

UM ALGORITMO BAYESIANO ÓTIMO PARA DETECÇÃO E RASTREAMENTO DE ALVOS MÓVEIS COM DEFORMAÇÃO ALEATÓRIA

Marcelo G. S. Bruno

PTC, Escola Politécnica,

Universidade de São Paulo

Caixa Postal 61548, São Paulo SP 05424-970, Brasil

tel:(55-11) 3818-5290; e-mail:bruno@lcs.poli.usp.br

RESUMO

Apresenta-se nesse artigo um algoritmo bayesiano ótimo para detecção e rastreamento integrados de objetos móveis com deformação ou rotação aleatória. Como observações, dispõe-se de uma seqüência de imagens digitais dos alvos de interesse corrompida por ruído e reflexões espúrias (*clutter*). O movimento translacional dos alvos nas imagens e a sua deformação ou rotação ao longo do tempo são descritos por cadeias ocultas de Markov (HMM). O algoritmo proposto incorpora ainda o modelo estatístico para a correlação espacial do clutter de fundo e realiza um processamento espacial-temporal recursivo ao longo de todos os quadros da seqüência de imagens.

1. INTRODUÇÃO

O problema de detecção e rastreamento automáticos de alvos móveis em clutter tem recebido atenção crescente recentemente, ver p.ex. [1, 2]. Entretanto, na maioria dos algoritmos encontrados na literatura, ver p.ex. [3], as tarefas de detecção e rastreamento são realizadas em dois estágios separados. As medidas disponíveis para o rastreador não são as imagens originais do sensor, mas sim a saída de um subsistema preliminar de detecção. O estágio detector processa normalmente um único quadro do sensor, gerando estimativas preliminares do estado dinâmico de alvos declarados presentes. Tais estimativas são tratadas como observações do estado real do alvo corrompidas por ruído. Um filtro rastreador linear, normalmente um filtro de Kalman-Bucy, combina então as estimativas preliminares com o modelo dinâmico a priori do alvo, refinando assim a estimativa do seu estado real.

Ao invés de desacoplar detecção e rastreamento como em [3], introduziu-se em [4, 5] um novo algoritmo bayesiano que integra de forma ótima as tarefas de detecção e estimação dinâmica da posição do alvo. Nosso detector/rastreador é um algoritmo espacial-temporal, não-linear, recursivo que incorpora os modelos de assinatura e movimento dos alvos,

bem como o modelo do clutter de fundo. O algoritmo original em [4] assumia, entretanto, que a assinatura do alvo era determinística e perfeitamente conhecida. Nesse artigo, generaliza-se o algoritmo de modo a incluir alvos com máscaras que variam aleatoriamente de quadro a quadro.

O artigo é dividido em seis seções. A primeira seção é essa introdução. Na seção 2, introduzem-se os modelos de alvo e clutter que são usados nas seções subsequentes. Na seção 3, deriva-se o detector/rastreador bayesiano. Detalhes adicionais sobre a estrutura do algoritmo são fornecidos na seção 4. A seção 5 discute o desempenho do algoritmo proposto através de simulações Monte Carlo com dados sintéticos. Finalmente, apresenta-se na seção 6 um resumo das principais contribuições desse artigo.

2. O MODELO

Um dispositivo sensor, p.ex. uma câmera infravermelha, gera uma seqüência de imagens bidimensionais (2D) de possíveis alvos de interesse obscurecida por clutter. Nosso objetivo é determinar a cada quadro se os alvos estão ou não presentes na cena e, se um alvo for declarado presente, estimar sua posição no espaço. Por simplicidade, assume-se um alvo único sendo seguido a cada quadro (para um tratamento matemático para rastreamento de múltiplos alvos, ver [5]).

Nesse artigo, considera-se a situação em que a forma ou orientação espacial do alvo variam no tempo devido a rotações ou deformações aleatórias da sua máscara. Assume-se um número finito de possíveis estados para a máscara. O estado da máscara evolui no tempo de acordo com uma cadeia oculta de Markov (HMM) de primeira ordem com probabilidades de transição conhecidas. O centróide do alvo possui por sua vez um movimento translacional aleatório descrito por um HMM bidimensional definida sobre a grade de resolução do sensor.

