

# Estimação de trajetórias usando filtragem $H_\infty$ em múltiplos modelos interagentes

Marco Aurélio Carvalho Leandro, Karl Heinz Kientz

Instituto Tecnológico de Aeronáutica

Divisão de Engenharia Eletrônica - 12228-900, São José dos Campos, SP, Brasil

**Resumo**—Observadores são estimadores de estado para sistemas determinísticos, i.e., sistemas sem ruídos de processo e de medidas significativos. O problema de reconstrução do vetor de estados pode também ser formulado para o caso de modelagem estocástica. Nesse caso, o observador de estado, doravante denominado estimador de estado requer o uso de um critério estocástico de otimização para obtenção de uma solução ótima ou sub-ótima. Esse artigo considera o problema estimação de estados em sistemas estocásticos lineares com saltos Markovianos (MJLS) no contexto de estimação de alvos aéreos. São considerados os múltiplos modelos interagentes (IMM) com filtragem  $H_\infty$  e a ponderação dos estados estimados pelos filtros é feita conforme um critério que envolve o menor traço da matriz de covariância dos erros de estimação. Um estudo de caso é abordado, envolvendo a estimação de trajetória de alvo aéreo, buscando ilustrar os potenciais ganhos das técnicas elencadas.

**Palavras-Chave**—Múltiplos modelos interagentes, sistemas lineares com saltos Markovianos, Estimação  $H_\infty$

## I. INTRODUÇÃO

A abordagem da filtragem  $H_\infty$  foi assunto de extensa pesquisa na década passada. Na filtragem  $H_\infty$ , as fontes de ruído são sinais determinísticos arbitrários com energia limitada e o filtro visa garantir um limitante superior para o ganho  $\mathcal{L}_2$ -induzido entre o sinal de ruído e o erro de estimação ([1], [2], [3]). A estimação de estados em sistemas estocásticos tempo-discreto com saltos Markovianos tem sido objeto de interesse, nas últimas décadas, na área de pesquisa envolvendo acompanhamento de alvos aéreos manobrantes ([4],[5], [6],[7]). Algoritmos envolvendo múltiplos modelos (MM) são geralmente considerados a corrente principal de abordagem dessa área. Dentre os MM, os múltiplos modelos interagentes (IMM) são largamente empregados e consideram a combinação das matrizes dos estados estimados e das matrizes de covariância dos erros de estimação dos múltiplos modelos como um modelo de Markov. Recentemente, foram publicados trabalhos que permitem que os algoritmos IMM envolvam a estimação dos estados do alvo no sentido de variância mínima ([8], [9], [10]). O traço da matriz de covariância dos erros de estimação nesses algoritmos é menor que o traço calculado nos algoritmos IMM clássicos. Nesse trabalho, foi implementado um modelo IMM com filtragem  $H_\infty$  e com ponderação dos estados pelo traço da matriz de covariância dos erros de estimação. Através de uma trajetória hipotética, os resultados foram comparados via o erro quadrático médio (RMSE) do modelo IMM clássico e variações envolvendo a filtragem  $H_\infty$  na presença e na ausência do critério de ponderação pelo traço. A contribuição deste artigo está na aplicação

da filtragem  $H_\infty$  no problema de estimação de estados em sistemas estocásticos tempo-discreto com saltos Markovianos empregando um critério de otimalidade na combinação dos estados estimados. O contexto é o de acompanhamento de alvos aéreos manobrantes [11]. O restante do artigo está assim dividido: a subseção a seguir introduz a notação utilizada nesse trabalho; a seção 2 apresenta a formulação utilizada para o KF presente no IMM clássico; na seção 3, é apresentada a técnica utilizada no filtro  $H_\infty$ ; Na seção 4, o algoritmo IMM empregado é detalhado; a seção 5 inicia com uma descrição do modelo dinâmico empregado e em seguida a apresentação dos resultados é feita. Discussões a respeito da aplicação dos modelos completam a seção. Finalmente, as conclusões e perspectivas de trabalhos futuros são apresentadas na seção 6.

