

* Filtro de Kalman

O conceito de filtragem de Kalman está intimamente ligado à noção de estimação recursiva MMSE, tendo como pano de fundo a definição do espaço de estados do sistema dinâmico tratado.

- Definição do Problema

- parâmetros de interesse associados à operação de um sistema dinâmico variam com o tempo.
- estes parâmetros apresentam erros de medição ou não podem ser observados diretamente. Somente podemos recorrer a medidas ruidosas de grandezas disponíveis para obter informações sobre os parâmetros internos.

Estado: conjunto mínimo de variáveis que fornece uma representação completa das condições internas do sistema em um dado instante de tempo. Em um instante k_0 , o estado juntamente com a entrada para $k \geq k_0$ determina de maneira única a saída do sistema para $k \geq k_0$.

Representação de um sistema dinâmico linear a tempo discreto


$$(1) \quad \underline{h}_k = F_k \underline{h}_{k-1} + G_k \underline{w}_k$$

Equação de processo \rightarrow pode incluir uma entrada externa do tipo $B_k \underline{u}_k$

$$(2) \quad \check{y}_k = X_k \underline{h}_k + \tilde{\eta}(k)$$

Equação de medida

A primeira equação define a dinâmica dos variáveis de estado, enquanto a segunda relaciona estas variáveis aos sinais que efetivamente conseguimos observar.



- h_k : vetor de estados que desejamos estimar a cada instante k .
- F_k : matriz de transição de estados - descreve a evolução temporal dos variáveis de estado entre os instantes $k-1$ e k
- w_k : vetor de ruído de processo (ou de excitação)
- X_k : matriz de medida (observação)
- \tilde{n}_k : ruído aditivo de medida.

• os ruídos w_k e \tilde{n}_k são brancos, descorrelacionados, de média nula e matrizes de covariância dadas por $E\{w_k w_l^T\} = \begin{cases} Q_k, & k=l \\ 0, & k \neq l \end{cases}$
 e $E\{\tilde{n}_k \tilde{n}_l^T\} = \begin{cases} R_k, & k=l \\ 0, & k \neq l \end{cases}$

Objetivo: a partir do conhecimento da dinâmica do sistema (modelo) e do sinal observado $\tilde{y}_1, \dots, \tilde{y}_n$, queremos estimar o vetor h_i

- * Filtragem: $i = n$
- * Predição: $i > n$
- * Suavização: $0 \leq i \leq n$

Critério para estimação: mínimo erro quadrático médio (MMSE)

Vimos no tópico inicial deste curso que o estimador MMSE é obtido pela média condicional dos parâmetros desconhecidos (variáveis de estado) dados os sinais observados:

$$\hat{\underline{h}}_{\text{MMSE}} = E \{ \underline{h} | \{ \tilde{\underline{y}} \} \}, \text{ onde } \{ \tilde{\underline{y}} \} \text{ denota a sequência observada disponível.}$$


⇒ Como o estado possui natureza dinâmica, é interessante desenvolver algoritmos que calculem a estimativa ótima a cada instante de tempo. Se nos restringirmos aos estimadores lineares - cujas estimativas são dadas por combinações lineares dos medidos disponíveis - a solução ótima é dada pelo filtro de Kalman.

Características iniciais:

- fornece uma solução recursiva de mínimo erro quadrático médio para o problema de estimação de estados.
- a recursão evita o armazenamento de todo o histórico de sinais observados, tornando o algoritmo computacionalmente eficiente.
- versatilidade para trabalhar em ambientes estacionários e não-estacionários.

*Derivação do Filtro de Kalman

O processo recursivo da filtragem de Kalman pode ser dividido em duas etapas: (i) na fase de predição, a equação de processo é usada para prever o estado em um instante k a partir da estimativa do estado calculada no instante $k-1$; (ii) na fase de filtragem, os valores preditos para as variáveis de estado são corrigidos (atualizados) com base na equação de medida e na observação do instante k .



$\hat{h}_{k-1|k-2}$ representa a estimativa do estado no instante $k-1$ baseada nos sinais observados até o instante $k-2$.

• a melhor estimativa do estado no instante k , dada a observação dos sinais \tilde{y} do instante inicial até k , é calculada como:

$$\hat{h}_{k|k} = E \{ h_k | \tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_k \}$$

Se, porém, tivermos acesso às medidas até o instante $k-1$, podemos computer uma estimativa a priori do estado:

$$\hat{h}_{k|k-1} = E\{h_k | \tilde{y}_1, \dots, \tilde{y}_{k-1}\}$$

Usando a equação de estado, podemos escrever:

$$\begin{aligned} \hat{h}_{k|k-1} &= E\{F_k h_{k-1} + G_k w_k | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} \\ &= F_k E\{h_{k-1} | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} + G_k E\{w_k | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} \end{aligned}$$

