

# Técnicas de Reconhecimento de Padrões aplicadas na Classificação de Varreduras de Radar

Jorge C. Pires Filho<sup>1</sup> e Diego B. Haddad<sup>2</sup>, Luiz P. Calôba<sup>2</sup>

<sup>1</sup>Instituto de Pesquisas da Marinha, Grupo de Guerra Eletrônica, Rua Ipiru, 2- CEP: 21930-090 - Rio de Janeiro- RJ-Brasil  
<sup>2</sup>Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica, CEP: 21945-970 – Rio de Janeiro – RJ – Brasil

**Resumo** — Este artigo compara diferentes técnicas de reconhecimento de padrões aplicadas na classificação de varreduras de radar. As técnicas implementadas foram: redes neurais, máquinas de vetores suporte, modelos de misturas gaussianas e vizinho mais próximo. A classificação almejada comumente revela grande valor em sistemas táticos de defesa, assim como para sistemas estratégicos de inteligência.

**Palavras-chaves** — Reconhecimento de Padrões, Máquina de Vetor Suporte, Modelo de Misturas Gaussianas, Vizinho mais próximo, Radar, Padrão de Varredura, Defesa, Guerra Eletrônica.

## I. INTRODUÇÃO

No contexto da guerra eletrônica, não raro cumpre identificar de forma automática o tipo de varredura dos radares existentes no cenário, de forma a identificar a eventual presença de uma ameaça, conforme Tabela I. Para tal propósito, é de praxe utilizar um receptor MAGE (ESM), processando posteriormente as informações geradas pelo mesmo. Após uma clusterização não-supervisionada (processo de *deinterleaving* ou “desembaralhamento”) que distingue os diferentes radares, cabe empregar um algoritmo de identificação que classifique o tipo de varredura de cada radar. Esta identificação é muito importante, pois, por exemplo, radares com varredura do tipo cônica e, especialmente, do tipo *lock-on* (sendo este, na verdade, o estágio final da varredura cônica, quando a mesma consegue “travar” no alvo) podem representar sérias ameaças à sobrevivência da unidade. Ao mesmo tempo, radares dotados de varredura circular ou setorial não devem atrair atenção desnecessária, já que não costumam representar perigo.

TABELA I PADRÕES DE VARREDURA E SEU EMPREGO

Padrão de Varredura	Emprego
Palmer	Controle de Armas / Busca
Circular	Busca
Setorial	Busca
Helicoidal	Busca
Vertical	Determinador de Altitude
Raster	Controle de Armas / Direção de Tiro
Espiral	Controle de Armas / Busca
Cônica	Acompanhamento de Precisão
Chaveamento de lóbulos	Acompanhamento de Precisão
Horizontal/Vertical (TWS)	Busca e Controle de Armas
Monopulso	Controle de Armas / Direção de Tiro

Os algoritmos de identificação vigentes costumam ser do tipo cognitivo. Porém, estes algoritmos apresentam desvantagens que implicam uma degradação no desempenho do sistema de classificação, quais sejam: sensibilidade ao ruído (o qual freqüentemente acompanha as medidas efetuadas), dificuldades no tocante à manutenção e quanto ao acréscimo de novas classes, perdas de pulsos e separação imperfeita na supracitada clusterização. A partir deste contexto, este artigo compara métodos de reconhecimento de padrões baseados em redes neurais, máquinas de vetores suporte, modelos de misturas gaussianas (sigla em inglês, GMM, de *Gaussian Mixture Models*) e vizinho mais próximo. Estas implementações almejam contornar os problemas acima citados apresentados pelos métodos cognitivos.

