Kappa	Concordância	Kappa	Concordância		Kappa	Concordância	Kappa	Concordância
Barker 13	100%	PERFEITA	99.07%	EXCELENTE	Barker 13	92.52%	MUITO BOA	89.59%	BOA
Frank	100%	PERFEITA	99.08%	EXCELENTE	Frank	88.35%	BOA	85.60%	BOA
LFM	100%	PERFEITA	100%	PERFEITA	LFM	98.86%	EXCELENTE	94.17%	MUITO BOA
Unmod	100%	PERFEITA	100%	PERFEITA	Unmod	99.24%	EXCELENTE	96.34%	EXCELENTE
P1	100%	PERFEITA	100%	PERFEITA	P1	89.81%	BOA	78.08%	REGULAR
P2	100%	PERFEITA	100%	PERFEITA	P2	90.64%	BOA	89.46%	BOA
P3	100%	PERFEITA	100%	PERFEITA	P3	81.79%	BOA	80.25%	REGULAR
P4	100%	PERFEITA	100%	PERFEITA	P4	89.92%	BOA	81.48%	BOA
T1	100%	PERFEITA	100%	PERFEITA	T1	94.58%	MUITO BOA	93.12%	MUITO BOA
T2	100%	PERFEITA	100%	PERFEITA	T2	95.64%	MUITO BOA	96.68%	MUITO BOA
T3	100%	PERFEITA	100%	PERFEITA	T3	96.46%	MUITO BOA	97.40%	EXCELENTE
T4	100%	PERFEITA	100%	PERFEITA	T4	96.39%	MUITO BOA	98.53%	EXCELENTE

Fonte: Elaborado pelo autor (2025)

6 CONCLUSÃO

A pesquisa conduzida ao longo desta monografia permitiu constatar que o emprego de técnicas de Inteligência Artificial, na forma das Redes Neurais Convolucionais, representa um grande potencial para aplicação nas Medidas de Apoio à Guerra Eletrônica, ao possibilitar a classificação automatizada, precisa e eficiente de sinais radar com modulação intrapulso, mesmo em condições adversas de SNR. As simulações realizadas no MATLAB, sob o mesmo conjunto de dados e com condições de ruído equivalentes, evidenciaram que tanto a GoogLeNet quanto a CNN proposta por Kong *et al.* (2018) apresentaram desempenho elevado, destacando-se pela capacidade de generalização e pelos altos valores de acurácia e índice kappa.

No referencial teórico foram examinadas contribuições importantes, como a proposta de Kong *et al.*, que fundamenta a possibilidade de classificar o tipo de modulação intrapulso por análise tempo-frequência utilizando redes neurais convolucionais. Observa-se que a Inteligência Artificial, já amplamente empregada nos meios acadêmicos, médicos e empresariais, assume particular relevância no campo de batalha moderno.

A GoogLeNet demonstrou melhor acurácia do que a CNN proposta por Kong *et al.*, alcançando índices de acurácia elevados, que podem ser observados também com as matrizes de confusão obtidas com as simulações, e valores de índice Kappa melhores, indicando altos valores de concordância entre as predições e as classes verdadeiras. Essa arquitetura mostrou-se mais eficiente na distinção entre diferentes modulações, mesmo em cenários de menores razão sinal-ruído, revelando-se a melhor das duas CNN comparadas, podendo ser integrada em sistemas MAGE embarcados.

Em termos de aplicabilidade prática, os resultados obtidos neste estudo comprovam que o uso de redes neurais profundas aplicadas a matrizes tempo-frequência em sistemas MAGE da Marinha do Brasil pode reduzir significativamente o tempo de resposta e aumentar a eficiência na classificação de emissores hostis, fornecendo ao operador do Centro de Operações de Combate (COC) informações táticas mais precisas e tempestivas.

O presente trabalho consolida uma base experimental para o prosseguimento de pesquisas destinadas à integração de arquiteturas CNN aos sistemas MAGE Defensor MK3 e às novas plataformas da Classe Tamandaré, representando um passo relevante no fortalecimento da Capacidade de Guerra Eletrônica da Marinha do Brasil.