## A. Notação

$F, G, \Gamma, H, L$  : matrizes com dimensões apropriadas

$x(k) \in \mathfrak{R}^n$  : vetor de estados

$u(k) \in \mathfrak{R}^p$  : vetor de controle

$y(k) \in \mathfrak{R}^q$  : vetor de medidas

$v(k) \in \mathfrak{R}^n$  : vetor de ruído de estado

$w(k) \in \mathfrak{R}^q$  : vetor de ruído de medida

$E[v(k)v(k)'] = Q(k)$  : covariância do ruído de estado

$E[w(k)w(k)'] = R(k)$  : covariância do ruído de medida

$\mathcal{N}(0, I)$  : distribuição gaussiana com média zero e variância unitária

$T$  : taxa de amostragem

$z(k) \triangleq L(k)x(k)$  : combinação linear dos estados

$\hat{z}(k) = E[z(k)|y(0)...y(k)]$ ,  $\hat{z}(k) \in \mathfrak{R}^m$

$Z^k \triangleq \{z(i), i \in [0; k]\}$

$\hat{x}(j|k) \triangleq E[x(j)|Z^k]$  : estimação para  $j = k$

$\tilde{x}(j|k) \triangleq x(j) - \hat{x}(j|k)$  : erro estimado

$P(j|k) \triangleq E[\tilde{x}(j|k)\tilde{x}(j|k)']|Z^k$  : matriz de covariância do erro de predição

$\delta_{(\cdot)}$  : função Delta de Dirac

$x_{k+1}^- = x(k+1|k)$

$P_{k+1}^- = P(k+1|k)$

$x_{k+1}^+ = x(k+1|k+1)$

$P_{k+1}^+ = P(k+1|k+1)$

$\hat{z}_k$  : política de minimização

$(w_k, v_k, x_0)$  : política de maximização

$\|s_k\|_{R_k}^2 = s_k^T R_k s_k$

DWNA: Discrete White Noise Acceleration - aceleração discreta como ruído branco.

## II. FILTRO DE KALMAN

A formulação adotada é a formulação linear discreta, onde a iteração atual é indicada por  $k \in [0, N]$

$$x(k+1) = Fx(k) + Gu(k) + \Gamma(k)v(k) \quad (1)$$

$$y(k) = Hx(k) + w(k) \quad (2)$$

$$z(k) = Lx(k) \quad (3)$$

As seguintes hipóteses devem ser válidas:

$$E(x(0)|Z^0) = \hat{x}(0|0) \quad (4)$$

$$\text{cov}[x(0)|Z^0] = P(0|0) \quad (5)$$

$$E[v(k)] = 0 \quad (6)$$

$$E[v(k)v(j)'] = Q(k)\delta_{kj} \quad (7)$$

$$E[w(k)] = 0 \quad (8)$$

$$E[w(k)w(j)'] = R(k)\delta_{kj} \quad (9)$$

$$E[x(0)v(k)'] = 0, \forall k \quad (10)$$

$$E[x(0)w(k)'] = 0, \forall k \quad (11)$$

$$E[v(k)w(j)'] = 0, \forall k \quad (12)$$

(4) e (5) indicam que o estado filtrado inicial e a covariância filtrada inicial são conhecidos a priori. De (6) e (7), (8) e (9) pode-se concluir que o ruído de estado e o ruído de medida são brancos com média zero. (10), (11) e (12) indicam que os ruídos e o estado inicial são descorrelacionados. Supondo  $v(k) \sim \mathcal{N}(0, I)$ ,  $w(k) \sim \mathcal{N}(0, I)$  e de (6) e (8):

$$E[v(k)|Z^k] = E[v(k)] = 0 \quad (13)$$

$$E[w(k)|Z^k] = E[w(k)] = 0 \quad (14)$$

O KF pode ser derivado de diversas maneiras. Nessa seção esse algoritmo será derivado conforme [12]. A notação usada em (1) à (14) será alterada buscando uma maior clareza nas expressões a seguir. A iteração atual  $k$  passará a ser subscrita.

