

CLASSIFICAÇÃO DE SINAIS DE RADARES DE BAIXA PROBABILIDADE DE INTERCEPTAÇÃO NOS DOMÍNIOS DO TEMPO E DA FREQUÊNCIA EMPREGANDO REDES NEURAI CONVOLUCIONAIS¹

Classification of low probability of interception radar signals in the time and frequency domain using convolutional neural networks

Jorge Amaral Alves¹, Edgard Braz Alves², Ronaldo Ribeiro Goldschmidt³

Resumo: Guerra Eletrônica (GE) Radar tem assumido papel fundamental na defesa de países em todo mundo e requer o aperfeiçoamento constante das medidas de apoio à GE (MAGE). Um dos principais aperfeiçoamentos dos equipamentos MAGE consiste na inclusão da capacidade de inteligência artificial (IA) ao classificador automático de sinais (ATR) de radares de baixa probabilidade de interceptação (LPI). Este trabalho propõe duas arquiteturas de ATR, baseadas em IA, para a classificação automática de sinais de radares LPI. As arquiteturas propostas foram baseadas na técnica de análise no tempo-frequência (TFA), denominada Distribuição Pseudo-Wigner-Ville Suavizada (SPWVD), e em duas redes neurais convolucionais (CNN): *SqueezeNet* e *GoogLeNet*. O ATR baseado na *GoogLeNet* apresentou 99,06% de precisão na classificação de 13 tipos de sinais LPI, superando o Estado da Arte de trabalhos relacionados. Os resultados obtidos evidenciam o potencial emprego dos ATR propostos em futuros equipamentos MAGE em desenvolvimento pela Marinha do Brasil, contribuindo para o fortalecimento da soberania nacional na área de GE radar.

Palavras-chave: Rede Neural Convolucional. Radar de Baixa Probabilidade de Interceptação. Medidas de Apoio à Guerra Eletrônica. Inteligência Artificial.

Abstract: Radar electronic warfare (EW) has played a fundamental role in the defense of countries worldwide and requires the constant improvement of electronic support measures (ESM). One of the main improvements to ESM equipment is the inclusion of artificial intelligence (AI) capabilities in the automatic signal classifier (ATR) of low probability of interception (LPI) radars. This work proposes two AI-based ATR architectures for the automatic classification of LPI radar signals. The proposed architectures are based on the time-frequency analysis (TFA) technique called Smoothed Pseudo-Wigner-Ville Distribution (SPWVD) and two convolutional neural networks (CNN): *SqueezeNet* and *GoogLeNet*. The *GoogLeNet*-based ATR achieved 99.06% accuracy in classifying 13 types of LPI signals, surpassing the state of the art of related works. The results obtained demonstrate the potential use of the proposed ATRs in future ESM equipment under development by the Brazilian Navy, contributing to the strengthening of national sovereignty in the radar EW domain.

Keywords: Convolutional Neural Network. Low Probability of Interception Radar. Electronic Support Measures. Artificial Intelligence.

1. Capitão de Mar e Guerra. Mestre em Ciência da Computação pela Naval Postgraduate School (Califórnia, Estados Unidos). Coordenador de Eletrônica do Centro Técnico-Científico, Escola Naval, Rio de Janeiro, RJ - Brasil. E-mail: jorge.amaral@marinha.mil.br

2. Capitão-Tenente. Mestre em Ciência da Computação pelo Instituto Militar de Engenharia. Ajudante de Divisão do Centro de Apoio a Sistemas Operativos, Rio de Janeiro, RJ - Brasil. E-mail: edgard.braz@marinha.mil.br

3. Doutor em Engenharia Elétrica pela Pontifícia Universidade Católica. Professor Associado do Programa de Pós-Graduação em Sistemas e Computação, Instituto Militar de Engenharia, Rio de Janeiro, RJ - Brasil. E-mail: ronaldo.rgold@ime.eb.br

¹ Os resultados deste estudo foram publicados no livro *Lecture Notes in Artificial Intelligence (LNAI)*, volume 15412, pp. 444-459, 2025. Disponível em https://doi.org/10.1007/978-3-031-79029-4_31.

1. INTRODUÇÃO

Atualmente, a Guerra Eletrônica (GE) Radar tem assumido papel fundamental na defesa de países em todo o mundo. Especificamente, o aperfeiçoamento das Medidas de Apoio à Guerra Eletrônica (MAGE) tem se tornado essencial para garantir a eficiência dos processos de detecção, identificação e classificação de sinais eletromagnéticos transmitidos por radares, e, portanto, assegurar a eficácia da consequente proteção contra esses radares e os armamentos a eles associados, como, por exemplo, mísseis guiados por radar. Nesse contexto, pode-se citar, como principal aperfeiçoamento de um equipamento MAGE, a incorporação de sistemas de inteligência eletrônica (*electronic intelligence* – ELINT) capazes de identificar sinais de radares de baixa probabilidade de interceptação (*low probability intercept* – LPI). Outro desafio tecnológico consiste em incorporar aos MAGE a capacidade de inteligência artificial (IA) e, dessa forma, torná-los capazes de classificar automaticamente sinais de radares LPI, reduzindo o tempo de reação diante de uma ameaça.

O presente artigo propõe duas arquiteturas inovadoras, baseadas em IA, destinadas à classificação automática de modulações intrapulso presentes em sinais de radares LPI. Os resultados obtidos neste trabalho evidenciam o potencial de emprego dessas arquiteturas em futuros equipamentos MAGE nacionais em desenvolvimento pela Marinha do Brasil (MB), contribuindo para o fortalecimento da soberania nacional. As arquiteturas propostas combinam técnicas de análise no domínio do tempo e da frequência (TFA) e classificadores baseados em redes neurais convolucionais (*convolutional neural networks* – CNN), uma abordagem de Aprendizado Profundo aplicada a um banco de sinais simulados de radares LPI. De maneira inédita, realizou-se, neste trabalho, a otimização dos hiperparâmetros das CNN testadas, elevando as precisões obtidas quando comparadas às de trabalhos relacionados, especialmente em ambientes eletromagnéticos com baixos valores de relação sinal-ruído (*signal-to-noise ration* – SNR). Para fins de simplificação do texto, neste artigo, a sigla correspondente a *Automatic Target Recognition*, ATR, será utilizada para designar cada arquitetura testada.