Como w_k é independente das observações passadas,

$$= F_k E\{h_{k-1} | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} + G_k \cancel{E\{w_k\}} \rightarrow 0$$

$$= \underline{F_k \cdot \hat{h}_{k-1|k-1}} \quad (1)$$

O desempenho (ou qualidade) de um estimador pode ser calculado através da matriz de covariância do erro de estimação:

$$\begin{aligned} P_{k|k-1} &= E\{(h_k - \hat{h}_{k|k-1})(h_k - \hat{h}_{k|k-1})^H\} \\ &= E\{[F_k h_{k-1} + G_k w_k - F_k \hat{h}_{k-1|k-1}][F_k h_{k-1} + G_k w_k - F_k \hat{h}_{k-1|k-1}]^H\} \\ &= E\{[F_k (h_{k-1} - \hat{h}_{k-1|k-1}) + G_k w_k][F_k (h_{k-1} - \hat{h}_{k-1|k-1}) + G_k w_k]^H\} \\ &= F_k E\{(h_{k-1} - \hat{h}_{k-1|k-1})(h_{k-1} - \hat{h}_{k-1|k-1})^H\} F_k^H + G_k E\{w_k w_k^H\} G_k^H \\ &= \underline{F_k P_{k-1|k-1} F_k^H + G_k Q_k G_k^H} \quad (2) \end{aligned}$$

A equações (1) e (2) dependem do conhecimento da dinâmica do sistema e da estimativa do estado no instante anterior ($\hat{h}_{k-1|k-1}$) \Rightarrow por isso, elas formam a etapa de predição.

O próximo passo é entender como os sinais observados são utilizados para refinar a estimativa produzida na etapa de predição.

• Estimador linear recursivo: $\hat{h}_{k|k} = \hat{h}_{k|k-1} + K_k \underbrace{(\tilde{y}_k - \chi_k \hat{h}_{k|k-1})}_{\text{erro}}$

Qual o valor ótimo de K_k ?

estimativa da observação k usando as informações até $k-1$

$J_k = \text{Tr}\{P_{k|k}\}$, onde $P_{k|k}$ é a matriz de covariância do erro de estimação do estado.

Ora, $e_{k|k} = h_k - \hat{h}_{k|k}$

$$\begin{aligned} &= \underbrace{h_k - \hat{h}_{k|k-1}}_{e_{k|k-1}} - K_k (\tilde{y}_k - \chi_k \hat{h}_{k|k-1}) \\ &= e_{k|k-1} - K_k (\chi_k h_k + \tilde{\eta}_k - \chi_k \hat{h}_{k|k-1}) \\ &= e_{k|k-1} - K_k (\chi_k (h_k - \hat{h}_{k|k-1}) + \tilde{\eta}_k) \\ &= e_{k|k-1} - K_k \chi_k e_{k|k-1} - K_k \tilde{\eta}_k \\ &= (\mathbf{I} - K_k \chi_k) e_{k|k-1} - K_k \tilde{\eta}_k \end{aligned}$$

Então, $P_{k|k} = E\{e_{k|k} \cdot e_{k|k}^H\}$
 $= E\{[(\mathbf{I} - K_k \chi_k) e_{k|k-1} - K_k \tilde{\eta}_k][\dots]^H\}$

Os termos cruzados do erro com o ruído serão cancelados pois o ruído é independente do erro e possui média nula. Logo,

$$P_{k|k} = (\mathbf{I} - K_k \chi_k) P_{k|k-1} (\mathbf{I} - K_k \chi_k)^H + K_k R_k K_k^H (*)$$

MÍNIMA COVARIÂNCIA DO ERRO : $\frac{\partial J_k}{\partial K_k} = 0$

$$\frac{\partial J_k}{\partial K_k} = \frac{\partial \text{Tr}\{P_{k|k}\}}{\partial K_k} = 0$$

Propriedade: $\frac{\partial \text{Tr}\{ABA^H\}}{\partial A} = 2AB$ se B é simétrica.

$$\frac{\partial J_k}{\partial K_k} = 2(I - K_k X_k) P_{k|k-1} (-X_k^H) + 2K_k R_k = 0$$

Solução: $K_k = P_{k|k-1} X_k^H (X_k P_{k|k-1} X_k^H + R_k)^{-1}$ (3)

Voltando à equação do estimador linear recursivo:


$$\hat{h}_{k|k} = \hat{h}_{k|k-1} + K_k (\tilde{y}_k - X_k \hat{h}_{k|k-1})$$

erro de "predição" de \tilde{y}_k a partir de $\hat{h}_{k|k-1}$:

$$\alpha_k = \tilde{y}_k - X_k \hat{h}_{k|k-1} \quad (4)$$

Logo, $\hat{h}_{k|k} = \hat{h}_{k|k-1} + K_k \alpha_k$ (5)

As duas etapas do processo de filtragem de Kalman podem ser resumidas no seguinte diagrama de blocos.



Observe que o modelo dinâmico do sistema faz parte do filtro de Kalman. Assim, o termo $K_k \underline{\alpha}_k$ do filtro de Kalman pode ser visto como uma estimativa do ruído de excitação $G_k \underline{w}_k$.

É justamente pelo fato de o filtro de Kalman usar uma "cópia" do modelo dinâmico do sistema que ele é capaz de restituir a evolução temporal do estado.

