

Combinando Redes Neurais Convolucionais e Distribuição Smoothed Pseudo Wigner Ville na Classificação de Sinais Radar de Baixa Probabilidade de Intercepção

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

¹Seção de Engenharia de Computação
Instituto Militar de Engenharia (IME) – Rio de Janeiro, RJ – Brasil

²Coordenadoria de Eletrônica – Escola Naval (EN)
Rio de Janeiro, RJ – Brasil

braz.edgard@ime.eb.br, jorge.amaral@marinha.mil.br

ronaldo.rgold@ime.eb.br

Abstract. *Radar Electronic Warfare has a fundamental role in the defense of the nations. To adapt it to current threats, it is necessary to use automatic recognition algorithms for intrapulse modulations (ATR) of Low Probability of Interception (LPI) radar signals. The main existing LPI signal ATR combine the Choi-Williams Distribution with Convolutional Neural Networks (CNN). This work proposes a combination based on the Smoothed Pseudo-Wigner-Ville distribution (SPWVD) and the CNN SqueezeNet, to obtain a better-performing ATR. The proposed combination achieved 97,8% classification accuracy for 13 types of modulations and 806,000 samples generated. The datasets with such samples are available for research.*

Resumo. *A Guerra Eletrônica radar tem um papel fundamental na defesa das nações. Para adequá-la às ameaças atuais, é necessário usar algoritmos de reconhecimento automático de modulações intrapulso (ATR) de sinais radar de Baixa Probabilidade de Intercepção (LPI). Os principais ATR de sinais LPI existentes combinam a Distribuição Choi-Williams com Redes Neurais Convolucionais (CNN). Este trabalho propõe uma combinação baseada na distribuição Smoothed Pseudo-Wigner-Ville (SPWVD) e na CNN SqueezeNet, a fim de obter um ATR de melhor desempenho. A combinação proposta alcançou 97,8% de acurácia de classificação para 13 tipos de modulações e 806.000 amostras geradas. Os datasets com tais amostras estão disponíveis para pesquisa.*

1. Introdução

Atualmente, a Guerra Eletrônica (GE)¹ tem assumido um papel fundamental na defesa dos países ao redor do mundo. Cada vez mais, *Medidas de Apoio à GE* (MAGE) têm se tornado essenciais para aprimorar processos de detecção, identificação e proteção contra equipamentos inimigos como mísseis, por exemplo. No contexto de detecção de mísseis,

¹Conjunto de ações que visam assegurar o uso do espectro eletromagnético por forças amigas e impedir, reduzir ou prevenir seu uso por forças inimigas [da Defesa 2004].

tem-se buscado incorporar sistemas de Inteligência Eletrônica (ELINT – *Electronic Intelligence*) a equipamentos MAGE voltados à identificação de sinais radar de Baixa Probabilidade de Intercepção (LPI - *Low Probability of Interception*) [Kong et al. 2018]. Devido ao emprego de modelos robustos de reconhecimento automático de modulações intrapulso (ATR – *Automatic Target Recognition*) de sinais radar LPI, os sistemas de ELINT possuem bom desempenho, mesmo em ambientes com baixa relação sinal ruído (SNR - *Signal to Noise Ratio*) [Liu et al. 2024]. Para fins de simplificação do texto, neste artigo, a sigla ATR será utilizada em substituição à expressão *modelo de ATR*.

Nos últimos anos, diversos ATR de sinais radar LPI foram desenvolvidos a partir de diferentes algoritmos de classificação, tais como: Redes Neurais Artificiais clássicas (ANN – *Artificial Neural Networks*) [Milczarek et al. 2023], Árvores de Decisão (DT - *Decision Trees*) [Niranjan et al. 2021], e Redes Neurais Convolucionais (CNN – *Convolutional Neural Networks*) [Liu et al. 2024], dentre outros [Kong et al. 2018]. Para serem aplicados, tais ATR requerem que os sinais sejam pré-processados por meio de técnicas de TFA (*Time-Frequency Analysis*)². As principais técnicas de TFA empregadas em ATR de sinais radar LPI são: Distribuição Choi-Williams (CWD) [Liu et al. 2024]; Transformada de Fourier de Tempo Curto (STFT) [Walencykowska et al. 2023]; e variações da Distribuição de Wigner-Ville (WVD) [Wan et al. 2023], [Willets et al. 2020], como, por exemplo, a Smoothed Pseudo-Wigner-Ville (SPWVD). A SPWVD é uma das mais eficazes técnicas de TFA para a estimação de diferentes parâmetros temporais e espectrais de sinais radar LPI, principalmente, em situações com forte influência de ruído [Ma and Wang 2013]. Apesar da boa capacidade de concentrar a energia do sinal LPI no plano tempo-frequência de modo a permitir sua correta identificação provida pela SPWVD, até onde foi possível observar, os trabalhos da literatura que combinaram a técnica TFA-CWD³ com alguma CNN foram os que obtiveram melhor desempenho na identificação de sinais radar LPI [Liu et al. 2024, Huynh-The et al. 2021, Kong et al. 2018].

Ao analisar tais trabalhos, pode-se perceber que, embora todos tenham adotado diferentes métodos de TFA no pré-processamento dos sinais, não houve qualquer iniciativa de se buscar otimizar os hiperparâmetros das CNN utilizadas, em função do pré-processamento realizado. Iniciativas de otimização de hiperparâmetros nas aplicações de Aprendizado de Máquina se justificam, uma vez que, em geral, o desempenho dos modelos de classificação varia em função dos dados e do pré-processamento realizado sobre os dados [Faceli et al. 2021]. Apesar disso, em todos os referidos trabalhos, foi adotada a parametrização *default* das implementações das CNN utilizadas.