O sistema MAGE (ESM) retorna automaticamente vários parâmetros relativos às medições, como por exemplo o AOA (*angle of arrival*, ângulo ou marcação de chegada da onda eletromagnética), freqüência, amplitude, largura de pulso e medida de qualidade. Alguns deles não representam informação relevante para a classificação, como por exemplo o ângulo de chegada<sup>1</sup>. Os parâmetros que definem o padrão de varredura são dois: medida de instante de chegada de pulso (TOA, do inglês *time of arrival*, em  $\mu s$ ) e de amplitude (em dB). Apenas estes dois parâmetros serão utilizados na identificação dos numerosos tipos de varredura. Este artigo, assim como [1], se restringe à identificação dos quatro tipos mais comuns de varredura, quais sejam: a) *lock-on*, b) cônica, c) circular e d) setorial. Os padrões de Amplitude x TOA das quatro estirpes de varredura são exibidos a seguir, Fig. 1:

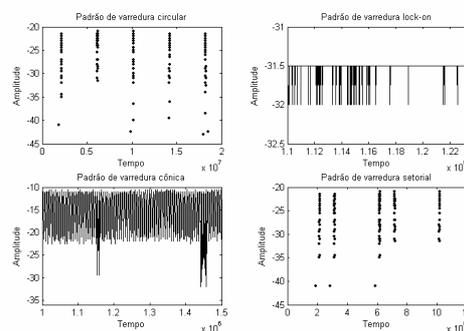


Fig. 1. Padrões de Amplitude x TOA.

Jorge C. P. Filho, [jcpfilho@gmail.com](mailto:jcpfilho@gmail.com), Luiz P. Calôba, [caloba@lps.ufrj.br](mailto:caloba@lps.ufrj.br), Diego B. Haddad, [diego\\_haddad@gmail.com](mailto:diego_haddad@gmail.com). Este trabalho foi parcialmente financiado pela FAPERJ.

<sup>1</sup> Embora este parâmetro, cabe enfatizar, seja importantíssimo no desembaralhamento.

Alguns dos principais algoritmos cognitivos que abordam este problema almejam estimar a frequência de nutação juntamente com o período de varredura do radar. Contudo, sendo estes parâmetros interdependentes, é comum deparar-se com dificuldades na tarefa. Para contornar este problema (da interdependência), este artigo propõe uma alternativa que divide a tarefa em duas fases independentes: a primeira identificando o padrão de varredura (recorrendo a um algoritmo não cognitivo) e a segunda a qual, após identificado o padrão, utiliza um algoritmo cognitivo para extração das medidas características, como a frequência de nutação.

O presente artigo apresenta algumas soluções para a primeira fase supracitada. Caso haja um reconhecimento confiável, a segunda tarefa é enormemente facilitada.

## II. AQUISIÇÃO DE DADOS E SEPARAÇÃO

A base de dados foi coletada a partir de dois eventos de gravações, uma em julho de 2003 e outra em outubro de 2005, no IPqM (Instituto de Pesquisas da Marinha), Rio de Janeiro, RJ, na Baía de Guanabara. Cada evento gerou diversas gravações, cada qual contemplando um período de 20s, gerando 23 arquivos de aproximadamente 2 Megabytes de dados. Essa base de dados, portanto, é constituída de cenários digitalizados, com taxas de amostragem da ordem de dezenas de Mhz, suficiente para a caracterização de *PDWs* (*pulse descriptor word*), e foi obtida mediante um sistema receptor passivo (ESM). Não havendo acesso à etapa pós-clusterização (relativa ao desembaralhamento), os arquivos portavam informações de vários emissores simultaneamente, de forma ordenada no tempo. Cada entrada de registro contempla basicamente os seguintes parâmetros do pulso: ângulo de chegada, tempo de chegada, qualidade da informação de ângulo, tempo de chegada, frequência, largura de pulso, amplitude (em dB) e *bit* indicador de modulação interna.

O sistema receptor passivo (ESM) processa indistintamente todos os radares presentes no cenário, o que evidencia a necessidade de um pré-processamento (na realidade uma separação de fontes) antes do reconhecimento do padrão de varredura, como citado na Introdução. Nesta fase, estima-se também a IRP (intervalo de repetição dos pulsos).

Sendo o propósito deste artigo o reconhecimento de padrões de varredura, não se elaborou em demasia o algoritmo de separação de fontes. Para tal, utilizou-se um clusterizador do tipo *k-means*, onde somente a frequência foi o parâmetro de entrada. Para cada um dos arquivos, inicializou-se a clusterização com 250 *clusters* de centróides igualmente espaçados na banda de frequências (2 a 20 GHz). Os *clusters* dotados de um número de amostras menor do que 40 foram descartados ao fim do processo. Então, ao associar a cada *cluster* o seu padrão, gerando nossa base de dados. Para os padrões não foram enquadrados nas quatro classes já descritas, foi criada a nova classe “desconhecida”.