As seguintes equações são representativas do KF, dadas as condições iniciais:

$$\hat{x}_{k+1}^- = F\hat{x}_k^+ + \Gamma u_k \quad (15)$$

$$P_{k+1}^- = FP_k^+ F' + \Gamma Q_k \Gamma' \quad (16)$$

$$\hat{x}_{k+1}^+ = \hat{x}_{k+1}^- + k_{k+1}(y_{k+1} - H\hat{x}_{k+1}^-) \quad (17)$$

$$P_{k+1}^+ = (I - K_{k+1}H)P_{k+1}^-(I - K_{k+1}H)' + K_{k+1}R_{k+1}K_{k+1}' \quad (18)$$

Conforme foi comentado na seção 1, o critério de mérito a ser empregado aqui é minimizar o somatório dos quadrados dos erros de estimação  $\hat{x}_{k+1}^+$ . Isso equivale a  $\min_{k+1} Tr(P_{k+1}^+)$ .

Dessa forma, obtém-se a expressão em função de  $K_{k+1}$ :

$$K_{k+1} = P_{K+1}^- H' [HP_{K+1}^- H' + R_{k+1}]^{-1} \quad (19)$$

Substituindo (19) em (18):

$$P_{k+1}^+ = P_{k+1}^- - P_{k+1}^- H' [HP_{k+1}^- H' + R_{k+1}]^{-1} HP_{k+1}^- \quad (20)$$

As equações (17) e (20) caracterizam a distribuição a posteriori  $f_+ \sim \mathcal{N}(\hat{x}_{k+1}^+, P_{k+1}^+)$ . O sistema linear invariante no tempo (1) - (3) converge para uma covariância em estado estacionário, se o par  $\{F, H\}$  for completamente observável e se o par  $\{F, C\}$ , onde  $C$  é tal que  $CC' = Q$ , for completamente controlável.

## III. FILTRO $H_\infty$

Nessa seção será considerado o problema de estimação minimax de horizonte finito, também conhecido como problema de filtragem  $H_\infty$ . Considerando o sistema dinâmico dado pelas equações (1) e (2), deseja-se estimar o vetor  $\hat{z}_{k+1} = L\hat{x}_k$ , onde  $\hat{x}_k$  é uma estimativa baseada em uma sequência de medidas  $\{y_0, \dots, y_k\}$ .

A escolha da função de custo  $J(\hat{z}, x_0, w, v)$  completa a definição do problema, em que a estimativa  $\hat{z}_k$  deve ser tal que o erro quadrático médio  $\sum_{k=0}^N \|z_k - \hat{z}_k\|^2$  seja minimizado, enquanto a tripla  $(\hat{x}_0, w_k, v_k)$  leva à minimização do erro quadrático médio definido em (21).

$$J(\hat{z}, x_0, w, v) = \sum_{k=0}^N \|z_k - \hat{z}_k\|^2 - \gamma^2 \left( \sum_{k=0}^N \|v_k\|^2 + \sum_{k=0}^N \|w_k\|^2 + \|x_0 - \hat{x}_0\|_{P_0^{-1}}^2 \right) \quad (21)$$

O segundo termo do lado direito da equação é uma penalidade em termos de  $x_0, w_k, v_k$ ;  $\gamma$  é uma constante positiva, que define a magnitude da penalidade. A matriz  $P_0$  é positiva definida e representa a incerteza do estado inicial. O problema  $H_\infty$  de horizonte finito é encontrar uma estimativa para  $\hat{x}_k$  e  $\hat{z}_k$  que satisfaz:

$$\text{Sup}_{(w, v, x_0)} \frac{\sum_{k=0}^N \|z_k - \hat{z}_k\|^2}{\sum_{k=0}^N (\|w_k\|^2 + \|v_k\|^2) + \|x_0 - \hat{x}_0\|_{P_0^{-1}}^2} < \gamma^2 \quad (22)$$

Onde  $w, v \in \mathcal{L}_2$ . Essa condição é equivalente a:

$$J(\hat{z}, x_0, w, v) < 0, \forall (x_0, w, v), \quad (23)$$

s.a.

