

Reconhecimento Automático de Alvos em Imagens SAR utilizando-se Wavelets e a Classificação pela Mínima Distância e pelo MAP

João Paulo Pordeus Gomes^{1,2}, José Fernando Basso Brancalion¹ e David Fernandes²

¹Empresa Brasileira de Aeronáutica S/A, EMBRAER, Av. Brigadeiro Faria Lima, 2170 - 12227-901, São José dos Campos, SP

²Instituto Tecnológico de Aeronáutica, Comando-Geral de Tecnologia Aeroespacial, Praça Mal. Eduardo Gomes, 50 - 12228-900, São José dos Campos, SP

Resumo — O reconhecimento automático de alvos de interesse em imagens de Radar de Abertura Sintética (SAR) agiliza o tempo de resposta às possíveis ameaças, minimiza erros devido as falhas humanas e pode ser utilizado no engajamento de armamentos contra os alvos. Apresenta-se neste trabalho um processo automático de reconhecimento de alvos em imagens SAR, que independe do azimute dos alvos nas imagens. Utiliza-se a transformada Wavelet de Haar como ferramenta para extração das características das imagens dos alvos e dois classificadores, estatísticos um baseado na mínima distância de Mahalanobis e outro no critério do máximo a posteriori (MAP). São realizadas avaliações comparativas de desempenho entre os dois classificadores utilizando-se imagens SAR de veículos militares de combate disponibilizados pela Sandia National Laboratories/EUA

Palavras-chaves — Reconhecimento de padrões, classificação de alvos, reconhecimento de alvos em imagens SAR, inteligência de imagens.

I. INTRODUÇÃO

A área de reconhecimento de padrões envolve uma vasta gama de conhecimentos e possui aplicações nas mais diversas áreas. Aplicações militares constituem uma grande área de interesse onde particularmente o Reconhecimento Automático de Alvos (RAA) desempenha um papel importante. O objetivo de um sistema RAA é automatizar, auxiliar e reduzir as tarefas exercidas por um operador humano na tarefa de detecção e reconhecimento de alvos, através de um sistema de tempo real confiável e de alto desempenho. A tarefa de um sistema de reconhecimento de padrões consiste basicamente em dotar a máquina da capacidade de extrair características (padrões) de uma determinada massa de dados e classificar estes dados em um número finito de categorias.

Desenvolveu-se neste trabalho uma metodologia para RAA em imagens de Radar de Abertura Sintética (SAR) através de técnicas de reconhecimento de padrões, utilizando-se classificadores estatísticos [1]. A técnica desenvolvida não utiliza pré-processamento da imagem SAR e independe do ângulo de azimute do alvo na imagem. Utilizou-se para testes imagens SAR, contendo veículos militares, coletadas e disponibilizadas pela Sandia National Laboratories/EUA.

J. P. P. Gomes, joão.pordeus@embraer.com.br, Tel +55-12-39273285, J. F. B. Brancalion, jose.brancalion@embraer.com.br, Tel +55-12-39277143, Fax +55-12-39272060 e D. Fernandes, david@ita.br, Tel. +55-12-39476807, Fax +55-12-39476930.

A seção II mostra os tipos de alvos e imagens utilizadas no processo de reconhecimento de padrões desenvolvido neste trabalho. Na seção III mostra-se como a Transformada Wavelet foi utilizada na extração das características das imagens dos alvos que serão classificados. Na seção IV definem-se dois processos de classificação, um pela distância mínima de Mahalanobis e outro pelo MAP. Na seção V apresentam-se e analisam-se os resultados obtidos no processo de classificação e na seção VI são apresentados os comentários finais relativos ao trabalho realizado.

II. ALVOS E IMAGENS SAR

A Fig.1 ilustra a aquisição da cena por um SAR, que através da técnica de compressão de pulsos e da sintetização, por processamento de sinais, de uma abertura angular azimutal, da antena transmissora/receptora, muito estreita, é capaz de gerar imagens de alta resolução [2, 3].




Fig. 1. Aquisição de dados de uma cena por um sistema imageador SAR.

Utilizou-se nos testes imagens de cinco veículos de combates terrestres. Estes alvos estavam dispostos em um conjunto de 200 a 300 imagens com ângulos de depressão de 15° e 17° e com os alvos com diferentes ângulos de azimute.

A Fig. 2 mostra os alvos de interesse e as suas respectivas imagens SAR. A granulosidade apresentada nas imagens SAR é devido ao *speckle*, originado pela reflexão coerente, e pelo processamento de síntese das imagens também coerente, dos espalhadores na cena da ordem do comprimento da onda

da portadora do sistema SAR. O *speckle* tem características de ruído multiplicativo e a sua existência penaliza os processos de detecção e classificação dos alvos nas imagens SAR. Além do *speckle* tem-se o ruído branco aditivo comum aos sistemas de comunicações.