Nos últimos anos, várias arquiteturas de ATR para sinais de radares LPI foram desenvolvidas utilizando diferentes tipos de classificadores, tais como redes neurais artificiais clássicas (MILCZAREK, et al., 2023), árvores de decisão (NIRANJAN, et al., 2021) e CNN (LIU et al., 2024), entre outros (KONG

et al., 2018). Esses ATR apresentam, como etapa inicial, o pré-processamento dos sinais LPI, empregando diferentes técnicas de TFA. As principais técnicas de TFA empregadas em ATR de sinais de radar LPI incluem: Distribuição Choi-Williams (CWD) (LIU et al., 2024), Transformada de Fourier de Tempo Curto (*Short-time Fourier Transform* – STFT) (WALENCZYKOWSKA; KAWALEC; KRENC, 2023) e variações da Distribuição Wigner-Ville (*Wigner-Ville Distribution* – WVD) (WAN; SI; DENG, 2023; WILLETTS; RITCHIE; GRIFFITHS, 2020), como a Pseudo-Wigner-Ville Suavizada (*Smoothed Pseudo Wigner-Ville Distribution* – SPWVD). A SPWVD é uma das técnicas de TFA mais eficazes para estimar diversos parâmetros temporais e espectrais de sinais de radares LPI, especialmente em ambientes ruidosos (MA; WANG, 2013). Trabalhos acadêmicos que combinaram a técnica CWD com classificadores CNN obtiveram os melhores desempenhos na identificação de sinais de radares LPI (HUYNH-THE et al., 2021; KONG et al., 2018; LIU et al., 2024). Ao analisar esses trabalhos, observa-se que, embora alguns autores tenham testado diferentes técnicas de TFA na etapa de pré-processamento, não foi identificada qualquer iniciativa quanto à importância do processo de otimização dos hiperparâmetros das CNN utilizadas; ou seja, nos trabalhos relacionados foram empregados apenas parâmetros padrão das CNN. A iniciativa inédita implementada neste estudo, referente à otimização dos hiperparâmetros das CNN, justifica-se, pois o desempenho do classificador varia em função dos dados e do pré-processamento aplicado (FACELI et al., 2021). Ademais, o processo de otimização das CNN deve ser executado para cada técnica de pré-processamento testada.

Diante do exposto, levantou-se a seguinte hipótese: o uso de uma CNN com hiperparâmetros otimizados de acordo com a técnica de TFA empregada no pré-processamento de sinais de radares LPI pode resultar em um ATR de melhor desempenho ao combinar TFA+CNN. Além disso, ao comparar uma arquitetura de ATR composta pela combinação SPWVD+CNN com outra composta pela combinação CWD+CNN, a primeira pode apresentar resultados superiores. Para reunir evidências que sustentassem essa hipótese, analisaram-se os resultados produzidos pelos seguintes ATR: SPWVD+SqueezeNet_{opt}; CWD+SqueezeNet_{opt}; SPWVD+GoogLeNet_{opt}; e CWD+GoogLeNet_{opt}. Especificamente, o ATR SPWVD+GoogLeNet_{opt} atingiu precisão média de classificação de 99,06% em 0dB de SNR. Esse resultado superou os obtidos em trabalhos relacionados anteriores.

O presente trabalho está estruturado em cinco seções. A Seção 2 apresenta a fundamentação teórica associada às técnicas de TFA utilizadas. A Seção 3 apresenta trabalhos relacionados à classificação de sinais de radares LPI. A Seção 4 descreve a metodologia adotada. A Seção 5 apresenta os resultados obtidos, comparando-os com aqueles de trabalhos relacionados. Por fim, a Seção 6 apresenta as conclusões da pesquisa, destacando as principais contribuições e sugerindo investigações futuras.

2. FUNDAMENTAÇÃO TEÓRICA

Diversas técnicas de pré-processamento de sinais de radares LPI foram desenvolvidas. Dentre elas, destacam-se as diferentes técnicas de TFA, tais como: a WVD; as variações da WVD; e a CWD. A WVD permite ótima concentração de energia no domínio tempo-frequência, em comparação com outros métodos de TFA (PACE, 2009). No entanto, a WVD introduz termos cruzados (*cross terms* – CT). Para mitigar a influência dos CT, foi criada a distribuição pseudo-Wigner-Ville (*pseudo-Wigner-Ville distribution* – PWVD), que incorporou uma janela de análise deslizante ao longo do eixo da frequência (PACE, 2009). Posteriormente, como aprimoramento da PWVD, foi desenvolvida a CWD, que reduziu a influência dos CT tanto no domínio da frequência quanto no domínio do tempo. A CWD é definida com base na transformada de Fourier $X(\omega)$ de $x(t)$, conforme detalhado em Choi e Williams (1989).

Outra abordagem proposta para mitigar a interferência causada pelos CT foi a criação da SPWVD. A SPWVD introduziu janelas de suavização tanto no domínio do tempo quanto no domínio da frequência. Sua formulação é detalhada em Ma e Wang (2013).

O efeito visual da interferência resultante dos CT, no domínio tempo-frequência, pode ser observado na Figura 1.