Diante do exposto, este trabalho levanta a seguinte hipótese: *A utilização de uma CNN com hiperparâmetros otimizados em função da técnica de TFA utilizada no pré-processamento dos sinais radar LPI pode levar a resultados em que a combinação TFA+CNN⁴, onde a TFA seja a SPWVD, apresente desempenho superior à combinação em que a TFA seja a CWD.*

²Uma técnica de TFA consiste em converter os sinais do domínio do tempo para o domínio do tempo-frequência [Pace 2009].

³Também para fins de simplificação do discurso, será adotada, no decorrer do artigo, a expressão *técnica TFA-X* para denotar a expressão *técnica de TFA X*, onde X é uma técnica de TFA.

⁴Neste trabalho a notação TFA+CNN será utilizada para denotar a aplicação da técnica TFA no pré-processamento dos dados, seguida da aplicação da CNN indicada sobre os dados pré-processados.

Assim, a fim de obter evidências de validade da hipótese levantada acima, o presente trabalho teve como objetivo analisar os resultados gerados pelas combinações SPWVD+SqueezeNet_{opt} e CWD+SqueezeNet_{opt} em 13 tipos de modulações intrapulso de sinais radar LPI, onde SPWVD+SqueezeNet_{opt} e CWD+SqueezeNet_{opt} foram versões da CNN SqueezeNet com hiperparâmetros otimizados treinadas após a aplicação da TFA-SPWVD e da TFA-CWD sobre os dados, respectivamente. As 13 modulações testadas foram geradas considerando uma faixa de valores aleatórios para seus respectivos parâmetros, a fim de construir duas bases de Imagens de Tempo-Frequência (TFI - *Time-Frequency Image*): uma resultante do emprego da técnica TFA-SPWVD (SPWVD-TFI) e a outra resultante do emprego da técnica TFA-CWD (CWD-TFI). Cada uma dessas bases contém 403.000 TFI⁵. A combinação SPWVD+SqueezeNet_{opt} atingiu acurácia de classificação média de 97,8% em 0dB de SNR, superando tanto os resultados obtidos em trabalhos relacionados anteriores quanto os resultados obtidos pela combinação CWD+SqueezeNet_{opt}, confirmando a hipótese considerada.

O presente texto está estruturado em mais cinco seções. A Seção 2 apresenta as técnicas de TFA adotadas para geração das bases de TFI utilizadas nos experimentos. A Seção 3 apresenta os trabalhos considerados estado da arte na identificação de sinais radar LPI. A Seção 4 descreve a metodologia empregada nos experimentos deste trabalho, detalhando o processo de criação das bases de TFI e a estrutura dos classificadores baseados na SqueezeNet. A Seção 5 descreve os resultados obtidos e compara tais resultados com aqueles do estado da arte. A Seção 6 apresenta as reflexões finais da pesquisa realizada, elencando as principais contribuições do trabalho, bem como algumas propostas para futuras investigações.

2. Fundamentação Teórica

Diversas técnicas de pré-processamento de sinais radar LPI têm sido desenvolvidas. Dentre elas, podem ser destacadas as TFA WVD (e suas variações) e CWD, cuja utilização tem contribuído para a melhoria do desempenho de ATR.

A WVD permite uma concentração no tempo-frequência ótima quando comparada com outras TFA [Pace 2009]. Entretanto, apresenta Termos Cruzados (CT - Cross-Terms)⁶. Como forma de reduzir a influência dos CT, surgiu a Distribuição Pseudo-Wigner-Ville (PWVD) que inclui uma janela deslizante de análise ao longo do eixo de frequência [Pace 2009]. Como um aprimoramento da PWVD, criou-se a CWD, que buscou reduzir a influência dos CT tanto em frequência quanto no tempo. A CWD é definida a partir da transformada de Fourier $X(\omega)$ de $x(t)$ conforme indicada na Equação 1. Nela t é a variável de tempo, ω é a variável de frequência angular, $*$ denota o complexo conjugado, e $\sigma = 1$ é o fator de escala que desempenha um papel vital 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 de Cohen [Pace 2009]. Tipicamente, nesta distribuição, adota-se o kernel exponencial $\phi(\xi, \tau) = e^{-\xi^2\tau^2/\sigma}$ [Choi and Williams 1989].

⁵Disponíveis em https://drive.google.com/drive/folders/1fmqiW9Kf06v6Vc5W0yDVrY93vowqpOg8?usp=drive_link

⁶CT são termos fantasmas que surgem em algumas transformadas no domínio do tempo-frequência.

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

Outra abordagem proposta para atenuar a interferência dos CT da WVD, foi a criação da SPWVD, que introduziu uma janela de suavização tanto em frequência quanto no tempo. A SPWVD é definida pela Equação 2 [Ma and Wang 2013]. Nela, $h(\tau)$ 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 $r(t)$.

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

O efeito visual da interferência decorrente da presença dos CT no domínio do tempo-frequência pode ser observado nos exemplos da Figura 1. Eles mostram o resultado da aplicação de cada TFA em um sinal radar LPI. As TFI resultantes da WVD 1a e da PWVD 1b apresentam valores elevados de CT (observáveis por meio das barras verticais em destaque), em comparação com as TFI produzidas pela CWD 1c e pela SPWVD 1d. Importante notar que, embora sejam TFI similares, a imagem da letra 1d parece apresentar resolução levemente superior à da imagem 1c, sugerindo uma possível vantagem no uso da SPWVD em relação à CWD.