Conclui-se, portanto, que a aplicação de redes neurais profundas na classificação de sinais radar é tecnicamente viável e operacionalmente vantajosa, contribuindo para o aprimoramento da capacidade de Guerra Eletrônica e proporcionando ganhos expressivos de desempenho, autonomia e consciência situacional no campo de batalha do espectro eletromagnético.

6.1 Sugestão para Trabalhos Futuros

Diante dos resultados experimentais obtidos, recomenda-se o prosseguimento das pesquisas aplicadas em redes neurais profundas, contemplando a prototipação das arquiteturas avaliadas e a realização de testes em ambiente marítimo integrados aos sistemas de guerra eletrônica embarcados. Tais etapas são essenciais para validar a eficiência, a velocidade de processamento e a compatibilidade operacional das soluções propostas em cenários reais de emprego.

No tocante ao contínuo avanço das redes neurais aplicadas à classificação de imagens, esta pesquisa recomenda o aprofundamento de estudos sobre a arquitetura *Squeeze-and-Excitation* Network (SENet), proposta por Hu, Shen e Sun (2018), a qual se consagrou vencedora do desafio ILSVRC 2017 — o mesmo em que a GoogLeNet obteve destaque em 2014. Essa rede tem como objetivo aprimorar o desempenho de uma CNN tradicional por meio da introdução do bloco *Squeeze-and-Excitation*, que realiza uma compressão (*squeeze*) dos mapas de características a fim de capturar estatísticas globais de cada canal e, em seguida, uma etapa de excitação (*excitation*) que gera pesos específicos para cada canal. O resultado é um vetor de pesos que realça os canais mais relevantes e atenua os menos significativos.

Quanto ao banco de dados de sinais de radiofrequência (RF), este trabalho sugere que pesquisas futuras realizem treinamentos e testes utilizando os dados disponíveis na biblioteca FÊNIX, do CGAEM, a qual armazena sinais de sensores provenientes de serviços de inteligência. Dessa forma, os resultados obtidos tenderão a representar com maior fidelidade um cenário operacional real no ambiente marítimo.

Por fim, propõe-se que o desenvolvimento de pesquisas futuras concentre esforços em adaptação das arquiteturas e avaliação das restrições computacionais embarcadas; integração com a biblioteca Fênix e fluxos de dados do sensor até console no COC; e avaliação contínua mediante ensaios no mar, a fim de elevar o Poder Naval brasileiro frente às ameaças contemporâneas no espectro eletromagnético.

REFERÊNCIAS

ALVES, E.; CORRIÇA, J.; COSTA, I. *et al.* **A importância da Electronic Intelligence (ELINT) na estimação e parametrização de pulsos eletromagnéticos detectados por Medidas de Apoio à Guerra Eletrônica (MAGE) com receptor digital na Marinha do Brasil.** In: XVIII SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA, 2021, Resende. Anais [...]. Resende: Faculdades Dom Bosco, 2021. Sigla do Evento: XVIII SEGeT. Disponível em: <https://www.aedb.br/seget/artigos2021.php?pag=349>. Acesso em: 4 jun. 2025.

ALVES, Edgard Braz. **Emprego de técnicas de análise de tempo-frequência e de redes neurais convolucionais na classificação automática de sinais radar de baixa probabilidade de interceptação.** 2024. 250 f. Dissertação (Mestrado em Ciências em Sistemas e Computação) – Instituto Militar de Engenharia, Rio de Janeiro, 2024.

ANDRADE, Filipe de Oliveira. **Desenvolvimento do MAGE Defensor MK3.** Passadiço, v. 36, n. 43, Revista Passadiço – 80 Anos do CAAML, 2023. Publicado em 9 jan. 2024. Disponível em: <https://www.portaldeperiodicos.marinha.mil.br/index.php/passadico/article/view/5277/5140>. Acesso em: 19 set. 2025.

