

# Detecção e Rastreamento Conjuntos de Alvos com Aspecto Variável usando Filtros de Partículas

Marcelo G. S. Bruno, Rafael V. de Araújo e Anton G. Pavlov

**Resumo**—Apresenta-se nesse artigo um algoritmo original para detecção e rastreamento conjuntos de alvos de aspecto variável em seqüências de imagens utilizando filtros de partículas. O algoritmo proposto possibilita detecção e rastreamento multiquadros incorporando os modelos estatísticos para movimento e aspecto do alvo e levando também em consideração o modelo para a correlação espacial do clutter de fundo. Duas implementações do algoritmo proposto são investigadas utilizando respectivamente um filtro de partículas auxiliares (APF) e um filtro de partículas “resample-move” (RS). Os resultados das simulações sugerem um desempenho superior da configuração APF em comparação com o filtro RS em cenários com alvos de baixa visibilidade.

**Palavras-Chave**—Rastreamento de alvos com múltiplos aspectos, detecção multiquadros, filtros de partículas auxiliares, campos aleatórios Gauss-Markov.

**Abstract**—We present in this paper a new algorithm for joint detection and tracking of multi-aspect targets in images using particle filters. The proposed algorithm enables multiframe detection and tracking incorporating the statistical models for target motion and target aspect, and also taking into account the model for the spatial correlation of the clutter background. Two implementations of the proposed algorithm are investigated using respectively an auxiliary particle filter (APF) and a resample-move (RS) particle filter. Simulation results suggest that the APF configuration outperforms the RS filter in scenarios of stealthy targets.

**Keywords**—Multi-aspect target tracking, multiframe detection, auxiliary particle filtering, Gauss-Markov random fields.

## I. INTRODUÇÃO

As abordagens tradicionais para detecção e rastreamento de alvos móveis em imagens, ver p.ex. [1], [2], baseiam-se na associação subótima de detectores de correlação de quadro único com filtros linearizados de Kalman usados para rastreamento multiquadros. Tal associação apresenta, porém, um desempenho reconhecidamente ruim [3] em cenários onde se deseja seguir alvos que são fortemente obscurecidos por clutter e têm aspecto desconhecido e variante no tempo. Nesse artigo, propõe-se uma solução alternativa baseada em filtragem de partículas [4] onde se elimina o estágio preliminar de detecção baseado em um quadro único e se possibilita detecção e rastreamento multiquadros integrados incorporando os modelos estatísticos para movimento e mudança de aspecto do alvo, e levando também em consideração o modelo para a correlação espacial do clutter de fundo.

Os autores são afiliados à Divisão de Engenharia Eletrônica, Instituto Tecnológico de Aeronáutica, São José dos Campos SP, Brasil. E-mails: {bruno,vidal,anton}@ita.br. O trabalho do segundo e terceiro autores foi parcialmente financiado pela CAPES, Brasil.

O detector/rastreador integrado apresentado nesse artigo é uma evolução do algoritmo introduzido em [5]. Em [5], considerava-se o uso de filtros de partículas apenas para o rastreamento de um alvo de aspecto incerto, assumindo-se que o alvo estava sempre presente na cena. Nesse artigo, tem-se um grau adicional de incerteza na medida em que o algoritmo rastreador não só desconhece o aspecto real do alvo, mas também não tem nenhuma informação a priori sobre a presença ou ausência do alvo em cada imagem. O algoritmo deve então, a cada quadro, decidir primeiro se o alvo está ou não presente e, caso ele seja considerado presente, estimar o seu estado oculto (por exemplo, posição, velocidade e aspecto).

Como em [5], modelam-se a posição e a velocidade do centróide do alvo como variáveis aleatórias contínuas assumindo valores no conjunto dos números reais. O aspecto desconhecido do alvo em cada quadro  $n$  é modelado por sua vez como uma variável aleatória discreta que assume valores em um alfabeto finito  $\mathcal{I}$ , onde cada símbolo, como em [5], é um ponteiro para uma possível versão do padrão de referência do alvo de interesse modificada por transformações afins. Para permitir a integração das tarefas de detecção e rastreamento, estende-se porém o alfabeto  $\mathcal{I}$  em [5] de modo a incluir um estado artificial adicional que representa a ausência do alvo. A evolução no tempo do estado cinemático e do aspecto do alvo é descrita então por um modelo dinâmico estocástico acoplado onde as seqüências de posições, velocidades e aspectos são estatisticamente dependentes entre si. A imagem livre do alvo é modelada, por outro lado, por uma função não-linear que mapeia uma dada posição do centróide do alvo em uma distribuição espacial de pixels com forma e intensidade dependentes do aspecto atual. Finalmente, o alvo é sobreposto a um fundo estruturado cuja correlação espacial é representada por um modelo de campo aleatório Gauss-Markov não-causal [6], [7].

Dados os modelos descritos anteriormente, a solução ótima (do ponto de vista bayesiano) para o problema de detecção e rastreamento integrados requer o cálculo recursivo da distribuição conjunta a posteriori do estado cinemático e do aspecto do alvo a cada instante  $n$ , condicionada às imagens observadas do instante 0 até o instante  $n$ . Porém, dada a não-linearidade dos modelos de observação e de movimento, o cálculo analítico exato dessa distribuição a posteriori não é em geral possível. Uma solução então é utilizar um método Monte Carlo seqüencial conhecido como filtragem de partículas [4], [8], ou, na literatura de visão computacional, algoritmo de condensação [9].

De forma resumida, a idéia básica dos filtros de partículas

é representar a distribuição a posteriori de interesse por um conjunto apropriadamente ponderado de amostras, ou partículas, tal que, a cada iteração do algoritmo, à medida que o número de amostras vai para infinito, a média ponderada das partículas converge (em algum sentido estatístico) para a estimativa de mínimo erro quadrático médio (MMSE) do estado oculto dadas as observações. Usando uma estratégia padrão de amostragem por importância com estado misto (discreto/contínuo), ver [10], esse conjunto aproximadamente ponderado de amostras pode ser construído amostrando-se seqüencialmente a população de partículas segundo o modelo dinâmico acoplado para movimento e aspecto do alvo e, atualizando-se recursivamente os pesos de cada nova amostra de acordo com a função de verossimilhança que incorpora os modelos de assinatura do alvo e clutter de fundo.