A última operação do filtro de Kalman consiste da atualização da covariância do erro de estimação na etapa de filtragem. A partir da equação (*), pode-se mostrar:

$$\begin{aligned} P_{k|k} &= (I - K_k \chi_k) P_{k|k-1} (I - K_k \chi_k)^H + K_k R_k K_k^H \\ &= \left[(P_{k|k-1})^{-1} + \chi_k^H R_k^{-1} \chi_k \right]^{-1} \\ &= \underline{(I - K_k \chi_k) P_{k|k-1}} \quad (6) \end{aligned}$$

Reunindo as expressões de (1) a (6), obtemos o filtro de Kalman

PREDIÇÃO: $\hat{\underline{h}}_{k|k-1} = F_k \hat{\underline{h}}_{k-1|k-1}$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^H + G_k Q_k G_k^H$$

FILTRAGEM: $K_k = P_{k|k-1} \chi_k^H (\chi_k P_{k|k-1} \chi_k^H + R_k)^{-1}$

$$\underline{\alpha}_k = \tilde{\underline{y}}_k - \chi_k^H \hat{\underline{h}}_{k|k-1}$$

$$\hat{\underline{h}}_{k|k} = \hat{\underline{h}}_{k|k-1} + K_k \underline{\alpha}_k$$

$$P_{k|k} = (I - K_k \chi_k) P_{k|k-1}$$

Observações e propriedades:

• o termo de correção $\underline{\alpha}_k$ é chamado de inovação

$$\begin{aligned}\hat{\tilde{y}}_{k|k-1} &= E\{\tilde{y}_k | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} \\ &= E\{X_k h_k + \tilde{z}_k | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} \\ &= X_k E\{h_k | \tilde{y}_1, \dots, \tilde{y}_{k-1}\} + E\{\tilde{z}_k\} = X_k \hat{h}_{k|k-1}\end{aligned}$$

$$\text{Logo, } \alpha_k = \tilde{y}_k - \hat{\tilde{y}}_{k|k-1} \Rightarrow \tilde{y}_k = \hat{\tilde{y}}_{k|k-1} + \alpha_k$$

O termo $\hat{\tilde{y}}_{k|k-1}$ é a parcela da observação atual \tilde{y}_k que pode ser predita a partir das observações passadas (possui redundância em relação ao passado). α_k , por sua vez, é a parcela nova, que não pode ser predita (daí o nome inovação).

Em termos geométricos, $\hat{\tilde{y}}_{k|k-1}$ é a projeção ortogonal de \tilde{y}_k no espaço gerado por $\{\tilde{y}_1, \dots, \tilde{y}_{k-1}\}$, enquanto α_k é a componente de \tilde{y}_k ortogonal a esse espaço.

É possível mostrar que a sequência de inovações $\alpha_1, \dots, \alpha_k$ forma um processo branco de média nula.

• quando \underline{u}_k e \tilde{z}_k são processos aleatórios brancos e gaussianos, o filtro de Kalman corresponde à solução ótima MMSE para o problema de estimação de estados.

• o filtro de Kalman sempre representa o estimador ótimo MMSE linear (que produz uma estimativa a partir de uma combinação linear dos medidos) quando os ruídos considerados não são gaussianos, por exemplo.

• se \underline{w}_k e $\tilde{\underline{\eta}}_k$ forem correlacionados ou coloridos, então o filtro de Kalman pode ser modificado para resolver o problema.

• para sistemas não-lineares, várias formulações de filtros de Kalman não-lineares oferecem soluções aproximadas para o problema.

• O algoritmo RLS pode ser visto como um caso particular do filtro de Kalman.

• $P_{k|k-1}$, K_k e $P_{k|k}$ não dependem de \tilde{y}_k , apenas das características do sistema dinâmico (X_k, G_k, Q_k e R_k) - poderiam, portanto, ser pré-calculados e armazenados em uma memória. É possível saber se o filtro terá ou não sucesso de modo antecipado, verificando se $P_{k|k}$ converge para valores pequenos.

• Inicialização de matriz de covariância:
$$\left\{ \begin{array}{l} P_{0|0} = 0, \text{ se conhecemos} \\ \text{exatamente } \underline{h}_0 \\ \\ P_{0|0} = \infty I, \text{ se não sabe} \\ \text{mos nada sobre o} \\ \text{estado inicial.} \end{array} \right.$$

• Há alguns motivos que podem levar o filtro de Kalman a não funcionar adequadamente: (i) aritmética de precisão finita, (ii) erros na definição do modelo matemático do sistema dinâmico.

"Truques" interessantes:

- usar um filtro com desvanecimento de memória
 - inserir um ruído de processo fictício
- fazem com que o filtro dê mais ênfase às medidas do que ao modelo adotado (eq. de processo)

Referências Complementares:

- D. Simon, "Optimal State Estimation - Kalman, Hoo and Nonlinear Approaches", John Wiley & Sons, 2006.
- B.D.O. Anderson e J.B. Moore, "Optimal Filtering", Prentice Hall, 1979.
- S.M. Kay, "Fundamentals of Statistical Signal Processing, Volume I: Estimation Theory", Prentice Hall, 1993.
- T. Kailath, A.H. Sayed e B. Hamibi, "Linear Estimation", Prentice Hall, 2000.