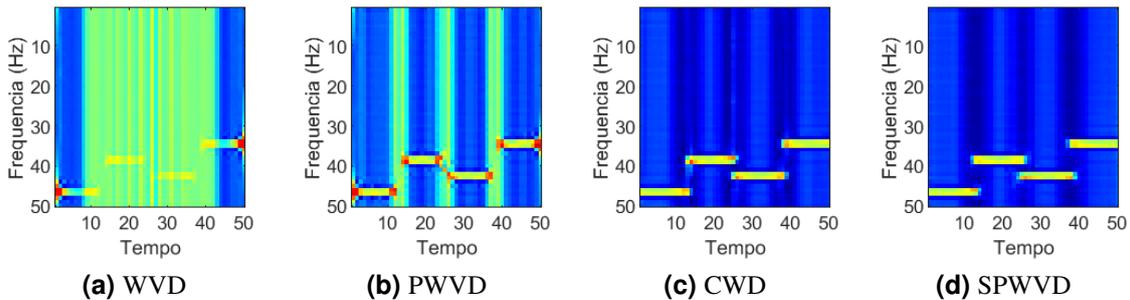


Figura 1. Sinal LPI Costas-4 pré-processado por diferentes TFA.

3. Trabalhos Relacionados

Atualmente, os trabalhos que compõem o estado da arte na área de classificação de sinais radar LPI quanto ao tipo de modulação são os de [Liu et al. 2024], [Huynh-The et al. 2021] e [Kong et al. 2018]. Estes trabalhos obtiveram avanços distintos e encontram-se descritos brevemente a seguir.

Kong et. al. [Kong et al. 2018] conseguiram atingir, até o momento de publicação do artigo, a maior precisão de classificação de sinais radar LPI, usando um banco de dados composto de CWD-TFI, com imagens de 128x128 pixels, e uma CNN denominada LWRT (LPI Radar Waveform Recognition Technique).

Huynh-The et al. [Huynh-The et al. 2021], por sua vez, optaram pelo uso de imagens de 50x50 pixels, pelo emprego da mesma técnica de formação de banco de imagens de TFI, porém pelo emprego de uma CNN denominada LPI-Net. Desta forma, os autores superaram os resultados obtidos por Kong et. al. [Kong et al. 2018], alcançando uma acurácia de 96,33% na faixa de -6dB a 10dB de SNR, mesmo empregando uma rede com um menor número de parâmetros.

Em comparação com seus predecessores, Liu et al. [Liu et al. 2024], optaram por confeccionar uma rede CNN (CV-LPINet) que fosse mais leve e possibilitasse o seu uso em dispositivos com pouca memória, em detrimento de uma queda de acurácia de 4.57 p.p., em relação ao modelo de Huynh-The et al. [Huynh-The et al. 2021]. Liu et al. [Liu et al. 2024] optaram pelo uso do mesmo banco de dados fornecido por Huynh-The et al. [Huynh-The et al. 2021].

A Tabela 1 apresenta algumas das principais características desses trabalhos em comparação com as da presente proposta. Observando-se a referida tabela, percebe-se que o único trabalho que utilizou diferentes técnicas de TFA e comparou resultados entre os modelos de classificação foi [Huynh-The et al. 2021]. No entanto, diferentemente da proposta ora apresentada, as três CNN do tipo LPINet avaliadas nos experimentos descritos em [Huynh-The et al. 2021] foram geradas a partir dos mesmos valores *default* dos hiperparâmetros da implementação utilizada pelos autores, independente da técnica de TFA adotada no pré-processamento dos sinais. Adicionalmente, a proposta do presente trabalho foi a única a avaliar e comparar os efeitos do emprego da TFA-SPWVD e da TFA-CWD nos mesmos sinais. Tal estratégia baseou-se na expectativa de que mesmo com pequenas diferenças de resolução, como as ilustradas na Figuras 1d e 1c, a TFA-SPWVD pudesse prover uma maior capacidade de concentrar a energia do sinal radar LPI, no plano tempo-frequência, permitindo a sua correta identificação e levando a melhores resultados de classificação do que a TFA-CWD.

Tabela 1. Principais características dos trabalhos relacionados e desta proposta

Trabalhos	Técnicas de TFA	Tipo de CNN	Otimiz. Hiper.	Faixa de SNR (dB)		Total de sinais LPI	Total de Parâmetros da CNN
				de	a		
Kong ^a	CWD	LWRT	Não	-20	10	12	2 097 512
Huynh-The ^b	CWD, STFT, WVD	LPINet	Não	-20	10	13	288 768
Liu ^c	CWD	CV-LPINet	Não	-18	10	12	9784
Proposta	CWD, SPWVD	SqueezeNet	Sim	-20	10	13	729 100

^a[Kong et al. 2018];^b [Huynh-The et al. 2021];^c [Liu et al. 2024].

4. Metodologia Proposta

Com o objetivo de validar a hipótese levantada neste trabalho, empregou-se a metodologia graficamente representada na Figura 2. Esta metodologia é composta pelas 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 e TFA-SPWVD a fim de produzir as Bases SPWVD-TFI e CWD-TFI; treinamento e teste dos modelos de classificação quanto ao tipo de modulação; e avaliação dos resultados obtidos. As próximas subseções detalham cada uma dessas etapas.

