

Filtro de Kalman

Teoria e Aplicação para Iniciantes

Prof. Dr. Marco Antonio Leonel Caetano

M&V Consultoria e Treinamento


www.mudancasabruptas.com.br

Consultoria
Treinamento

M & V


MARCO ANTONIO LEONEL CAETANO

A História da Filtragem de Sinais



1930

**Filtro de Wiener
(contínuo)**



1940

**Filtro de Kolmogorov
(discreto)**



1960

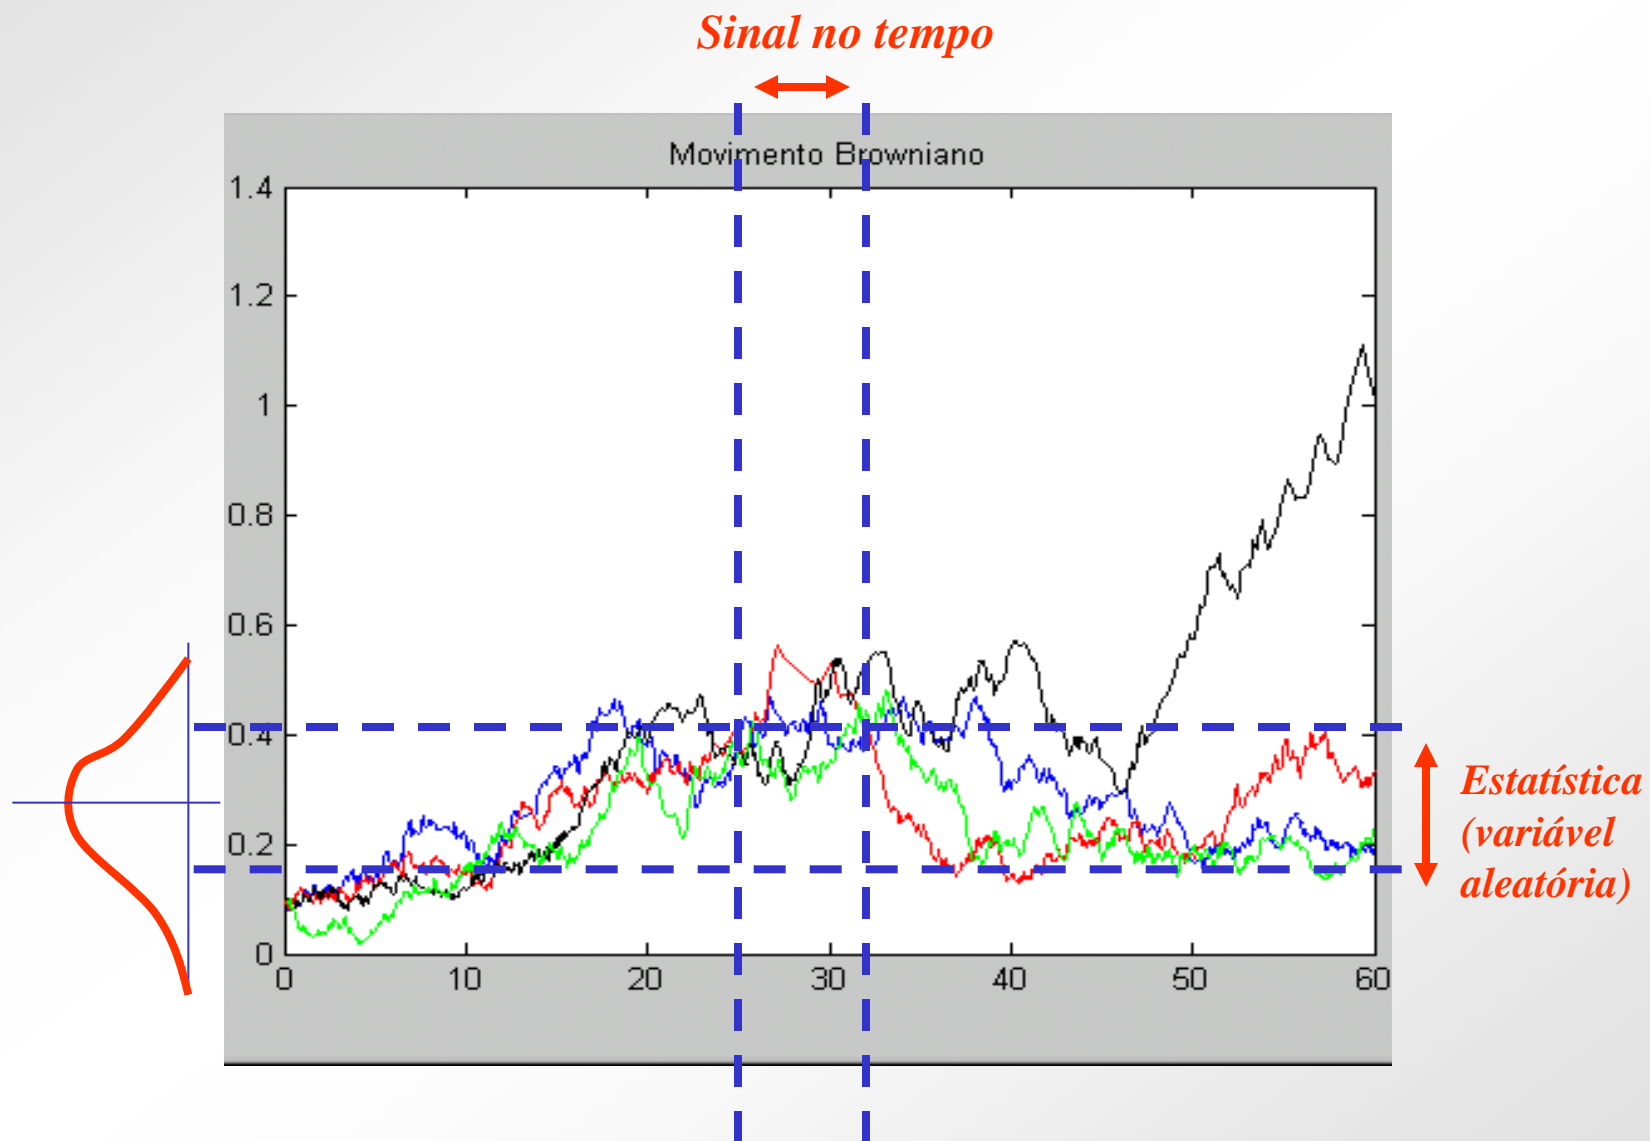
**Filtro de Kalman
(linear e estendido)**

