

Emprego da STFT e da CNN na Classificação Automática de Sinais Radar de Baixa Probabilidade de Interceptação

Edgard B. Alves¹, Jorge A. Alves² e Ronaldo R. Goldschmidt¹

¹Instituto Militar de Engenharia (IME), Rio de Janeiro/RJ - Brasil

²Escola Naval (EN), Rio de Janeiro/RJ - Brasil

Resumo—As atividades de Guerra Eletrônica desempenham um papel essencial em um Teatro de Operações. O surgimento de radares de Baixa Probabilidade de Interceptação (LPI) tornou a eficácia das atividades de Medidas de Apoio a Guerra Eletrônica (MAGE) dependente de sua capacidade em identificar as modulações intrapulso presentes nos sinais desses radares. Portanto, tornou-se imprescindível o desenvolvimento de equipamentos MAGE modernos, dotados de algoritmos de Inteligência Eletrônica (ELINT), bem como de Classificadores Automáticos de Modulações Intrapulso (ATR_{LPI}) de sinais LPI. Dentre os principais ATR_{LPI} existentes na literatura, destacam-se aqueles baseados em técnicas de análise no domínio do tempo-frequência (TFA) combinados com Redes Neurais Convolucionais (CNN). Este trabalho propõe uma arquitetura de ATR_{LPI} baseada na Transformada de Fourier de Tempo Curto (STFT) combinada com a CNN SqueezeNet. A arquitetura proposta apresentou resultados que superam os disponíveis na literatura, sugerindo sua adequação para inclusão nos futuros sistemas MAGE da Marinha do Brasil (MB).

Palavras-Chave—Rede Neural Convolucional (CNN), Radar de Baixa Probabilidade de Interceptação (LPI), Medidas de Apoio a Guerra Eletrônica (MAGE).

I. INTRODUÇÃO

As atividades de Guerra Eletrônica (GE) são essenciais para o sucesso de operações nas guerras atuais. As ações de GE permitem assegurar o uso do espectro eletromagnético por forças amigas e impedir, reduzir ou prevenir seu uso por forças inimigas. De modo geral, as atividades de Medidas de Apoio a GE (MAGE) destinam-se a detectar de forma passiva os armamentos e os meios inimigos, ou seja, sem que seja necessária uma transmissão. Desta forma, o processo de detecção MAGE possui conceitualmente uma vantagem sobre os radares, pois estes precisam transmitir para detectar, enquanto aqueles são passivos. Entretanto, os radares de Baixa Probabilidade de Interceptação (LPI) foram desenvolvidos com a finalidade de eliminar essa vantagem, ou seja, os radares LPI pretendem “detectar sem serem detectados”, de modo semelhante aos MAGE. Este paradigma foi solucionado pelos radares LPI ao transmitirem seus sinais com baixa potência e muitas vezes imersos em ruído dificultando a sua detecção pelos MAGE. A pesquisa teórica e a exploração do radar LPI tiveram origem no artigo de Robert G. Siefker, especialista em guerra eletrônica [1]. Posteriormente, J.R. Forest, da Universidade de Londres, publicou um artigo em

1983 que transformou a equação de baixa probabilidade de interceptação de Siefker em uma forma adequada para engenheiros de radar, intensificando a pesquisa experimental de radares LPI [2].

O surgimento dos radares LPI tornou os processos de detecção e de identificação dos equipamentos MAGE convencionais comprometidos, ou seja, estes processos não devem mais ser baseados na análise de sinais no domínio do tempo, mas sim no domínio da frequência.

A existência de radares LPI instalados em meios navais, aéreos e terrestres, bem como em mísseis tornou imprescindível o aperfeiçoamento dos equipamentos MAGE. Os equipamentos MAGE modernos são dotados de hardware específico para a análise dos sinais radar no domínio da frequência, bem como de software robusto destinado a classificar de forma automática o tipo de modulação intrapulso presente nos sinais LPI.

Conforme evidenciado por [3], uma das principais limitações dos processos de detecção e de identificação dos sinais LPI, enfrentada pelos equipamentos MAGE, é que os sinais LPI operam em ambientes com muito baixa Relação Sinal-Ruído (SNR - *Signal to Noise Ratio*). Para superar este desafio, uma abordagem eficaz envolve o desenvolvimento de Classificadores Automáticos de Modulações Intrapulso (ATR_{LPI}) de sinais LPI baseados na análise no domínio do Tempo-Frequência (TFA - *Time-Frequency Analysis*) combinados com Redes Neurais Convolucionais (CNN - *Convolutional Neural Network*)[1].