2.1. Modelos de Alvo e Sensor

Seja a região retangular de dimensões $(r_i + r_s + 1) \times (l_i + l_s + 1)$ que contém todas as possíveis máscaras do alvo de

interesse. Para modelar situações em que os alvos entram e saem da região de vigilância, define-se a *grade centróide* $\hat{\mathcal{L}} = \{(i, j): -r_s + 1 \leq i \leq L + r_i, -l_s + 1 \leq j \leq M + l_i\}$, onde L e M são o número de células de resolução em cada dimensão. A grade centróide coleciona todos os possíveis valores para a posição do centróide para os quais pelo menos um pixel do alvo encontra-se dentro da imagem do sensor.

Seja $\bar{\mathcal{L}}$ uma representação unidimensional equivalente da grade centróide $\hat{\mathcal{L}}$ obtida por ordenação lexicográfica linha a linha. Para integrar detecção e rastreamento, aumenta-se a grade $\bar{\mathcal{L}}$ com um estado adicional artificial que representa a ausência do alvo. Por conveniência, atribui-se ao estado adicional o índice $(L + r_i + r_s)(M + l_i + l_s) + 1$. A *grade estendida* unidimensional final é portanto

$$\tilde{\mathcal{L}} = \{l: 1 \leq l \leq (L + r_i + r_s)(M + l_i + l_s) + 1\}. \quad (1)$$

Modelo do Alvo Denote por $z_n \in \tilde{\mathcal{L}}$ a posição do centróide do alvo no n -ésimo quadro. Seja m o número de estados para a máscara do alvo e denote por $s_n \in \mathcal{I} = \{0, 1, \dots, m-1\}$ o estado da máscara no instante n . Define também $L_1 = (L + r_i + r_s)(M + l_i + l_s)$. Modelar-se a imagem livre de clutter de um alvo presente pela função não-linear

$$\mathbf{F}_1[z_n(i_n, j_n), s_n] = \sum_{k=-r_i}^{r_s} \sum_{l=-l_i}^{l_s} a_{k,l}(s_n) \mathbf{E}_{i_n+k, j_n+l}. \quad (2)$$

Em (2), para $1 \leq i \leq L$, $1 \leq j \leq M$, $\mathbf{E}_{i,j}$ é uma matriz $L \times M$ cujas entradas são iguais a zero, com exceção do elemento (i, j) que é igual a 1. Para qualquer $(i, j) \notin \mathcal{L}_1 \times \mathcal{L}_2$, onde $\mathcal{L}_1 = \{l: 1 \leq l \leq L\}$ e $\mathcal{L}_2 = \{l: 1 \leq l \leq M\}$, $\mathbf{E}_{i,j}$ é uma matriz identicamente nula. Finalmente, quando nenhum alvo está presente, o modelo do alvo retorna uma imagem nula, i.e. se $z_n = L_1 + 1$, então $\mathbf{F}_1(z_n, s_n) = \mathbf{0}_{L \times M}, \forall s_n \in \mathcal{I}$.

Os coeficientes $a_{k,l}$ in (2) são chamados *coeficientes de assinatura do alvo* e variam de acordo com a máscara correspondente ao estado s_n . Para um dado valor de s_n , os coeficientes de assinatura são o produto de um parâmetro binário $c_{k,l}(s_n) \in \mathcal{B} = \{0, 1\}$, que define a forma do alvo, e um coeficiente real $\phi_{k,l}(s_n) \in \mathcal{R}$, que especifica a intensidade dos pixels do alvo. Por simplicidade, assume-se nesse artigo que as intensidades dos pixels do alvo são determinísticas e conhecidas em cada quadro da seqüência de imagens. Para uma versão diferente do algoritmo com intensidades de alvo aleatórias e parâmetros de clutter desconhecidos, ver a referência [6].

