



Estratégias de acompanhamento de múltiplos alvos: uma comparação entre diferentes metodologias de associação de dados

Manuel Ramón Vargas Avila

Cachimo Combo Assane

Beatriz de Souza Leite Pires de Lima

Rubens Lopes de Oliveira

manuelvargas760@gmail.com

cachimo.assane@gmail.com

bia@coc.ufrj.br

rubensliv@yahoo.com

COPPE/UFRJ

Ilha do fundão, centro de Tecnologia, Cep: 21941-972, Rio de Janeiro, RJ, Brasil

Resumo. Neste trabalho propomos as redes neurais e máquinas de vetores suporte como metodologia de associação de dados para o acompanhamento de múltiplos alvos que trafegam em um ambiente marítimo, usando informações provenientes de um único sensor radar. Dessas duas técnicas de aprendizado de máquina, selecionamos aquela que apresenta o melhor desempenho e comparamos-la com a abordagem clássica, baseada no algoritmo de associação de dados Multi Hypothesis Tracking (MHT).

Com base nos resultados, pode-se inferir que as redes neurais representam uma boa opção para resolver o problema de associação dos dados empregados neste trabalho. Esta abordagem apresentou um tempo médio de execução por iteração menor do que o observado quando utilizado o método clássico (MHT). Em relação ao número de acompanhamentos confirmados, a metodologia clássica também possui um desempenho inferior, pois apresenta um número maior quando comparada com a abordagem proposta. Provavelmente, este resultado é devido à complexidade de sua estratégia de busca e ao seu processo de inicialização.

Palavras-Chaves: Algoritmo de acompanhamento, associação de dados, MHT, redes neurais, máquina de vetor suporte.

1 INTRODUÇÃO

Acompanhar um alvo que trafega num ambiente com alta densidade de *clutter* ou falsos alarmes é um processo complexo que exige algoritmos de associação de dados sofisticados capazes de lidar com um grande volume de dados. Em sistemas de navegação e vigilância civis e militares, varias estratégias de acompanhamento de múltiplos alvos (*Multiple Target Tracking-MTT*) tem sido propostas tendo em vista a identificação e rastreamento de ameaças em tempo real.

No contexto deste trabalho, entenda-se por contato, medida ou observação qualquer ponto fornecido pelo sensor cuja fonte pode ser um alvo ou *clutter*. Define-se por alvo qualquer objeto de interesse e *clutter* um contato gerado devido às condições do mar, objetos como boias ou erros internos do sensor entre outros fatores. *Tracks* ou acompanhamentos referem-se ao conjunto de parâmetros ou medidas que podem representar o movimento de um alvo. Falsos acompanhamentos referem-se a acompanhamentos compostos em sua maioria por medidas geradas por *clutter*. *Scan* refere-se à varredura completa da antena do radar. Finalmente, *tracking* ou rastreamento é o processo de estimação dos parâmetros da cinemática do alvo de interesse.

O foco principal de qualquer sistema de acompanhamento de múltiplos alvos é o processo de associação de dados, do qual depende a correta inicialização e atualização dos acompanhamentos. A presença de *clutter* dificulta a associação dos dados na medida em que se torna praticamente impossível decidir, com maior nível de certeza, se um contato se refere ao alvo de interesse ou simplesmente é *clutter*. Associar estas observações espúrias (*clutter*) ao alvo de interesse pode resultar na perda do acompanhamento, além de produzir maior quantidade de falsos acompanhamentos, comprometendo o desempenho computacional dos algoritmos.

O algoritmo clássico de associação de dados amplamente utilizado no MTT é o *Multi Hypothesis Tracking* (MHT) (Barbosa, 2012), o qual se baseia na criação de hipóteses para a obtenção do caminho mais provável do alvo. Uma característica principal do MHT é a necessidade de uso de um algoritmo completar que tenha a função de estimar a posição futura do alvo existente afim de delimitar o conjunto de novas medidas que podem ser associadas a este mesmo alvo. O método mais utilizado na literatura para esta função é o algoritmo de múltiplos modelos interagentes (IMM). A combinação destes dois algoritmos é conhecida como IMM/MHT (Blackman, 2004). Esta estratégia também foi adotada neste trabalho.

Algumas aplicações do algoritmo IMM/MHT podem ser encontradas em Blackman (2004), Blackman et al. (1997) e Bar-Shalom e Li (1995).

