

Avanços da detecção de sinais de tiros baseada em sensores acústicos

José Antonio Apolinário Junior¹, apolin@ime.eb.br, Orcid 0000-0003-1426-9636

Lucas Rafael de Aguiar Silva¹, lucas.silva@ime.eb.br, Orcid 0009-0007-8139-4644

¹ Instituto Militar de Engenharia (IME) – SE/3

RESUMO: A detecção de sinais acústicos impulsivos e sua classificação como disparos de arma de fogo desempenham um papel crucial em sistemas destinados a localizar a origem de tiros por caçadores ou atiradores em geral. Com aplicações de relevância no contexto militar, os sistemas de detecção de tiros enfrentam desafios substanciais relacionados ao seu uso em ambientes operacionais, que frequentemente envolvem propagação multipercursos e ruído ambiental. Além disso, esses sistemas precisam ser capazes de operar em tempo real. Este artigo aborda métodos modernos para a detecção e classificação das componentes acústicas dos sinais de tiro, propondo modificações visando aprimorar seus desempenhos e avaliando-os com uma diversificada base de sinais de tiros reais. Os resultados obtidos são comparados para determinar o método que se mostra mais adequado para uma implementação em hardware. O texto fornece insights valiosos para o desenvolvimento de sistemas de detecção de tiros em ambientes desafiadores.

PALAVRAS-CHAVE: Sinais de Tiro. Caçador. Detecção. Classificação. Direção de Chegada.

ABSTRACT: The detection of impulsive acoustic signals and their classification as gunshots plays a crucial role in systems designed to pinpoint the origin of gunshots fired by snipers or regular shooters. With significant applications in the military context, gunshot detection systems face substantial challenges related to their use in operational environments, which often involve multipath propagation and environmental noise. Moreover, these systems need to be capable of real-time operation. This article addresses modern methods for detecting and classifying the acoustic components of gunshot signals, proposing modifications to enhance their performance and evaluating them using a diverse dataset of real-life gunshot signals. The results are compared to determine the most suitable method for hardware implementation. The text provides valuable insights for developing gunshot detection systems in challenging environments.

KEYWORDS: Gunshot Signals. Sniper. Detection. Classification. Direction of Arrival.

1. INTRODUÇÃO

Os conflitos contemporâneos estão intrinsecamente relacionados à aplicação de tecnologia no campo de batalha. A Guerra da Ucrânia, por exemplo, evidencia aplicações militares que englobam mísseis, drones, radares e guerra cibernética [1]. Mesmo assim, recursos militares convencionais persistem de maneira onipresente e letal nas fileiras das forças de segurança. Este trabalho destaca uma ameaça notoriamente silenciosa: os caçadores, conhecidos como *snipers* no vernáculo inglês [2].

Os caçadores, também denominados atiradores de elite ou franco-atiradores, têm a missão de penetrar nas defesas inimigas, utilizando técnicas refinadas de camuflagem, e eliminar alvos estratégicos, causando, assim, confusão nas tropas inimigas [2]. A atuação dos caçadores tem uma aura mística, sendo ressaltada na mídia, como nos filmes *Círculo de Fogo* (de 2001, que narra a história de um soldado soviético chamado

Vasily Zaitsev na Batalha de Stalingrado) [3] e *Sniper Americano* (de 2014, baseado na autobiografia de Chris Kyle, um caçador americano que obteve feitos notórios na Guerra do Iraque) [4]. Outros exemplos notáveis de atiradores de elite incluem o finlandês Simon Häyhä (conhecido como “Morte Branca”) e Lyudmila Pavlichenko (conhecida como “Senhora Morte”), nascida na Província de Kiev (então Império Russo) [5].

As principais táticas contra a ação de franco-atiradores consistem em deslocar a tropa para fora do ângulo de visada do inimigo e alvejá-lo com disparos, a fim de forçá-lo a mudar de posição [2]. No entanto, essas duas ações demandam o conhecimento da direção de onde provém o disparo [6]. Nesse contexto, destaca-se a pesquisa desenvolvida há mais de uma década no Laboratório de Processamento Digital de Sinais (LPDS) do Instituto Militar de Engenharia (IME) [7-13], que visa aprimorar os algoritmos de estimação da direção na qual o atirador inimigo se encontra (DOA, do inglês

Direction of Arrival). Isso é realizado por meio do processamento dos componentes acústicos de um sinal de tiro: a onda de choque (SW, do inglês *Shock Wave*), no caso de um projétil supersônico, e a explosão da carga propelente do projétil (MB, do inglês *Muzzle Blast*).

Soluções comerciais que fornecem essa direção já existem e são aplicadas por exércitos ao redor do mundo. Temos como exemplos os sistemas *Boomerang III*, de origem americana (Raytheon), *TRV-SD 500*, de origem turca (Transvaro) e *Pilar V*, de origem francesa (Metravib Defence) [14-16].

A estimação da direção na qual o caçador realizou um disparo requer uma prévia detecção do tiro, compreendendo duas etapas: a detecção de sinais impulsivos e a classificação em SW ou MB, quando for o caso [6]. Este trabalho objetiva avaliar o desempenho de algoritmos de detecção de sinais de tiros, propor adaptações que visem melhorar seus resultados e indicar a melhor opção para aplicações práticas. Foram analisados quatro métodos neste artigo: o método da correlação cruzada proposto em [7], o método da análise espectral da energia proposto em [17], o método da SNR (Razão Sinal-Ruído, do inglês *Signal to Noise Ratio*) apresentado em [18] e o método utilizando Redes Neurais proposto em [19].