BENECASE JÚNIOR, Antonio Carlos. **Estudo do uso de técnicas simples de inteligência artificial na classificação de sinais radar modulados.** 2023. 99 f. Trabalho de Conclusão de Curso (Curso de Aperfeiçoamento Avançado em Guerra Eletrônica) – Centro de Instrução Almirante Alexandrino, Rio de Janeiro, 2023.

CUNHA, L. **Redes neurais convolucionais e segmentação de imagens: uma revisão bibliográfica.** 2020. Dissertação (Graduação em Engenharia de Controle e Automação) – Universidade Federal de Ouro Preto, Ouro Preto, 2020.

DEEP LEARNING BOOK. **O neurônio biológico e matemático.** Disponível em: <https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>. Acesso em: 13 out. 2025.

DUTRA, Arthur Santos. **Análise de dados de inspeção em motores de indução para classificação utilizando técnicas de machine learning.** 2023. 93 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) – Universidade Federal de Ouro Preto, Instituto de Ciências Exatas e Aplicadas, João Monlevade, 2023.

FIGUEIREDO, R.; SILVA, E.; NEVES, S. **Abordagens para análise e extração de características de radares LPI.** 2019. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019. Disponível em: <http://www.pee.ufrrj.br/index.php/pt/producao-academica/dissertacoes-de-mestrado/2019-1/2016033326--149/file>. Acesso em: 3 ago. 2025.

FLAUZINO, Letícia de Almeida. **Visão computacional com redes neurais convolucionais: uma abordagem histórica, teórica e prática.** 2024. 63 f. Trabalho de Conclusão de Curso (Licenciatura em Matemática) – Universidade Federal de São Carlos, Sorocaba, 2024. Disponível em: https://www.matematicasorocaba.ufscar.br/arquivos/tcc_leticia_almeida_flauzino.pdf. Acesso em: 5 out. 2025.

GODINHO, Lahiri Jumonji. **Avaliação do desempenho de redes neurais convolucionais para o reconhecimento biométrico da região periocular utilizando Transfer Learning**. São Carlos: Universidade de São Paulo, Escola de Engenharia de São Carlos, 2019.

GUIMARÃES, Alberto Junior Saraiva; BARBOSA, Douglas Silva; SOUSA, Gustavo da Silva; SANTOS, Armando José de Sá. **Ação de redes neurais convolucionais na classificação de imagens: abordagens e resultados**. Contemporary Journal, v. 5, n. 1, p. 1–19, 2025. DOI: 10.56083/RCV5N1-012.

HU, Jie; SHEN, Li; SUN, Gang. **Squeeze-and-Excitation Networks**. In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, Salt Lake City. Proceedings [...]. Los Alamitos: IEEE Computer Society, 2018. p. 7132–7141. DOI: 10.1109/CVPR.2018.00745. Disponível em: <https://github.com/hujie-frank/SENet>. Acesso em: 16 out. 2025.

KONG, S.; KIM, M.; HOANG, L.; KIM, E. **Automatic LPI Radar Waveform Recognition Using CNN**. In: IEEE Access. vol. 6. p. 4207-4219, 2018. Disponível em: https://www.researchgate.net/publication/322201609_Automatic_LPI_Radar_Waveform_Recognition_using_CNN. Acesso em: 22 jul. 2025

LANDIS, J. R.; KOCH, G. G. **The measurement of observer agreement for categorical data**. Biometrics, v. 33, n. 1, p. 159–174, 1977. Disponível em: <https://www.scinapse.io/papers/216>. Acesso em: 10 jun. 2025.

LECUN, Y. *et al.* **Backpropagation applied to handwritten zip code recognition**. Neural Computation, v. 1, n. 4, p. 541–551, 1989. DOI: 10.1162/neco.1989.1.4.541.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. **Gradient-based learning applied to document recognition**. Proceedings of the IEEE, 1998. Disponível em: http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf. Acesso em: 3 jun. 2025.

LEITE JUNIOR, Walmor Cristino. **A Guerra Eletrônica na História Naval**. Revista Marítima Brasileira, Rio de Janeiro, v. 141, n. 1º trim., p. 199–212, 2021. Disponível em: <https://portaldeperiodicos.marinha.mil.br/index.php/revistamaritima/article/view/4110/3975>. Acesso em: 4 abr. 2025.