O algoritmo de amostragem por importância seqüencial padrão descrito anteriormente sofre, porém, da limitação, ver [11], de que a variância dos pesos das amostras cresce ao longo do tempo, levando no extremo ao fenômeno de *degeneração de partículas* [4], segundo o qual a maior parte das partículas terão pesos negligenciáveis, não contribuindo, portanto, para a estimativa do estado. Para contornar o problema de degeneração, utiliza-se nesse artigo um método alternativo baseado em filtros com partículas auxiliares (APF), ver [12], onde se pré-selecionam no instante  $n-1$  as partículas que, quando propagadas para o instante  $n$  de acordo com o modelo dinâmico, têm maior probabilidade de gerar amostras de alta verossimilhança.

Organização do Artigo Esse artigo é dividido em 5 seções. A Seção I é essa Introdução. Na Seção II, apresentam-se os modelos dinâmicos de movimento e aspecto do alvo e o modelo de observação que são usados na implementação do detector/rastreador. Na Seção III, apresenta-se o algoritmo de detecção/rastreamento por filtragem com partículas auxiliares. Os estudos de desempenho do algoritmo proposto são mostrados na Seção IV usando medidas simuladas de radar infravermelho aerotransportado. Para fins de comparação apenas, apresentam-se também na Seção IV medidas de desempenho para o filtro de partículas alternativo introduzido em [13], baseado na técnica “resample-move”, ver [14]. Finalmente, apresentam-se na Seção V as conclusões do nosso trabalho.

## II. O MODELO

A seguir, apresentam-se os modelos de alvo e de observações usados nesse artigo. Ao longo do artigo, utilizam-se letras minúsculas para denotar tanto variáveis/vetores aleatórios quanto realizações de variáveis/vetores aleatórios; a interpretação apropriada está implícita no contexto. Utiliza-se ainda a letra  $p$  minúscula para denotar funções densidade de probabilidade (fdp's) e a letra  $P$  maiúscula para indicar funções massa de probabilidade (fmp's). O símbolo  $Pr(A)$  é usado para denotar a probabilidade de um evento  $A$  na  $\sigma$ -álgebra do espaço amostral.

Variáveis de Estado Seja  $n$  um número inteiro não-negativo e use o símbolo superscrito  $T$  para representar matrizes ou vetores transpostos. Define-se então o estado cinemático do alvo no quadro  $n$  como o vetor de dimensão quatro,

$\mathbf{s}_n = [x_n \dot{x}_n y_n \dot{y}_n]^T$ , que coleciona as posições,  $x_n$  e  $y_n$ , e as velocidades,  $\dot{x}_n$  e  $\dot{y}_n$ , do centróide do alvo em um sistema bidimensional de coordenadas cartesianas  $(x, y)$ . O vetor  $\mathbf{s}_n$  é modelado como um vetor aleatório contínuo assumindo valores em  $\mathbb{R}^4$ . Por outro lado, o aspecto do alvo no quadro  $n$ , denotado  $z_n$ , é modelado como uma variável aleatória discreta que assume valores no conjunto finito  $\mathcal{I} = \{0, 1, 2, 3, \dots, K\}$ , onde o evento  $\{z_n = 0\}$  indica que não há nenhum alvo presente na imagem no quadro  $n$ . Cada estado  $i$ ,  $i = 1, 2, \dots, K$ , representa por sua vez um ponteiro para um possível modelo de aspecto do alvo, correspondendo a rotações, escalonamento e/ou cisalhamento de um padrão de referência nominal do alvo.

### A. Modelos de Movimento e Aspecto dos Alvos

A seqüência aleatória  $\{(\mathbf{s}_n, z_n)\}$ ,  $n \geq 0$ , é modelada como um processo de Markov de primeira ordem especificado pela fdp do estado cinemático inicial,  $p(\mathbf{s}_0)$ ; pela fmp do aspecto inicial,  $P(z_0)$ ; e, pelas fdp e fmp de transição, respectivamente,  $p(\mathbf{s}_n | z_n, \mathbf{s}_{n-1}, z_{n-1})$ , e  $P(z_n | z_{n-1}, \mathbf{s}_{n-1})$ .

Transição de Aspecto Considere que, em qualquer quadro dado, para qualquer aspecto  $z_n$ , a imagem livre de clutter do alvo está contida em uma região retangular limitada de dimensão máxima  $(r_i + r_s + 1) \times (l_i + l_s + 1)$ . Assuma ainda que cada quadro da seqüência de imagens tem dimensão  $L \times M$  pixels. Baseado nessas hipóteses, introduz-se a *grade estendida*  $\hat{\mathcal{L}} = \{(r, j) : -r_s + 1 \leq r \leq L + r_i, -l_s + 1 \leq j \leq M + l_i\}$ , que coleciona todos os possíveis valores da posição do centróide do alvo para os quais pelo menos um pixel do alvo se encontra no interior da imagem do sensor. A seguir, seja  $\mathbf{G}$  uma matriz de probabilidades de transição de dimensão  $K \times K$  tal que  $G(i, j) \geq 0$  para qualquer  $i, j = 1, 2, \dots, K$  e

$$\sum_{i=1}^K G(i, j) = 1 \quad \forall j = 1, \dots, K.$$

Assumindo que um alvo só passa de um estado “alvo presente” para o estado “alvo ausente” quando ele sai completamente da imagem, modela-se a probabilidade de uma mudança no aspecto do alvo entre os quadros  $n-1$  e  $n$ , do estado  $j$  para o estado  $i$ ,  $Pr(\{z_n = i\} | \{z_{n-1} = j\}, \mathbf{s}_{n-1})$ , por

