

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

**CURSO DE APERFEIÇOAMENTO AVANÇADO EM GUERRA ELETRÔNICA**

**TRABALHO DE CONCLUSÃO DE CURSO**

**ESTUDO DO USO DE TÉCNICAS SIMPLES DE INTELIGÊNCIA ARTIFICIAL NA  
CLASSIFICAÇÃO DE SINAIS RADAR MODULADOS**



**PRIMEIRO-TENENTE ANTONIO CARLOS BENECASE JUNIOR**

Rio de Janeiro  
2023

PRIMEIRO-TENENTE ANTONIO CARLOS BENECASE JUNIOR

ESTUDO DO USO DE TÉCNICAS SIMPLES DE INTELIGÊNCIA ARTIFICIAL NA  
CLASSIFICAÇÃO DE SINAIS RADAR MODULADOS

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

Orientadores:

DSc Rodrigo da Silva Moreira

DSc Jorge Costa Pires Filho

CIAA  
Rio de Janeiro  
2023

PRIMEIRO-TENENTE ANTONIO CARLOS BENECASE JUNIOR

ESTUDO DO USO DE TÉCNICAS SIMPLES DE INTELIGÊNCIA ARTIFICIAL NA  
CLASSIFICAÇÃO DE SINAIS RADAR MODULADOS

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

Aprovada em 24/11/2023

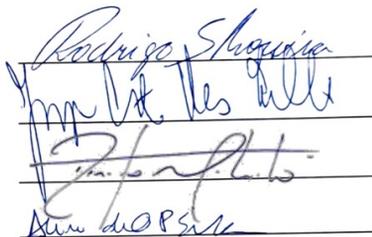
Banca Examinadora:

Rodrigo da Silva Moreira, DSc – IPqM

Jorge Costa Pires Filho, DSc – IPqM

Renato Machado, DSc – ITA

Aline de Oliveira Pinto Silva, DSc – IPqM



The image shows four handwritten signatures in blue ink, each written on a horizontal line. From top to bottom, the signatures correspond to the names listed on the left: Rodrigo da Silva Moreira, Jorge Costa Pires Filho, Renato Machado, and Aline de Oliveira Pinto Silva.

CIAA  
Rio de Janeiro  
2023

## AGRADECIMENTO

A conclusão deste trabalho representa mais do que um simples marco acadêmico para mim: é o resultado de um esforço conjunto e do apoio incalculável de diversas pessoas que, de diferentes formas, contribuíram para que este projeto se concretizasse.

Primeiramente, gostaria de expressar minha gratidão aos meus orientadores, o Senhor Jorge Costa Pires Filho e o Senhor Rodrigo da Silva Moreira. Seus conhecimentos ímpares e orientações precisas foram determinantes para a confecção deste trabalho. Suas valiosas contribuições, representadas na vontade e disponibilidade em compartilhar suas experiências e sabedorias foram insuperáveis.

Aos meus amigos de longa data, companheiros de jornada desde os tempos do Colégio Naval ou Escola Naval, Felipe Bitencourt, Matheus Araujo, Patuelli, Bruno Costa, Jonas, Esquitino, Thales, Pará, Diego Fernandes, Leonardo Cordeiro e Felipe dos Anjos, o meu muito obrigado. Suas palavras de encorajamento, o apoio mútuo e a amizade que construímos ao longo dos anos foram um alicerce sólido que me impulsionou a seguir em frente.

À minha amada esposa, Marcele, meu mais sincero agradecimento. Seu apoio incondicional e compreensão durante as longas jornadas de pesquisa e estudo foram essenciais para que eu pudesse enfrentar os desafios e as horas dedicadas a este trabalho. Sua paciência e incentivo foram verdadeiramente incomensuráveis.

À minha mãe, Véra Lucia, não existem palavras suficientes para expressar a profundidade da minha gratidão. Sua dedicação incansável em me proporcionar educação e valores inestimáveis moldaram meu caráter e me tornaram quem sou hoje. Você é a base de tudo o que alcancei na vida e sua influência é eterna.

A todos vocês, expresso o meu mais profundo agradecimento. Este trabalho não seria possível sem o apoio, a orientação e o amor de cada um de vocês. Espero que possam compartilhar comigo o orgulho desta conquista, pois ela também pertence a vocês. Muito obrigado!

# ESTUDO DO USO DE TÉCNICAS SIMPLES DE INTELIGÊNCIA ARTIFICIAL NA CLASSIFICAÇÃO DE SINAIS RADAR MODULADOS

## Resumo

No cenário bélico moderno, a Capacidade de Guerra Eletrônica se torna cada vez mais vital para a manutenção da segurança nacional e para o alcance efetivo dos objetivos militares e geopolíticos de uma nação ao proporcionar uma vantagem estratégica e um poder de dissuasão decisivos. Diante disso, este trabalho norteia-se pela ideia de promover uma contribuição para o desenvolvimento das Medidas de Apoio à Guerra Eletrônica da Marinha do Brasil. Para atingir esse propósito, esta pesquisa analisa a eficiência de algoritmos classificadores de modulação intrapulso em sinais radar e intenciona servir como estágio inicial de um estudo mais aprofundado no assunto. Sendo assim, este trabalho abrange uma análise comparativa entre três classificadores que utilizam técnicas de Inteligência Artificial distintas (Redes Neurais de Elman, Redes Neurais Convolucionais e Máquinas de Vetores de Suporte). Outrossim, todos os três algoritmos visam performar classificações assertivas sobre os tipos dos sinais investigados, sejam eles modulados linearmente em frequência ou modulados em fase por meio de códigos Barker, polifásicos ou politemporais. Nesse contexto, a correta classificação da modulação dos sinais radar permite uma identificação precoce de emissores hostis, o que impulsiona uma maior eficiência e celeridade nas tomadas de decisão das autoridades e reação dos sistemas de combate. A classificação de sinais radar modulados, portanto, assume vital importância na detecção de ameaças e confere uma vantagem significativa no âmbito da Guerra Eletrônica para a nação.

**Palavras-chave:** classificação; radar; sinais; modulação; Inteligência Artificial.

## Abstract

In the modern military scenario, Electronic Warfare Capability becomes increasingly vital for maintaining national security and effectively achieving a nation's military and geopolitical objectives by providing a decisive strategic advantage and dissuasion power. In light of this, this paper is guided by the idea of making a contribution to the development of Electronic Warfare Support Measures for the Brazilian Navy. To achieve this goal, this research analyzes the efficiency of intrapulse modulation classification algorithms in radar signals and aims to serve as an initial step for a more in-depth study on the subject. Thus, this study encompasses a comparative analysis of three classifiers employing different Artificial Intelligence techniques (Elman Neural Networks, Convolutional Neural Networks, and Support Vector Machines). Furthermore, all three algorithms aim to perform accurate classifications of the investigated signal types, whether they are linearly frequency modulated or phase modulated using Barker codes, polyphase codes, or polytime codes. In this context, the correct classification of radar signal modulation allows for early identification of hostile emitters, thereby enhancing efficiency and expediting decision-making by authorities and reaction of combat systems. Therefore, the classification of modulated radar signals assumes paramount importance in threat detection and provides a significant advantage in the realm of Electronic Warfare for the nation.

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

## LISTA DE FIGURAS

Figura 1 – Conceito de Capacidade de Guerra Eletrônica .....	20
Figura 2 – Forma de onda de um CWR .....	23
Figura 3 – Forma de onda de um PR.....	24
Figura 4 – Estrutura de um neurônio biológico .....	26
Figura 5 – Representação simplificada de um neurônio matemático.....	27
Figura 6 – <i>Perceptron</i> .....	28
Figura 7 – <i>Multilayer Perceptron</i> (MLP).....	29
Figura 8 – Esquema básico de conexão de rede recorrente.....	30
Figura 9 – Redes Neurais de Elman .....	31
Figura 10 – Os canais RGB de uma imagem colorida. ....	33
Figura 11 – Classificação da imagem de um pássaro por uma CNN.....	34
Figura 12 – Convolução de uma imagem de entrada 6x6 e um filtro 3x3, stride 1 .....	36
Figura 13 – Max Pooling em uma matriz 4x4 com stride 2 gerando uma matriz 2x2 .....	37
Figura 14 – <i>Support Vector Machine</i> .....	38
Figura 15 – Hiperplano ótimo .....	39
Figura 16 – SVM não linearmente separável.....	40
Figura 17 – <i>Kernel Trick</i> .....	41
Figura 18 – Função $\text{Rect}(t/\tau)$ .....	44
Figura 19 – Representação gráfica de sinais LFM e não modulado (amplitude x tempo).....	45
Figura 20 – Modulação em fase .....	45
Figura 21 – Minimização dos lóbulos laterais .....	46
Figura 22 – Classificador proposto por Zhang, Liu e Diao.....	56
Figura 23 – Módulo classificador proposto por Zhang, Liu e Diao.....	57
Figura 24 – Módulo classificador baseado na Rede Neural de Elman.....	58
Figura 25 – As três camadas do classificador baseado na Rede Neural de Elman .....	58
Figura 26 – Módulos do classificador baseado na CNN.....	59
Figura 27 – CNN utilizada no classificador .....	61
Figura 28 – MLP <i>Fully Connected</i> utilizada no classificador baseado na CNN.....	61
Figura 29 – Módulos do classificador baseado na SVM.....	62
Figura 30 – Gráficos das amplitudes das amostras analisadas por tipo de modulação .....	64
Figura 31 – Gráficos de amplitude com SNR -25 dB e 0 dB (Barker13 e Frank) .....	65
Figura 32 – Gráficos após aplicação da STFT (tempo x frequência).....	65
Figura 33 – Gráficos após aplicação da STFT com SNR -25 dB e 0 dB (Barker13 e Frank) .....	66
Figura 34 – Gráficos de autocorrelação com SNR = 15 dB.....	67

Figura 35 – Gráficos de autocorrelação com SNR = 0 dB e SNR = -25 dB (Barker13 e Frank) .	68
Figura 36 – Gráfico geral de taxa de acertos por classificador .....	80
Figura 37 – Gráficos de taxa de acertos por classificador utilizando sinais com diferentes SNR	81
Figura 38 – Conjuntos de treinamento hipotéticos de Bagging .....	90
Figura 39 – Sugestão de arquitetura para futuros trabalhos .....	91
Figura 40 – Arquitetura da rede 2 sugerida.....	92

## LISTA DE TABELAS

Tabela 1 – Nomenclatura padrão das faixas de frequência de operação dos radares.....	23
Tabela 2 – Parâmetros intrapulso e interpulso de um Radar Pulsado .....	24
Tabela 3 – Códigos de Barker .....	47
Tabela 4 – Matriz de Confusão Geral gerada com os sinais de treinamento (classificador Elman) .....	69
Tabela 5 – Matriz de Confusão gerada com os sinais de treinamento ( <i>redel</i> Elman).....	69
Tabela 6 – Matrizes de confusão geradas com os sinais de treinamento em diferentes SNR (classificador Elman).....	70
Tabela 7 – Matriz de Confusão Geral gerada com os sinais do conjunto de teste (classificador Elman).....	71
Tabela 8 – Matriz de Confusão gerada com os sinais do conjunto de teste ( <i>redel</i> Elman).....	72
Tabela 9 – Matrizes de Confusão com diferentes SNR (classificador Elman) .....	73
Tabela 10 – Matriz de Confusão Geral gerada com os sinais de treinamento (classificador CNN) .....	74
Tabela 11 – Matrizes de Confusão geradas com os sinais do conjunto de treinamento em diferentes SNR (CNN) .....	75
Tabela 12 – Matriz de Confusão Geral gerado com os sinais de teste (classificador CNN) .....	76
Tabela 13 – Matrizes de Confusão com diferentes SNR (classificador CNN).....	76
Tabela 14 – Matriz de Confusão Geral gerada com os sinais de treinamento (classificador SVM) .....	77
Tabela 15 – Matriz de Confusão Geral gerada com os sinais do conjunto de teste (classificador SVM).....	78
Tabela 16 – Matrizes de Confusão com diferentes SNR (classificador SVM).....	79
Tabela 17 – Exemplo de Teste de Diagnósticos para a classificação da modulação P1 .....	82
Tabela 18 – Escala do nível de concordância (kappa) .....	84
Tabela 19 – Verificação do nível de concordância do classificador baseado na Rede Neural de Elman .....	84
Tabela 20 – Verificação do nível de concordância com diferentes SNR (Elman).....	85
Tabela 21 – Verificação do nível de concordância do classificador baseado na SVM.....	86
Tabela 22 – Verificação do nível de concordância com diferentes SNR (SVM) .....	86
Tabela 23 – Verificação do nível de concordância do classificador baseado na CNN.....	87
Tabela 24 – Verificação do nível de concordância com diferentes SNR (CNN).....	87
Tabela 25 – Comparação de confiabilidade entre os três classificadores .....	88

## LISTA DE SIGLAS E ABREVIATURAS

AGE	Atividades de Guerra Eletrônica
AWGN	<i>Additive White Gaussian Noise</i>
CGE	Capacidade de Guerra Eletrônica
CNN	Rede Neural Convolutacional
CW	Onda Contínua
CWR	Radar de Onda Contínua
EEM	Espectro Eletromagnético
ELINT	<i>Electronic Intelligence</i>
FFT	<i>Fast Fourier Transform</i>
FMCW	<i>Frequency Modulation Continuous Wave</i>
FMOP	<i>Frequency Modulation on Pulse</i>
FIR	<i>Finite Impulse Response</i>
GE	Guerra Eletrônica
IA	Inteligência Artificial
IPqM	Instituto de Pesquisas da Marinha
LFM	<i>Linear Frequency Modulation</i>
LPC	<i>Linear Predictive Coding</i>
LPI	<i>Low Probability of Intercept</i>
MAE	Medidas de Ataque Eletrônico
MAGE	Equipamentos de Medidas de Apoio à Guerra Eletrônica
MATLAB	<i>Software</i> de computação numérica da empresa Mathworks Inc
MB	Marinha do Brasil
MGE	Medidas de Guerra Eletrônica
MOP	<i>Modulation on Pulse</i>

PAR	<i>Peak-to-Average Power Ratio</i>
PMOP	<i>Phase Modulation on Pulse</i>
PR	<i>Pulsed Radar</i>
PRF	Frequência de Repetição de Pulsos
PRI	<i>Pulse Repetition Interval</i>
PSM	Pulso sem modulação
PW	Largura de Pulso
RCS	Seção Reta Radar
ReLU	<i>Rectified Linear Unity</i>
RETRON	Reconhecimento Eletrônico
RF	Radiofrequência
SLR	<i>Side Lobe Ratio</i>
SNR	Razão Sinal-Ruído
SEM	Minimização do Risco Estrutural
STFT	<i>Short-Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
TF	Matriz Resultante da <i>Short-Time Fourier Transform</i> aplicada ao sinal

## LISTA DE SÍMBOLOS

$A$	Amplitude
$a(z)$	Coefficientes da <i>Linear Predictive Coding</i>
$B$	Largura de banda
$b_{(k)}$	Viés ou bias
$c$	Constante na <i>kernel</i> polinomial
$d$	Grau da <i>kernel</i> polinomial
$dB$	Decibéis
$e$	Número de Euler ou neperiano
$\exp$	Função exponencial natural (base é o número de Euler)
$\varepsilon(n)$	Erro entre as amostras predita e atual na <i>Linear Predictive Coding</i>
$f_c$	Frequência da portadora
$f(x)$	Função definida por x
$FP$	Quantidade de falsos-positivos no cálculo do índice <i>kappa</i>
$FN$	Quantidade de falsos-negativos no cálculo do índice <i>kappa</i>
$H$	Matriz na camada oculta (classificador da Rede Neural de Elman)
$I$	Matriz na camada de entrada (classificador da Rede Neural de Elman)
$K_{(x_i,y_i)}$	<i>Kernel</i> polinomial
$k$	Índice da amostra ou do neurônio
$kappa$	Índice para cálculo do nível de concordância ou confiabilidade do classificador
$k_r$	Razão entre a largura de banda e a largura do pulso
$k_s$	Número de segmentos
$L$	Representação da ordem do código P1 e P2
$\log$	Função logarítmica na base 10
$M$	Razão de compressão

$\max(0, x)$	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
$n_a$	Número de amostras
$N$	Quantidade de fases presentes no código
$N_{Barker}$	Tamanho do código Barker
$N_I$	Número de neurônios na <i>Input Layer</i> (classificador da Rede Neural de Elman)
$N_O$	Número de neurônios na <i>Output Layer</i> (classificador da Rede Neural de Elman)
$O$	Matriz na camada de saída (classificador da Rede Neural de Elman)
$p$	Ordem do polinômio $a(z)$ da <i>Linear Predictive Coding</i>
$P_{ruído}$	Potência média do ruído
$P_{sinal}$	Potência média do sinal
$P_o$	Proporção de concordância observada
$P_e$	Proporção de concordância estimada
$PW$	Largura de pulso
$R$	Parte real de um número complexo
$\text{Rect}(t/\tau)$	Função retangular com PW igual a $\tau$
$s(t)$	Sinal no domínio do tempo
$s_p(n)$	Vetor da amostra predita ou estimada
$t$	Tempo
$t_s$	Período de amostragem
$T$	Período do código
$T_p$	Período para a modulação
$VP$	Quantidade de verdadeiros-positivos no cálculo do índice <i>kappa</i>
$VN$	Quantidade de verdadeiros-negativos no cálculo do índice <i>kappa</i>

$W$	Matriz com pesos sinápticos $w_i$
$w_i$	Valores dos pesos sinápticos
$w^T$	Transposta do vetor de pesos $w$ ajustáveis
$x_i$	Sinal de entrada em uma <i>kernel</i> polinomial ( $K_{(x_i,y_i)}$ )
$y^{(k)}$	Sinal de saída
$y_i$	Sinal de entrada em uma <i>kernel</i> polinomial ( $K_{(x_i,y_i)}$ )
$z$	Número de iterações em uma <i>kernel</i> polinomial ( $K_{(x_i,y_i)}$ )
$[]$	Função <i>floor</i>
$\emptyset_k$	Fase do sinal ( $\emptyset_{Frank}, \emptyset_{P1}, \emptyset_{P2}, \emptyset_{P3}, \emptyset_{P4}, \emptyset_{T1}, \emptyset_{T2}, \emptyset_{T3}, \emptyset_{T4}$ )
$\Sigma$	Somatório

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>15</b>
<b>1.1 Contextualização.....</b>	<b>15</b>
<b>1.2 Apresentação do problema .....</b>	<b>16</b>
<b>1.3 Justificativa e relevância .....</b>	<b>18</b>
<b>1.4 Objetivos.....</b>	<b>18</b>
1.4.1 Objetivo Geral .....	19
1.4.2 Objetivo Específico .....	19
<b>1.5 Estruturação do trabalho.....</b>	<b>19</b>
<b>2 REFERENCIAL TEÓRICO .....</b>	<b>20</b>
<b>2.1 Guerra Eletrônica.....</b>	<b>20</b>
2.1.1 RETRON .....	21
2.1.2 MAGE .....	21
<b>2.2 RADAR.....</b>	<b>22</b>
2.2.1 Radares de Onda Contínua (CWR) .....	23
2.2.2 Radares Pulsados (PR).....	24
<b>2.3 Inteligência Artificial.....</b>	<b>25</b>
2.3.1 O neurônio biológico .....	25
2.3.2 O neurônio matemático .....	26
2.3.3 <i>Perceptron e Multilayer Perceptrons</i> (MLP) .....	28
<b>2.4 Redes Neurais de Elman .....</b>	<b>30</b>
<b>2.5 Redes Neurais Convolucionais (CNN).....</b>	<b>32</b>
2.5.1 Estrutura básica de uma CNN .....	34
2.5.2 Convolução.....	35
2.5.3 <i>Max Pooling</i> .....	36
2.5.4 <i>Fully Connected Layer</i> .....	37
<b>2.6 <i>Support Vector Machine</i> (SVM).....</b>	<b>37</b>
2.6.1 SVM Linearmente Separável.....	38
2.6.2 SVM não linearmente separável.....	40
2.6.3 <i>Kernel</i> .....	41
<b>2.7 Tipos de modulação .....</b>	<b>42</b>
2.7.1 <i>Linear Frequency Modulation</i> (LFM).....	43

2.7.2 Códigos Barker .....	45
2.7.3 Polifásicos: P1, P2, P3, P4 e Frank.....	47
2.7.4 Politemporais: T1, T2, T3 e T4 .....	49
<b>2.8 O Problema da Classificação de Sinais.....</b>	<b>51</b>
<b>3 METODOLOGIA.....</b>	<b>52</b>
<b>3.1 Quanto aos fins.....</b>	<b>53</b>
<b>3.2 Quanto aos meios .....</b>	<b>53</b>
<b>3.3 Quanto à natureza do método .....</b>	<b>53</b>
<b>3.4 Limitações do método.....</b>	<b>53</b>
<b>3.5 Coleta e tratamento dos dados .....</b>	<b>54</b>
<b>4 ALGORITMOS DE CLASSIFICAÇÃO UTILIZADOS .....</b>	<b>56</b>
<b>4.1 Classificador baseado na Rede Neural de Elman .....</b>	<b>56</b>
<b>4.2 Classificador baseado na Rede Neural CNN.....</b>	<b>59</b>
<b>4.3 Classificador baseado na SVM.....</b>	<b>62</b>
<b>5 SIMULAÇÕES E ANÁLISE DOS RESULTADOS .....</b>	<b>64</b>
<b>5.1 Resultados do Classificador baseado na Rede Neural de Elman .....</b>	<b>68</b>
<b>5.2 Resultados do Classificador baseado na Rede Neural CNN.....</b>	<b>73</b>
<b>5.3 Resultados do Classificador baseado na SVM.....</b>	<b>77</b>
<b>5.4 Comparação entre os três classificadores.....</b>	<b>79</b>
<b>6 CONCLUSÃO.....</b>	<b>88</b>
<b>6.1 Sugestões para trabalhos futuros .....</b>	<b>89</b>
<b>REFERÊNCIAS.....</b>	<b>93</b>

# 1 INTRODUÇÃO

Este capítulo contextualiza o assunto de Guerra Eletrônica (GE) abordando um breve histórico, desde o seu surgimento, de forma a facilitar a compreensão da relevância deste estudo. Além disso, são apresentados os desafios da classificação eficiente de sinais radar modulados, uma vez que tais sinais possuem um papel preponderante para as Medidas de Apoio à Guerra Eletrônica (MAGE). Em seguida, são abordados os objetivos e as etapas do trabalho a serem versadas com o fito de esclarecer o escopo e as metas desta pesquisa.

## 1.1 Contextualização

No cenário hodierno dos conflitos bélicos, a dominância do espectro eletromagnético emerge como uma necessidade crescente para garantir proteção e vantagem tática em operações militares. Isso impulsiona um constante desenvolvimento tecnológico, frequentemente motivado pelos setores de defesa e segurança das diversas nações ao redor do mundo. Por conta disso, essas inovações tecnológicas acabam por desempenhar um papel crucial na área da GE.

Retornando ao início do século XX para um melhor entendimento do assunto, percebe-se o prelúdio da GE com o advento da radiotelegrafia sem fio. Esta tecnologia introduziu a capacidade de transmitir informações de longa distância por meio da transmissão de ondas de rádio pelo ar em pulsos curtos e longos. “A invenção do rádio por Guglielmo Marconi, na forma de telegrafia sem fio, logo recebeu uma aplicação militar. [...] no início da Guerra Russo-Japonesa de 1904-1905, a maioria dos navios nas frotas da Rússia e do Japão estava equipada com essa tecnologia” (LATIMER, 2015, p. 49, tradução nossa).

Segundo Nohra (2023), o pioneirismo da GE de fato ocorreu durante a Batalha de Tsushima, entre Rússia e Japão em 27 de maio de 1905, quando foram notadas as primeiras aparições de MAGE e Medidas de Ataque Eletrônico (MAE).

A partir desse ponto, em face à recente e notória vantagem bélica obtida pelos russos por meio do controle do espectro eletromagnético, as nações começaram a perceber o potencial desse novo meio. Isso provocou uma exploração progressiva das investigações nesse campo de conhecimento.

No período pós-guerra, a GE crescia vertiginosamente à medida que os conflitos globais e a Guerra Fria estimulavam a pesquisa e o desenvolvimento de tecnologias mais avançadas. Novos sistemas de interferência eletrônica e guerra eletrônica surgiam.

A Guerra do Vietnã marcou o início de um período de rápida expansão da Guerra Eletrônica [...] a Força Aérea dos EUA enfrentou um avançado sistema de defesa

aérea integrada enquanto bombardeava alvos no Vietnã do Norte. O Exército dos EUA enfrentou os desafios duplos de encontrar os sinais de rádio inimigos no terreno implacável do Vietnã e, posteriormente, proteger suas aeronaves de asa rotativa e de asa fixa de armas de defesa aérea guiadas por radar. (HENKE, 2019, p. 16, tradução nossa)

Com o advento da era digital e da computação avançada, a GE entrou em uma nova dimensão. A maior capacidade de processamento permitiu a criação de sistemas mais inteligentes e adaptáveis, capazes de identificar e neutralizar ameaças de forma mais eficaz, expandindo ainda mais o campo de batalha eletrônico. Atualmente, a GE continua a se desenvolver. Na moderna e corrente guerra Russo-Ucraniana, drones pequenos e uma densa constelação de satélites enriquecem a vigilância, permitindo identificar ameaças em tempo real (LIPTON, 2023, tradução nossa).

Além disso, as tecnologias de Inteligência Artificial (IA) e Aprendizado de Máquina (do inglês, *Machine Learning*) estão sendo aplicadas para aprimorar a detecção e a supressão de ameaças eletrônicas. De acordo com Lipton (2023, tradução nossa), uma nova geração de drones de ataque – mais baratos e notavelmente precisos – estão agora atravessando os céus, operando autonomamente até encontrarem seus objetivos. Alimentados por sistemas computacionais impulsionados por IA, esses drones têm a capacidade de identificar e selecionar alvos com maior facilidade do que a capacidade humana permitiria.

Logo, à medida que a tecnologia avança, é essencial que as forças armadas mantenham-se à frente da curva, adaptando-se e desenvolvendo estratégias de GE cada vez mais robustas e sofisticadas para enfrentar os desafios sempre em evolução do campo de batalha moderno.

Nesse sentido, este trabalho se propõe a explorar a aplicação de técnicas simples de IA e Aprendizado de Máquina voltadas à classificação de sinais radar modulados. Essa abordagem é especialmente relevante no âmbito da Inteligência Eletrônica (ELINT, do inglês *Electronic Intelligence*) e das MAGE e visa contribuir para a resolução de uma parcela desafiadora do complexo problema de classificação dos sinais radar.

## 1.2 Apresentação do problema

A evolução das táticas de guerra moderna tem ressaltado a importância crítica do desenvolvimento tecnológico e da Capacidade de Guerra Eletrônica (CGE) das nações para garantir superioridade em conflitos. Dentro desse contexto, a aplicação estratégica e operacional da ELINT tornou-se essencial tanto para potencializar a eficácia da GE por forças aliadas, quanto para mitigar seus efeitos prejudiciais quando utilizada por forças oponentes

(ALVES, E.; CORRIÇA, J.; COSTA, 2021, p. 3).

No campo operacional, conforme aponta Alves, Corriça e Costa (2021, p. 3), a ELINT analisa e determina as características de sinais eletromagnéticos em tempo real, permitindo a identificação da origem e da intenção do emissor durante operações. Já em um contexto estratégico, a ELINT contribui para a construção de um acervo de informações sobre sinais de radar, possibilitando análises detalhadas em longo prazo para a extração de conhecimentos valiosos a fim de formar uma biblioteca de dados cada vez mais confiável e precisa.

Adicionalmente, à medida que nações oponentes adotam sistemas de radar cada vez mais complexos para dificultar a interceptação dos sinais – como os radares *Low Probability of Interception* (LPI) – surge uma demanda cada vez maior por receptores de Equipamentos de MAGE mais modernos, que integrem a tecnologia de ELINT para otimizar o desempenho em ambientes de baixa Razão Sinal-Ruído (SNR). A evolução dos receptores MAGE analógicos para os receptores MAGE digitais propiciou a realização de análises mais detalhadas dos parâmetros dos sinais radar detectados, fornecendo uma compreensão mais completa dos sistemas de radar.

No passado, muitos radares projetados utilizavam pulsos de curta duração e alta potência de pico para reduzir suas perdas de radiação eletromagnética. [...] No entanto, nos dias de hoje, por meio do uso de técnicas de *Low Probability of Interception* (LPI), é possível projetar um radar que seja eficiente contra receptores de guerra eletrônica. (GHADIMI.; NOROUZI; BAYDERKHANI; *et al.*, 2020, p. 1179, tradução nossa)

Nesse cenário, a virada tecnológica para as operações de GE está na adoção de algoritmos complexos de ELINT. Por conseguinte, visando selecionar um classificador eficiente de sinais radar modulados que possa ser utilizado nos MAGE das nossas forças, esta pesquisa abrange o estudo e a comparação de três algoritmos de classificação de sinais radar que usam as seguintes técnicas de Aprendizado de Máquina: Redes Neurais de Elman, Redes Neurais Convolucionais (CNN) e Máquinas de Vetores Suporte (SVM, do inglês, *Support Vector Machine*). A investigação emprega sinais radar simulados com diversos tipos de modulação em fase: o bifásico Barker; os polifásicos P1, P2, P3, P4 e Frank; e os politemporais T1, T2, T3 e T4. Além desses, um tipo muito empregado de modulação em frequência, a *Linear Frequency Modulation* (LFM), também é incluído no estudo que visa proporcionar informações sobre a eficácia desses algoritmos em cenários desafiadores com baixo SNR.

### **1.3 Justificativa e relevância**

A crescente complexidade das operações de guerra moderna exige avanços constantes em tecnologia para manter a eficácia das forças militares. Diante dessa perspectiva, o domínio de uma CGE expressiva se destaca determinadamente para o sucesso de estratégias bélicas contemporâneas, onde a proficiência na classificação de sinais radar modulados representa uma vantagem significativa. Essa vantagem se dá pelo fato de que uma correta classificação de sinais radar pelos MAGE da força permite distinguir os sinais em graus de letalidade, o que contribui para a inteligência em combate ao fornecer informações valiosas para a tomada de decisões táticas e estratégicas. No entanto, a seleção de um classificador eficiente para sinais radar apresenta-se como um vultoso desafio.

Diante disso, a razão subjacente a esse estudo é fundamentada na necessidade de avaliar a eficiência de algoritmos de classificação fornecidos pelos orientadores. Isso visa elevar a preparação da força em ambientes de GE. Somado a isso, a busca por classificadores eficientes é impulsionada pela necessidade de aperfeiçoar a identificação de ameaças potenciais, diminuindo o tempo de reação do meio.

A diversidade dos sinais modulados presente nesta pesquisa – como Barker, polifásicos e politemporais, bem como a modulação em frequência LFM – simula diferentes possibilidades de cenários realistas e desafiadores que podem ser encontrados. Ademais, esse estudo não apenas fornece uma visão sobre a eficácia dos algoritmos de classificação, mas também aponta para o aprimoramento das MAGE e sua implementação eficaz em diferentes contextos.

Portanto, a justificativa para esse trabalho reside na necessidade de proporcionar maior confiabilidade para os classificadores de sinais radar dos MAGE da força. Sua relevância, por outro lado, envolve oferecer informações fundadas e factuais para desenvolver aprimoramentos e eventuais novas funcionalidades nos algoritmos de classificação dos MAGE, aprimorando a prontidão e o desempenho da Marinha do Brasil (MB) em ambientes de GE, cada vez mais complexos.