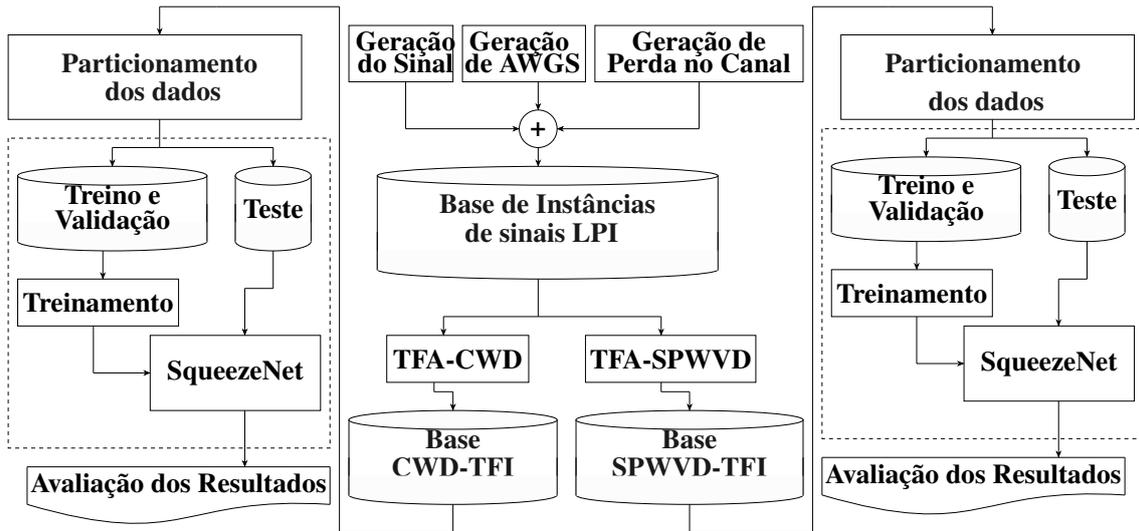


Figura 2. Fluxograma da Metodologia Adotada nos Experimentos.

4.1. Criação da Base de Instâncias de sinais radar LPI

Para a criação da Base de Instâncias de sinais radar LPI foi feita a modelagem do receptor de um sistema de radar considerando que a amostra complexa de um sinal radar LPI interceptado é perturbada pelo AWGN e pela perda no canal, conforme indicado na equação: $y(k) = x(k) \otimes h(k) + n(k)$. Nesta equação: $x(k)$ representa o sinal gerado na etapa Geração do Sinal, ou seja, livre de ruído; $h(k)$ corresponde à interferência proveniente do canal decorrente da etapa Geração de Perda no Canal de transmissão; $n(k)$ 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*).

É importante ressaltar que o presente trabalho buscou empregar um mecanismo de criação da base de dados que fosse idêntico ao empregado nos trabalhos relacionados. Para tanto, foram utilizados os códigos fonte de geração de sinais radar LPI fornecidos pelos autores de [Liu et al. 2024], após contato por correspondência eletrônica. Além disso, a base de dados foi criada usando as mesmas modulações intrapulso e as mesmas faixas para os respectivos parâmetros indicados na Tabela 1. Assim, foram gerados 13 diferentes tipos de modulações 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). Semelhante ao adotado por [Huynh-The et al. 2021], o ruído foi criado na etapa Geração de

AWGN variando-se a faixa de SNR de $-20dB$ a $+10dB$ com incremento de $1,0dB$, da mesma forma, a interferência gerada pela perda do canal de transmissão foi criada na etapa Geração de Perda no Canal e modelada conforme o desvanecimento de Rayleigh. As diferentes instâncias de sinal constituintes da Base de Sinais LPI foram criadas a partir da variação aleatória dos parâmetros específicos de cada modulação intrapulso de acordo com as especificações de [Huynh-The et al. 2021] e detalhadas na Figura 3.

Notações		Formas de onda LPI		
Param.	Descrição	Tipos	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	Rect	B	$U(f_s/20, f_s/15)$
N	Número de Amostras		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
Configurações do Canal			n_g	{4, 5, 6}
Modelo	Desvanecimento Rayleigh		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. Faixas de valores dos parâmetros utilizados na geração das instâncias dos sinais LPI. Adaptado de [Huynh-The et al. 2021].

4.2. Pré-processamento e Criação das Bases CWD-TFI e SPWVD-TFI

Conforme especificado em [Huynh-The et al. 2021], para a geração das Bases CWD-TFI e SPWVD-TFI, inicialmente, cada sinal radar LPI foi pré-processado empregando as técnicas TFA-SPWVD e TFA-CWD. 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 Figura 4 apresenta exemplos de TFI obtidos a partir da TFA-SPWVD com SNR de $+10dB$.

Assim sendo, conforme previamente indicado na Tabela 2, foram geradas duas bases de dados contendo 403.000 TFI (31 Níveis de SNR * 13 sinais LPI * 1000 Instâncias de Sinais LPI) cada.