## III PRÉ-PROCESSAMENTO E EXTRAÇÃO DE CARACTERÍSTICAS

Os padrões de Amplitude x TOA não se revelam muito tratáveis para uma extração direta de características. No intuito de contornar esta dificuldade, adotamos uma

abordagem nova (assim como em [1]), dividindo-se o problema de reconhecimento em dois. A proposta consiste em transformar os padrões amplitude x tempo em dois subpadrões: amplitude por amostra e TOA por amostra, como vê-se nas Figs. 2 e 3. Pode-se notar que a tarefa de reconhecimento torna-se mais simples.

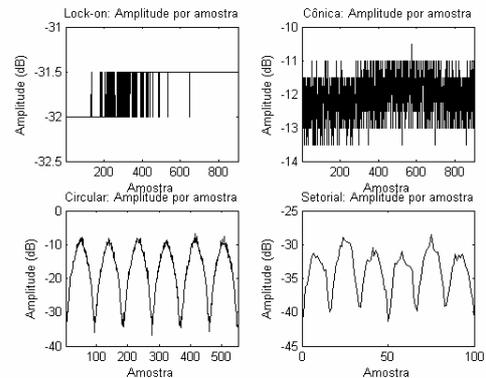


Fig. 2. Padrões de Amplitude por Amostra.

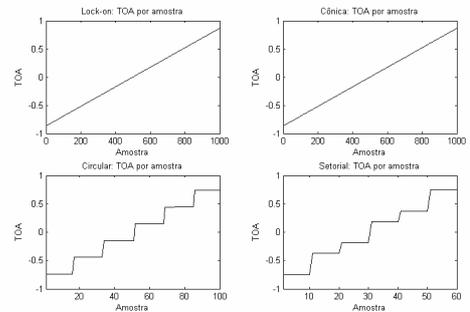


Fig. 3. Padrões de TOA por amostra.

Nas Figs. 2 e 3, vê-se que os padrões de amplitude por amostra para varreduras do tipo circular e setorial são os mesmos, assim como os padrões de TOA por amostra das varreduras cônica e *lock-on*. Essa redundância acaba por reduzir o número de classes em cada classificador. Na Tabela II, verificamos as possíveis combinações, assim como as classificações correspondentes.

TABELA II COMBINAÇÕES POSSÍVEIS ENTRE PADRÕES DE TOA E DE AMPLITUDE E CLASSIFICAÇÃO CORRESPONDENTE

#	Amplitude	TOA	Varredura
1	Patamares	Linear	<i>Lock-On</i>
2	Patamares	(Distinto de Linear)	(Desconhecida)
3	Senoidal	Linear	Cônica
4	Senoidal	(Distinto de Linear)	(Desconhecida)
5	Senóides retificadas	Linear	(Desconhecida)
6	Senóides retificadas	Degraus uniformes	Circular
7	Senóides retificadas	Degraus não-uniformes	Setorial
8	Diferente	(Qualquer coisa)	RESTO
9	(Qualquer coisa)	Não-Linear	RESTO

Dessa forma, o problema de reconhecimento do padrão de varredura do radar foi dividido em dois problemas separados: um para reconhecimento do padrão de amplitude e outro para o padrão de TOA. Cada *cluster* gera dois conjuntos de dados para classificação (padrões de TOA e de Amplitude). A classificação final será obtida a partir da combinação das duas classificações.

Cada *cluster* teve suas medidas escalonadas, retirando-se sua média e tornando sua variância unitária.