2.2. Modelo de Observação e Clutter

Refletores espúrios e ruído ambiental no raio de visão do sensor corrompem as medidas com clutter. Em um cenário

com um único alvo de interesse, o modelo para o n -ésimo quadro do sensor é dado pela matriz $L \times M$

$$\mathbf{Y}_n = \mathbf{F}_1(z_n, s_n) + \mathbf{V}_n \quad (3)$$

onde z_n é a posição do alvo na grade estendida $\tilde{\mathcal{L}}$ (incluindo o estado ausente), s_n é o estado da máscara, $\mathbf{F}_1(\cdot)$ é o modelo 2D de alvo da equação (2), e \mathbf{V}_n é a matriz das intensidades do clutter de fundo.

Em geral, o clutter \mathbf{V}_n pode ser espacialmente correlacionado. Descreve-se a correlação espacial do clutter usando-se um modelo de campo aleatório Gauss-Markov (GMrf) [7, 8] homogêneo e não-causal. Os retornos relativos a clutter no quadro n , $V_n(i, j)$, $1 \leq i \leq L$, $1 \leq j \leq M$, são modelados como a saída da equação de diferenças

$$V_n(i, j) = \beta_v^c [V_n(i-1, j) + V_n(i+1, j)] + \beta_h^c [V_n(i, j-1) + V_n(i, j+1)] + U_n(i, j) \quad (4)$$

onde $E[V_n(i, j)U_n(p, r)] = \sigma_c^2 \delta(i-p, j-r)$. A suposição de clutter com média nula reflete um pré-processamento dos dados que subtrai as médias locais do fundo. Admite-se também que a seqüência de matrizes de intensidade de clutter, $\{\mathbf{V}_n\}$, $n \geq 0$, é *independente, identicamente distribuída* (i.i.d). Usam-se condições de contorno de Dirichlet para especificar a equação (4) nas proximidades das bordas da grade do sensor. Assume-se ainda que $L \gg r_i + r_s$ e $M \gg l_i + l_s$.

2.3. Modelos para o Movimento e Máscara dos Alvos

A probabilidade de deslocamento do centróide do alvo entre dois quadros sucessivos é descrita pela matriz \mathbf{T}_1 tal que

$$T_1(k, r) = \text{Prob}(z_n = k \mid z_{n-1} = r) \quad (k, r) \in \tilde{\mathcal{L}} \times \tilde{\mathcal{L}}. \quad (5)$$

Por outro lado, as mudanças no estado da máscara do sensor ao longo do tempo são especificadas pela matriz \mathbf{T}_2 , onde

$$T_2(k, r) = \text{Prob}(s_n = k \mid s_{n-1} = r) \quad (k, r) \in \mathcal{I} \times \mathcal{I}. \quad (6)$$

3. O ALGORITMO

Defina o operador *vec* que converte uma matriz $P \times Q$ no vetor longo $PQ \times 1$ empilhando seqüencialmente as linhas da matriz e, seja $\mathbf{y}_n = \text{vec}(\mathbf{Y}_n)$, onde \mathbf{Y}_n , com dimensão $L \times M$, é a imagem observada do sensor no quadro n . O detector/rastreador bayesiano ótimo requer a computação recursiva a cada quadro n da função massa de probabilidade (fmp) a posteriori, $P(z_n \mid \mathbf{Y}_0^n)$, do estado desconhecido z_n condicionada a todos os quadros presente e passados.

3.1. Recursão Bayesiana

Deriva-se primeiro um algoritmo para a computação recursiva de $P(z_n = l, s_n = k | \mathbf{Y}_0^n)$, $l \in \tilde{\mathcal{L}}, k \in \mathcal{I}$. Assume-se como primeira aproximação que as seqüências aleatórias $\{z_n\}$ e $\{s_n\}$, $n \geq 0$, são estatisticamente independentes, e que ambas as seqüências são também independentes da seqüência de matrizes de clutter, $\{\mathbf{V}_n\}$, $n \geq 0$. O algoritmo divide-se em três passos.

Passo de Filtragem Pela lei de Bayes e usando-se a suposição de que a seqüência $\{\mathbf{V}_n\}$ é i.i.d., escreve-se

$$P(z_n, s_n | \mathbf{Y}_0^n) = C_n p(\mathbf{y}_n | z_n, s_n) P(z_n, s_n | \mathbf{Y}_0^{n-1}) \quad (7)$$

onde C_n é um fator de normalização que não depende de z_n e s_n .