MARINHA DO BRASIL. **Apostila de Guerra Eletrônica – Medidas de Apoio à Guerra Eletrônica Radar**. Rio de Janeiro: Centro de Instrução Almirante Wandenkolk, 2002. 1. ed. Finalidade: didática.

MARINHA DO BRASIL. **GE-101 – Introdução à Guerra Eletrônica: Fundamentos**. 2. ed. Niterói, RJ: Centro de Guerra Acústica e Eletrônica da Marinha, 2023. Publicação ostensiva. Finalidade: didática.

MATHESON, R. J.; SMILLEY, J. D.; FALCON, G. D.; LAWRENCE, V. S. **Output Tube Emission Characteristics of Operational Radars**. Boulder, CO: National Telecommunications and Information Administration (NTIA), U.S. Department of Commerce, 1982. (NTIA Report 82-92). Disponível em: https://its.ntia.gov/publications/download/82-92_ocr.pdf. Acesso em: 20 set. 2025.

MATLAB. The MathWorks, Inc. Disponível em: <https://www.mathworks.com/products/matlab.html>. Acesso em: 19 set. 2025.

MELO, Fernando Guedes de. **Deteccção de sinais radar chirp por receptores MAGE digitais de banda larga**. Rio de Janeiro: Centro de Instrução Almirante Alexandrino, 2023. Monografia (Curso de Aperfeiçoamento Avançado em Guerra Eletrônica) – Marinha do Brasil.

MELVIN, William L.; SCHEER, James A. **Principles of Modern Radar: Volume 3 – Radar Applications**. Edison, NJ: SciTech Publishing, 2014.

MINISTÉRIO DA DEFESA (Brasil). **Manual de Guerra Eletrônica para Emprego em Operações Conjuntas – MD31-M-05**. 1. ed. Brasília: Estado-Maior Conjunto das Forças Armadas, 2023. Disponível em: <https://www.gov.br/defesa-apresenta-balanco-das-aco-es-para-combater-o-novo-coronavirus/pt-br/assuntos/estado-maior-conjunto-das-forcas-armadas/doutrina-militar/publicacoes-1/publicacoes/MD31M05ManualdeGuerraEletrnicaparaEmpregoemOperaesConjuntas1Edio2023.pdf>. Acesso em: 5 jun. 2025.

MOREIRA, Rodrigo de Souza. **Dispositivos de detecção passiva**. Aula expositiva ministrada em 19 jun. 2025, no Curso de Guerra Eletrônica, Centro de Instrução Almirante Alexandrino (CIAA), Rio de Janeiro. Anotações pessoais do autor.

NAVAL.COM.BR. **Janes: NDM Bahia receberá MAGE Defensor MK3**. 2018. Disponível em: <https://www.naval.com.br/blog/2018/12/19/janes-ndm-bahia-recebera-mage-defensor-mk3/>. Acesso em: 19 set. 2025.

NERI, Filippo. **Introduction to Electronic Defense Systems**. 3. ed. Norwood, MA: Artech House Inc., 2018.

PARQUE CIENTEC. **O espectro eletromagnético**. Universidade de São Paulo, [s.d.]. Disponível em: <https://www.parquecientec.usp.br/passeio-virtual/tudo-sao-ondas/o-espectro-eletromagnetico>. Acesso em: 19 set. 2025.

RODRIGUES, Diego Alves. **Deep learning e redes neurais convolucionais: reconhecimento automático de caracteres em placas de licenciamento automotivo**. 2018. 66 f. Monografia (Bacharelado em Ciência da Computação) – Universidade Federal da Paraíba, João Pessoa, 2018.

