

Interacting Multiple Model Kalman Filters (IMMKF)

Henrique M. Menegaz Pedro Henrique R.Q.A. Santana

03 de julho de 2009.



Sumário

- 1 Introdução
 - Abordagens de múltiplos modelos
 - Introdução ao Interacting Multiple Model (IMM)
- 2 Estado da Arte
- 3 Interacting Multiple Model
 - Descrição do sistema
 - Motivação para o algoritmo
 - O Algoritmo IMM
 - Discussão
- 4 Modelos Múltiplos Autônomos (AMM)
- 5 Exemplo
 - Descrição do problema
 - Modelagem do CTA
 - Movimento Uniforme (MU)
 - Modelo de Manobra
 - Linearização da função
 - Modelo EKF para CT final
- 6 Simulação
- 7 Conclusões
- 8 Referências bibliográficas

Introdução

Situação 1

Um sistema de segurança industrial monitora o transcorrer de um processo químico. Em caso de falha, o processo necessita ser imediatamente encerrado e um alarme acionado para que a fábrica seja evacuada. Com medo de depender de um técnico para tarefa tão delicada, o gerente dá ao engenheiro encarregado a tarefa de projetar um sistema automático de detecção de falha. Estando disponíveis apenas medições ruidosas do processo, como fazer para estimar a presença de problemas?

Situação 2

Um sistema de controle de tráfego aéreo faz uso de leituras de radares para determinar as posições de diferentes aeronaves. Entretanto, por limitações do equipamento, a quantidade de objetos passíveis de detecção pelos radares é limitada, não sendo possível obter leituras de posição de todas as aeronaves simultaneamente. Além disso, a presença de ruído corrompe as medidas e dificulta a obtenção de estimativas de posição. Como fazer para estimar as coordenadas de cada aeronave para evitar colisões?

Situação 3

Um engenheiro é incumbido da tarefa de determinar os modelos de diferentes motores que fazem parte de equipamentos recém-adquiridos pela empresa. Os equipamentos foram instalados e postos em operação e não houve cuidado em se documentar a descrição de cada um deles. Agora, o engenheiro sabe as características técnicas de todos os modelos de motores existentes, mas não pode desmontar os equipamentos para determinar quem é quem. Tendo apenas medições de entrada e saída dos motores, o que pode ser feito para se determinar o modelo mais provável de cada um deles?

Abordagens de múltiplos modelos

Motivados pelas situações apresentadas, consideremos as seguintes hipóteses:

- O sistema em estudo transita entre diferentes modos (estados discretos), cada um deles caracterizado por um modelo dinâmico distinto (Figura 1);
- Sabe-se que o sistema obedece um dentre vários diferentes modelos, mas não se sabe qual (Figura 2).





Figura 1: Sistema híbrido com chaveamento entre modelos.



?

Figura 2: Hipóteses de modelo para um mesmo sistema.

Introdução ao Interacting Multiple Model (IMM)

- Artigo introdutor: H.A.P. Blom, *An Efficient Filter for Abruptly Changing Systems*, 1984 [1].
- Motivação para o desenvolvimento do algoritmo: problema de rastreamento de aeronaves em sistemas de controle de tráfego aéreo.
 - Necessidade de rastreamento de aeronaves nos modos de vôo retilíneo e manobras.

Segundo [2], temos:

- O estimador IMM é um filtro híbrido subótimo;
- É uma das melhores opções para estimação híbrida em termos de custo e eficiência;
- Sua principal característica é a sua habilidade de estimar o estado de um sistema dinâmico com diferentes modelos que chavessem entre si;
- Filtro auto-ajustável com largura de banda variável;
- Bom compromisso entre complexidade computacional e desempenho:
 - Custo computacional aproximadamente linear em relação ao número de modos;
 - Desempenho muito semelhante ao de algoritmos com complexidade quadrática.