Processos Estocásticos

Consultoria
Treinamento

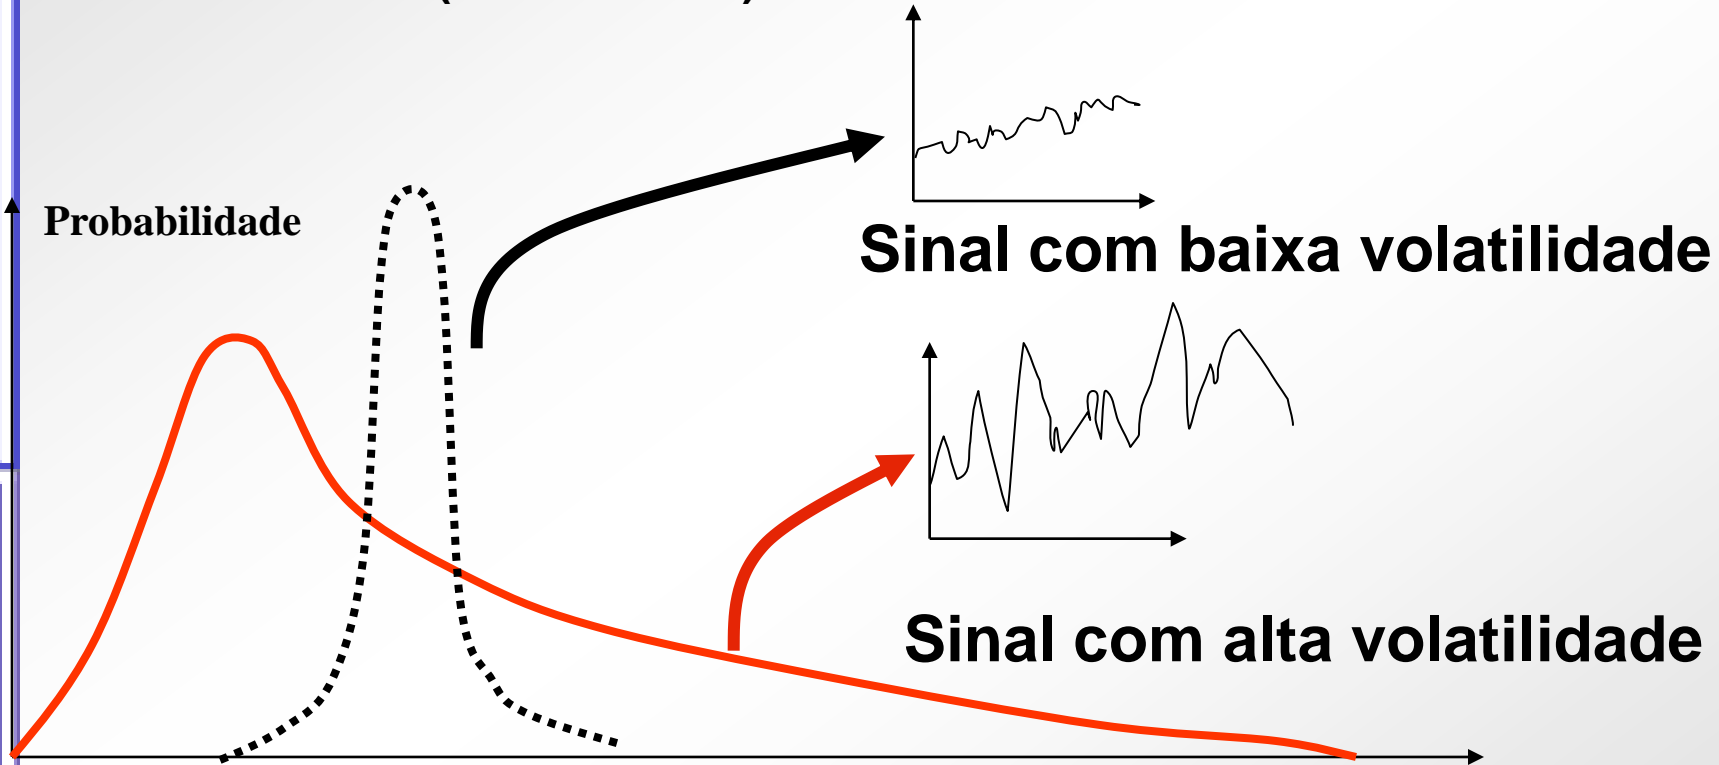
M & V

MARCO ANTONIO LEONEL CAETANO



O que caracteriza um sinal?

- Média
- Desvio Padrão (volatilidade)



Resolvendo Sistema Linear

Observar o seguinte sistema linear:

$$\begin{cases} 5x_1 + 2x_2 = 4 \\ 2x_1 - x_2 = 1 \end{cases}$$

Para resolver seguem-se duas maneiras diferentes:

- (1) Isolar x_1 da primeira equação e substituir na segunda.
- (2) Transformar o sistema em matrizes e vetores.

Primeira Resolução

$$\begin{cases} 5x_1 + 2x_2 = 4 \\ 2x_1 - x_2 = 1 \end{cases}$$

(a) Isolando x_1 na primeira equação:

$$x_1 = \frac{4 - 2x_2}{5}$$

(b) Substituindo na segunda equação:

$$2\left(\frac{4 - 2x_2}{5}\right) - x_2 = 1$$

\Rightarrow

$$8 - 4x_2 - 5x_2 = 5$$

\Rightarrow

$$-9x_2 = -3$$

\Rightarrow

$$x_2 = \frac{1}{3}$$

(c) Substituindo x_2 em x_1 isolado em (a):

$$x_1 = \frac{2}{3}$$

Solução: $x_1 = \frac{2}{3}$ $x_2 = \frac{1}{3}$

Segunda Resolução

$$\begin{cases} 5x_1 + 2x_2 = 4 \\ 2x_1 - x_2 = 1 \end{cases}$$

(a) Transformar o sistema em representação matricial:

$$\underbrace{\begin{pmatrix} 5 & 2 \\ 2 & -1 \end{pmatrix}}_{\mathbf{A}} \underbrace{\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}}_{\mathbf{X}} = \underbrace{\begin{pmatrix} 4 \\ 1 \end{pmatrix}}_{\mathbf{B}}$$