RUBACK, Livia; ÁVILA, Sandra; CANTERO, Lucia. **Vieses no aprendizado de máquina e suas implicações sociais: um estudo de caso no reconhecimento facial**. In: WORKSHOP SOBRE INCLUSÃO DIGITAL E COMPUTAÇÃO SOCIAL (WICS), 2021, Porto Alegre. Anais [...]. Porto Alegre: SBC, 2021. DOI: 10.5753/wics.2021.15967. Disponível em: https://www.researchgate.net/publication/353340459_Vieses_no_Aprendizado_de_Maquina_e_suas_Implicacoes_Sociais_Um_Estudo_de_Caso_no_Reconhecimento_Facial. Acesso em: 7 out. 2025.

SCHWERZ, Jorge Luiz. **O papel da Guerra Eletrônica de Comunicação no conflito Rússia-Ucrânia**. DefesaNet, 3 dez. 2023. Disponível em: https://www.defesanet.com.br/us_ru_otan/o-papel-da-guerra-eletronica-de-comunicacao-no-conflito-russia-ucrania/. Acesso em: 19 out. 2025.

SISTON, Gustavo Lopes Braga. **Estudo comparativo das técnicas de estimação de ângulo para um sistema MAGE**. 2023. 101 f. Trabalho de Conclusão de Curso (Curso de Aperfeiçoamento Avançado em Sistemas de Armas) – Centro de Instrução Almirante Alexandrino, Diretoria de Ensino da Marinha, Rio de Janeiro, 2023.

SKOLNIK, M. I. **Introduction to Radar Systems**. Maryland: McGraw-Hill, 1981.

SOUZA, Roberto Macedo de. **Classificação de falhas em ativos rotativos utilizando rede neural convolucional**. 2020. Dissertação (Mestrado em Gestão e Desenvolvimento Industrial) – Centro Universitário SENAI CIMATEC, Salvador, 2020.

SPRECKELSEN, Malte von. **Electronic warfare – the forgotten discipline: why is the refocus on this traditional warfare area key for modern conflict?** JAPCC Journal, Kalkar, n. 27, p. 57–62, 2018. Disponível em: https://www.japcc.org/wp-content/uploads/JAPCC_J27_screen.pdf. Acesso em: 5 jun. 2025.

SUSTELO, Rui Pedro Carreiras. **Compressão de impulsos de radar com filtros adaptados**. Dissertação (Mestrado em Engenharia Electrotécnica e de Computadores) – Instituto Superior Técnico, Universidade de Lisboa, Lisboa, 2021. Disponível em: https://fenix.tecnico.ulisboa.pt/downloadFile/844820067127129/57809_RuiSustelo_tese_depois_provaspublicas.pdf. Acesso em: abr. 2025.

UTSCH, Kaio Giurizatto. **Uso de redes neurais convolucionais para classificação de imagens digitais de lesões de pele**. Vitória–ES: Universidade Federal do Espírito Santo, Centro Tecnológico, Departamento de Engenharia Elétrica, 2018. Projeto de Graduação (Engenharia Elétrica).

WOLFF, C. **Noções básicas de radar: funcionamentos físicos e princípio do radar**. [S. l.], 2023. Tradução: Eduardo Dourado. Disponível em: <https://www.radartutorial.eu/01.basics/rb04.pt.html>. Acesso em: 22 jul. 2025.

XU, Yongjun *et al.* **Artificial intelligence: a powerful paradigm for scientific research**. The Innovation, v. 2, n. 4, p. 100179, 2021. DOI: 10.1016/j.xinn.2021.100179. Disponível em: <https://www.cell.com/the-innovation>. Acesso em: 5 out. 2025.