4.3. Treinamento e Teste do Classificador

Na etapa de Particionamento dos Dados, cada base de TFI foi dividida em cinco conjuntos disjuntos de forma a viabilizar a aplicação da técnica de validação cruzada. A cada rodada da validação cruzada, os dados foram separados de forma estratificada na proporção de

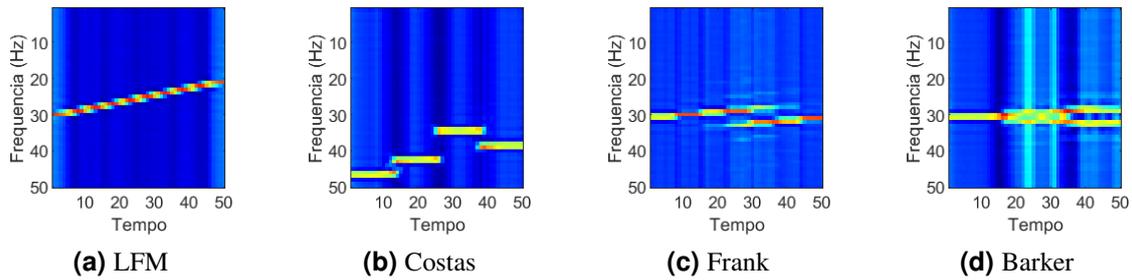


Figura 4. Exemplos de TFI da base SPWVD-TFI.

Tabela 2. Bases de TFI geradas neste trabalho

Bases de TFI	Níveis de SNR (-20dB a 10dB com o incremento de 1dB)	Tipos de Modulações Intrapulso	Instâncias de Sinais LPI	Total de TFI
CWD-TFI	31	13	1.000	403.000
SPWVD-TFI	31	13	1.000	403.000

70-15-15 para os *datasets* de treinamento, validação e teste, respectivamente, de forma análoga ao processo e à proporção adotados por [Huynh-The et al. 2021].

Na etapa de treinamento e teste dos modelos de classificação, optou-se por empregar a CNN SqueezeNet⁷. A escolha por esta CNN deveu-se, fundamentalmente, ao fato dela apresentar um bom desempenho, comparável ao da AlexNet, em tarefa de classificação de imagens, porém com 50 vezes menos parâmetros e 510 vezes menor em tamanho. Tal característica permite que a SqueezeNet seja usada em dispositivos com pouca memória [Iandola et al. 2016]. Adicionalmente, como pode ser observado na Tabela 1, a SqueezeNet é uma rede de tamanho médio em comparação com as demais CNN empregadas pelos trabalhos relacionados. Em termos topológicos, a arquitetura da rede SqueezeNet é distinta da arquitetura de outras CNN, por conta de seus *Fire Modules* que são compostos por camadas *squeeze*, que contêm filtros de convolução 1x1, e por camadas *expand*, que contêm filtros de convolução 1x1 e 3x3. Tal arquitetura pode ser visualizada na Figura 5.

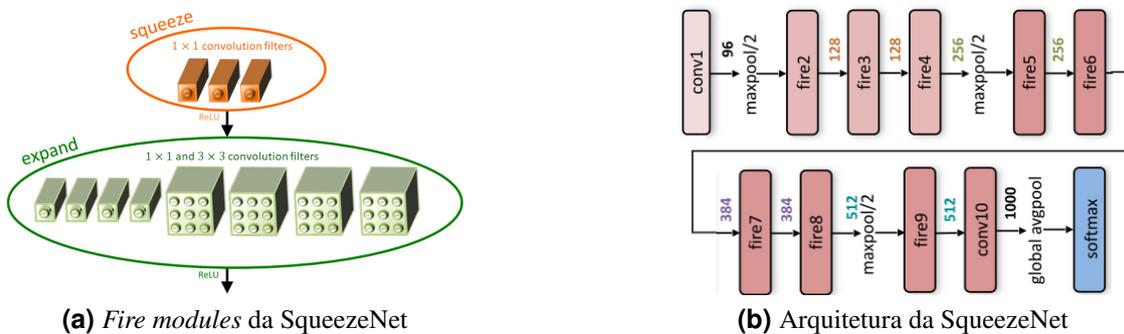


Figura 5. CNN SqueezeNet. Adaptado de [Iandola et al. 2016].

Neste trabalho, optou-se em empregar a versão 1.1 da rede SqueezeNet uma vez

⁷<https://github.com/forresti/SqueezeNet>

que requer 2,4 vezes menos cálculos em relação a versão 1.0, mantendo a mesma precisão⁸. Para o *Fine Tuning* da CNN SqueezeNet v1.1 foi empregado o aplicativo Deep Designer do MATLAB⁹.

Durante o treinamento, foram otimizados os valores dos hiperparâmetros da SqueezeNet aplicada à CWD-TFI (CNN_{CWD}) e da SqueezeNet aplicada à SPWVD-TFI (CNN_{SPWVD}) por meio de buscas bayesianas empregando o aplicativo Experiment Manager do MATLAB¹⁰ nas respectivas bases de imagens, ao longo do processo de validação cruzada. Tais buscas foram executadas empregando o método de gradiente descendente estocástico com momento (SGDm - Stochastic Gradient Descent with Momentum) como otimizador. Os valores ótimos encontrados para os hiperparâmetros (associados ao modelo da SqueezeNet com melhor desempenho identificado durante o processo de validação cruzada), assim como as suas respectivas faixas de busca, durante o treinamento, podem ser visualizados na Tabela 3. Em todos os modelos construídos durante a validação cruzada foi utilizado o valor 128 como tamanho de *minibatch*.

Tabela 3. Faixas de busca e valores ótimos encontrados para os hiperparâmetros das CNN SqueezeNet durante a validação cruzada.