Uma vez detectado um sinal impulsivo, é necessário determinar se ele é oriundo de um sinal de tiro (classificá-lo como SW ou MB) ou não. As SW são ondas acústicas geradas pelo efeito Mach, formadas na trajetória dos projéteis supersônicos lançados, por exemplo, por um fuzil [20]. Por outro lado, o MB corresponde à onda acústica formada pela diferença de pressão entre o meio exterior ao armamento e o gás interior ao armamento aquecido pelo acionamento da carga do projétil [20]. Uma informação relevante sobre o SW é que ele tem um formato em “N” e uma duração entre 0,3 e 0,5 ms, enquanto o MB tem duração entre 3 e 5 ms [20].


2. CONCEITOS FUNDAMENTAIS

2.1 Geometria do problema

A geometria típica da detecção do disparo de um caçador é composta por três elementos: atirador, alvo

e arranjo de microfones. Um arranjo de microfones é utilizado para permitir a estimação da direção de chegada. A Figura 1 apresenta a disposição desses elementos, além de indicar as frentes de onda de SW e de MB geradas pelo disparo.

Figura 1 - Geometria típica do problema de detecção de um projétil supersônico.



É importante destacar que, havendo um tiro, a configuração típica pode não se passar como indicado na Figura 1, não somente pela ausência da SW, mas também pela ausência da MB. Essas situações ocorrem quando objetos ou barreiras impedem que as ondas acústicas atinjam o arranjo de microfones [6]. No caso da componente SW, ela também pode estar ausente se os microfones estiverem posicionados atrás do atirador e, portanto, fora do campo de visão da onda de choque.

2.2 Detecção de sinal impulsivo

A primeira etapa do processamento abordado neste trabalho consiste em verificar se a janela de tempo do sinal acústico em análise corresponde a um sinal impulsivo. A detecção envolve a averiguação de se um parâmetro específico, obtido pela aplicação de um algoritmo (por exemplo, o pico de correlação cruzada da janela do sinal adquirido com um modelo conhecido de SW), excede um determinado limiar. O treinamento é conduzido pela variação do limiar

em uma faixa de valores, formando, assim, uma curva denominada ROC (acrônimo de *Receiver Operation Characteristic*) [21].

A curva ROC é construída a partir das medidas de desempenho denominadas Taxa de Verdadeiros Positivos (TPR, de *True Positive Rate*) e Taxa de Falsos Verdadeiros (FPR, de *False Positive Rate*). Os conceitos de TPR e FPR, expressos respectivamente pelas Equações (1) e (2) [21], são mais bem compreendidos no contexto de uma matriz de confusão, exemplificada na Tabela 1.

$$TPR = \frac{TP}{TP + FN} \quad (1)$$

$$FPR = \frac{FP}{FP + TN} \quad (2)$$

Na curva ROC, o sistema de eixos FPR $\times$ TPR tem a particularidade de que quanto mais a curva se aproxima do ponto (FPR, TPR) = (0,1), melhor é o desempenho do detector. Como, na prática, esse ponto geralmente não é atingido, o ponto de operação é escolhido com base em critérios operacionais.

Tabela 1 - Matriz de confusão

		Condição Verdade	
		Presente	Ausente
Resultado do Teste	Positivo	TP	FP
	Negativo	FN	TN

2.3 Classificação de sinais de tiro

A classificação de um sinal designado impulsivo envolve a decisão sobre quais componentes estão presentes em uma dada janela de áudio, sendo elas SW, MB ou NT (janela de não tiro, isto é, apesar do sinal ser impulsivo, a presença de um tiro não é caracterizada). Essa tipificação acontece pela extração de parâmetros do sinal e, em seguida, pela aplicação de um critério de classificação nesses parâmetros. Os quatro parâmetros ou características (*features*, como conhecidas em inglês) empregados neste trabalho foram: o pico de correlação cruzada com um modelo, os coeficientes *Linear Predictive Coding* (LPC), os coeficientes *Mel-Frequency Cepstral Coefficients* (MFCC) e a energia normalizada do sinal [7] [17] [18] [19].

Tabela 2 - Vetor de características (*features*)

Parâmetros	Índices
Correlação Cruzada com Modelo de AGLC SW/MB	1 e 2
Correlação Cruzada com Modelo de FAL SW/MB	3 e 4
Correlação Cruzada com Modelo de M2 <i>Browning</i> SW/MB	5 e 6
Correlação Cruzada com Modelo de IA2 SW/MB	7 e 8
Coeficientes LPC (20 ao todo)	9 a 28
Coeficientes MFCC (26 ao todo)	29 a 54
Energia Normalizada do Sinal (Z)	55

A Tabela 2 indica como os parâmetros empregados para a classificação estão distribuídos. Os armamentos mencionados são detalhados na Seção 3.1. Cada método realiza a extração de um número diferente de parâmetros. O processamento (detecção e classificação) é realizado no software Matlab® pelos aplicativos *Classification Learner* ou *Neural Pattern Recognition*, em que a entrada de ambos é uma matriz contendo os parâmetros de um conjunto de janelas, e a saída é uma função que realiza a classificação.