Para extração de características, em ambos os tipos de classificadores, foram concatenados os coeficientes LP (do inglês *Linear Prediction*) e a variância do erro de predição de forma a criar um vetor de características associado a cada *cluster*. Outros tipos de extração foram tentados, com menor sucesso. O preditor LPC de ordem N consiste num conjunto de coeficientes  $a(k)$  que minimiza o erro quadrático médio do seguinte preditor *forward*, aplicado a uma seqüência  $x(n)$ :

$$\hat{x}(n) = \sum_{k=1}^N a(k)x(n-k). \quad (1)$$

Para o classificador de amplitude, acrescentou-se ao vetor de características o desvio-padrão do *cluster*. Para o classificador de TOA, acrescentou o desvio-padrão da diferença entre as amostras do *cluster* e as amostras da reta obtida via regressão linear de cada cluster. Após testes, verificamos que a reta definida pela primeira e última amostra do *cluster* era suficiente para garantir uma classificação de desempenho similar, com um custo computacional bem inferior.

#### IV IMPLEMENTAÇÃO DOS MÉTODOS DE CLASSIFICAÇÃO

Para efetuar a tarefa de reconhecimento, foram utilizados os seguintes métodos: redes neurais, máquinas de vetor suporte (em inglês SVM, *machine vector support*), modelo de misturas gaussianas e vizinho mais próximo. Estes métodos são aplicados tanto para os padrões de TOA quanto para os de amplitude, cujos exemplares típicos são mostrados nas Figs. 4 e 5.

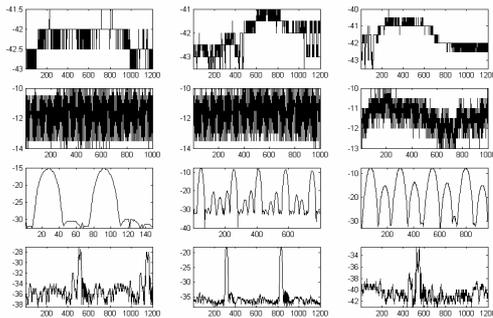


Fig. 4. Padrões de Amplitude a classificar.

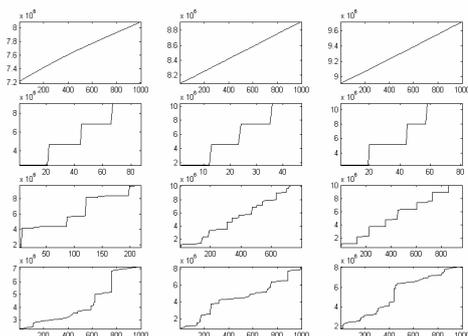


Fig. 5. Padrões de TOA a classificar.

Dada a falta de espaço, não detalharemos a modelagem inerente a cada método; apenas indicaremos a forma como os implementamos.

#### A. Redes Neurais

Foram utilizadas redes neurais do tipo *feedforward* (maiores detalhes em [1],[3],[4]) de duas camadas, completamente conectadas, com função de ativação do tipo tangente hiperbólica e treinadas por meio do algoritmo *resilient backpropagation* [2]. Foi reservado 70% do banco de dados para treinamento com o restante dividido em partes iguais para validação e teste. As classes menos numerosas foram replicadas, para efeito de balanceamento. As quatro classes de cada rede neural (uma para TOA e outra para amplitude) foram representadas de forma maximamente esparsa.

A melhor topologia encontrada em ambas as redes neurais foi 3 coeficientes LP para a entrada, 20 neurônios na primeira camada e 4 neurônios na última.

#### B. Máquinas de Vetor Suporte

Embora existam implementações SVM multiclases, adotou-se uma abordagem simples, resolvendo o problema multiclasse por meio de decisões binárias, as quais não são necessariamente ótimas. Observou-se que alterar a árvore de decisão resulta em desempenhos distintos, embora não muito diferentes entre si. O kernel utilizado, devido ao fato de obter melhores resultados, foi o polinomial de grau 2 (maiores detalhes em [1],[6]).

Entre as possíveis árvores de decisão, a que obteve os melhores resultados no tocante a TOA era constituída por três SVMs binárias, tomando decisões na seguinte seqüência: 1) TOA linear do resto; 2) TOA não-linear do TOA degrau e 3) TOA degrau uniforme de degrau não-uniforme. Já para a árvore de decisão quanto à Amplitude, as decisões foram tomadas na seguinte ordem: 1) senoidal retificada do resto; 2) senoidal do resto e 3) patamares de Diferente. Em todas as SVMs, a codificação LP utilizou 3 coeficientes, à exceção da terceira SVM de Amplitude, que usou 16 coeficientes.