Nota-se nas imagens que o *speckle* tende a ser mais marcante na região de fundo (correspondente ao solo em que está posto o alvo na cena) e que os alvos tendem a saturar a imagem devido a sua forte reflexão.



Fig. 2. Alvos de interesse e suas imagens SAR.

Para se realizar o procedimento de classificação dos alvos cada uma das imagens disponíveis foi convertida em duas imagens uma com 75×75 pixels contendo no seu centro o alvo e no seu entorno uma pequena porção do fundo e uma imagem de 60×60 pixels do mesmo alvo, com um fundo mais reduzido ainda. A diferença entre as imagens é a sua dimensão uma contendo mais fundo e outra menos.

A remoção do fundo foi um procedimento destinado a diminuir a sua influência no processo de classificação dos

alvos. Pois ele, além de não trazer informações sobre o alvo, penaliza o processo de identificação/classificação.

III. EXTRAÇÃO DE CARACTERÍSTICAS DAS IMAGENS

Utilizaram-se cinco níveis de decomposição da Transformada Wavelet Haar (TWH) para a extração das características das imagens SAR. A decomposição utilizada é esquematizada na Fig. 3 para três níveis, onde *A* representa a aproximação e *D* os detalhes.

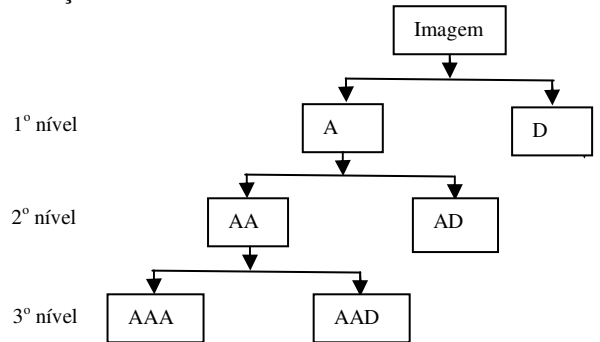


Fig. 3. Esquema de decomposição pela TWH em três níveis.

A Fig. 4 mostra uma imagem SAR de um alvo decomposta nos cinco níveis utilizados.




Fig. 4. Decomposição de uma imagem SAR pela TWH em cinco níveis.

A decomposição em cinco níveis pela TWH foi aplicada em cada uma das imagens de 75×75 pixels e de 60×60 pixels contendo o alvo. Com a aplicação da decomposição pela

TWH obteve-se, para cada imagem original não reduzida, 16+16=32 imagens. Para cada imagem, originada no processo de decomposição, calculou-se o valor quadrático médio dos seus *pixels*, formando-se assim um vetor $\mathbf{x}_{k,i}$ com 32 características relativas a cada imagem original i de cada uma das classes k ($k = 1, 2, \dots, 5$) de alvos.

O cálculo de um único parâmetro para cada imagem da decomposição, no caso o valor quadrático médio, faz com que as características extraídas independam do azimute do alvo na imagem. Normalmente os diferentes azimutes, que podem se encontrar os alvos, penalizam o desempenho dos sistemas RAA.

IV. CLASSIFICAÇÃO

No processo de classificação utilizaram-se dois classificadores estatísticos, um baseado no cálculo da distância de Mahalanobis mínima e outro um classificador bayesiano, para classes com distribuição gaussiana, que utilizou o critério do máximo a posteriori (MAP) [4].

Os classificadores utilizaram as imagens SAR obtidas com ângulos de depressão de 17° para treinamento e as imagens SAR obtidas com ângulos de depressão de 15° foram utilizadas para a avaliação do teste de desempenho dos classificadores.

O treinamento para o classificador de mínima distância consistiu na obtenção, para cada uma das cinco classes de alvos (c_k com $k = 1, 2, \dots, 5$), do vetor de características médio, μ_k , e da matriz de covariância, C_k , dos vetores características representativos de cada uma das cinco classes :

$$\mu_k = \frac{1}{N_k} \sum_{i=1}^{N_k} \mathbf{x}_{k,i} \quad (1)$$

$$C_k = \frac{1}{N_k} \sum_{i=1}^{N_k} (\mathbf{x}_{k,i} - \mu_k)(\mathbf{x}_{k,i} - \mu_k)^T \quad (2)$$

onde N_k é o número de imagens originais relativas a classe c_k , com $k = 1, 2, \dots, 5$, utilizadas no processo de treinamento e $\mathbf{x}_{k,i}$ é o vetor de características da amostra i pertencente à classe c_k .