3. METODOLOGIA

A detecção e classificação de sinais impulsivos, como SW ou MB, envolvem diversas etapas iniciais, desde a aquisição dos sinais de áudio até o treinamento de algoritmos responsáveis por atingir automaticamente os objetivos deste trabalho. A seguir, apresentamos os armamentos utilizados, a composição da base de sinais para o treinamento e teste, a preparação da base antes da aplicação dos algoritmos e os métodos analisados, destacando detalhes dos algoritmos originais, assim como as adaptações implementadas.

3.1 Base de sinais e armamentos

Os armamentos utilizados pelos caçadores do Exército Brasileiro, que constituíram a base de sinais,

foram o AGLC, o FAL, o IA2 e o M2 *Browning* [22–25], todos com a capacidade de realizar disparos super-

sônicos. Algumas características técnicas de cada um desses armamentos estão apresentadas na Tabela 3.

Tabela 3 - Características de alguns armamentos empregados por caçadores brasileiros

Armamento	AGLC	IA2	FAL	M2 <i>Browning</i>
Calibre	.308" ou 7,62 mm	7,62 mm	5,56 mm	.50" ou 12,7mm
Velocidade inicial (m/s)	820	840	780	930
Alcance (m)	800	1800	300	300
Fabricante	IMBEL	IMBEL	IMBEL	General Dynamics

A amostragem do sinal foi realizada por um microfone da marca Behringer, modelo ECM8000 [26], usado nos arranjos previamente empregados para a aquisição de áudio da principal base utilizada neste trabalho.

A frequência de amostragem utilizada no processamento dos sinais de áudio foi de 96 kHz. Os sinais que inicialmente haviam sido adquiridos a 44,1 kHz foram reamostrados no Matlab®.

Os sinais foram coletados em quatro estandes de tiro: Centro de Avaliação do Exército (CAEx) 2011, Centro de Instrução de Operações Especiais (CIOpEsp) 2010, CAEx 2014 e Centro de Instrução Almirante Milcíades Portela Alves (CIAMPA) 2010. A Tabela 4 apresenta a distribuição dos sinais de tiros para o treinamento.

Todos os sinais foram divididos em janelas com duração de 20 ms e uma superposição de 50%, permitindo a obtenção de janelas contendo SW, MB ou ausência de sinal de tiro (NT). A distribuição dessas janelas para o treinamento e teste está indicada na Tabela 5. No treinamento, a separação de um número de janelas de SW, MB e NT foi realizada com o objetivo de evitar viés na classificação, procurando manter quantidades equilibradas. No teste, foram empregados 60 áudios completos das bases de tiro (12 do CAEx 2014, 40 do CAEx 2011, 5 do CIOpEsp 2010, e 9 do CIAMPA 2010), simulando, assim, os grandes intervalos de tempo sem disparo de caçador no campo de batalha. Isso resultou em um número discrepante de janelas de NT em relação às outras classes.

Tabela 4 - Distribuição de SW e de MB no treinamento para cada base

Base	Armamento (distâncias)	Número de Sinais
CAEx 2011	AGLC (300 a 700 m)	28 SW e 28 MB
	FAL (300 a 500 m)	20 SW e 20 MB
	IA2 (300 a 500 m)	21 SW e 21 MB
	.50 BMG (300 a 500 m)	16 SW e 15 MB
CIOpEsp	AGLC (200 m)	5 SW e 5 MB
	PSG1 (200 m)	3 SW e 3 MB
CAEx 2014	AGLC (540 a 1062 m)	43 SW e 43 MB
CIAMPA 2010	FAL (31 a 74 m)	23 SW e 10 MB

Tabela 5 - Distribuição das janelas

Tipo de Janela	Treinamento	Teste
SW	159	60
MB	144	60
NT	313	36476

Para avaliar o desempenho do método escolhido mais eficiente, no processamento dos sinais disponíveis no LPDS/IME, em comparação a uma outra base de dados, foram utilizados os sinais de tiros previamente apresentados em outro artigo [27] e disponíveis para download na internet. Nessa segunda base, foram empregados três armamentos distintos: pistolas automáticas calibre .45", .40" e 9 mm; ela possui 12 disparos em 9 posições distintas, totalizando 324 disparos [27]. Os projéteis dessas pistolas não são supersônicos, portanto, o áudio gravado apresenta apenas MB.

3.2 Preparação da base


Considerando que a aquisição dos sinais de tiro ocorreu em diferentes ambientes e com distintos

valores de ganhos de microfones, após a remoção do nível DC (quando presente), procedeu-se à normalização da energia de cada sinal. Com o objetivo de reduzir a influência do ruído, especialmente nas componentes MB dos sinais, os quais, devido às maiores distâncias dos atiradores, apresentam as menores SNRs, aplicou-se um filtro de mediana [9] para realçar as porções impulsivas dos sinais de áudio.

3.2 Métodos

A seguir, serão detalhados os quatro métodos investigados neste trabalho. O treinamento para cada um desses métodos envolve duas etapas: a obtenção de um limiar de detecção (por exemplo, a partir da construção de uma curva ROC e escolha de um ponto de operação) e a geração de um critério ou função (por exemplo, por um algoritmo de aprendizado de máquina) que realize a classificação das janelas em SW, MB ou NT. Ambas as etapas são indicadas na Figura 2. O teste de cada um dos métodos envolve a utilização de um limiar de detecção e um critério de classificação obtidos no treinamento com sinais de áudio dividido em janelas contendo tiros (SW, MB ou ambos) ou não (somente ruído ambiente).