### **1.4 Objetivos**

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

### 1.4.1 Objetivo Geral

Contribuir para a compreensão das aplicações de técnicas de IA na classificação de sinais radar modulados, abrindo novos horizontes para o avanço das MAGE na MB ao conduzir uma análise comparativa da eficácia de três algoritmos de classificação baseados em Aprendizado de Máquina.

### 1.4.2 Objetivo Específico

Testar a implementação de três algoritmos de classificação de sinais radar modulados que utilizam as técnicas computacionais *Support Vector Machine* (SVM), Rede Neural Convolucional (CNN) e Rede Neural de Elman. Os resultados, obtidos a partir de simulações realizadas com o *software* MATLAB, permitirão determinar qual dos três classificadores utilizados neste trabalho é mais adequado para cada tipo de modulação testado para a base de dados empregada.

Ao final, com base na taxa de acertos na classificação, no índice *kappa* e na matriz de confusão, pretende-se fornecer *insights* valiosos sobre a utilização destes algoritmos na classificação de sinais radar modulados, contribuindo para a aplicação eficiente dessas técnicas em cenários reais.

## 1.5 Estruturação do trabalho

Este trabalho está dividido em cinco capítulos. O primeiro introduz uma ambientação do cenário da Guerra Eletrônica ao longo de sua história até os dias atuais. Além disso, apresenta a motivação da abordagem do tema e o propósito do estudo. O capítulo 2 enfoca no embasamento teórico dos conteúdos necessários para a compreensão do tema, como as definições de Guerra Eletrônica e MAGE, além de breves explicações acerca do radar, dos problemas encontrados na classificação de sinais, das técnicas de *Machine Learning* utilizadas e dos tipos de modulação de sinais abordados. No capítulo 3, a metodologia do trabalho é apontada, sendo apresentada a maneira como foram realizados a coleta e o tratamento dos dados utilizados. O quarto capítulo apresenta uma explicação detalhada dos classificadores utilizados no estudo. No capítulo 5, estão dispostas as análises das simulações realizadas no MATLAB por meio dos resultados obtidos com as matrizes de confusão e com os testes de concordância de cada classificador. Ao final, o sexto capítulo exhibe a comparação entre as confiabilidades de cada classificador estudado e expõe sugestões para futuros trabalhos relacionados ao assunto.

## 2 REFERENCIAL TEÓRICO

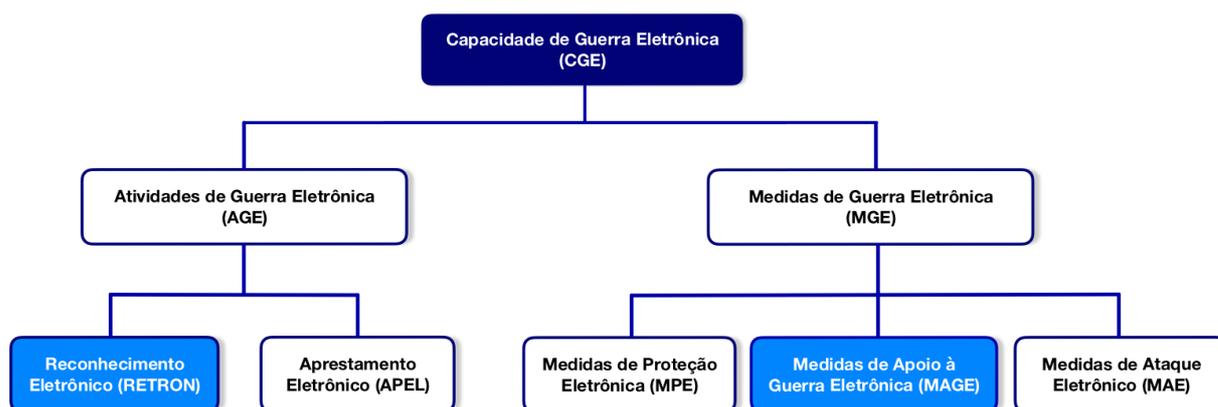
Esta Seção servirá como alicerce para fundamentar as investigações realizadas, proporcionando as bases conceitual e contextual necessárias para a compreensão das questões abordadas. O referencial teórico não apenas delinea as principais teorias relevantes, mas também traça os caminhos que orientam uma melhor compreensão do estudo.

### 2.1 Guerra Eletrônica

Conforme a definição proposta por Brasil (2017), a GE é o conjunto de ações com o objetivo de identificar, explorar, impedir, reduzir ou evitar a utilização do espectro eletromagnético (EEM) pelas forças oponentes e garantir a utilização deste espectro pelas forças amigas por meio do emprego de energia eletromagnética. Sendo assim, com o intuito de conduzir ações de Guerra Eletrônica, a Marinha do Brasil necessita evoluir sua Capacidade de Guerra Eletrônica.

Segundo Brasil (2017), a CGE é o conjunto de todos os meios e recursos que proporciona, ao Poder Naval, executar ações de Guerra Eletrônica de forma eficaz. Suas ramificações – conceitualmente falando – apresentam um amplo objeto de estudo. Entretanto, ressalta-se as áreas afetas ao alvo de investigação deste trabalho, o Reconhecimento Eletrônico (RETRON) e o MAGE, realçados na Figura 1.

Figura 1 – Conceito de Capacidade de Guerra Eletrônica



Fonte: Elaborado pelo autor (2023)

As Atividades de Guerra Eletrônica (AGE) são de natureza estratégica, tática, logística e de pesquisa que corroboram para o aperfeiçoamento da CGE e que estão principalmente relacionadas ao planejamento de operações bélicas navais, como salientado por Brasil (2017). Por outro lado, ainda segundo esse autor, as Medidas de Guerra Eletrônica (MGE) referem-se às ações relativas à CGE em suporte direto a uma operação no contexto

naval de conflito.

As ações de GE têm como propósito reforçar as chances de sucesso e de sobrevivência em uma possível contenda entre Forças Navais. Este objetivo guia os esforços realizados em proveito da CGE e, conforme as palavras de Brasil (2017), “chama a atenção do planejador para a importância de se considerar o tipo de ameaça esperada, pois de nada valerão equipamentos e técnicas sofisticadas se estes não forem eficazes contra ela.”

### 2.1.1 RETRON

O RETRON, sendo parte das AGE, possuem como meta o apoio à fase de planejamento das operações militares a serem executadas pela Marinha do Brasil. De acordo com Brasil (2017), o RETRON “terá caráter estratégico na medida em que for utilizado em proveito do planejamento e controle da CGE; será tático, quando empregado em apoio ao planejamento de uma operação de guerra naval, onde o valor das informações é diretamente proporcional à sua atualidade.”

Essa parte das AGE permitem dimensionar a nossa CGE perante o oponente, pois visam colher informações da capacidade das outras nações por meio de um processamento sistemático de dados obtidos oportunamente em comissões realizadas por navios de guerra nacionais, por exemplo. Esses dados, cuja atualização possui uma importância essencial, são colhidos por meio dos MAGE a bordo dos meios da Marinha do Brasil e se somam a outras informações angariadas por meio de fontes abertas.

### 2.1.2 MAGE

Esta ramificação das MGE é definida por Brasil (2017) como um:

Conjunto de ações visando à busca, interceptação, identificação e localização eletrônica das fontes de energia eletromagnética irradiada no ambiente eletrônico de uma Força ou unidade, a fim de permitir a análise, o imediato reconhecimento de uma ameaça ou sua posterior exploração. (BRASIL, 2017)

Com o fito de conseguir atingir os objetivos supracitados, os meios de todas as Marinhas utilizam equipamentos capazes de obter informações de nações oponentes de maneira furtiva. Esses equipamentos, homônimos às próprias Medidas de Guerra Eletrônica que incentivaram sua criação e desenvolvimento – MAGE – estão em constante aperfeiçoamento. Nesse sentido, a Marinha do Brasil possui, até o presente momento, o equipamento MAGE DEFENSOR, de desenvolvimento nacional, instalado nos seus principais meios.

Entretanto, em um cenário atual de constantes mudanças, onde contínuas inovações tecnológicas são projetadas por outros países, como os radares LPI utilizados em sistemas de navegação de mísseis, aeronaves e navios, faz-se necessária a elaboração de novas capacitações em nossos equipamentos. Sob essa perspectiva, o Instituto de Pesquisas da Marinha (IPqM) desenvolve, atualmente, novas gerações do MAGE DEFENSOR: o MAGE MK2, voltado para viaturas terrestres, o MAGE MK3, para navios de superfície e o MAGE MK4, para instalação a bordo de submarinos. Nessa direção, este trabalho servirá como um apoio inicial para o estudo aprofundado em classificação de sinais por meio da realização de testes de algoritmos a serem implementados no MAGE MK4.

## 2.2 RADAR

A origem do nome deste equipamento deriva do inglês *Radio Detection and Ranging* (RADAR) e suas principais funções são a detecção e a localização de objetos. Seu funcionamento envolve a emissão de ondas eletromagnéticas que refletem quando encontram uma superfície eletricamente condutora. Se essas ondas refletidas retornam ao seu ponto de origem, isso indica a presença de um obstáculo na direção da propagação (WOLFF, 2023).

Uma das principais vantagens deste equipamento é a capacidade de operar em condições nas quais a visão humana seria limitada, tais como escuridão, neblina, nevoeiro, chuva e neve. Além disso, o radar é capaz de medir a distância até um objeto, sua velocidade relativa calculada por meio do efeito *Doppler* e outras informações como a posição angular do objeto ao longo do tempo.

O sistema básico de radar consiste em um transmissor, responsável por determinar a forma de onda do sinal a ser transmitido; uma antena de transmissão, que emite radiação eletromagnética; uma antena de recepção, que capta o sinal refletido pelo objeto alvo; e um dispositivo ou um receptor para detectar e processar essa energia eletromagnética retornada (FIGUEIREDO; SILVA; NEVES, 2019, p. 2-3). A distância até o objeto é determinada pela medição do tempo que o sinal do radar leva para viajar até o objeto e retornar. A direção do objeto pode ser determinada pela direção de chegada da onda refletida, geralmente com o uso de feixes de antena estreitos (SKOLNIK, 1981, p. 1, tradução nossa).

A classificação dos radares é recorrentemente dada pela forma de onda utilizada ou pela faixa de frequências de operação. Baseados na forma de onda, os radares podem ser Radares de Onda Contínua (CWR, do inglês, *Continuous Wave Radars*) ou Radares Pulsados

(PR, do inglês, *Pulsed Radars*) (FIGUEIREDO; SILVA; NEVES, 2019, p. 2-3). Em relação às faixas de frequências de operação – ou bandas, cuja representação é dada por meio do uso padrão de letras – Skolnik (1981, p. 8) categoriza os radares conforme ilustrado na Tabela 1:

Tabela 1 – Nomenclatura padrão das faixas de frequência de operação dos radares

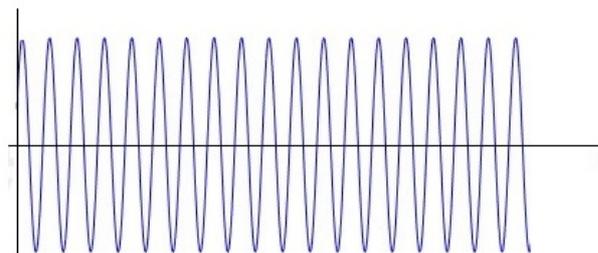
Banda	Faixa de Frequências (GHz)
HF	0,003 – 0,03
VHF	0,03 – 0,3
UHF	0,3 – 1
L	1 – 2
S	2 – 4
C	4 – 8
X	8 – 12
Ku	12 – 18
K	18 – 27
Ka	27 – 40
mm	40 – 300

Fonte: Elaborado pelo autor (2023).

### 2.2.1 Radares de Onda Contínua (CWR)

Os CWR emitem ondas eletromagnéticas de forma contínua como a da Figura 2. Esses radares, geralmente, usam antenas separadas para transmissão e recepção, isto é, são biestáticos (FIGUEIREDO; SILVA; NEVES, 2019, p. 3). Eles medem com precisão a velocidade relativa e a posição angular do alvo usando o Efeito Doppler, mas não são capazes de medir a distância do alvo. Alguns CWR são mais simples e utilizam formas de onda senoidal com amplitude, frequência e fase constantes. Outros, mais complexos, usam modulações em frequência ou fase.

Figura 2 – Forma de onda de um CWR



Fonte: FIGUEIREDO; SILVA; NEVES (2019, p. 3).

Não obstante, vale ressaltar que este trabalho foca, essencialmente, na análise de

resultados considerando sinais radares pulsados, que estão detalhados na Seção 2.2.2 a seguir. O intuito de apresentar os radares CWR é de proporcionar uma base comparativa para ressaltar as especificidades e as características distintas dos radares pulsados em relação aos primeiros.

## 2.2.2 Radares Pulsados (PR)

Os PR emitem energia eletromagnética na forma de pulsos estreitos e retangulares, normalmente utilizando uma única antena tanto para a transmissão quanto para a recepção dos sinais, o que os torna sistemas monoestáticos. Os parâmetros fundamentais da forma de onda de um PR podem ser categorizados como parâmetros intrapulso e interpulso, como demonstrado na Tabela 2.

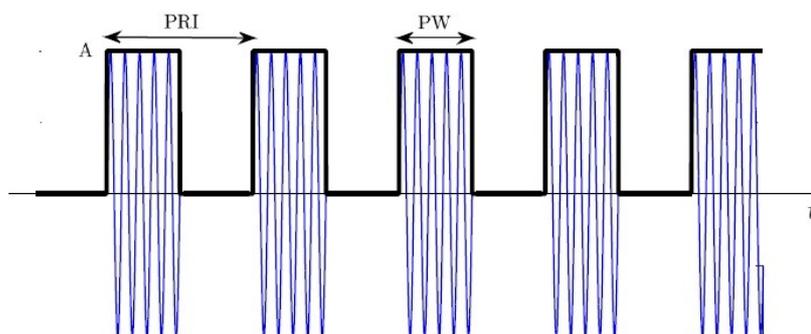
Tabela 2 – Parâmetros intrapulso e interpulso de um Radar Pulsado

Parâmetros Intrapulso	Parâmetros Interpulso
<ul style="list-style-type: none"> <li>• Frequência da Portadora (<math>f_c</math>, do inglês, <i>Carrier Frequency</i>);</li> <li>• Largura de Pulso (PW, do inglês, <i>Pulse Width</i>);</li> <li>• Amplitude do Pulso (A); e</li> <li>• Modulação Intrapulso.</li> </ul>	<ul style="list-style-type: none"> <li>• Frequência de Repetição de Pulsos (PRF, do inglês, <i>Pulse Repetition Frequency</i>);</li> <li>• Tipo de Varredura; e</li> <li>• Taxa de Varredura (SR, do inglês, <i>Scan Rate</i>).</li> </ul>

Fonte: Elaborado pelo autor (2023).

A Figura 3 ilustra um exemplo comum da forma de onda de um PR. A diferença entre o Intervalo de Repetição de Pulsos (PRI, do inglês *Pulse Repetition Interval*) e a Largura de Pulso (PW) representados nessa figura é chamada de período de silêncio e significa o intervalo de tempo em que o radar recebe os ecos refletidos pelos alvos. Outrossim, matematicamente falando, o PRI é definido como o inverso da PRF (SKOLNIK, 1981, p. 30, tradução nossa). Somado a isso, ressalta-se que os pulsos estreitos e retangulares englobam uma onda senoidal denominada portadora.

Figura 3 – Forma de onda de um PR



Fonte: FIGUEIREDO; SILVA; NEVES (2019, p. 4).

## 2.3 Inteligência Artificial

A inteligência é uma capacidade inerentemente humana, que nos diferencia dos demais animais. Na Ciência da Computação, o termo “Inteligência Artificial” surgiu em meados da década de 50 como uma proposta de estudo para o desenvolvimento de máquinas capazes de utilizar a linguagem e executar algumas tarefas como seres humanos (AGGARWAL, 2011, tradução nossa).

Fundamentalmente, a IA é a união entre *Big Data*, Processamento Paralelo e Modelos de Aprendizagem de Máquina. O termo “*Big Data*” pode ser entendido como um grande conjunto de dados diferentes e não ordenados que estão em rápido crescimento, sendo produzidos diariamente (MAYER-SCHÖNBERGER, V; CUKIER, K, 2013, p. 6, tradução nossa). Os dados podem ser analisados e transformados simultaneamente por unidades de processamento paralelo para a descoberta de informações e padrões presentes. O conceito de Processamento Paralelo é explicado mais adiante na Seção que versa sobre os neurônios matemáticos e biológicos. Já o termo “*Machine Learning*” (ou Aprendizado de Máquina) foi inicialmente cunhado por Arthur Lee Samuel (1959, p. 535). Essa expressão pode ser entendida como a “habilidade das máquinas em aprender sem serem explicitamente programadas” (AWARI, 2023), ou seja, um conjunto de métodos computacionais que tem por objetivo permitir que máquinas aprendam e desenvolvam modelos matemáticos a partir de um grupo de dados para resolver um problema específico, como a classificação e a regressão.

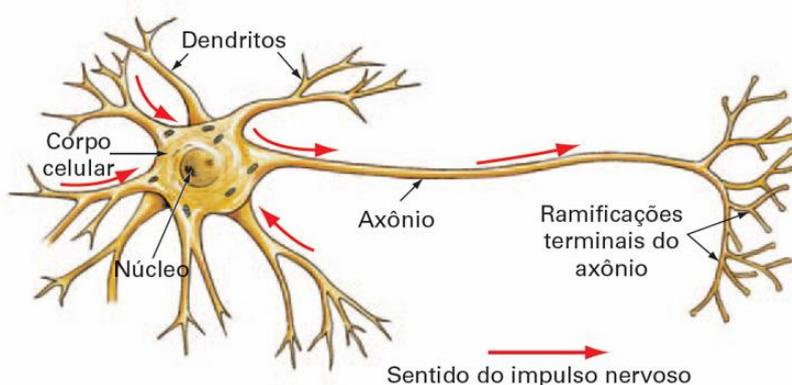
Além disso, dentro desse contexto e segundo Data Science Academy (2022, p. 3), o *Deep Learning* (ou Aprendizagem Profunda), constitui uma subárea do Aprendizado de Máquina na qual as estruturas dos modelos computacionais são mais complexas, sendo compostas por muitas unidades de processamento lineares e não lineares (no caso de redes neurais, composta por muitas camadas) e que necessitam de muitos dados de treinamento para conseguir replicar o processamento realizado pelo cérebro humano.

### 2.3.1 O neurônio biológico

O neurônio biológico – caracterizada como a unidade fundamental do cérebro humano – é uma célula especializada na transmissão de informações, incorporando particularidades de excitabilidade e condução de mensagens. Estruturalmente, segundo Data Science Academy (2022, p. 4), um neurônio é composto por três componentes principais que podem ser observados na Figura 4: o corpo celular ou soma; os dendritos, que são ramificações

do corpo celular; e o axônio, uma ramificação descendente mais extensa a partir da soma. Nas extremidades dos axônios, encontram-se as terminações nervosas, que permitem a transmissão das informações (ou impulsos nervosos) para outros neurônios por meio de um processo conhecido como sinapse.

Figura 4 – Estrutura de um neurônio biológico



Fonte: DATA SCIENCE ACADEMY (2022, p. 4).

Acerca do cérebro biológico, ressalta-se um estágio de desenvolvimento especificamente intenso nos primeiros dois anos de vida de um indivíduo, conforme explicado por Data Science Academy (2022, p. 4). Esse período é caracterizado por um rápido crescimento e formação de conexões neurais, onde a capacidade de aprendizado e adaptação do cérebro é impressionante. No entanto, esse processo de desenvolvimento cerebral não se encerra nesse estágio inicial, mas continua durante toda a vida do ser humano.

Com apoio nas ideias desse mesmo autor, esse fenômeno biológico supracitado serviu de inspiração para que muitos pesquisadores buscassem replicar o funcionamento cerebral no contexto da Inteligência Artificial. Em particular, eles se concentraram em criar sistemas inteligentes que pudessem executar uma variedade de funções, assim como o cérebro humano faz. Isso inclui tarefas como classificação de informações, reconhecimento de padrões em dados, processamento de imagens e muitas outras atividades que exigem aprendizado e adaptação contínuos.

### 2.3.2 O neurônio matemático

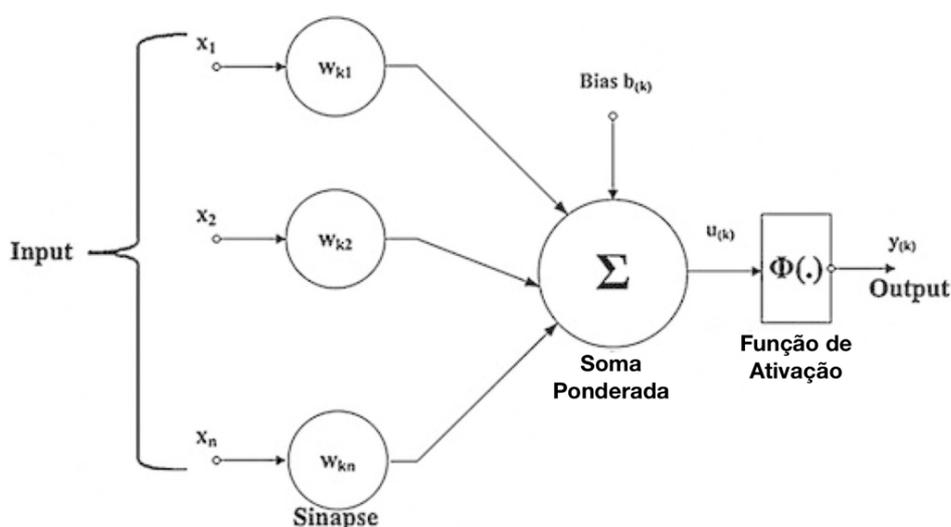
No âmbito da Inteligência Artificial, os neurônios matemáticos, também conhecidos como neurônios artificiais, tem suas raízes baseadas nos neurônios biológicos e a interconexão entre eles é inspirada na estrutura cerebral humana. O conjunto desses neurônios artificiais recebe o nome de Rede Neural Artificial.

Além disso, emular o processo de aprendizagem por experiência, que é uma das características mais notáveis do cérebro humano, envolve a capacidade de aprender com a interação com o ambiente, adaptando-se a novas situações e adquirindo conhecimento com experiências passadas. Com base nisso, em 1943, Warren McCulloch e Walter Pitts apresentaram o primeiro modelo “computacional” de um neurônio, buscando replicar esse processo por meio de simulações computacionais que simplificaram o funcionamento de um neurônio biológico (MCCULLOCH; PITTS, 1943, tradução nossa).

Nesse modelo, o neurônio matemático é visto como um componente que calcula a soma ponderada de diversos *inputs* (ou sinais de entrada), aplica-os a uma função e transmite o resultado adiante. Esses sinais de entrada são como os impulsos nervosos (informações a serem transmitidas) e são os dados que alimentam a Rede Neural Artificial. Eles estão representados pela variável  $x$  na Figura 5.

Entre os vários estímulos recebidos, alguns excitam o neurônio receptor mais intensamente do que outros. Essa medida de excitação é representada pelos pesos sinápticos. Os pesos sinápticos são representados como  $w_{kn}$  neste diagrama, onde  $k$  representa o índice do neurônio em questão e  $n$  refere-se ao terminal de entrada da sinapse ao qual o peso sináptico está associado.

Figura 5 – Representação simplificada de um neurônio matemático



Fonte: DATA SCIENCE ACADEMY (2022, p. 4, tradução nossa).

O corpo celular é composto por dois módulos nessa representação: o primeiro realiza uma soma aditiva, que é o somatório dos estímulos (sinais de entrada) multiplicados pelos seus respectivos fatores excitatórios (pesos sinápticos). Em seguida, aplica-se uma função

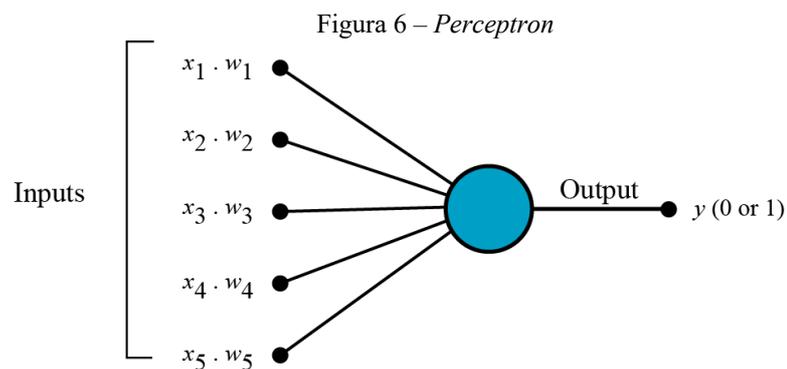
de ativação que determinará o *output* (ou sinal de saída)  $y_{(k)}$  do neurônio com base nas entradas e pesos sinápticos. Esse sinal de saída é a representação do axônio biológico. Além disso, assim como no cérebro humano, o estímulo pode ser excitatório ou inibitório, representado pelos pesos sinápticos positivos ou negativos, respectivamente.

Adicionalmente, o neurônio matemático pode também incluir um viés de entrada, conhecido como polarização ou bias (representado como  $b_{(k)}$ ). Essa polarização permite que um neurônio gere uma saída não nula mesmo quando todas as suas entradas são iguais a zero.

Em uma última análise, a ativação, ou não, do neurônio é determinada pela aplicação da função de ativação, que decide com base no valor da soma ponderada das entradas e o seu limiar de excitação, chamado de *threshold*. O neurônio dispara quando a soma ponderada dos valores  $x_i$  e  $w_i$  ultrapassa o *threshold*.

### 2.3.3 Perceptron e Multilayer Perceptrons (MLP)

O *Perceptron* é a arquitetura mais simples de uma Rede Neural Artificial e foi desenvolvido nas décadas de 1950 e 1960 pelo cientista Frank Rosenblatt, de acordo com o Data Science Academy (2022, p. 6). Um *Perceptron*, diante de várias entradas recebidas, produz uma única saída binária ou *output*, conforme a Figura 6.



Fonte: DATA SCIENCE ACADEMY (2022, p.6).

Nesse cenário, introduzindo pesos às entradas para expressar a relevância de cada *input*, Rosenblatt propôs uma forma de cálculo simples para valorar a saída (Equação 1):

$$output = \begin{cases} 0 & \text{se } \sum_{i=1}^n w_i \cdot x_i \leq threshold \\ 1 & \text{se } \sum_{i=1}^n w_i \cdot x_i > threshold \end{cases} \quad (1)$$

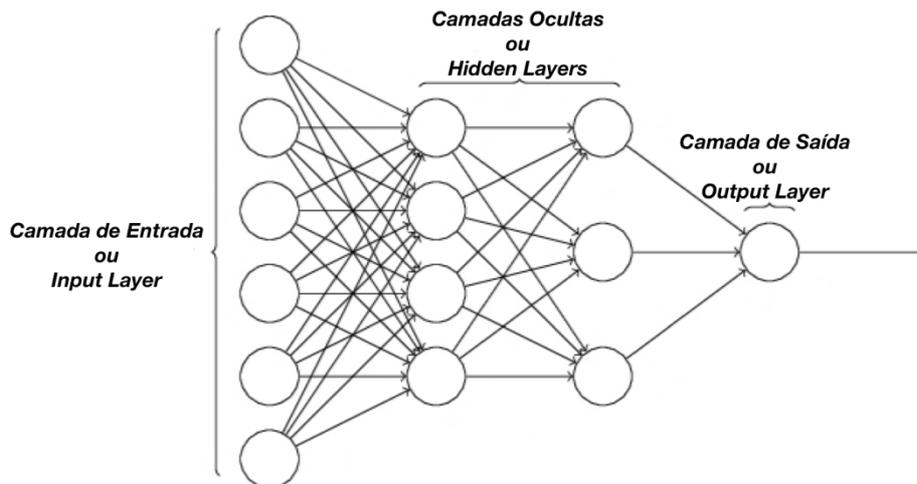
Entretanto, uma maneira mais simplificada e comumente utilizada de escrever a regra Perceptron proposta por Rosenblatt é apresentada a seguir (Equação 2):

Sendo  $b = -threshold$ , então:

$$output = \begin{cases} 0 & \text{se } \sum_{i=1}^n w_i \cdot x_i + b \leq 0 \\ 1 & \text{se } \sum_{i=1}^n w_i \cdot x_i + b > 0 \end{cases} \quad (2)$$

Por conta de sua simplicidade e por ser um neurônio simples, ou seja, uma rede de camada única, o *Perceptron* não consiste em um modelo decisório completo como a mente humana. O *Perceptron* é apenas um classificador linear, ou seja, limitado a tarefas em que a decisão de classificação pode ser dividida por uma única linha reta (ou hiperplano). Entretanto, ao serem adicionadas diversas camadas de Perceptrons em uma rede neural complexa, como na Figura 7, isso leva a crer numa capacidade artificial de tomar decisões mais sofisticadas, como classificações não lineares. Esse conjunto de perceptrons em diferentes camadas é o que se denomina *Perceptrons Multicamadas* ou *Multilayer Perceptrons (MLP)*.

Figura 7 – *Multilayer Perceptron (MLP)*



Fonte: DATA SCIENCE ACADEMY (2022, tradução nossa, p. 9).

A rede MLP se desenvolveu com o passar dos anos até chegar ao que é hoje, uma rede artificial de múltiplas camadas de neurônios artificiais em que os neurônios de cada camada já não são mais exatamente iguais ao Perceptron inicialmente proposto por Frank Rosenblatt (Figura 8), podendo possuir funções de ativação lineares e não lineares.

Antes de uma rede neural MLP ou outras arquiteturas de Aprendizado de Máquina serem efetivamente empregadas na fase de testes, elas passam por um processo de treinamento para “aprender” com os dados que lhe são apresentados (sinais de entrada e seus respectivos sinais de saída esperados). Nesse processo, o modelo ajusta os pesos das conexões entre os neurônios e o bias. Após o treinamento, o modelo estará apto a receber novos dados de entrada e fazer previsões, podendo funcionar como um classificador não linear ou ser aplicado a outros tipos de problemas, como a regressão linear.

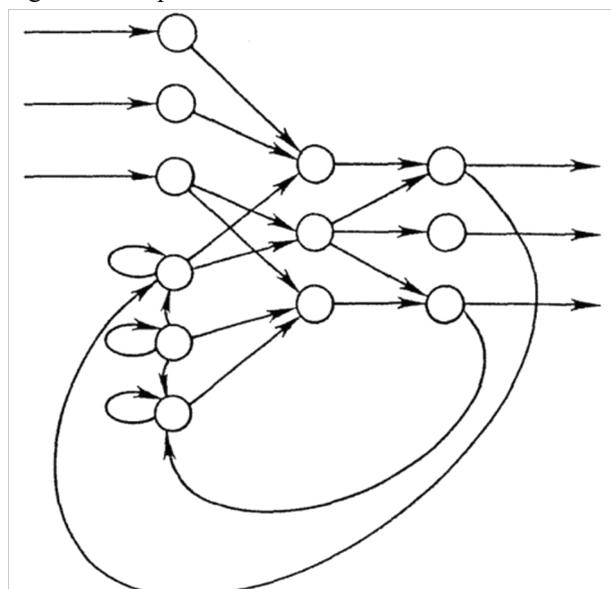
## 2.4 Redes Neurais de Elman

Iniciando o assunto das Redes Neurais de Elman, deve-se compreender primariamente as conexões recorrentes criadas por Michael I. Jordan em 1986:

Uma distinção importante pode ser feita entre redes com base em sua conectividade geral. Se uma rede possui um ou mais ciclos, ou seja, se é possível seguir um caminho de uma unidade de volta para si mesma, então a rede é chamada de recorrente. Uma rede não recorrente não possui ciclos. (JORDAN, 1986, p. 11, tradução nossa)

Sob essa perspectiva, pode-se entender que a conexão recorrente consiste em um caminho possível que um sinal de saída de um elemento pode fazer, retornando como entrada do mesmo elemento, sendo modificado ou não durante o trajeto, conforme pode ser observado na Figura 8. Isso significa que a saída da rede depende não apenas do sinal recebido pela Camada de Entrada, mas também do estado da rede no passo de tempo anterior, isto é, “são sistemas dinâmicos com propriedades sensitivas a sequências temporais” (ANDRADE; DA SILVA, 2011, p. 2).