A Figura 1 apresenta os resultados obtidos ao aplicar diferentes técnicas de TFA a um sinal de radar LPI do tipo Costas-4. As imagens no domínio tempo-frequência (*time-frequency images* – TFI) resultantes da WVD (Figura 1A) e da PWVD (Figura 1B) apresentaram elevadas interferências por CT, visíveis como barras verticais destacadas nas respectivas figuras. Em contrapartida, as TFI produzidas pela CWD (Figura 1C) e pela SPWVD (Figura 1D) apresentaram poucas interferências por CT. Embora as TFI das Figuras 1C e 1D sejam semelhantes, observa-se que a imagem da Figura 1D apresenta nitidez ligeiramente superior à da Figura 1C, sugerindo, de forma intuitiva, que o uso da SPWVD pode apresentar alguma vantagem em relação à CWD. Mais detalhes sobre cada técnica de TFA podem ser obtidos em Pace (2009).

3. TRABALHOS RELACIONADOS

Atualmente, os principais estudos na área de classificação de sinais de radares LPI incluem os de Huynh-The et al. (2021), Kong et al. (2018) e Liu et al. (2024). A Tabela 1 apresenta as principais características desses trabalhos e do proposto neste artigo.

Observando-se a Tabela 1, nota-se que apenas em Huynh-The et al. (2021) foram testadas diferentes técnicas de TFA. No entanto, nesses experimentos, os três ATR avaliados empregaram a LPINet com valores padrão para os hiperparâmetros. Os ATR propostos neste trabalho foram avaliados considerando, como etapa inicial, a otimização dos hiperparâmetros das CNN durante a fase de treinamento. Adicionalmente, os

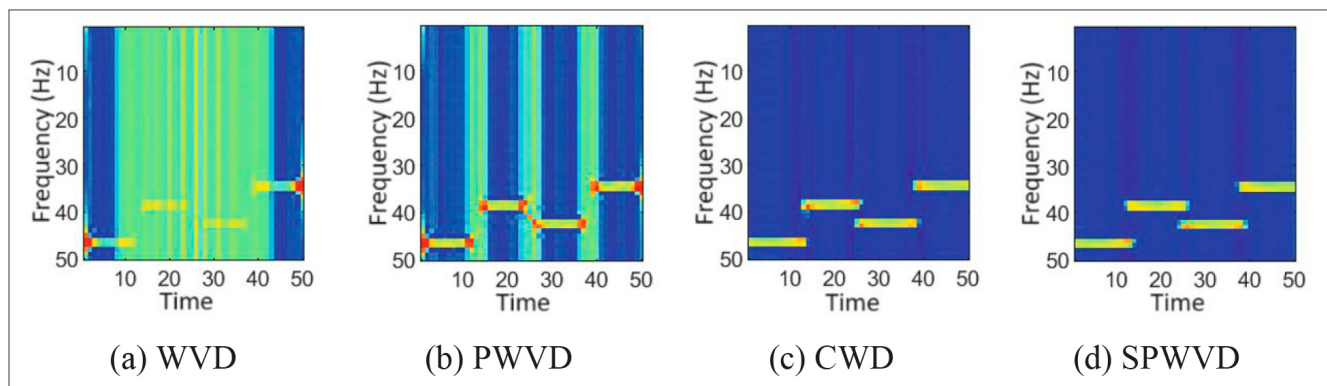


Figura 1. Exemplo de um sinal de baixa probabilidade de interceptação Costas-4 pré-processado por diferentes análises no domínio do tempo e da frequência.

ATR testados neste trabalho priorizaram as técnicas CWD e SPWVD, pois se assumiu que o emprego da SPWVD poderia levar a melhores resultados de classificação quando comparada à tradicional CWD.

4. METODOLOGIA PROPOSTA

Para validar a hipótese proposta neste trabalho, foi empregada a metodologia descrita na Figura 2. Essa metodologia consistiu

nas seguintes etapas: Criação do Banco de Instâncias de Sinais de Radares LPI, na qual o sinal de radar LPI livre de ruído foi simulado, sendo adicionados a este o Ruído Gaussiano Branco Aditivo (*Additive White Gaussian Noise – AWGN*) e a perda de canal modelada; pré-processamento do Sinal, no qual os bancos de imagens SPWVD-TFI e CWD-TFI foram gerados por meio do pré-processamento utilizando as técnicas SPWVD e CWD, respectivamente; treinamento, validação e teste das CNN, em que os classificadores CNN foram treinados, validados e testados empregando os bancos de imagens SPWVD-TFI e CWD-TFI;

Tabela 1. Características principais dos trabalhos relacionados e do proposto.

Trabalhos Relacionados	Técnicas de TFA testadas	Tipo de CNN utilizada	Otimização dos Hiperparâmetros	Faixa de SNR (dB)		Total de tipos de sinais LPI testados	Total de parâmetros da CNN
				de	até		
Kong et al., 2018	CWD	LWRT	não	-20	10	12	2.097.512
Huynh-The et al., 2021	CWD,STFT,WVD	LPINet	não	-20	10	13	288.768
Liu et al., 2024	CWD	CV-LPINet	não	-18	10	12	9.784
Proposto neste trabalho	CWD, SPWVD	SqueezeNet	sim	-20	10	13	729.100
	CWD, SPWVD	GoogLeNet	sim	-20	10	13	5.900.000

TFA: análise no domínio do tempo e da frequência; CWD: distribuição Choi-Williams; STFT: transformada de Fourier de tempo curto; WVD: distribuição Wegner-Ville; SPWVD: pseudo-Wegner-Ville suavizada; CNN: redes neurais convolucionais; SNR: relação sinal-ruído; LPI: baixa probabilidade de interceptação