Figura 2 - Fluxograma geral da detecção e classificação.




3.2.1 Método da Correlação Cruzada

Na versão original desse método, a detecção é realizada pela aplicação do algoritmo *Generalized Cross Correlation* (GCC) em cada uma das janelas, indicando um sinal impulsivo caso o valor obtido do pico de correlação cruzada seja superior a um limiar. No treinamento da detecção, conforme mostrado na Figura 3, a correla-

ção cruzada de cada uma das janelas do sinal de treinamento com um modelo (sinal de referência) de SW do AGLC é computada; os picos de correlação cruzada são separados e convertidos em uma matriz de confusão. A obtenção de diversas matrizes de confusão mediante a variação do limiar gera uma curva ROC que permite a escolha do ponto de operação. Em nossos experimentos, o ponto de operação escolhido foi TPR > 90%.

Figura 3 - Delimitação do limiar de detecção do Método da Correlação Cruzada.



Fonte: [7].

O método proposto em [7], como visto, usa exclusivamente a SW do fuzil AGLC como sinal de referência e não apresenta um algoritmo de separação de SW, MB e NT. Neste trabalho, empregamos as componentes SW e MB dos quatro armamentos indicados na Tabela 3, ou seja, os oito primeiros parâmetros (picos de correlação cruzada) do vetor de características detalhado na Tabela 2. Adicionalmente, a versão modificada desse método utiliza como algoritmo de classificação a função não linear gerada no aplicativo *Classification Learner* do Matlab® utilizando o algoritmo de *Support Vector Machine Kernel* (SVM Kernel).

$$E_{Jan} = \sum_k |X(k)|^2 \quad (3)$$

$$D_{Jan} = \frac{E_{(Jan+1)} - E_{(Jan-1)}}{3} \quad (4)$$

Esse método não requer o treinamento da classificação, pois baseia-se simplesmente nas duas condições descritas pelas Equações (5) e (6) [17].

$$S1 : E_{(f>1600Hz)} > 2E_{(f<1600Hz)} \quad (5)$$

$$S2 : Impulso(i) - Impulso(i-1) > 0.2 \quad (6)$$

A Tabela 6 indica como ocorre a classificação nesse método de acordo com as condições S1 e S2 [17].

Tabela 6 - Classificação pelo Método da Análise Espectral de Energia

S1			
		Verdadeiro	Falso
S2	Verdadeiro	SW	NT
	Falso	NT	MB

3.2.3 Análise da SNR

Neste método, a obtenção do limiar de detecção é realizada pela energia normalizada do sinal (Z) [18]. Se o valor de Z de uma janela for superior a um limiar, então existe um sinal impulsivo nessa janela. Seja $x(n) = hs(n) + r(n)$, em que $r(n)$ é o ruído (consi-

3.2.2 Análise espectral da energia

A obtenção do limiar de detecção deste método envolve a computação da energia E_{Jan} obtida da Transformada de Fourier a Tempo Curto (STFT ou *Short Time Fourier Transform*) do sinal $x(n)$ janelado, ou seja, $X(k)$ que corresponde à DFT do produto $x(n)$ por uma janela $w(n)$, em que “n” é o tempo discreto e “k” é o índice (*bin* de frequência) da DFT. De E_{Jan} , obtém-se a função de detecção de sinal impulsivo de cada janela D_{Jan} , conforme Equações (3) e (4) [17]. Se D_{Jan} for maior do que um limiar, assume-se que o sinal da janela é impulsivo [17]. Para obter esse limiar, foi construída uma curva ROC a fim de permitir a escolha do ponto de operação, em nossos experimentos usados valores de TPR > 90%.

derado branco gaussiano), $s(n)$ é o sinal impulsivo que existe caso $h = 1$ (condição da presença de sinal impulsivo). Se $h = 0$, a janela em questão não apresenta um sinal impulsivo [17]. Assim, a energia do sinal da janela normalizada pela energia do ruído naquela janela (parâmetro Z) é dada pela Equação (7) [18].

$$Z = \frac{1}{\sigma_r^2} \sum_{n \in \text{janela}} x^2(n), \quad (7)$$

em que $\sigma_r^2 = \sum_{n \in \text{janela}} r^2(n)$ é uma estimativa da energia do ruído.

O treinamento da detecção desse método se inicia pela obtenção do parâmetro $a = WT$, em que W é a largura de banda dos sinais que têm SW ou MB, e T é o período de amostragem. Em seguida, é determinado o menor valor da SNR das janelas de SW e MB que, com o parâmetro a , é usado para computar P_m (probabilidade de perder um sinal impulsivo) e P_{fa} (probabilidade de indicar que uma janela sem impulso é impulsiva), conforme as Equações (8) e (9), em que Γ é a função Gamma, γ é a função Gamma incompleta inferior, Q_a é a função Marcum Q Generalizada e λ é o decisor [18].

$$P_{fa} = FP = 1 - \frac{\Gamma(a, \frac{\lambda}{2})}{\Gamma(a)} \quad (8)$$

$$P_m = FN = 1 - Q_a(\sqrt{2\gamma}, \sqrt{\lambda}) \quad (9)$$


Em seguida, os gráficos de probabilidades de P_{fa} e de P_m em função de λ são obtidos. O gráfico de P_m é uma função crescente com o aumento de λ , enquanto o gráfico de P_{fa} é uma função decrescente [18]. O ponto de operação escolhido para este artigo foi $P_{fa} < 2\%$.