Diante de um cenário com alta densidade de *clutters*, o algoritmo IMM/MHT pode gerar um número significativamente grande de hipóteses, elevando o custo computacional de sua execução. Como alternativa, neste trabalho propomos duas técnicas de aprendizado de máquina, nomeadamente Redes Neurais e Maquinas de Vetor Suporte (SVM), visando contornar as dificuldades de caráter combinatória associadas ao algoritmo MHT.

As redes neurais são popularmente conhecidas pela recursividade dos seus modelos, seu baixo custo computacional após o seu treinamento, capacidade de se adaptar às mudanças no ambiente, robustez na presença de dados ruidosos e potencial para sua computação massiva paralela (Wasseman, 1989, Hertz, 1991). Por estas razões esta é uma das ferramentas recomendadas para aplicações que requerem resultados em tempo real. A revisão geral e referências sobre aplicações de Redes Neurais em problemas de associação de dados podem ser encontra-

das em Winter et al. (1999), Winter et al. (1998), Lin et al. (2005) e Lippmann et al. (1991).

As máquinas de vetor suporte são uma técnica de aprendizado estatístico, baseada no princípio da minimização do risco estrutural, e pode ser usada para resolver diversos problemas de classificação (Cristianini et al., 2000), obtendo resultados comparáveis e muitas vezes superiores aos obtidos por outros algoritmos de aprendizado, como as Redes Neurais (Braga et al., 2000, Haykin, 1999). Por esta razão, opta-se por utilizar esta técnica como uma alternativa para solucionar o problema relatado neste trabalho.

O objetivo principal deste trabalho é desenvolver uma estratégia de acompanhamento de múltiplos alvos utilizando como metodologia de associação de dados uma das técnicas de aprendizado de máquina acima mencionadas. A decisão de qual técnica deve ser utilizada é baseada na comparação de desempenho das mesmas. Importa destacar que o processo de treinamento para cada uma destas técnicas é *off-line* e utiliza o mesmo conjunto de pares de dados. O desempenho da estratégia aqui desenvolvida é comparado com o da metodologia clássica baseada no algoritmo de associação de dados MHT.

2 Medidas do sistema Radar

Neste trabalho é utilizado o sistema Radar de pulsos de busca de superfície, um dos mais populares na navegação marítima. Este sistema fornece uma medição da localização de um objeto em coordenadas polares a cada instante k de tempo discreto. O tempo entre as medições é uma variável que depende da velocidade, direção do navio e do tempo de rotação de antena (Miguens, 1996). Esta medição é perturbada por ruídos assumidos independentes e estacionários com distribuição gaussiana de média zero e variâncias constantes (Kang, 2008). Assim, esta medição é representada em forma de vetor

$$Z(k) = \begin{bmatrix} d(k) \\ \theta(k) \end{bmatrix} = \begin{bmatrix} d_r(k) \\ \theta_r(k) \end{bmatrix} + e(k) = \begin{bmatrix} d_r(k) \\ \theta_r(k) \end{bmatrix} + \begin{bmatrix} e_d(k) \\ e_\theta(k) \end{bmatrix}, \quad (1)$$

onde $d(k)$ e $d_r(k)$ são respectivamente as distâncias medida e real (em metros) do alvo ao observador, $\theta(k)$ e $\theta_r(k)$ representam o azimuth medido e real (em graus) com respeito ao norte geográfico, $e_d(k)$ é o ruído na distância com variância σ_d^2 e $e_\theta(k)$ é o ruído no azimuth com variância σ_θ^2 .

2.1 Geração de dados

Uma vez que não temos à disposição dados provenientes do sensor radar para realizar o treinamento das técnicas de aprendizado de máquina e validação do método proposto, foi necessário utilizar um gerador artificial de dados. Assim, foram empregados dois programas, nomeadamente gerador de trajetória de alvos e gerador de cenários. Estes programas foram fornecidos pelo Instituto de Pesquisa da Marinha (IPqM) apenas para fins de realização deste trabalho.

O gerador de trajetória permite criar trajetórias coerentes de alvos com diferentes padrões de movimentos. É importante destacar que, inicialmente, as trajetórias aqui geradas não apresentam ruído de processo ou de medição. Para o nosso caso, foram geradas trajetórias com

uma velocidade máxima de 200 m/seg, velocidade mínima de 70 m/seg, aceleração tangencial máxima de 5 m/seg² e taxa de guinada máxima de 5 grau/seg.