(b) Resolve-se agora o sistema : $\mathbf{AX} = \mathbf{B}$

(c) A solução deve envolver a inversa da matriz A, ou seja, \mathbf{A}^{-1}

$$\mathbf{A}^{-1}\mathbf{AX} = \mathbf{A}^{-1}\mathbf{B}$$

(d) Como $\mathbf{A}^{-1}.\mathbf{A}$ é matriz identidade a solução será: $\mathbf{X} = \mathbf{A}^{-1}\mathbf{B}$

(e) No matlab basta : $\mathbf{x} = \text{inv}(\mathbf{A})*\mathbf{B}$

No Matlab

```
>> A=[5 2; 2 -1 ]
```

```
A =
```

```
    5    2
    2   -1
```

```
>> B=[4 1]
```

```
B =
```

```
    4    1
```

```
>> B=B'
```

```
B =
```

```
    4
    1
```

```
>> x = inv(A)*B
```

B tem que ser transposto! Ou B = [4 ; 1]

```
x =
```

```
    0.6667
```

```
    0.3333
```

Problema com dimensão de matrizes

Resolver sistema linear com mesmo número de linhas e colunas é fácil usando matlab. Mas quando se tem MAIS equação que incógnita a inversa da matriz não é possível.

$$\begin{cases} 2x_1 + x_2 = 1 \\ 3x_1 + 2x_2 = 2 \\ x_1 + x_2 = 3 \end{cases}$$

3 equações

2 incógnitas (x1,x2)


```
>> a=[2 1;3 2; 1 1]
```

```
a =
```

```
    2    1
    3    2
    1    1
```

```
>> inv(a)
```

```
??? Error using ==> inv
Matrix must be square.
```




????