Estado da Arte

- Introdutores
 - H.A.P. Blom, *An Efficient Filter for Abruptly Changing Systems*, 1984 [1];
 - H.A.P. Blom e Y. Bar-Shalom, *The Interacting Multiple Model Algorithm for Systems with Markovian Switching Coefficients*, 1988 [3].
- Desempenho
 - X.R. Li e Y. Bar-Shalom, *Performance Prediction of the Interacting Multiple Model Algorithm*, 1993 [4];
 - L.A. Johnston e V. Krishnamurthy, *An Improvement to the Interacting Multiple Model (IMM) Algorithm*, 2001 [5];
 - T. Kirubarajan e Y. Bar-Shalom, *Kalman Filter Versus IMM Estimator: When Do We Need the Latter?*, 2003 [6];
 - C.E. Seah e I. Hwang, *Stability Analysis of the Interacting Multiple Model Algorithm*, 2008 [7];
- Métodos de estimação diferentes do Filtro de Kalman
 - Y. Boers e J.N. Driessen, *Interacting multiple model particle filter*, 2003 [8];
 - J. Wang, D. Zhao, W. Gao e S. Shan, *Interacting Multiple Model Particle Filter To Adaptive Visual Tracking*, 2004 [9];
 - R. Guo, Z. Qin, X. Li e J. Chen, *Interacting Multiple Model Particle-type Filtering Approaches to Ground Target Tracking*, 2008 [10];
- Telecomunicações
 - C. Ramesh e V. Vaidehi, *IMM Based Kalman Filter for Channel Estimation in UWB OFDM Systems*, 2007 [11];

- Rastreamento e estimação

- A. Houles e Y. Bar-Shalom, *Multisensor Tracking of a Maneuvering Target in Clutter*, 1989 [12];
- X.R. Li e Y. Bar-Shalom, *Design of an Interacting Multiple Model Algorithm for Air Traffic Control Tracking*, 1993 [13];
- M. Yeddanapudi, Y. Bar-Shalom e K.R. Pattipati, *IMM Estimation for Multitarget-Multisensor Air Traffic Surveillance*, 1997 [14];
- E. Mazor, A. Averbuch, Y. Bar-Shalom e J. Dayan, *Interacting Multiple Model Methods in Target Tracking: A Survey*, 1998 [2];
- W. Schmaedeke e K. Kastella, *Sensor Management using Discrimination Gain and Interacting Multiple Model Kalman Filters*, 1998 [15];
- Y. Bar-Shalom, X.R. Li e T. Kirubarajan, *Estimation with Applications to Tracking and Navigation*, 2001 [16];
- I. Hwang, H. Balakrishnan e C. Tomlin, *State estimation for hybrid systems: applications to aircraft tracking*, 2006 [17];
- J. Buret, O. Aycard, A. Spalanzani e C. Laugier, *Pedestrian Tracking in car parks : an Adaptive Interacting Multiple Models based Filtering Method*, 2006 [18];
- J.B.B. Gomes, *An Overview on Target Tracking Using Multiple Model Methods*, 2008 [19];
- M.E. Farmer, R.L. Hsu e A.K. Jain, *Interacting Multiple Model (IMM) Kalman Filters for Robust High Speed Human Motion Tracking*, [20].

Descrição do Sistema

Sistema linear com saltos Markovianos

$$\begin{aligned}x_k &= A(\theta_k)x_{k-1} + B(\theta_k)v_k \\y_k &= C(\theta_k)x_k + D(\theta_k)w_k\end{aligned}\tag{1}$$

- $\theta_k \in \{1, \dots, N\}$ é uma cadeia de Markov com matriz de transição H ;
- $v_k \sim N(0, Q)$ e $w_k \sim N(0, R)$ são processos Gaussianos independentes;
- As matrizes $A(\theta_i)$, $B(\theta_i)$, $C(\theta_i)$ e $D(\theta_i)$ são conhecidas para cada modo θ_i .

Motivação para o Algoritmo

Considere o processo Markoviano (x_k, θ_k) descrito por (1). Dado um conjunto de medidas ruidosas Y_k obtidas até o instante k , queremos estimativas tanto do estado \hat{x}_k quanto do modo $\hat{\theta}_k$ do sistema no instante k .

Contudo, a transição $\theta_j \rightarrow \theta_i$ entre os modos do sistema é desconhecida, supondo-se conhecidas apenas as probabilidades $H_{i,j}$ da matriz de transição de estados H .

Como fazer para estimar \hat{x}_k e $\hat{\theta}_k$?