No programa gerador de cenários são acrescentados tanto os ruídos de processo como os de medição. O ruído de processo é visto como uma perturbação na aceleração e supõem-se que tem média zero e covariância constante. Em relação ao ruído de medição, o programa permite ajustar o desvio da distribuição dos ruídos segundo as características do sensor que se quer modelar. Além disso, permite definir parâmetros como alcances máximo e mínimo do Radar, a quantidade de clutter por varredura, tempo entre varreduras, número de sensores, número de alvos no cenário, entre outros. Assim, neste trabalho, foram estabelecidos os seguintes parâmetros: um desvio da distribuição dos ruídos de processo de 2 m/seg² para as componentes x e y , um desvio da distribuição dos ruídos de medição de 30 m na distância e de 3 mrad no azimuth, alcances máximo e mínimo de 30 Km e 5 Km respectivamente, tempo de rotação da antena de 2 seg e um máximo de 100 pontos de clutters por varredura, sendo que foi utilizado apenas um sensor por cenário.

A cada momento em que o gerador de cenários é executado, um cenário diferente com ruído aleatório é gerado. Como resultado da geração do cenário, é formada uma matriz que contém informações referentes à distância e azimuth de cada um dos contatos contidos no cenário e os respectivos tempos de detecção. Adicionalmente, é construído um vetor que contém informação sobre o tipo de contato, i.e, se o contato é clutter ou se é gerado pelo alvo.

Uma situação a ser levada em conta na geração dos dados é a possibilidade de acontecer perdas de detecção do alvo por algumas varreduras. Assim, para o nosso caso, opta-se por gerar trajetórias com três perdas consecutivas no máximo. A escolha deste número de perdas foi intuitiva pelo fato de que quanto maior o número de perdas consecutivas maior será a incerteza na associação dos contatos.

A partir desses dois programas foram gerados 17 cenários para o treinamento *off-line* da rede neural e da máquina de vetor suporte, compostos por alvos que descrevem diversas trajetórias visando incorporar grande parte dos tipos de manobras que acontecem na realidade. Para este caso, foram gerados cenários com um único alvo.

A título de exemplo, destacaremos apenas um desses cenários, o qual é apresentado na Figura 1(a). Neste cenário considera-se um alvo que descreve um movimento retilíneo com velocidade constante de 99 m/seg durante os primeiros 80 seg, seguido de um movimento curvilíneo com aceleração normal de 5 m/seg² (taxa de giro de 2.89 graus/seg) durante 100 seg e finalmente o alvo descreve um movimento retilíneo com velocidade constante de 99 m/seg durante 80 seg. Além disso, também foram inseridas perdas de detecção nos intervalos de tempo conforme apresentados na Tabela 1. Finalmente, para efeito de visualização, na Figura 1(b) é apresentada a trajetória resultante deste cenário na sua dimensão ampliada omitindo o clutter.

Uma etapa fundamental neste trabalho é a validação do método proposto e posterior comparação com o método clássico baseado no algoritmo MHT. Para o efeito, foram gerados 2 cenários compostos por múltiplos alvos, os quais incluem situações de alvos navegando próximos um dos outros, com diferentes padrões de cinemática e apresentando diferentes tipos de manobras, visando incorporar situações frequentes em áreas como portos ou baías. Os cenários gerados são apresentados nas Figuras 2(a) e 3(a). É importante destacar que nestes cenários também foram incluídas perdas de detecção em algumas das trajetórias.





Figura 1: Geração de cenário

Tabela 1: Intervalos de tempo e varreduras com perda de detecção no cenário

Tempo (seg)	Varredura
[12 – 18]	7 a 8
[28 – 36]	15 a 17
[46 – 52]	24 a 25
[58 – 62]	30
[70 – 78]	36 a 38
[82 – 88]	42 a 43
[92 – 96]	47
[100 – 108]	51 a 53
[198 – 206]	100 a 102
[228 – 232]	115


As trajetórias que compõem os cenários gerados podem ser observadas nas Figuras 2(b) e 3(b). As trajetórias mostradas nestas figuras não são afetadas por ruídos de processo e de medição.



(a) Cenário1 para validação

(b) Trajetórias que compõem o cenário 1

Figura 2: Geração do cenário 1 para validação do método proposto



(a) Cenário2 para validação

(b) Trajetórias que compõem o cenário 2

Figura 3: Geração do cenário 2 para validação do método proposto

3 Método clássico

O método clássico de acompanhamento de múltiplos alvos, pode ser decomposto em dois processos fundamentais:

- **Inicialização:**

Criação do track preliminar:

Uma medida não associada a um *track* existente é considerada como um “iniciador”, usado para produzir uma “tentativa de *track*”. Na varredura, após a detecção de um iniciador, é construída entorno dele uma janela de associação circular com limites estabelecidos por

$$D.min = (V_{min} * t_r) - (3 * \sigma_d) \quad (2)$$

$$D.max = (V_{max} * t_r) + (3 * \sigma_d), \quad (3)$$

onde $D.min$ e $D.max$ são o alcance mínimo e máximo da janela respectivamente, V_{min} e V_{max} representam as velocidades mínima e máxima definidas para o tipo de alvo de

interesse, t_r é o tempo de rotação de antena do Radar e σ_d é o desvio padrão do ruído de medição na distância.