Para o treinamento da classificação, foram utilizados 18 parâmetros (8 picos de correlação cruzada e 10 coeficientes LPC) como entrada no aplicativo Classification Learner do Matlab®. A função gerada pelo algoritmo de SVM Kernel foi escolhida como critério de classificação devido ao seu melhor desempenho para esse método.

3.2.4 Classificação usando redes neurais

Originalmente, este método não distinguia claramente entre detecção e classificação. Para aprimorá-lo, optamos por incorporar o mecanismo de detecção utilizado no método da SNR [18]. No processo de treinamento da etapa de classificação, utilizamos o aplicativo Neural Pattern Recognition do Matlab®. A entrada consistiu em um vetor de 55 elementos, composto por 8 picos de correlação cruzada, 20 coeficientes LPC, 26 coeficientes MFCC e 1 parâmetro Z . A saída desse aplicativo foi modelada por uma função simulando uma rede neural *feed-forward* de duas camadas: uma camada escondida com dez neurônios (função de ativação sigmoide) e uma camada de saída com três neurônios (função de ativação *softmax*). O algoritmo empregado para o treinamento foi o do Conjugado Gradiente Escalado (*Scaled Conjugate Gradient*). A Figura 4 ilustra a arquitetura da rede neural utilizada neste método.

Figura 4 - Estrutura da rede *feed-forward* usada na classificação pelo Método da Rede Neural.



4. RESULTADOS EXPERIMENTAIS

A Tabela 7 exhibe a análise dos resultados do treinamento, destacando as métricas TPR e FPR para cada um dos métodos, abrangendo tanto a etapa de detecção quanto a etapa de classificação.

Os tempos de execução são detalhados na Tabela 8. Todo o processamento, incluindo treinamento e teste, foi conduzido no ambiente Matlab® utilizando um computador equipado com um processador Intel® Core™ i5-8250U CPU @1.60GHz 1.80 GHz e 8 GB de RAM, sem SSD.

Observa-se que o método da Análise Espectral da Energia apresentou o menor tempo de execução em janelas com impulsos, resultado atribuído ao fato de que o seu algoritmo de classificação dispensa a necessidade de se obter novos parâmetros. O método que utiliza Redes Neurais obteve o segundo melhor desempenho nesse aspecto, mesmo tendo um número maior de parâmetros. Esse resultado se deve à robustez do algoritmo de classificação desse método, que é, ao mesmo tempo, mais simples em comparação com a abordagem de SVM Kernel, uma técnica não linear.

Tabela 7 - Resultado do treinamento

Método	TPR	FPR
Correlação Cruzada	93,79 %	6,21 %
Análise Espectral da Energia	90,03 %	4,70 %
Análise da SNR	97,27 %	5,25 %
Redes Neurais	95,83 %	2,28 %

Tabela 8 - Tempo de execução

Método	Janela sem impulso	Janela com impulso
Correlação Cruzada	2,26 ms	6,49 ms
Análise Espectral da Energia	3,65 ms	3,82 ms
Análise da SNR	1,13 ms	11,72 ms
Redes Neurais	1,02 ms	4,80 ms

A Tabela 9 apresenta os resultados brutos do teste. Nota-se que o método da Correlação Cruzada conseguiu detectar todos os SWs, mas apresentou uma detecção relativamente baixa de MBs em comparação com os outros métodos. O método das redes neurais, por sua vez, alcançou a detecção e classificação do maior número de MBs.

Tabela 9 - Resultados Brutos (janelas corretas)

Método	SW (60)	MB (60)	NT (36476)
Correlação Cruzada	60	17	36471
Análise Espectral da Energia	56	31	36461
Análise da SNR	53	48	36471

Método	SW (60)	MB (60)	NT (36476)
Redes Neurais	55	54	36457

A Tabela 10 mostra os erros de classificação durante o teste. Nela, é possível verificar que os métodos da análise da SNR e das redes neurais apresentaram um número de erros total menor em relação com os outros métodos.

Tabela 10 - Erros brutos (janelas erradas)

	Correlação Cruzada (48)	Análise Espectral da Energia (67)	Análise da SNR (19)	Redes Neurais (30)
SW → MB	0	1	7	5
SW → NT	0	2	0	0
MB → SW	0	3	2	1
MB → NT	43	26	10	5
NT → SW	0	1	1	4
NT → MB	5	34	4	15

A Tabela 11 apresenta os resultados de um coeficiente autoral sugerido, conforme indicado pela Equação (10), no qual o TPR do MB é priorizado em relação ao TPR do SW. Essa escolha foi feita devido ao fato de o algoritmo de estimação da direção do caçador fazer uso das informações do MB como dados de entrada. Sob essa perspectiva, o método que utiliza as redes neurais obteve o melhor resultado.