$$\sum_{k=0}^N (\|w_k\|^2 + \|v_k\|^2) + \|x_0 - \hat{x}_0\|_{P_0^{-1}}^2 \neq 0 \quad (24)$$

Reescrevendo (2) como:  $w_k = y_k - Hx_k$ , o custo pode ser reescrito como:

$$J(\hat{z}, x_0, w, v) = \sum_{k=0}^N \|z_k - \hat{z}_k\|^2 - \gamma^2 \left( \sum_{k=0}^N \|v_k\|^2 + \sum_{k=0}^N \|y_k - Hx_k\|_{R_k^{-1}}^2 + \|x_0 - \hat{x}_0\|_{P_0^{-1}}^2 \right) \quad (25)$$

A apresentação da solução do problema de filtragem  $H_\infty$  e teoremas acessórios necessários podem ser encontrados em [13], [14], [15], [16] e [17].

### A. Algoritmo do problema de filtragem $H_\infty$

De forma geral o algoritmo para o filtro  $H_\infty$  segue de perto [14] e pode ser descrito como:

$$\hat{x}_{k+1}^- = F\hat{x}_k^+ + \Gamma u_k \quad (26)$$

$$P_{k+1}^- = FP_k^+ F' + \Gamma Q_k \Gamma' \quad (27)$$

$$K_{k+1} = P_{k+1}^- H' [HP_{k+1}^- H' + R_{k+1}]^{-1} \quad (28)$$

$$\hat{x}_{k+1}^+ = \hat{x}_{k+1}^- + k_{k+1}(y_{k+1} - H\hat{x}_{k+1}^-) \quad (29)$$

$$P_{k+1}^+ = FP_{k+1}^- F' + \Gamma Q_k \Gamma' - FP_{k+1}^- [H' \quad L'] (S_k)^{-1} \begin{bmatrix} H \\ L \end{bmatrix} \quad (30)$$

Onde

$$S_k = \begin{bmatrix} R_{k+1} & 0 \\ 0 & -\gamma^2 I \end{bmatrix} + \begin{bmatrix} H \\ L \end{bmatrix} P_{k+1}^- [H' \quad L'] \quad (31)$$

## IV. MULTIPLOS MODELOS INTERAGENTES - IMM

### A. Modelos Lineares com saltos Markovianos

O sistema discreto descrito em (1)-(3) é agora descrito como um modelo linear com saltos Markovianos. Dessa forma:

$$\begin{aligned} x(k+1) &= F_j x(k) + G_j u(k) + \Gamma_j(k) v_j(k) \\ y(k) &= H_j x(k) + w_j(k) \end{aligned} \quad (32)$$

Onde o subscrito  $j \in S = \{1, 2, \dots, s\}$  denota o modelo. Dado que  $M_j^k$  denota o modelo  $j$  no instante  $k$ , o modelo dinâmico pode ser modelado como uma cadeia finita de Markov com conhecida matriz de transição de probabilidades do modelo  $i$  no instante  $k-1$  para o modelo  $j$  no instante  $k$ . Dessa forma:

$$\pi_{ij} \doteq P \{M_j^k | M_i^{k-1}\} \quad (33)$$

$$0 \leq \pi_{ij} \leq 1, \sum_{j=1}^s \pi_{ij} = 1, i, j \in S \quad (34)$$

A distribuição de estado inicial da cadeia de Markov é  $\rho = [\rho_1, \dots, \rho_s]$ , onde:

$$0 \leq \rho_j \leq 1, \sum_{j=1}^s \rho_j = 1, j \in S \quad (35)$$

### B. Algoritmo IMM

O algoritmo IMM é o mais presente na abordagem do problema envolvendo o acompanhamento de alvos manobранtes, isto é, a estimação de estado envolvendo um sistema tempo-discreto estocástico com parâmetros comutando conforme uma cadeia finita de Markov. O algoritmo IMM pode ser descrito conforme a seguir:

Passo 1: Cálculo do conjunto inicial de probabilidades  $(i, j = 1, \dots, s)$ . A probabilidade que o modelo  $M_i$  esteja em vigor em  $(k-1)$  dado que  $M_j$  está em vigor em  $k$ , condicionado por  $Z^{k-1}$ :

$$\mu_{i|j}(k-1|k-1) = \frac{1}{\bar{c}_j} \pi_{ij} \mu_i(k-1), i, j = 1, \dots, s \quad (36)$$

Onde  $\bar{c}_j$  é uma constante de normalização dada por:

$$\bar{c}_j = \sum_{i=1}^s \pi_{ij} \mu_i(k-1) \quad (37)$$

Passo 2: Cálculo do estado e covariância iniciais para o filtro associado ao modelo  $M_j^k, j \in S$ :

$$\hat{x}^{0j}(k-1|k-1) = \sum_{i=1}^s \hat{x}^i(k-1|k-1) \mu_{i|j}(k-1|k-1), j = 1, \dots, s \quad (38)$$

$$P^{0j}(k-1|k-1) = \sum_{i=1}^s \mu_{i|j}(k-1|k-1) \begin{aligned} &-\hat{x}^{0j}(k-1|k-1) \times [\hat{x}^i(k-1|k-1) \\ &-\hat{x}^{0j}(k-1|k-1)] \times [\hat{x}^i(k-1|k-1) \\ &-\hat{x}^{0j}(k-1|k-1)]^T, j = 1, \dots, s \end{aligned} \quad (39)$$

Passo 3: Cálculo da função de verossimilhança e filtragem a partir dos resultados do passo anterior.

A estimativa (37) e a covariância (38) são a entrada dos filtros  $M_j^k$ . A função de verossimilhança para o filtro  $s$  é:

$$\Delta_j(k) = N [z(k); \hat{z}^j [k|k-1; \hat{x}^{0j}(k-1|k-1)], \quad (40)$$

$$S^j [k; P^{0j}(k-1)(k-1)] \quad j = 1, \dots, s \quad (41)$$

Onde  $S^j$  é a covariância da inovação correspondente a cada filtro.

Passo 4: Cálculo dos estados estimados e da matriz de covariância dos erros de estimação a partir da atualização da probabilidade de cada filtro  $M_j^k$ :

$$\hat{x}(k|k) = \sum_{j=1}^s \hat{x}^j(k|k) \mu_j \quad (42)$$

$$P(k|k) = \sum_{j=1}^s \mu_j(k) \{P^j(k|k) + [\hat{x}^j(k|k) - \hat{x}(k|k)][\hat{x}^j(k|k) - \hat{x}(k|k)]^T\} \quad (43)$$

Onde:

$$\mu_j = \frac{1}{c} \Delta_j(k) \bar{c}_j, \quad (44)$$

$$c = \sum_{j=1}^s \Delta_j(k) \bar{c}_j \quad (45)$$

Para uma descrição mais detalhada do algoritmo IMM e outras técnicas empregadas para acompanhamento de alvo aéreo envolvendo múltiplos modelos ver [6].

### C. Algoritmo IMM modificado

O objetivo é encontrar estimativas locais para o estado a partir dos  $s$  filtros existentes e ponderar essas estimativas de forma a ter:

$$\hat{x}(k|k) = \sum_{i=1}^s \Omega_i x_i(k|k) \quad (46)$$

Onde o peso  $\Omega$  é escolhido minimizando o índice de performance:

$$J = \text{tr}(P_i) \quad (47)$$

Sendo  $P_i$  a variância do erro de estimação em estado estacionário de cada modelo (filtros).