Parâmetro Selecionado	Faixa Avaliada		Valor Ótimo Obtido	
	de	a	CWD+ SqueezeNet _{opt}	SPWVD+ SqueezeNet _{opt}
Taxa de Aprendizagem Inicial	0.1	0.0005	0.0009	0.0081
Momento	0.98	0.8	0.8631	0.8494
Regularização L2	0.01	10^{-10}	$9.3111 * 10^{-7}$	0.0001
<i>Learn Rate Drop Period</i>	10 épocas	1 época	10 épocas	10 épocas
<i>Learn Rate Drop Factor</i>	0.2	0.01	0.1	0.1

Por fim, a etapa de avaliação dos resultados consistiu em comparar os resultados obtidos pelas combinações SPWVD+SqueezeNet_{opt} e CWD+SqueezeNet_{opt} entre si e com os resultados reportados pelos trabalhos do estado da arte.

Todos os experimentos foram realizados em uma plataforma 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.

5. Resultados

A fim de obter evidências que apontem para a validade da hipótese levantada neste trabalho, foram realizadas três análises a partir da avaliação dos resultados obtidos.

Na primeira análise, foram comparados os melhores resultados das combinações CWD+SqueezeNet_{opt} e SPWVD+SqueezeNet_{opt} obtidos durante o processo de validação cruzada. Tais resultados podem ser observados na Figura 6. Ela apresenta os valores de precisão obtidos por cada combinação testada considerando os 13 tipos de sinais LPI e variando-se a SNR entre $-20dB$ e $10dB$. Ressalta-se que, para

⁸https://github.com/forresti/SqueezeNet/tree/master/SqueezeNet_v1.1.

⁹<https://www.mathworks.com/help/deeplearning/ref/deepnetworkdesigner-app.html>.

¹⁰<https://www.mathworks.com/help/matlab/ref/experimentmanager-app.html>.

valores de SNR mais altos, acima de $0dB$, a precisão se aproxima de 100% em todos os tipos de sinais LPI testados. Adicionalmente, nota-se que em $-20dB$ o sinal Barker apresentou $97,4\%$ de precisão com a $CWD+SqueezeNet_{opt}$ e $84,3\%$ de precisão com a $SPWVD+SqueezeNet_{opt}$. Em contrapartida, também em $-20dB$ de SNR, o sinal T1 apresentou $50,7\%$ de precisão com a $CWD+SqueezeNet_{opt}$ e $69,6\%$ com a $SPWVD+SqueezeNet_{opt}$. Outra observação importante foram os bons resultados obtidos para os sinais T1 a T4 empregando-se a $SPWVD+SqueezeNet_{opt}$, em comparação com os resultados obtidos com a $CWD+SqueezeNet_{opt}$, principalmente nos SNR negativos. Por outro lado, em $-15dB$ de SNR, os resultados obtidos com a $CWD+SqueezeNet_{opt}$ foram melhores que os resultados obtidos com a base $SPWVD+SqueezeNet_{opt}$, considerando apenas os sinais Costas e LFM.

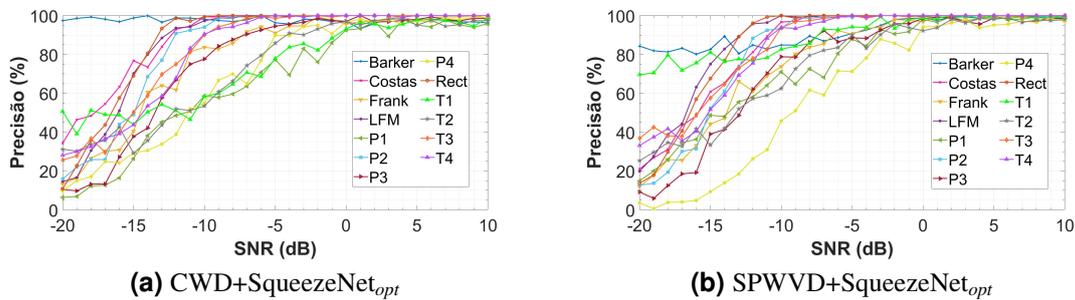


Figura 6. Comparação de precisão de classificação dos 13 sinais LPI testados.

Em resumo, com base nos resultados obtidos na primeira análise, percebe-se que as duas combinações apresentaram resultados comparáveis, ou seja, cada uma das combinações apresentou resultados melhores para alguns tipos de sinais radar LPI e piores para outros tipos, não havendo, portanto, uma combinação que supere a outra 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 média obtidos considerando todos os 13 tipos de sinais radar LPI juntos e as 5 rodadas de validação cruzada executadas. Desta forma, foram calculados o valor de acurácia média para cada combinação testada e em toda a faixa de valores de SNR considerada, conforme ilustrado na Figura 7. Ao observar esta figura, percebe-se que a combinação $SPWVD+SqueezeNet_{opt}$ apresentou valores de acurácia média superiores em toda faixa de valores de SNR em comparação com a combinação $CWD+SqueezeNet_{opt}$. Adicionalmente, ressalta-se que para valores elevados de SNR, os valores de acurácia média se aproximam de 100% , independente de se utilizar a $CWD+SqueezeNet_{opt}$ ou a $SPWVD+SqueezeNet_{opt}$. Como exemplo, cita-se que em $0dB$ foi obtida a acurácia de $97,36\%$ com a $CWD+SqueezeNet_{opt}$ e $97,83\%$ com a $SPWVD+SqueezeNet_{opt}$. Outro ponto das curvas da Figura 7 que reflete um melhor desempenho da combinação $SPWVD+SqueezeNet_{opt}$ em relação a $CWD+SqueezeNet_{opt}$ ocorre na SNR de -15 . Neste ponto de SNR, a acurácia com a $SPWVD+SqueezeNet_{opt}$ fica $4,4$ p.p acima daquele obtido com a $CWD+SqueezeNet_{opt}$.