Método dos Mínimos Quadrados

A solução para o problema anterior é encontrar o vetor x mais próximo possível tal que o sistema $AX = B$ seja o mais verdadeiro possível!

Deve-se encontrar o vetor x cujo erro do sistema seja o menor possível ao quadrado. Por isso o método se chama **MÍNIMOS QUADRADOS**.

Exemplo:



Reta que mais se aproxima dos pontos amostrados

Os resíduos dessa diferença são os menores possíveis quando elevados ao quadrado.

A Estimativa do Método dos Mínimos Quadrados (MMQ)

Seja

$$A\vec{x} = B$$

\Rightarrow

$$A^T A\vec{x} = A^T B$$

\Rightarrow

$$\underbrace{(A^T A)^{-1} \cdot (A^T A)}_{\text{identidade}} \vec{x} = (A^T A)^{-1} \cdot A^T B$$

Logo, para encontrar o vetor x mais próximo possível da solução:

$$\vec{x} = (A^T A)^{-1} A^T B$$

Aplicação dos MMQ à medidas

Imaginar que duas variáveis foram acompanhadas por 3 dias e tiveram seus valores relacionados na tabela a seguir:

medida1	medida 2
0,10	13
0,18	22
0,28	36

Suponha que exista a seguinte relação entre as medidas:

$$medida_1 \times k = medida_2$$

Como estimar k ?

Solução via MMQ

$$0,10k = 13$$

$$0,18k = 22$$

$$0,28k = 36$$

Sistema com 3 equações e 1 incógnita

Neste caso as matrizes A e B serão:

$$A = \begin{pmatrix} 0,10 \\ 0,18 \\ 0,28 \end{pmatrix} \quad B = \begin{pmatrix} 13 \\ 22 \\ 36 \end{pmatrix}$$

Então, lembrando que o x nesse problema é o valor de k e:

$$\vec{x} = (A^T A)^{-1} A^T B$$

Qual a solução?

Solução

$$(a) A^T A = (0,1 \quad 0,18 \quad 0,28) \begin{pmatrix} 0,1 \\ 0,18 \\ 0,28 \end{pmatrix} = 0,1208$$

$$(b) A^T B = (0,1 \quad 0,18 \quad 0,28) \begin{pmatrix} 0,1 \\ 0,18 \\ 0,28 \end{pmatrix} = 15,34$$

Assim,

$$k = \frac{1}{0,1208} 15,34 \approx 127$$

A Solução Numérica

```
>> A=[0.1; 0.18; 0.28];  
>> B=[13; 22; 36];  
>> k=inv(A'*A)*A'*B
```

```
k =
```

```
126.9868
```

$$\vec{x} = (A^T A)^{-1} A^T B$$

Estimativa de parâmetros - Ajuste de Função

Dada uma tabela de dados

$$\begin{bmatrix} X : & x_1 & x_2 & x_3 \\ Y : & y_1 & y_2 & y_3 \end{bmatrix}$$

Deseja-se encontrar a melhor função linear que ajuste y aos valores de x:

$$y = c_0 + c_1 x$$

Observando que os dados são inseridos na função da seguinte forma:

$$y(i) = c_0 + c_1 x(i)$$

O sistema a ser resolvido é:

$$\begin{matrix} \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} & \cdot & \begin{pmatrix} c_0 \\ c_1 \end{pmatrix} & = & \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \\ \mathbf{A} & & \mathbf{X} & & \mathbf{B} \end{matrix}$$

Exercício

Fazer um programa para entrar com n valores de x e de y e no final o programa deve ajustar a função linear pelo método dos mínimos quadrados. Use como exemplo a tabela a seguir:

X	0	3	6
Y	1	4	5

```

1 - clear
2 - n = input('qtde de pares de valores = ');
3
4 - *-----*
5 - for i = 1:n
6 -     A(i,1)=1;
7 -     A(i,2)=input('valor de x=');
8 -     B(i,1)=input('valor de y=');
9 - end
10
11 - *-----*
12 - coeficientes=inv(A'*A)*A'*B
13 - *-----*
```