$$\begin{cases} G(i, j) Pr(\{\mathbf{s}_n^* \in \hat{\mathcal{L}}\} | \mathbf{s}_{n-1}, \{z_{n-1} = j\}) & i, j = 1, \dots, K \\ 1 - Pr(\{\mathbf{s}_n^* \in \hat{\mathcal{L}}\} | \mathbf{s}_{n-1}, \{z_{n-1} = j\}) & i = 0; j \neq 0 \\ \frac{p_a}{K} & i \neq 0; j = 0 \\ 1 - p_a & i = 0; j = 0 \end{cases} \quad (1)$$

onde o vetor bidimensional  $\mathbf{s}^*$  representa a posição quantizada do alvo na grade da imagem e é obtida do vetor quadrimensional contínuo  $\mathbf{s}_n$  fazendo-se

$$\mathbf{s}_n^*(1) = \text{round}\left(\frac{\mathbf{s}_{n,1}(1)}{\xi_1}\right) \quad (2)$$

$$\mathbf{s}_n^*(2) = \text{round}\left(\frac{\mathbf{s}_{n,2}(1)}{\xi_2}\right) \quad (3)$$

onde  $\xi_1$  e  $\xi_2$  são as resoluções espaciais da imagem respectivamente nas coordenadas  $x$  e  $y$ . O parâmetro  $p_a$  em

(1) denota, por sua vez, a probabilidade de um novo alvo entrar na imagem uma vez que o alvo anterior se tornou ausente (por simplicidade, assume-se que existe no máximo apenas um único alvo presente na imagem em cada quadro). A especificação  $Pr(\{z_n = i\} | \{z_{n-1} = 0\}, \mathbf{s}_{n-1}) = p_a/K$ ,  $i = 1, \dots, K$ , corresponde a assumir o pior cenário em que, dado que um novo alvo apareceu na imagem no instante  $n$ , há uma probabilidade uniforme de esse alvo apresentar qualquer um dos  $K$  possíveis aspectos. O termo  $1 - Pr(\{s_n^* \in \hat{\mathcal{L}}\} | \mathbf{s}_{n-1}, \{z_{n-1} = j\})$  é por outro lado a probabilidade de o alvo deixar a imagem no quadro  $n$  dados o seu aspecto e estado cinemático no quadro  $n - 1$ .

**Modelo de Movimento** Por simplicidade, assume-se ainda que, excetuando-se o caso em que há uma transição do estado “alvo ausente” para um estado “alvo presente”, a fdp do estado cinemático  $\mathbf{s}_n$  no quadro  $n$  condicionada ao estado cinemático  $\mathbf{s}_{n-1}$  é independente dos aspectos presente e passado, respectivamente,  $z_n$  e  $z_{n-1}$ . Em outras palavras, excetuando-se o caso em que  $z_{n-1} = 0$  e  $z_n \neq 0$ , tem-se

$$p(\mathbf{s}_n | z_n, \mathbf{s}_{n-1}, z_{n-1}) = f_s(\mathbf{s}_n | \mathbf{s}_{n-1}) \quad (4)$$

onde  $f_s(\mathbf{s}_n | \mathbf{s}_{n-1})$  é uma fdp arbitrária (não necessariamente gaussiana) que modela o movimento do alvo na imagem. Do contrário, para  $z_{n-1} = 0$  e  $z_n \neq 0$ , reinicializa-se a posição do alvo, fazendo

$$p(\mathbf{s}_n | z_n, \mathbf{s}_{n-1}, z_{n-1}) = f_0(\mathbf{s}_n) \quad (5)$$

onde  $f_0(\mathbf{s}_n)$  é, por exemplo, uma fdp uniforme definida em uma certa região da imagem. Com a hipótese de independência em (4), tem-se, para  $j = 1, \dots, K$ , que

$$Pr(\{s_n^* \in \hat{\mathcal{L}}\} | \mathbf{s}_{n-1}, \{z_{n-1} = j\}) = \int_{\{\mathbf{s}_n | s_n^* \in \hat{\mathcal{L}}\}} f_s(\mathbf{s}_n | \mathbf{s}_{n-1}) d\mathbf{s}_n. \quad (6)$$

### B. Modelo das Observações e Função de Verossimilhança

O  $n$ -ésimo quadro da seqüência de imagens é representado pela matriz  $L \times M$

$$\mathbf{Y}_n = \mathbf{H}(\mathbf{s}_n^*, z_n) + \mathbf{V}_n \quad (7)$$

onde a matriz  $\mathbf{V}_n$  representa o clutter (aditivo) de fundo, e a matriz  $\mathbf{H}(\mathbf{s}_n^*, z_n)$ , ver [5], mapeia a posição quantizada do centróide do alvo,  $\mathbf{s}_n^*$ , ver equações (2) e (3), em uma distribuição espacial de pixels centrada em  $\mathbf{s}_n^*$  e caracterizada por uma assinatura espacial  $\{a_{k,l}(z_n)\}$ ,  $-r_i \leq k \leq r_s$ ,  $-l_i \leq l \leq l_s$ , que varia com o aspecto  $z_n$  do alvo. Para descrever a correlação espacial do clutter de fundo, assume-se que, após um pré-processamento (que consiste em segmentar a imagem e subtrair a intensidade média local em cada segmento), o campo aleatório  $V_n(r, j)$ ,  $1 \leq r \leq L$ ,  $1 \leq j \leq M$ , é modelado como um processo Gauss-Markov bidimensional, não-causal e de primeira ordem, descrito pela equação de diferenças [6]

$$V_n(r, j) = \beta_{v,n}^c [V_n(r-1, j) + V_n(r+1, j)] + \beta_{h,n}^c [V_n(r, j-1) + V_n(r, j+1)] + \varepsilon_n(r, j) \quad (8)$$

onde  $E[V_n(r, j)\varepsilon_n(k, l)] = \sigma_{c,n}^2 \delta_{r-k, j-l}$ , com  $\delta(i, j) = 1$  se  $i = j$  e igual a zero caso contrário.