Ainda na segunda análise, com base nos valores da Figura 7 calculou-se o valor de acurácia média geral para toda a faixa de valores de SNR. A acurácia média obtida pela $CWD+SqueezeNet_{opt}$ foi de $79,91 \pm 0,34$ e pela $SPWVD+SqueezeNet_{opt}$

foi de $81,12 \pm 0,22$. Tal resultado apresenta indícios de uma leve superioridade da SPWVD+SqueezeNet_{opt} em relação à CWD+SqueezeNet_{opt}, uma vez que, na média, o pior resultado da SPWVD+SqueezeNet_{opt} (80,9%) mostrou-se superior ao melhor resultado da CWD+SqueezeNet_{opt} (80,25%). Além disso, é importante ressaltar que o desvio padrão da acurácia média da SPWVD+SqueezeNet_{opt} (0,22) foi bem inferior ao apresentado pela CWD+SqueezeNet_{opt} (0,34), indicando que a distribuição dos resultados de acurácia obtidos pela primeira combinação foi mais homogênea que a apresentada pela segunda.

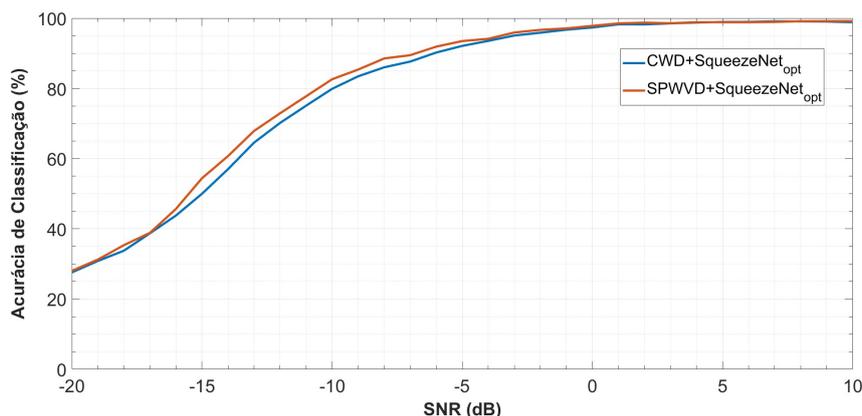


Figura 7. Acurácia média obtida com as combinações SPWVD+SqueezeNet_{opt} e CWD+SqueezeNet_{opt}.

Os resultados observados na primeira e segunda análises são indícios que apontam para a validade da hipótese levantada neste trabalho e de que o emprego da técnica TFA-SPWVD, combinada com uma CNN SqueezeNet treinada com os valores ótimos de hiperparâmetros, pode ser uma opção promissora na identificação das modulações de sinais radar LPI.

A fim de caracterizar o bom desempenho da combinação SPWVD+SqueezeNet_{opt}, proposta neste artigo, foi realizada uma terceira análise. Nesta análise, buscou-se comparar os resultados obtidos pela combinação proposta com os resultados reportados pelas combinações avaliadas nos trabalhos relacionados indicados na Tabela 1. Tal comparação foi considerada viável uma vez que todos os trabalhos avaliaram os desempenhos de suas combinações por meio de validação cruzada e a base de instâncias de sinais radar LPI utilizada neste artigo foi gerada pelo mesmo procedimento e condições de execução adotados pelos trabalhos relacionados em seus experimentos.

A Figura 8 apresenta os gráficos dos valores de acurácia média obtidos pelo presente trabalho e pelos trabalhos relacionados. A partir desta figura, percebe-se que a combinação proposta neste trabalho supera os resultados obtidos por todas as combinações dos trabalhos relacionados em toda a faixa de valores de SNR testados. Adicionalmente, é possível notar que, para SNR acima de $0dB$, os valores de acurácia são elevados e que, especificamente em $0dB$, a combinação proposta obtém expressivos 97,8% de acurácia média. Considerando-se a faixa de $-6dB$ a $10dB$ de SNR, a acurácia média obtida pela combinação proposta foi 97,41%, enquanto que pela combinação proposta por [Huynh-The et al. 2021] foi 96,33%. No limite inferior da faixa de SNR, ou seja, em $-18dB$, o valor de acurácia obtido pelo presente trabalho foi de 35%, enquanto que o

obtido por [Huynh-The et al. 2021] foi de 25%, ou seja, uma diferença de 10 p.p. ou um resultado 40% melhor, mesmo diante de alto nível de ruído. O ganho alcançado pelo presente trabalho, principalmente sob baixos valores de SNR, confere ao ELINT, incorporado a um sistema MAGE, uma melhor capacidade de reação antecipada contra ameaças que empregam a tecnologia de guiagem baseada em radares LPI, como, por exemplo, contra mísseis. Tal ganho, embora abaixo de 50% para SNR menores do que $-16dB$, indica que o modelo desenvolvido pode propiciar uma detecção de ataques com maior antecipação do que os existentes no estado da arte. Ressalta-se que os sinais radar transmitidos por um míssil dotado de radar LPI possuem muito baixa potência e estão imersos em ruído. Portanto, o maior alcance de detecção de um MAGE estará limitado ao menor valor de SNR em que esse MAGE é capaz de detectar corretamente um sinal LPI.