Vários ATR_{LPI} foram criados considerando diferentes arquiteturas. Por exemplo, algumas arquiteturas empregam diferentes classificadores, tais como: Redes Neurais Artificiais clássicas (ANN - *Artificial Neural Networks*) [4]; Árvores de Decisão (DT - *Decision Trees*) [5]; K-Means [6]; Redes Neurais Convolucionais (CNN - *Convolutional Neural Network*) [1], dentre outros [7]. Porém, os classificadores mais empregados têm sido os baseados em CNN [1]. Da mesma forma, algumas arquiteturas de ATR_{LPI} empregam diferentes técnicas de TFA, tais como: Distribuição Choi-Williams (CWD - *Choi-Williams Distribution*) [1]; Transformada de Fourier de Tempo Curto (STFT - *Short-Time Fourier Transform*) [8] e variações da Distribuição de Wigner-Ville (WVD - *Wigner-Ville Distribution*) [9], [10], como, por exemplo, a Distribuição Smoothed Pseudo-Wigner-Ville (SPWVD). Dentre estas arquiteturas, a STFT apresenta algumas vantagens sobre as demais distribuições, sendo a principal, a sua imunidade a Termos Cruzados (CT - *Cross Terms*) [11].

Este trabalho propõe uma nova arquitetura de ATR_{LPI} de sinais LPI baseada na STFT, como técnica de TFA, e na CNN SqueezeNet, como classificador. Esta arquitetura foi testada empregando sinais LPI simulados contendo os 13 tipos de modulações intrapulso, 1000 instâncias de sinais LPI, gerados de forma aleatória, e considerando uma faixa de valores de SNR variando entre $-20dB$ a $+10dB$, em incrementos de $1dB$.

Inicialmente, são apresentadas as fundamentações teóricas de três das principais técnicas de TFA empregadas na literatura, e que foram implementadas neste trabalho.

Em seguida, faz-se a abordagem das principais características dos trabalhos relacionados considerados Estado da Arte na classificação de sinais radar LPI.

Posteriormente, é apresentada a metodologia adotada a fim de caracterizar a arquitetura de ATR_{LPI} proposta.

Concluindo, são apresentados os resultados obtidos, bem como é feita a comparação destes com os resultados dos trabalhos relacionados.

A. Principais Técnicas de TFA

Os sinais LPI não são sinais estacionários, ou seja, suas características de fase e frequência intrapulso variam ao longo do tempo. Desta forma, a análise de sinais LPI requer o emprego de ferramentas de análise que combinem informações espectrais e variações ao longo do tempo, em outras palavras, ferramentas de TFA.

Diversas técnicas de TFA se mostraram adequadas para a análise de sinais LPI, dentre elas destacam-se: a SPWVD, a CWD e a STFT.

1) *SPWVD*: A SPWVD é uma variação da WVD. A WVD foi uma das primeiras distribuições a apresentar bons resultados na concentração de energia de sinais LPI no domínio do tempo-frequência [11]. Entretanto, a WVD possui o inconveniente de sofrer forte influência de CT. Os CT são termos espúrios que algumas distribuições apresentam no domínio do tempo-frequência. A fim de atenuar a influência desses CT, foi desenvolvida a SPWVD. A SPWVD atenuou os CT com a introdução de duas janelas de suavização, uma para o domínio da frequência e outra para o domínio do tempo. A SPWVD é definida por (1) [12]. Em (1), t é a variável de tempo, $h(\tau)$ e $g(\nu)$ representam as funções de janela no tempo e na frequência, respectivamente; $x(t)$ denota o sinal analítico de $r(t)$; e $*$ representa o complexo conjugado. O sinal analítico $x(t)$ segue a Equação $x(t) = r(t) + jH[r(t)]$, onde $H[r(t)]$ denota a transformada de Hilbert do sinal real $r(t)$.

$$SPWVD_x(t, f) = \int \int x(t - \nu + \tau/2)x^*(t - \nu - \tau/2)h(\tau)g(\nu)e^{-j2\pi f\tau} d\nu d\tau \quad (1)$$

2) *CWD*: Outra técnica de TFA bastante empregada na literatura é a CWD. Esta técnica também emprega janelas de suavização para o eixo de frequência e para o eixo do tempo. A CWD é definida a partir da transformada de Fourier $X(\omega)$ de $x(t)$ conforme indicada em (2).

$$CWD_x(t, \omega) = \frac{1}{2\pi} \int_{\xi=-\infty}^{\infty} e^{-j\xi t} \int_{\mu=-\infty}^{\infty} \sqrt{\frac{\sigma}{4\pi\xi^2}} e^{\frac{(\mu-\omega)^2}{4\xi^2/\sigma}} x\left(\mu + \frac{\xi}{2}\right)x^*\left(\mu - \frac{\xi}{2}\right) d\mu d\xi \quad (2)$$

Em (2), t é a variável de tempo, ω é a variável de frequência angular, $*$ denota o complexo conjugado, e σ é o fator de escala que desempenha um importante papel na supressão dos CT através da suavização da distribuição da CWD. O kernel ϕ representa um filtro passa-baixa para processar a Transformada de Fourier bidimensional em uma função de ambiguidade da classe Cohen, conforme detalhado em [11]. Tipicamente, nesta distribuição, adota-se o kernel exponencial $\phi(\xi, \tau) = e^{-\xi^2\tau^2/\sigma}$ [13].

3) *STFT*: A STFT é uma técnica de TFA que possui como principal vantagem, em relação as demais técnicas, a sua imunidade aos indesejáveis CT. A STFT é definida por (3). Nesta equação, $h(t)$ representa a janela de análise de período curto localizada em torno de $t = \emptyset$ e $\nu = \emptyset$. A multiplicação pela janela $h^*(\mu - t)$ suprime efetivamente o sinal fora da vizinhança do ponto de tempo $\mu = t$, então a STFT funciona como um espectro “local” do sinal $x(\mu)$ em torno de t .