Se existe uma nova medida dentro dessa janela o conjunto dos dois contatos formam um “*track* preliminar”. Caso não haja alguma medida que possa ser associada, a tentativa de *track* é descartada.

Atualização dos *tracks* preliminares:

Para isto utiliza-se num primeiro momento um filtro de kalman padrão com modelo de cinemática retilíneo uniforme, para prever a posição futura do alvo em acompanhamento (*track* preliminar), seguidamente, com centro na posição prevista pelo filtro é criada uma janela de precorreção utilizando as equações 2 e 3. Finalmente, no caso de houver mais de um contato nesta janela é empregado o método de associação pelo vizinho mais próximo, o critério considerado neste caso é a distancia euclidiana.

Confirmação ou eliminação do *track*:

A partir da terceira varredura, a lógica de M detecções em N scans é utilizada para decidir se o *track* preliminar é confirmado ou eliminado. Esta lógica é nomeada critério M/N . Se no final das $N + 2$ varreduras o critério lógico for satisfeito, o *track* preliminar é agora chamado por “*track* confirmado”, de outra maneira o *track* é eliminado. Esta lógica é executada como apresentado em Bar-Shalom et al. (1995) e Peters (2001). Para o nosso caso, segundo a densidade de clutter na área de vigilância, os parâmetros M e N podem assumir valores inteiros entre 3 e 9.

- **Manutenção:**

O primeiro passo deste processo é o de prever a posição futura do alvo para isso utiliza-se o algoritmo de filtragem IMM o qual também é utilizado para fazer o alisamento do acompanhamento. Entorno da posição prevista é criada uma janela de precorreção utilizando as equações 2 e 3. Finalmente, como algoritmo de associação é empregado o MHT orientado a tracks (Track-oriented MHT, TOMHT). A descrição deste algoritmo é apresentada em Amditis et al. (2012) e Bar-Shalom (1990).

4 Metodologia

Conforme referido anteriormente, neste trabalho são testadas duas técnicas de aprendizado de máquina, Redes Neurais e SVM, para resolver o problema de associação de dados. O objetivo é selecionar a técnica que apresente o melhor desempenho para posteriormente construir a nossa estratégia de acompanhamento. A bem da simplicidade, de agora em diante, esta estratégia de acompanhamento é designada por método proposto.

A Figura 4 representa o esquema funcional do método proposto neste trabalho, o qual consiste em três etapas principais: na primeira, os acompanhamentos preliminares são criados, em seguida, ao receber novas medidas, os mesmos podem ser atualizados mediante o algoritmo de associação de dados e por último um processo de filtragem é aplicado com o objetivo de encontrar a aproximação da trajetória real do alvo que é de interesse para o usuário do sistema.

As etapas que compõem este método são detalhadas a seguir.




Figura 4: Esquema funcional do método proposto para abordar o problema de MTT

4.1 Criação dos acompanhamentos preliminares

Nesta etapa é criada uma janela circular entorno de qualquer medida não associada a um acompanhamento existente. Esta janela terá limites estabelecidos por alcances mínimo de 70 metros e máximo de 490 metros. Se na varredura seguinte aparece uma medida dentro da janela criada, é inicializado um acompanhamento. Devido à densidade de clutter, é possível que dentro de uma mesma janela apareçam mais do que uma medida, criando acompanhamentos com medidas em comum, os quais, no decorrer do tempo, muito provavelmente serão excluídos, permanecendo unicamente aqueles que representam um objeto de interesse. Os acompanhamentos criados são armazenados e atualizados nas seguintes varreduras por meio do algoritmo de associação de dados.