Figura 8 – Esquema básico de conexão de rede recorrente

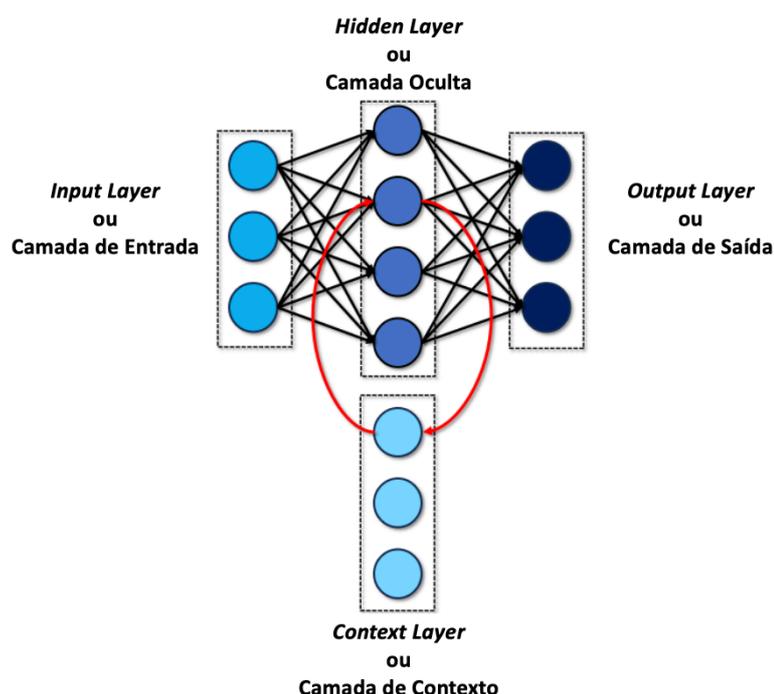


Fonte: JORDAN (1986, p. 11).

Nesse sentido, Elman (1990, p. 5, tradução nossa) explica que as conexões recorrentes moldam o comportamento das unidades subsequentes graças às respostas anteriores, o que representa algo parecido com uma memória para a Rede Neural Artificial.

Seguindo essa linha de raciocínio, Elman propõe a ampliação de conexões recorrentes à rede neural artificial através de unidades adicionais, denominadas Unidades de Contexto, conforme a Figura 9. Essas unidades também são "ocultas" no sentido de que interagem exclusivamente com os neurônios das camadas internas da rede (ELMAN, 1990, p. 4-6, tradução nossa).

Figura 9 – Redes Neurais de Elman



Fonte: Elaborado pelo autor (2023).

Apoiando-se na ilustração acima, é possível detalhar o passo a passo do funcionamento de uma Rede Neural de Elman:

- a) **Camadas de Entrada e de Contexto:** cada unidade pode representar um único valor ou um vetor, dependendo da complexidade do problema. Tanto as unidades de entrada quanto as unidades de contexto ativam as unidades ocultas. As unidades de entrada representam os dados de entrada em um determinado momento, enquanto as unidades de contexto representam o estado anterior da rede, que foi armazenado para uso futuro.
- b) **Camada Oculta:** as unidades ocultas recebem as ativações das unidades de entrada e das unidades de contexto. Elas aplicam uma função de ativação para determinar a sua saída, que depende das entradas e do contexto atualizado. Outrossim, além de alimentar as

unidades de saída, as unidades ocultas também retroalimentam as unidades de contexto. Isso significa que informações do estado atual das unidades ocultas são armazenadas nas unidades de contexto, permitindo que a rede mantenha uma espécie de "memória" de estados anteriores.

- c) Camada de Saída: as ativações das unidades ocultas são então utilizadas para calcular as ativações das unidades de saída. Assim como nas unidades ocultas, isso envolve a aplicação de uma função de ativação. As unidades de saída representam a saída prevista pela rede neural para um dado conjunto de entradas e contexto. No presente trabalho, representam as classes dos sinais radar, que são os tipos de modulação dos sinais.
- d) Fase de Aprendizado (não obrigatório): durante o treinamento da rede, que é a fase de aprendizado, a saída prevista pela rede é comparada com uma saída de referência (uma espécie de resposta correta, no caso deste trabalho, a classe correta). Se houver discrepâncias entre a saída prevista e a de referência, um algoritmo de aprendizado, como o *backpropagation* (ou retropropagação do erro), pode ser usado para ajustar gradualmente os pesos das conexões. Ressalta-se que as conexões recorrentes que vão das unidades ocultas para as unidades de contexto não possuem pesos.
- e) Próximo Passo de Tempo: no próximo passo de tempo, a sequência de passos descritos acima é repetida. As unidades de contexto agora contêm informações do estado anterior da rede, as unidades de entrada representam novos dados de entrada, e o processo continua.

## 2.5 Redes Neurais Convolucionais (CNN)

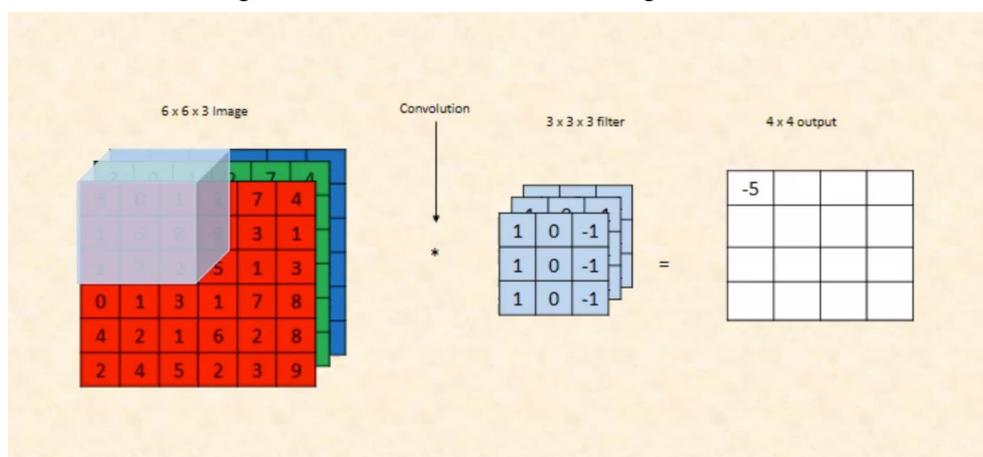
Em 1998, o pesquisador francês Yann LeCun e seus colaboradores elaboraram um classificador com o propósito inicial de reconhecer dígitos manuscritos (LECUN; BOTTOU; BENGIO; HAFFNER, 1998). Esse classificador, mais tarde, receberia o nome de Redes Neurais Convolucionais (CNN).

Esse modelo de Rede Neural de *Deep Learning* incorporou o algoritmo de *backpropagation* às tradicionais Redes *Feedforward* – redes em que as informações se propagam numa única direção (da entrada para a saída), como as MLPs – além de outras estruturas voltadas especificamente para receber imagens como entrada (EBERMAM; KROHLING, 2018, p. 49).

Conforme as palavras de Data Science Academy (2022, p. 9): “As Redes Neurais Convolucionais (ConvNets ou CNNs) são redes neurais artificiais profundas que podem ser usadas para classificar imagens, agrupá-las por similaridade (busca de fotos) e realizar reconhecimento de objetos dentro de cenas”. Em resumo, esta Rede Neural busca se assemelhar à percepção da visão humana com a finalidade de classificar imagens.

Nesse sentido, as CNN podem interpretar imagens como volumes tridimensionais, devido à codificação de cores RGB (Vermelho, Verde e Azul, do inglês, *Red, Green and Blue*) das imagens digitais ou como planos, no caso de imagens em tons de cinza (KONG; KIM, M.; HOANG; KIM, E., 2018, tradução nossa). A codificação de cores RGB combina as três cores para criar o espectro colorido enxergado pelos seres humanos. Nesse caso, uma CNN recebe uma imagem como um paralelepípedo reto, com largura e altura determinadas pelo número de *pixels* em cada dimensão e uma profundidade de três camadas, uma para cada cor, conforme a Figura 10.

Figura 10 – Os canais RGB de uma imagem colorida.



Fonte: RIZWAN (2018).

Cada entrada e saída de um passo de processamento da CNN é expressa matematicamente como uma matriz multidimensional, também conhecida como tensor.

O processo de extração de padrões – também chamados de *features* – se dá por meio de filtros convolucionais. Esses filtros são matrizes que percorrem os dados realizando a operação de convolução. Essa operação matemática é explicada mais detalhadamente na Seção 2.5.2.

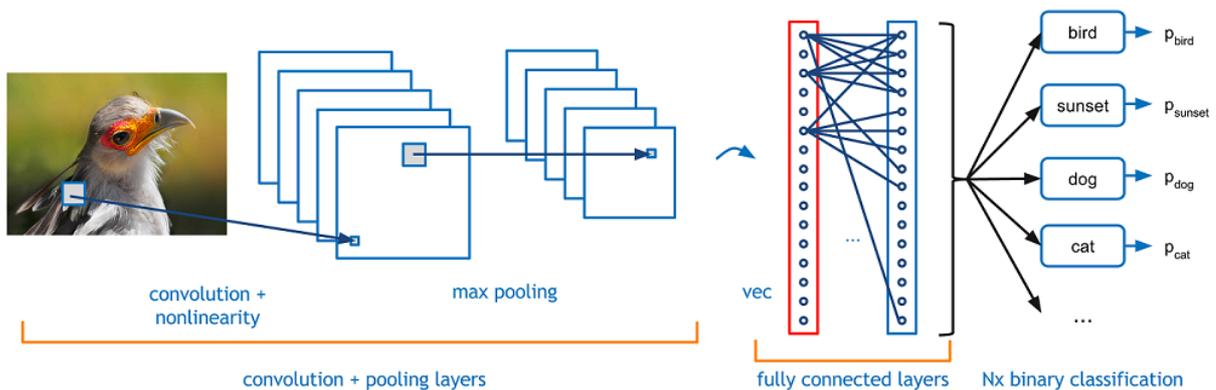
Adicionalmente, ressalta-se que em algumas aplicações é necessário obter uma grande quantidade de dados para o treinamento e extração das *features* (RODRIGUES, 2018, p. 23). No período de treinamento da rede, apenas os pesos da parte final da CNN, a rede MLP

completamente conectada, são ajustados. Os filtros da parte inicial da CNN são projetados para identificar padrões específicos de uma imagem, como bordas, valores máximos e mínimos, retas ou algumas curvas em particular, entre outras características.

### 2.5.1 Estrutura básica de uma CNN

Essencialmente, uma CNN consiste em várias camadas ou blocos de processamento, incluindo camadas de convolução, camadas de *max pooling* e camadas totalmente conectadas, que são as funções de ativação da rede (DA CUNHA, 2020, p. 18). À medida que a imagem de entrada, representada por matrizes, é passada através dos blocos, a quantidade e o tamanho das matrizes de entrada podem mudar devido às operações realizadas em cada bloco. Na Figura 11, podemos ver um exemplo de uma estrutura CNN montada para a classificação da imagem de um pássaro.

Figura 11 – Classificação da imagem de um pássaro por uma CNN



Fonte: DESHPANDE (2016).

A rede CNN apresentada na Figura 11 recebe, como entrada, três matrizes contendo os valores RGB dos pixels da imagem do um pássaro. A camada de saída da CNN é composta por um conjunto de neurônios, cada um referente a uma classe de saída. Nesse caso, cada neurônio representa um animal diferente e gera um valor da probabilidade da imagem de entrada pertencer à classe associada a ele. As probabilidades são calculadas com base nas características extraídas da imagem ao longo das camadas anteriores, que recebem o nome de camadas de codificação. A imagem de entrada é classificada como pertencente à classe associada ao neurônio que gerou o maior valor de probabilidade. No exemplo, para não ocorrer um erro de classificação, o valor gerado pelo neurônio associado à classe Pássaros ( $p_{bird}$ ) deve ser o maior.

Nos subtópicos seguintes, detalha-se o processamento realizado nos blocos de uma

CNN.

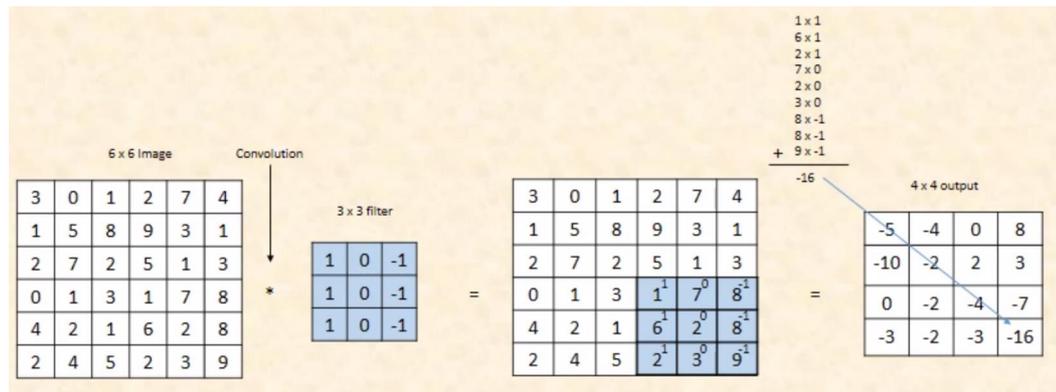
### 2.5.2 Convolução

A convolução (do inglês, *convolution*), denotada por  $f * g$ , é uma operação matemática usada em processamento de sinais e imagens que combina duas funções para criar uma terceira função (DA CUNHA, 2020, p. 18). Conforme explicado por Rodrigues (2018, p. 22-23), a convolução é um operador linear, ou seja, realiza operações de adição e multiplicação nas funções de entrada. As funções de entrada,  $f$  e  $g$ , são chamadas de função alvo (ou sinal de entrada) e *kernel* (ou filtro convolucional), respectivamente.

Na CNN, o *kernel* é uma matriz pequena utilizada para extrair características de baixo nível das imagens de entrada. Essa matriz é aplicada a regiões específicas da imagem, multiplicando-se os valores da região pelo *kernel*. Em cada região, os resultados das multiplicações são somados para gerar um único valor. Esse processo de multiplicação e soma ocorre em diferentes regiões da imagem, criando uma matriz que representa um novo mapa de características que destaca padrões relevantes. Em outras palavras, o *kernel* é deslocado (ou movido) sobre a matriz de entrada uma ou mais posições de cada vez. Em cada posição, gera-se um valor de saída que é a soma das multiplicações realizadas entre os valores do *kernel* e os valores da matriz de entrada que sobrepõem o *kernel*. Esses produtos são somados para criar um valor.

Um exemplo de aplicação da função de ativação convolucional está descrita na Figura 12, onde a matriz de entrada 6x6 é reduzida para uma matriz 4x4 após a aplicar um *kernel* que se desloca com um *stride* (salto dado ao *kernel* sobre a matriz de entrada) de 1. Isto é, o *kernel* é deslocado de uma posição em relação ao eixo x ou y. Os produtos gerados a cada aplicação do *kernel*, segundo Da Cunha (2020, p. 19), recebem o nome de mapas de ativação ou de características (do inglês, *feature maps*).

Figura 12 – Convolução de uma imagem de entrada 6x6 e um filtro 3x3, stride 1



Fonte: RIZWAN (2018).

Além disso, deve-se ter em mente que, em alguns casos, o encolhimento da matriz original é indesejado. Para isso, no sentido de manter o tamanho da matriz resultante igual à matriz de entrada, pode ser adicionado um *padding* igual a 0, que adiciona, nas bordas da matriz de entrada, algumas colunas e linhas contendo zeros antes de realizar a convolução.

Ademais, ressalta-se que entre as camadas de convolução e *max pooling*, pode-se incluir uma função de ativação denominada *Rectified Linear Unity* (ReLU). Neste trabalho, essa função está presente na estrutura da CNN utilizada por um dos classificadores. A ReLU é uma função não linear, que repete o valor de entrada caso seja positivo ou gera a saída 0 caso a entrada seja negativa (Equação 3). O benefício de incluir a ReLU na estrutura é diminuir a quantidade de neurônios utilizados e aumentar a não linearidade da CNN, reduzindo a probabilidade de ocorrer o *overfitting*.

$$f(x) = \max(0, x) \quad (3)$$

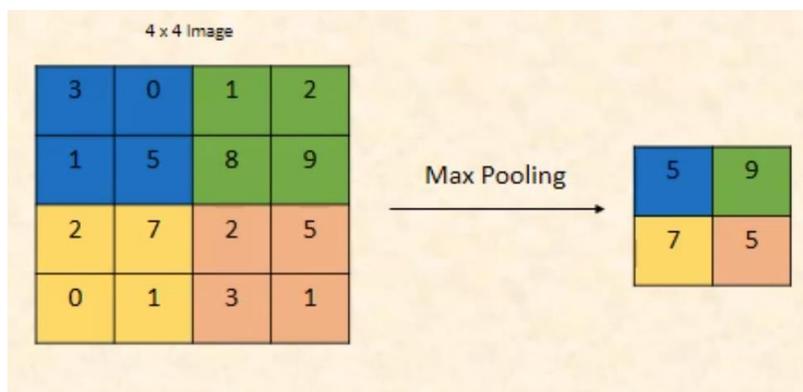
### 2.5.3 Max Pooling

O propósito por trás da camada de *pooling* é reduzir a quantidade de valores contidos nos mapas de características, diminuindo o tempo de processamento sem interferir muito na eficiência da CNN. Esse processo é denominado de *downsampling* (DA CUNHA, 2020, p. 27). Outra vantagem de sua utilização é fazer com que a rede continue classificando corretamente uma imagem de entrada mesmo que ela sofra uma pequena translação, rotação ou escalonamento (invariância espacial da rede).

O *Pooling* é a aplicação de um filtro, que pode ser, por exemplo, um filtro de máximo, de mínimo, de média, entre outros, sobre diferentes regiões da matriz de entrada

retornando um único valor para cada região. O *Max Pooling*, por exemplo, retorna o valor máximo de cada região (Figura 13).

Figura 13 – Max Pooling em uma matriz 4x4 com stride 2 gerando uma matriz 2x2



Fonte: RIZWAN (2018).

#### 2.5.4 Fully Connected Layer

A camada de neurônios completamente conectados (do inglês, *Fully Connected Layer*), é o bloco da arquitetura responsável por realizar a classificação final da imagem. Para isso, são utilizadas arquiteturas neurais tradicionais, como as MLPs. Essa camada final possui como entrada todos os atributos extraídos da imagem pelas camadas anteriores (convolução, ReLU e *Max Pooling*).

Outrossim, salienta-se que, o resultado produzido pelo último bloco de processamento responsável por extrair as características – último bloco antes da Fully Connected Layer – é uma matriz de características. Essa matriz é transformada em um vetor pelo processo conhecido como *flattening*. Esse procedimento consiste em colocar os valores de cada linha da matriz lado a lado, formando um vetor. O *flattening* deve ser feito pois a camada de entrada da *Fully Connected Layer* é composta por um conjunto de neurônios dispostos em linha e cada neurônio deve receber como entrada uma característica.

## 2.6 Support Vector Machine (SVM)

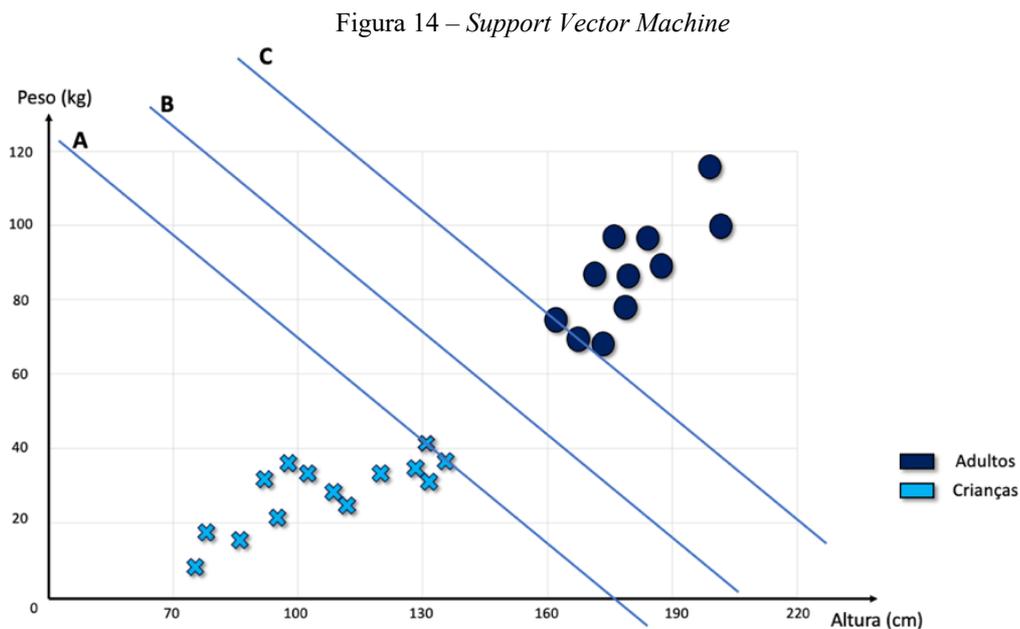
As Máquinas de Vetores Suporte são algoritmos de Aprendizado de Máquina Supervisionado que podem ser utilizados em problemas de classificação ou regressão (ADDAN, 2019). Segundo De Lima (2014, p. 17), as SVMs foram desenvolvidas por Vapnik e seus colaboradores em 1995 e uma de suas características mais marcantes é a capacidade de operar com vetores de atributos multidimensionais, como é o caso de um dos classificadores testado neste trabalho.

Além do mais, essa ferramenta de *Machine Learning* é baseada no princípio da Minimização do Risco Estrutural (SRM, do inglês, *Structural Risk Minimization*) e procura diminuir os erros durante as fases de treinamento e de teste (ANDREOLA; HAERTEL, 2009, p. 6758). Entretanto, é relevante mencionar que o objetivo da SVM é conseguir um equilíbrio entre os erros obtidos nas duas fases, pois quanto mais o hiperplano for ajustado durante o treino, maior será o risco estrutural. Sendo assim, uma harmonia entre os erros é fundamental para minimizar o excesso de ajustes (*overfitting*) e melhorar a capacidade de generalização.

Essencialmente e em sentido estrito, a SVM se resume em uma “fronteira que melhor segrega duas classes” (ADDAN, 2019). Essa fronteira pode ser representada por linhas (retas ou curvas) – em problemas mais simples, mas menos comuns – ou hiperplanos, em problemas mais complexos e usuais. Essas linhas ou hiperplanos dividem o espaço em áreas que contenham objetos com características em comum, o que permite sua separação em classes.

### 2.6.1 SVM Linearmente Separável

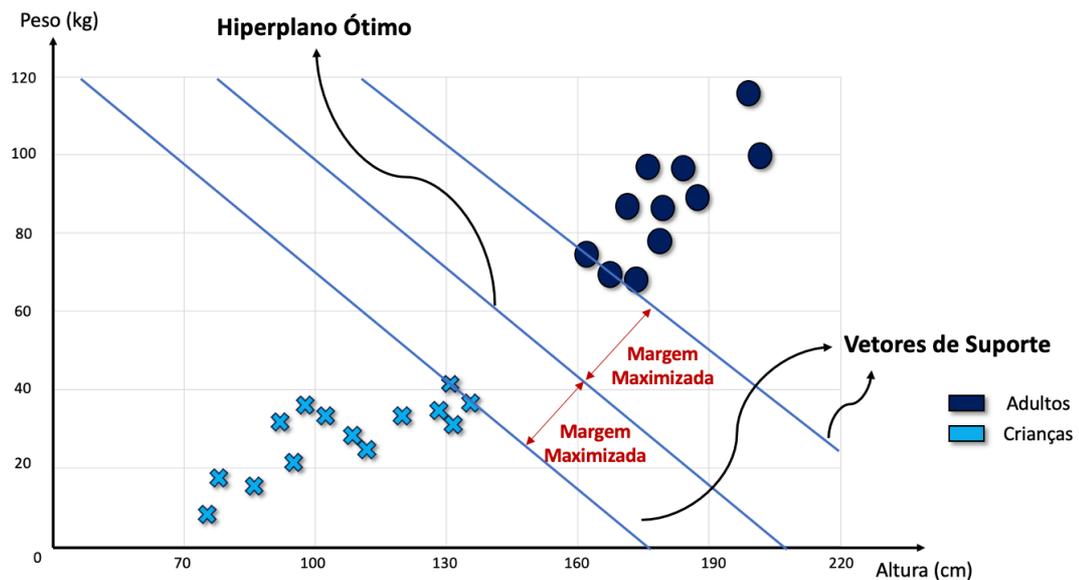
Supondo um exercício de classificação entre crianças e adultos e levando em consideração características como tamanho e peso, obtém-se uma representação gráfica como a da Figura 14. Nesse exemplo, a divisão entre crianças e adultos é feita por uma linha reta ou um hiperplano sem grandes dificuldades.



Por outro lado, a partir da observação da Figura 14, pode-se perceber que infinitas

possibilidades de hiperplanos poderiam dividir os objetos entre as duas classes diferentes, como as retas A, B e C. Nesse sentido, a fronteira que deve ser escolhida pelo SVM para ser responsável pela separação das classes é obtida maximizando a margem de separação entre os vetores de suporte (TAKAHASHI, 2012, p. 7). Em outras palavras, posiciona-se o hiperplano separador de forma a ser equidistante dos vetores suporte de cada classe. Esse hiperplano é nomeado hiperplano ótimo, conforme representado na Figura 15.

Figura 15 – Hiperplano ótimo



Fonte: Elaborado pelo autor (2023).

Além disso, a equação que separa as classes por meio de hiperplanos (TAKAHASHI, 2012, p. 6) é definida pela função linear representada na Equação 4 a seguir:

$$w^T \cdot x + b = 0 \quad (4)$$

Nesta equação, as variáveis  $w$ ,  $x$  e  $b$  foram vistas anteriormente nas Seções 2.3.2 e 2.3.3 e significam o vetor de pesos ajustáveis, os padrões de entrada do conjunto de treinamento e o bias, respectivamente.

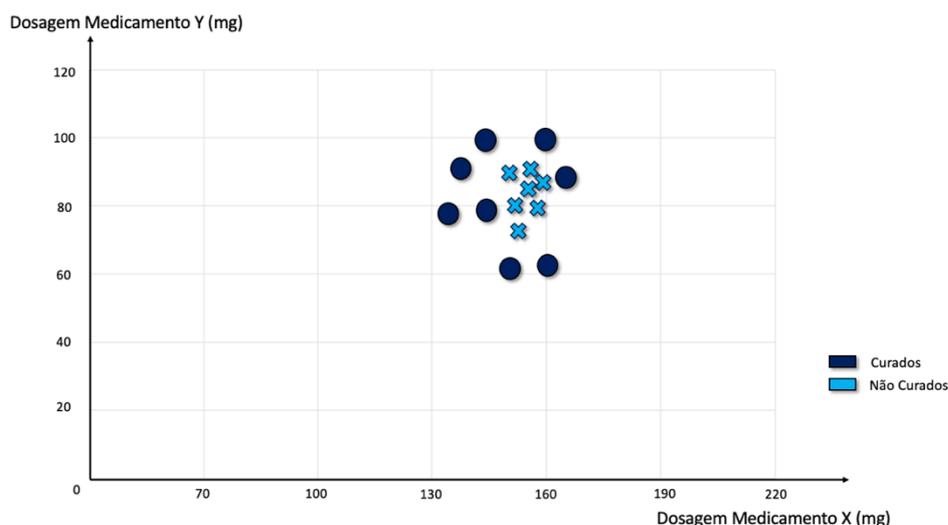
Não obstante, existem situações em que a separação completa das duas classes por meio de uma linha reta não é viável devido à presença de objetos com atributos discrepantes (outliers) ou devido ao fato dos objetos de uma classe ocasionalmente possuírem alguns atributos que estão nos intervalos de valores pertencentes à outra classe, sendo posicionados em regiões do espaço de características que não correspondem à sua classe. Contudo, o SVM possui um recurso para ignorar valores discrepantes (primeiro caso) e encontrar o melhor

hiperplano de separação possível. Sob essa perspectiva, pode-se afirmar que o SVM é robusto a outliers (ADDAN, 2019).

### 2.6.2 SVM não linearmente separável

Em alguns casos específicos, os dados analisados podem não ser linearmente separáveis no espaço original, como o gráfico presente na Figura 16.

Figura 16 – SVM não linearmente separável



Fonte: Elaborado pelo autor (2023).

De forma a exemplificar os dados ali dispostos, pode-se supor uma tentativa de classificação entre pessoas que se curaram e pessoas que não se curaram de uma doença utilizando dosagens específicas de dois medicamentos. Nesse cenário, há um problema de classificação que pode ser resolvido por um produto interno nomeado *kernel*<sup>1</sup>.

Caso fossem extraídas outras características dos supostos pacientes – como o peso de cada um deles – os objetos de análise poderiam passar a ser linearmente separáveis. Nesse exemplo simples, a função do *kernel* seria aumentar o espaço de características extraídas em uma dimensão, representado pelo peso. Contudo, o uso do *kernel* pode elevar a capacidade de separação entre as classes mesmo sem aumentar a dimensão do espaço de características.

O aspecto mais interessante do SVM é a “capacidade separar as instâncias quando as classes não são linearmente separáveis. Isto porque o algoritmo projeta o problema em um espaço de alta dimensão, tornando as classes linearmente separáveis” (RAJKUMAR;

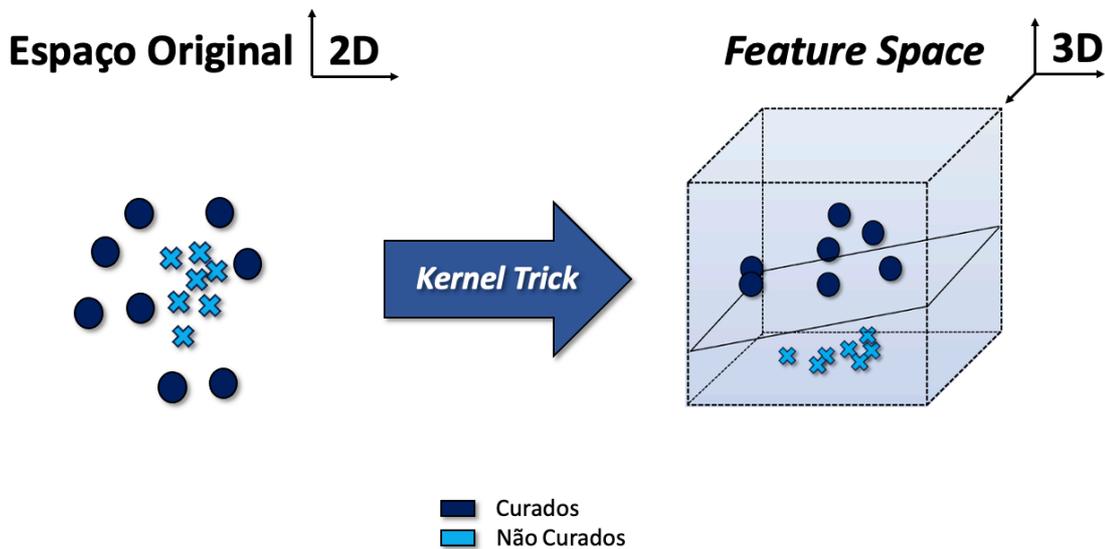
<sup>1</sup> Este *kernel* não se confunde com seu homônimo apresentado na Seção 2.5, sendo aquele um filtro convolucional.