Predição do Estado da Máscara Pela hipótese de que s_n é independente de $\{z_n\}$, e $\{\mathbf{V}_n\}$, $n \geq 0$, e modelando-se $\{s_n\}$ como uma cadeia de Markov oculta de primeira ordem, conclui-se que, condicionado a s_{n-1} , o estado s_n é independente de \mathbf{Y}_0^{n-1} e, portanto, pode-se escrever

$$P(z_n, s_n | \mathbf{Y}_0^{n-1}) = \sum_{s_{n-1}} [P(s_n | s_{n-1}) \times P(z_n, s_{n-1} | \mathbf{Y}_0^{n-1})] . \quad (8)$$

Predição da Translação Usando-se um argumento análogo ao usado no passo anterior, obtém-se

$$P(z_n, s_{n-1} | \mathbf{Y}_0^{n-1}) = \sum_{z_{n-1}} [P(z_n | z_{n-1}) \times P(z_{n-1}, s_{n-1} | \mathbf{Y}_0^{n-1})] . \quad (9)$$

Se houver medidas disponíveis no instante 0, a recursão é inicializada com um passo de filtragem adicional onde se faz

$$P(z_0, s_0 | \mathbf{Y}_0^{-1}) = P(z_0) P(s_0) . \quad (10)$$

As massas de probabilidade *marginais* a posteriori das posições do centróide z_n condicionadas nas observações são calculadas a partir da função massa de probabilidades conjunta fazendo-se

$$P(z_n | \mathbf{Y}_0^n) = \sum_{s_n \in \mathcal{I}} P(z_n, s_n | \mathbf{Y}_0^n) . \quad (11)$$

3.2. Detecção e Rastreamento

Uma vez que a fmp a posteriori $P(z_n | \mathbf{Y}_0^n)$ foi computada, é imediato projetar o detector/rastreado multiquadros de Bayes usando um dado critério de optimalidade.

Detector de Mínima Probabilidade de Erro Denote por H_0 a hipótese de que nenhum alvo está presente no instante n e, por H_1 a hipótese de que um alvo está presente durante a n -ésima varredura do sensor. Dado $P(z_n | \mathbf{Y}_0^n)$,

calculam-se as probabilidades a posteriori das hipóteses H_j , $j = 0, 1$. O detector de Bayes de mínima probabilidade de erro, assumindo-se custo zero para as decisões corretas e custo idêntico para perdas (não-deteções) e alarmes falsos, é dado pela regra de decisão

$$P(H_0 | \mathbf{Y}_0^n) \underset{H_1}{\overset{H_0}{>}} P(H_1 | \mathbf{Y}_0^n) . \quad (12)$$

Mudando-se o limiar em (12), pode-se alterar o teste de um detector de mínima probabilidade de erro para um teste Neyman-Pearson multiquadros que maximiza a probabilidade de detecção para um certo valor fixo de probabilidade de alarme falso definido pelo valor do limiar.

Rastreador MAP Se a hipótese H_1 é declarada verdadeira, calcula-se o vetor de probabilidades condicionais

$$Q_i^f [n] = P(\mathbf{z}_n = l | \text{alvo presente}, \mathbf{Y}_0^n) \quad l \in \bar{\mathcal{L}} \\ = \frac{P(z_n = l | \mathbf{Y}_0^n)}{1 - P(z_n = L_1 + 1 | \mathbf{Y}_0^n)} \quad (13)$$

A estimativa MAP da posição do centróide do alvo é

$$\hat{z}_{\text{map}} [n] = \arg \max_{l \in \bar{\mathcal{L}}} Q_i^f [n] . \quad (14)$$

4. IMPLEMENTAÇÃO DO PASSO DE FILTRAGEM

Detalha-se em seguida a implementação do passo de filtragem do algoritmo. Para implementar a equação (7), precisamos calcular primeiro o vetor em núcleo das observações

$$S_n(l) = p(\mathbf{y}_n | z_n = l, s_n) \quad (15)$$

para todos $z_n \in \tilde{\mathcal{L}}$ e para todas as possíveis máscaras $s_n \in \mathcal{I}$. A equação (7) é uma expressão genérica para o passo de filtragem e independe da distribuição estatística do clutter. Na seqüência, impõe-se a restrição adicional de que matriz de intensidade de clutter \mathbf{V}_n em cada quadro é um GMrf não-causal 2D modelado pela equação (4), ver subseção 2.2.