Em resumo, os resultados da terceira análise reforçam os indícios de que a combinação SPWVD+SqueezeNet_{opt} se apresenta como uma alternativa promissora às combinações do estado da arte na identificação das modulações de sinais radar LPI.

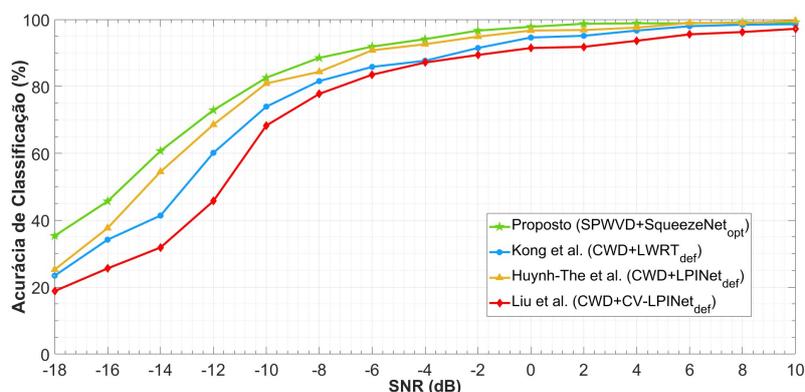


Figura 8. Valores de acurácia média dos ATR dos trabalhos relacionados e do ATR proposto (obtidos a partir do conjunto de teste).

6. Considerações Finais

Diante do problema de identificação automática de sinais radar de baixa probabilidade de interceptação (LPI), este artigo apresentou as seguintes principais contribuições: (i) evidências experimentais de que o uso, até então inédito, da técnica de TFA SPWVD no pré-processamento dos sinais pode propiciar a construção de modelos de classificação com melhor desempenho do que os modelos construídos a partir da técnica de TFA CWD, atual estado da arte na solução do referido problema; (ii) uma nova combinação TFA+CNN, onde TFA=SPWVD e CNN=SqueezeNet, que apresentou valores de acurácia melhores que as combinações disponíveis na literatura para a faixa de valores de SNR de $-18dB$ a $+10dB$ e considerando 13 diferentes modulações intrapulso, possibilitando a um MAGE alcançar maior eficácia na reação antecipada contra ameaças que utilizem sinais radar LPI; (iii) a disponibilização, para uso em experimentos na área, de duas bases de imagens com 403.000 amostras cada.

Como trabalhos futuros, em busca de mais evidências que confirmem a hipótese levantada neste artigo e de melhorias no estado da arte na detecção de modulações de sinais radar LPI, pretende-se avaliar o desempenho de novas combinações TFA+CNN, como, por exemplo, a combinação da SPWVD com outras CNN mais atuais que a SqueezeNet, assim como, de outras técnicas de TFA com tais CNN.

Referências

- Choi, H.-I. and Williams, W. J. (1989). Improved time-frequency representation of multicomponent signals using exponential kernels. *IEEE Trans on Acoustics, Speech, and Signal Processing*, 37(6):862–871.
- da Defesa, M. (2004). Política de ge de defesa. Portaria 333/MD. Art. 4.
- Faceli, K., Lorena, A. C., Gama, J., Almeida, T. A. d., and Carvalho, A. C. P. d. L. F. d. (2021). *Inteligência artificial: uma abordagem de aprendizado de máquina*. LTC.
- Huynh-The, T. et al. (2021). Accurate lpi radar waveform recognition with cwd-tfa for deep convolutional network. *IEEE Wireless Com. Letters*, 10(8):1638–1642.
- Iandola, F. N. et al. (2016). Squeezenet: Alexnet-level accuracy with 50x fewer parameters and 0.5 mb model size. *arXiv preprint arXiv:1602.07360*.
- Kong, S.-H. et al. (2018). Automatic lpi radar waveform recognition using cnn. *Ieee Access*, 6:4207–4219.
- Liu, Z. et al. (2024). A method for lpi radar signals recognition based on complex convolutional neural network. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 37(1):e3155.
- Ma, N. and Wang, J. (2013). Dynamic threshold for spwvd parameter estimation based on otsu algorithm. *Journal of Systems Engineering and Electronics*, 24(6):919–924.
- Milczarek, H. et al. (2023). Automatic classification of frequency-modulated radar waveforms under multipath conditions. *IEEE Sensors Journal*.
- Niranjan, R., Rama Rao, C., and Singh, A. (2021). Fpga based identification of frequency and phase modulated signals by time domain digital techniques for elint systems. *Defence Science Journal*, 71(1).
- Pace, P. E. (2009). *Detecting and classifying low probability of intercept radar*. Artech house.
- Walencykowska, M., Kawalec, A., and Krenc, K. (2023). An application of analytic wavelet transform and convolutional neural network for radar intrapulse modulation recognition. *Sensors*, 23(4):1986.
- Wan, C., Si, W., and Deng, Z. (2023). Research on modulation recognition method of multi-component radar signals based on deep convolution neural network. *IET Radar, Sonar & Navigation*.
- Willetts, B., Ritchie, M., and Griffiths, H. (2020). Optimal time-frequency distribution selection for lpi radar pulse classification. In *2020 IEEE Int Radar Conf (RADAR)*, pages 327–332. IEEE.