JAGANATHAN, 2013, p. 554, tradução nossa).

### 2.6.3 Kernel

O truque de *kernel* (do inglês, *kernel trick*) é definido como um recurso matemático que possibilita ao SVM realizar uma classificação em outra dimensão espacial como na Figura 17.

Figura 17 – Kernel Trick



Fonte: Elaborado pelo autor (2023).

Essencialmente, a transformação, ou truque, que o *kernel* produz envolve a transição das características originais para um espaço linear de dimensão superior, chamado de espaço de características (ou *feature space*). Neste novo espaço, as características se tornam mais fáceis de serem classificadas por um hiperplano. Pode-se afirmar, portanto, que o *kernel* é utilizado para diminuir o nível de complexidade da separação.

Adicionalmente, conforme as palavras de Oliveira Junior (2010, p. 10), existem diversos tipos de funções de *kernel* que possam ser utilizadas, porém as mais populares são a Polinomial, a Gaussiana e a Sigmoidal. A função *kernel* Polinomial é representada matematicamente conforme a Equação 5, sendo  $c$  uma constante,  $x_i$  e  $y_i$  vetores de entrada,  $d$  o grau do polinômio e  $z$  o número de iterações:

$$K_{(x_i, y_i)} = \left( c + \sum_{i=1}^z x_i \cdot y_i \right)^d \quad (5)$$

## 2.7 Tipos de modulação

A modulação é uma técnica essencial para aplicações em radares e envolve a modificação de uma ou mais características de um sinal a ser transmitido, como sua frequência e/ou fase, de acordo com um padrão específico. Isso significa que o radar não apenas emite um sinal cossenoidal puro, mas modifica suas características de frequência e/ou fase para isso. O sinal cossenoidal anterior à modulação possui uma frequência principal denominada frequência da portadora, que, em aplicações de radares, costuma ser uma frequência alta. A modulação permite, ao radar, estimar informações importantes sobre o alvo com maior precisão, como distância, velocidade e direção.

De maneira complementar, um radar, que deseje estimar a informação de distância (*range*) com maior precisão, deve reduzir a PW no receptor. Uma das formas de fazer isso é realizando o que é chamado de compressão de pulso. Essa técnica permite melhorar a resolução em distância do sinal reduzindo a PW na recepção sem precisar reduzi-la na transmissão (DECASTRO, 2022, p. 57). De acordo com Neri (2018, p. 94, tradução nossa), existem várias maneiras de realizar a compressão de pulso por meio de radares que empregam modulação no pulso (MOP, do inglês, *Modulation on Pulse*), mas a maioria delas pode ser dividida em duas categorias: modulação em frequência (FMOP, do inglês *Frequency Modulation on Pulse*) e modulação em fase (PMOP, do inglês *Phase Modulation on Pulse*).

Além de melhorar a resolução de distância de um radar pulsado, existem outras vantagens de se utilizar modulação de fase ou de frequência (Neri, 2018):

- a) Aumento da relação SNR: o radar diminui a influência do ruído, dessa forma um radar de navegação, por exemplo, apresentaria menos borrões provocados por clutter no display do operador.
- b) Possibilidade de diminuir a potência do sinal transmitido: o transmissor de um radar de navegação pode utilizar menos potência na transmissão, simplificando o seu projeto. Um Radar de Baixa Probabilidade de Interceptação (LPI, do inglês *Low Probability of Intercept*) pode reduzir muito a potência de transmissão utilizando um sinal CW ou *interrupt CW* modulado em frequência.
- c) Espalhamento da energia do sinal no espectro, no caso do sinal LFM: um MAGE que detecte um sinal por nível de magnitude no domínio da frequência teria maior dificuldade de detectá-lo.

- d) Dificultar a detecção do sinal radar com o uso da modulação intrapulso de fase pseudo-aleatória. Um radar LPI pode variar de forma pseudo-aleatória a fase, dificultando a sua separação em relação ao ruído.

Conforme explicado por Ghadimi (2020, p. 1181, tradução nossa), o sinal gerado por um radar pode ser definido pela Equação 6.

$$s(t) = R \{A \exp(j2\pi f_c t + \phi_k)\} \quad (6)$$

Nessa expressão,  $R$  representa a parte real do número complexo;  $A$ , a amplitude do sinal;  $f_c$ , a frequência da portadora; e  $\phi_k$ , a fase do sinal; e  $k$  o índice da amostra.

A técnica PMOP consiste em mudar a fase  $\phi_k$  do sinal transmitido. A fase é modificada de acordo com uma regra que define o momento (tempo) em que isso ocorre. Esses momentos podem ser interpretados como um código (um vetor) composto por  $n$  elementos. Depois da detecção do eco do sinal transmitido, o radar realiza uma filtragem através de um filtro casado FIR (do inglês, *Finite Impulse Response*) cujos coeficientes estão relacionados ao código. A resposta do filtro é equivalente a um novo sinal com menor PW e maior potência de pico, mantendo o ruído no mesmo patamar de potência (a SNR da saída do filtro é igual a  $n$  vezes a SNR da entrada). As modulações de fase Barker, Frank, P1, P2, P3, P4, T1, T2, T3 e T4 são objeto de estudo deste trabalho. Segundo Chilukuri, Kakarla e Subbarao (2020, p. 2, tradução nossa), essas são algumas das técnicas de modulação de fase mais utilizadas por radares.

Na técnica FMOP, a frequência do sinal transmitido muda de acordo com uma regra, podendo ser uma variação linear ou não linear (ROHDE SCHWARZ, 2020). A modulação do tipo LFM é objeto de estudo deste trabalho. Segundo Chilukuri, Kakarla e Subbarao (2020, p. 2, tradução nossa), a LFM é uma das técnicas de modulação de frequência mais utilizadas por radares.

### 2.7.1 *Linear Frequency Modulation* (LFM)

A LFM é um tipo de modulação linear em frequência. Isso simboliza que a frequência do sinal transmitido varia linearmente ao longo do tempo (SPOORTHI; RAMESH, 2017, p. 1-3). Isso implica que a sua representação em um gráfico *tempo x frequência* pode ser feita por meio de retas. Além disso, essa variação da frequência pode ser crescente ou decrescente.

Sobre a modulação em frequência, ela pode ocorrer dentro de um sinal contínuo – Modulação em Frequência de Onda Contínua (FMCW, do inglês *Frequency Modulation Continuous Wave*) – ou dentro de um pulso (FMOP). Quando a modulação em frequência dentro de um pulso é linear, diz-se que o sinal possui uma modulação LFM. Sinais LFM também são conhecidos na literatura como sinais *chirp*. Esses sinais são objeto de estudo deste trabalho.

Essencialmente, quanto mais larga é a PW de um pulso, maior é a energia do sinal transmitido, melhorando a capacidade do radar detectar o eco do sinal transmitido, porém pior fica a sua resolução de distância (MATLAB, 2023). Nesse sentido, a LFM é vista como uma técnica importante de compressão de pulsos de radar, uma vez que o radar alcança uma melhor resolução em distância sem precisar aumentar a energia do sinal transmitido para manter a capacidade de detectar o seu eco. A Equação 7 expressa a fase do sinal *chirp* em um instante de tempo. Nela,  $f_c$  é a frequência da portadora;  $k_r = \frac{B}{PW}$  é a razão entre a largura de banda e a largura do pulso; e  $t$  é o tempo.

$$\phi(t) = 2\pi \left( f_c t + \frac{k_r t^2}{2} \right) \quad (7)$$

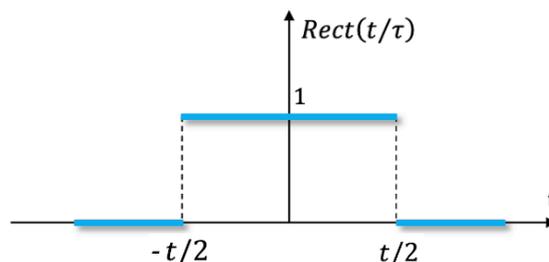
Um sinal LFM pode ser expresso de acordo com a equação 8:

$$S(t) = \text{Rect}(t/\tau) \exp \left( j2\pi \left( f_c t + \frac{\mu t^2}{2} \right) \right) \quad (8)$$

Nessa equação,  $\text{Rect}(t/\tau)$  descreve uma função retangular que tem uma PW igual a  $\tau$ . Ou seja, é uma função que retorna 1 dentro do intervalo de tempo de duração  $\tau$  e 0 fora do intervalo (Figura 18).

Figura 18 – Função  $\text{Rect}(t/\tau)$

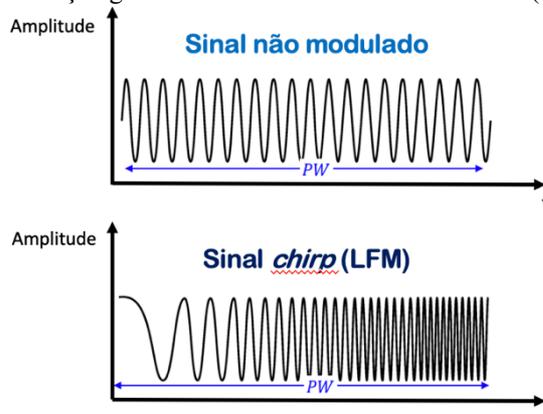
$$\text{Rect}(t/\tau) = \begin{cases} 1 & \text{se } |t| < \tau \\ 0 & \text{se } |t| \geq \tau \end{cases}$$



Fonte: Elaborado pelo autor (2023).

Adicionalmente, de forma a melhorar a compreensão do assunto, a Figura 19 ilustra as diferenças entre sinais não modulados e sinais LFM.

Figura 19 – Representação gráfica de sinais LFM e não modulado (amplitude x tempo)

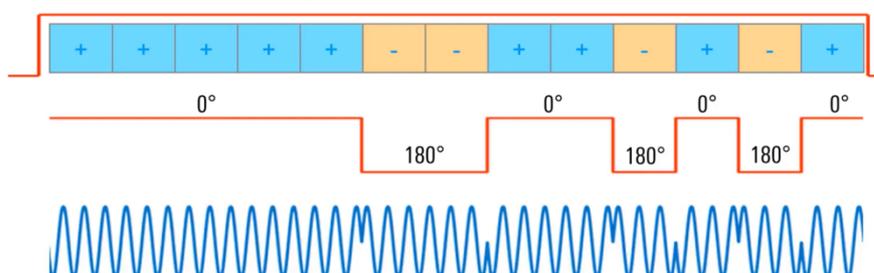


Fonte: Elaborado pelo autor (2023).

### 2.7.2 Códigos Barker

Os códigos de Barker foram publicados por Ronald Hugh Barker, seu inventor, em 1953 (BARKER, 1953). Por ser um tipo de modulação em fase, o sinal tem sua fase alterada em vários instantes de tempo durante a transmissão do pulso. Toda modulação PMOP é implementada dividindo o pulso em intervalos de tempo iguais denominados segmentos. No caso da modulação do tipo Barker e nas demais modulações do tipo polifásicas descritas nesse trabalho (Frank, P1, P2, P3 e P4), o sinal mantém a fase constante dentro de cada segmento e pode mudar a fase entre um segmento e outro. No caso da modulação tipo Barker, a fase do sinal em cada segmento de tempo pode ser  $0^\circ$  ou  $180^\circ$ , que são os dois estados de fase produzidos por essa modulação. A Figura 20 mostra um sinal Barker13. O pulso é dividido em 13 segmentos e muda de fase 6 vezes.

Figura 20 – Modulação em fase



Fonte: ROHDE SCHWARZ (2020).

Quando um sinal modulado em fase possui apenas duas fases possíveis, como é o caso de sinais com modulação Barker ( $0^\circ$  ou  $180^\circ$ ), a modulação é dita binária. Ressalta-se que existem outras modulações em fase que produzem sinais com mais de duas fases possíveis, isto

é, mais de dois estados de fase. Estas modulações são denominadas polifásicas e estão detalhadas na Seção 2.7.2.

Conforme explicitado por Rohde Schwarz (2020), o principal objetivo de uma modulação é obter a melhor precisão de distância possível ao determinar o atraso do eco recebido do pulso transmitido. Quando o eco é recebido no receptor do radar, é feita uma filtragem por um pulso FIR. O resultado do filtro é equivalente a se fazer a correlação entre o sinal transmitido e o seu eco. A correlação é uma ferramenta que possibilita medir a similaridade entre dois sinais, no caso de sinais radar. O padrão de inversões de fase é pensado e projetado para maximizar o valor central da correlação (valor de pico, do inglês, *peak*) e simultaneamente minimizar os demais valores e picos secundários (Figura 21). Esses picos secundários são denominados lóbulos laterais ou *sidelobes*.

Figura 21 – Minimização dos lóbulos laterais



Fonte: ROHDE SCHWARZ (2020).

Acrescentadamente, sublinha-se que a modulação Barker é muito utilizada até a atualidade e possui como diferencial, em relação às demais modulações de fase, produzir um menor valor de pico do primeiro lóbulo secundário. Para que isso ocorra, o Barker produz lóbulos secundários iguais ao primeiro lóbulo secundário.

Na literatura existem códigos Barker com diferentes tamanhos (Tabela 3). Os códigos possuem como característica a proporcionalidade inversa entre seu tamanho e o nível dos lóbulos secundários. Em outras palavras, quanto maior o comprimento do código (*code length*), menores são os valores de pico dos *sidelobes*. Neste estudo, foi utilizado, para análise dos resultados dos algoritmos, o código Barker13.

Tabela 3 – Códigos de Barker

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

Fonte: ROHDE SCWARZ (2020).

A Equação 9 define os valores presentes na terceira coluna da Tabela 3, sendo  $N_{Barker}$  o tamanho do código:

$$\text{Nível dos Lóbulos Secundários} = -20 \log(N_{Barker}) \quad (9)$$

### 2.7.3 Polifásicos: P1, P2, P3, P4 e Frank

Um sinal polifásico diferencia-se dos bifásicos por possuírem mais do que dois estados de fase. Assim como no código Barker, o pulso é dividido em segmentos de tempo iguais. Nesse contexto, o valor da fase pode variar de um segmento para o próximo, mas permanece constante dentro de cada um deles. Nesse sentido, o valor da fase em cada segmento é gerado a partir de uma sequência de valores discretos que descreve o código polifásico do sinal. Uma vez determinado o código polifásico, ele é utilizado para modular a fase de um sinal contínuo senoidal (VANHOY; SCHUCKER; BOSE, 2017, p. 307, tradução nossa).

As modulações polifásicas utilizadas nas simulações deste trabalho são definidas pelas Equações de 10 a 14, conforme descrito por (BEKTAŞ; ERGEZER, 2020, p. 138-139), (GHADIMI, G.; NOROUZI, Y.; BAYDERKHANI, R.; *et al.*, 2020, p. 1181), e (VANHOY; SCHUCKER; BOSE, 2017, p. 307-308). Cada equação define a fase ( $\phi$ ) em função de alguns parâmetros.

a) Frank:

$$\phi_{Frank} = \phi_{i,j} = \frac{2\pi}{M} (i-1)(j-1) \quad (10)$$

O código Frank é o primeiro dos códigos polifásicos que derivam de uma aproximação por etapas de uma forma de onda LFM (VANHOY; SCHUCKER; BOSE, 2017,

p. 307, tradução nossa). Inicialmente, o pulso é dividido em  $M$  grupos contendo a mesma quantidade de amostras. Em seguida, cada grupo de amostras é dividido novamente em  $M$  partes, formando  $M$  subpulsos de igual tamanho dentro de cada grupo. A quantidade de mudanças de fase, no código Frank, é  $n = M^2$ , sendo  $M$  a quantidade total de grupos, que são indexados pela variável  $i$ . Cada um dos  $M$  subpulsos de cada grupo são indexados pela variável  $j$ . Por exemplo, para  $M = 8$  (valor utilizado para a geração dos sinais simulados com o código Frank), a quantidade de mudanças de fase é 64, pois todos os pares ordenados  $[i, j]$  devem ser percorridos ( $[1,1];[2,1];\dots;[8,1];[1,2];\dots;[8,8]$ ).

b) P1:

$$\phi_{P1} = \phi_{i,j} = -\frac{\pi}{L}[L - (2j - 1)][(j - 1)L + (i - 1)] \quad (11)$$

O código P1 é semelhante ao código Frank no sentido de que seu comprimento é  $N_c = L^2$  (VANHOY; SCHUCKER; BOSE, 2017, p. 307, tradução nossa). No P1, assim como no P2,  $L$  representa a ordem do código e as variáveis  $i$  e  $j$  variam de 1 até  $L$ . Outrossim, ressalta-se que, neste trabalho, foram adotados os valores  $L = 8$  tanto para P1 quanto para P2.

c) P2:

$$\begin{aligned} \phi_{P2} = \phi_{i,j} &= \left[ -\frac{\pi}{2} \cdot \frac{(L-1)}{L} - \frac{\pi}{L} \cdot (i-1) \right] (L+1-2j) = \\ &= -\frac{\pi}{2L} \cdot (2i-1-L) \cdot (2j-1-L) \end{aligned} \quad (12)$$

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

d) P3:

$$\phi_{P3} = \phi_k = \frac{\pi}{M} \cdot (k-1)^2 \quad (13)$$

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

e) P4:

$$\phi_{P4} = \phi_k = \frac{\pi}{M} \cdot (k - 1)^2 - \pi(k - 1) \quad (14)$$

P4 é gerado de forma parecida com o P3, mas faz uso de outra regra para determinar os estados de fase (VANHOY; SCHUCKER; BOSE, 2017, p. 307, tradução nossa). As variáveis  $k$  e  $M$  possuem o mesmo significado explicado na modulação P3.

#### 2.7.4 Politemporais: T1, T2, T3 e T4

As modulações politemporais são parecidas com as polifásicas no sentido de que são geradas a partir de um código que se aproxima de uma forma de onda escalonada ou LFM. Nos códigos politemporais, diferentemente dos polifásicos, o intervalo de tempo em cada estado de fase é variável, ou seja, a permanência do sinal em uma determinada fase é variável. Os códigos implementados para as simulações deste trabalho são os códigos T1, T2, T3 e T4, conforme exposto em (CHILUKURI; KAKARLA; SUBBARAO, 2020, p. 6-7), (VANHOY; SCHUCKER; BOSE, 2017, p. 307-308), (BEKTAŞ; ERGEZER, 2020, p. 139) e (GHADIMI, G.; NOROUZI, Y.; BAYDERKHANI, R.; *et al.*, 2020, p. 1181).

a) T1:

$$\phi_{T1}(t) = \text{mod} \left\{ \frac{2\pi}{N} \lfloor (kT - jT) \rfloor \cdot \frac{jN}{T}, 2\pi \right\} \quad (15)$$

O código T1 é gerado pela aproximação da forma de onda de frequência escalonada, onde o segmento inicial é zero (Equação 15). A operação  $\text{mod}(x)$  faz parte de uma área da matemática denominada aritmética modular. Essa operação gera como resultado o resto obtido com a divisão de  $x$  por  $y$ . Outrossim, os símbolos  $\lfloor \rfloor$  representam a função *floor*, isto é, uma operação matemática de arredondamento que retorna o maior número inteiro que é menor que o valor obtido na resposta. A variável  $N$  é a quantidade de fases e  $T$  é o período do código (que é igual à largura de pulso).

Adicionalmente,  $j \in [0, k - 1]$  e é o resultado da operação  $j = \left\lfloor \frac{i \cdot t_s}{PW} \cdot k \right\rfloor$ , em que  $PW$  é a largura de pulso em segundos e  $t_s$  é o período de amostragem.

A variável  $k$ , presente nas Equações 15 e 16, é o número de segmentos. Além disso, o número de mudanças de fase depende de  $k$ , tal que  $k = 4$  representam 12 mudanças de fase.

Nas simulações feitas neste trabalho, foram utilizados  $k = 4$  para T1 e T2 e  $N = 2$  ( $0^\circ$  e  $180^\circ$ ) para todos os tipos de modulação politemporais (T1, T2, T3 e T4).

b) T2:

$$\Phi_{T2}(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[ (kt - jT) \left( \frac{2j - k + 1}{T} \right) \frac{N}{2} \right], 2\pi \right\} \quad (16)$$

Segundo Vanhoy, Schucker e Bose (2017, p. 307, tradução nossa), o código T2 é gerado de forma semelhante ao código T1 ao aproximar a forma de onda de frequência escalonada, mas se aproxima de uma forma de onda que é zero em sua frequência central (Equação 16). Quando se utiliza um número ímpar de segmentos  $k_s$ , a frequência zero está no segmento central, e quando  $k_s$  é par, a frequência zero ficará entre os dois segmentos no centro (VANHOY; SCHUCKER; BOSE, 2017, p. 307-308, tradução nossa), o que é o caso ( $k_s = 4$ ).

c) T3:

$$\Phi_{T3}(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[ \frac{NBt^2}{2T_p} \right], 2\pi \right\} \quad (17)$$

O código T3 é gerado de maneira diferente dos dois códigos politemporais anteriores (Equação 17). Ele é gerado ao aproximar uma forma de onda LFM que é zero na sua borda inicial, em vez de usar a forma de onda de frequência escalonada (VANHOY; SCHUCKER; BOSE, 2017, p. 308, tradução nossa).

Na Equação 17,  $B$  é a largura de banda da modulação e  $T_p$ , o período de modulação. Para os sinais simulados com a modulação de fase T3, foram atribuídos os valores de 2MHz para  $B$  e  $T_p = 4PW$ . Além do mais, vale ressaltar que a quantidade de mudanças de fase depende da  $PW$ . Neste estudo, quando os valores simulados para  $PW$  foram 10 e 15, foram implicadas 10 e 15 mudanças de fase em T3, respectivamente. Contudo, todos os valores simulados para  $PW$  neste trabalho estão dispostos na Seção 3.4.

d) T4:

$$\Phi_{T4}(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[ \frac{NBt^2}{2T_p} - \frac{NBt}{2} \right], 2\pi \right\} \quad (18)$$

O código T4, expresso pela Equação 18, é gerado de maneira conceitualmente semelhante ao código T3, mas se aproxima de uma forma de onda LFM que é zero na sua frequência central (VANHOY; SCHUCKER; BOSE, 2017, p. 308, tradução nossa). Para os

sinais simulados com a modulação de fase T4, o valor para o período para a modulação ( $T_p$ ) utilizado neste trabalho foi de  $8PW$ . Além disso, os valores para  $PW$  de 10 e 15, conforme citado anteriormente, implicaram em 15 e 23 mudanças de fase em T4, respectivamente.

## 2.8 O Problema da Classificação de Sinais

O objetivo de um algoritmo de classificação é a geração de um modelo denominado classificador, capaz de categorizar um dado de entrada, que é representado por um conjunto de valores numéricos ou atributos, em uma das diferentes classes pré-definidas. O modelo deve ser capaz de identificar qual é a classe do dado de entrada.

O presente trabalho tem por objetivo comparar a eficiência de três classificadores diferentes que são capazes de classificar sinais radar pulsados, identificando o tipo de modulação presente no pulso. Os sinais são representados pelas características extraídas no domínio do tempo e tempo-frequência. Um dado de entrada é, portanto, um conjunto de características, que são valores numéricos calculados a partir das amostras de um pulso e do resultado da transformada STFT aplicada à essas amostras. As classes pré-definidas são os tipos de modulação em fase Barker, P1, P2, P3, P4, Frank, T1, T2, T3, T4, a modulação em frequência LFM e o tipo sem modulação.

### 3 METODOLOGIA

Este trabalho se propõe à realização de uma análise comparativa entre três algoritmos de classificação baseados em técnicas de IA. A utilização de técnicas de IA nos classificadores deste estudo é justificada pela sua capacidade de generalização, que garante a manutenção da eficiência na classificação mesmo em situações de baixa SNR. Além disso, a adoção de técnicas de IA neste estudo baseia-se na abundância de artigos na literatura que endossam sua eficiência na classificação do tipo de modulação em sinais radar. O grande número de estudos nesse sentido reforçam a capacidade da IA em lidar com esse problema específico de classificação.

Uma justificativa adicional reside no fato de que ao utilizar algoritmos de IA, o modelo matemático resultante é estatístico, em função dos dados percebidos. Isso difere dos modelos teóricos que geralmente assumem algum comportamento físico ou esperado. Dessa forma, técnicas de *Machine Learning* ou *Deep Learning* tendem a proporcionar modelos mais robustos diante de alterações que não foram teoricamente previstas.

Por outro lado, vale a pena ressaltar que, nos três classificadores analisados, os sinais são digitalmente processados para a extração de características antes de serem aplicadas as técnicas de IA. Um exemplo é o uso do janelamento aplicado às amostras digitalizadas do sinal antes de calcular a STFT, conforme explicado nas Seções 4.1, 4.2 e 4.3.

Outra técnica de processamento de sinais utilizada é a filtragem do sinal, que implica numa tentativa de aumentar a SNR antes da extração de características. Ademais, salienta-se que com relação à própria extração de características, são também aplicadas técnicas de processamento de sinais. Em suma, é importante notar que as técnicas de processamento de sinais foram aplicadas não apenas para aprimorar a SNR do sinal que chega à antena do radar, mas também para extrair as características desses sinais.

Em relação aos classificadores utilizados neste estudo, dois foram desenvolvidos baseados em duas Arquiteturas de Redes Neurais Artificiais diferentes: um utiliza a Rede Neural de Elman e o outro, a CNN. Além desses, o terceiro algoritmo classificador foi criado com base na SVM.

Com o objetivo de alcançar o propósito do estudo, foram conduzidas simulações utilizando o *software* MATLAB para analisar diversos sinais radar presentes em uma base de dados.

### 3.1 Quanto aos fins

Para a elaboração deste trabalho, foram empregados dois tipos distintos de pesquisa em relação aos fins. Por um lado, a pesquisa exploratória desempenhou um papel importante ao definir os conceitos aplicados em GE e radar, além das técnicas de IA utilizadas e os sinais sob análise e suas características. Por outro, a pesquisa explicativa proporcionou uma descrição detalhada dos modelos e sistemas classificadores utilizados de forma a demonstrar as diferenças entre cada um no processo de classificação dos sinais entre os tipos de modulação analisados neste trabalho.

### 3.2 Quanto aos meios

Em relação aos meios, os métodos de pesquisa empregados compreenderam a pesquisa experimental, na qual utilizamos o *software* MATLAB para abordar o problema em questão, e a pesquisa bibliográfica, que envolveu a análise de documentos em meio eletrônico e físico, além de artigos e publicações relacionados ao tema central deste trabalho.

### 3.3 Quanto à natureza do método

Nesse contexto, a pesquisa quantitativa foi utilizada por meio da definição das hipóteses a serem testadas (as distintas classes referentes aos diferentes tipos de sinais) e da realização de procedimentos sistemáticos para a análise dos sinais, com o uso dos algoritmos de classificação no *software* MATLAB. Além disso, está presente o uso de métodos estatísticos, como o índice *kappa* e a análise da taxa de acertos de cada algoritmo na classificação por meio da matriz de confusão gerada como resultado.

### 3.4 Limitações do método

Neste trabalho, apenas três classificadores são objetos de análise, ainda que inúmeras possibilidades de classificadores com distintas formas de Aprendizado de Máquina sejam viáveis para a solução do problema apresentado.

Outra circunstância importante de ser destacada é a de que os sinais utilizados neste estudo são oriundos de simulações. Essas simulações foram necessárias devido à indisponibilidade de informações sobre os radares militares de outros países. Obviamente, essas informações são mantidas sob sigilo por nações estrangeiras por questões de segurança.

Portanto, este estudo se baseia em suposições sobre as capacidades que os radares de nações adversárias possam ostentar. Devido à dificuldade de obter informações, uma variedade de modulações em sinais pulsados conhecidas foi contemplada. Isso significa que alguns dos tipos de modulações investigados não são comprovadamente utilizados em radares de outras nações, mas foram incluídas para análise.

### 3.5 Coleta e tratamento dos dados

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

É importante destacar que os sinais simulados abrangem 14 valores diferentes de SNR para verificar sua influência na eficácia dos classificadores. A SNR, um conceito comum em radar, quantifica a relação entre as potências médias do sinal ( $P_{sinal}$ ), que chega no receptor do MAGE, e do ruído ( $P_{ruído}$ ), que é um sinal indesejado. A Equação 19 expressa essa relação em decibéis (dB):

$$SNR = 10\log_{10}\left(\frac{P_{sinal}}{P_{ruído}}\right) \quad (19)$$

Já as potências médias do sinal e do ruído são dadas pelas Equações 20 e 21, sendo  $N$  o número de amostras:

$$P_{sinal} = \frac{1}{n_a} \sum_{i=1}^N amostra^2(i) \quad (20)$$

$$P_{ruído} = \frac{1}{n_a} \sum_{i=1}^N ruído^2(i) \quad (21)$$

Nas simulações, o número de amostras  $n_a$  por arquivo é de 528.000 (quinhentos e vinte e oito mil). Ademais, os valores adotados para SNR foram os seguintes:

$$[15, 10, 5, 2.5, 0, -2.5, -5, -7.5, -10, -12.5, -15, -17.5, -20, -25]$$

Além disso, o ruído considerado foi um Ruído Gaussiano Branco Aditivo (AWGN, do inglês, *Additive White Gaussian Noise*). Isso significa dizer que a potência média do ruído é constante no domínio da frequência e a função densidade de probabilidades é uma distribuição normal (função Gaussiana representada pela curva de sino). Neste trabalho, seu valor médio é zero e sua variância é 6 (7.79 dB de potência média). Ademais, para gerar sinais com diferentes valores de SNR, a amplitude do sinal é modificada e a amplitude do ruído é mantida constante.

Para a PW, foram adotados os seguintes valores em microssegundos ( $\mu s$ ): [6.5, 8, 10, 12.5, 15]. A PW de 6.5  $\mu s$  é comum em aplicações radar. Os demais valores foram simulados para verificar o comportamento dos classificadores com valores diferentes de PW. Para a frequência de amostragem, que é o inverso do período de amostragem, foi considerado 2.4GHz. Já a banda de frequências analisada foi de 120MHz a 200MHz e a  $f_c$ , frequência central dos pulsos simulados, igual a 160MHz.

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

Para a rede de Elman e para a CNN, 25% dos dados do conjunto de treinamento formam o conjunto de validação, que não é utilizado para o ajuste de pesos, mas como um dos critérios de parada do treinamento. Os 75% restantes do conjunto de dados de treinamento são utilizados para o ajuste dos pesos das redes. Portanto, nas redes Elman e CNN, 30% dos dados são do conjunto de testes; 17.5%, do conjunto de validação; e 52.5%, do conjunto de treinamento para o ajuste dos pesos. Por outro lado, na SVM não foi utilizado um conjunto de validação. O conjunto de treinamento e o de testes foram divididos com 50% dos dados cada, o que é bem próximo aos 52.5% utilizados como conjunto de treinamento para o ajuste de pesos e aos 47.5% utilizados como conjunto de testes e validação pela rede de Elman e pela CNN, o que torna a comparação dos classificadores justa.