**Função de Verossimilhança** Sejam  $\mathbf{y}_n$ ,  $\mathbf{h}(\mathbf{s}_n^*, z_n)$  e  $\mathbf{v}_n$  as representações unidimensionais equivalentes respectivamente de  $\mathbf{Y}_n$ ,  $\mathbf{H}(\mathbf{s}_n^*, z_n)$  e  $\mathbf{V}_n$  em (7), obtidas lendo-se as entradas das matrizes linha-a-linha e armazenando-se seqüencialmente as linhas lidas em um vetor longo. Denote ainda por  $\Sigma_v = E[\mathbf{v}_n \mathbf{v}_n^T]$  a matriz de covariância associada ao vetor  $\mathbf{v}_n$  (assumido como de média nula após pré-processamento apropriado). Para um modelo de campo Gauss-Markov como em (8), a função de verossimilhança correspondente para um estado de aspecto fixo *diferente de zero*  $z_n = \tilde{z}$ ,  $\tilde{z} \in \{1, 2, 3, \dots, K\}$  é dada por [5]

$$p(\mathbf{y}_n | \mathbf{s}_n, \tilde{z}) = p(\mathbf{y}_n | \mathbf{s}_n, 0) \exp \left[ \frac{2\lambda(\mathbf{s}_n, \tilde{z}) - \rho(\tilde{z})}{2\sigma_{c,n}^2} \right]. \quad (9)$$

onde, explorando-se a estrutura de  $\Sigma_v^{-1}$ , pode-se mostrar que o termo  $\lambda(\mathbf{s}_n, \tilde{z}) = \mathbf{y}_n^T (\sigma_{c,n}^2 \Sigma_v^{-1}) \mathbf{h}(\mathbf{s}_n^*, \tilde{z})$  é calculado pela expressão

$$\lambda(\mathbf{s}_n, \tilde{z}) = \sum_{k=-r_i}^{r_s} \sum_{l=-l_i}^{l_s} a_{k,l}(\tilde{z}) d(s_n^*(1) + k, s_n^*(2) + l) \quad (10)$$

onde  $s_n^*(i)$ ,  $i = 1, 2$ , são obtidos das equações (2) e (3), e  $d(r, j)$  é a saída do filtro diferencial

$$d(r, j) = Y_n(r, j) - \beta_{h,n}^c [Y_n(r, j-1) + Y_n(r, j+1)] - \beta_{v,n}^c [Y_n(r-1, j) + Y_n(r+1, j)] \quad (11)$$

com condições de contorno nula. O chamado “termo de energia”  $\rho(\tilde{z}) = \mathbf{h}^T(\mathbf{s}_n^*, \tilde{z})(\sigma_{c,n}^2 \Sigma_v^{-1})\mathbf{h}(\mathbf{s}_n^*, \tilde{z})$  pode ser também calculado eficientemente explorando-se as propriedades de  $\Sigma_v^{-1}$ . Finalmente, o termo  $p(\mathbf{y}_n | \mathbf{s}_n, 0)$  em (9) é a verossimilhança do estado “alvo ausente” que se reduz a

$$p(\mathbf{y}_n | \mathbf{s}_n, 0) = \frac{1}{(2\pi)^{\frac{LM}{2}} [\det(\Sigma_v)]^{1/2}} \exp(-\frac{1}{2} \mathbf{y}_n^T \Sigma_v^{-1} \mathbf{y}_n)$$

para qualquer  $\mathbf{s}_n \in \mathbb{R}^4$ .

**Nota:** A equação (10) é válida para  $r_i + 1 \leq s_n^*(1) \leq L - r_s$  e  $l_i + 1 \leq s_n^*(2) \leq M - l_s$ . Para posições do alvo próximas às bordas da imagem, os limites da soma em (10) devem ser alterados de acordo com a tabela em [3].

## III. FILTRO DE PARTÍCULAS PARA DETECÇÃO/RASTREAMENTO INTEGRADOS

### A. Amostragem por Importância Seqüencial

Dada uma seqüência de quadros observados  $\{\mathbf{y}_1, \dots, \mathbf{y}_n\}$ , e dada uma função mensurável arbitrária  $\mathbf{g}(\mathbf{s}_{0:n}, z_{0:n})$ , nosso objetivo é construir a cada instante  $n$  um conjunto apropriadamente ponderado de trajetórias amostradas  $\{\mathbf{s}_{0:n}^{(j)}, z_{0:n}^{(j)}\}$ ,  $1 \leq j \leq N_p$ , com pesos associados  $\{w_n^{(j)}\}$  tal que, segundo algum critério estatístico (por exemplo, convergência quase certa), à medida que  $N_p$  tende a infinito,

$$\sum_{j=1}^{N_p} w_n^{(j)} \mathbf{g}(\mathbf{s}_{0:n}^{(j)}, z_{0:n}^{(j)}) \rightarrow E\{\mathbf{g}(\mathbf{s}_{0:n}, z_{0:n}) | \mathbf{y}_{1:n}\} \quad (12)$$

onde  $E\{\cdot\}$  denota esperança matemática. Em particular, se  $\mathbf{g}(\mathbf{s}_{0:n}, z_{0:n}) = [\mathbf{s}_n^T z_n]^T$ , então a esperança no lado direito

de (12) corresponde precisamente à estimativa MMSE dos estados ocultos no instante  $n$  dadas as observações. Se fosse possível gerar amostras independentes  $z_{0:n}^{(j)} \sim P(z_{0:n} | \mathbf{y}_{1:n})$  e  $\mathbf{s}_{0:n}^{(j)} \sim p(\mathbf{s}_{0:n} | z_{0:n}^{(j)}, \mathbf{y}_{1:n})$ , então, fazendo-se  $w_n^{(j)} = 1/N_p, \forall j$ , a convergência com probabilidade um (“almost sure”) em (12) seria garantida trivialmente pela lei forte dos grandes números. Entretanto, a amostragem direta descrita anteriormente não é em geral possível em sistemas dinâmicos não-lineares e/ou não-gaussianos. Uma abordagem alternativa denominada *amostragem por importância* [8] consiste então em gerar as amostras a partir de uma distribuição de probabilidade arbitrária conhecida, por exemplo, a distribuição induzida por  $p(\mathbf{s}_{0:n} | z_{0:n})P(z_{0:n})$ , e ajustar apropriadamente os pesos  $w_n^{(j)}$  de forma a garantir a convergência para a estimativa ótima desejada. Em um contexto de filtragem “on-line”, a geração de partículas e a correspondente atualização dos pesos podem ser feitas sequencialmente, ver [10], usando o algoritmo recursivo descrito a seguir:

1) Inicialização Para  $j = 1, \dots, N_p$

- Amostre  $\mathbf{s}_0^{(j)} \sim p(\mathbf{s}_0)$ , e  $z_0^{(j)} \sim P(z_0)$ .
- Faça  $w_0^{(j)} = 1/N_p$  e  $n = 1$ .

2) Amostragem por Importância Para  $j = 1, \dots, N_p$

- Amostre  $z_n^{(j)} \sim P(z_n | z_{n-1}^{(j)}, \mathbf{s}_{n-1}^{(j)})$  de acordo com (1).
- Amostre  $\mathbf{s}_n^{(j)} \sim p(\mathbf{s}_n | z_n^{(j)}, \mathbf{s}_{n-1}^{(j)}, z_{n-1}^{(j)})$  de acordo com (4) ou (5).
- Calcule os pesos de importância

$$w_n^{(j)} \propto w_{n-1}^{(j)} p(\mathbf{y}_n | \mathbf{s}_n^{(j)}, z_n^{(j)}) \quad (13)$$

usando a função de verossimilhança na Seção II-B.

Fim-laço

- Normalize os pesos  $\{w_n^{(j)}\}$  de modo que  $\sum_{j=1}^{N_p} w_n^{(j)} = 1$ .
- Faça  $n = n + 1$  e retorne ao passo 2.

Observação: Usando-se a função de importância  $p(\mathbf{s}_{0:n} | z_{0:n})P(z_{0:n})$ , pode-se mostrar, ver [11], que os pesos apropriados correspondentes são dados por

$$w_n^{(j)} \propto \frac{p(\mathbf{s}_{0:n}^{(j)} | z_{0:n}^{(j)}, \mathbf{y}_{1:n})P(z_{0:n}^{(j)} | \mathbf{y}_{1:n})}{p(\mathbf{s}_{0:n}^{(j)} | z_{0:n}^{(j)})P(z_{0:n}^{(j)})}, \quad (14)$$

onde  $\sum_j w_n^{(j)} = 1$  e o símbolo  $\propto$  denota “proporcional a”. Usando a seguir a lei de Bayes e as propriedades usuais de independência condicional de processos de Markov de primeira ordem, pode-se mostrar, após uma certa manipulação algébrica, que a expressão (14) pode ser calculada recursivamente usando a fórmula (13). A dedução completa do algoritmo é omitida nesse artigo por limitação de espaço.

### B. Filtro de Partículas Auxiliares

O algoritmo de amostragem por importância sequencial (SIS) descrito na Seção III-A converge assintoticamente com probabilidade um, ver [15], quando o número de partículas tende a infinito. Entretanto, devido ao fenômeno de degeneração de partículas [4], [8] causado pelo aumento ao longo do tempo na variância dos pesos  $w_n^{(j)}$ , o algoritmo SIS é ineficiente, requerendo o uso de um número muito

alto de partículas para se atingir um desempenho satisfatório. Uma possível alternativa para melhorar a eficiência do algoritmo é usar um filtro de partículas auxiliares (APF) [12]. Basicamente, o algoritmo APF utiliza a observação atual  $\mathbf{y}_n$  para pré-selecionar um subconjunto de amostras no instante  $n - 1$  que, quando propagadas para o instante  $n$ , terão maior probabilidade de gerar partículas com alta verossimilhança, reduzindo assim o fenômeno de degeneração. Formalmente, isso pode ser feito através do algoritmo abaixo (a etapa de inicialização foi omitida por ser idêntica ao caso anterior):

1) Pré-Amostragem Para  $j = 1, \dots, N_p$

- Amostre  $\hat{z}_n^{(j)} \sim P(z_n | z_{n-1}^{(j)}, \mathbf{s}_{n-1}^{(j)})$  de acordo com (1).
- Amostre  $\hat{\mathbf{s}}_n^{(j)} \sim p(\mathbf{s}_n | \hat{z}_n^{(j)}, \mathbf{s}_{n-1}^{(j)}, z_{n-1}^{(j)})$  de acordo com (4) ou (5).
- Calcule

$$\lambda_n^{(j)} \propto p(\mathbf{y}_n | \hat{\mathbf{s}}_n^{(j)}, \hat{z}_n^{(j)}), \quad \sum_{j=1}^{N_p} \lambda_n^{(j)} = 1$$

usando o modelo de função de verossimilhança na Seção II-B. Fim-laço.

2) Amostragem com Partículas Auxiliares Para  $j = 1, \dots, N_p$

- Amostre  $i^{(j)} \sim \{1, \dots, N_p\}$  com  $Pr(\{i^{(j)} = l\}) = \lambda_n^{(l)}$ .
- Amostre  $z_n^{(j)} \sim P(z_n | z_{n-1}^{(i^{(j)})}, \mathbf{s}_{n-1}^{(i^{(j)})})$  de acordo com (1).
- Amostre  $\mathbf{s}_n^{(j)} \sim p(\mathbf{s}_n | z_n^{(j)}, \mathbf{s}_{n-1}^{(i^{(j)})}, z_{n-1}^{(i^{(j)})})$  de acordo com (4) ou (5).
- Calcule os pesos de importância

$$w_n^{(j)} \propto w_{n-1}^{(i^{(j)})} \frac{p(\mathbf{y}_n | \mathbf{s}_n^{(j)}, z_n^{(j)})}{p(\mathbf{y}_n | \hat{\mathbf{s}}_n^{(i^{(j)})}, \hat{z}_n^{(i^{(j)})})}. \quad (15)$$

Fim-Laço

- Normalize os pesos  $\{w_n^{(j)}\}$  de modo que  $\sum_{j=1}^{N_p} w_n^{(j)} = 1$ .
- Faça  $n = n + 1$  e retorne ao passo 1.