Calculando-se a distância de Mahalanobis entre um vetor de características \mathbf{x} de um alvo, que se quer classificar, com cada uma das classes c_k , atribui-se ao alvo a classe que lhe for mais próxima. A distância de Mahalanobis entre o vetor de características \mathbf{x} e a classe c_k é dada por:

$$D_k(\mathbf{x}) = \sqrt{(\mathbf{x} - \mu_k)^T C_k^{-1} (\mathbf{x} - \mu_k)} \quad (3)$$

Deste modo o vetor característica \mathbf{x} é classificado como sendo da classe c_j se e somente se sua distância á classe c_j for a menor distância, ou seja:

$$x \in c_j \Leftrightarrow D_j(x) = \max_n D_n(x) \quad (4)$$

Para o classificador MAP estimou-se para cada uma das cinco classes as mesmas características anteriores, μ_k e C_k , para se calcular, para cada uma das cinco classes, a densidade de probabilidade gaussiana multivariada, de dimensão 32,

relativa a probabilidade condicional de se ter um vetor de características dado que se conhece a classe: $p(\mathbf{x} | c_k)$.

A densidade de probabilidade a posteriori é dada por:

$$p(c_k | \mathbf{x}) = \frac{p(\mathbf{x} | c_k) p(c_k)}{p(\mathbf{x})} \quad (5)$$

O vetor de característica \mathbf{x} , de um alvo que se quer classificar, é classificado como pertencente a classe c_j se a densidade a posteriori da classe c_j dado que se observou \mathbf{x} for a maior dentre as densidade a posteriori.

$$\mathbf{x} \in c_j \Leftrightarrow p(c_j | \mathbf{x}) = \max_n p(c_n | \mathbf{x}) = \max_n \frac{p(\mathbf{x} | c_n) p(c_n)}{p(\mathbf{x})} \quad (6)$$

Como $p(\mathbf{x})$ independe da classe, tem-se a regra de decisão:

$$\mathbf{x} \in c_j \Leftrightarrow p(c_j | \mathbf{x}) = \max_n p(\mathbf{x} | c_n) p(c_n) \quad (7)$$

onde a densidade de probabilidade gaussiana multivariada $p(\mathbf{x} | c_n)$, de dimensão 32, é dada por:

$$p(\mathbf{x} | c_n) = \frac{1}{(2\pi)^{16} |C_n|^{1/2}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mu_n)^T C_n^{-1} (\mathbf{x} - \mu_n) \right] \quad (8)$$

No desenvolvimento realizado as classes foram consideradas equiprováveis, ou seja, todas elas tem a mesma probabilidade a priori de ocorrerem e, portanto:

$$p(c_k) = 1/5, \quad \text{para } k = 1, 2, \dots, 5. \quad (9)$$

V. RESULTADOS

Com o treinamento dos classificadores feitos com as imagens SAR dos alvos com ângulo de depressão de 17° fez-se a classificação dos alvos das imagens obtidas com ângulo de depressão de 15° e avaliou-se o porcentual de alvos classificados corretamente (P_C).

A Tabela 1 mostra a matriz de confusão relativa a classificação pela mínima distância e a Tabela 2 mostra a matriz de confusão para a classificação MAP.

Nestas Tabelas cada linha horizontal mostra como um dado alvo foi classificado. A soma dos valores constantes nas linhas horizontais dá o valor do número total de imagens do alvo correspondente a linha. Por exemplo, na Tabela 1 de 272 imagens do alvo As1, 250 foram classificadas corretamente e 22 incorretamente (três foram classificados como alvo T62, duas como alvo Zsu234 e 17 como alvo BTR-60).

No teste foram utilizadas 272 imagens de cada um dos veículos 2s1, Brdm2 e Zsu234, 271 imagens do veículo T62 e 195 imagens do veículo BTR-60.

A Tabela 3 apresenta, na segunda e terceira coluna, as porcentagem de acertos relativos às Tabelas 1 e 2. Na quarta e quinta coluna são apresentados os acertos da classificação feita somente com as imagens SAR dos alvos com ângulo de depressão de 17°, ou seja, foram utilizados os mesmos alvos para o treinamento e para a classificação.

TABELA 1: MATRIZ DE CONFUSÃO NA CLASSIFICAÇÃO DOS ALVOS DESEJÁVEIS PELA MÍNIMA DISTÂNCIA.

	2s1	Brdm2	T62	Zsu234	BTR-60
2s1	250	0	3	2	17
Brdm2	0	259	1	0	12
T62	10	1	232	7	21
Zsu234	7	2	1	260	2
BTR-60	0	0	0	2	193

TABELA 2: MATRIZ DE CONFUSÃO NA CLASSIFICAÇÃO MAP DOS ALVOS DESEJÁVEIS.