A resolução temporal da STFT é proporcional à duração, no eixo do tempo, da janela de análise h , enquanto que a resolução da STFT em frequência é proporcional a largura de banda, no eixo de frequência, dessa janela de análise h .

$$STFT_x(t, \nu) = \int_{-\infty}^{\infty} x(\mu)h^*(\mu - t)e^{-j2\pi\nu\mu} d\mu \quad (3)$$

O efeito da interferência causada pelos CT pode ser observado nas Fig. 1a e 1b, identificado pelas barras verticais em destaque nos pontos de salto em frequência. Da mesma forma, percebe-se pela Fig. 1c a ausência dessa interferência, comportamento inerente a STFT que confere a ela uma vantagem sobre as demais.

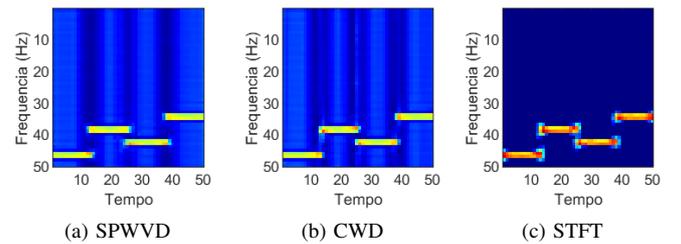


Fig. 1: Sinal LPI Costas-4 pré-processado por diferentes TFA

B. Trabalhos Relacionados

Os trabalhos que compõem o Estado da Arte na área de classificação de sinais radar LPI quanto ao tipo de modulação são os de [1], [7] e [14]. A Tabela I apresenta as principais características desses trabalhos em comparação com as da presente proposta. Conforme a Tabela I percebe-se que o único trabalho que utilizou diferentes técnicas de TFA e comparou os resultados entre as diferentes arquiteturas de ATR_{LPI} testadas foi [14]. No entanto, diferentemente da abordagem proposta neste trabalho, as três CNN do tipo LPINet dos experimentos de [14] foram geradas empregando os mesmos

valores *default* para os hiperparâmetros, independente da técnica de TFA adotada como pré-processamento, ou seja, não foi feita a otimização dos hiperparâmetros. A presente proposta é a única a avaliar comparativamente o desempenho de 3 arquiteturas de ATR_{LPI} (TFA-SPWVD, TFA-CWD e TFA-STFT) implementando o processo de otimização dos hiperparâmetros. Tal abordagem permitiu confirmar o melhor desempenho da arquitetura que emprega a STFT, em comparação com as que empregam a CWD e a SPWVD. Este comportamento pode ser atribuído à imunidade da STFT em relação aos CT, conforme observado na Fig. 1c.

TABELA I: Principais características dos trabalhos relacionados e desta proposta

Trabalhos	Técnicas de TFA	Tipo de CNN	Otimiz. Hiper.	Faixa de SNR (dB)		Tot. sin. LPI
				de	a	
Kong [7]	CWD	LWRT	Não	-20	10	12
Huynh [14]	CWD, STFT, WVD	LPINet	Não	-20	10	13
Liu [1]	CWD	CV-LPINet	Não	-18	10	12
Proposto	CWD, SPWVD, STFT	SqueezeNet	Sim	-20	10	13

C. Metodologia Proposta

A Fig. 2 apresenta o fluxograma da metodologia adotada neste trabalho. A fim de melhor caracterizar a arquitetura de ATR_{LPI} proposta, além da TFA STFT, foram realizadas comparações envolvendo outras duas TFA: a CWD e a SPWVD.

Em todas as 03 arquiteturas testadas (CWD+SqueezeNet, SPWVD+SqueezeNet, e STFT+SqueezeNet), foi empregada a mesma base de sinais radar LPI. Adicionalmente, as 03 arquiteturas foram testadas adotando o mesmo classificador, ou seja, a CNN SqueezeNet. Entretanto, ressalta-se que para cada uma das 3 técnicas de TFA implementadas, inicialmente, foram obtidos os respectivos hiperparâmetros ótimos e, posteriormente, foram realizadas as etapas de treinamento, validação e teste da CNN SqueezeNet.

Observando-se a Fig. 2, percebe-se que a metodologia adotada neste trabalho pode ser resumida nas seguintes etapas: criação da Base de Instâncias de sinais radar LPI, a partir da adição do sinal LPI sem ruído, com o ruído gaussiano branco aditivo complexo (AWGN - Additive White Gaussian Noise) e com a perda do canal de transmissão; pré-processamento de cada sinal gerado, empregando as técnicas TFA-CWD, TFA-SPWVD e TFA-STFT a fim de produzir as Bases de TFI (*Time Frequency Image* - Imagens de Tempo Frequência) CWD-TFI, SPWVD-TFI e STFT-TFI, respectivamente; treinamento, validação e teste da CNN SqueezeNet; e avaliação dos resultados obtidos. Os próximos parágrafos detalham cada uma dessas etapas.