Para o estado alvo ausente, $L_1 = (L + r_i + r_s)(M + l_i + l_s) + 1$, o núcleo das observações reduz-se a

$$p(\mathbf{y}_n | z_n = L_1 + 1, s) = k \exp\left(-\frac{\mathbf{y}_n^T \Sigma_c^{-1} \mathbf{y}_n}{2}\right) \quad \forall s \in \mathcal{I} \quad (16)$$

onde k é uma constante e Σ_c é a matriz de covariância do campo \mathbf{V}_n . Por conveniência, normaliza-se $S_n(L_1 + 1)$ para 1, ver [4]. Para um $s_n = s$ fixo, $s \in \mathcal{I}$, o termo à direita em (15) é calculado para todos os $z_n \in \tilde{\mathcal{L}}$ usando o algoritmo para alvos de assinatura determinística introduzido em [4], com coeficientes de assinatura $a_{k,l}(s)$, $-r_i \leq k \leq r_s$, $-l_i \leq l \leq l_s$. Recordando os resultados em [4], após normalizarmos todas as entradas de \mathbf{S}_n por $S_n(L_1 + 1)$, pode-se

escrever, para $-r_s + 1 \leq i \leq L + r_i$ e $-l_s + 1 \leq j \leq M + l_i$, que

$$S_n((i + r_s - 1)M_2 + j + l_s) = \exp\left(\frac{2\lambda_{ij} - \rho_{ij}}{2\sigma_c^2}\right) \quad (17)$$

onde λ_{ij} and ρ_{ij} são chamados respectivamente de termo de dados e termo de energia, e $M_2 = M + l_i + l_s$. Para $r_i + 1 \leq i \leq L - r_s$, e $l_i + 1 \leq j \leq M - l_s$, tem-se [4]

$$\lambda_{i,j} = \sum_{k=-r_i}^{r_s} \sum_{l=-l_i}^{l_s} a_{k,l}(s) \Upsilon_n(i+k, j+l) \quad (18)$$

onde $\Upsilon_n(i, j)$ é dado pela equação

$$\begin{aligned} \Upsilon_n(i, j) &= Y_n(i, j) - \beta_h^c [Y_n(i, j-1) + Y_n(i, j+1)] \\ &- \beta_v^c [Y_n(i+1, j) + Y_n(i-1, j)] \end{aligned} \quad (19)$$

com condições de contorno nulas. Como observado em [4], a operação no argumento da função exponencial na equação (18) corresponde a duas operações de filtragem linear. O primeiro filtro gera uma imagem de erro de predição, Υ_n , a partir da imagem do sensor, \mathbf{Y}_n , usando o preditor não-causal em (19). O segundo filtro é um filtro bidimensional de correlação cuja resposta ao impulso é casada à máscara de assinatura, $a_{k,l}(s)$. Por outro lado, para $r_i + 1 \leq i \leq L - r_s$ e $l_i + 1 \leq j \leq M - l_s$, o termo de energia ρ_{ij} é constante e dado por

$$\rho_{ij} = \rho = \mathbf{a}^T \mathbf{A}_c \mathbf{a} \quad (20)$$

onde o vetor \mathbf{a} é obtido por ordenação lexicográfica da matriz de coeficientes de assinatura $a_{k,l}(s)$, $-r_i \leq k \leq r_s$, $-l_i \leq l \leq l_s$, e, \mathbf{A}_c é uma matriz bloco-Toeplitz, blocotridiagonal com estrutura

$$\mathbf{A}_c = \mathbf{I}_{\bar{r}} \otimes (\mathbf{I}_{\bar{l}} - \beta_h^c \mathbf{H}_{\bar{l}}) - \beta_v^c \mathbf{H}_{\bar{r}} \otimes \mathbf{I}_{\bar{l}} \quad (21)$$

onde \otimes denota o produto de Kronecker (ou produto tensorial [9]), $\bar{r} = r_i + r_s + 1$, $\bar{l} = l_i + l_s + 1$, \mathbf{I} é a matriz identidade e \mathbf{H} é uma matriz cujos elementos são identicamente nulos, excetuando-se os elementos H_{ij} tais que $|i - j| = 1$, que são iguais a 1.