Com base nos resultados apresentados em [18] e [9] o algoritmo IMM apresentado na seção anterior foi alterado no passo 3 e no passo 4. No passo 3 não é mais calculada a verossimilhança  $\Delta_j(k)$  e no passo 4, a atualização da probabilidade para cada filtro,  $\mu_j$ , é substituída por  $a_j$ , que leva em consideração o traço matriz de covariância dos erros de estimação. Dessa forma as novas equações (41)-(43) são:

$$\hat{x}(k|k) = \sum_{j=1}^s a_j \hat{x}_j(k|k) \quad (48)$$

$$P(k|k) = \sum_{j=1}^s a_j(k) \{P^j(k|k) + [\hat{x}^j(k|k) - \hat{x}(k|k)][\hat{x}^j(k|k) - \hat{x}(k|k)]^T\} \quad (49)$$

Onde

$$a_j(k) = \left( \sum_{i=1}^s \frac{1}{tr P_i(k|k)} \right)^{-1} \frac{1}{tr P_j(k|k)} \quad (50)$$

## V. MODELO DINÂMICO DO ESTUDO DE CASO

Considerando um modelo bidimensional e o exemplo usado em [19],[9] e [10] tem-se o seguinte modelo de aceleração constante por partes (DWNA).

$$F_j = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \Gamma_j = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix}$$

$$H_j = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

### A. Resultados

Os dados utilizados nesse trabalho foram extraídos de uma dinâmica hipotética, onde um alvo move-se com velocidade constante durante  $t = 400s$ . A partir de então executa uma manobra lenta, guinando  $90^\circ$  na direção do eixo  $x$  com aceleração  $u_x = u_y = 0.075m/s^2$  e completa a guinada após  $t = 200s$ . Em  $t = 600s$  a aceleração é zero. Uma nova guinada de  $90^\circ$  inicia-se em  $t = 610s$  com aceleração  $u_x = -0,3m/s^2$  e  $u_y = 0,3m/s^2$ . Essa guinada termina em  $t = 660s$  e o alvo permanece a partir daí com velocidade constante. O estado inicial é  $x(0) = [2100; 0; 10000; -15]$ . A Figura 1 ilustra a trajetória acima no plano XY, bem como as trajetórias e velocidades ao longo de  $k = t/T$ , onde a abscissa representa o tempo  $t$  dividido pelo período de amostragem  $T = 10$ .

Com base na trajetória apresentada foram avaliados o modelo IMM com dois KF, o modelo IMM modificado com dois KF, o modelo IMM com dois filtros  $H_\infty$  e o modelo IMM modificado com dois filtros  $H_\infty$ . Foram adotadas as seguintes matrizes:




Fig. 1. Trajetória gerada no plano  $xy$ , velocidades nos eixos  $x$  e  $y$  pelo tempo  $k = t/T$ , trajetórias no eixo  $y$  e e no eixo  $x$  pelo tempo  $k = t/T$

$$\pi_{ij} = \begin{bmatrix} 0,95 & 0,05 \\ 0,05 & 0,95 \end{bmatrix}, \rho = \begin{bmatrix} 0,5 \\ 0,5 \end{bmatrix}$$

$$P_i(0) = \begin{bmatrix} r & r/T & 0 & 0 \\ r/T & 2r/T^2 & 0 & 0 \\ 0 & 0 & r & r/T \\ 0 & 0 & r/T & 2r/T^2 \end{bmatrix} \quad (51)$$

Onde  $r$  é a variância do erro de medida nas coordenadas  $x$  e  $y$  para um intervalo de amostragem de  $T = 10s$ .

As matrizes de covariância do ruído de estado e do ruído de medida são, respectivamente,  $Q_i$  e  $R_i$ :

$$Q_i = \Gamma \sigma_v^2 \Gamma' = \begin{bmatrix} \frac{1}{4}T^4 & \frac{1}{2}T^3 \\ \frac{1}{2}T^3 & T^2 \end{bmatrix} \sigma_v^2 \quad (52)$$

$$R_i = \begin{bmatrix} r & \frac{r}{20} \\ \frac{r}{20} & r \end{bmatrix} \quad (53)$$

Onde  $\sigma_{v1}^2 = 0,01$  e  $\sigma_{v2}^2 = 50$ . Os modelos foram avaliados baseado no erro quadrático médio (RMSE - root mean square error) e os resultados foram obtidos a partir da simulação de 100 trajetórias ( $N = 100$ ):

$$RMSE_k = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{x}_k^i - x_k^i)^2} \quad (54)$$