Para compor a Base de Instâncias de Sinais Radar LPI foi feita a simulação da recepção, por um MAGE, de um sinal radar considerando sua amostra complexa interceptada e perturbada pelo AWGN e pela perda no canal, conforme indicado na equação: $y(k) = x(k) \otimes h(k) + n(k)$. Nesta equação: $x(k)$ corresponde ao sinal gerado na etapa Geração do Sinal, ou seja, livre de ruído; $h(k)$ representa a interferência proveniente do canal de transmissão decorrente da etapa Geração de

Perda no Canal; $n(k)$ caracteriza o ruído proveniente da etapa Geração de AWGN; e k retrata o índice da amostra para cada intervalo T_s (*sampling period*), considerando uma frequência de amostragem f_s (*sampling frequency*).

Neste trabalho, foi empregado o mesmo mecanismo de geração da base de instâncias de sinais radar LPI utilizado pelos trabalhos relacionados fornecido pelos autores de [1], após contato por correspondência eletrônica. Além disso, as bases de sinais foram criadas usando as mesmas modulações intrapulso, os mesmos parâmetros e as mesmas faixas adotadas por [14]. Portanto, foram gerados os 13 principais tipos de modulações intrapulso de sinais radar LPI: modulação linear de frequência (LFM); sinal sem modulação (retangular); modulação Costas ou por salto em frequência (FSK - *Frequency Shift Key*); codificação binária Barker; cinco codificações polifásicas (Frank, P1, P2, P3 e P4) e quatro codificações politemporais (T1, T2, T3 e T4). A amplitude do ruído, criado na etapa Geração de AWGN, variou de modo a se obter a faixa de SNR de $-20dB$ a $+10dB$, com incrementos de $1,0dB$. A interferência gerada pela perda do canal de transmissão, criada na etapa Geração de Perda no Canal, foi modelada conforme o desvanecimento de Rayleigh [15]. As instâncias de sinal da Base de Sinais LPI foram criadas a partir da variação aleatória de seus parâmetros específicos, conforme as especificações de [14], detalhadas na Fig. 3.

Cada sinal radar LPI foi pré-processado empregando as técnicas TFA-CWD, TFA-SPWVD e TFA-STFT. Nesta etapa, foram empregados filtros Kaiser de 63 amostras de tamanho e com fator de forma 0.5 para suavização das janelas de tempo e de frequência. Posteriormente, foram obtidas as respectivas TFI, considerando imagens capturadas com 256 níveis de cinza e de tamanho 50×50 pixels empregando-se redimensionamento por interpolação bicúbica. A Fig. 4 apresenta exemplos de TFI obtidos a partir da TFA-STFT e com $+10dB$ de SNR.

Cada uma das três bases de dados geradas (CWD-TFI, SPWVD-TFI e STFT-TFI) contém 403.000 TFI (31 níveis de SNR * 13 sinais LPI * 1000 instâncias de sinais LPI). Os 31 níveis de SNR correspondem a faixa testada de $-20dB$ a $+10dB$, com incremento de $1dB$.

Na etapa de Particionamento dos Dados, as bases de TFI foram separadas na proporção de 70-15-15 dando origem aos *datasets* de treinamento, validação e teste, respectivamente.

Para a etapa de classificação, optou-se por empregar a CNN SqueezeNet (<https://github.com/forresti/SqueezeNet>). Esta CNN foi escolhida por apresentar desempenho comparável ao da AlexNet na tarefa de classificação de imagens, porém com 50 vezes menos parâmetros e 510 vezes menor em tamanho [16]. A arquitetura da rede SqueezeNet é formada por *Fire Modules* que são compostos por camadas *squeeze* e *expand*, e que contêm filtros de convolução 1×1 e 3×3 . Tal arquitetura pode ser visualizada na Fig. 5.

Neste trabalho, optou-se em empregar a versão 1.1 da rede SqueezeNet uma vez que requer 2.4 vezes menos cálculos em relação a versão 1.0, mantendo a mesma precisão (https://github.com/forresti/SqueezeNet/tree/master/SqueezeNet_v1.1). Para o *Fine Tuning* da CNN SqueezeNet v1.1 foi empregado o aplicativo Deep Designer do MATLAB (https://www.mathworks.com/help/deeplearning/ref/deepnet_workdesigner-app.html).