#### C. Modelo de Misturas Gaussianas

Foram usados tanto para rede TOA quanto para a rede de Amplitude 3 coeficientes LPC. Os parâmetros do modelo de misturas gaussianas foram estimados mediante o algoritmo EM (*Expectation Maximization*) [5],[6]. O número de gaussianas que modelam as classes com melhores resultados é mostrado na tabela III

TABELA III NÚMERO DE GAUSSIANAS CORRESPONDENTE A CADA CLASSE

Classe	Número de Gaussianas
Senóides Retificadas	1
Senoidal	4
Patamares	3
Diferente	1
Linear	2
Degraus Uniformes	2
Degraus Não Uniforme	2
Não Linear	2

#### D. Vizinho mais próximo

Os melhores resultados para o K vizinhos para vizinho mais próximo [7] ( $K = 1$ ), para a rede TOA foram obtidos recorrendo a 4 coeficientes LPC, enquanto que para rede de amplitude obtivemo-los com 6 coeficientes LPC. A distância utilizada foi a euclideana.

## V RESULTADOS

A taxa de acerto estimada para cada método é mostrada na Tabela IV:

TABELA IV TAXA DE ACERTO CORRESPONDENTE A CADA MÉTODO DE CLASSIFICAÇÃO

#	Método	Amplitude	TOA
1	Rede Neural	99,50%	97,79%
2	SVM	98,43%	98,98%
3	GMM	96,85%	99,24%
4	K-vizinho	96,85%	97,45%

## VI OBSERVAÇÕES FINAIS

Os métodos de reconhecimento implementados demonstraram robustez ao ruído de forma diversa dos algoritmos cognitivos que são normalmente empregados; também revelaram que provavelmente serão capazes de classificar mais que quatro classes, demonstrando um desempenho no mínimo equivalente aos algoritmos cognitivos ora empregados.

Como pode se observar o método do vizinho mais próximo apresentou resultados inferiores para os dois subconjuntos: TOA e Amplitude.

Ao contrário dos demais métodos a Rede Neural necessitou um balanceamento dos dados de entrada.

Todos os classificadores apresentaram boa capacidade de generalização, aceitando amostras pessimamente clusterizadas, ou seja, contendo mais de um emissor, não apresentando problemas de agrupar padrões diversos em uma classe (p.ex. Classes Diferente e Não Linear).

A GMM apresentou o melhor resultado para os padrões de TOA, enquanto a Rede Neural obteve o melhor resultado para os padrões de amplitude, o que sugere uma possível solução combinada, empregando o classificador neural para Amplitude e o classificador GMM para TOA. Dessa forma, minimizamos a taxa de erro global, à medida que esta será, no pior caso, resultado da soma das taxas de erro de cada classificador. Por este critério a performance dos métodos pode ser ordenada de forma decrescente conforme a seguir: SVM (Taxa de Acerto mínima 97,29%); Rede Neural (97,41%); GMM (96,09%); Vizinho mais próximo (94,03%). Assim sendo, caso seja utilizado um único método para os dois subconjuntos, o recomendável seria utilizar SVM.

## REFERÊNCIAS

- [1] Jorge C. P. Filho, Diego B. Haddad e Luiz P. Caloba. "Classificação de Padrões de Varredura de Radars", Submetido para o VIII Congresso de Redes Neurais, 2007.
- [2] M. Riedmiller e H. Brown. "A Direct adaptive method for faster backpropagation learning: The RPROP algorithm", *Proceedings of the IEEE International Conference on Neural Networks*, (1993).

- [3] S. Haykin. "Neural Networks: A Comprehensive Foundation". *Prentice Hall*, 1999.
- [4] C. Bishop, "Neural Networks for Pattern Recognition". *Oxford University Press*, 1995.
- [5] Jeff A. Bilmes, "A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models", *International Computer Science Institute*, 1998.
- [6] Christopher J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", *Data Mining and Knowledge Discovery*, 1998.
- [7] R. O. Duda, P. E. Hart e D. G. Stork, "Pattern Classification", 2<sup>nd</sup> ed, *John Wiley & Sons*, 2000.