Condições de Contorno e o Estado Alvo Ausente Para calcular as entradas de \mathbf{S}_n nas bordas da grade do sensor, i.e., fora da faixa $r_i + 1 \leq i \leq L - r_s$ e $l_i + 1 \leq j \leq M - l_s$, basta alterar os limites das somatórias em (18) de acordo com a tabela III, seção V-A em [5], e redefinir \mathbf{a} e \mathbf{A}_c em (20) com as dimensões apropriadas.

5. DESEMPENHO DO RASTREADOR

Examina-se a seguir o desempenho do rastreador bayesiano proposto usando dados sintéticos. O algoritmo é testado em duas classes ilustrativas de alvos.




Figura 1. Quadro inicial: (a) Imagem do alvo sem clutter, (b) Imagem simulada do sensor, PSNR = 3 dB.

1) Alvos Rotatórios No primeiro exemplo, os alvos simulados são objetos triangulares bidimensionais com intensidade constante e dimensão 9×9 . Além de um movimento translacional aleatório, os alvos exibem ainda uma rotação aleatória em torno do seu centróide. Por simplicidade computacional, mas sem perda de generalidade, admitem-se nessa simulação apenas 4 posições angulares para o alvo, respectivamente 0, 90, 180, e 270 graus. A probabilidade de rotação de 90 graus entre dois quadros consecutivos é 0.8. Os alvos são obscurecidos por um campo GMrf sintético altamente correlacionado, com parâmetros $\beta_h^c = \beta_v^c = 0.24$.

Em cada quadro da seqüência de imagens, há no máximo um alvo de interesse. O alvo move-se em uma grade de dimensão 150×150 com velocidade nominal constante igual a 2 pixels/quadro em ambas as direções (vertical e horizontal). A posição real do centróide do alvo flutua ao redor da posição nominal de acordo com um modelo “random walk” bidimensional de primeira ordem. Se a posição nominal do centróide é o pixel (i, j) , existe uma probabilidade uniforme $p = 0.20$ de a posição real do centróide ser qualquer um dos pixels $(i-1, j)$, $(i+1, j)$, $(i, j+1)$, or $(i, j-1)$.

As figuras 1 (a) and (b) mostram as imagens simuladas, respectivamente sem e com clutter, do alvo de interesse no instante $n = 0$. A relação sinal-ruído de pico (PSNR) é igual a 3 dB. O alvo está centrado nas coordenadas (42, 23). As figuras 2 (a) e (b) mostram respectivamente as imagens sem e com clutter do mesmo alvo no instante $n = 11$, também com PSNR = 3 dB. O centróide do alvo moveu-se aleatoriamente para a posição (61, 43), enquanto a máscara do alvo sofreu uma rotação de 90 graus. O alvo simulado parte no instante zero de uma posição aleatória desconhecida no quadrante superior esquerdo da imagem e é subsequentemente rastreado ao longo de 45 quadros consecutivos.

Para o rastreador não-linear bayesiano, a figura 3(a) mostra a evolução no tempo do desvio-padrão do erro na estimação da coordenada vertical do centróide. O desvio-padrão é expresso em número de pixels e calculado a partir de uma




Figura 2. Décimo-segundo quadro: (a) Imagem do alvo sem clutter, (b) Imagem simulada do sensor, PSNR = 3 dB.

simulação Monte Carlo onde se repete o experimento 130 vezes com dois níveis de PSNR, respectivamente 3 e 0 dB. As curvas correspondentes para o erro na estimativa da coordenada horizontal são qualitativamente semelhantes e são omitidas para economia de espaço. Nota-se na figura 3(a) que o erro de localização inicial declina com o tempo à medida que novas medidas se tornam disponíveis para o rastreador. Os erros inicial e em regime, assim como o tempo de aquisição do alvo, aumentam à medida que a relação sinal-ruído cai.