4.2 Algoritmos de associação de dados

Tendo em conta os diferentes tipos de movimento que um alvo marítimo pode experimentar e as informações provenientes do sensor Radar, foram selecionadas como variáveis de entrada para cada uma das técnicas de aprendizado de máquina,

$$\Delta V(t_k) = V(t_k) - V(t_{k-1}) \quad (4)$$

$$\Delta \alpha(t_k) = \frac{\alpha(t_k) - \alpha(t_{k-1})}{\Delta T} \quad (5)$$

$$\Delta T = t_k - t_{k-1} \quad (6)$$

onde $V(t_k)$ é a velocidade necessária para percorrer a distancia entre dois contatos, $\alpha(t_k)$ representa a variação do rumo da trajetória do alvo em graus e ΔT é o tempo entre medições. O cálculo destas variáveis é feito para cada um dos contatos disponíveis para associação com um acompanhamento existente. No caso apresentado na Figura 5, os contatos 1 a 3 representam um acompanhamento existente e os contatos 4 a 5, gerados na mesma varredura, são aqueles que estão em avaliação para serem associados ao acompanhamento. Só um destes contatos será selecionado para associação.

Devido à quantidade maior de contatos gerados numa única varredura e à grande área de vigilância do radar, optamos por dividir a área de vigilância em 16 setores, o que implica uma separação mínima entre dois setores não vizinhos de aproximadamente 1.96 km. Observe que é impossível percorrer esta distância em 8 seg (tempo máximo entre medições considerando as perdas consecutivas) tomando como referência a velocidade máxima dos alvos estabelecida neste trabalho. Portanto, para não testar contatos fora de alcance do alvo que esta sendo acompanhado, definimos uma heurística segundo a qual, todas associações entre acompanhamentos e contatos em setores não vizinhos são ignoradas.




Figura 5: Demonstração de cálculo das variáveis de entrada

Uma vez selecionados os contatos em setores vizinhos, calcula-se a velocidade necessária para percorrer a distância entre o acompanhamento (track) e cada um destes contatos. A partir desta informação, são selecionados candidatos à associação apenas os contatos que tenham velocidade coerente com a descrita pelo alvo. Desta forma, foi estabelecido que um alvo com velocidade superior a 400 m/seg ou inferior a 30 m/seg não pode ser considerado candidato à associação.

A geração das entradas para a aplicação do treinamento de cada uma das técnicas testadas, é feita assumindo que as medidas fornecidas pelo sensor até o instante de tempo $k - 1$ pertencem à trajetória de um determinado alvo e não a clutter correlacionado (falsos acompanhamentos).

A informação do tipo de contato, fornecida pelo programa gerador de cenário, onde o valor 1 indica que o contato é gerado por um alvo e -1 indica que o contato é clutter, é utilizada para compor o vetor de saídas desejadas. É assumido que o contato identificado como tipo 1 é o mais adequado ou coerente para atualizar o acompanhamento existente do mesmo alvo.

A partir dos 17 cenários gerados para o treinamento da rede neural e da SVM (seção 2) e da descrição sobre como é calculado cada um dos pares entrada-saída, obtém-se 2766 pares de dados dos quais, 831 representam a associação do acompanhamento com o contato gerado pelo mesmo alvo e 1935 representam associação com clutter. Estes dados são pré-processados através de sua normalização. Esta etapa é feita utilizando a ferramenta de pré-processamento de dados do *software* Matlab. Finalmente, o conjunto de entradas é dividido em 3 subconjuntos nomeadamente treinamento, validação e teste, definidos aleatoriamente com proporções de 60%, 20% e 20% respectivamente.

A rede neural aqui utilizada é composta por uma camada escondida ou intermediária com cinco neurônios e outra camada de saída com apenas um neurônio, sendo que em ambas as camadas foi empregada a função de ativação de tipo tangente hiperbólica. Para o treinamento desta rede foi utilizado o algoritmo *backpropagation* com otimização Levenberg-Marquart, considerado um dos algoritmos com melhor desempenho no treinamento de redes neurais unidirecionais (*feedforward*) (Hagan, 1994). Embora este algoritmo misture alta velocidade de convergência com estabilidade, seu custo computacional pode ser elevado, por ser um método de segunda ordem.

O modelo SVM consiste na seleção de um hiperplano separador que minimize o risco estrutural, a partir da resolução de um problema convexo quadrático. Esta técnica de aprendizado quando associada à função núcleo permite a construção de classificadores não-lineares, através do mapeamento dos dados iniciais em um espaço de dimensão superior ao original. Neste caso, o classificador linear obtido em um espaço de dimensão superior corresponderá a um classifi-

cador não-linear no espaço original, vide Burges (1998) e Gunn (1998) para maiores detalhes. Estas características garantem ao SVM uma boa generalização, ou seja, uma boa capacidade de prever corretamente dados não relacionados na amostra de treinamento.