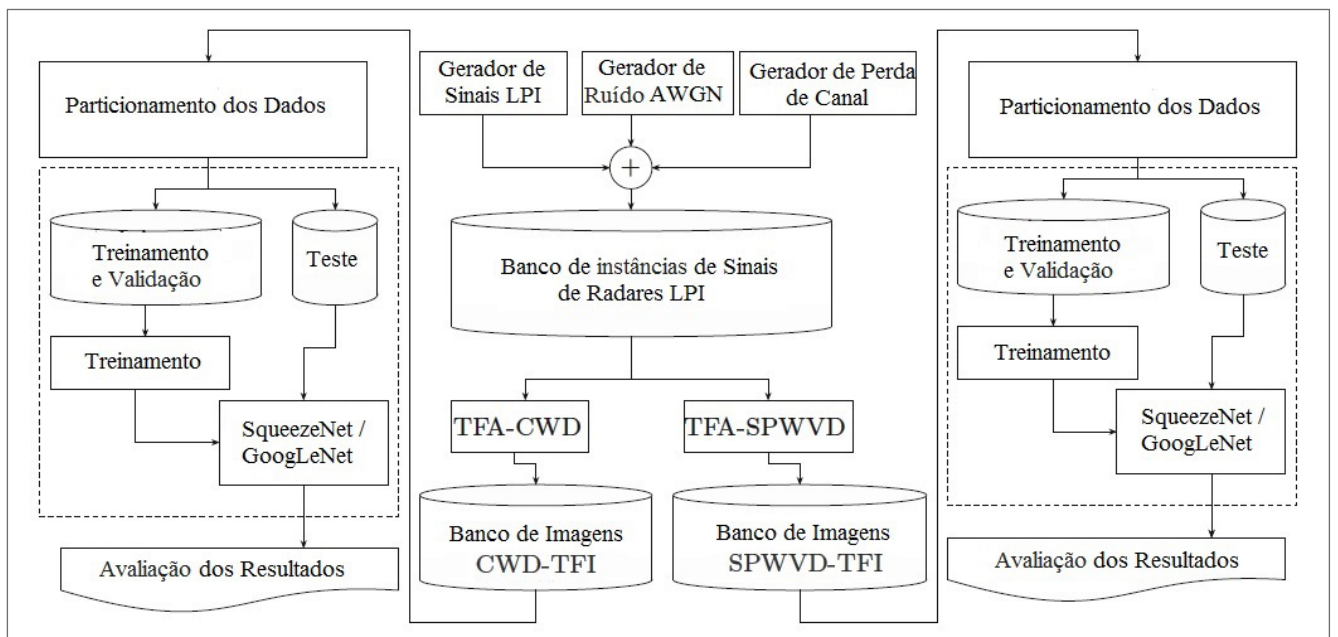


Figura 2. Fluxograma da metodologia adotada.

e Avaliação de Resultados, na qual o desempenho da abordagem proposta foi avaliado por comparação com o Estado da Arte. Os próximos parágrafos detalham essas etapas.

O Banco de Instâncias de Sinais de Radares LPI foi criado considerando, na modelagem do sistema de recepção do MAGE, a influência do ruído AWGN e da perda de canal. Considerou-se que a amostra complexa de um sinal LPI interceptado foi perturbada pelo AWGN e pela perda de canal, conforme a relação: $y(k) = x(k) * h(k) + n(k)$. Nessa relação: $x(k)$ representa o sinal LPI livre de ruído; $h(k)$ corresponde à interferência de canal; $n(k)$ caracteriza o ruído; e k denota o índice da amostra para cada período de amostragem (T_s).

Ressalta-se que, neste estudo, buscou-se empregar o mecanismo de criação de sinais LPI idêntico ao utilizado nos trabalhos

relacionados. Assim, empregou-se o código-fonte de geração de sinais de radares LPI fornecido por Liu et al. (2024). Os bancos de imagens TFI foram criados considerando as mesmas 13 modulações intrapulso e as mesmas faixas de parâmetros, conforme especificado na Figura 3. Foram gerados 13 tipos diferentes de modulações intrapulso de sinais de radares LPI: modulação linear em frequência (*linear frequency modulation* – LFM); sinais não modulados (retangulares); codificação por chaveamento de frequência (*frequency shift keying* – FSK) do tipo Costas; codificação binária Barker; cinco codificações polifásicas (Frank, P1, P2, P3 e P4); e quatro codificações politemporais (T1, T2, T3 e T4). Optou-se por considerar a mesma faixa de SNR adotada por Huynh-The et al. (2021), ou seja, variou-se a SNR de -20 a +10 dB com incrementos de 1,0 dB. Da mesma forma, adotou-se a mesma modelagem para a perda de canal empregada por Huynh-The et al. (2021), isto é, o Desvanecimento de Rayleigh. Por fim, diferentes instâncias de sinais LPI foram geradas variando-se aleatoriamente os parâmetros de cada modulação, conforme detalhado na Figura 3.

Conforme especificado em Huynh-The et al. (2021), na etapa de pré-processamento foram adotados filtros Kaiser com tamanho de 63 amostras e fator de forma de 0,5, a fim de suavizar as janelas de tempo e de frequência. A imagem TFI foi obtida capturando imagens com 256 níveis de cinza e com dimensões de 50×50 pixels, empregando interpolação bicúbica. A Figura 4 ilustra exemplos de TFI obtidas com a técnica SPWVD e SNR de +10 dB. Foram gerados dois bancos de imagens TFI, cada um contendo 403.000 TFI (31 níveis de SNR * 13 tipos de sinais LPI * 1.000 instâncias de sinais LPI).