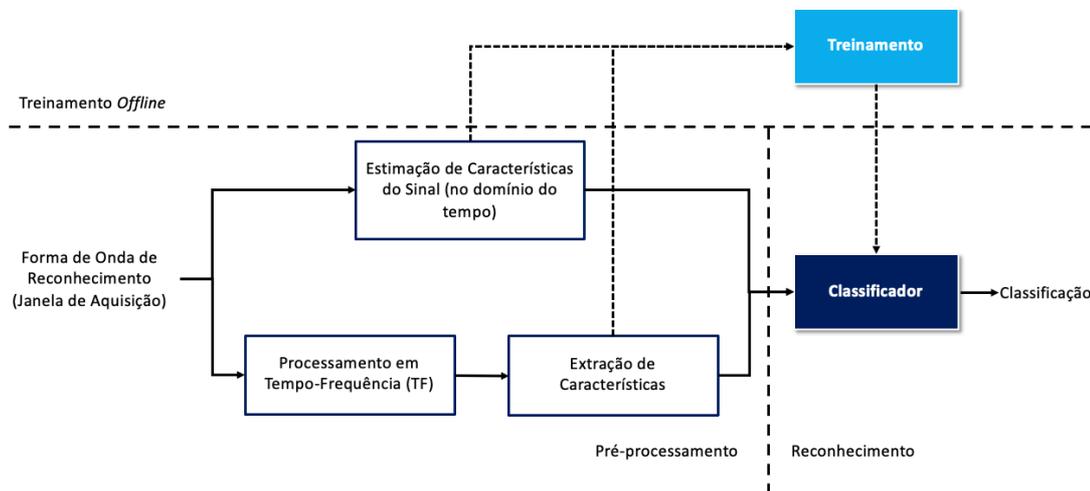
## 4 ALGORITMOS DE CLASSIFICAÇÃO UTILIZADOS

Neste trabalho, os modelos dos algoritmos utilizados na classificação dos sinais radar modulados e citados anteriormente estão elencados nas Seções que se seguem.

### 4.1 Classificador baseado na Rede Neural de Elman

Este primeiro classificador é baseado em um modelo proposto por três pesquisadores chineses, Zhang, Liu e Diao (2016). De acordo com o esquema exposto na Figura 22, o sistema possui 4 módulos: processamento e extração de características no domínio tempo-frequência, estimação de características do sinal no domínio do tempo e o classificador.

Figura 22 – Classificador proposto por Zhang, Liu e Diao

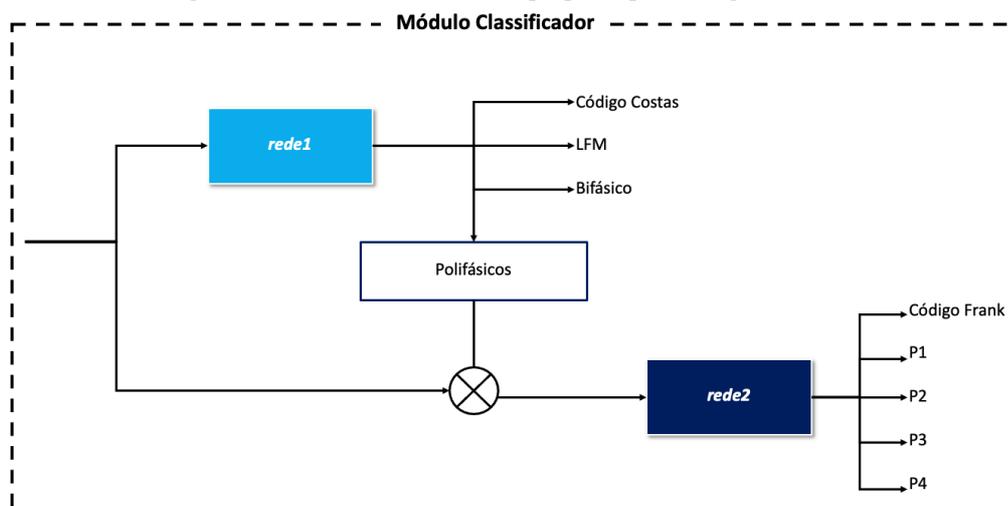


Fonte: ZHANG; LIU; DIAO (2016, p. 3, tradução nossa).

O classificador utiliza características do sinal estimadas no domínio do tempo (módulo de Estimação de Características do Sinal) e características extraídas no domínio *tempo x frequência* (módulo de Extração de Características). As características extraídas do sinal, neste trabalho, são as mesmas expostas no artigo dos pesquisadores Zhang, Liu e Diao (2016, p. 5-13). O sinal, junto com o ruído, entra no receptor (Janela de Aquisição) e é amostrado. Por já estarem no domínio do tempo, essas amostras são utilizadas pelo módulo Estimação de Características do Sinal. Porém, para o módulo Extração de Características agir, as amostras no domínio do tempo são transformadas para o domínio *tempo x frequência* por meio da Transformada de Fourier de Curto Prazo (STFT, do inglês *Short-Time Fourier Transform*) neste trabalho. No caso do classificador de Zhang, Liu e Diao (2016, p. 5, tradução nossa), a transformada utilizada é a de Choi-Williams, semelhante à STFT, porém bem mais complexa em termos de tempo de processamento, o que foi verificado a partir de simulações no *software* MATLAB.

O módulo classificador proposto pelos chineses consiste em duas células classificadoras chamadas de *rede1* e *rede2* (Figura 23). A *rede1* é responsável por classificar o tipo de modulação dos sinais em LFM, código Costas (um tipo de código de modulação em frequência), modulação bifásica ou polifásica. A *rede2* é controlada pela *rede1*. Caso a primeira análise feita pela *rede1* resultar numa classificação do sinal em modulação polifásica, a *rede2* é acionada. A partir disso, a *rede2* se encarrega da classificação do sinal polifásico em um dos tipos de modulação apresentados na Seção 2.7.3 (código Frank, P1, P2, P3 ou P4).

Figura 23 – Módulo classificador proposto por Zhang, Liu e Diao

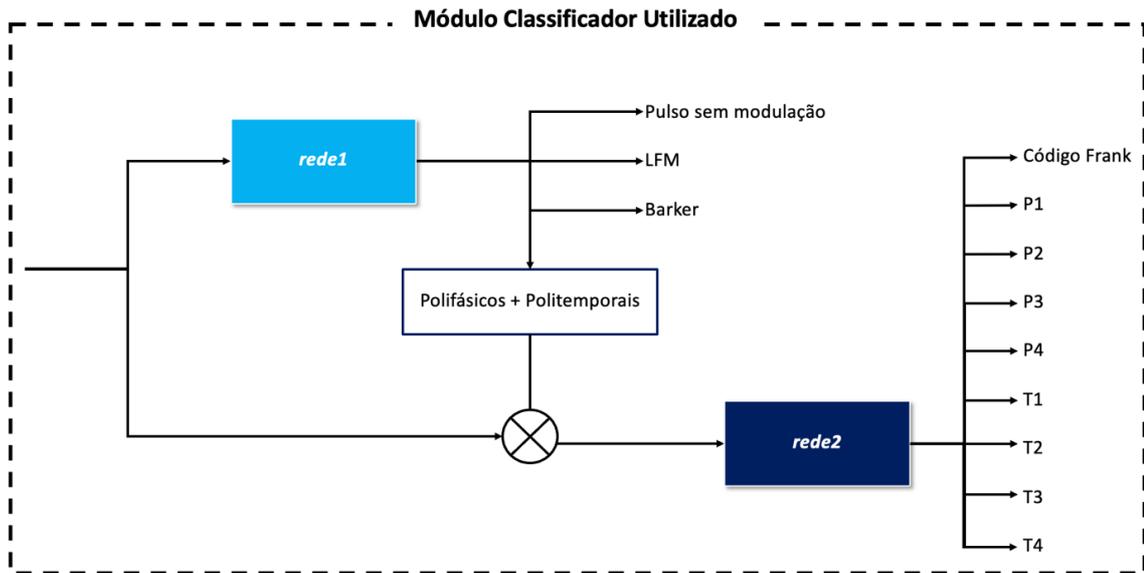


Fonte: ZHANG; LIU; DIAO (2016).

Somado a isso, ressalta-se que a razão para projetar duas células classificadoras (*rede1* e *rede2*) é reduzir o número de características de entrada do classificador e melhorar a precisão da classificação do sinal (ZHANG; LIU; DIAO, 2016, p. 4, tradução nossa).

Entretanto, algumas considerações precisam ser feitas para o classificador exposto na Figura 24 e que foi usado neste trabalho. No modelo utilizado, as classes controladas pela *rede1* e pela *rede2* foram propositalmente alteradas, sofrendo uma nova distribuição. A *rede1* classificou os sinais entre pulso sem modulação (pois o código Costas pode ser visto, por partes, como um conjunto de pulsos sem modulação), LFM, Barker (que é um tipo de sinal bifásico) ou polifásicos e politemporais. No caso de classificação dos sinais em polifásicos e politemporais, a *rede2* é acionada para identificar uma tipo de sinal entre as seguintes classes: Frank, P1, P2, P3, P4, T1, T2, T3 ou T4.

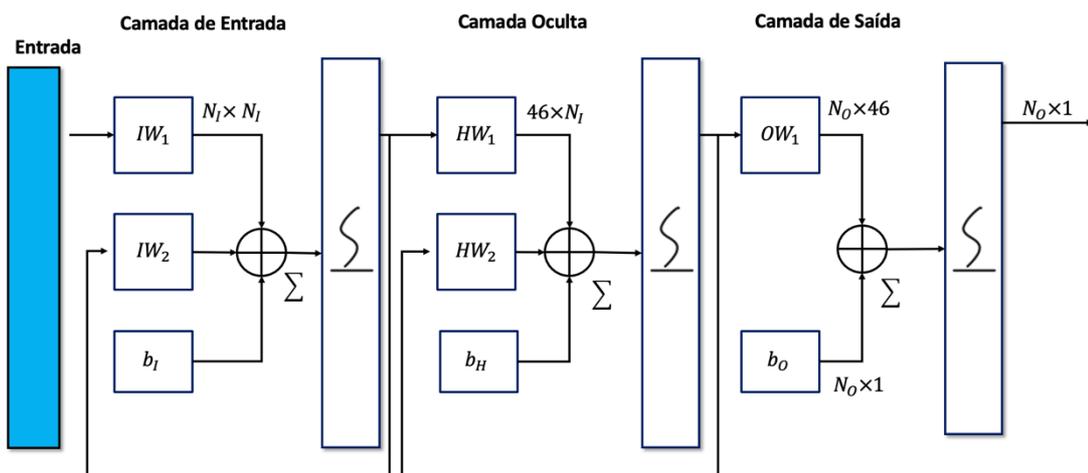
Figura 24 – Módulo classificador baseado na Rede Neural de Elman



Fonte: Elaborado pelo autor (2023).

Sobre a técnica computacional utilizada pela *rede1* e pela *rede2*, temos uma Rede Neural de Elman de três camadas semelhante à do modelo proposto pelos chineses, conforme a Figura 25. Além disso, as conexões da camada oculta são conectadas a unidades de contexto fixadas com o peso 1. Nessa arquitetura, a propagação das entradas ocorrem em sentido único e são dadas por uma forma padrão em cada passo de tempo. Ademais, o aprendizado do modelo é dada por uma regra de retropropagação de erro.

Figura 25 – As três camadas do classificador baseado na Rede Neural de Elman



Fonte: Elaborado pelo autor (2023).

Quando a rede neural realiza um passo de processamento, os valores nas unidades da camada oculta são propagados através dessas conexões de retorno para as unidades de contexto antes que a regra de aprendizado de retropropagação de erro seja aplicada. Como resultado, as unidades de contexto, que não estão explicitamente representadas na Figura 25,

armazenam os valores das unidades ocultas antes de qualquer ajuste de peso ocorrer durante o treinamento. Essa configuração permite que as unidades de contexto mantenham uma memória das informações anteriores processadas pela rede e proporciona, ao modelo, a possibilidade de resolver problemas como a regressão – que é a previsão do próximo valor de uma sequência – de forma mais eficiente do que uma rede MLP padrão (ZHANG; LIU; DIAO, 2016, p. 3, tradução nossa).

Na Figura 25, a quantidade de neurônios da camada de entrada é determinada pelo número de características de entrada representado por  $N_I$ ;  $I$  denota uma matriz de entrada;  $W$  é a matriz de pesos atribuída; e  $b$  é a representação do vetor de bias, possuindo valores constantes.

Sendo assim, na camada de entrada,  $IW_1$  gera uma matriz  $N_I \times N_I$  que é somada a  $IW_2$  (uma realimentação da saída para a entrada da camada de entrada que passa pela camada de contexto) e ao bias  $b_I$ . Essa soma, então, passa por uma função de ativação sigmoideal, cuja representação pode ser dada pela Equação 23.

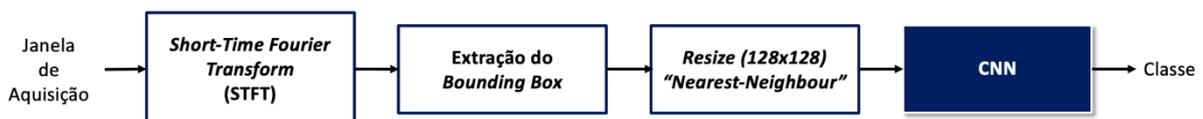
$$f(x) = \frac{1}{1 + e^{-x}} \quad (23)$$

Na camada oculta, 46 neurônios estão presentes e, portanto, a matriz gerada por  $HW_1$  é da grandeza  $46 \times N_I$ . A partir disso, o mesmo processo somatório ocorre entre  $HW_1$ ,  $HW_2$  (uma realimentação da saída para a entrada da camada oculta que passa pela camada de contexto) e  $b_H$  prosseguindo também para uma função de ativação sigmoideal. Na camada de saída,  $OW_1$  produz uma matriz  $N_O \times 46$  (sendo  $N_O$  o número de neurônios nesta camada) que é somada ao vetor  $b_O$ , de tamanho  $N_O \times 1$ . A última função sigmoideal é então acionada, gerando um vetor de tamanho  $N_O \times 1$ . Esse vetor é utilizado para decidir, entre as  $N_O$  classes, qual é a classe mais provável do sinal de entrada.

## 4.2 Classificador baseado na Rede Neural CNN

Este classificador possui os módulos apresentados no diagrama da Figura 26.

Figura 26 – Módulos do classificador baseado na CNN



Fonte: Elaborado pelo autor (2023).

Neste sistema, a Janela de Aquisição representa a entrada do programa que, neste

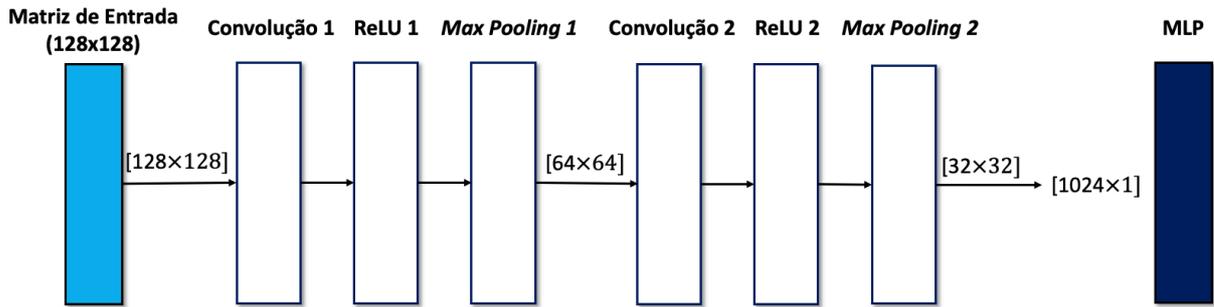
trabalho, é um conjunto de 528.000 amostras do ambiente eletromagnético onde o sinal de interesse está inserido. A STFT é uma técnica de processamento de sinais utilizada, nesta monografia, para converter um vetor contendo a amplitude das amostras (Janela de Aquisição) em uma matriz no domínio *tempo x frequência* num curto espaço de tempo (POULARIKAS, 2000, p. 868-869, tradução nossa).

Essa matriz (TF), resultante da transformada STFT aplicada às amostras, armazena apenas valores absolutos (maiores ou iguais a zero). Na TF, cada coluna representa os valores obtidos pela Transformada de Fourier Rápida (FFT, do inglês *Fast Fourier Transform*) aplicada a um *frame* de amostras, que é um subconjunto das amostras de entrada (MINSKY, 1974, p. 1-2, tradução nossa). Neste trabalho, cada *frame* foi composto por 8.192 valores discretos (amostras) e o *hop*, de 1.024 valores discretos. O *hop* significa quantas amostras devem ser puladas para formar o próximo *frame*, que é utilizada para formar a próxima coluna da TF. Em outras palavras, o termo “*hop*” se refere ao deslocamento ou avanço entre *frames* durante a aplicação da STFT.

Na etapa de extração do *Bounding Box* (ou caixa mínima delimitadora), após a aplicação da STFT, ocorre a identificação da região de interesse na TF, que é a região formada pelos valores da TF onde o sinal está presente, o que, neste caso, são os maiores valores (O’ROURKE, 1985, p. 183-199, tradução nossa). O termo “*Bounding Box*” vem da figura geométrica que cerca essa região.

Na Seção de *Resize*, ocorre o redimensionamento da matriz resultante da extração do *Bounding Box* para um tamanho específico. No caso deste trabalho, o tamanho da matriz redimensionada foi de 128x128. O método *Nearest-Neighbour* adotado durante o redimensionamento da matriz é baseado em distância (DUDA; HART; STORK, 2001, p. 18-26, tradução nossa) e, neste caso, significa que, dentro da *Bounding Box*, os vizinhos mais próximos aos pontos gerados pela malha 128x128 pontos serão os valores da matriz resultante do *Resize*. Essa matriz, de dimensão 128x128, é a entrada da rede CNN exposta na Figura 27, que foi baseada no artigo de (KONG; KIM, M.; HOANG; KIM, E., 2018, p. 4213).

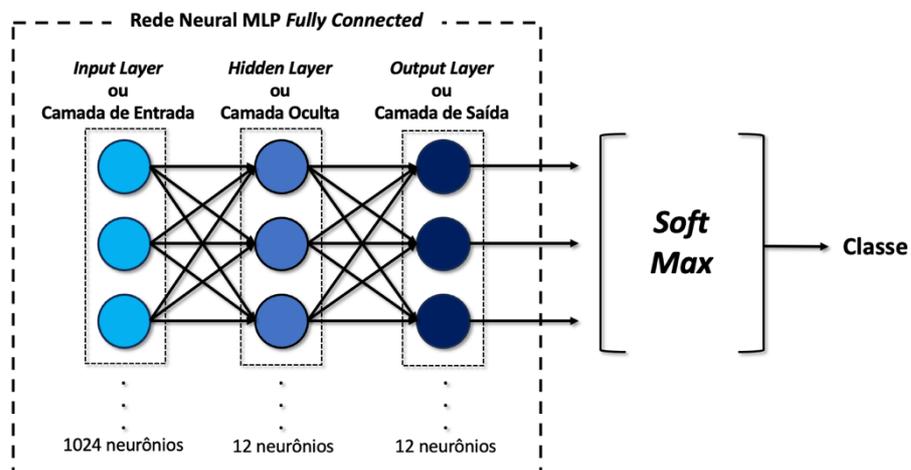
Figura 27 – CNN utilizada no classificador



Fonte: Elaborado pelo autor (2023).

Na CNN exposta acima, as funções de ativação convolucional, ReLU e *Max Pooling* –vistas nas Seções 2.5.2 e 2.5.3 deste trabalho – são aplicadas duas vezes de forma a gerar uma matriz de saída  $32 \times 32$ . Essa matriz é transformada em um vetor de tamanho  $1024 \times 1$  que é a entrada da Rede Neural MLP *Fully Connected* que se segue, como apresentado na Figura 28. Outrossim, destaca-se as seguintes configurações e/ou características usadas nas camadas do rede CNN exposta:

- Convolução 1 e Convolução 2: *kernel 7x7* e *padding same* (completa a matriz de entrada com valores nulos para que a matriz de saída da convolução fique com o mesmo tamanho da matriz de entrada); e *kernel 3x3* com *padding same*, respectivamente.
- ReLU 1 e ReLU 2: valores negativos se transformam em valores nulos. Serve para acelerar o treino do modelo e para aumentar a não linearidade da CNN.
- Max Pooling 1* e *Max Pooling 2*: *kernel 2x2* e *stride 2* para ambas as camadas. Reduz o tamanho da matriz de entrada, diminuindo a complexidade computacional do problema.

Figura 28 – MLP *Fully Connected* utilizada no classificador baseado na CNN

Fonte: Elaborado pelo autor (2023).

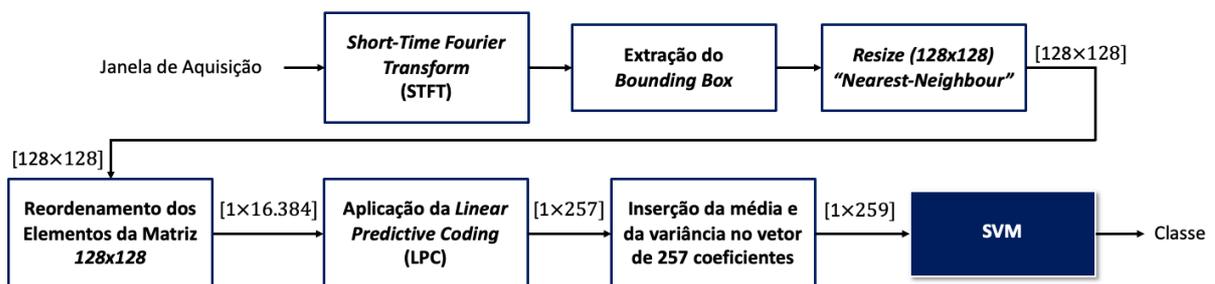
Na MLP utilizada, 1024 neurônios foram necessários na camada de entrada por conta do vetor gerado na etapa de codificação da CNN. Nas camadas oculta e de saída, 12 neurônios foram dispostos em cada uma. Na CNN, os neurônios da MLP *Fully Connected Layer* não possuem função de ativação. No final da CNN, a camada *Soft Max* determina qual é o neurônio da camada de saída da MLP *Fully Connected Layer* que está produzindo o maior valor na sua saída, definindo a classe do sinal analisado (pulso sem modulação, LFM, código Barker, código Frank, P1, P2, P3, P4, T1, T2, T3 ou T4).

### 4.3 Classificador baseado na SVM

O terceiro e último classificador é inspirado nos modelos de classificação presentes na dissertação de mestrado de um dos orientadores deste trabalho, Pires Filho (2009). Nessa dissertação, um dos métodos utilizados para a extração de características foi a Codificação Preditiva Linear (LPC, do inglês *Linear Predictive Coding*) e uma das ferramentas computacionais testadas para a classificação de notas musicais foi a SVM (PIRES FILHO, 2009, p. 8). Ambas são utilizadas no terceiro classificador deste estudo.

Conforme ilustrado na Figura 29, os primeiros blocos de processamento deste modelo são bastante semelhantes ao do classificador descrito na Seção 4.2. Os módulos STFT, Extração do *Bounding Box* e *Resize* pelo método “*Nearest-Neighbour*” desempenham as mesmas funções identificadas no classificador baseado na CNN (Seção 4.2). Já os módulos subsequentes, são diferentes.

Figura 29 – Módulos do classificador baseado na SVM



Fonte: Elaborado pelo autor (2023).

Neste classificador, o processo de Reordenamento dos Elementos da Matriz  $128 \times 128$ , posterior ao módulo *Resize*, consiste em uma etapa na qual todas as linhas da matriz  $128 \times 128$  são dispostas horizontalmente, resultando na transformação da matriz em um único vetor de 16.384 elementos. Em outras palavras, todos os elementos da matriz são rearranjados em uma única linha (vetor unidimensional), sendo as linhas da matriz organizadas lado a lado

sequencialmente.

No bloco de Aplicação da LPC, a Equação 24 é empregada para achar os coeficientes  $a(z)$  da LPC de ordem  $p$  de modo que a soma dos quadrados dos erros dados por  $\varepsilon(n) = s(n) - s_p(n)$ , seja minimizada (MATHWORKS, 2006, tradução nossa). A LPC é uma forma de prever amostras sucessivas do sinal como combinações lineares de amostras anteriores (BUNDY; ALLEN, 1984, p. 82, tradução nossa). A combinação linear é uma expressão que se forma por meio da multiplicação de cada termo de um conjunto por uma constante, por exemplo,  $ax + by$ , sendo  $a$  e  $b$  constantes (CALLIOLI; DOMINGUES; COSTA, 1990, p. 57-58).

$$s_p(n) = -a(2) \cdot s(n-1) - a(3) \cdot s(n-2) - \dots - a(p+1) \cdot s(n-p) \quad (24)$$

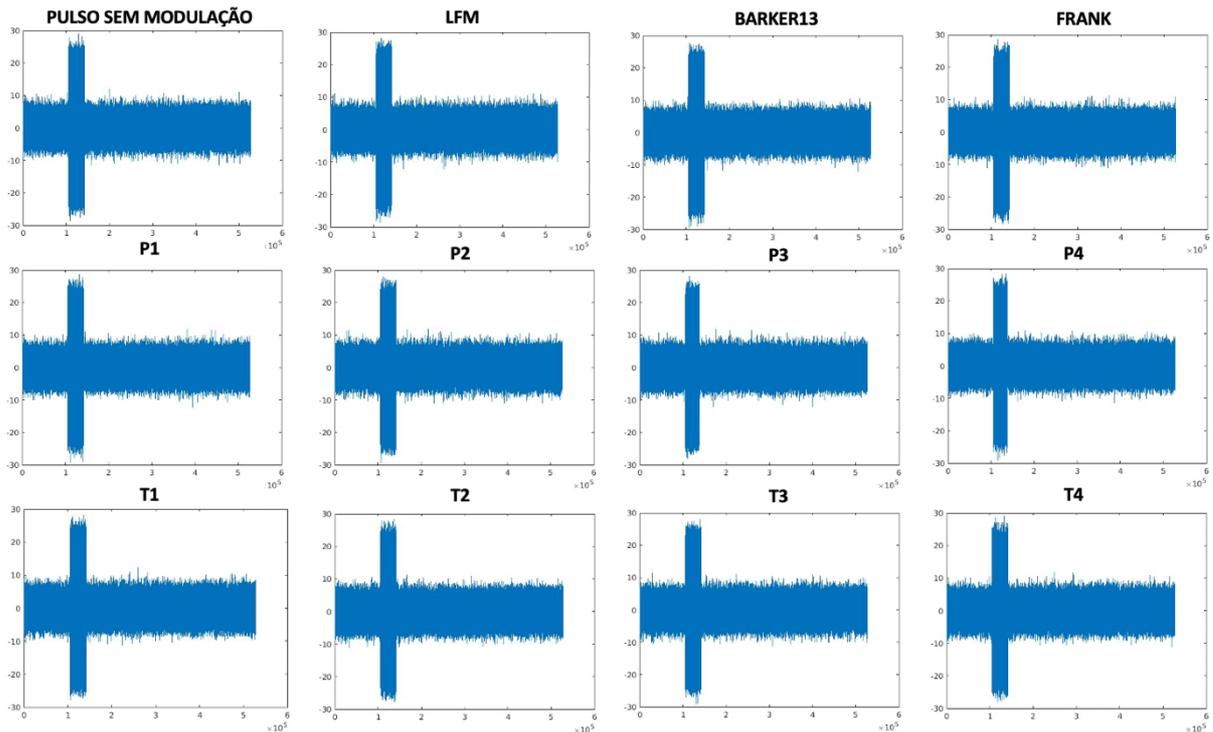
Nessa equação,  $s_p(n)$  representa um vetor com a amostra predita, em outras palavras, estimada;  $s(n-1)$ ,  $s(n-2)$  até  $s(n-p)$  são as amostras anteriores; e  $a(z)$  são os coeficientes da LPC. Os coeficientes  $a(z)$  relacionam as  $p$  amostras anteriores do sinal com seu valor atual (MATHWORKS, 2006, tradução nossa). Além disso, a variável  $p$  especifica a ordem do polinômio  $a(z)$  e deve ser um número inteiro positivo. No caso deste estudo, o valor de  $p$  é igual ao comprimento de  $s(n)$  diminuído de uma unidade.

Na saída do bloco de Aplicação da LPC, um vetor de 257 coeficientes é gerado. No módulo seguinte, a média e a variância do vetor de 257 coeficientes são adicionadas ao final desse mesmo vetor. Isso gera um novo vetor de 259 elementos, que segue como entrada da SVM. Na SVM, uma *kernel* polinomial de grau 2 ( $d = 2$  na Equação 5) é aplicada para realizar a classificação do tipo de modulação do sinal (LFM, código Barker, código Frank, P1, P2, P3, P4, T1, T2, T3, T4 ou pulso sem modulação).

## 5 SIMULAÇÕES E ANÁLISE DOS RESULTADOS

Os gráficos expostos na Figura 30 representam as amplitudes das amostras contidas em uma janela de aquisição, onde estão presentes o ruído e um sinal pulsado de cada tipo de modulação estudado. Para esta representação, todas as amostras são colhidas a partir de um ambiente eletromagnético simulado onde a SNR é de 15dB.

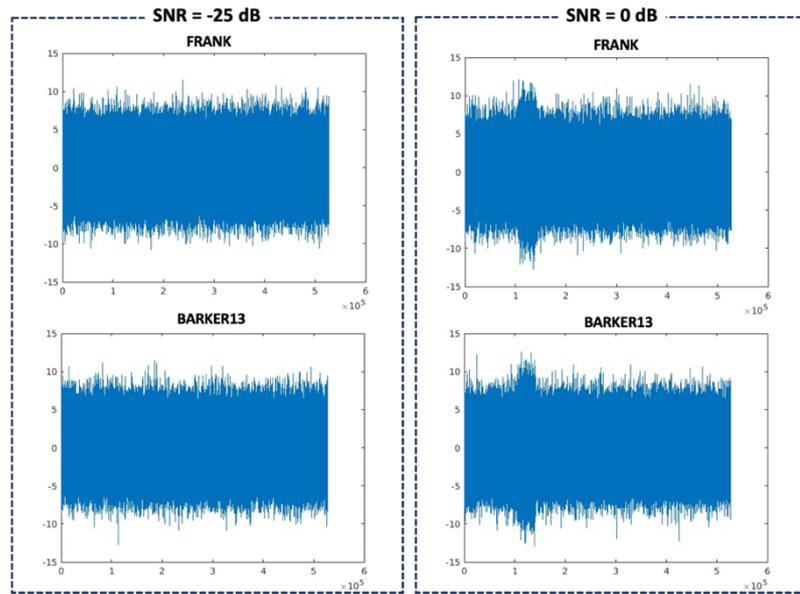
Figura 30 – Gráficos das amplitudes das amostras analisadas por tipo de modulação



Fonte: Elaborado pelo autor (2023).

Ainda a partir da Figura 30, pode-se observar que todos os sinais pulsados são nitidamente distinguíveis frente ao ruído do ambiente, independentemente do tipo de modulação do sinal. Contudo, quando o sinal recebido pelo MAGE tem baixa potência, seja pela grande distância do radar emissor ou pela técnica de modulação utilizada (SNR igual a -25 dB e 0 dB, por exemplo), a distinção entre o pulso e o ruído torna-se mais difícil. Isso pode ser visto na Figura 31, onde os tipos de modulação Barker13 e Frank foram escolhidos para ratificar essa análise.