Solução

coeficientes =

1.3333

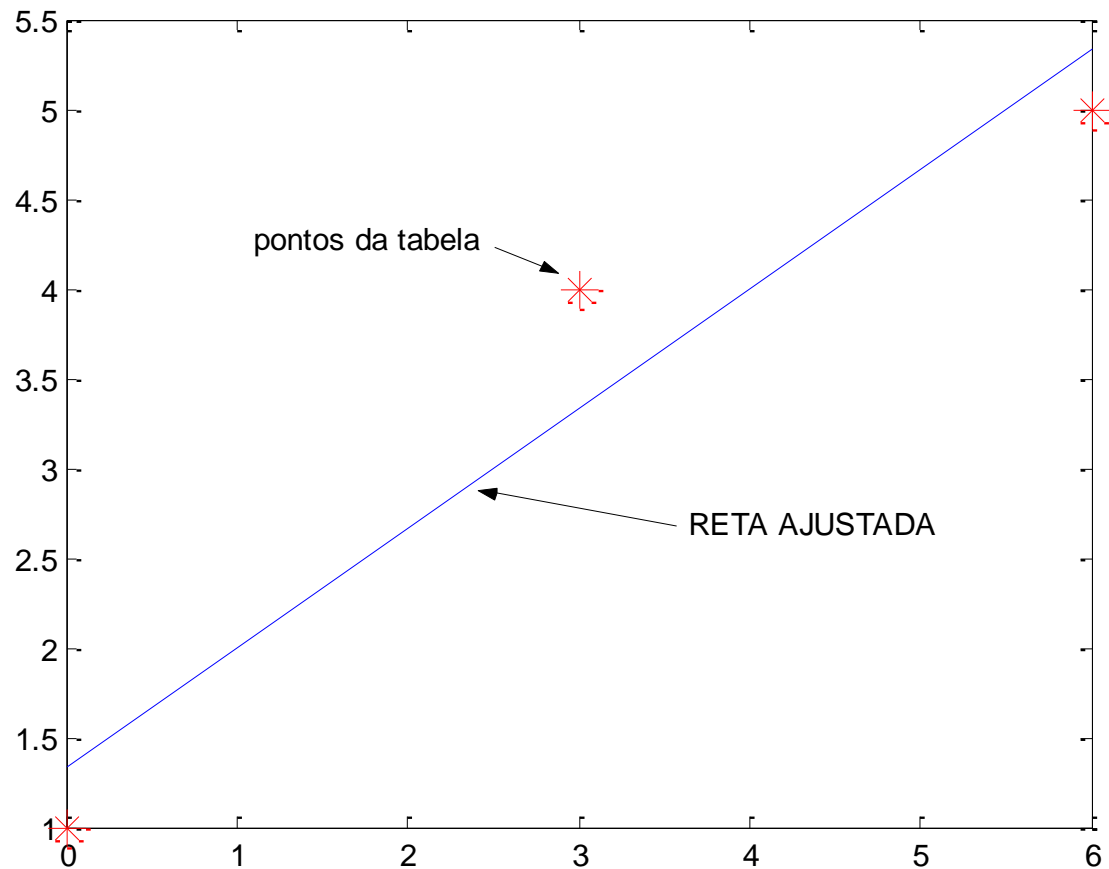
0.6667

Exercício

Modificar o programa anterior para fazer o gráfico dos pontos da Tabela e dos pontos da reta ajustada $y(i) = c0 + c1 * x(i)$

```
1 - clear
2 - n = input('qtde de pares de valores = ');
3
4 - %-----
5 - for i = 1:n
6 -     A(i,1)=1;
7 -     A(i,2)=input('valor de x=');
8 -     B(i,1)=input('valor de y=');
9 - end
10
11 - %-----
12 - coef=inv(A'*A)*A'*B
13 - %-----
14 - % FUNCAO AJUSTADA
15
16 - for i=1:n
17 -     y(i)=coef(1)+coef(2)*A(i,2);
18 - end
19
20 - plot(A(:,2),B,'.r',A(:,2),y,'-b')
```

Solução



Estimação Recursiva

Considere o problema da estimativa de uma constante escalar não Aleatória baseada em k medidas anteriores, corrompidas por ruído:

$$z_i = x + v_i \quad i = 1, 2, 3, \dots, k$$

onde v_i é ruído branco gaussiano (média zero e desvio padrão fixo).

Qual a melhor estimativa para x ?

A média é a melhor estimativa para x !

$$\hat{X}_k = \frac{\sum_{i=1}^k z_i}{k}$$

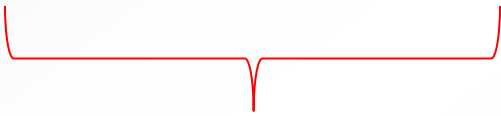
Para uma medida adicional ($k+1$) a nova estimativa será

$$\hat{X}_{k+1} = \frac{\sum_{i=1}^{k+1} z_i}{k+1}$$

Deve-se manipular os termos para deixar a estimativa sempre em função das medidas anteriores:

$$\begin{aligned}
 \hat{x}_{k+1} &= \frac{1}{k+1} \left(\sum_{i=1}^k z_i + z_{k+1} \right) \\
 &= \frac{1}{k+1} \left(\frac{k}{k} \sum_{i=1}^k z_i + z_{k+1} \right) \\
 &= \frac{1}{k+1} \left(\frac{k}{k} \sum_{i=1}^k z_i + z_{k+1} \right) \quad \text{média} \\
 &= \frac{k}{k+1} \hat{x}_k + \frac{z_{k+1}}{k+1}
 \end{aligned}$$