Durante a etapa de Particionamento dos Dados, cada banco de TFI foi separado em cinco conjuntos disjuntos para a realização da validação cruzada. Em cada rodada de

Notations		LPI waveforms		
Param.	Description	Types	Param.	Range of value
U	uniform distribution	All	f_c	$U(f_s/6, f_s/5)$
f_s	sampling frequency	LFM	N	[512, 1024]
B	bandwidth		B	$U(f_s/20, f_s/15)$
N	number of samples	Rect	N	[512, 1024]
f_c	center frequency		N	[512, 1024]
FH	frequency hop	Costas	FH	{3, 4, 5, 6}
f_m	fundamental frequency		f_m	$U(f_s/32, f_s/25)$
L_c	code length	Barker	L_c	{7, 11, 13}
c_{pp}	cycles per phase code		c_{pp}	[2, 5]
M	number of frequency steps	Frank	c_{pp}	[3, 5]
n_s	number of sub-codes		M	{6, 7, 8}
n_g	number of segments	P1, P2	c_{pp}	[3, 5]
n_p	number of phase states		M	{6, 8}
ψ	path delay	P3, P4	c_{pp}	[3, 5]
G	average path gain		n_s	{36, 64}
f_{Dmax}	maximum Doppler shift	T1, T2	n_p	2
Channel configuration			n_g	{4, 5, 6}
Model	Rayleigh fading		N	[512, 1024]
ψ	$U(1, 1000)$ ns	T3, T4	n_p	2
G	$U(-20, 0)$ dB		n_g	{4, 5, 6}
f_{Dmax}	$U(10, 1000)$ Hz		N	[512, 1024]
			B	$U(f_s/20, f_s/15)$

Figura 3. Parâmetros e faixas de valores dos sinais LPI (HUYNH-THE et al., 2021).

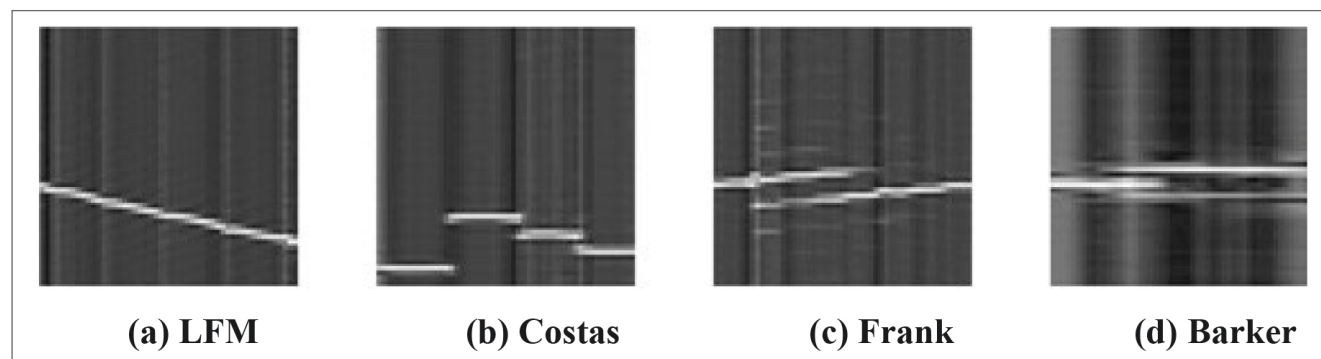


Figura 4. Exemplos de imagens TFI extraídas do banco SPWVD-TFI.

validação cruzada, os dados foram estratificados em conjuntos de treinamento, validação e teste na proporção 70-15-15, isto é, na mesma proporção adotada por Huynh-The et al. (2021).

Os ATR propostos neste trabalho foram avaliados utilizando dois classificadores CNN: *SqueezeNet* e *GoogLeNet*. A rede *SqueezeNet* foi escolhida por apresentar desempenho robusto, comparável à tradicional *AlexNet* em tarefas de classificação de imagens, porém com 50 vezes menos parâmetros e tamanho de modelo 510 vezes menor. Essa compactação torna a *SqueezeNet* adequada para dispositivos com restrição de memória (IANDOLA et al., 2016). Neste trabalho, foi empregada a versão 1.1 da rede *SqueezeNet*, pois requer 2,4 vezes menos cálculos do que a versão 1.0, mantendo a mesma precisão. A rede *GoogLeNet* foi escolhida principalmente por apresentar desempenho próximo ao Estado da Arte em termos de classificação (SZEGEDY et al., 2015). O ajuste fino (*fine tuning*) das redes CNN foi realizado empregando o aplicativo do MATLAB denominado *Deep Designer*. A otimização dos hiperparâmetros foi executada nas quatro combinações de ATR testadas, a saber: CWD+*SqueezeNet*_{opt}; SPWVD+*SqueezeNet*_{opt}; CWD+*GoogLeNet*_{opt}; e SPWVD+*GoogLeNet*_{opt}. As otimizações foram realizadas utilizando o aplicativo do MATLAB denominado *Experiment Manager*, adotando-se buscas bayesianas, gradiente estocástico descendente com momento (*stochastic gradient descent with momentum* – SGDm) e minilote de tamanho 128. Os valores ótimos dos hiperparâmetros e os intervalos de busca durante o treinamento estão resumidos na Tabela 2.

Por fim, a Avaliação dos Resultados foi realizada comparando-se o desempenho das combinações de ATR entre si e com os resultados de trabalhos relacionados.

5. RESULTADOS OBTIDOS

Para obter evidências que sustentassem a validade da hipótese levantada neste estudo, foram conduzidas três análises diferentes. A primeira análise comparou os valores de precisão obtidos para cada um dos 13 tipos de sinais LPI, variando-se a SNR de -20 a 10 dB. Os resultados da primeira análise utilizando a *SqueezeNet* podem ser visualizados na Figura 5. Comparando-se as Figuras 5A e 5B, observa-se que, em -20 dB, o sinal Barker atingiu 97,4% de precisão com a CWD+*SqueezeNet*_{opt} e 93,2% com a SPWVD+*SqueezeNet*_{opt}. Ainda em -20 dB, o sinal T2 atingiu 31,2% de precisão com a CWD+*SqueezeNet*_{opt} e 55,5% com a SPWVD+*SqueezeNet*_{opt}. Destacam-se os bons resultados obtidos com a SPWVD+*SqueezeNet*_{opt} para os sinais T1 a T4. Contudo, em -15 dB de SNR, a CWD+*SqueezeNet*_{opt} superou a SPWVD+*SqueezeNet*_{opt} para os sinais Costas e LFM.