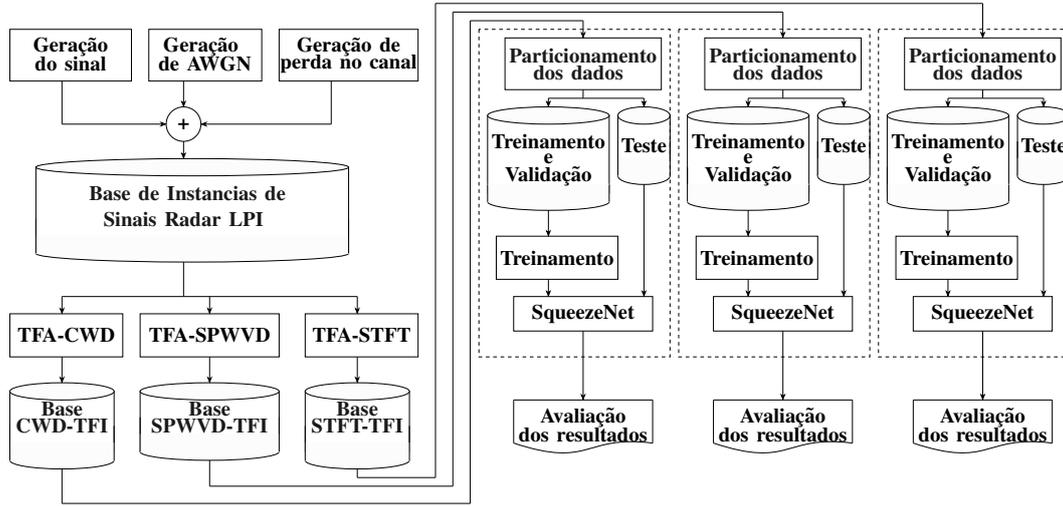


Fig. 2: Fluxograma da Metodologia Adotada neste trabalho

Notações		Formas de onda LPI	
Param.	Descrição	Típos	Param. Escala de Valores
U	Distribuição Uniforme	Todas	f_c $U(f_s/6, f_s/5)$
f_s	Frequência de Amostragem	LFM	N $[512, 1024]$
B	Largura de Banda		B $U(f_s/20, f_s/15)$
N	Número de Amostras	Rect	N $[512, 1024]$
f_c	Frequência Central	Costas	N $[512, 1024]$
FH	Frequência de Salto		FH $\{3, 4, 5, 6\}$
f_m	Frequência Fundamental		f_m $U(f_s/32, f_s/25)$
L_c	Largura do Código	Barker	L_c $\{7, 11, 13\}$
c_{pp}	Ciclos por Fase de Código		c_{pp} $[2, 5]$
M	Número de Passos de Frequência	Frank	c_{pp} $[3, 5]$
n_s	Número de Subcódigos		M $\{6, 7, 8\}$
n_g	Número de Segmentos	P1, P2	c_{pp} $[3, 5]$
n_p	Número de Estados de Fase		M $\{6, 8\}$
ψ	Atraso de Caminho	P3, P4	c_{pp} $[3, 5]$
G	Ganho Médio do Caminho		n_s $\{36, 64\}$
f_{Dmax}	Desvio Doppler Máximo	T1, T2	n_p 2
			n_g $\{4, 5, 6\}$
			N $[512, 1024]$
		T3, T4	n_p 2
			n_g $\{4, 5, 6\}$
			N $[512, 1024]$
			B $U(f_s/20, f_s/15)$

Configurações do Canal	
Modelo	Desvanecimento Rayleigh
ψ	$U(1, 1000)$ ns
G	$U(-20, 0)$ dB
f_{Dmax}	$U(10, 1000)$ Hz

Fig. 3: Faixas de valores dos parâmetros utilizados na geração das instâncias dos sinais LPI [14]

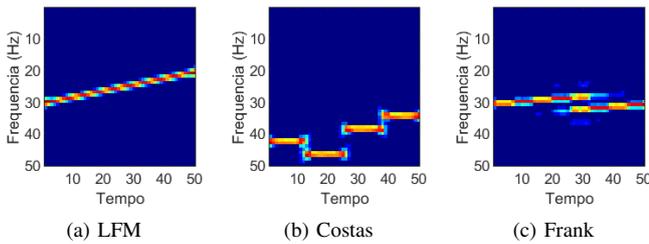
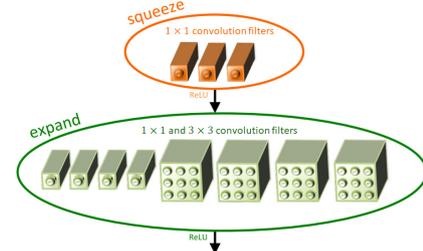
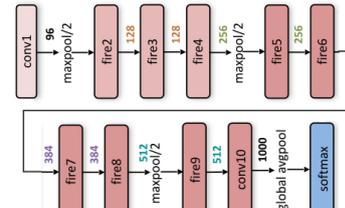


Fig. 4: Exemplos de TFI da base STFT-TFI

Durante o processo de treinamento foram otimizados os valores dos hiperparâmetros da SqueezeNet conforme o tipo de TFA específico, ou seja, cada TFA adotada (CWD, SPWVD e STFT) demandou uma otimização específica dos hiperparâmetros da CNN. Este processo foi aplicado, nesta área, de forma inédita pelos autores através do aplicativo Experiment Manager do MATLAB (<https://www.mathworks.com/help/matlab/ref/experimentmanager-app.html>) que foi configurado para buscas bayesianas. Tais buscas foram executadas com o método de gradiente descendente estocástico com momento (SGDm - *Stochastic Gradient Descent with Momentum*) como otimizador. Os valores ótimos encontrados para os hiperparâmetros,



(a) Fire modules da SqueezeNet



(b) Arquitetura da SqueezeNet

Fig. 5: CNN SqueezeNet [16]

assim como as suas respectivas faixas de busca, durante o treinamento, podem ser visualizados na Tabela II. Em todos os modelos de CNN implementados foi utilizado o valor 128 como tamanho de *minibatch*.