Somando-se e subtraindo $\frac{\hat{x}_k}{k+1}$

$$\hat{x}_{k+1} = \frac{k}{k+1} \hat{x}_k + \frac{1}{k+1} \hat{x}_k + \frac{1}{k+1} z_{k+1} - \frac{1}{k+1} \hat{x}_k$$


$$= \hat{x}_k + \frac{1}{k+1} (z_{k+1} - \hat{x}_k)$$

Estimação recursiva de variáveis

$$\hat{\mathbf{X}}_{k+1} = \hat{\mathbf{X}}_k + \frac{1}{\underbrace{k+1}_{\text{Ganho do Sistema}}} \cdot \underbrace{\left(\mathbf{z}_{k+1} - \hat{\mathbf{X}}_k \right)}_{\text{informação ainda não utilizada}}$$

Exemplo


Estimar a constante “ $a=10$ ” com ruído de medida v (média = 0, desvio=5) para 100 medidas de “ a ”.

```
1 - clear all
2 - clc
3 - %CONSTANTE A SER ESTIMADA
4 - a=10;
5 -
6 - % MEDIDAS COM ERRO
7 - z=a+5*randn(100,1);
8 - % EIXO DO TEMPO PARA GRAFICO
9 - t=1:length(z);
10
```

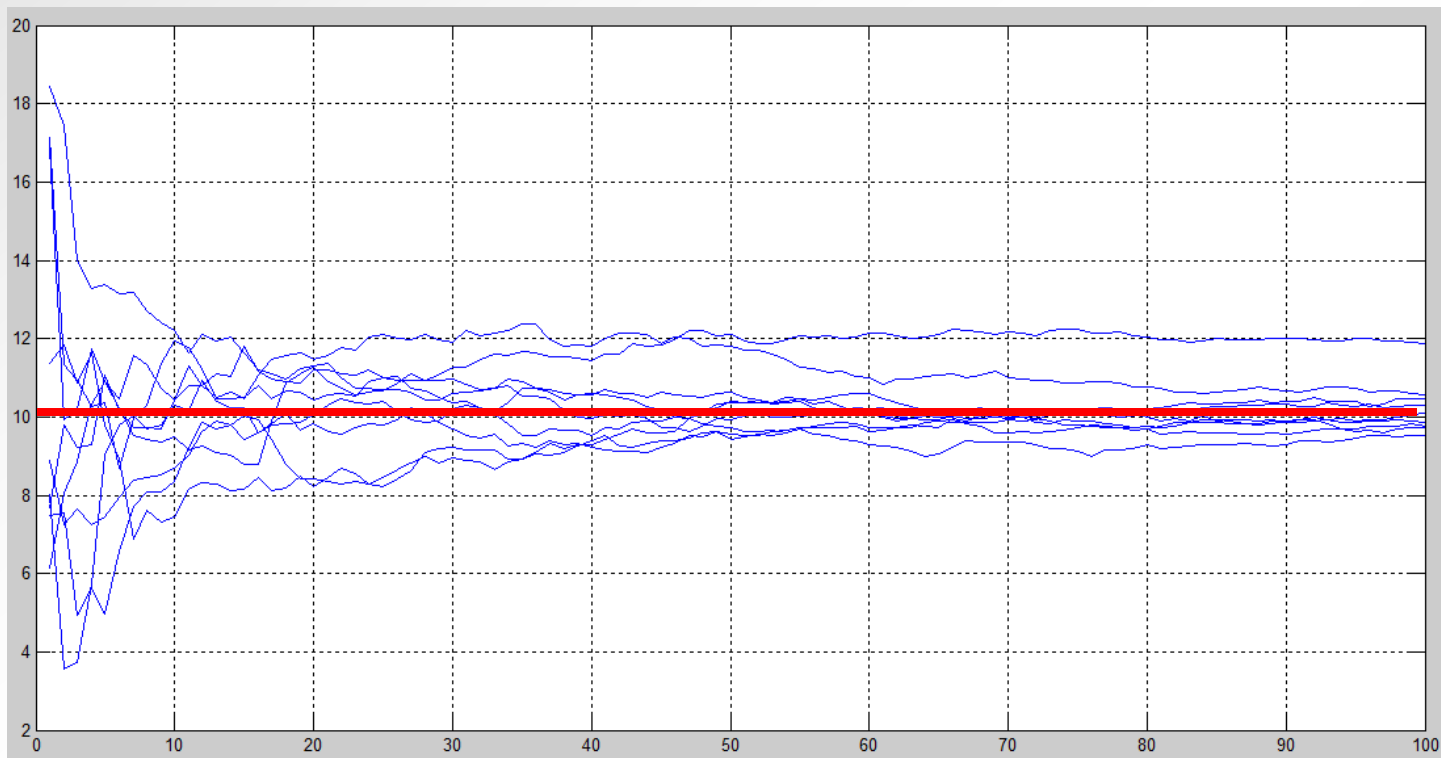
Programando a fórmula do mínimos quadrados recursivo:

```
10
11     % ESTIMACAO RECURSIVA
12
13 -     x(1) = z(1) ;
14
15 -     for i=1:length(z)-1
16 -         x(i+1) = x(i) + (z(i+1) - x(i)) / (i+1)
17 -     end
18 -     plot(t,x)
19
```