	2s1	Brdm2	T62	Zsu234	BTR-60
2s1	254	0	7	5	6
Brdm2	0	263	2	1	6
T62	5	0	255	6	5
Zsu234	2	2	1	266	1
BTR-60	0	0	2	2	191

TABELA 3: PORCENTUAL DE ACERTO NA CLASSIFICAÇÃO.

Alvos	Treinamento e classificação com diferentes alvos		Treinamento e classificação com os mesmos alvos	
	Pc (%)	Pc (%)	Pc (%)	Pc (%)
	Mín. Dist.	MAP	Mín. Dist.	MAP
2s1	91,91	93,38	97,64	98,65
Brdm2	95,22	96,69	98,99	100
T62	85,61	94,10	89,56	97,64
Zsu234	95,59	98,89	99,33	99,33
BTR-60	98,97	97,95	99,61	97,95
Total	93,14	95,87	96,95	98,96

Nota-se na avaliação dos resultados da Tabela 3 que os resultados obtidos são bons, sempre superiores a 85,61%, sem ter sido feita qualquer inferência a respeito do azimute dos alvos nas imagens SAR. Nota-se ainda que a classificação MAP teve um melhor desempenho, mesmo que não muito significativo.

Como era esperado o percentual de acerto quando se classificam os mesmos alvos utilizados no processo de treinamento é melhor que o caso mais realista em que o treinamento e a classificação são realizados com alvos diferentes. Entretanto como essa diferença não é muito acentuada pode-se concluir que os dois métodos de classificação são eficientes quanto o aprendizado das características dos alvos a serem classificados. Esta eficiência também mostra que o processo de escolha das características

dos alvos associado às 32 características escolhidas é razoável.

Outros trabalhos de reconhecimento de alvos, utilizando bancos de dados semelhantes, encontraram valores de percentual de acerto igual a $P_C = 93\%$, [5], e $P_C = 84,9\%$, [6]. Para este ultimo resultado os autores consideraram os azimutes dos alvos como conhecidos. A referência [7] no estudo de classificação de dez alvos, pelo método da máxima verossimilhança, obteve como resultados $P_C = 94,6\%$, $P_C = 95,01\%$, $P_C = 95,8\%$, $P_C = 97,36\%$ e $P_C = 97,7\%$, considerando diversas distribuições para as classes.

Comparando-se estes resultados com os obtidos na proposta deste trabalho verifica-se que o desempenho obtido é compatível com estes resultados.

VI. COMENTÁRIOS FINAIS

Fez-se a proposta de um processador para o reconhecimento automático de alvos de combate terrestre em imagens SAR, que não necessita de informações relativas ao azimute do alvo na imagem.

As características dos alvos foram obtidas pelo cálculo do valor quadrático médio da decomposição pela TWH das imagens em cinco níveis. A classificação foi realizada pelo método da mínima distância de Mahalanobis e pelo critério MAP.

O desempenho do processador foi testado com imagens SAR de alvos de interesse, obtendo-se resultados compatíveis com outros processadores citados pela literatura.

O processador proposto pode ser utilizado em processos decisórios automáticos e semi-automáticos que requeiram decisões rápidas e confiáveis.

A referência [8] estuda a detecção de alvos, que normalmente antecede os processos de reconhecimento automático dos alvos.

REFERÊNCIAS

- [1] J. P. P. Pordeus. *Reconhecimento automático de alvos em imagens SAR*. 2006. Dissertação de Mestrado – Instituto Tecnológico de Aeronáutica, São José dos Campos.
- [2] K. Tomiyasu. "Tutorial review on synthetic aperture radar (SAR) with application to imaging of ocean surface". *Proceedings of the IEEE*, v. 66, no. 5, 1978, pp. 563-583.
- [3] W. G. Carrara, R. M. Majewski and R. S. Goodman. *Spotlight Synthetic Aperture Radar*. Norwood: Artech House, 1995.
- [4] R. O. Duda, P. E. Hart and D. G. Stork.. *Pattern classification*. New York: Wiley, 2000.
- [5] M. Bryant and F. Garber. "Svm classifier applied to the mstar public data set". *SPIE Algorithm for synthetic aperture radar imagery*, 6.. 1999, Orlando. *Proceedings*, v. 3721, pp. 35-360.
- [6] Q. Zhao and J. C. Príncipe. "Suport vector machines for SAR automatic target recognition". *IEEE Trans. On Aerospace and Electronic System*, v. 37, 2001. pp.643-654.
- [7] M. Devore, J. O' Sullivan. "A performance complexity study of several approaches to automatic target recognition from synthetic aperture radar images". *IEEE Trans. On Aerospace and Electronic System*, v. 38, 2001. 1999, pp.632-648.
- [8] H. Oliveira. *Detecção automática de alvos em imagens SAR*. 2007. Dissertação de Mestrado – Instituto Tecnológico de Aeronáutica, São José dos Campos.