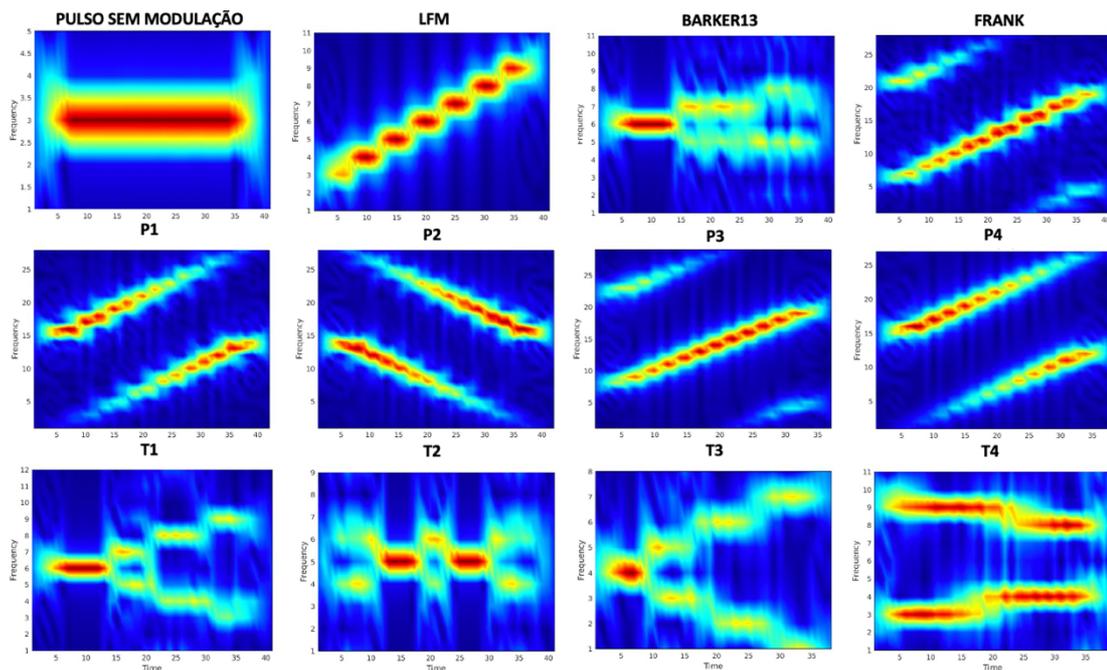
Figura 31 – Gráficos de amplitude com SNR -25 dB e 0 dB (Barker13 e Frank)



Fonte: Elaborado pelo autor (2023).

Analisando a Figura 31, pode-se perceber que a tarefa de se escolher um limiar (ou *threshold*) no domínio do tempo para distinguir o sinal pulsado em meio ao ruído torna-se muito mais difícil. Sendo assim, a utilização da transformada STFT em cada um dos classificadores possui o intuito de destacar o sinal em relação ao ruído e, com isso, facilitar a classificação dos sinais pulsados, promovendo a geração de imagens no domínio *tempo x frequência*. Isso pode ser visto nas Figuras 32 e 33, onde as representações gráficas foram originadas após a aplicação dessa transformada em sinais simulados com SNR de 15dB.

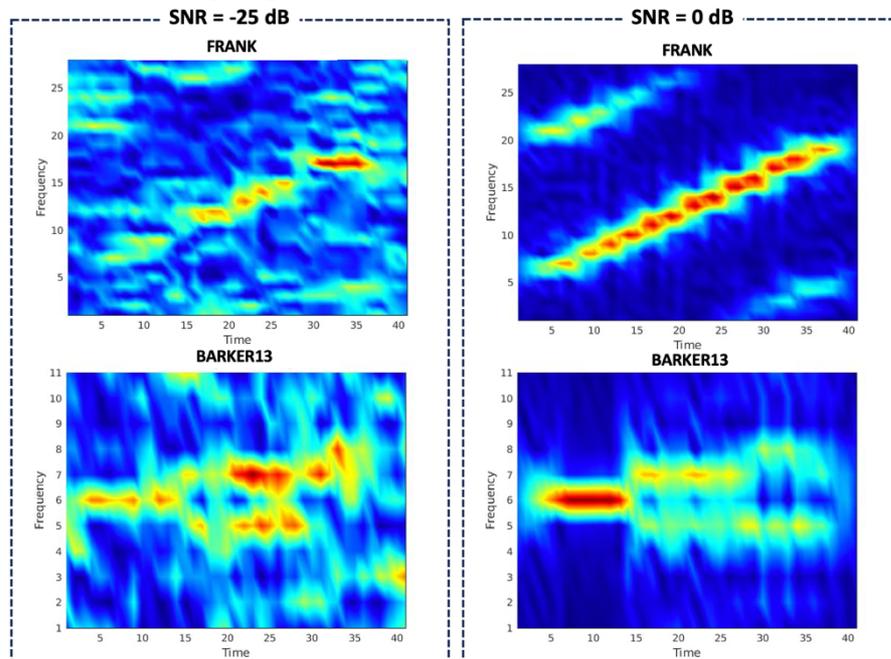
Figura 32 – Gráficos após aplicação da STFT (tempo x frequência)



Fonte: Elaborado pelo autor (2023).

De maneira semelhante aos gráficos presentes na Figura 32, a Figura 33 apresenta o resultado da transformada STFT aplicada às amostras dos pulsos com modulações Barker13 e Frank com SNR de 0 dB e -25 dB.

Figura 33 – Gráficos após aplicação da STFT com SNR -25 dB e 0 dB (Barker13 e Frank)



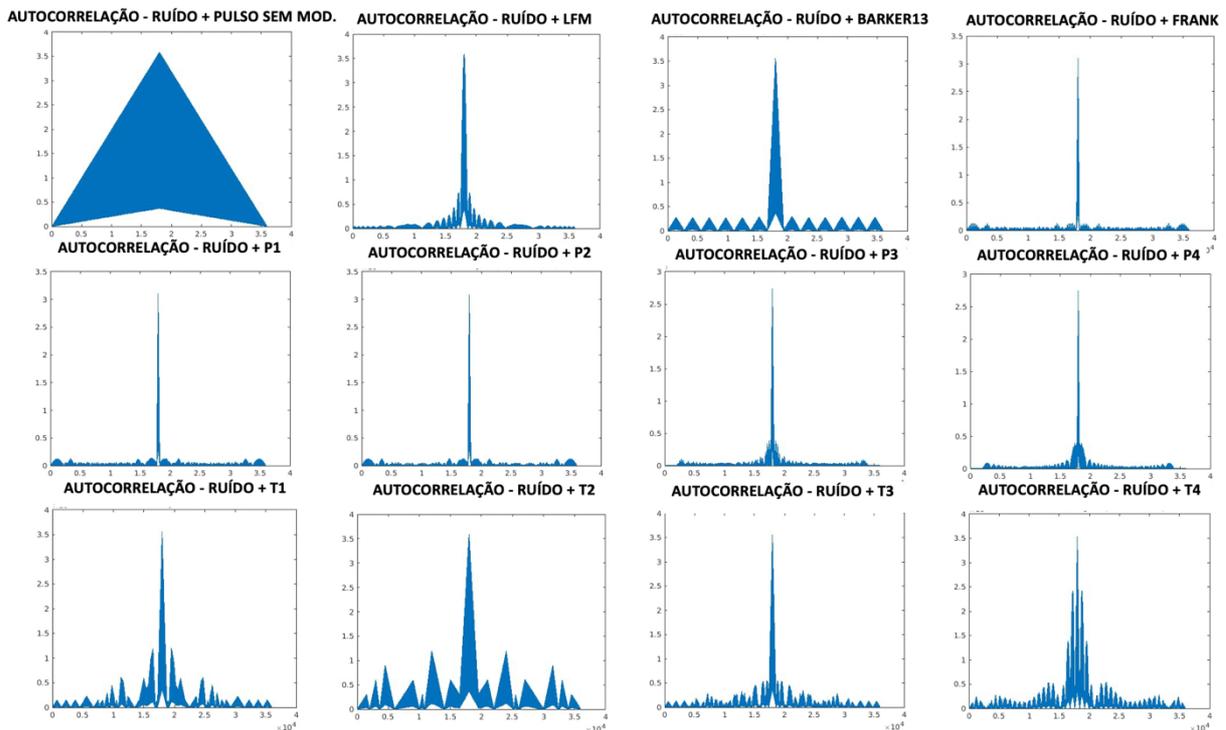
Fonte: Elaborado pelo autor (2023).

Analisando a Figura 33, percebe-se que quanto menor é a SNR, mais ruidosa fica a matriz resultante da transformada STFT, tornando a classificação mais difícil. Tendo em vista as 14 SNR diferentes consideradas para a realização deste trabalho (Seção 3.4), as Seções 5.1 a 5.3 revelam os resultados (erros e acertos) da tarefa de classificação realizada por cada classificador explicado nas Seções 4.1 a 4.3. Ressalta-se que o banco de dados simulado contendo as amostras das janelas de aquisição (sinais com diferentes modulações adicionados à ruído) é balanceado. Em outras palavras, há a mesma quantidade de sinais para cada tipo de modulação, para cada SNR e para cada PW.

Na Figura 34, estão dispostas as representações gráficas das autocorrelações que abrangem todos os tipos de modulação dos sinais estudados em meio ao ruído. Os radares podem aumentar a resolução de distância utilizando, em seu receptor, um filtro casado do tipo FIR. A saída desse filtro é semelhante à resposta da função de autocorrelação (Figura 34). A autocorrelação é uma função que mede a similaridade de um sinal com o mesmo sinal deslocado no tempo (ENGINEERING FUNDA, 2019, tradução nossa). Se não há similaridade, o valor da autocorrelação é zero. Quanto maior a similaridade (ou quanto menos o sinal analisado for deslocado no tempo em relação ao sinal original), maior o valor da autocorrelação. O pico da

função de autocorrelação se dá quando os sinais estão perfeitamente correlacionados (não há deslocamento no tempo), que ocorre no ponto central da autocorrelação (Figura 34). O receptor do radar recebe o eco do sinal com determinadas PW e potência máxima. O eco é enviado para a entrada do filtro FIR. Esse filtro produz uma resposta equivalente a um outro pulso de largura menor ( $PW/M$ , em que se comprimiu a PW M vezes) e com potência de pico maior. Aumentar a potência máxima e reduzir a largura de pulso fazem com que o radar aumente a resolução de distância, propriedade importante em um radar de rastreamento (do inglês, *tracking*).

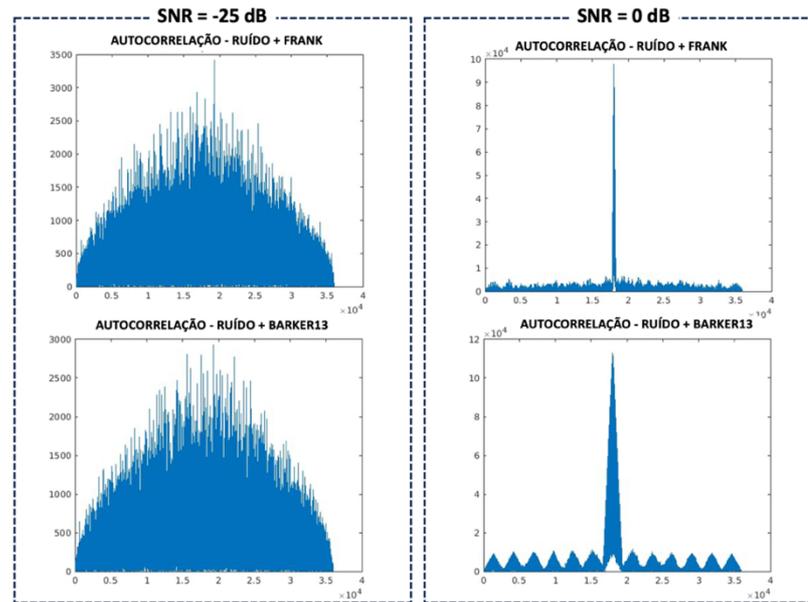
Figura 34 – Gráficos de autocorrelação com SNR = 15 dB



Fonte: Elaborado pelo autor (2023).

Na Figura 35, é possível perceber como a SNR afeta o resultado da autocorrelação. Novamente, os sinais Barker13 e Frank foram escolhidos para a ratificação da análise. Nesse cenário, nota-se como é difícil perceber a correlação dos sinais de maneira correta com SNR baixas.

Figura 35 – Gráficos de autocorrelação com SNR = 0 dB e SNR = -25 dB (Barker13 e Frank)



Fonte: Elaborado pelo autor (2023).

## 5.1 Resultados do Classificador baseado na Rede Neural de Elman

A matriz de confusão presente na Tabela 4 aponta o resultado da classificação gerada pelo classificador detalhado na Seção 4.1 de uma maneira geral (considerando todas as amostras em todas as SNR e PW estudadas) com os sinais utilizados na fase de treinamento do algoritmo.

Analisar o desempenho do classificador com os sinais do conjunto de treinamento é importante, pois revela se o modelo do classificador está coerente e pode ser utilizado para o problema em estudo. Um classificador treinado deve ser capaz de classificar os sinais do conjunto de treinamento com um mínimo de eficiência, caso contrário o classificador não será capaz de classificar os sinais do conjunto de testes (que são os dados novos) com eficiência suficiente que justifique o seu uso, seja porque a arquitetura do classificador não está correta ou porque as características extraídas dos sinais não são relevantes ou suficientes.

Adicionalmente, sublinha-se que, nas figuras presentes neste capítulo, a sigla PSM significa pulso sem modulação e a sigla FASE, os códigos polifásicos ou politemporais.

Tabela 4 – Matriz de Confusão Geral gerada com os sinais de treinamento (classificador Elman)

**Matriz de Confusão (Dados de Treino) - Elman**

True Class	Predicted Class												Accuracy	
	BARKER	FRANK	LFM	P1	P2	P3	P4	PSM	T1	T2	T3	T4	93.0%	7.0%
BARKER	911	9	1	13		1	1		12	21	11		93.0%	7.0%
FRANK	1	751	1	69	25	74	48		3	2	2	4	76.6%	23.4%
LFM	7	8	893	32		15	2		6	15	2		91.1%	8.9%
P1	1	48		816	51	30	30		3	1			83.3%	16.7%
P2	1	48		97	777	24	30		2	1			79.3%	20.7%
P3		62	20	39	11	754	60			12		22	76.9%	23.1%
P4		36	1	51	22	67	791		3	3		6	80.7%	19.3%
PSM				7	22	1	1	881		33		35	89.9%	10.1%
T1	137	23		13		3	3		771	8	14	8	78.7%	21.3%
T2	8	8	5	10	1	4	1	34	1	905	2	1	92.3%	7.7%
T3	25	6	8	9	2		1		32	6	885	6	90.3%	9.7%
T4	4	11	4	11	1	3	2		1	9	10	924	94.3%	5.7%

83.2%	74.4%	95.7%	69.9%	85.2%	77.3%	81.5%	96.3%	92.4%	89.1%	95.6%	91.8%
16.8%	25.6%	4.3%	30.1%	14.8%	22.7%	18.5%	3.7%	7.6%	10.9%	4.4%	8.2%

Fonte: Elaborado pelo autor (2023).

Além disso, como este classificador possui a particularidade de possuir duas células classificadoras em sua arquitetura, apresenta-se, na Tabela 5, os resultados da *rede1*, pois os erros gerados por essa célula influenciam diretamente na classificação realizada pela *rede2*.

Tabela 5 – Matriz de Confusão gerada com os sinais de treinamento (*rede1* Elman)

**Matriz de Confusão (Dados de Treino) – *rede1* - Elman**

True Class	Predicted Class				Accuracy	
	Barker	FASE	LFM	PSM	59.4%	40.6%
Barker	582	397	1		59.4%	40.6%
FASE	138	8609	39	34	97.6%	2.4%
LFM		87	893		91.1%	8.9%
PSM		99		881	89.9%	10.1%

80.8%	93.7%	95.7%	96.3%
19.2%	6.3%	4.3%	3.7%

Fonte: Elaborado pelo autor (2023).

Sinais que não são polifásicos ou politemporais, mas que assim foram classificados pela *rede1* (587 no total), implicam, necessariamente, na classificação errônea da *rede2*, pois não há outra alternativa para esta célula, se não a classificação destes sinais em um dos tipos de modulação polifásicos ou politemporais. Além destes, os sinais que são polifásicos ou



Tabela 7 – Matriz de Confusão Geral gerada com os sinais do conjunto de teste (classificador Elman)

**Matriz de Confusão (Dados de Teste) - Elman**

True Class	Predicted Class												Accuracy	
	BARKER	FRANK	LFM	P1	P2	P3	P4	PSM	T1	T2	T3	T4	Accuracy	Loss
BARKER	395	4		2		2	1		5	8	2	1	94.0%	6.0%
FRANK	3	311	1	31	21	25	24			2		2	74.0%	26.0%
LFM	2	4	382	14	1	3	2		4	7	1		91.0%	9.0%
P1		24		335	24	12	22		2			1	79.8%	20.2%
P2	1	21		41	332	11	10		2			2	79.0%	21.0%
P3		16	11	18	8	314	41		1	5		6	74.8%	25.2%
P4		19		35	7	29	321			1	2	6	76.4%	23.6%
PSM		1	1	7	4			380		16	1	10	90.5%	9.5%
T1	60	8	3	1		3			328	3	12	2	78.1%	21.9%
T2	7	3	1	8	2	1	1	11	2	381	1	2	90.7%	9.3%
T3	14	3	7	5					18	4	364	5	86.7%	13.3%
T4	1	10	6	2	2	2			2	1		394	93.8%	6.2%

Accuracy		Loss		Accuracy		Loss		Accuracy		Loss		Accuracy		Loss	
BARKER	FRANK	LFM	P1	P2	P3	P4	PSM	T1	T2	T3	T4	BARKER	FRANK	LFM	P1
81.8%	73.3%	92.7%	67.1%	82.8%	78.1%	76.1%	97.2%	90.1%	89.0%	95.0%	91.4%	18.2%	26.7%	7.3%	32.9%

Fonte: Elaborado pelo autor (2023).

Com base na comparação entre as Tabelas 4 e 7, nota-se que a taxa de acerto deste classificador com os sinais do conjunto de treinamento é superior à taxa de acerto com os sinais do conjunto de teste. Isso ocorre pelo fato dos sinais do conjunto de teste serem diferentes dos sinais presentes no conjunto de treinamento, além de não terem sido utilizados para ajustar os parâmetros do classificador. É natural, então, que ocorra uma pequena redução na taxa de acertos, não só neste classificador, mas também nos demais classificadores presentes neste trabalho, ainda que isso seja indesejável.

Além disso, é possível perceber que o percentual de acertos de classificação deste algoritmo ficou aquém do desejado, principalmente nas classes Barker, P1, P2, P3, P4 e Frank, cujas taxas de erro de classificação foram de 18,2%, 32,9%, 17,2%, 21,9%, 23,9% e 26,7%, respectivamente. Esses são os percentuais dos Falsos Positivos. 32,9% dos sinais classificados como P1 não são dessa classe, sendo, portanto, a classe menos confiável. Além desses números, outros que chamam a atenção são as taxas de acertos referentes aos sinais com modulação P1, P2, P3, P4, Frank e T1. Todos apresentaram taxa de acerto inferior à 80%. Em outras palavras, de todos os sinais com essas modulações, menos de 80% foram classificados como tal. Isso denota uma quantidade de erros considerável para sinais dessas classes.

Tabela 8 – Matriz de Confusão gerada com os sinais do conjunto de teste (*rede1* Elman)

**Matriz de Confusão (Dados de Teste) – *rede1* - Elman**

True Class	Predicted Class					
	Barker	FASE	LFM	PSM		
Barker	249	171			59.3%	40.7%
FASE	59	3681	29	11	97.4%	2.6%
LFM	1	37	382		91.0%	9.0%
PSM		39	1	380	90.5%	9.5%
	80.6%	93.7%	92.7%	97.2%		
	19.4%	6.3%	7.3%	2.8%		
	Barker	FASE	LFM	PSM		

Fonte: Elaborado pelo autor (2023).

Analisando a matriz de confusão da *rede1* com os sinais do conjunto de teste (Tabela 8), percebe-se uma alta taxa de acertos (97,2%) na classe dos pulsos sem modulação (PSM), apesar do grande percentual de erros de classificação na classe Barker (19,4%), sendo essa a classe menos confiável. Ao analisar os sinais que não são polifásicos ou politemporais, mas que foram considerados como tal, observa-se uma porcentagem relativamente pequena (6,3%), mas que ainda assim gerou um problema de classificação para a *rede2*. Em relação aos polifásicos ou politemporais que não foram classificados como são, a porcentagem cai ainda mais (2,6%), sendo um ponto positivo na análise da classificação da *rede1*. Nota-se também que a *rede1* tem pouca capacidade de classificar sinais modulados com Barker13. A taxa de acerto é de apenas 59,3%.

Na Tabela 9, estão dispostas as matrizes de confusão gerais para diferentes valores de SNR, procurando analisar com mais detalhes o principal fator causador de erros de classificação, que é a baixa relação SNR. Na análise, destaca-se a alta taxa de acertos para sinais que possuem SNR acima de 0 dB em quase todos os tipos de modulação assim como ocorreu com os sinais do conjunto de treinamento. A maior quantidade de erros ocorreu na classe Barker, em que 14,3% dos pulsos foram classificados erroneamente como Barker, sendo que 80% deles possuem modulação do tipo T1. Somente os sinais com modulação de fase T1 proporcionam uma taxa de erro considerável, 13,3%.

A quantidade de erros gerados pelos sinais com  $SNR < 0$  dB foi notoriamente alta. Isso denota pouca confiabilidade deste classificador em casos de baixa SNR. Portanto, este classificador não possui alta confiabilidade para classificar sinais modulados em fase em todos



Tabela 10 – Matriz de Confusão Geral gerada com os sinais de treinamento (classificador CNN)

**Matriz de Confusão (Dados de Treino) - CNN**

True Class	Barker	FRANK	LFM	P1	P2	P3	P4	PSM	T1	T2	T3	T4	Accuracy	Loss
Barker	973		1		2				2	2			99.3%	0.7%
FRANK		959		5	3	12	1						97.9%	2.1%
LFM			979								1		99.9%	0.1%
P1		2		971	1	2	3			1			99.1%	0.9%
P2		1		3	974	1	1						99.4%	0.6%
P3		2		2	3	968	2		2		1		98.8%	1.2%
P4		5	2	10	5	4	951				3		97.0%	3.0%
PSM								980					100.0%	
T1	1	1			1	2			974		1		99.4%	0.6%
T2	1				1	2	1			975			99.5%	0.5%
T3					1						979		99.9%	0.1%
T4			1			1		1				977	99.7%	0.3%

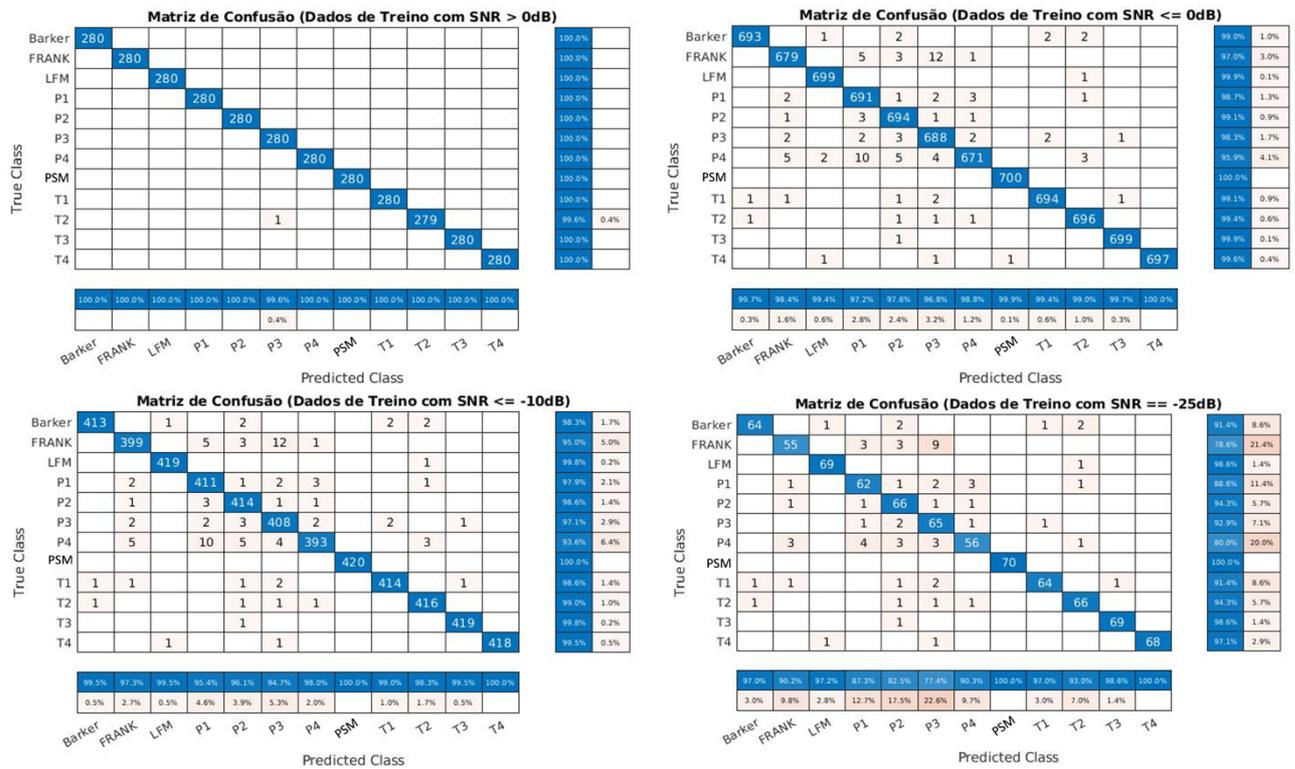
99.8%	98.9%	99.6%	98.0%	98.3%	97.6%	99.2%	99.9%	99.6%	99.3%	99.8%	100.0%
0.2%	1.1%	0.4%	2.0%	1.7%	2.4%	0.8%	0.1%	0.4%	0.7%	0.2%	

Predicted Class

Fonte: Elaborado pelo autor (2023).

De acordo com as informações obtidas na Tabela 11, é possível perceber que os maiores erros deste classificador ocorrem com sinais que possuem modulação polifásica e Barker13, apesar de serem consideravelmente baixos para sinais com SNR de menor ou igual a -10dB. Para esse classificador, quando um sinal com SNR menor ou igual a -10dB é classificado como P1, P2 ou P3, a classificação é menos confiável. Em outras palavras, sinais com outras modulações, quando são classificados erroneamente, são frequentemente classificados como sendo P1, P2 ou P3. Em contrapartida, quando um sinal é classificado como sendo da classe T4 ou PSM, a classificação é bastante confiável, mesmo em casos de SNR muito baixa. Esse comportamento também pode ser observado com os sinais do conjunto de testes. Sinais com modulação Frank e P4 são classificados com as menores taxas de acerto.

Tabela 11 – Matrizes de Confusão geradas com os sinais do conjunto de treinamento em diferentes SNR (CNN)



Fonte: Elaborado pelo autor (2023).

A partir da Tabela 12, pode-se verificar a maior taxa de acertos com o conjunto de sinais de teste – para todos os tipos de modulação de sinais – comparando com os demais classificadores testados neste estudo. As maiores taxas de erros de classificação, entretanto, foram geradas para os sinais das classes P1, P2 e P3, com 6,5%, 6,6% e 8,4%, respectivamente. Ainda que existam erros de classificação (Tabela 12), analisando os sinais de cada uma das classes, pode-se afirmar que este classificador possui uma capacidade notadamente superior de classificação quando comparado com o primeiro.



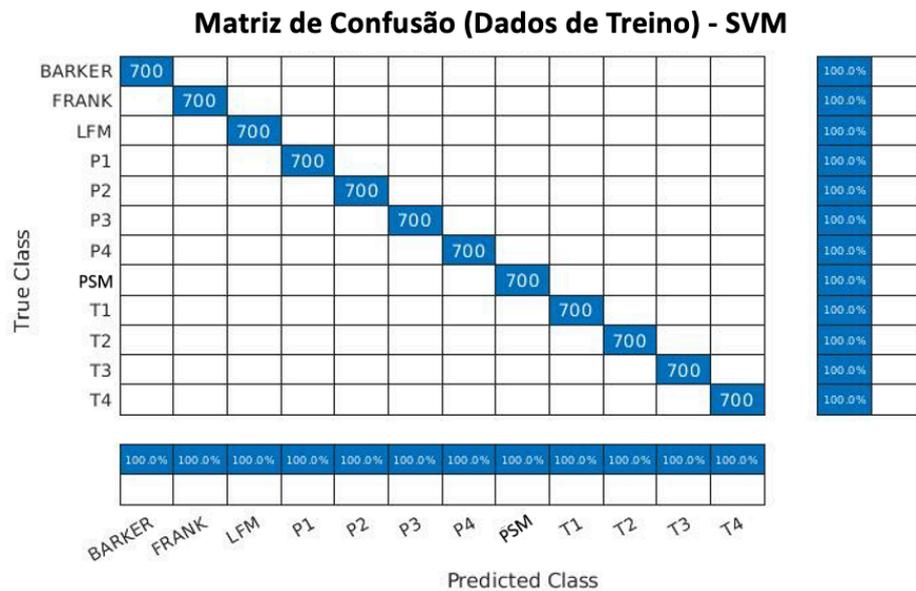
dB), a maior dificuldade deste classificador é ressaltada. A classe P3, seguida pelas classes P2, Frank e P1, são as classes menos confiáveis. Para os sinais com SNR menor ou igual a -10 dB, os sinais modulados com P4 e Frank são os únicos que proporcionam uma taxa de classificação correta menor do que 85%. Além disso, ressalta-se que 9 dos 30 sinais com modulação P4 foram classificados como sendo da classe P1 para uma SNR de -25 dB.

As classificações erradas produzidas pelo classificador baseado na CNN e elencadas no parágrafo anterior podem ser esperadas ao analisar a resposta à transformada STFT (Figura 32). Observando os respectivos espectrogramas, as modulações polifásicas (P1, P2, P3, P4 e Frank) possuem padrões muito parecidos. A rede CNN, por procurar reproduzir a compreensão humana a partir da visão (Seção 3.5), realizou uma maior taxa de erros de classificação para os sinais dessas classes.

### 5.3 Resultados do Classificador baseado na SVM

Com o intuito de fazer uma análise semelhante à feita na Seção 5.2, as Tabelas 14 a 17 remetem às matrizes de confusão geradas com os sinais do conjunto de treinamento e de teste.

Tabela 14 – Matriz de Confusão Geral gerada com os sinais de treinamento (classificador SVM)



Fonte: Elaborado pelo autor (2023).

No classificador baseado na SVM, é possível notar que a classificação dos sinais do conjunto de treinamento foram inteiramente acertados independentemente da SNR das amostras (Tabela 14). Isso remete ao fato de que a *kernel* polinomial de grau 2 foi eficaz para a classificação de todos os sinais do conjunto de treinamento. A representação das matrizes de

confusão com intervalos de SNR distintos, diferentemente do ocorrido nas Seções 5.1 e 5.2, não foi disposta nesta Seção, pois a taxa de acerto foi de 100% em todos os casos.