A seguir, compara-se o rastreador não-linear de Bayes com a associação subótima alternativa de um rastreador de máxima verossimilhança (ML) de quadro único e um filtro linearizado de Kalman-Bucy. A estimativa ML da posição do centróide, calculada a partir de um único quadro do sensor, assumindo-se a independência entre s_n e z_n , é dada por

$$\hat{z}_{ML} = \arg \max_{z_n} \sum_{s_n} p(\mathbf{y}_n | s_n, z_n) P(s_n). \quad (22)$$

As probabilidades a priori do estado da máscara s_n são computadas a partir da cadeia de Markov que descreve a sequência $\{s_n\}$. A saída do rastreador ML é tratada como uma estimativa preliminar de posição que é subsequentemente incorporada como uma medida ruidosa da posição real a um filtro linearizado de Kalman-Bucy (Kf). O Kf é usado para compensar os grandes erros nas estimativas ML no caso de baixas relações sinal-ruído.

A figura 3(b) mostra o desvio-padrão ao longo do tempo do erro na estimativa da coordenada vertical do centróide para o rastreador não-linear de Bayes e para o rastreador subótimo descrito nos parágrafos anteriores, com PSNR igual a 6 dB. Vê-se pela figura que o rastreador Kf tem erros muito maiores, tanto inicial quanto em regime, além de apresentar um maior tempo de aquisição de alvo em comparação com o rastreador bayesiano.

2) Alvos Deformáveis No segundo exemplo, os alvos simulados são objetos bidimensionais de formato retangular e intensidade constante, cujas dimensões (largura e altura) vari-

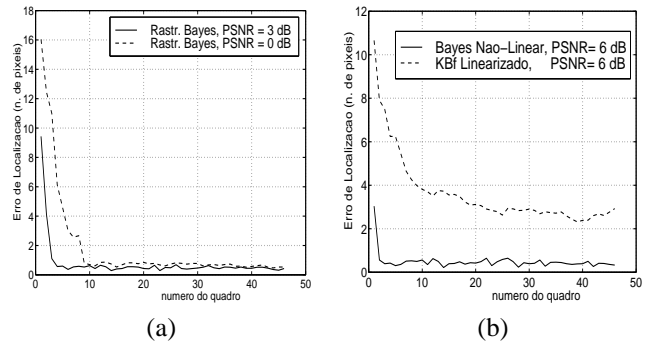


Figura 3. (a) Desempenho do rastreador de Bayes em clutter correlacionado; (b) Desempenho do rastreador não linear bayesiano vs. filtro linear de Kalman.




Figura 4. Décimo-oitavo quadro: (a) Imagem do alvo sem clutter, (b) Imagem simulada do sensor, PSNR = 3 dB.

am aleatoriamente de quadro a quadro. Partindo de um estado inicial *desconhecido*, (w_0, h_0) , a altura e a largura variam de um estado para um outro de acordo com uma regra de deformação linear. As probabilidades de transição de um estado da máscara para os estados adjacentes é fixada em 40 %. Nos estados terminais da máquina de estados finita que define as deformações, as probabilidades de transição para o estado seguinte ou anterior são fixadas em 80 %. O alvo deformável move-se em uma grade 110×110 de acordo com um modelo de “random walk” com arresto bidimensional que é idêntico ao usado no exemplo com alvos rotatórios. A imagem do alvo é também obscurecida por um GMrf bidimensional com parâmetros $\beta_h^c = \beta_v^c = 0.24$.