A função que representa hiperplano separador é dada por:

$$f(x) = \sum_{i=1}^l \alpha_i y_i k(\vec{x}, \vec{x}_i) + b \quad (7)$$

onde $k(\vec{x}, \vec{x}_i)$ é a função núcleo, $f(x)$ determina a associação de um determinado vetor de entrada, $\vec{x}$, a uma determinada classe, y_i é a etiqueta do vetor de treinamento $\vec{x}_i$ e α_i identifica os registros correspondentes aos vetores de suporte. Qualquer $\vec{x}_i$ que correspondente a um α_i diferente de zero é considerado um vetor de suporte.

No nosso trabalho foram testadas duas configurações da SVM, uma com função núcleo linear e outra com função núcleo Quadrática. Para solucionar o problema de ajuste dos parâmetros deste modelo foi empregado o algoritmo de *otimização mínima sequencial* (SMO) considerando as mesmas variáveis de entradas e os mesmos dados de treinamentos utilizados na rede neural. Os detalhes sobre a formulação matemática e funcionamento do algoritmo SMO podem ser encontrados em Platt (1999).

A implementação destas técnicas foi feita utilizando o *software* Matlab.

4.3 Confirmação e eliminação de acompanhamentos

Para a confirmação ou eliminação do acompanhamento é utilizado numa fase temprana o critério M/N descrito na seção 3, onde M e N são empiricamente definidos com valores iguais a 3 e 4 respectivamente. Se o critério é satisfeito e o acompanhamento confirmado, é verificado se no decorrer do tempo este acompanhamento apresenta mais do que três perdas consecutivas. Se assim acontecer, o mesmo é considerado como perdido e posteriormente eliminado.

4.4 Filtragem

Nesta etapa é utilizado o algoritmo de Múltiplos Modelos Interagentes (IMM), composto por dois filtros de Kalman estendido (EKF). A idéia é atingir um desempenho satisfatório quando a trajetória do alvo experimenta diferentes padrões de comportamento ao longo do tempo (Kirubarajan, 2003). A descrição dos parâmetros de cada um dos modelos de filtros utilizados é apresentada em Vargas (2015).

5 Desempenho dos algoritmos de associação de dados

Conforme referido anteriormente, as técnicas de aprendizado de máquina apresentadas neste trabalho tem como tarefa principal identificar se um contato pode ser associado ou não a um determinado acompanhamento, ou seja, pretende-se identificar se um contato foi gerado pela trajetória do alvo que esteja sendo acompanhado ou se é clutter. Cada uma destas técnicas foi treinada em *off-line* a partir dos 2766 pares de dados descritos na seção anterior. Após o treinamento, é feita uma comparação do desempenho entre estas duas técnicas com o propósito de selecionar aquela que vai servir para construir o nosso método proposto. Assim, para construir a matriz de confusão (Tabela 2) de cada um dos algoritmos de associação testados, os contatos foram divididos em duas classes, nomeadamente classe alvo e classe clutter.

Tabela 2: Matriz de Confusão dos resultados do treinamento para cada uma das técnicas de associação de dados testadas. A classe alvo refere-se ao fato de o contato ser gerado pelo alvo, caso contrário o contato pertence à classe clutter.

		Treinamento					
		Rede neural		SVM kernel linear		SVM kernel quadrática	
		Previsto		Previsto		Previsto	
		Alvo	Clutter	Alvo	Clutter	Alvo	Clutter
Real	Alvo	488	5	490	3	489	4
	Clutter	11	1156	38	1129	36	1131
		Validação					
		Rede neural		SVM kernel linear		SVM kernel quadrática	
		Previsto		Previsto		Previsto	
		Alvo	Clutter	Alvo	Clutter	Alvo	Clutter
Real	Alvo	161	1	162	0	162	0
	Clutter	6	385	15	376	13	378
		Teste					
		Rede neural		SVM kernel linear		SVM kernel quadrática	
		Previsto		Previsto		Previsto	
		Alvo	Clutter	Alvo	Clutter	Alvo	Clutter
Real	Alvo	174	2	176	0	176	0
	Clutter	1	376	11	366	10	367
		Total					
		Rede neural		SVM kernel linear		SVM kernel quadrática	
		Previsto		Previsto		Previsto	
		Alvo	Clutter	Alvo	Clutter	Alvo	Clutter
Real	Alvo	823	8	828	3	827	4
	Clutter	18	1917	64	1871	59	1876

A partir da informação contida na Tabela 2 calculamos a taxa de acerto, a sensibilidade e especificidade de cada uma das soluções testadas como medidas do desempenho, conforme a Tabela 3. Lembrando que a sensibilidade é a probabilidade de classificar corretamente uma entrada cujo estado real é definido como positivo. No nosso contexto, o estado positivo refere-se à classe alvo. A especificidade é a probabilidade de classificar corretamente uma entrada cujo

estado real é definido como negativo. No nosso contexto, o estado negativo refere-se à classe clutter.