Segundo [3], podemos dividir o problema em cinco partes. Supondo $\theta_k = i$, $i \in \{1, \dots, N\}$, temos

- 1 Estimar a probabilidade do modo por predição;

$$P[\theta_{k-1} | Y_{k-1}] \rightarrow P[\theta_k | Y_{k-1}]$$

- 2 Atualizar a distribuição de \hat{x}_{k-1} a partir da atualização de θ_k ;

$$p[x_{k-1} | \theta_{k-1}, Y_{k-1}] \rightarrow p[x_{k-1} | \theta_k, Y_{k-1}]$$

- 3 Propagar a estimativa \hat{x}_k por predição;

$$p[x_{k-1} | \theta_k, Y_{k-1}] \rightarrow p[x_k | \theta_k, Y_{k-1}]$$

- 4 Corrigir a estimativa \hat{x}_k por meio da nova medição;

$$p[x_k | \theta_k, Y_{k-1}] \rightarrow p[x_k | \theta_k, Y_k]$$

- 5 Corrigir a probabilidade do modo $\theta_k = i$ por meio da nova medição;

$$P[\theta_k | Y_{k-1}] \rightarrow P[\theta_k | Y_k]$$

Determinemos expressões para cada um dos passos anteriores

- 1 Aplicando a equação de Chapman-Kolmogorov à cadeia de Markov θ_k , temos

$$P[\theta_k = i | Y_{k-1}] = \sum_j H_{i,j} P[\theta_{k-1} = j | Y_{k-1}] \rightarrow \hat{\theta}_{k|k-1}. \quad (2)$$

- 2 A partir da Lei da Probabilidade Total, temos a expressão

$$p[x_{k-1} | \theta_k = i, Y_{k-1}] = \sum_j [p[x_{k-1} | \theta_{k-1} = j, \theta_k = i, Y_{k-1}] \cdot P[\theta_{k-1} = j | \theta_k = i, Y_{k-1}]] \quad (3)$$

Como θ_k é independente de x_{k-1} se θ_{k-1} é conhecido¹, chega-se à expressão

$$p[x_{k-1} | \theta_{k-1} = j, \theta_k = i, Y_{k-1}] = p[x_{k-1} | \theta_{k-1} = j, Y_{k-1}]. \quad (4)$$

Pela fórmula de Bayes,

$$P[\theta_{k-1} = j | \theta_k = i, Y_{k-1}] = H_{i,j} \frac{P[\theta_{k-1} = j | Y_{k-1}]}{P[\theta_k = i | Y_{k-1}]}. \quad (5)$$

Substituindo (4) e (5) em (3), temos

$$p[x_{k-1} | \theta_k = i, Y_{k-1}] = \sum_j H_{i,j} P[\theta_{k-1} = j | Y_{k-1}] \frac{p[x_{k-1} | \theta_{k-1} = j, Y_{k-1}]}{P[\theta_k = i | Y_{k-1}]} \quad (6)$$

¹A transição de estados em uma cadeia de Markov é função apenas do estado anterior.

- 3 Etapa de predição do Filtro de Kalman a partir do modelo (1)

$$\hat{\mathbf{x}}_{k|k-1} = A(\hat{\theta}_{k|k-1})\hat{\mathbf{x}}_{k-1} \quad (7)$$

$$P_{k|k-1} = A(\hat{\theta}_{k|k-1})P_{k-1}A(\hat{\theta}_{k|k-1})^T + B(\hat{\theta}_{k|k-1})QB(\hat{\theta}_{k|k-1})^T \quad (8)$$

- 4 Etapa de correção da estimativa do Filtro de Kalman

$$K_k = P_{k|k-1}C(\hat{\theta}_{k|k-1})^T \left(C(\hat{\theta}_{k|k-1})P_{k|k-1}C(\hat{\theta}_{k|k-1})^T + D(\hat{\theta}_{k|k-1})RD(\hat{\theta}_{k|k-1})^T \right)^{-1} \quad (9)$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_{k|k-1} + K_k(y_k - C(\hat{\theta}_{k|k-1})\hat{\mathbf{x}}_{k|k-1}) \quad (10)$$

$$P_k = (\mathbb{I} - K_kC(\hat{\theta}_{k|k-1}))P_{k|k-1}(\mathbb{I} - K_kC(\hat{\theta}_{k|k-1}))^T + K_kD(\hat{\theta}_{k|k-1})RD(\hat{\theta}_{k|k-1})^TK_k^T \quad (11)$$