A figura 4(a) mostra a imagem sem clutter do alvo simulado no quadro $n = 17$. A figura 4(b) mostra a imagem observada do mesmo alvo corrompida com clutter em um cenário com PSNR= 3 dB. A figura 5(a) mostra a imagem sem clutter do alvo, agora no quadro $n = 32$. A figura 5(b) mostra a imagem observada com clutter sobreposto, também com PSNR= 3 dB. Nota-se pela figura 5(a) que, entre os instantes $n = 17$ e $n = 32$, não só o centróide do alvo se transladou, mas também a sua máscara sofreu uma deformação. O alvo simulado parte de uma posição ini-




Figura 5. Trigésimo-terceiro quadro: (a) Imagem do alvo sem clutter, (b) Imagem simulada do sensor, PSNR = 3 dB.

cial desconhecida no canto superior esquerdo da imagem e é posteriormente rastreado ao longo de 40 quadros consecutivos usando o rastreador não-linear bayesiano. A figura 6 mostra o desvio-padrão do erro na estimativa da posição do centróide, dessa vez na direção horizontal. O desvio-padrão é expresso em número de pixels e mostrado para dois níveis diferentes de PSNR, respectivamente 3 e 0 dB. As curvas na figura 6 foram obtidas a partir de 70 Monte Carlos. A




Figura 6. Desempenho do rastreador com um alvo deformável, PSNR= 3 dB (pontilhado) e 0 dB (sólido)

análise das curvas na figura 6 mostra um comportamento semelhante àquele encontrado na figura 3(a). Existe um erro na estimativa da posição inicial que decai com o tempo à medida que novos quadros são processados pelo algoritmo. O erro inicial e o tempo de aquisição do alvo variam com o nível do clutter de fundo.

6. CONCLUSÕES

Introduziu-se nesse artigo um novo algoritmo bayesiano, não-linear e ótimo para detecção e rastreamento integrais de alvos móveis deformáveis em seqüências de imagens digitais corrompidas por clutter de alta densidade. Os estudos de desempenho a partir de simulações Monte Carlo com dados sintéticos mostraram uma significativa melhoria de performance em comparação com a associação usual

de um estimador de máxima verossimilhança e um filtro linear de Kalman-Bucy (KBf). O detector/rastreador proposto apresenta ainda baixos erros de estimação em regime e baixos tempos de aquisição de alvos mesmo em cenários com alvos fortemente obscurecidos e invisíveis a um operador humano.

AGRADECIMENTO

O autor gostaria de agradecer ao Dr. Amir Asif e à Dra. Susan Schweizer por valiosas discussões a respeito do tema desse artigo.

7. REFERÊNCIAS

- [1] H. Im e T. Kim, "Optimization of multiframe target detection schemes", *IEEE Transactions on Aerospace and Electronic Systems*, vol.35, n.1, pp. 176-187, Janeiro de 1999.
- [2] R. Bethel e G. Paras, "A PDF multisensor, multitarget tracker," *IEEE Transactions on Aerospace and Electronic Systems*, vol.34, n.1, pp. 153-168, Janeiro de 1998.
- [3] Y. Bar-Shalom e X. Li. *Multitarget-Multisensor Tracking: Principles and Techniques*. YBS, Storrs, CT, 1995.
- [4] M. G. S. Bruno e J. M. F. Moura, "The optimal 2D multiframe detector/tracker," *AEÜ International Journal of Electronics and Communications*, 53(6), pp. 346-355, Dezembro de 1999.
- [5] M. G. S. Bruno e J. M. F. Moura, "Multiframe Detector/Tracker: Optimal Performance," a aparecer em *IEEE Transactions on Aerospace and Electronic Systems*, Julho de 2001.
- [6] M. G. S. Bruno e J. M. F. Moura, "Clutter Adaptive Multiframe Detection/Tracking of Random Signature Targets", *Proceedings IEEE ICASSP 2001*, Salt Lake City UT, USA, 7 a 11 de maio de 2001.
- [7] 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.
- [8] J. M. F. Moura e M. G. S. Bruno, "DCT/DST and Gauss-Markov fields: conditions for equivalence," *IEEE Transactions on Signal Processing*, vol. 46, n. 9, pp. 2571-2574, Setembro de 1998.
- [9] A. Graham, *Kronecker Products and Matrix Calculus with Applications*, Ellis Horwood Limited, 1981.