Onde  $\hat{x}_k^i$  e  $x_k^i$  denotam o estado estimado e o estado verdadeiro, respectivamente, na  $i$ th trajetória simulada no espaço de tempo  $k$ . Foi adotado um ruído igual a  $r = 1000$ . Nas Figuras e na Tabela a seguir as abreviações IMM (I), IMMmod (II), IMM $H_\infty$  (III) e IMM $H_\infty$  mod (IV) representam o algoritmo IMM na sua configuração tradicional com dois KF, o algoritmo IMM modificado por (49), o algoritmo IMM com dois filtros  $H_\infty$  e o algoritmo IMM com dois filtros  $H_\infty$  e modificado por (49), respectivamente. Através do RMSE médio, a Tabela 1 sumariza o que foi realizado.

Observando as Figuras de 2 à 5 e a Tabela 1, pode-se perceber que a combinação IMM $H_\infty$  modificada pela ponderação dos estados (IMM $H_\infty$  mod) foi bastante superior às demais. A primeira guinada, mais suave não resultou em aumento do RMSE. Entretanto, a segunda guinada, mais rápida, resultou em aumento do RMSE, exceto para a posição na coordenada

TABELA I  
RESULTADOS PARA  $r = 1000$

	I	II	III	IV
Pos $x$	1,8916	0,8247	0,1197	0,0357
Veloc $x$	3,0134	2,7881	2,4817	0,7418
Pos $y$	2,9777	1,7534	0,1449	0,0355
Veloc $y$	3,2354	2,9690	3,0397	0,7626




Fig. 2. RMSE da posição em  $x$  para  $r=1000$  ao longo de  $k$




Fig. 3. RMSE da posição em  $y$  para  $r=1000$  ao longo de  $k$




Fig. 4. RMSE da velocidade em  $x$  para  $r=1000$  ao longo de  $k$




Fig. 5. RMSE da velocidade em  $y$  para  $r=1000$  ao longo de  $k$

$x$ . Os modelos IMM com os filtros  $H_\infty$ , incluindo ou não a alteração na ponderação dos estados estimados foram bas-

tante superiores (menor RMSE), principalmente com relação à estimação da posição nas coordenadas  $x$  e  $y$ . O modelo  $IMMH_\infty\text{mod}$ , embora tenha apresentado um transitório maior na estimação da velocidade nas coordenadas  $x$  e  $y$ , foi mais acurado que os demais.

Não foi percebida diferença no tempo de execução dos algoritmos descritos. Esse tempo foi computado pela função "tic (inicia) toc (finaliza)" do Matlab.

## VI. CONCLUSÕES E PERSPECTIVAS

Nesse trabalho, foi implementado um modelo IMM com filtragem  $H_\infty$  e com ponderação dos estados baseada no traço da matriz de covariância dos erros de estimação. Através de uma trajetória hipotética, os resultados foram comparados via o erro quadrático médio (RMSE) após 100 trajetórias simuladas. Os modelos abordados foram o modelo IMM clássico e variações envolvendo o modelo IMM com a filtragem  $H_\infty$  na presença ( $IMMH_\infty\text{mod}$ ) e na ausência do critério de ponderação baseado no traço da matriz de covariância dos erros de estimação ( $IMMH_\infty$ ). Os resultados indicam que os modelos IMM combinados com o critério de ponderação pelo traço da matriz de covariância obtiveram menores erros de estimação, comparativamente ao modelo IMM tradicional. Além disso, aliado ao uso da estimação  $H_\infty$  foram os mais acurados, inclusive diante de variações bruscas de velocidade. Diante dos resultados obtidos e da menor complexidade dos algoritmos IMMmod e  $IMMH_\infty\text{mod}$ , estes podem ser uma alternativa vantajosa diante dos algoritmos IMM tradicionais. Os MM modelos tradicionais com MJLS tem a interpolação dos estados estimados baseada na matriz de transição de probabilidades, a qual muitas vezes é computada como parâmetro de projeto pelo seu desconhecimento. Como próximo trabalho, o modelo IMM será formulado como um modelo convexo e os resultados serão comparados com as formulações tradicionais.