- 5 Definindo y_k como a medição tomada no instante k , temos a seguinte relação a partir da fórmula de Bayes

$$p(\theta_k | Y_k) = p(\theta_k | y_k, Y_{k-1}) = \frac{p(y_k | \theta_k, Y_{k-1}) p(\theta_k | Y_{k-1})}{p(y_k | Y_{k-1})} \rightarrow \hat{\theta}_k \quad (12)$$

Observação

Para uma cadeia de Markov $\theta_k \in \{1, \dots, N\}$, o algoritmo IMM utiliza N Filtros de Kalman, cada um deles estimando os parâmetros do modelo $\theta_k = i, i \in \{1, \dots, N\}$.

O Algoritmo IMM

De acordo com [1, 3], o algoritmo IMM consiste dos quatro passos seguintes:

- 1 Sejam $\hat{p}_n(k-1)$ a probabilidade do modo $\theta_{k-1} = n$, $\hat{x}_n(k-1)$ a estimativa do Filtro de Kalman que rastreia o modo $\theta_k = n$ no instante $k-1$ e $\hat{P}_n(k-1)$ sua matriz de covariância associada. A condição inicial combinada, no instante k , para o Filtro de Kalman que rastreia o modo $\theta_k = i$, $i \in \{1, \dots, N\}$, é calculada por meio das equações

$$\bar{p}_i(k) = \sum_j H_{i,j} \hat{p}_j(k-1), \bar{p}_i(k) \neq 0, \quad (13)$$

$$\hat{x}^i(k-1) = \sum_j \frac{H_{i,j} \hat{p}_j(k-1) \hat{x}_j(k-1)}{\bar{p}_i(k)}, \quad (14)$$

$$\hat{P}^i(k-1) = \sum_j \frac{H_{i,j} \hat{p}_j(k-1) \left[\hat{P}_j(k-1) + \left(\hat{x}_j(k-1) - \hat{x}^i(k-1) \right) (\cdot)^T \right]}{\bar{p}_i(k)}. \quad (15)$$

- 2 O par $(\hat{x}^i(k-1), \hat{P}^i(k-1))$ é usado como condição inicial para o Filtro de Kalman que rastreia o modo $\theta_k = i$, $i \in \{1, \dots, N\}$. A etapa de predição gera $(\bar{x}_i(k), \bar{P}_i(k))$, seguido do resultado $(\hat{x}_i(k), \hat{P}_i(k))$ da etapa de correção.
- 3 A probabilidade predita $\bar{p}_i(k)$ do modo $\theta_k = i$ é atualizada a partir da inovação do Filtro de Kalman de seu modo

$$\begin{aligned} \vartheta_i(k) &= y_k - C(i)\bar{x}_i(k), \\ V_i(k) &= C(i)\bar{P}_i(k)C^T(i) + D(i)RD^T(i), \\ \hat{p}_i(k) &= \frac{\bar{p}_i(k)}{c\|V_i(k)\|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}\vartheta_i^T(k)V_i^{-1}(k)\vartheta_i(k)\right\}, \end{aligned}$$

em que c é uma constante de normalização.

- 4 Finalmente, as saídas do estimador podem ser dadas por

$$\hat{x}_k = \sum_i \hat{p}_i(k) \hat{x}_i(k),$$
$$\hat{P}_k = \sum_i \hat{p}_i(k) \left[\hat{P}_i(k) + (\hat{x}_i(k) - \hat{x}_k) (\cdot)^T \right].$$

Discussão

A evolução das estimativas no algoritmo IMM advém diretamente das equações anteriormente apresentadas:

- Passo 1 \rightarrow Equações (2) e (6);
- Passo 2 \rightarrow Equações (7)-(11);
- Passo 3 \rightarrow Equação (12);

Dentre os passos do algoritmo, apenas 1 é típico do IMM [3]. Dentre suas equações, (14) e (15), derivadas de (6), merecem atenção especial. A equação (13) é a mesma que (2). O Passo 2 é uma aplicação direta das equações do Filtro de Kalman, enquanto o Passo 3 é um resultado simples da fórmula de Bayes.