$$\text{Coeficiente} = \frac{3TPR_{SW} + 5TPR_{MB}}{8} \quad (10)$$

Tabela 11 - Coeficiente Equação (10)

Método	TPR _{SW}	TPR _{MB}	Coeficiente
Correlação Cruzada	1	0,283	0,552
Análise Espectral da Energia	1	0,516	0,697
Análise da SNR	0,933	0,8	0,849
Redes Neurais	0,916	0,9	0,906

A Tabela 12 exhibe os resultados pelo coeficiente Taxa de Erro, dado pela Equação (11) [21], em que $N = 36596$ representa o número total de janelas. Nota-se

que, para essa métrica, o método da análise da SNR apresentou um melhor resultado frente aos erros.

$$Taxa\ de\ Erro = \frac{FN + FP}{N} \quad (11)$$

Tabela 12 - Taxa de erro

Método	FN	FP	Taxa de Erro
Correlação Cruzada	43	5	0,13 %
Análise Espectral da Energia	25	35	0,16 %
Análise da SNR	17	5	0,06 %
Redes Neurais	11	19	0,08 %

A Tabela 13 exibe os resultados de cada algoritmo diante da aplicação do coeficiente *F1 Score*, conforme definido na Equação (12). Esse coeficiente é importante na análise de conjuntos de dados com grandes discrepâncias no número de amostras entre as classes [21], como verificado nos sinais de teste.

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (12)$$

Considerando todos os resultados apresentados, o método que utiliza redes neurais foi considerado o mais adequado para a detecção e classificação de sinais de tiro. Ele demonstrou um desempenho robusto na classificação de MB e sua complexidade computacional, dado que o treinamento ocorre *offline*, é baixa.

Tabela 13 - Coeficiente *F1 Score*

Método	TP	FN	FP	F1 (%)
Correlação Cruzada	36818	43	5	99,9348
Análise Espectral da Energia	36806	25	35	99,9185
Análise da SNR	36844	17	5	9,9701
Redes Neurais	36836	11	19	99,9592

Os resultados provenientes da aplicação do método utilizando redes neurais, aqui considerado o mais adequado à presente aplicação, na base proveniente de [27] estão apresentados na Tabela 14. Nesse contexto, a situação campestre refere-se aos sinais de tiro originados das bases utilizadas neste artigo (ambiente rural) enquanto o cenário urbano diz respeito à base de tiros de [27]. Mesmo quando empregado em um conjunto de disparos de

armas de fogo distintas daquelas usadas no treinamento, destacando-se a ausência de características supersônicas nos projéteis e um elevado grau de multipercurso típicos de ambientes urbanos, o método demonstrou habilidade na separação do MB, alcançando uma TPR superior a 70% para todos os armamentos usados em [27].

Tabela 14 - Resultados do teste na base urbana [27] com treinamento na base rural

	Calibre.45	Calibre.40	Calibre 9 mm
MB→MB	80	79	92
MB→NT	28	29	16
NT→MB	4	5	17
TPR	74,07%	73,15%	85,18%

A Tabela 15 apresenta os resultados do treinamento e do teste contemplando as diversas configurações de treinamento/teste.

Tabela 15 - Resultados dos testes com diferentes tipos de treinamento e cenários de teste

Treinamento	Teste	TPR
Campestre	Campestre	95,83 %
	Urbano	77,47 %
Urbano	Campestre	90,56 %
	Urbano	88,88 %
Misto	Campestre	90,56 %
	Urbano	85,18 %

5. Conclusão

A principal meta deste projeto [28] consistiu em replicar e comparar algoritmos de detecção e classificação de sinais impulsivos em três categorias: SW (onda de choque), MB (estouro no cano) ou NT (outro tipo de evento impulsivo). Com essa finalidade, foram desenvolvidas rotinas no ambiente Matlab® para as etapas de treinamento e de teste de cada um dos quatro métodos avaliados neste artigo. Além disso, visando aprimorar os resultados de classificação, foram sugeridas algumas modificações no método da Correlação Cruzada e no método que emprega redes neurais.

O foco primordial deste trabalho foi direcionado às aplicações militares, em tempo real, destinadas a

atender às possíveis necessidades no combate a caçadores. A automação dos procedimentos de detecção e classificação tem o potencial de integrar de forma eficaz requisitos de software e hardware voltados à estimação da DOA de atiradores. Como resultado, os soldados podem, ao dispor de informações sobre a direção de disparos, desfrutar de maior proteção contra ameaças letais por terem melhores condições de buscar abrigo ou neutralizar franco-atiradores.

Este estudo buscou comparar e otimizar os algoritmos de detecção de sinais de tiros. Ao observar que o método da Correlação Cruzada, baseado em [7], carecia de uma metodologia clara para distinguir entre SW e MB, utilizamos mais sinais de referências e um esquema de classificação baseado em RBF SVM Kernel; contudo, este método ainda enfrentou dificuldades em diferenciar claramente os componentes de SW. Por outro lado, o método da análise espectral da energia apresentado, conforme apresentado em [17], não obteve bons resultados na classificação de tiros, uma vez que sua eficácia dependia das características do armamento e da geometria do ambiente (posições relativas do atirador, alvo e microfone). Em relação ao método da SNR, descrito em [18], verificou-se que ele se mostrou robusto na detecção de sinais impulsivos, porém ainda carecia de aprimoramento na classificação das componentes MB, informação mais relevante para as aplicações consideradas. Finalmente, o método que emprega redes neurais, tal como descrito em [19], não apresentava uma clara distinção entre as etapas de detecção e classificação. Para aprimorá-lo, foi sugerida a adoção do mesmo processo de detecção conforme delineado em [18], com a metodologia de

[17] sendo utilizada para a obtenção do critério de classificação. Esse método, com as adaptações sugeridas, foi considerado o mais adequado para o propósito deste trabalho, resultando numa taxa de acerto de MB superior entre os quatro métodos avaliados.