No entanto, na investigação dos resultados produzidos com os sinais do conjunto de testes (Tabela 15), o desempenho do classificador diminuiu consideravelmente. Nesse sentido, uma possível justificativa para os erros de classificação, além das diferentes características entre os sinais do conjunto de treinamento e de teste, é o *overfitting*. O *overfitting* ocorre quando um classificador se especializa muito nos dados de treinamento, não conseguindo generalizar ou classificar dados novos (conjunto de teste). O sobreajuste indesejado do hiperplano resulta em um modelo que se ajusta muito bem aos sinais do conjunto de treinamento, mas não aos sinais do conjunto de teste (não utilizados no treino). No classificador baseado na CNN, o *overfitting* pode ser evitado com a função de ativação ReLU.

Tabela 15 – Matriz de Confusão Geral gerada com os sinais do conjunto de teste (classificador SVM)

**Matriz de Confusão (Dados de Teste) - SVM**

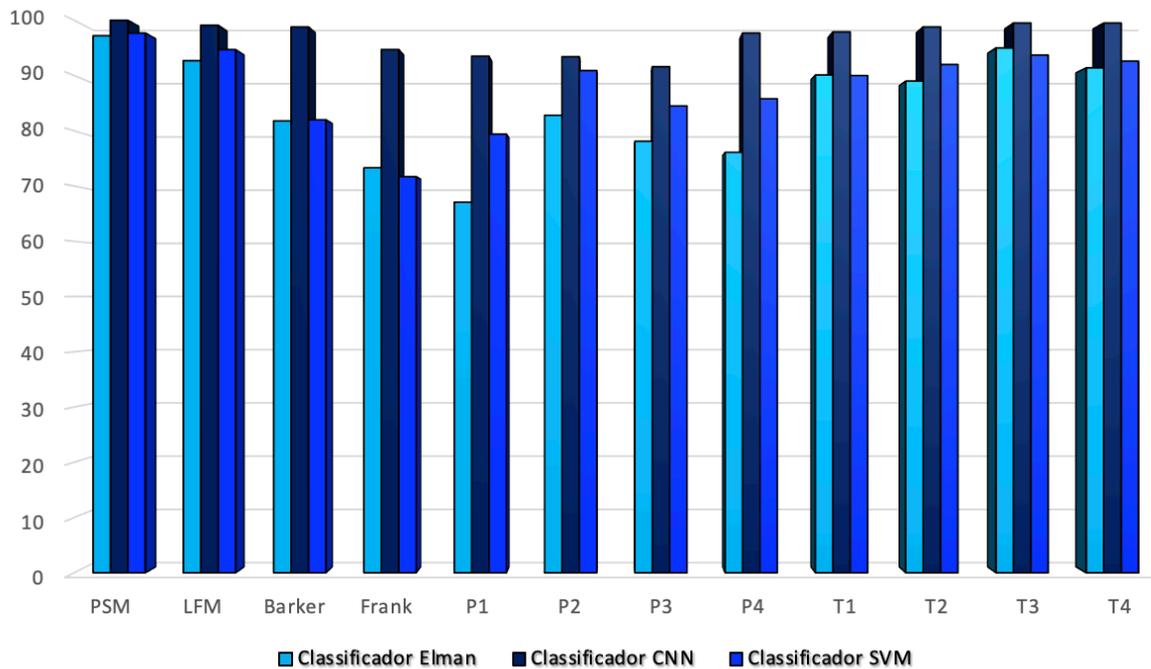
True Class	BARKER	645		9					1	23	20	1	1	92.1%	7.9%
	FRANK		560		99	34	2	5						80.0%	20.0%
	LFM	25		644						22	7	2		92.0%	8.0%
	P1		156		519	20	4	1						74.1%	25.9%
	P2		46		33	620	1							88.6%	11.4%
	P3		11		1	6	591	91						84.4%	15.6%
	P4		8		2	2	101	587						83.9%	16.1%
	PSM			3					673	1	1	10	12	96.1%	3.9%
	T1	50		13						618	14	1	4	88.3%	11.7%
	T2	41		10					1	21	621	5	1	88.7%	11.3%
	T3	10							3		3	651	33	93.0%	7.0%
	T4	16		1					11	2	9	25	636	90.9%	9.1%
			82.0%	71.7%	94.7%	79.4%	90.9%	84.5%	85.8%	97.7%	90.0%	92.0%	93.7%	92.6%	
		18.0%	28.3%	5.3%	20.6%	9.1%	15.5%	14.2%	2.3%	10.0%	8.0%	6.3%	7.4%		
		BARKER	FRANK	LFM	P1	P2	P3	P4	PSM	T1	T2	T3	T4		
		Predicted Class													

Fonte: Elaborado pelo autor (2023).

Os sinais referentes à SNR acima de 0 dB (Tabela 16) proporcionam uma alta percentagem de acertos de classificação, o que leva à conclusão de que este classificador é provavelmente confiável para sinais com essas SNR.



Figura 36 – Gráfico geral de taxa de acertos por classificador  
**Taxa geral de acertos de classificação com os sinais do conjunto de teste (%)**

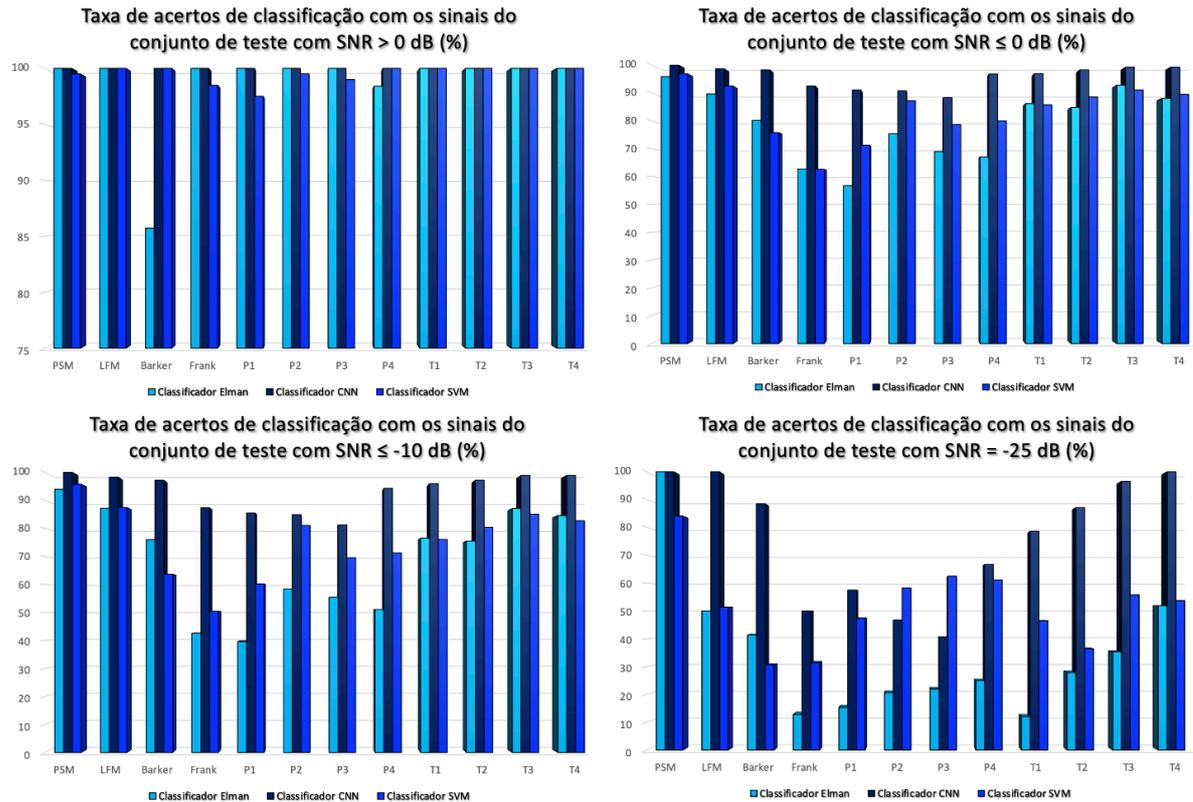


Fonte: Elaborado pelo autor (2023).

Para os sinais de todas as classes, o classificador CNN obteve a maior taxa de acertos. O classificador Elman obteve uma taxa maior de acerto em relação ao classificador SVM em apenas duas classes: Frank e T3.

De forma a permitir uma análise ainda mais simples e conclusiva acerca do classificador que mais se destacou na quantidade de acertos, a Figura 37 conta com 4 gráficos que permitem realizar uma investigação da taxa de acertos por classificador utilizando os sinais que foram analisados com as matrizes de confusão presentes no Capítulo 5, nas diferentes SNR.

Figura 37 – Gráficos de taxa de acertos por classificador utilizando sinais com diferentes SNR



Fonte: Elaborado pelo autor (2023).

Em relação à taxa de acertos, investigando os quatro gráficos apresentados na Figura 37, pode-se afirmar que o classificador CNN foi mais eficiente que os demais classificadores, sendo superado em apenas duas classes, P2 e P3, somente no caso da SNR ser de -25dB.

Examinando as Figuras 36 e 37, verifica-se que todos os classificadores possuem maior dificuldade em classificar os sinais modulados com Barker, Frank, P1, P2, P3 e P4 quando comparado com a taxa de acertos gerada utilizando os sinais com outros tipos de modulação. Também pode ser verificado que o classificador CNN é o único que consegue classificar sinais modulados com Barker13 eficientemente, mesmo nos casos em que a SNR é de -25dB (SNR muito baixa). Classificar sinais com modulação Barker13 é de grande relevância, pois as Fragatas Classe “Niterói” possuem esse tipo de modulação de fase em alguns modos de seus radares e, portanto, acredita-se que outros radares estrangeiros também utilizem esse tipo de modulação.

A partir dos resultados obtidos com as simulações e das análises feitas por meio dos gráficos (Figuras 36 e 37) e matrizes de confusão dispostas nas Tabelas 4 a 16, diferentes conclusões podem ser extraídas por meio de distintas interpretações das informações

explicitadas. Contudo, como a categorização dos classificadores em confiáveis ou não é consequência de algum processo de julgamento humano e complexo, torna-se importante determinar uma maneira de estimar quantitativamente a confiança que pode ser depositada nos classificadores de acordo com os resultados obtidos.

Desse modo, com o objetivo de mensurar mais adequadamente a confiabilidade dos classificadores testados, adota-se, nesta pesquisa, uma metodologia estatística proposta por (COHEN, 1960, p. 40).

Apesar dessa metodologia ter sido desenvolvida para examinar a confiabilidade de diagnósticos médicos na área de psicologia, neste trabalho, essa metodologia é utilizada como um teste estatístico para determinar o grau de confiabilidade dos classificadores comparados.

Nesse método, há quatro possibilidades de diagnóstico: verdadeiro-positivo (VP), verdadeiro-negativo (VN), falso-positivo (FP) e falso-negativo (FN) (HULLEY; CUMMINGS; BROWNER; *et al.*, 2007, p. 55-57, tradução nossa). Um exemplo das possibilidades de diagnóstico está indicado na Tabela 17. Neste estudo, o teste será realizado para os três classificadores de modo a comparar, estatisticamente, a confiabilidade de cada um. Espera-se que o classificador baseado na CNN, por ter obtido os melhores resultados em quase todos os testes realizados (Capítulo 5), demonstre maior confiabilidade (Figuras 36 e 37).

Tabela 17 – Exemplo de Teste de Diagnósticos para a classificação da modulação P1

		<b>Classificação Estimada pelo Classificador CNN</b>	
		<b>Positivo</b> Estima-se que seja P1	<b>Negativo</b> Estima-se que não seja P1
Classe Verdadeira do Sinal	O sinal é P1	<b>Verdadeiro-Positivo (VP)</b> É P1 e foi classificado como P1 (Total: 405)	<b>Falso-Negativo (FN)</b> É P1, mas foi classificado como outro sinal (Total: 15)
	O sinal não é P1	<b>Falso-Positivo (FP)</b> Não é P1, mas foi classificado como P1 (Total: 28)	<b>Verdadeiro-Negativo (VN)</b> Não é P1 e não foi classificado como P1 (Total: 4592)

- **Verdadeiro:** a classificação está certa.
- **Falso:** a classificação está errada.

Fonte: Elaborado pelo autor (2023)

No método de Cohen, um índice denominado *kappa* é utilizado para a realização da análise estatística sobre duas coleções de dados com o fito de estabelecer uma razão de concordância entre elas (COHEN, 1960, p. 41, tradução nossa). No nosso caso de estudo, as

duas coleções são o gabarito da classificação e a classificação gerada por um classificador. Os valores do *kappa* são obtidos por meio da Equação 25, gerando valores não inteiros no intervalo [-1; 1] (COHEN, 1960, p. 41, tradução nossa).

$$kappa = \frac{P_o - P_e}{1 - P_e} \quad (25)$$

Na Equação 25,  $P_o$  representa a proporção de concordância observada e  $P_e$  a proporção de concordância estimada (DE SOUZA, 2022, p. 34). Seus valores são obtidos de acordo com as Equações 26 e 27.

$$P_o = \frac{VP + VN}{VP + FN + FP + VN} \quad (26)$$

$$P_e = \frac{(VP + FN)(VP + FP) + (FP + VN)(FN + VN)}{(VP + FN + FP + VN)^2} \quad (27)$$

O índice *kappa* pode também ser entendido como nível de concordância, isto é, uma padronização estatística para um correto julgamento acerca da confiabilidade de determinada ferramenta de teste. No caso do presente trabalho, retrata a confiabilidade de cada classificador.

Para manter uma nomenclatura consistente ao descrever a confiabilidade do classificador, são atribuídas categorias para os diferentes intervalos de valores do índice *kappa*. Sendo assim, seus resultados são categorizados de acordo com uma escala definida por Landis e Koch (1977, p. 165, tradução nossa) conforme a Tabela 18. Embora essas divisões ainda sejam arbitrárias, elas servem como referências úteis para a discussão do exemplo hipotético acerca do correto diagnóstico de um paciente mentalmente doente, assim como para uma aceitação de confiabilidade de um classificador.

Tabela 18 – Escala do nível de concordância (kappa)

Índice <i>kappa</i>	Força da Concordância
< 0,00	Nenhuma
0,00 – 0,20	Irrisória
0,21– 0,40	Muito Fraca
0,41 – 0,60	Fraca
0,61 – 0,80	Regular
0,81 – 0,90	Boa
0,91 – 0,96	Muito Boa
0,97 – 0,99	Excelente
1,00	Perfeita

Fonte: Elaborado pelo autor (2023).

A Tabela 19 apresenta, de maneira simplificada, os valores obtidos a partir da Tabela 7 com o propósito de reunir os dados que são relevantes para os cálculos do nível de concordância (confiabilidade) do classificador baseado na Rede Neural de Elman. Adicionado à isso, foram acrescentados os resultados do índice *kappa* ao serem aplicadas as Equações 25, 26 e 27 e a sua respectiva força de concordância.

Tabela 19 – Verificação do nível de concordância do classificador baseado na Rede Neural de Elman

Dados Gerais (Todas as SNR)						
	VP	FN	FP	VN	<i>Kappa</i>	Força da Concordância
<b>PSM</b>	380	40	11	4609	93,16%	Muito boa
<b>LFM</b>	382	38	30	4590	91,09%	Muito boa
<b>BARKER</b>	395	25	88	4532	86,26%	Boa
<b>FRANK</b>	311	109	113	4507	71,29%	Regular
<b>P1</b>	335	85	164	4456	70,21%	Regular
<b>P2</b>	332	88	69	4551	79,18%	Regular
<b>P3</b>	314	106	88	4532	74,30%	Regular
<b>P4</b>	321	99	101	4519	74,08%	Regular
<b>T1</b>	328	92	36	4584	82,30%	Boa
<b>T2</b>	381	39	47	4573	88,93%	Boa
<b>T3</b>	364	56	19	4601	89,85%	Boa
<b>T4</b>	394	26	37	4583	91,91%	Muito boa

Fonte: Elaborado pelo autor (2023).

Na Tabela 20, foram considerados diferentes valores de SNR de forma a permitir a verificação da confiabilidade de cada classificador em questão, especificamente nos casos de maior dificuldade ( $\text{SNR} \leq 0 \text{ dB}$ ) e de menor dificuldade ( $\text{SNR} > 0 \text{ dB}$ ) de classificação.

Tabela 20 – Verificação do nível de concordância com diferentes SNR (Elman)

SNR > 0dB							SNR ≤ 0dB						
	VP	FN	FP	VN	Kappa	Força da Concordância		VP	FN	FP	VN	Kappa	Força da Concordância
PSM	120	0	0	1320	100,00%	Perfeita	PSM	260	40	11	3289	90,30%	Boa
LFM	120	0	0	1320	100,00%	Perfeita	LFM	262	38	30	3270	87,48%	Boa
BARKER	120	0	20	1300	91,55%	Muito boa	BARKER	275	25	68	3232	84,13%	Boa
FRANK	120	0	0	1320	100,00%	Perfeita	FRANK	191	109	113	3187	59,88%	Fraca
P1	120	0	0	1320	100,00%	Perfeita	P1	215	85	164	3136	59,57%	Fraca
P2	120	0	0	1320	100,00%	Perfeita	P2	212	88	69	3231	70,61%	Regular
P3	118	2	0	1320	99,08%	Excelente	P3	196	104	88	3212	64,22%	Regular
P4	120	0	2	1318	99,10%	Excelente	P4	201	99	99	3201	64,00%	Regular
T1	104	16	0	1320	92,26%	Muito boa	T1	224	76	36	3264	78,32%	Regular
T2	118	2	0	1320	99,08%	Excelente	T2	263	37	47	3253	84,96%	Boa
T3	118	2	0	1320	99,08%	Excelente	T3	246	54	19	3281	85,98%	Boa
T4	120	0	0	1320	100,00%	Perfeita	T4	274	26	37	3263	88,73%	Boa
SNR ≤ -10dB							SNR = -25dB						
	VP	FN	FP	VN	Kappa	Força da Concordância		VP	FN	FP	VN	Kappa	Força da Concordância
PSM	140	40	9	1971	83,89%	Boa	PSM	3	27	0	330	16,92%	Irrisória
LFM	143	37	21	1959	81,68%	Boa	LFM	4	26	4	326	18,18%	Irrisória
BARKER	155	25	49	1931	78,86%	Regular	BARKER	12	18	17	313	35,38%	Muito Fraca
FRANK	79	101	107	1873	37,91%	Muito Fraca	FRANK	6	24	41	289	6,02%	Irrisória
P1	103	77	157	1823	41,01%	Fraca	P1	9	21	50	280	10,32%	Irrisória
P2	97	83	69	1911	52,25%	Fraca	P2	7	23	27	303	14,29%	Irrisória
P3	97	83	78	1902	50,59%	Fraca	P3	7	23	25	305	15,29%	Irrisória
P4	93	87	89	1891	46,93%	Fraca	P4	9	21	27	303	20,00%	Irrisória
T1	117	63	36	1944	67,80%	Regular	T1	3	27	22	308	3,61%	Irrisória
T2	145	35	47	1933	75,88%	Regular	T2	12	18	31	299	25,57%	Muito Fraca
T3	128	52	19	1961	76,53%	Regular	T3	6	24	11	319	20,75%	Muito Fraca
T4	154	26	28	1952	83,72%	Boa	T4	14	16	13	317	44,76%	Fraca

Fonte: Elaborado pelo autor (2023).

Em conformidade com a conclusão da análise realizada para o classificador baseado na Rede Neural de Elman (Seção 5.1), nota-se que suas forças de concordância chegam a ser irrisórias em diversas modulações quando a SNR é igual a -25 dB (Tabela 20). Ademais, níveis como muito fraca, fraca e regular também foram frequentes nos resultados obtidos com o teste de nível de concordância para  $SNR \leq 0$  dB. Isso demonstra a incapacidade do classificador em classificar eficientemente a modulação dos sinais nesses níveis de SNR.

As Tabelas 21 e 22 a seguir apresentam as mesmas informações das Tabelas 19 e 20, porém representam os níveis de concordância em relação ao classificador baseado na SVM.

Tabela 21 – Verificação do nível de concordância do classificador baseado na SVM

Dados Gerais (Todas as SNR)						
	VP	FN	FP	VN	Kappa	Força da Concordância
PSM	673	27	16	7034	96,60%	Muito boa
LFM	644	56	36	7014	92,68%	Muito boa
BARKER	645	55	142	6908	85,35%	Boa
FRANK	560	140	221	6829	73,06%	Regular
P1	519	181	135	6915	74,43%	Regular
P2	620	80	62	6988	88,72%	Boa
P3	591	109	108	6942	82,95%	Boa
P4	587	113	97	6953	83,34%	Boa
T1	618	82	69	6981	88,04%	Boa
T2	621	79	54	6996	89,39%	Boa
T3	651	49	44	7006	92,67%	Muito boa
T4	636	64	51	6999	90,89%	Muito boa

Fonte: Elaborado pelo autor (2023).

Tabela 22 – Verificação do nível de concordância com diferentes SNR (SVM)

SNR > 0dB							SNR ≤ 0dB						
	VP	FN	FP	VN	Kappa	Força da Concordância		VP	FN	FP	VN	Kappa	Força da Concordância
PSM	200	0	1	2199	99,73%	Excelente	PSM	473	27	15	5485	95,37%	Muito boa
LFM	200	0	0	2200	100,00%	Perfeita	LFM	444	56	36	5464	89,78%	Boa
BARKER	200	0	0	2200	100,00%	Perfeita	BARKER	445	55	142	5358	80,08%	Regular
FRANK	195	5	3	2197	97,81%	Excelente	FRANK	365	135	218	5282	64,19%	Regular
P1	196	4	5	2195	97,55%	Excelente	P1	323	177	130	5370	65,01%	Regular
P2	200	0	1	2199	99,73%	Excelente	P2	420	80	61	5439	84,35%	Boa
P3	200	0	2	2198	99,46%	Excelente	P3	391	109	106	5394	76,48%	Regular
P4	198	2	0	2200	99,45%	Excelente	P4	389	111	97	5403	77,02%	Regular
T1	200	0	0	2200	100,00%	Perfeita	T1	418	82	69	5431	83,33%	Boa
T2	200	0	0	2200	100,00%	Perfeita	T2	421	79	54	5446	85,15%	Boa
T3	200	0	0	2200	100,00%	Perfeita	T3	451	49	44	5456	89,81%	Boa
T4	199	1	0	2200	99,73%	Excelente	T4	437	63	51	5449	87,43%	Boa

SNR ≤ -10dB							SNR = -25dB						
	VP	FN	FP	VN	Kappa	Força da Concordância		VP	FN	FP	VN	Kappa	Força da Concordância
PSM	274	26	12	3288	92,94%	Muito boa	PSM	37	13	7	543	76,92%	Regular
LFM	244	56	35	3265	82,91%	Boa	LFM	19	31	18	532	39,38%	Muito Fraca
BARKER	245	55	140	3160	68,59%	Regular	BARKER	26	24	59	491	31,31%	Muito Fraca
FRANK	190	110	187	3113	51,64%	Fraca	FRANK	22	28	48	502	29,85%	Muito Fraca
P1	157	143	104	3196	52,27%	Fraca	P1	18	32	20	530	36,33%	Muito Fraca
P2	223	77	52	3248	75,62%	Regular	P2	28	22	20	530	53,33%	Fraca
P3	210	90	92	3208	67,01%	Regular	P3	25	25	15	535	52,00%	Fraca
P4	203	97	82	3218	66,70%	Regular	P4	33	17	21	529	60,00%	Fraca
T1	220	80	69	3231	72,45%	Regular	T1	20	30	23	527	38,25%	Muito Fraca
T2	222	78	54	3246	75,09%	Regular	T2	16	34	28	522	28,46%	Muito Fraca
T3	251	49	44	3256	82,96%	Boa	T3	24	26	19	531	47,57%	Fraca
T4	240	60	50	3250	79,69%	Regular	T4	29	21	25	525	51,58%	Fraca

Fonte: Elaborado pelo autor (2023).

Em relação ao classificador SVM, nota-se uma considerável melhora quando em comparação com o inspirado na Rede Neural de Elman principalmente pelo fato de suas classificações não terem resultado em forças de concordância irrisórias. Níveis de força muito fracos e fracos também aparecem com menos frequência nas tabelas do classificador que utiliza a SVM quando em comparação com o primeiro. Entretanto, ao serem considerados os resultados do classificador baseado na CNN (Tabelas 23 e 24), nota-se uma grande diferença entre a confiabilidade dos três. Uma comparação mais aprofundada com o índice *kappa* está descrita na conclusão do trabalho (Capítulo 6).

Tabela 23 – Verificação do nível de concordância do classificador baseado na CNN

Dados Gerais (Todas as SNR)						
	VP	FN	FP	VN	Kappa	Força da Concordância
PSM	420	0	0	4620	100,00%	Perfeita
LFM	418	2	4	4616	99,22%	Excelente
BARKER	413	7	5	4615	98,44%	Excelente
FRANK	392	28	22	4598	93,46%	Muito boa
P1	405	15	28	4592	94,49%	Muito boa
P2	397	23	28	4592	93,41%	Muito boa
P3	394	26	36	4584	92,03%	Muito boa
P4	388	32	9	4611	94,54%	Muito boa
T1	411	9	9	4611	97,66%	Excelente
T2	416	4	5	4615	98,83%	Excelente
T3	418	2	2	4618	99,48%	Excelente
T4	418	2	2	4618	99,48%	Excelente

Fonte: Elaborado pelo autor (2023).

Tabela 24 – Verificação do nível de concordância com diferentes SNR (CNN)

SNR > 0dB							SNR ≤ 0dB						
	VP	FN	FP	VN	Kappa	Força da Concordância		VP	FN	FP	VN	Kappa	Força da Concordância
PSM	120	0	0	1320	100,00%	Perfeita	PSM	300	0	0	3300	100,00%	Perfeita
LFM	120	0	0	1320	100,00%	Perfeita	LFM	298	2	4	3296	98,91%	Excelente
BARKER	120	0	0	1320	100,00%	Perfeita	BARKER	293	7	5	3295	97,81%	Excelente
FRANK	120	0	0	1320	100,00%	Perfeita	FRANK	272	28	21	3279	91,00%	Muito boa
P1	120	0	0	1320	100,00%	Perfeita	P1	285	15	28	3272	92,33%	Muito boa
P2	120	0	0	1320	100,00%	Perfeita	P2	277	23	28	3272	90,80%	Muito boa
P3	120	0	0	1320	100,00%	Perfeita	P3	274	26	36	3264	88,90%	Boa
P4	120	0	0	1320	100,00%	Perfeita	P4	268	32	9	3291	92,28%	Muito boa
T1	120	0	0	1320	100,00%	Perfeita	T1	291	9	9	3291	96,73%	Excelente
T2	120	0	0	1320	100,00%	Perfeita	T2	296	4	5	3295	98,37%	Excelente
T3	120	0	0	1320	100,00%	Perfeita	T3	298	2	2	3298	99,27%	Excelente
T4	120	0	0	1320	100,00%	Perfeita	T4	298	2	2	3298	99,27%	Excelente

SNR ≤ -10dB							SNR = -25dB						
	VP	FN	FP	VN	Kappa	Força da Concordância		VP	FN	FP	VN	Kappa	Força da Concordância
PSM	180	0	0	1980	100,00%	Perfeita	PSM	30	0	0	330	100,00%	Perfeita
LFM	178	2	3	1977	98,49%	Excelente	LFM	28	2	0	330	96,25%	Muito boa
BARKER	173	7	5	1975	96,35%	Excelente	BARKER	23	7	3	327	80,65%	Boa
FRANK	152	28	22	1958	84,62%	Boa	FRANK	15	15	15	315	45,45%	Fraca
P1	165	15	28	1952	87,38%	Boa	P1	23	7	17	313	62,11%	Regular
P2	157	23	28	1952	84,74%	Boa	P2	14	16	16	314	41,82%	Fraca
P3	155	25	36	1944	82,01%	Boa	P3	17	13	25	305	41,54%	Fraca
P4	148	32	9	1971	86,81%	Boa	P4	12	18	6	324	46,67%	Fraca
T1	171	9	9	1971	94,55%	Muito boa	T1	22	8	6	324	73,75%	Regular
T2	176	4	5	1975	97,28%	Excelente	T2	27	3	4	326	87,46%	Boa
T3	178	2	2	1978	98,79%	Excelente	T3	28	2	1	329	94,46%	Excelente
T4	178	2	2	1978	98,79%	Excelente	T4	28	2	0	330	96,25%	Excelente

Fonte: Elaborado pelo autor (2023).

## 6 CONCLUSÃO

A qualidade superior do classificador baseado na CNN na classificação dos tipos de modulação dos sinais analisados torna-se evidente quando comparamos os três classificadores (Tabela 25).

Tabela 25 – Comparação de confiabilidade entre os três classificadores

SNR > 0 dB							SNR ≤ 0 dB						
Modulação	CNN		SVM		Elman		Modulação	CNN		SVM		Elman	
	Kappa	Concordância	Kappa	Concordância	Kappa	Concordância		Kappa	Concordância	Kappa	Concordância	Kappa	Concordância
PSM	100,00%	Perfeita	99,73%	Excelente	100,00%	Perfeita	PSM	100,00%	Perfeita	95,37%	Muito boa	90,30%	Boa
LFM	100,00%	Perfeita	100,00%	Perfeita	100,00%	Perfeita	LFM	98,91%	Excelente	89,78%	Boa	87,48%	Boa
BARKER	100,00%	Perfeita	100,00%	Perfeita	91,55%	Muito boa	BARKER	97,81%	Excelente	80,08%	Regular	84,13%	Boa
FRANK	100,00%	Perfeita	97,81%	Excelente	100,00%	Perfeita	FRANK	91,00%	Muito boa	64,19%	Regular	59,88%	Fraca
P1	100,00%	Perfeita	97,55%	Excelente	100,00%	Perfeita	P1	92,33%	Muito boa	65,01%	Regular	59,57%	Fraca
P2	100,00%	Perfeita	99,73%	Excelente	100,00%	Perfeita	P2	90,80%	Muito boa	84,35%	Boa	70,61%	Regular
P3	100,00%	Perfeita	99,46%	Excelente	99,08%	Excelente	P3	88,90%	Boa	76,48%	Regular	64,22%	Regular
P4	100,00%	Perfeita	99,45%	Excelente	99,10%	Excelente	P4	92,28%	Muito boa	77,02%	Regular	64,00%	Regular
T1	100,00%	Perfeita	100,00%	Perfeita	92,26%	Muito boa	T1	96,73%	Excelente	83,33%	Boa	78,32%	Regular
T2	100,00%	Perfeita	100,00%	Perfeita	99,08%	Excelente	T2	98,37%	Excelente	85,15%	Boa	84,96%	Boa
T3	100,00%	Perfeita	100,00%	Perfeita	99,08%	Excelente	T3	99,27%	Excelente	89,81%	Boa	85,98%	Boa
T4	100,00%	Perfeita	99,73%	Excelente	100,00%	Perfeita	T4	99,27%	Excelente	87,43%	Boa	88,73%	Boa

SNR ≤ -10 dB							SNR = -25 dB						
Modulação	CNN		SVM		Elman		Modulação	CNN		SVM		Elman	
	Kappa	Concordância	Kappa	Concordância	Kappa	Concordância		Kappa	Concordância	Kappa	Concordância	Kappa	Concordância
PSM	100,00%	Perfeita	92,94%	Muito boa	83,89%	Boa	PSM	100,00%	Perfeita	76,92%	Regular	16,92%	Irrisória
LFM	98,49%	Excelente	82,91%	Boa	81,68%	Boa	LFM	96,25%	Muito boa	39,38%	Muito Fraca	18,18%	Irrisória
BARKER	96,35%	Excelente	68,59%	Regular	78,86%	Regular	BARKER	80,65%	Boa	31,31%	Muito Fraca	35,38%	Muito Fraca
FRANK	84,62%	Boa	51,64%	Fraca	37,91%	Muito Fraca	FRANK	45,45%	Fraca	29,85%	Muito Fraca	6,02%	Irrisória
P1	87,38%	Boa	52,27%	Fraca	41,01%	Fraca	P1	62,11%	Regular	36,33%	Muito Fraca	10,32%	Irrisória
P2	84,74%	Boa	75,62%	Regular	52,25%	Fraca	P2	41,82%	Fraca	53,33%	Fraca	14,29%	Irrisória
P3	82,01%	Boa	67,01%	Regular	50,59%	Fraca	P3	41,54%	Fraca	52,00%	Fraca	15,29%	Irrisória
P4	86,81%	Boa	66,70%	Regular	46,93%	Fraca	P4	46,67%	Fraca	60,00%	Fraca	20,00%	Irrisória
T1	94,55%	Muito boa	72,45%	Regular	67,80%	Regular	T1	73,75%	Regular	38,25%	Muito Fraca	3,61%	Irrisória
T2	97,28%	Excelente	75,09%	Regular	75,88%	Regular	T2	87,46%	Boa	28,46%	Muito Fraca	25,57%	Muito Fraca
T3	98,79%	Excelente	82,96%	Boa	76,53%	Regular	T3	94,46%	Excelente	47,57%	Fraca	20,75%	Muito Fraca
T4	98,79%	Excelente	79,69%	Regular	83,72%	Boa	T4	96,25%	Excelente	51,58%	Fraca	44,76%	Fraca

Fonte: Elaborado pelo autor (2023).