Tabela 3: Resumo de medidas de desempenho

	Levenberg-Marquart	SVM kernel linear	SVM kernel Quadratica
Taxa de acerto(%)	99.06	97.57	97.72
Sensibilidade	0.9904	0.9964	0.9952
Especificidade	0.9907	0.9669	0.9695

Com base nestes resultados é possível afirmar que o desempenho obtido pela rede neural é ligeiramente superior em relação às duas variações de SVM testadas, uma vez que apresenta maior taxa de acerto e maior equilíbrio na classificação de ambas as classes. Além disso, é possível observar que a probabilidade de classificar corretamente entradas desconhecidas para a rede de ambas as classes é de aproximadamente 99%. Por estas razões, a rede neural é a melhor escolha para a construção do método proposto cujo desempenho é posteriormente comparado com o do método clássico.

6 Resultados do método proposto

Para comparar o desempenho dos métodos clássico e proposto são construídas as Tabelas 4 e 5, levando em consideração as seguintes métricas

- Número de acerto de associação dos contatos: quando o contato selecionado para associação é gerado pelo alvo de interesse.
- Número de erros de associação: inclui perdas de detecção e associação de clutter ao acompanhamento.
- Número de clutter's associados aos acompanhamentos após a finalização do tempo de duração da trajetória real do alvo: uma vez que as trajetórias contidas nos cenários podem apresentar diferentes tempo de duração, algumas com 100 seg e outras com 150 seg, o algoritmo pode continuar associando clutters a um determinado acompanhamento até que o tempo de execução do cenário seja finalizado, sendo que este acompanhamento na verdade não continuará gerando novos contatos. Esta medida de desempenho é considerada com o propósito de avaliar o comportamento do algoritmo antes que aconteçam essas situações. Por simplicidade nomearemos esta métrica como número de clutter's associados.
- Taxa de acerto: calculada considerando o número de contatos gerados pelos alvos e o número de clutter's associados aos acompanhamentos após o tempo de duração da trajetória.
- Tempo médio por Iteração: esta medida está relacionada ao tempo que o programa leva em analisar os dados contidos numa única varredura de antena do radar.

- Número de acompanhamentos confirmados ao finalizar a execução do cenário: alguns destes acompanhamentos podem ser considerados como falsos acompanhamentos e podem levar a uma diminuição do desempenho do algoritmo.

Tabela 4: Resultados do Cenário 1

Cenário 1		
	Método Clássico	Método Proposto
Número de Contatos gerados pelos alvos	188	188
Número de acertos	184	187
Número de erros	8	1
Número de Clutter's associados	6	0
Taxa de acerto (%)	94.85	99.46
Tempo medio por Iteração (seg)	1.8421	0.1377
Número de acompanhamentos confirmados	11	5

Tabela 5: Resultados do Cenário 2

Cenário 2		
	Método Clássico	Método Proposto
Número de Contatos gerados pelos alvos	308	308
Número de acertos	307	305
Número de erros	4	3
Número de clutter's associados	3	0
Taxa de acerto (%)	98.71	99.03
Tempo medio por Iteração (seg)	2.20885	0.1957
Número de acompanhamentos confirmados	9	6

7 Conclusões

O foco principal deste trabalho é desenvolver uma estratégia de acompanhamento de múltiplos alvos que tenha um desempenho comparável com o da metodologia clássica baseada no algoritmo de associação de dados MHT. Para construir esta estratégia, é selecionada, através de comparação de desempenhos, uma das técnicas de aprendizado de máquina (redes neurais e

SVM) utilizadas como ferramentas para resolver o problema de associação de dados relacionado ao processo de acompanhamento. Os resultados dessa comparação mostram que, para o problema em estudo, a rede neural é a melhor opção para compor o método proposto, uma vez que apresenta um desempenho ligeiramente superior em relação ao de outra técnica. Além disso, a rede neural apresenta maior taxa de acerto e maior equilíbrio na classificação de ambas as classes, e a probabilidade de classificar corretamente entradas desconhecidas para a rede de ambas as classes é de aproximadamente 99%.