As redes neurais utilizadas neste trabalho foram do tipo *feed-forward* com duas camadas geradas pelo aplicativo Classification Learner do Matlab®. Uma possível extensão deste estudo, abordando o estado da arte em métodos de detecção e classificação de sinais de tiro, poderia incluir uma investigação sobre o uso de redes neurais profundas e redes neurais convolucionais no processamento de imagens geradas a partir dos espectrogramas dos sinais de tiro. Essa abordagem pode abrir novas perspectivas para o aprimoramento desses métodos e sua aplicação em situações práticas de combate.

A utilização do método que identificamos como o mais eficaz para gravações realizadas em ambientes rurais, como estandes de tiros e campos de instrução, em uma segunda base de dados contendo tiros provenientes de um ambiente urbano, trouxe novas perspectivas sobre a aplicabilidade dessa técnica. Verificou-se que, apesar dos bons resultados obtidos com o treinamento em ambiente campestre, a utilização desse método em cenários urbanos apresenta desafios adicionais e requer um treinamento específico com sinais coletados nesse contexto. A estratégia de empregar um treinamento híbrido para aplicação em ambos os ambientes, rural e urbano, resultou em uma redução na taxa de positivos verdadeiro (TPR) entre 3,7% (ambiente urbano) e 5,3% (ambiente rural), em comparação com a situação em que o treinamento e teste ocorrem no mesmo ambiente.

REFERÊNCIAS

- [1] PALAVENIS, D. The use of emerging disruptive technologies by the Russian Armed Forces in the Ukrainian War. **Air Land Sea Application Center**. Hampton, 1 out. 2022. Disponível em: <https://www.alssa.mil/News/Article/3170285/the-use-of-emerging-disruptive-technologies-by-the-russian-armed-forces-in-the/>. Acesso em: 7 jun. 2025.
- [2] SOUZA, G. L. **História Militar**: o emprego do caçador. Trabalho de Conclusão de Curso (Bacharelado em Aperfeiçoamento Militar) – Escola de Aperfeiçoamento Militar, [s. l.], 2020. Disponível em: <http://bdex.eb.mil.br/jspui/handle/123456789/6570>. Acesso em: 7 jun. 2025.
- [3] Círculo de fogo. Direção: Jean-Jacques Annaud. Produção de Mandalay Pictures. Estados Unidos: Paramount Pictures, 2001.
- [4] Sniper Americano. Direção: Clint Eastwood. Produção de Village Roadshow Studios e Malpaso Productions. Estados Unidos: Warner Bros, 2014.