APÊNDICE A – RESULTADO DA SIMULAÇÃO GOOGLNET TREINADA COM 6 ÉPOCAS

A seguir, é o apresentado o relatório gerado pelo MATLAB do desempenho da rede GoogLeNet treinada com seis épocas.

```
>> googleNETcnnV2
Total de arquivos: 16800
Total de classes: 12
Total de arquivos do conjunto de treinamento: 8820
Total de arquivos do conjunto de testes: 5040
Total de arquivos do conjunto de validação: 2940
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Frank + ruído: 1400
Total de arquivos com pulso modulado em fase tipo LFM + ruído: 1400
Total de arquivos com pulso sem Modulação + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de
Treinamento):980
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de
Treinamento):980
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Treinamento):
980
Total de arquivos com pulso sem Modulação + ruído: 980
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de Testes):
420
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Testes): 420
Total de arquivos com pulso sem Modulação + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Testes): 420
Acurácia com dados do conjunto de TESTE: 97.6786%
Acurácia com dados do conjunto de TESTE para SNR = -25dB: 73.8889%
Acurácia com dados do conjunto de TESTE para SNR = -20dB: 96.1111%
Acurácia com dados do conjunto de TESTE para SNR = -18dB: 98.6111%
Acurácia com dados do conjunto de TESTE para SNR = -15dB: 99.1667%
```

Acurácia com dados do conjunto de TESTE para SNR = -13dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = -10dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = -8dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = -5dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = -3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 0dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 5dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 10dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 15dB: 100%
Acurácia com dados do conjunto de TREINAMENTO: 99.9433%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -25dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -20dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -18dB: 99.843%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -15dB: 99.6845%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -13dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -10dB: 99.844%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -8dB: 99.8425%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -5dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -3dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 0dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 3dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 5dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 10dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 15dB: 100%

APÊNDICE B – RESULTADO DA SIMULAÇÃO GOOGLNET TREINADA COM 2 ÉPOCAS

A seguir, é o apresentado o relatório gerado pelo MATLAB do desempenho da rede GoogLeNet treinada com duas épocas.

```
>> googleNETcnnV2
Total de arquivos: 16800
Total de classes: 12
Total de arquivos do conjunto de treinamento: 8820
Total de arquivos do conjunto de testes: 5040
Total de arquivos do conjunto de validação: 2940
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Frank + ruído: 1400
Total de arquivos com pulso modulado em fase tipo LFM + ruído: 1400
Total de arquivos com pulso sem Modulação + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de
Treinamento):980
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de
Treinamento):980
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Treinamento):
980
Total de arquivos com pulso sem Modulação + ruído: 980
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de Testes):420
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Testes): 420
Total de arquivos com pulso sem Modulação + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Testes): 420
Acurácia com dados do conjunto de TESTE: 97.5%
Acurácia com dados do conjunto de TESTE para SNR = -25dB: 73.6111%
Acurácia com dados do conjunto de TESTE para SNR = -20dB: 94.4444%
Acurácia com dados do conjunto de TESTE para SNR = -18dB: 98.6111%
```

Acurácia com dados do conjunto de TESTE para SNR = -15dB: 99.1667%
Acurácia com dados do conjunto de TESTE para SNR = -13dB: 99.4444%
Acurácia com dados do conjunto de TESTE para SNR = -10dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = -8dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = -5dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = -3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 0dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 5dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 10dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 15dB: 100%
Acurácia com dados do conjunto de TREINAMENTO: 99.8639%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -25dB: 99.5342%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -20dB: 99.6764%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -18dB: 99.687%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -15dB: 99.8438%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -13dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -10dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -8dB: 99.8405%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -5dB: 99.8415%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -3dB: 99.6805%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 0dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 3dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 5dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 10dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 15dB: 100%

APÊNDICE C – RESULTADO DA SIMULAÇÃO CNN PROPOSTA POR KONG ET AL. (2018) TREINADA COM 6 ÉPOCAS

A seguir, é o apresentado o relatório gerado pelo MATLAB do desempenho da rede GoogLeNet treinada com seis épocas.

```
>> cnn3CNN
Total de arquivos: 16800
Total de classes: 12
Total de arquivos do conjunto de treinamento: 8820
Total de arquivos do conjunto de testes: 5040
Total de arquivos do conjunto de validação: 2940
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Frank + ruído: 1400
Total de arquivos com pulso modulado em fase tipo LFM + ruído: 1400
Total de arquivos com pulso sem Modulação + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de Treinamento):980
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de Treinamento):980
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Treinamento):980
Total de arquivos com pulso sem Modulação + ruído: 980
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de Testes):420
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Testes): 420
Total de arquivos com pulso sem Modulação + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Testes): 420
Acurácia com dados do conjunto de TESTE: 96.6667%
Acurácia com dados do conjunto de TESTE para SNR = -25dB: 66.6667%
Acurácia com dados do conjunto de TESTE para SNR = -20dB: 92.2222%
Acurácia com dados do conjunto de TESTE para SNR = -18dB: 97.2222%
Acurácia com dados do conjunto de TESTE para SNR = -15dB: 98.3333%
Acurácia com dados do conjunto de TESTE para SNR = -13dB: 99.7222%
```