Observação: O algoritmo APF é formalmente equivalente a se introduzir a cada instante  $n$  um índice auxiliar  $i$  que assume valores no intervalo  $\{1, \dots, N_p\}$  e gerar sequencialmente amostras da função de importância *mista*

$$q(i, \mathbf{s}_n, z_n | \mathbf{y}_{1:n}) \propto p(\mathbf{y}_n | \hat{\mathbf{s}}_n^{(i)}, \hat{z}_n^{(i)}) p(\mathbf{s}_n, z_n | \mathbf{s}_{n-1}^{(i)}, z_{n-1}^{(i)}) \quad (16)$$

onde  $\hat{z}_n^{(i)}$  e  $\hat{\mathbf{s}}_n^{(i)}$  são grandezas representativas (nesse artigo, amostras), respectivamente de  $P(z_n | z_{n-1}, \mathbf{s}_{n-1})$  e  $p(\mathbf{s}_n | z_n, \mathbf{s}_{n-1}, z_{n-1})$ . Para que o conjunto de partículas geradas a partir da função de importância mista em (16) permaneça apropriadamente ponderado, é preciso então modificar a regra de atualização de pesos de acordo com a expressão (15), ver [4], [12]. A dedução formal é novamente omitida por limitações de espaço.

### C. Detecção e Rastreamento Multiquadros

Denote por  $H_1$  a hipótese de que o alvo está presente no quadro  $n$  e, por  $H_0$ , a hipótese de que o alvo está ausente. Dado o conjunto apropriadamente ponderado de partículas  $(\mathbf{s}_n^{(j)}, z_n^{(j)})$  no instante  $n$ , gerado de acordo com os algoritmos nas seções III-A ou III-B, calcula-se então a estimativa Monte

Carlo  $\widehat{Pr}(\{z_n = 0\} | \mathbf{y}_{1:n})$  da probabilidade a posteriori de ausência de alvo  $Pr(\{z_n = 0\} | \mathbf{y}_{1:n})$ . A seguir, aplica-se o teste de detecção de mínima probabilidade de erro [16]

$$\widehat{Pr}(\{z_n = 0\} | \mathbf{y}_{1:n}) \underset{H_1}{\overset{H_0}{>}} 1 - \widehat{Pr}(\{z_n = 0\} | \mathbf{y}_{1:n}) \quad (17)$$

para decidir se o alvo está ou não presente no quadro  $n$ . Se a hipótese  $H_1$  for aceita, a estimativa  $\hat{s}_{n|n}$  do estado cinemático do alvo no quadro  $n$  é calculada então pela aproximação Monte Carlo de  $E[\mathbf{s}_n | \mathbf{y}_{1:n}, \{z_n \neq 0\}]$ .

#### IV. RESULTADOS

A seguir, estuda-se o desempenho do filtro APF proposto na Seção III-B usando imagens simuladas a partir de dados reais gerados por um radar infravermelho aerotransportado (IRAR). Os resultados obtidos para o filtro APF são comparados ao desempenho do filtro de partículas “resample-move” alternativo introduzido em [13]. O filtro “resample-move” utiliza a configuração SIS básica da Seção III-A, seguida de um estágio de reamostragem com substituição de acordo com os pesos e de um passo adicional de movimento Metropolis-Hastings [17] usado para rejuvenescer a população de partículas (para maiores detalhes, consulte [13]).

As imagens IRAR brutas usadas nas simulações provêm da base de dados do MIT Lincoln Laboratory e foram obtidas através do Center for Imaging Sciences na Johns Hopkins University. Para simular o alvo, tomou-se um padrão artificial representando um veículo militar e gerou-se uma biblioteca de transformações afins desse padrão de referência usando operações compostas de rotação, escalonamento e cisalhamento. Adicionou-se então o alvo artificial à seqüência de fundo com a posição do centróide mudando de quadro a quadro segundo um modelo linear com aceleração ruído branco [1] da forma  $\mathbf{s}_{n+1,i} = \mathbf{F}\mathbf{s}_{n,i} + \mathbf{u}_{n,i}$ ,  $i = 1, 2$  com

$$\mathbf{s}_{n,1} = [x_n \dot{x}_n]^T, \quad \mathbf{s}_{n,2} = [y_n \dot{y}_n]^T, \quad \mathbf{F} = \begin{bmatrix} 1 & \Delta \\ 0 & 1 \end{bmatrix}$$

onde  $\Delta$  é assumido igual a 0,04 e  $\{\mathbf{u}_{n,i}\}$ ,  $i = 1, 2$  são seqüências de vetores aleatórios gaussianos tais que  $E[\mathbf{u}_{n,1}] = E[\mathbf{u}_{n,2}] = \mathbf{0}$ , e

$$E[\mathbf{u}_{n,i} \mathbf{u}_{l,j}^T] = q \underbrace{\begin{bmatrix} \frac{\Delta^3}{3} & \frac{\Delta^2}{2} \\ \frac{\Delta^2}{2} & \Delta \end{bmatrix}}_{\mathbf{Q}} \delta_{n-l, i-j}.$$

O parâmetro  $q$  na equação acima é assumido igual a 6. As imagens de fundo do alvo foram geradas adicionando-se uma seqüência sintética de campos Gauss-Markov a uma matriz de médias locais extraídas da imagem IRAR real. Os parâmetros dos campos Gauss-Markov sintéticos foram estimados a partir da imagem real usando um algoritmo de estimação por máxima verossimilhança aproximado (AML), ver [5], [18] para detalhes.