Com base nos resultados apresentados na Tabela 25, conclui-se que o classificador baseado na CNN é confiável para a classificação de sinais com SNR abaixo de -10 dB (até o valor mínimo de análise de -25 dB). Isso se dá porque a menor força de concordância foi considerada boa nesses casos.

Em relação às modulações polifásicas e T1, esse classificador produz uma menor taxa de acertos em relação às demais classes. Considerando todas as análises feitas no Capítulo 5 e a partir da Tabela 25, pode-se concluir que o classificador baseado na CNN foi o que proporcionou a classificação mais eficiente da modulação dos sinais (problema proposto neste estudo), atingindo resultados bastante animadores.

A única ressalva a ser considerada é a de que a taxa de acertos do classificador baseado na SVM na classificação das modulações P2 e P3, especificamente em ambientes cuja SNR seja igual a -25 dB, foram ligeiramente maiores que a do classificador proposto na Seção 4.2 (CNN). Nesse caso, a força de concordância para os dois classificadores (CNN e SVM) foi igual, porém o índice *kappa* para o classificador baseado na SVM foi ligeiramente maior. Sendo assim, este trabalho propõe algumas sugestões para tentar promover uma melhoria nos

classificadores apresentados na Seção 6.1.

## 6.1 Sugestões para trabalhos futuros

Existem diversas possibilidades de aprimoramento do classificador para se tentar alcançar maiores valores para as taxas de acerto de classificação. O emprego de outras técnicas de IA, como outros tipos de redes neurais ou o uso de arquiteturas diferentes para os classificadores podem gerar melhores taxas de acerto para a tarefa proposta. O emprego de outras topologias ou distribuições de classes no classificador da Rede Neural de Elman, por exemplo, pode melhorar os resultados obtidos. Da mesma maneira, o estudo de mudanças nas formas de extração de características dos sinais (como a utilização da transformada de Choi-Williams em vez da STFT) pode promover um aumento no número de acertos dos classificadores. Outras características extraídas dos sinais podem ser pesquisadas e testadas para a classificação.

Contudo, este trabalho sugere, principalmente, a aplicação do *Ensemble Learning* nos classificadores a serem desenvolvidos. No *Ensemble Learning*, classificadores treinados individualmente (como a CNN e a SVM) são combinados em uma arquitetura que promova uma maior precisão na classificação em detrimento da aplicação dos classificadores de forma individual (OPITZ; MACLIN, 1999, p. 169, tradução nossa). Segundo os mesmos autores, pesquisas prévias provaram a maior eficácia de classificadores que utilizam *Ensemble Learning*.

Obviamente, combinações de classificadores idênticos não produzem ganhos para a classificação. Além disso, segundo Opitz e Maclin (1999, p. 171, tradução nossa), o conjunto ideal de redes neurais para o emprego do *Ensemble Learning* consiste em classificadores que tenham boas taxas de acerto, mas que não concordem sempre. O classificador baseado na CNN, mesmo que com pouca frequência, tende a confundir mais a modulação P4 com a P1 (Tabela 12), enquanto que, o classificador SVM, a modulação P4 é mais frequentemente confundida com a Frank (Tabela 15). Essas discordâncias entre os classificadores podem ser exploradas para a aplicação do *Ensemble Learning* com o intuito de gerar uma classificação combinada mais precisa.

Nesse sentido, dois métodos podem ser utilizados: *Bagging* (BREIMAN, 1996) ou *Boosting*. O *Boosting* é uma técnica que combina classificadores fracos em série para gerar um único classificador forte. Nele, exemplos que foram incorretamente previstos pelos classificadores anteriores na série durante o treinamento são escolhidos com mais frequência

do que exemplos que foram previstos corretamente por meio de reajustes de pesos (OPITZ; MACLIN, 1999, p. 172, tradução nossa). Isso permite que o algoritmo se concentre nas instâncias que são mais difíceis de classificar durante o treinamento. Depois de treinados, o classificador forte (classificador final) produz a sua classificação combinando os classificadores fracos com pesos. Classificadores fracos com desempenhos melhores possuem peso maior na classificação final.

No entanto, a análise feita por Opitz e Maclin (1999) com 23 bancos de dados diferentes concluiu que a performance do *Boosting* produz piores resultados para sinais adicionados a ruído com maior energia. Por isso, este trabalho sugere a aplicação do método *Bagging*, mas nada impede que sejam feitas tentativas com o outro método.

No método *Bagging*, múltiplas versões de um mesmo modelo de Aprendizado de Máquina são criadas para combinar previsões e obter uma classificação ou regressão mais precisa (BREIMAN, 1996, p. 123, tradução nossa). A partir de um conjunto de dados de treinamento original, os classificadores fracos são treinados com diferentes subconjuntos de dados amostrados com reposição do conjunto de dados de treinamento original (OPITZ; MACLIN, 1999, p. 172-174, tradução nossa). Cada subconjunto de dados contém o mesmo tamanho que o conjunto de dados de treinamento original, mas pode conter alguns dados duplicados e outros ausentes, como na Figura 38. Esse procedimento é denominado *bootstrap* (BREIMAN, 1996, p. 123, tradução nossa).

Figura 38 – Conjuntos de treinamento hipotéticos de Bagging

<p><b>Exemplo de um classificador individual em um banco de dados imaginário.</b></p> <p><b>Conjuntos de Treinamento Original</b></p> <ul style="list-style-type: none"> <li>• Conjunto de Treinamento 1: 1, 2, 3, 4, 5, 6, 7, 8.</li> </ul>
<p><b>Um exemplo de <i>Bagging</i> com o mesmo banco de dados.</b></p> <p><b>Conjuntos de Treinamento <i>Bagging</i></b></p> <ul style="list-style-type: none"> <li>• Conjunto de Treinamento 1: 2, 7, 8, 3, 7, 6, 3, 1.</li> <li>• Conjunto de Treinamento 2: 7, 8, 5, 6, 4, 2, 7, 1.</li> <li>• Conjunto de Treinamento 3: 3, 6, 2, 7, 5, 6, 2, 2.</li> <li>• Conjunto de Treinamento 4: 4, 5, 1, 4, 6, 4, 3, 8.</li> </ul>

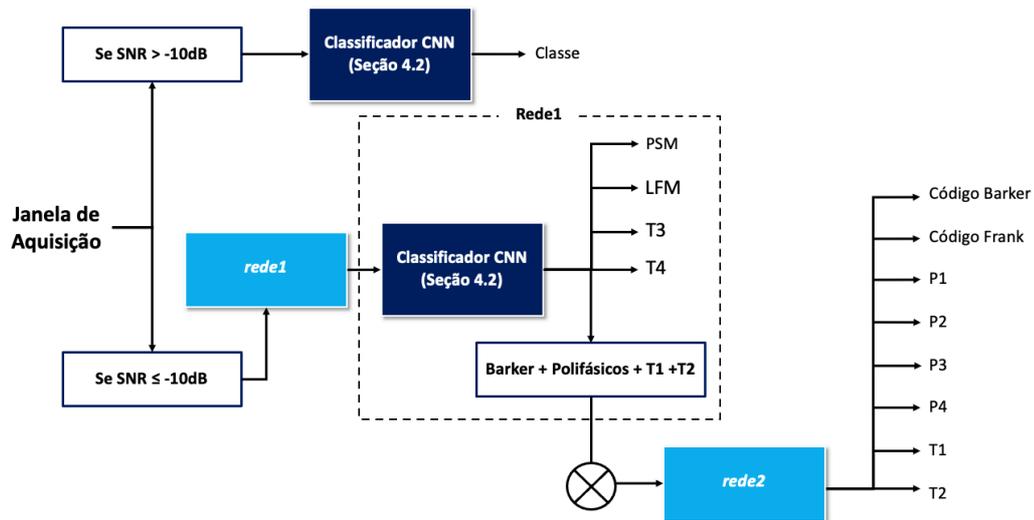
Fonte: Elaborado pelo autor (2023).

Um modelo de aprendizado de máquina (SVM e CNN) é treinado de forma independente com cada subconjunto de treinamento gerado. Isso significa que várias versões do mesmo modelo são treinadas, cada uma com um subconjunto de treinamento diferente. Quando é necessário fazer uma previsão para uma nova instância, as previsões de todas as versões dos modelos são combinadas. Ao final, para problemas de classificação, pode ser

realizada uma votação majoritária, onde a classe votada com maior frequência ou a classe de maior probabilidade média é escolhida como a classe final.

Numa das formas possíveis de promover o *Ensemble Learning* nos classificadores voltados para solucionar o problema deste trabalho, sugere-se a arquitetura a seguir (Figura 39).

Figura 39 – Sugestão de arquitetura para futuros trabalhos

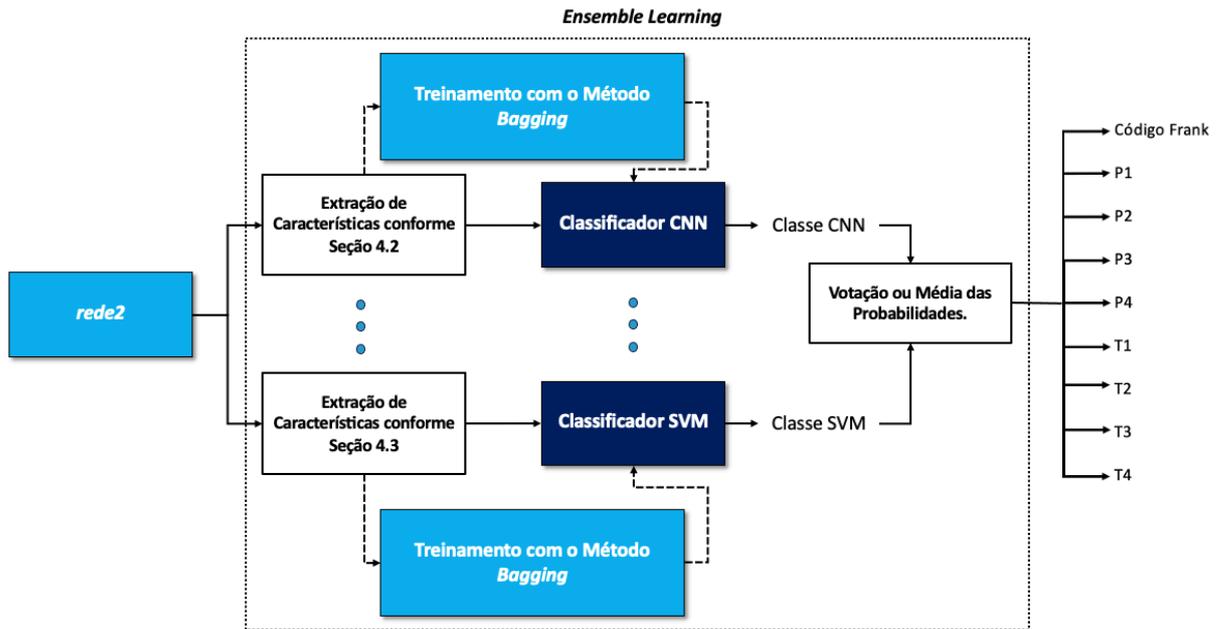


Fonte: Elaborado pelo autor (2023).

Nessa arquitetura, problemas com SNR acima de  $-10\text{dB}$  são puramente classificadas pela CNN, já que obteve resultados no mínimo bons para estas SNR. Caso o modelo estime que a SNR é abaixo disso, a tentativa de uma forma de *Ensemble Learning* entre os classificadores SVM e CNN, já que o SVM apresentou potencial para melhor classificar as modulações P2 e P3 em ambientes cuja SNR é de  $-25\text{dB}$ , pode ser uma boa estratégia. Nesse contexto, para as modulações Barker, polifásicas, T1 e T2, a rede 2 é acionada. Todos os outros tipos de modulações (PSM, LFM, T3 e T4) são ainda classificados apenas empregando o classificador CNN.

A arquitetura da rede 2 está descrita na Figura 40.

Figura 40 – Arquitetura da rede 2 sugerida



Fonte: Elaborado pelo autor (2023).

Na rede 2, diversas formas de extração de características podem ser exploradas de forma a fornecer diferentes entradas em vários classificadores baseados na CNN e na SVM, como exposto na Figura 40. Na saída da rede 2, a decisão de classificação é feita por uma votação ou a uma média das probabilidades. Um peso maior pode ser adicionado à decisão dos classificadores CNN, tendo em vista seus melhores resultados para as modulações Barker, T2 e T1, por exemplo. Os pesos adicionados às classificações das redes CNN e SVM permitem uma maior confiança na classificação final.

## REFERÊNCIAS

- ADDAN, D. **Support Vector Machine**. [S. l.], 2019. Unibrasil. Disponível em: <https://www.inf.ufpr.br/dagoncalves/IA07.pdf>. Acesso em: 18 set. 2023.
- AGGARWAL, C. **Social Network Data Analytics**. Boston: Springer, 2011. Disponível em: <http://charuaggarwal.net/socialintro.pdf>. Acesso em: 19 set. 2023.
- 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. Artigos [...]. Resende: Faculdades Dom Bosco, 2021. Sigla do Evento: XVIII SEGeT. Disponível em: <https://www.aedb.br/seget/artigos2021.php?pag=349> Acesso em: 18 ago. 2023.
- ANDRADE, L.; DA SILVA, I. **Redes Neurais Recorrentes de Elman para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 2011, São Carlos. Artigos [...]. São Carlos: Universidade de São Paulo, 2011. Disponível em: <https://fei.edu.br/sbai/SBAI2011/85231.pdf>. Acesso em: 17 ago. 2023.
- ANDREOLA, R.; HAERTEL, V. **Support Vector Machines na Classificação de Imagens Hiperespectrais**. In: XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009, Natal. Anais [...]. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2009. INPE. p. 6757-6764. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.13.18.03/doc/6757-6764.pdf?languagebutton=pt-BR>. Acesso em: 18 set. 2023.
- AWARI. **Machine Learning: Quem criou? História e desenvolvimento**. [S. l.], 2023. Disponível em: <https://awari.com.br/machine-learning-quem-criou-historia-e-desenvolvimento/#:~:text=O%20termo%20%E2%80%9CMachine%20Learning%E2%80%9D%20foi,aprender%20sem%20serem%20explicitamente%20programadas>. Acesso em: 22 set. 2023.
- BARKER, R. **Group Synchronizing of Binary Digital Systems**. *Communication Theory*. London: Butterworth, 1953. p. 273–287.
- BRASIL. Comando de Operações Navais. **ComOpNav-521 - Manual de Guerra Eletrônica**. Rio de Janeiro, 2003. Confidencial.
- BRASIL. Estado Maior da Armada. **EMA-305 – Doutrina Militar Naval**. Brasília, 2017.
- BREIMAN, L. **Bagging Predictors**. Boston: Kluwer Academic Publishers, 1996. n. 24. p. 123-140. Disponível em: <https://link.springer.com/article/10.1007/BF00058655>. Acesso em: 30 set. 2023.
- BUNDY, A.; ALLEN, L. **Catalogue of Artificial Intelligence Tools**. ed. 2. Berlim: Springer, 1986. Disponível em: <http://libgen.is/search.php?req=catalogue+of+artificial+intelligence+tools&open=0&res=25&view=simple&phrase=1&column=def>. Acesso em: 26 set. 2023.

CALLIOLI, C.; DOMINGUES, H.; COSTA, R. **Álgebra Linear e Aplicações**. Atual Editora, 1990. ed. 6. Disponível em: [https://brogdomonzao.files.wordpress.com/2011/10/algebra\\_linear\\_e\\_aplicacoes\\_-\\_callioli.pdf](https://brogdomonzao.files.wordpress.com/2011/10/algebra_linear_e_aplicacoes_-_callioli.pdf). Acesso em: 26 set. 2023.

CHILUKURI, R.; KAKARLA, H.; SUBBARAO, K. **Estimation of Modulation Parameters of LPI Radar Using Cyclostationary Method**. [S. l.]: Springer, 2020.

COHEN, J. **A Coefficient of Agreement for Nominal Scales**. In: Educational and Psychological Measurement. New York: SAGE Publications, 1960. v. 20. n. 1. p. 37-46. Disponível em: <https://w3.ric.edu/faculty/organic/coge/cohen1960.pdf>. Acesso em: 30 set. 2023.

DA CUNHA, L. **Redes Neurais Convolucionais e Segmentação de Imagens: Uma Revisão Bibliográfica**. 2020. Dissertação (Graduação em Engenharia de Controle e Automação) – Faculdade de Engenharia de Controle e Automação. Universidade Federal de Ouro Preto, Ouro Preto, 2020.

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

DE LIMA, R. **Avaliação do Algoritmo SVM na Detecção de Comportamentos Suspeitos em Cenas de Vídeo**. 2014. Dissertação (Graduação em Análise e Desenvolvimento de Sistemas) – Faculdade de Análise e Desenvolvimento de Sistemas. Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2014.

DE MORAES, M. **Princípios de Telecomunicações**. Londrina: Editora e Distribuidora Educacional S.A., 2018. Disponível em: [http://cm-kl-content.s3.amazonaws.com/201801/INTERATIVAS\\_2\\_0/PRINCIPIOS\\_DE\\_TELECOMUNICACOES/U1/LIVRO\\_UNICO.pdf](http://cm-kl-content.s3.amazonaws.com/201801/INTERATIVAS_2_0/PRINCIPIOS_DE_TELECOMUNICACOES/U1/LIVRO_UNICO.pdf). Acesso em: 20 set. 2023.

DE SOUZA, T. **Análise do Grau de Relevância da classificação dos sinais polifásicos para um estimador baseado em duas redes em cascata**. Dissertação (Pós-Graduação em Sistemas de Armas) – Faculdade de Ciências Navais, Centro de Instrução Almirante Wandenkolk, Rio de Janeiro, 2022.

DECASTRO, F. **ELC1149 Técnicas de Radar**. Santa Maria: Universidade Federal de Santa Maria, 2022. p. 1-222. Departamento de Eletrônica e Computação. Centro de Tecnologia. Disponível em: [http://www.fccdecastro.com.br/pdf/TR\\_CapI.pdf](http://www.fccdecastro.com.br/pdf/TR_CapI.pdf). Acesso em: 23 set. 2023.

DESHPANDE, A. **A Beginner's Guide to Understanding Convolutional Neural Networks**. **Adit Deshpande Blog**. 2016. Disponível em: <https://adeshpande3.github.io/A-Beginner's-Guide-To-Understanding-Convolutional-Neural-Networks/>. Acesso em: 18 set. 2023.

DUDA, R.; HART, P.; STORK, D. **Pattern classification**. New York: John Wiley & Sons Inc, 2001. ed. 2. Disponível em: [https://github.com/rohinarora/EECE5644-Machine\\_Learning/blob/master/Richard%20Duda%20Peter%20E.%20Hart%20David%20G.%20Stork%20-%20Pattern%20classification%20\(2001%20Wiley\).pdf](https://github.com/rohinarora/EECE5644-Machine_Learning/blob/master/Richard%20Duda%20Peter%20E.%20Hart%20David%20G.%20Stork%20-%20Pattern%20classification%20(2001%20Wiley).pdf). Acesso em: 25 set. 2023.

EBERMAM, E.; KROHLING, R. A. **Uma Introdução Compreensiva às Redes Neurais Convolucionais: Um Estudo de Caso para Reconhecimento de Caracteres Alfabéticos.** *In: Sistemas de Informação. [S. l.]: Revista Sistemas de Informação da FSMA, 2018. n. 22. p. 49-59.*

ELMAN, J. **Finding Structure in Time.** *In: Cognitive Science 14. San Diego, 1990. p. 179-211.* Disponível em: [http://wexler.free.fr/library/files/elman%20\(1990\)%20finding%20structure%20in%20time.pdf](http://wexler.free.fr/library/files/elman%20(1990)%20finding%20structure%20in%20time.pdf) f. Acesso em: 20 set. 2023.

ENGINEERING FUNDA. **Auto correlation of Energy signal (Basics, Definition and Function).** YouTube, 20 maio 2019. Disponível em: [https://www.youtube.com/watch?v=p3kBb\\_KJvxxk&list=PLgwJf8NK-2e7R2U6LLZHm-AECqA\\_ptCt8&index=2](https://www.youtube.com/watch?v=p3kBb_KJvxxk&list=PLgwJf8NK-2e7R2U6LLZHm-AECqA_ptCt8&index=2). Acesso em: 4 out. 2023.

FIGUEIREDO, R.; SILVA, E.; NEVES, S. **Abordagens para análise e extração de características de radares LPI.** 2019. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019. Disponível em: <http://www.pee.ufrj.br/index.php/pt/producao-academica/dissertacoes-de-mestrado/2019-1/2016033326--149/file>. Acesso em: 6 set. 2023.

GHADIMI, G.; NOROUZI, Y.; BAYDERKHANI, R.; *et al.* **Theory and Methods of Signal Processing. Deep Learning-Based Approach for Low Probability of Intercept Radar Signal Detection and Classification.** *Journal of Communications Technology and Electronics, Teerã, v. 65, n. 10, 2020.*

HENKE, P. **Lessons Learned and Forgotten: Electronic Warfare in the United States Army.** Fort Leavenworth: School of Advanced Military Studies US Army Command and General Staff College, 2021. Disponível em: <https://apps.dtic.mil/sti/pdfs/AD1161059.pdf>. Acesso em: 10 ago. 2023.

HULLEY, S.; CUMMINGS, S.; BROWNER, W.; *et al.* **Designing Clinical Research.** Wolters Kluwer Health: Philadelphia, 2007. ed. 3. Disponível em: [https://edisciplinas.usp.br/pluginfile.php/5486505/mod\\_resource/content/1/Stephen%20B.%200Hulley%2C%20Steven%20R.%20Cummings%2C%20Warren%20S.%20Browner%2C%20Deborah%20G.%20Grady%2C%20Thomas%20B.%20Newm.pdf](https://edisciplinas.usp.br/pluginfile.php/5486505/mod_resource/content/1/Stephen%20B.%200Hulley%2C%20Steven%20R.%20Cummings%2C%20Warren%20S.%20Browner%2C%20Deborah%20G.%20Grady%2C%20Thomas%20B.%20Newm.pdf). Acesso em: 30 set. 2023.

JARPA, P. **Quantifying the Differences in Low Probability of Intercept Radar Waveforms Using Quadrature Mirror Filtering.** 2002. Electrical Engineer's Thesis – Naval Postgraduate School, Monterey, California, EUA, 2002.

JORDAN, M. **Serial Order: A Parallel Distributed Processing Approach.** San Diego: University of California, 1986. Disponível em: <https://cseweb.ucsd.edu/~gary/PAPER-SUGGESTIONS/Jordan-TR-8604-OCRed.pdf>. Acesso em: 17 set. 2023.

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](https://www.researchgate.net/publication/322201609_Automatic_LPI_Radar_Waveform_Recognition_using_CNN). Acesso em: 21 set. 2023.

LANDIS, J; KOCH, G. **The Measurement of Observer Agreement for Categorical Data.** *In: Biometrics* 33. [S. l.]: International Biometric Society, 1977. v. 33. n. 1. p. 159-174. Disponível em: <https://www.scinapse.io/papers/2164777277>. Acesso em: 30 set. 2023.

LATIMER, J. **Deception in War.** London: Thistle Publishing, 2015.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. **Gradient-Based Learning Applied to Document Recognition.** *Proc. of the IEE*, 1998. Disponível em: [http://vision.stanford.edu/cs598\\_spring07/papers/Lecun98.pdf](http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf). Acesso em: 17 set. 2023.

LIPTON, E. **Start-Ups Bring Silicon Valley Ethos to a Lumbering Military-Industrial Complex. Small, fast-moving U.S. tech firms are using the war in Ukraine to demonstrate a new generation of military systems but face the challenge of selling them to a risk-averse Defense Department.** *The New York Times*. Washington, 21 maio 2023. Disponível em: <https://www.nytimes.com/2023/05/21/us/politics/start-ups-weapons-pentagon-procurement.html>. Acesso em: 10 ago. 2023.

MATHWORKS. **LPC: Linear prediction filter coefficients.** [S. l.], 2006. Disponível em: [https://www.mathworks.com/help/signal/ref/lpc.html?searchHighlight=LPC&s\\_tid=srchtitle\\_support\\_results\\_1\\_LPC](https://www.mathworks.com/help/signal/ref/lpc.html?searchHighlight=LPC&s_tid=srchtitle_support_results_1_LPC). Acesso em: 26 set. 2023.

MATLAB. **Pulse waveform basics: Visualizing radar performance with the ambiguity function.** YouTube, 18 abr. 2023. Disponível em: <https://www.youtube.com/watch?v=UCir6mOW2OU&t=544s>. Acesso em: 23 set. 2023.

MAYER-SCHÖNBERGER, V; CUKIER, K. **Big Data: A Revolution That Will Transform How We Live, Work, and Think.** Boston, NY: Houghton Mifflin Harcourt; 2013. Disponível em: <https://books.google.com.br/books?id=uy4lh-WEhhIC&printsec=frontcover&hl=pt-BR#v=onepage&q&f=false>. Acesso em: 16 ago. 2023.

MCCULLOCH, W.; PITTS, W. **A Logical Calculus of the Ideas Immanent in Nervous Activity.** *In: Bulletin of Mathematical Biophysics.* [S. l.], 1943. v. 5, n. 4, p. 115-133. Disponível em: <https://home.csulb.edu/~cwallis/382/readings/482/mcculloch.logical.calculus.ideas.1943.pdf>. Acesso em: 19 set. 2023.

MINSKY, M. **A Framework for Representing Knowledge.** [S. l.]: McGraw Hill, 1974. Disponível em: <https://courses.media.mit.edu/2004spring/mas966/Minsky%201974%20Framework%20for%20knowledge.pdf>. Acesso em: 26 set. 2023.

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

NOHRA, L. **Aula 3 – História da Guerra Eletrônica.** GUERRAELETRÔNICA.COM, Rio de Janeiro, 2023. Disponível em: <https://www.guerraeletronica.com/aula-3-historia-da-guerra-eletronica/>. Acesso em: 6 ago. 2023.

O'ROURKE, J. **Finding minimal Enclosing Boxes.** *In: International Journal of Computer and Information Sciences.* v. 14. n. 3. p. 183-199. Bruges: St. Catherine Press Ltd., 1985. Disponível em: <https://www.science.smith.edu/~jorourke/Papers/MinVolBox.pdf>. Acesso em:

26 set. 2023.

OPITZ, D; MACLIN, R. **Popular Ensemble Methods: An Empirical Study**. *In: Journal of Artificial Intelligence Research*. [S. l.]: Morgan Kauffmann Publishers, 1999. 11. p. 169-198. Disponível em: <https://jair.org/index.php/jair/article/view/10239>. Acesso em: 30 set. 2023.

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

PIRES FILHO; J. **Classificação de Instrumentos Musicais em Configurações Monofônicas e Polifônicas**. 2009. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica. Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.

POULARIKAS, A. **The Transforms and Applications Handbook**. ed. 2. Boca Raton: CRC Press, 2000. Disponível em: [http://libgen.is/search.php?req=POULARIKAS&lg\\_topic=libgen&open=0&view=simple&rs=25&phrase=1&column=def](http://libgen.is/search.php?req=POULARIKAS&lg_topic=libgen&open=0&view=simple&rs=25&phrase=1&column=def). Acesso em: 25 set. 2023.

RAJKUMAR, N.; JAGANATHAN, P. **A New RBF Kernel Based Learning Method Applied To Multiclass Dermatology Diseases Classification**. *In: Information Communication Technologies (ICT), 2013 IEEE Conference on*. [S.l.: s.n.], 2013.

RIZWAN, M. **Convolutional Neural Networks – In a Nut Shell**. Medium. 17 set. 2018. Disponível em: <https://medium.com/coinmonks/convolutional-neural-network-in-a-nut-shell-107b5b9364ab>. Acesso em: 18 set. 2023.

RODRIGUES, D. **Deep Learning e Redes Neurais Convolucionais: Reconhecimento Automático de Caracteres em Placas de Licenciamento Automotivo**. 2018. Dissertação (Graduação em Ciência da Computação) – Faculdade de Ciência da Computação. Universidade Federal da Paraíba, João Pessoa, 2018.

ROHDE SCHWARZ. **Understanding Barker Codes**. YouTube, 2 abr. 2020. Disponível em: <https://www.youtube.com/watch?v=ARspKn76TEU>. Acesso em: 20 set. 2023.

SAMUEL, A. **Some Studies in Machine Learning Using the Game of Checkers**. *In: IBM Journal*. [S. l.], 1959. v. 3. n. 3. p. 335-354. Disponível em: <https://www.cs.virginia.edu/~evans/greatworks/samuel1959.pdf>. Acesso em: 22 set. 2023.

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

SPOORTHI, C; RAMESH, S. **FGPA Implementation of Linear Frequency Modulation (LFM) Waveforms for Radar**. *In: Journal integrated circuits in electrical devices*. Bengaluru: MAT Journals, 2017. v. 2. ed. 3. Disponível em: <https://core.ac.uk/download/pdf/230495524.pdf>. Acesso em: 21 set. 2023.

TAKAHASHI, A. **Máquinas de Vetores-Suporte Intervalar**. 2012. Tese (Doutorado em Ciências) – Faculdade de Engenharia Elétrica. Universidade Federal do Rio Grande do Norte, Natal, 2012.

VANHOY, G.; SCHUCKER, T.; BOSE, T. **Classification of LPI radar signals using**

**spectral correlation and support vector machines.** 2016. *In: Analog Integr Circ Sig Process.* New York: Springer, 2017. p. 305-313.

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 set. 2023.

ZHANG, M.; LIU, L.; DIAO, M. **LPI Radar Waveform Recognition Based on Time-Frequency Distribution.** Basel: Sensors, 2016. Disponível em: <https://www.mdpi.com/1424-8220/16/10/1682>. Acesso em: 23 set. 2023.