Acurácia com dados do conjunto de TESTE para SNR = -10dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = -8dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = -5dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = -3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 0dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 5dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 10dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 15dB: 99.7222%
Acurácia com dados do conjunto de TREINAMENTO: 98.1293%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -25dB: 82.4726%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -20dB: 93.3439%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -18dB: 98.7034%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -15dB: 99.844%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -13dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -10dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -8dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -5dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -3dB: 99.6815%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 0dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 3dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 5dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 10dB: 100%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 15dB: 100%

APÊNDICE D – RESULTADO DA SIMULAÇÃO CNN PROPOSTA POR KONG ET AL (2018) TREINADA COM 2 ÉPOCAS

A seguir, é o apresentado o relatório gerado pelo MATLAB do desempenho da rede GoogLeNet treinada com duas épocas.

```
>>> cnn3CNN
Total de arquivos: 16800
Total de classes: 12
Total de arquivos do conjunto de treinamento: 8820
Total de arquivos do conjunto de testes: 5040
Total de arquivos do conjunto de validação: 2940
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Frank + ruído: 1400
Total de arquivos com pulso modulado em fase tipo LFM + ruído: 1400
Total de arquivos com pulso sem Modulação + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo P4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T1 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T2 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T3 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo T4 + ruído: 1400
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de
Treinamento):980
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de
Treinamento):980
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Treinamento):
980
Total de arquivos com pulso sem Modulação + ruído: 980
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Treinamento): 980
Total de arquivos com pulso modulado em fase tipo Barker 13 + ruído (Conjunto de Testes):420
Total de arquivos com pulso modulado em fase tipo Frank + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo LFM + ruído (Conjunto de Testes): 420
Total de arquivos com pulso sem Modulação + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo P4 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T1 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T2 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T3 + ruído (Conjunto de Testes): 420
Total de arquivos com pulso modulado em fase tipo T4 + ruído (Conjunto de Testes): 420
Acurácia com dados do conjunto de TESTE: 94.0079%
Acurácia com dados do conjunto de TESTE para SNR = -25dB: 55.8333%
Acurácia com dados do conjunto de TESTE para SNR = -20dB: 85%
Acurácia com dados do conjunto de TESTE para SNR = -18dB: 89.1667%
Acurácia com dados do conjunto de TESTE para SNR = -15dB: 94.4444%
```

Acurácia com dados do conjunto de TESTE para SNR = -13dB: 96.3889%
Acurácia com dados do conjunto de TESTE para SNR = -10dB: 98.8889%
Acurácia com dados do conjunto de TESTE para SNR = -8dB: 98.3333%
Acurácia com dados do conjunto de TESTE para SNR = -5dB: 99.1667%
Acurácia com dados do conjunto de TESTE para SNR = -3dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = 0dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 3dB: 100%
Acurácia com dados do conjunto de TESTE para SNR = 5dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = 10dB: 99.7222%
Acurácia com dados do conjunto de TESTE para SNR = 15dB: 99.7222%
Acurácia com dados do conjunto de TREINAMENTO: 94.4785%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -25dB: 60.625%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -20dB: 84.4094%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -18dB: 91.2363%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -15dB: 95.4397%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -13dB: 97.12%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -10dB: 97.9398%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -8dB: 98.7097%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -5dB: 99.3651%
Acurácia com dados do conjunto de TREINAMENTO para SNR = -3dB: 99.8397%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 0dB: 99.686%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 3dB: 99.8425%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 5dB: 99.681%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 10dB: 99.6885%
Acurácia com dados do conjunto de TREINAMENTO para SNR = 15dB: 99.839%