Uma questão razoável neste momento:

Questão

Qual é a justificativa para a etapa de combinação de estimativas do Passo 1 do algoritmo IMM, descrita por (14) e (15)?

Esta questão pode ser respondida por meio da análise de (6), repetida abaixo por conveniência

$$p[x_{k-1} | \theta_k = i, Y_{k-1}] = \sum_j H_{i,j} P[\theta_{k-1} = j | Y_{k-1}] \frac{p[x_{k-1} | \theta_{k-1} = j, Y_{k-1}]}{P[\theta_k = i | Y_{k-1}]}$$

Reescrevendo a equação, temos

$$p[x_{k-1}|\theta_k = i, Y_{k-1}] = \sum_j \alpha_j p[x_{k-1}|\theta_{k-1} = j, Y_{k-1}]$$

Mesmo que $p[x_0|Y_0]$ seja Gaussiano, em geral $p[x_k|\theta_k = i, Y_k]$ é uma soma ponderada de N^{k-1} Gaussianas [3]. Esta soma é fruto de nosso desconhecimento acerca das transições entre os modos do sistema e o diagrama da Figura 3 procura ilustrá-lo.




Figura 3: Diagrama de evolução do histórico dos modos.

Com o aumento do número k de iterações, o custo computacional de processamento de $p[x_{k-1}|\theta_k = i, Y_{k-1}]$ torna-se proibitivo e inviabiliza uma abordagem de estimação ótima, visto que seria necessário um filtro associado a cada um dos possíveis históricos dos modos [3, 19, 16].

O que fazer?

$$p[x_{k-1}|\theta_{k-1} = i, Y_{k-1}] \sim N(\hat{x}_i(k-1), \hat{R}_i(k-1)) \quad (16)$$

(Abordagem de fusão com profundidade fixa - *Fixed depth merging approach* [3])

Com o aumento do número k de iterações, o custo computacional de processamento de $p[x_{k-1}|\theta_k = i, Y_{k-1}]$ torna-se proibitivo e inviabiliza uma abordagem de estimação ótima, visto que seria necessário um filtro associado a cada um dos possíveis históricos dos modos [3, 19, 16].

O que fazer?

$$p[x_{k-1}|\theta_{k-1} = i, Y_{k-1}] \sim N(\hat{x}_i(k-1), \hat{R}_i(k-1)) \quad (16)$$

(Abordagem de fusão com profundidade fixa - *Fixed depth merging approach* [3])

Substituindo (16) em (6) e definindo $W = \{x_{k-1} | \theta_k = i, Y_{k-1}\}$, temos

$$p[W] = \sum_j H_{i,j} P[\theta_{k-1} = j | Y_{k-1}] \frac{P[x_{k-1} | \theta_{k-1} = j, Y_{k-1}]}{P[\theta_k = i | Y_{k-1}]},$$

$$\begin{aligned} \hat{x}^i(k-1) &\triangleq E\{W\} \\ &= \sum_j \frac{H_{i,j} \hat{p}_j(k-1) \hat{x}_j(k-1)}{\bar{p}_i(k)} \rightarrow (14), \end{aligned}$$

$$\begin{aligned} \hat{P}^i(k-1) &\triangleq E\{(W - E\{W\})(W - E\{W\})^T\}, \\ &= \sum_j \frac{H_{i,j} \hat{p}_j(k-1) [\hat{P}_j(k-1) + (\hat{x}_j(k-1) - \hat{x}^i(k-1)) (\cdot)^T]}{\bar{p}_i(k)} \rightarrow (15). \end{aligned}$$

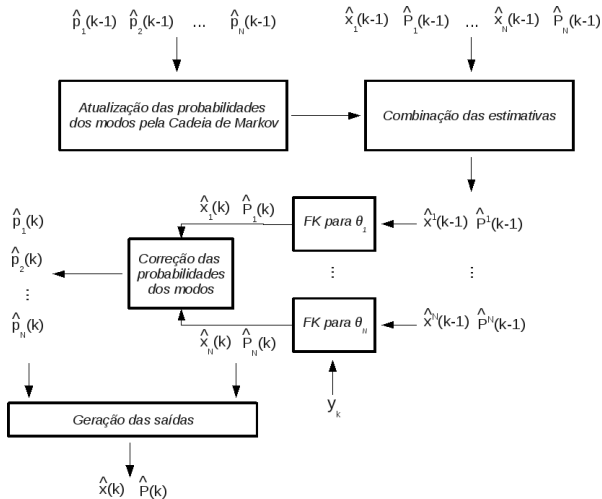


Figura 4: Diagrama do algoritmo IMM.