O método proposto permite abordar o problema de acompanhamento envolvendo um número maior de alvos para diferentes cenários com alta densidade de clutters. Seu custo computacional reduziu significativamente em comparação com o método clássico. A outra diferença de grande destaque entre os dois métodos diz respeito ao número de acompanhamentos confirmados, que é maior para o método clássico, provavelmente, um dos fatores que influenciam no aumento do custo computacional deste método. Em relação a outras métricas, os resultados são praticamente similares. Assim, podemos afirmar que o método proposto apresenta-se como uma alternativa eficaz na realização de acompanhamento de múltiplos alvos.

Agradecimentos

Ao IPqM e FUNDEP

REFERÊNCIAS

- Amditis, A., Thomaidis, G., Maroudis, P., Lytrivis, P., & Karaseitanidis, G., 2012. Multiple hypothesis tracking implementation. In Munoz, J., eds, *Laser Scanner Technology*. InTechOpen.
- Bar-Shalom, Y., 1990. *Multitarget-multisensor tracking: advanced applications*. Artech House, Norwood, MA.
- Barbosa, R. P., 2012. *Fusão de alvos utilizando grafos em ambientes de múltiplos sensores*. PhD thesis, Universidade Federal do Rio de Janeiro.
- Bar-Shalom, Y., & Li, X., 1995. *Multitarget-Multisensor Tracking: Principles and Techniques*. Yaakov Bar-Shalom, 3 edition.
- Blackman, S. S., 2004. Multiple hypothesis tracking for multiple target tracking. *IEEE Aerospace and Electronic Systems Magazine*, vol.19, n. 1, pp. 5-18.
- Blackman, S. S., Dempster, R. J., & Roszkowski, S. H., 1997. IMM/IMHT Applications to Radar and IR Multitarget Tracking. *Proc. SPIE, Signal and Data Processing of Small Targets*, vol.3163, pp. 429-439.
- Braga, A., Carvalho, A., & Ludemir, T., 2000. *Redes Neurais Artificiais: Teoria e Aplicações*. LTC.
- Burges, C. J., 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, vol.2, n. 2, pp. 121-167.
- Cristianini, N., & Shawe-Taylor, J., 2000. *An introduction to support Vector Machines: and other kernel-based learning methods*. New York: Cambridge University Press.

- Gunn, S. R., 1998. *Support Vector Machines for Classification and Regression*. Technical Report, University of Southampton.
- Hagan, M., & Menhaj, M., 1994. Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, vol. 5, n. 6, pp. 989-993.
- Haykin, S., 1999. *Neural Networks - A Comprehensive Foundation*. Prentice-Hall, New Jersey, 2nd edition.
- Hertz, J., Krogh, A., & Palmer, R., 1991. *Introduction to the Theory of Neural Computation*. Addison-Wesley.
- Kang, E., 2008. *Radar system analysis, design, and simulation*. Artech House.
- Kirubarajan, T., & Bar-Shalom, Y., 2003. Kalman filter vs. imm estimator: When do we need the latter?. *IEEE Transactions on Aerospace and Electronic Systems*, vol. 39, n. 4, pp. 1452-1457.
- Lin, Y., Chen, H., Su, J., Chen, J., Hu, Y., & Chung, Y., 2005. Applying the competitive hopfield neural network to multiple target tracking systems. *Automatic Control Conference Tainan, Taiwan*.
- Miguens, A., 1996. *Navegação a Ciência e a Arte: Navegação Costeira, Estimada e em águas Restritas*. Rio de Janeiro: DHN.
- Peters, D., 2001. *A practical guide to level one data fusion algorithms*. Defence Research Establishment Atlantic.
- Platt, J., 1999. Fast training of support vector machines using sequential minimal optimization. *Advances in kernel methodssupport vector learning*, vol. 3, pp. 185-208.
- Richard, M., & Lippmann, R., 1991. Neural network classifiers estimate Bayesian a posteriori probabilities. *Neural computation*, vol. 3, n. 4, pp. 461-483.
- Vargas, M., 2015. *Estratégias de acompanhamento de múltiplos alvos: uma comparação entre as abordagens de associação de dados MHT e redes neurais*. MSc thesis, Universidade Federal do Rio de Janeiro.
- Wasserman, P., 1989. *Neural Computing Theory and Practice*. Van Nostrand Reinhold.
- Winter, M., & Favier, G., 1999. A neural network for data association. *IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 2, pp. 1041-1044.
- Winter, M., & Favier, G., 1998. A neural solution for multitarget tracking based on a maximum likelihood approach. *IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 2, pp. 1141-1144.