## REFERÊNCIAS

- [1] SHAKED, U.  $h_\infty$  minimum error state estimation of linear stationary processes. *IEEE Trans. Automat. Control*, v. 35, p. 554–558, 1990.
- [2] NAGPAL, K. M.; KHARGONEKAR, P. Filtering and smoothing in  $H_\infty$  setting. *IEEE: Transaction on Automatic Control*, n. 36, p. 152–166, 1991.
- [3] SHAKED, U.; THEODOR, Y.  $H_\infty$  optimal estimation: a tutorial. *IEEE: Proceedings of the 31<sup>st</sup> Conference on Decision and Control*, p. 2278–2286, 1992.
- [4] BLOM, H. A. P.; BAR-SHALON, Y. The interacting multiple model algorithm for systems with markovian switching coefficients. *IEEE Trans. on Automatic Control*, v. 33, n. 8, p. 780–783, 1988.
- [5] LI, X.; ZHAO, Z.; LI, X. General model set design methods for multiple model approach. *IEEE Trans on Automatic Control*, v. 50, n. 9, p. 1260–1276, 2005.
- [6] LI, X. R.; JILKOV, V. P. Survey of maneuvering target tracking. part v: Multiple model methods. *IEEE Transactions on Aerospace and Electronic Systems*, v. 41, n. 4, p. 1255–1321, 2005.
- [7] YEPES, J. L.; HWANG, I.; ROTEVA, M. New algorithms for aircraft intent inference and trajectory prediction. *AIAA Journal of Guidance, Control and Dynamics*, v. 30, n. 2, p. 370–382, 2007.
- [8] FU, X. et al. New interacting multiple model algorithms for tracking of maneuvering target. *IET Control Theory and Applications*, v. 4, p. 2184–2194, 2010.
- [9] FU, X. et al. A novel interacting multiple model algorithm based on multi-sensor optimal information fusion rules. *American Control Conference*, p. 1201–1206, 2009.
- [10] FU, X. et al.  $h_\infty$  filtering with diagonal interacting multiple model algorithm for maneuvering target tracking. *American Control Conference*, p. 6187–6191, 2013.

- [11] MAZOR, E. et al. Interacting multiple model methods in target tracking: A survey. *IEEE Trans. on Aerospace and Electronic Systems*, v. 34, n. 1, p. 103–123, 1998.
- [12] CRASSIDIS, J. L.; JUNKINS, J. L. *Optimal estimation of dynamic systems*. [S.l.: s.n.], 2004.
- [13] TAKABA, K. *Studies on  $H_\infty$  Filtering Problems for Linear Discrete-Time Systems*. Tese (Doutorado) — Kyoto University, January 1996.
- [14] FORSELL, U. *On  $H_2$  and  $H_\infty$  optimal estimation*. Tese (Doutorado) — Linköping University, 1996.
- [15] HASSIBI, B.; SAYED, A. H.; KAILATH, T. Linear estimation in Krein space. *IEEE Transactions on Automatic Control*, v. 41, n. 1, 1996a.
- [16] HASSIBI, B.; SAYED, A. H.; KAILATH, T. Linear estimation in Krein space. *IEEE Transactions on Automatic Control*, v. 41, n. 1, 1996b.
- [17] HASSIBI, B.; SAYED, A. H.; KAILATH, T.  $h_\infty$  optimality of the lms algorithm. *IEEE Transactions on Signal Processing*, v. 44, n. 2, p. 267–280, 1996c.
- [18] DENG, Z. et al. New approach to information fusion steady state kalman filtering. *Automatica*, v. 41, p. 1695 – 1707, 2005.
- [19] HO, T.; FAROOQ, M. Comparing an interacting multiple model algorithm and a multiple process soft switching algorithm: equivalence relationship and tracking performance. *Proc Third Int Conf on Information Fusion*, 2000.