Modelos Múltiplos Autônomos (AMM)

- 1 Caso particular do IMM $\implies H = \mathbb{I}_{N \times N}$;
- 2 Cada filtro opera de forma independente;
- 3 Suposições:
 - O modelo verdadeiro é invariante no tempo;
 - o modelo verdadeiro sempre opera como um dos modos do modelo.
- 4 Não lida adequadamente com sistemas que transitam entre os seus modos.

Descrição do problema

Problema

Rastreador para um sistema de Controle de Tráfego Aéreo (CTA) [16].

Estimadores

- Filtro de Kalman para movimento uniforme;
- Filtro de Kalman para manobra;
- Filtro IMM de dois modos.




Figura 5: Rastreamento de aeronave.

Modelamento do CTA

Modos de operação de um avião civil

- Movimento uniforme \implies linha reta com velocidade e curso constante.
- Manobra \implies curva, subida ou descida.

Movimento Uniforme (MU)

Ruído branco de aceleração

$$x(k+1) = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} x(k) + \begin{bmatrix} \frac{1}{2}T^2 & 0 \\ T & 0 \\ 0 & \frac{1}{2}T^2 \\ 0 & T \end{bmatrix} v(k)$$

$$z = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} x(k) + w(k)$$

$$x = [\xi \dot{\xi} \eta \dot{\eta}]'$$

- ξ e η são as coordenadas (posição) do plano cartesiano.
- $v_k \sim N(0, Q)$ e $w_k \sim N(0, R)$ são ruídos Gaussianos independentes.

Modelo de Manobra

Coordinated turn

$$x(k+1) = \begin{bmatrix} 1 & \frac{\sin(\Omega(k)T)}{\Omega(k)} & 0 & -\frac{1-\cos(\Omega(k)T)}{\Omega(k)} & 0 \\ 0 & \cos(\Omega(k)T) & 0 & -\sin(\Omega(k)T) & 0 \\ 0 & \frac{1-\cos(\Omega(k)T)}{\Omega(k)} & 1 & \frac{\sin(\Omega(k)T)}{\Omega(k)} & 0 \\ 0 & \sin(\Omega(k)T) & 0 & \cos(\Omega(k)T) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} x(k) + \begin{bmatrix} \frac{1}{2}T^2 & 0 & 0 \\ \frac{1}{2}T^2 & 0 & 0 \\ 0 & T & 0 \\ 0 & 0 & T \\ 0 & 0 & 0 \end{bmatrix} v(k)$$

$$z = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix} x(k) + w(k)$$

$$x = [\xi \ \dot{\xi} \ \eta \ \dot{\eta} \ \Omega]'$$

- ξ e η são as coordenadas (posição) do plano cartesiano.
- Ω é a velocidade angular.
- $v_k \sim N(0, Q)$ e $w_k \sim N(0, R)$ são ruídos Gaussianos independentes.

Linearização da Função

Para velocidade angular não constante, torna-se necessário utilizar alguma técnica de filtragem não-linear, tendo sido escolhido o Filtro de Kalman Estendido (EKF).