Os resultados da primeira análise utilizando a *GoogLeNet* são apresentados na Figura 6. Comparando-se as Figuras 6A e 6B, observa-se que, em -20 dB, o sinal Barker atingiu 97,1% de precisão com a CWD+*GoogLeNet*_{opt} e 95,2% com a SPWVD+*GoogLeNet*_{opt}. Ainda em -20 dB, o sinal T1 atingiu 27,6% com a CWD+*GoogLeNet*_{opt} e 66,7% com a SPWVD+*GoogLeNet*_{opt}. Destacam-se o bom resultado obtido com a CWD+*GoogLeNet*_{opt} para o sinal Costas e o bom resultado obtido com a SPWVD+*GoogLeNet*_{opt} para o sinal LFM.

Com base nos resultados da primeira análise, evidenciou-se que cada combinação de ATR apresentou melhor desempenho para alguns tipos de sinais LPI, porém pior para outros. Concluiu-se que não houve uma única combinação

Tabela 2. Valores ótimos e respectivas faixas de busca dos hiperparâmetros.

Parâmetro Selecionado	Faixa de busca		Valores ótimos obtidos			
			SqueezeNet _{opt}		GoogLeNet _{opt}	
	de	até	CWD	SPWVD	CWD	SPWVD
Taxa de aprendizado inicial	0,1	0,0005	0,01	0,0081	0,0092	0,01
Momento	0,98	0,8	0,8631	0,8494	0,9421	0,9124
Regularização L2	0,01	10 ⁻¹⁰	9,3111 * 10 ⁻⁷	0,0001	0,0001	0,0005
Período de queda da taxa de aprendizado	10 épocas	1 época	10 épocas	10 épocas	10 épocas	10 épocas
Fator de queda da taxa de aprendizado	0,2	0,01	0,01	0,01	0,01	0,01

CWD: distribuição Choi-Williams; SPWVD: pseudo-Wegner-Ville suavizada

que superasse as demais considerando todos os 13 tipos de sinais de radares LPI e toda a faixa de SNR especificada.

A segunda análise teve como objetivo comparar os resultados médios de precisão obtidos considerando, em conjunto, os 13 tipos de sinais de radares LPI, conforme ilustrado na Figura 7. Observa-se que as duas combinações de ATR utilizando a rede *GoogLeNet_{opt}* obtiveram valores de precisão média superiores às duas que utilizaram a *SqueezeNet_{opt}*. Adicionalmente, observa-se que as combinações que utilizaram a técnica SPWVD apresentaram valores superiores às combinações que utilizaram a técnica CWD, independentemente da CNN empregada, principalmente em SNR negativos.

Ressalta-se que a precisão média se aproxima de 100% para SNR elevados (positivos), independentemente da combinação utilizada. Por exemplo, em 0 dB, a *SPWVD+GoogLeNet_{opt}* alcançou precisão de 99,06%, enquanto

a *SPWVD+SqueezeNet_{opt}* alcançou 97,83%. Outro aspecto a ser destacado da Figura 7, que reflete o desempenho superior da combinação *SPWVD+SqueezeNet_{opt}* em comparação com a *CWD+SqueezeNet_{opt}*, ocorreu em -15 dB de SNR. Nesse ponto, a *SPWVD+SqueezeNet_{opt}* superou a *CWD+SqueezeNet_{opt}*.




Figura 7. Precisão média obtida por cada combinação de ATR testada.

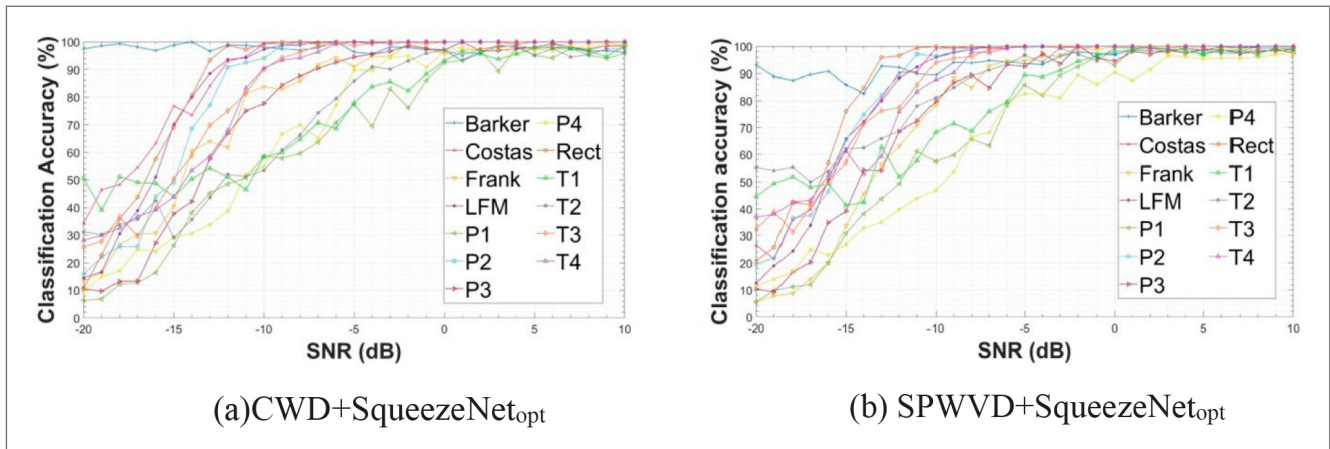


Figura 5. Precisão de classificação dos 13 sinais LPI obtida com a *SqueezeNet_{opt}*.