- [5] SLAWSON, L. The Top Ten Deadliest Snipers in History. **Owlcation**, September 15th, 2023. Disponível em: <https://owlcation.com/humanities/Top-Ten-Deadliest-Snipers-in-History>. Acesso em 9 jun. 2025.
- [6] FREYTAG, J. C.; BRUSTAD, B. M. A survey of audio forensic gunshot investigations. In: AES International Conference: Audio Forensics in the Digital Age, 26., 2005, Denver. **Anais [...]**. Denver: Audio Engineering Society, p. 131-134, 2005.
- [7] FREIRE, I. L.; APOLINÁRIO JR., J. A. Gunshot detection in noisy environments. In: International Telecommunication Symposium (ITS), 7., 2010, Manaus. **Anais [...]**. Manaus: ITS, p. 1-4, 2010.
- [8] SERRENHO, F. G. **Estimação robusta da direção de chegada de sinais de tiros a partir de VANT de asa rotativa**. 2020. Dissertação (Mestrado em Engenharia Elétrica) – Instituto Militar de Engenharia (IME), Rio de Janeiro, Brasil, 2020.
- [9] BORZINO, A. M. C. R. *et al.* Signal enhancement for gunshot DOA estimation with median filters. In: *IEEE Latin American Symposium on Circuits and Systems (LASCAS)*, 6., 2015, Montevideo. **Anais [...]**. Montevideo, 2015.
- [10] BORZINO, A. M. C. R.; APOLINÁRIO JR., J. A.; CAMPOS, M. L. R. Robust DOA estimation of heavily noisy gunshot signals. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, 2015, Brisbane. **Anais [...]**. Brisbane: IEEE, 2015. p. 449-453.
- [11] FREIRE, I. L.; APOLINÁRIO JR., J. A. GCC-based DoA estimation of overlapping muzzleblast and shockwave components of gunshot signals. *Latin American Symposium on Circuits and Systems (LASCAS) 2.*, 2011, Bogotá. **Anais [...]**. Bogotá: IEEE, 2011. <https://doi.org/10.1109/LASCAS.2011.5750273>.
- [12] BORZINO, A. M. C. R. **Processamento de sinais de áudio proveniente de disparo de arma de fogo e Aplicações**. 2016. Tese (Doutorado em Engenharia de Defesa) – Instituto Militar de Engenharia (IME), Rio de Janeiro, Brasil, 2016.
- [13] BORZINO, A. M. C. R.; APOLINÁRIO JR., J. A.; CAMPOS, M. L. R. Consistent DOA estimation of heavily noisy gunshot signals using a microphone array. **IET Radar, Sonar & Navigation**, Stevenage, p. 1517-1728, 2016.
- [14] MAGAND, F.; Donzier, A.; Molliex, F. **PILAR Acoustic Gunshot Detection & Localization system: principles of acoustic localization of small caliber gunshots**. Joint Congress CFA–DAGA, Strasbourg, France, 2004.
- [15] Raytheon Intelligence & Space, “Boomerang Gunshot Detection: Locate the Enemy - Coordinate the Response”. **Raytheon BBN Technologies**, Cambridge, 2020. Disponível em: <https://pt.scribd.com/document/532314657/boomerang-data-sheet-soft-copy-final>. Acesso em: 9 jun. 2025.
- [16] TRANSVARO SAVUNMA SANAYI A.Ş. **TV-SD 500 Acoustic Sniper Detection System: user manual**. İstanbul; Ankara: Transvaro Savunma Sanayi A.Ş., [s.d.]. Disponível em: <https://www.transvaro.com/wp-content/uploads/akustik-eng.pdf>. Acesso em: 7 jun. 2025.
- [17] MÄKINEN, T.; PERTILÄ, P. Shooter localization and bullet trajectory, caliber, and speed estimation based on detected firing sounds. **Applied Acoustics**, Amsterdam, v. 71, n. 10, p. 902-913, 2010. <https://doi.org/10.1016/j.apacoust.2010.05.021>
- [18] AHMED, T.; UPPAL, M.; MUHAMMAD, A. Improving efficiency and reliability of gunshot detection systems. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, 2013, Vancouver. **Anais [...]**. Vancouver: IEEE, 2013. p. 513-517.
- [19] HRABINA, M.; SIGMUND, M. Comparison of feature performance in gunshot detection depending on noise degradation. In: *International Conference Radioelektronika*, 27., 2017, Brno. **Anais [...]**. Brno: 2017. p. 223-226.
- [20] MAHER, R. C. Modeling and signal processing of acoustic gunshot recordings. *Signal Processing Education Workshop, Teton National Park, 4.*, Piscataway, 2006. **Anais [...]**. Piscataway: IEEE, 2006. pp. 257-261. <https://doi.org/10.1109/DSPWS.2006.265386>.
- [21] LARNER, A. J. **The 2x2 Matrix Contingency, Confusion, and the Metrics of Binary Classification**. Liverpool: Springer Nature Switzerland AG, 2021. <https://doi.org/10.1007/978-3-030-74920-0>
- [22] INDÚSTRIA DE MATERIAL BÉLICO DO BRASIL (IMBEL). **Manual do Fuzil .308 – IMBEL AGLC**: instruções de operação, manutenção e características técnicas. Brasília: IMBEL, 2018. Disponível em: <https://www.imbel.gov.br/phocadownload/produtos/manuais/fz-ca/manual-fzaglc308.pdf>. Acesso em: 7 jun. 2025.
- [23] BRASIL. Ministério do Exército. **Manual de Campanha C-23-65**: Metralhadora .50 M2. 3. ed. Rio de Janeiro: Ministério do Exército, 1963. Disponível em: <https://bdex.eb.mil.br/jspui/bitstream/123456789/425/5/C-23-65-final.pdf>. Acesso em: 7 jun. 2025.
- [24] INDÚSTRIA DE MATERIAL BÉLICO DO BRASIL (IMBEL). **Manual do Fuzil 7,62 M964–FAL / M964A1–PARAFAL**: operação, manutenção e características técnicas. Brasília, DF: IMBEL, 2014. Disponível em: <https://www.imbel.gov.br/phocadownload/produtos/manuais/fz-ca/manual-fz762m964.pdf>. Acesso em: 7 jun. 2025.
- [25] INDÚSTRIA DE MATERIAL BÉLICO DO BRASIL (IMBEL). **Manual do Usuário do Fuzil de Assalto 5,56 – IMBEL A2**: operação e manutenção. Brasília, DF: IMBEL, 2017. Disponível em: <https://www.imbel.gov.br/phocadownload/produtos/manuais/fz-ca/manual-fuzil-imbel-556-IA2.pdf>. Acesso em: 7 jun. 2025.
- [26] BEHRINGER. ECM8000: Ultra-linear measurement condenser microphone – Technical Specifications, Music Tribe Global Brands Ltd., 2021. Disponível em: <https://www.behringer.com/product.html?modelCode=0506-AAA>. Acesso em: 7 jun. 2025.
- [27] CALHOUN, R. B. *et al.* Precision and accuracy of acoustic gunshot location in an urban environment. **ShotSpotter Inc.**, Newark, v. 1, p.9-16, 2020. <https://doi.org/10.48550/arXiv.2108.07377>
- [28] SILVA, R. L. A. **Sistema Detector e Localizador de Caçador**. Projeto de Final de Curso (Bacharelado em Engenharia de Comunicações) – Instituto Militar de Engenharia (IME), Rio de Janeiro, Brasil, 2023.