Para simular as variações de aspecto do alvo, inicializou-se  $z_0$  com um valor escolhido ao acaso na biblioteca de modelos do alvo e modificou-se subsequentemente o aspecto de quadro a quadro usando uma cadeia de Markov de primeira

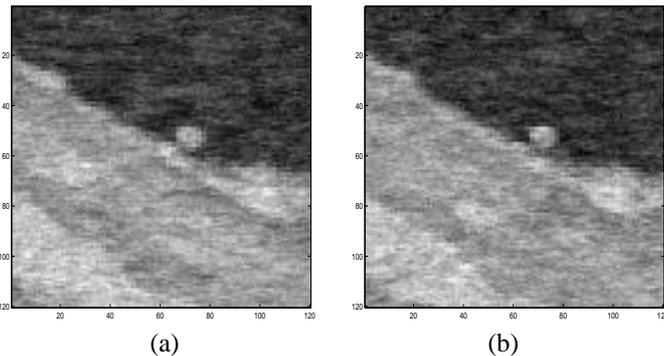


Fig. 1. (a) Primeiro quadro de uma seqüência simulada, PTCR = 10,6 dB, (b) Décimo quadro da mesma seqüência.

ordem conhecida. A intensidade do alvo simulada também é conhecida e foi escolhida de modo a atingir um baixo nível de contraste entre o alvo e o fundo. Como ilustração, a Figura 1(a) mostra o quadro inicial de uma seqüência simulada com o alvo centrado nas coordenadas (quantizadas) (65, 23) e relação alvo-clutter de pico (PTCR =  $20 \log(\max a_{k,l} / \sigma_{c,n})$ ) igual a 10,6 dB. A Figura 1(b) mostra o décimo quadro dessa mesma seqüência. Note que, em comparação com o quadro 1, o alvo sofreu uma translação aleatória, além de uma mudança aleatória de aspecto.

No estudo de desempenho do detector/rastreador, deseja-se avaliar a capacidade do algoritmo de: (1) adquirir um alvo e rastrear-lo tanto no centro quanto próximo às bordas da imagem onde partes do alvo não são mais visíveis; (2) detectar quando um alvo deixou completamente a cena não indicando nenhuma falsa detecção naqueles quadros em que o alvo está ausente; e, finalmente, 3) detectar quando um novo alvo entra na cena, adquiri-lo e segui-lo com sucesso. Um filme de vídeo com 50 quadros simulados demonstrando a capacidade do algoritmo de cumprir as três tarefas enunciadas acima está disponível para visualização na página <http://www.ele.ita.br/~bruno>. Nesse artigo, por limitação de espaço, mostra-se apenas um estudo estatístico do desempenho de rastreamento para um alvo ao longo de 20 quadros sucessivos. O alvo simulado foi detectado (declarado presente) em cada quadro e seguido pelo filtro APF da Seção III-B usando  $N_p = 5000$  partículas e 4 possíveis estado de aspecto. Em cada quadro, os parâmetros do modelo Gauss-Markov do clutter de fundo são estimados adaptativamente usando o algoritmo de máxima verossimilhança aproximada (AML) em [18]. Como ilustração, as estimativas de posição para os alvos observados nas Figuras 1(a) e (b) são mostrados respectivamente nas Figuras 2(a) e (b).

Para se obter uma avaliação estatisticamente significativa do erro de rastreamento, repetiu-se a simulação 100 vezes com realizações independentes do movimento/aspecto do alvo e do clutter de fundo em cada experimento. Em um cenário de PTCTR igual a 6,5 dB (portanto, com um alvo bem mais obscurecido do que na Figura 1), o filtro APF divergiu (ou seja, foi incapaz de seguir o alvo) em três das 100 realizações. Com PTCTR igual a 8,1 dB, o número de “tracks” divergentes caiu para dois em 100. Nas Figuras 3(a) e (b), para o caso em que PTCTR = 6,5 dB mostram-se as curvas de erro RMS (“root

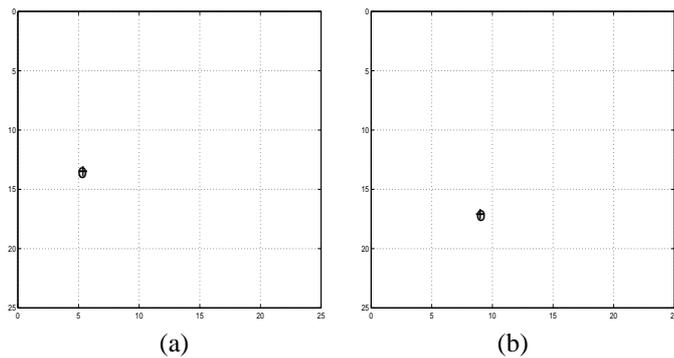
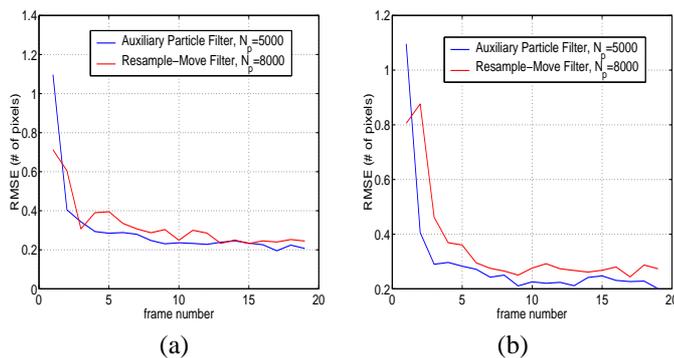


Fig. 2. Estimativas da posição dos alvos observados na Figura 1.