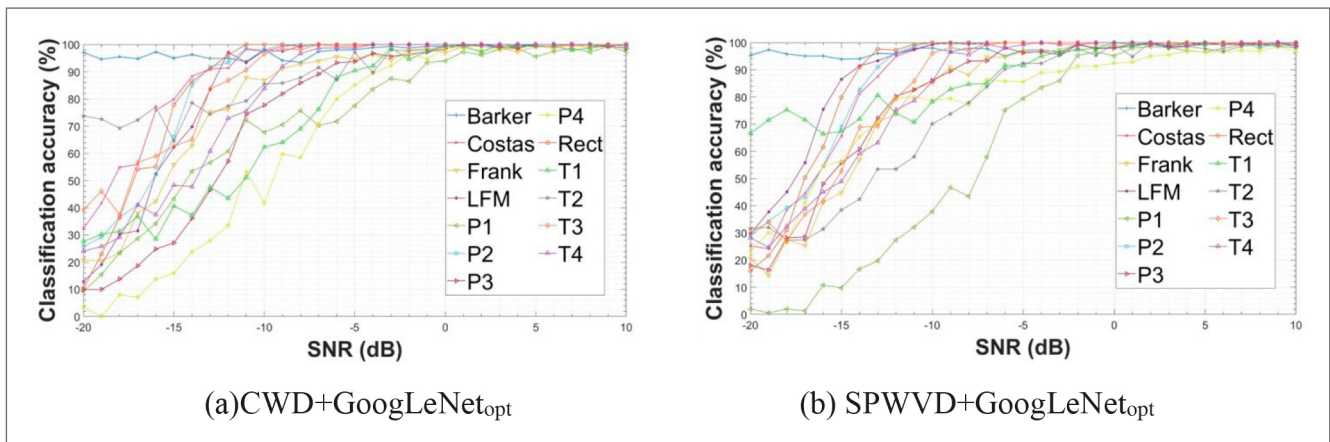


Figura 6. Precisão da classificação dos 13 sinais LPI obtida com a *GoogLeNet_{opt}*.

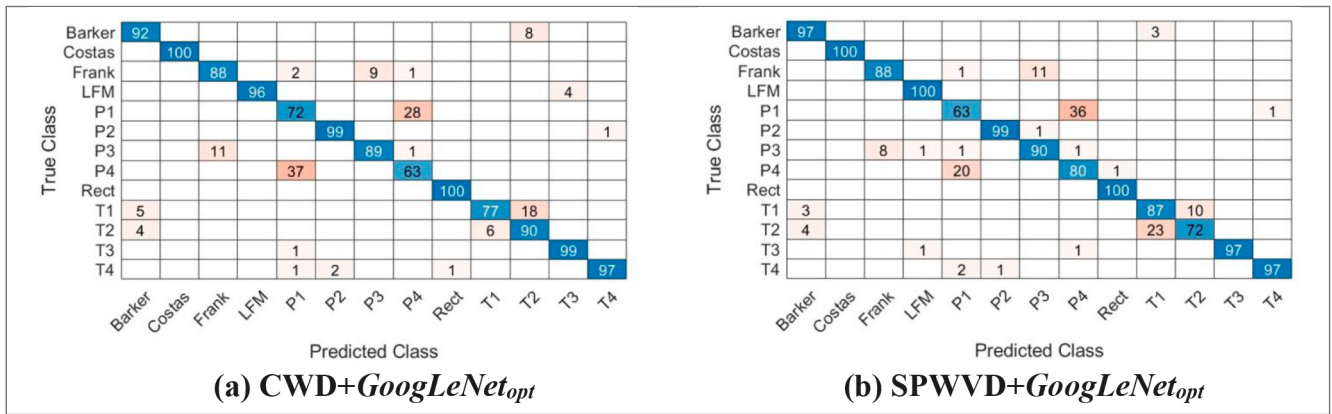


Figura 8. Matrizes de confusão obtidas com a GoogLeNet_{opt} em -8dB de SNR.

em 4,4 p.p. De forma semelhante, o ponto de melhor desempenho da combinação SPWVD+GoogLeNet_{opt} ocorreu em -16 dB. Nesse ponto, a SPWVD+GoogLeNet_{opt} superou a CWD+GoogLeNet_{opt} em 2,7 p.p.

Na Figura 8 são apresentadas as matrizes de confusão, em -8 dB de SNR, para as duas combinações que alcançaram as maiores precisões: SPWVD+GoogLeNet_{opt} e CWD+GoogLeNet_{opt}. Nessas matrizes, verifica-se que determinados tipos de modulação são fortemente confundidos entre si. Por exemplo, os sinais P1 são frequentemente classificados erroneamente como P4, enquanto os sinais T1 são confundidos com T2.

Observando-se a Figura 8, percebe-se melhor capacidade de classificação da SPWVD+GoogLeNet_{opt} em relação à CWD+GoogLeNet_{opt}. Essa conclusão baseou-se em duas observações: o maior valor de precisão alcançado pela SPWVD+GoogLeNet_{opt} foi de 90,00%, enquanto, com a CWD+GoogLeNet_{opt}, foi de 89,38%; e o fato de a SPWVD+GoogLeNet_{opt} ter superado a CWD+GoogLeNet_{opt} na classificação de cinco tipos de sinais (Barker, LFM, P3, P4 e T1), sendo superada apenas na classificação de três tipos (P1, T2 e T3).

Os resultados da primeira e da segunda análises forneceram evidências que sustentam a validade da hipótese proposta neste estudo. O uso da técnica SPWVD combinada com a SqueezeNet ou a GoogLeNet, treinadas com valores ótimos de hiperparâmetros, apresenta-se como uma opção adequada para identificar modulações intrapulso de sinais de radares LPI.