TABELA II: Faixas de busca e valores ótimos dos hiperparâmetros da SqueezeNet.

Parâmetro Selecionado	Faixa Avaliada		Valor Ótimo Obtido		
	de	a	SqueezeNet		
			CWD	SPWVD	STFT
Taxa de A-prend. Inicial	0.1	0.0005	0.01	0.0081	0.0007
Momento	0.98	0.8	0.8631	0.8494	0.9081
Regularização L2	0.01	10^{-10}	$9.3 \cdot 10^{-7}$	0.0001	0.0027
Learn Rate	10	1	10	10	10
Drop Period (épocas)					
Learn Rate Drop Factor	0.2	0.01	0.01	0.01	0.01

Por fim, a etapa de avaliação dos resultados consistiu em comparar os resultados obtidos pela ATR_{LPI} proposta (STFT+SqueezeNet) com os resultados das outras duas arquiteturas implementadas. Adicionalmente, foi feita outra análise comparativa considerando os resultados reportados pelos trabalhos do Estado da Arte na classificação de sinais radar LPI. Todos os experimentos foram realizados em uma plata-

forma de hardware usando uma CPU 12th Gen Intel(R) Core(TM) i5-12500H de 2.50 GHz, 16GB de RAM, e uma única GPU NVIDIA GeForce RTX 3070 Ti de 8GB.

D. Resultados

De modo a avaliar o desempenho do ATR_{LPI} proposto (STFT+SqueezeNet), foram realizadas três análises.

Na primeira análise, foram comparados os resultados de 03 arquiteturas de ATR_{LPI} : CWD+SqueezeNet, SPWVD+SqueezeNet e STFT+SqueezeNet. Tais resultados podem ser observados na Fig. 6.

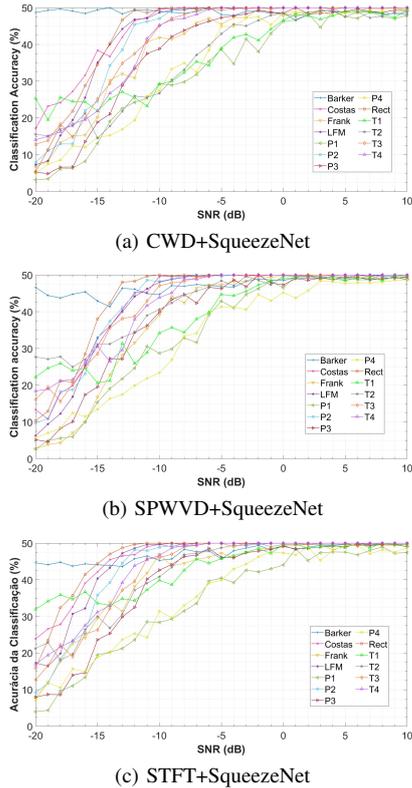


Fig. 6: Precisão de classificação de cada um dos 13 sinais LPI testados em cada arquitetura implementada

Observando a Fig. 6, percebe-se que para valores de SNR elevados (acima de $0dB$) a precisão de classificação se aproxima de 100% para todos os tipos de sinais LPI testados independente da arquitetura implementada.

Adicionalmente, a Tabela III apresenta alguns, valores de precisão de classificação extraídos dos gráficos da Fig. 6, considerando SNR de $-20dB$ e para os sinais Barker, T2, Costas e T1. Nesta tabela, nota-se que em $-20dB$ o sinal Barker é melhor classificado pela CWD+SqueezeNet, o sinal T2 é melhor classificado pela SPWVD+SqueezeNet e os sinais Costas e T1 são melhores classificados pela STFT+SqueezeNet.

TABELA III: Precisão de classificação em $-20dB$

ATR	Sinais LPI			
	Barker	T2	Costas	T1
CWD+SqueezeNet	97.4	31.17	34.27	50.7
SPWVD+SqueezeNet	93.2	55.48	26.67	44.44
STFT+SqueezeNet	89.6	42.58	47.73	63.85

Com base nos resultados da primeira análise, percebe-se que os três ATR_{LPI} testados apresentaram resultados comparáveis, ou seja, cada um apresentou melhores resultados

para certos tipos de sinais radar LPI e piores para outros, não havendo, portanto, um ATR_{LPI} que supere os demais considerando todos os 13 tipos de sinais radar LPI e toda a faixa de SNR.

A segunda análise teve por objetivo comparar os resultados de acurácia de classificação média obtidos considerando todos os 13 tipos de sinais radar LPI juntos e em toda a faixa de valores de SNR considerada, conforme ilustrado na Fig. 7. Observando esta figura, percebe-se que a arquitetura STFT+SqueezeNet apresentou valores de acurácia média superiores aos demais em toda faixa de valores de SNR. Adicionalmente, ressalta-se que para valores elevados de SNR, os valores de acurácia média se aproximam de 100%, independente da arquitetura utilizada. Como exemplo, cita-se que em $0dB$ foi obtida a acurácia de 98.23% com o STFT+SqueezeNet, de 97.83% com o SPWVD+SqueezeNet e de 97.36% com o CWD+SqueezeNet. Outra observação importante da Fig. 7 que reflete o melhor desempenho do ATR_{LPI} proposto (STFT+SqueezeNet) em relação aos demais ocorre na faixa de SNR de $-20dB$ a $-11dB$, na qual o ATR_{LPI} proposto, apresenta uma acurácia de mais de 6 p.p. acima dos demais alcançando, 11.31 p.p. em $-17dB$.