Resultado



Para "n" simulações



Comparando com as medidas






```

15 - for i=1:length(z)-1
16 -     x(i+1)=x(i)+(z(i+1)-x(i))/(i+1)
17 - end
18 - plot(t,x,t,z,'.r')
19 - grid
--

```


Por que usar a distribuição gaussiana?

- Segundo o teorema do limite central, todas convergem para a normal para um número grande de pontos.



Teorema do Limite Central

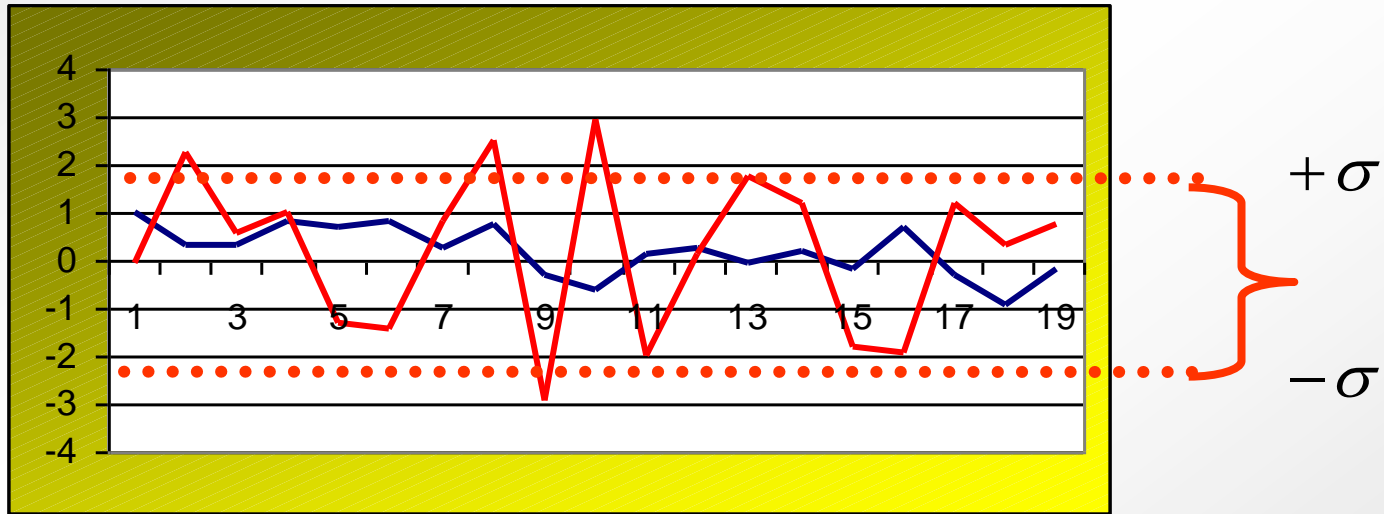
NORMALIZAÇÃO



Para uma única variável

- Média:
- Variância: σ^2

$$f(x) = \frac{e^{-\frac{(x-\bar{x})^2}{2\sigma^2}}}{\sqrt{2\pi\sigma^2}}$$



Para duas variáveis – Distribuição Espacial

$$f(x, y) = \frac{e^{-\frac{[(x-\bar{x}) \quad (y-\bar{y})](\sigma_{xy}^2)^{-1} \begin{bmatrix} (x-\bar{x}) \\ (y-\bar{y}) \end{bmatrix}}{2}}}{\sqrt{2\pi\sigma_{xy}^2}}$$

Média de **x**: \bar{x}


Média de **y**: \bar{y}

Desvio Padrão de **x**: σ_x^2

Desvio padrão de **y**: σ_y^2

Covariância de **x** e **y**: σ_{xy}^2

Correlação de **x** e **y**: ρ



Mas a Covariância é uma matriz (P)

- É necessário uma correção na fórmula pois,

$$P = \sigma_{xy}^2 = \begin{pmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{pmatrix}$$

A função gaussiana corrigida para duas variáveis

$$f(x, y) = \frac{e^{-\frac{[(x-\bar{x}) \quad (y-\bar{y})] P^{-1} \begin{bmatrix} (x-\bar{x}) \\ (y-\bar{y}) \end{bmatrix}}{2}}}{\sqrt{2\pi} |P|^{1/2}}$$

onde $|P|$ é o determinante da matriz de covariância

Problema

- E se as variáveis forem vetores de dados com sinais do tipo:

$$\vec{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$


- A covariância seria:

$$P = \begin{pmatrix} \sigma_1^2 & \rho_{12}\sigma_1\sigma_2 & \dots & \rho_{1n}\sigma_1\sigma_n \\ \rho_{12}\sigma_1\sigma_2 & \sigma_2^2 & & \\ \vdots & & \ddots & \\ & & & \sigma_n^2 \end{pmatrix}$$

Impraticável! Todos os sinais teriam que serem armazenados em gigantescos bancos de dados para o calculo no fim.