Fig. 3. Erro RMS para a estimativa de posição respectivamente para os filtros APF (taxa de divergência 3 %) e "resample-move" (taxa de divergência 5 %), PTCR= 6,5 dB: (a)  $x$  coordinate, (b)  $y$  coordinate

mean-square error") em número de pixels para as estimativas de posição do alvo geradas pelo filtro APF, respectivamente nas coordenadas  $x$  e  $y$ . As curvas na Figura 3 foram calculadas a partir do erro medido nas 100 realizações *excluindo-se* as realizações divergentes. Para efeito de comparação, mostramos também nas Figuras 3(a) e (b) as correspondentes curvas de erro RMS para o filtro alternativo "resample-move" introduzido em [13], operando, porém, com  $N_p = 8000$  partículas. Nota-se a partir das curvas na Figura 3 que, apesar da diminuição no número de partículas utilizadas de 8000 para 5000, o filtro APF tem desempenho de rastreamento estatisticamente comparável àquele do filtro "resample-move" com um erro maior nos primeiros quadros e declinante à medida que o alvo é adquirido e novas imagens são processadas. Além disso, o filtro "resample-move" de 8000 partículas mostrou uma taxa de divergência ligeiramente superior à do filtro APF de 5000 partículas, tendo divergido em cinco das 100 realizações no caso em que PTCR= 6,5 dB e, em três das 100 realizações no caso em que PTCR = 8,1 dB. Os resultados das nossas simulações sugerem então que a configuração APF é preferível à configuração "resample-move" em cenários com alvos fortemente obscurecidos, apresentando desempenho equivalente ou ligeiramente superior com menor esforço computacional (i.e., menor número de partículas).

## V. CONCLUSÕES

Apresentou-se nesse artigo um novo algoritmo baseado em filtros de partículas para detecção e rastreamento conjuntos de

alvos móveis com aspecto variável em seqüências de imagens geradas por sensores aerotransportados. Ao contrário dos métodos previamente encontrados na literatura, o algoritmo proposto possibilita detecção e rastreamento conjuntos, utilizando múltiplos quadros e incorporando plenamente os modelos estatísticos para movimento do objeto, aspecto do alvo, e correlação espacial do clutter de fundo. Duas configurações para a implementação do detector/rastreador foram investigadas usando respectivamente um filtro de partículas auxiliar (APF) e um filtro de partícula "resample-move". Os resultados das nossas simulações sugerem que a configuração APF tem desempenho ligeiramente superior à configuração "resample-move" em cenários com alvos fortemente obscurecidos, atingindo, com um número menor de partículas, um menor erro RMS em regime para as estimativas da posição do alvo e uma menor porcentagem de realizações divergentes.

## REFERÊNCIAS

- [1] Y. Bar-Shalom e X. Li, *Multitarget-Multisensor Tracking: Principles and Techniques*. YBS, Storrs, CT, 1995.
- [2] E. Oron, A. K. Kumar, e Y. Bar-Shalom, "Precision tracking with segmentation for imaging sensors," *IEEE Trans. on Aerospace and Electronic Systems*, vol.29, pp. 977-987, julho de 1993.
- [3] M. G. S. Bruno e J. M. F. Moura, "Multiframe detection/tracking in clutter: optimal performance," *IEEE Trans. on Aerospace and Electronic Systems*, vol.37, n.3, pp. 925-946, julho de 2001.
- [4] M. S. Arulampalam, S. Maskell, N. Gordon e T. Clapp, "A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking," *IEEE Trans. on Signal Processing*, vol.50, n.2, pp. 174-188, fevereiro de 2002.
- [5] M. G. S. Bruno, "Bayesian methods for multiaspect target tracking in image sequences," *IEEE Trans. on Signal Processing*, vol. 52, n.7, pp. 1848-1861, julho de 2004.
- [6] J. M. F. Moura e N. Balram, "Recursive Structure of Noncausal Gauss Markov Random Fields," *IEEE Trans. on Inf. Theory* IT-38(2), pp. 334-354, março de 1992.
- [7] J. M. F. Moura e M. G. S. Bruno, "DCT/DST and Gauss-Markov fields: conditions for equivalence," *IEEE Trans. on Signal Processing*, vol.46, n.9, pp 2571-2574, setembro de 1998.
- [8] A. Doucet, J. F. G. Freitas, e N. J. Gordon, "An introduction to sequential Monte Carlo methods," in *Sequential Monte Carlo Methods in Practice*, A. Doucet, J. F. G. Freitas, and N. J. Gordon, Editors. New York: Springer-Verlag, 2001.
- [9] M. Isard e A. Blake, "Condensation - conditional density propagation for visual tracking," *International Journal of Computer Vision*, vol.28, n.1, pp. 5-28, 1998.
- [10] M. Isard e A. Blake, "A mixed-state condensation tracker with automatic model switching," *Proceedings of the 6th International Conference on Computer Vision*, pp. 107-112, 1998.
- [11] A. Doucet, S. J. Godsill, e C. Andrieu, "On sequential Monte Carlo sampling methods for Bayesian filtering," *Stat. Comput.*, vol.10, pp. 197-208, 2000.
- [12] M. K. Pitt e N. Shephard, "Filtering via simulation: Auxiliary particle filters," *Journal of the American Statistical Association*, 94(446), pp. 590-599, 1999.
- [13] M. G. S. Bruno, R. V. de Araújo e A. G. Pavlov, "Sequential Monte Carlo Filtering for Multi-Aspect Detection/Tracking", *Proceedings of the 2005 IEEE Aerospace Conference*, Big Sky MT, E.U.A., pp. 1-8, 5-13 de março de 2005.
- [14] W. R. Gilks e C. Berzuini, "Following a moving target - Monte Carlo inference for dynamic Bayesian models," *J. Royal Statist. Soc. B*, vol.63, pp. 127-146, 2001.
- [15] J. Geweke, "Bayesian inference in econometric models using Monte Carlo integration," *Econometrica*, 24, pp. 1317-1399, 1989.
- [16] L. Scharf, *Statistical Signal Processing: Detection, Estimation, and Time Series Analysis*, Addison-Wesley, 1992.
- [17] C. P. Robert e G. Casella, *Monte Carlo Statistical Methods*, Springer Texts in Statistics, Springer-Verlag New York, Inc., 1999.
- [18] J. M. F. Moura e N. Balram, "Noncausal Gauss-Markov random fields: parameter structure and estimation," *IEEE Trans. on Inf. Theory*, IT-39(4), pp. 1333-1355, julho de 1993.