EKF para o CT

$$x(k+1) = f[k, x(k)] + G_{CT}(k)v(k)$$

Expandindo a função f em uma série de Taylor em torno da última estimativa $\hat{x}(k|k)$ e tomando apenas o termo de primeira ordem, temos

$$x(k+1) = f[k, x(k)] + f_x(k)(x(k) - \hat{x}(k|k)) + G_{CT}(k)v(k)$$

em que

$$f_x(k) = \left[\nabla_x f(k, x)' \right]' \Big|_{x=\bar{x}(k|k)}$$

$$= \begin{bmatrix} 1 & \frac{\sin(\Omega(k)T)}{\Omega(k)} & 0 & -\frac{1-\cos(\Omega(k)T)}{\Omega(k)} & f_{\Omega,1}(k) \\ 0 & \cos(\Omega(k)T) & 0 & -\sin(\Omega(k)T) & f_{\Omega,2}(k) \\ 0 & \frac{1-\cos(\Omega(k)T)}{\Omega(k)} & 1 & \frac{\sin(\Omega(k)T)}{\Omega(k)} & f_{\Omega,3}(k) \\ 0 & \sin(\Omega(k)T) & 0 & \cos(\Omega(k)T) & f_{\Omega,4}(k) \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\begin{bmatrix} f_{\Omega,1}(k) \\ f_{\Omega,2}(k) \\ f_{\Omega,3}(k) \\ f_{\Omega,4}(k) \end{bmatrix} = \begin{bmatrix} \frac{\cos(\Omega(k)T)T\dot{\xi}}{\Omega(k)} - \frac{\sin(\Omega(k)T)\dot{\xi}}{\Omega(k)^2} - \frac{\sin(\Omega(k)T)T\dot{\eta}}{\Omega(k)} - \frac{(-1+\cos(\Omega(k)T))\dot{\eta}}{\Omega(k)^2} \\ -\sin(\Omega(k)T)T\dot{\xi} - \cos(\Omega(k)T)T\dot{\eta} \\ \frac{\sin(\Omega(k)T)T\dot{\xi}}{\Omega(k)} - \frac{(-1+\cos(\Omega(k)T))\dot{\xi}}{\Omega(k)^2} + \frac{\cos(\Omega(k)T)T\dot{\eta}}{\Omega(k)} - \frac{\sin(\Omega(k)T)\dot{\eta}}{\Omega(k)^2} \\ \cos(\Omega(k)T)T\dot{\xi} - \cos(\Omega(k)T)T\dot{\eta} \end{bmatrix}$$

obs: para Ω pequeno, usa-se $\lim_{\Omega \rightarrow 0}(f_x(k))$

Modelo EKF para CT final

Predição

$$\hat{x}(k+1|k) = f[k, \hat{x}(k|k)]$$

$$P(k+1|k) = f_x(k)P(k|k)f_x(k)' + G_{CT}Q(k)G_{CT}'$$

Mistura de estados com diferentes dimensões

- $\dim(MU) = 4$ e $\dim(CT) = 5 \implies$ problema na mistura do IMM;
- Solução: aumenta o estado do modo que for usar o MU como modelo.

Escolha dos Parâmetros

Comentários

- É bom que o ruído de processo do MU seja pequeno, mas pode ser usado um pouco grande para modelar pequenas curvas e acelerações.
- O ruído de processo do CT depende de quanto se espera de velocidade angular e de quantos modelos serão usados.
- A matriz de transição de probabilidade não influencia muito \implies probabilidades baseadas no tempo médio em cada modo.

Simulação

Simulating. Please, wait.

Conclusões

- Realizar a estimação linear ótima de sistemas com parâmetros Markovianos é computacionalmente impraticável, visto que a quantidade de hipóteses é $O(N^k)$. O estimador IMM tem custo aproximadamente linear com o número de modos, enquanto suas estimativas são comparáveis a de métodos de complexidade quadrática;
- Em aplicações práticas de filtragem com número de modos $N = 2$, o algoritmo IMM é a melhor primeira escolha [3];
- A aproximação introduzida por (16) pode tornar o estimador IMM inadequado em situações em que o número N de modos é grande. Nestes casos, deve-se considerar algoritmos de maior complexidade;
- A escolha dentre múltiplos do método AMM é um caso particular do IMM;
- Em geral, o Filtro de Kalman fornece estimativas inferiores às de um estimador IMM adequadamente ajustado [16];
- A capacidade do estimador IMM de detectar rapidamente transições entre modos do sistema (manobras) torna-o uma boa escolha para situações de rastreamento de alvos [16];
- Caso os múltiplos modelos estimados sejam semelhantes, o estimador IMM não é capaz distingui-los, tornando-o uma versão “disfarçada” do FK;
- A revisão do estado da arte mostrou que a abordagem IMM pode ser aplicada em muitos casos reais;