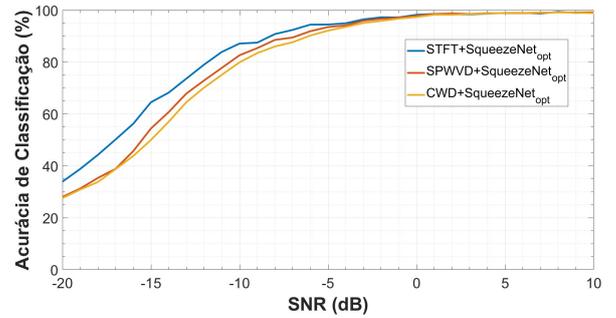


Fig. 7: Acurácia de classificação média obtida com os ATR_{LPI} implementados

Os resultados obtidos na primeira e na segunda análises indicam que o emprego da técnica TFA-STFT, combinada com a CNN SqueezeNet treinada com os valores ótimos de hiperparâmetros, resulta em um ATR_{LPI} adequado para a classificação automática das modulações intrapulso de sinais radar LPI.

De modo a qualificar o bom desempenho do ATR_{LPI} proposto neste artigo, foi realizada uma terceira análise. Nesta última análise, foram comparados os resultados obtidos pelo ATR_{LPI} proposto com os resultados reportados pelos ATR_{LPI} dos trabalhos relacionados indicados na Tabela I.

Na Fig. 8 tem-se os gráficos dos valores de acurácia de classificação média obtidos pelo presente trabalho e pelos trabalhos relacionados. Conforme apresentado nesta figura, percebe-se que o ATR_{LPI} proposto neste trabalho supera os resultados obtidos pelos ATR_{LPI} dos trabalhos relacionados em toda a faixa de valores de SNR testadas. Adicionalmente, considerando a faixa de $-6dB$ a $+10dB$ de SNR, a acurácia média obtida pelo ATR_{LPI} proposto foi 97.70%, enquanto que pelo ATR_{LPI} proposto por [14] foi 96.33%. No limite inferior da faixa de SNR, ou seja, em $-18dB$, o valor de acurácia obtido pelo presente trabalho foi 44%, enquanto que o obtido por [14] foi 25%, ou seja, uma diferença de 19 p.p. ou um resultado 76% melhor, mesmo frente ao elevado nível de ruído.

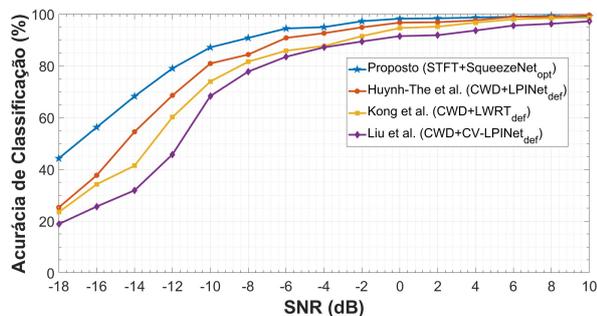


Fig. 8: Valores de acurácia média dos ATR_{LPI} dos trabalhos relacionados e do ATR_{LPI} proposto

Outra evidência da superioridade do ATR_{LPI} proposto surge ao compararmos as matrizes de confusão deste ATR_{LPI} com o do Estado da Arte, ou seja, a matriz de confusão de [14] em $-8dB$ de SNR. Estas matrizes podem ser visualizadas na Fig. 9.

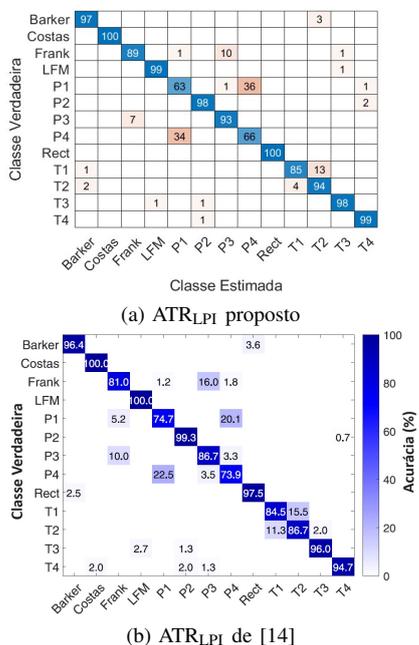


Fig. 9: Matrizes de Confusão do ATR_{LPI} proposto e do ATR_{LPI} de [14] em $-8dB$ de SNR

A partir da Fig. 9 pode-se constatar que o ATR_{LPI} proposto obteve melhores resultados que o ATR_{LPI} do Estado da Arte pois forneceu melhor precisão de classificação para oito dos 13 tipos de sinais radar LPI (Barker, Frank, P3, Rect, T1, T2, T3 e T4). Além disso, foi possível melhorar a acurácia média de classificação de 90.10% [14] para 90.79%.