A terceira análise foi conduzida com o objetivo de comparar o desempenho das combinações de ATR propostas com as de trabalhos relacionados. Essa comparação foi possível, pois todas as combinações de ATR foram avaliadas empregando




Figura 9. Precisão dos ATR propostos neste trabalho e dos trabalhos relacionados.

validação cruzada, utilizando-se a mesma base de instâncias de sinais de radares LPI dos trabalhos relacionados. O gráfico na Figura 9 apresenta os valores médios de acurácia obtidos neste estudo e nos trabalhos relacionados. Observa-se que as combinações propostas superaram todas as combinações dos trabalhos relacionados em toda a faixa de SNR testada. Na faixa de SNR de -6 a 10 dB, as combinações propostas alcançaram precisão média de 98,05% com a SPWVD+GoogLeNet_{opt} e 97,41% com a SPWVD+SqueezeNet_{opt}, enquanto a combinação proposta por Huynh-The et al. (2021) alcançou 96,33%. Em -18 dB, a combinação proposta SPWVD+GoogLeNet_{opt} obteve precisão de 39%, superando a precisão de 25% relatada por Huynh-The et al. (2021). Essa diferença de 14 p.p. equivale a uma melhoria de 56%.

Os resultados alcançados pelo presente trabalho, especialmente em valores baixos de SNR, fornecem a um sistema MAGE uma opção para melhoria de sua eficácia e, consequentemente, de sua capacidade de reação antecipada frente a ameaças que empregam guiagem baseada em radares LPI como, por exemplo, mísseis.

6. CONCLUSÕES

No contexto da identificação automática de sinais de radares LPI, este artigo apresenta as seguintes contribuições: (i) fornecer evidências experimentais de que o emprego da técnica SPWVD pode levar a um ATR com melhor desempenho em comparação com modelos tradicionais que utilizam a técnica CWD; (ii) propor duas novas combinações de ATR, nas quais o pré-processamento foi baseado na técnica SPWVD e os classificadores foram baseados nas CNN *SqueezeNet* e *GoogLeNet*. Essas combinações de ATR superaram as abordagens existentes na literatura em uma ampla

faixa de SNR, de -18 a +10 dB, considerando 13 modulações intrapulso distintas; (iii) disponibilizar dois grandes bancos de imagens, cada um contendo 403.000 amostras, para uso em experimentos futuros nesta área; e (iv) apresentar uma opção de ATR, baseada em IA, para um sistema MAGE. Tais resultados contribuem para o fortalecimento do domínio científico e tecnológico nacional na área de GE Radar e, conseqüentemente, para o fortalecimento da soberania nacional na área de Defesa.

Como trabalhos futuros, pretende-se avaliar novas combinações de ATR, considerando diferentes tipos de sinais LPI, novas técnicas de TFA e redes CNN distintas.

REFERÊNCIAS

- CHOI, H. I.; WILLIAMS, W. J. Improved time-frequency representation of multicomponent signals using exponential kernels. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 37, n. 6, p. 862-871, 1989. <https://doi.org/10.1109/ASSP1989.28057>
- FACELI, K.; LORENA, A. C.; GAMA, J.; ALMEIDA, T. A.; CARVALHO, A. C. P. L. F. Inteligência artificial: uma abordagem de aprendizado de máquina. *IEEE*, v. 1, p. 100, 2021.
- HUYNH-THE, T. DOAN, V.-S.; HUA, C.-H.; PHAM, Q.-V.; NGUYEN, T.-V.; KIM, D.-S. Accurate LPI radar waveform recognition with CWD-TFA for deep convolutional network. *IEEE Wireless Communications Letters*, v. 10, n. 8, p. 1638-1642, 2021. <https://doi.org/10.1109/LWC.2021.3075880>
- IANDOLA, F. N.; HAN, S.; MOSKEWICZ, M. W.; ASHRAF, K.; DALLY, W. J.; KEUTZER, K. *SqueezeNet*: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. arXiv preprint arXiv:1602.07360, 2016. <https://doi.org/10.48550/arXiv.1602.07360>
- KONG, S. H.; KIM, M.; HOANG, L. M.; KIM, E. Automatic LPI radar waveform recognition using CNN. *IEEE*, p. 4207-4219, 2018. <https://doi.org/10.1109/ACCESS.2017.2788942>
- LIU, Z.; WANG, J.; WU, T.; HE, T.; YANG, B.; FENG, Y. A method for LPI radar signals recognition based on complex convolutional neural network. *International Journal of Numerical Modelling Electronic Networks Devices and Fields*, v. 37, n. 1, e3155, 2024. <https://doi.org/10.1002/jnm.3155>
- MA, N., WANG, J. Dynamic threshold for SPWVD parameter estimation based on Otsu algorithm. *Journal of Systems Engineering and Electronics*, v. 24, n. 6, p. 919-924, 2013.
- MILCZAREK, H.; DJUROVIĆ, I.; LEŚNIK, C.; JAKUBOWSKI, J. Automatic classification of frequency-modulated radar waveforms under multipath conditions. *IEEE Sensors Journal*, v. 23, n. 16, p. 18349-18361, 2023. <https://doi.org/10.1109/JSEN.2023.3284610>
- NIRANJAN, R. K.; RAMA RAO, C. B.; SINGH, A. K. FPGA based identification of frequency and phase modulated signals by time domain digital techniques for ELINT systems. *Defence Science Journal*, v. 71, n. 1, p. 79-86, 2021. <https://doi.org/10.14429/dsj.71.15705>
- PACE, P. E. Detecting and classifying low probability of intercept radar. *Artech house*, 2009.
- SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D. Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015. p. 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- WALENCZYKOWSKA, M.; KAWALEC, A.; KRENC, K. An application of analytic wavelet transform and convolutional neural network for radar intrapulse modulation recognition. *Sensors*, v. 23, n. 4, 1986, 2023. <https://doi.org/10.3390/s23041986>
- WAN, C.; SI, W.; DENG, Z. Research on modulation recognition method of multi-component radar signals based on deep convolution neural network. *IET Radar, Sonar & Navigation*, v. 17, n. 9, p. 1313-1326, 2023. <https://doi.org/10.1049/rsn2.12421>
- WILLETTS, B.; RITCHIE, M.; GRIFFITHS, H. Optimal time-frequency distribution selection for LPI radar pulse classification. *2020 IEEE International Radar Conference (RADAR)*, 2020. p. 327-332. <https://doi.org/10.1109/RADAR42522.2020.9114598>