- [1] H.A.P. Blom.
An efficient filter for abruptly changing systems.
Proceeding of 23rd Conference on Decision and Control, 4(30):656–658, Dezembro 1984.
- [2] E. Mazor, A. Averbuch, Y. Bar-Shalom, and J. Dayan.
Interacting multiple model methods in target tracking: A survey.
IEEE Transactions on Aerospace and Electronic Systems, 34(1):103–123, Janeiro 1998.
- [3] H.A.P. Blom and Y. Bar-Shalom.
The interacting multiple model algorithm for systems with markovian switching coefficients.
IEEE Transactions on Automatic Control, 33(8):780–783, Agosto 1988.
- [4] X.R. Li and Y. Bar-Shalom.
Performance prediction of the interacting multiple model algorithm.
IEEE Transactions on Aerospace and Electronic Systems, 29(3):755–771, Julho 1993.
- [5] L.A. Johnston and V. Krishnamurthy.
An improvement to the interacting multiple model (IMM) algorithm.
IEEE Transactions on Signal Processing, 49(12):2909–2923, Dezembro 2001.
- [6] T. Kirubarajan and Y. Bar-Shalom.
Kalman filter versus imm estimator: When do we need the latter?
IEEE Transactions on Aerospace and Electronic Systems, 39(4):1452–1457, Outubro 2003.
- [7] C.E. Seah and I. Hwang.
Stability analysis of the interacting multiple model algorithm.
American Control Conference, pages 2415–2420, Junho 2008.
- [8] Y. Boers and J.N. Driessen.
Interacting multiple model particle filter.
IEE Proc.-Radar Sonar Navig., 150(5):344–349, Outubro 2003.

- [9] J. Wang, D. Zhao, W. Gao, and S. Shan.
Interacting multiple model particle filter to adaptive visual tracking.
Proceedings of the Third International Conference on Image and Graphics, 2004.
- [10] R. Guo, Z. Qin, X. Li, and J. Chen.
Interacting multiple model particle-type filtering approaches to ground target tracking.
Journal of Computers, 3(7):23–30, Julho 2008.
- [11] C. Ramesh and V. Vaidehi.
Imm based kalman filter for channel estimation in uwb ofdm systems.
IEEE-ICSCN, pages 320–325, Fevereiro 2007.
- [12] A. Houles and Y. Bar-Shalom.
Multisensor tracking of a maneuvering target in clutter.
IEEE Transactions on Aerospace and Electronic Systems, AES-25(2):176–189, Março 1989.
- [13] X.R. Li and Y. Bar-Shalom.
Design of an interacting multiple model algorithm for air traffic control tracking.
IEEE Transactions on Control Systems Technology, 1(3):186–194, Setembro 1993.
- [14] M. Yeddanapudi, Y. Bar-Shalom, and K.R. Pattipati.
Imm estimation for multitarget-multisensor air traffic surveillance.
Proceedings of the IEEE, 85(1):80–94, Janeiro 1997.
- [15] W. Schmaedeke and K. Kastella.
Sensor management using discrimination gain and interacting multiple model kalman filters.
Lockheed-Martin Tactical Defense Systems - Eagan, 1998.
- [16] Y. Bar-Shalom, X.R. Li, and T. Kirubarajan.
Estimation with Applications to Tracking and Navigation.
John Wiley & Sons, 2001.

- [17] I. Hwang, H. Balakrishnan, and C. Tomlin.
State estimation for hybrid systems: applications to aircraft tracking.
IEE Proc.-Control Theory Appl., 153(5):556–566, Setembro 2006.
- [18] J. Burlet, O. Aycard, A. Spalanzani, and C. Laugier.
Pedestrian tracking in car parks : an adaptive interacting multiple models based filtering method.
Proceedings of the IEEE ITSC 2006, pages 462–467, Setembro 2006.
- [19] J.B.B. Gomes.
An Overview on Target Tracking Using Multiple Model Methods.
PhD thesis, Universidade Técnica de Lisboa, 2008.
- [20] M.E. Farmer, R.L. Hsu, and A.K. Jain.
Interacting multiple model (imm) kalman filters for robust high speed human motion tracking.
Preprint.