Os resultados da terceira análise comprovam que o ATR_{LPI} proposto (STFT+SqueezeNet) apresenta uma arquitetura promissora quando comparada com as arquiteturas do Estado da Arte destinadas à classificação automática de modulações intrapulso de sinais radar LPI.

II. CONSIDERAÇÕES FINAIS

O surgimento de radares LPI e a sua consequente instalação em meios navais, aéreos e terrestres, bem como em mísseis, demandam uma constante evolução tecnológica dos equipamentos MAGE. Esta evolução tecnológica inclui a capacidade de classificação automática de modulações intrapulso de sinais radar LPI.

O ATR_{LPI} proposto neste trabalho apresentou resultados promissores na classificação de 13 tipos de sinais LPI, numa ampla faixa de SNR. O emprego da arquitetura composta pela STFT associada à CNN SqueezeNet mostrou-se mais adequada do que as tradicionais arquiteturas que empregam a CWD combinada com CNN, consideradas Estado da Arte no âmbito de classificação de sinais LPI. O ATR_{LPI}, proposto neste trabalho, apresentou valores de acurácia de classificação melhores que os disponíveis na literatura. Estes bons resultados podem ser atribuídos a duas iniciativas adotadas neste trabalho: a opção pelo emprego da STFT que é imune aos CT; e a decisão pela otimização dos hiperparâmetros da CNN SqueezeNet.

Os resultados obtidos neste trabalho permitem sugerir a inclusão da arquitetura proposta nos futuros sistemas MAGE da MB. Como trabalhos futuros pretende-se avaliar o desempenho de novas arquiteturas de ATR_{LPI} empregando novos TFA e outros classificadores baseados em CNN.

REFERÊNCIAS

- [1] Z. Liu *et al.*, “A method for lpi radar signals recognition based on complex convolutional neural network,” *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 37, no. 1, p. e3155, 2024.
- [2] J. Forest, “Technique for low probability of intercept radar,” *MSAT*, pp. 496–500, 1983.
- [3] E. B. Alves, J. A. Alves, J. C. Pires, J. V. de Pina Corrica, M. dos Santos, and A. P. de Araújo Costa, “Emprego da stft e da acf na identificação de codificações intrapulso de sinais radar e seu emprego nos futuros sistemas de elint,” *SIGE*, 2022.
- [4] H. Milczarek *et al.*, “Automatic classification of frequency-modulated radar waveforms under multipath conditions,” *IEEE Sensors Journal*, 2023.
- [5] R. Niranjana, C. Rama Rao, and A. Singh, “Fpga based identification of frequency and phase modulated signals by time domain digital techniques for elint systems,” *Defence Science Journal*, vol. 71, no. 1, 2021.
- [6] H. Changbo, L. Guowei, H. Lijie, and L. Yun, “Multimodal feature fusion recognition of modulated signals based on image and waveform domain,” in *2020 7th International Conference on Dependable Systems and Their Applications (DSA)*. IEEE, 2020, pp. 337–342.
- [7] S.-H. Kong *et al.*, “Automatic lpi radar waveform recognition using cnn,” *Ieee Access*, vol. 6, pp. 4207–4219, 2018.
- [8] M. Walencykowska, A. Kawalec, and K. Krenc, “An application of analytic wavelet transform and convolutional neural network for radar intrapulse modulation recognition,” *Sensors*, vol. 23, no. 4, p. 1986, 2023.
- [9] C. Wan, W. Si, and Z. Deng, “Research on modulation recognition method of multi-component radar signals based on deep convolution neural network,” *IET Radar, Sonar & Navigation*, 2023.
- [10] B. Willetts, M. Ritchie, and H. Griffiths, “Optimal time-frequency distribution selection for lpi radar pulse classification,” in *2020 IEEE Int Radar Conf (RADAR)*. IEEE, 2020, pp. 327–332.
- [11] P. E. Pace, *Detecting and classifying low probability of intercept radar*. Artech house, 2009.
- [12] N. Ma and J. Wang, “Dynamic threshold for spwvd parameter estimation based on otsu algorithm,” *Journal of Systems Engineering and Electronics*, vol. 24, no. 6, pp. 919–924, 2013.
- [13] H.-I. Choi and W. J. Williams, “Improved time-frequency representation of multicomponent signals using exponential kernels,” *IEEE Trans on Acoustics, Speech, and Signal Processing*, vol. 37, no. 6, pp. 862–871, 1989.
- [14] T. Huynh-The *et al.*, “Accurate lpi radar waveform recognition with cwd-tfa for deep convolutional network,” *IEEE Wireless Com. Letters*, vol. 10, no. 8, pp. 1638–1642, 2021.
- [15] T. R. Ferreira, “Modulação quantizada para sistemas com codificação wavelet sujeitos ao desvanecimento rayleigh,” Master’s thesis, Universidade Federal do Rio Grande do Norte, 2009.
- [16] F. N. Iandola *et al.*, “Squeezenet: Alexnet-level accuracy with 50x fewer parameters and 0.5 mb model size,” *arXiv preprint arXiv:1602.07360*, 2016.