Solução: Filtro de Kalman


Como o filtro de Kalman estima variáveis?



Algoritmo Esquemático

- Trabalha com dados
- Equação de Propagação
- Equação de Atualização
- Equação de Covariância

Satélite



dados



Bóia

Equação de Atualização \hat{x}_{k+1}^+

Equação de Atualização \hat{x}_{k+2}^+

k

k+1


k+2

Equação de Propagação \hat{x}_{k+1}^-

Equação de Propagação \hat{x}_{k+2}^-

Equação de Propagação \hat{x}_{k+3}^-

tempo



Algumas Definições

- **Variável de Estado (x)**

- Representa a variável de estudo do modelo matemático para a previsão dos dados futuros. Ex: temperatura, salinidade.
- O filtro linear usa modelo linear.
- O futuro é o presente com alguma correção e corrompido por ruído w_k .

$$x_{k+1} = Ax_k + C\omega_k$$

- **Variável de Medida (z)**

- Variável que simula a aquisição dos dados de um sensor.
- Para o filtro linear o modelo de medida é linear com ruído v_k do sensor.

$$z_k = Hx_k + v_k$$

- **Propagação (do estado ou da covariância)**

- É a simulação do que se espera de dados futuros baseados em k dados.
- Utiliza um modelo para a previsão.

- **Atualização (do estado ou da covariância)**

- É a correção da previsão usando os novos dados coletados pelo sensor

Assumir

1. O **estado** é corrompido por perturbação do tipo ruído branco gaussiano com média zero e covariância Q (matriz para todos os valores propagados e atualizados).

$$Q = \begin{pmatrix} \sigma_{1x}^2 & 0 & \dots & 0 \\ 0 & \sigma_{2x}^2 & 0 & 0 \\ \vdots & 0 & \ddots & \\ 0 & 0 & 0 & \sigma_{nx}^2 \end{pmatrix}$$

2. A **medida** do sensor é supostamente corrompida por ruído branco gaussiano com média zero e covariância R .

$$R = \begin{pmatrix} \sigma_{1z}^2 & 0 & \dots & 0 \\ 0 & \sigma_{2z}^2 & 0 & 0 \\ \vdots & 0 & \ddots & \\ 0 & 0 & 0 & \sigma_{nz}^2 \end{pmatrix}$$

Propagações

• Propagação do Estado (*à priori*)

Qual a melhor estimativa? A média! As barras representam a média.

$$\hat{x}_{k+1} = \overline{Ax_k + C\omega_k}$$

ω é o ruído branco do estado

\Rightarrow

$$\hat{x}_{k+1} = A\hat{x}_k$$

• Propagação da covariância do estado (*à priori*)

$$P_{k+1} = \overline{(x_{k+1} - \bar{x}_{k+1})(x_{k+1} - \bar{x}_{k+1})^T}$$

$$P_{k+1} = \overline{[A(x_k - \bar{x}_k) + C\omega_k][A(x_k - \bar{x}_k) + C\omega_k]^T}$$

$\Rightarrow \dots\dots$

$$P_{k+1} = AP_kA^T + CQC^T$$

Atualizações

• Atualização do estado

- A melhor estimativa de x_k quando se tem medida z_k é aquela que minimiza o termo do expoente da distribuição gaussiana.

$$f(x, y) = \frac{e^{-\frac{[(x-\bar{x}) \ (y-\bar{y})] P^{-1} \begin{bmatrix} (x-\bar{x}) \\ (y-\bar{y}) \end{bmatrix}}{2}}}{\sqrt{2\pi|P|^{1/2}}}$$

Isso é desejado!

Colocando a medida na distribuição gaussiana:

$$f(z|x) = \frac{e^{-\frac{(z-Hx)^T (z-Hx)}{2R}}}{\sqrt{(2\pi)R}}$$

Deseja-se minimizar

$$J = (z - Hx)^T R^{-1} (z - Hx) / 2$$

Ou,

$$\frac{\partial J}{\partial X} = 0$$

Isso leva à seguinte relação

$$H^T R^{-1}(z - Hx) = 0$$

Isolando o estado x para sua estimativa

$$\hat{x}^{posteriori} = (H^T R^{-1} H)^{-1} H^T R^{-1} z$$

Usando a mesma idéia do mínimos quadrados recursivos para novas medidas chega-se a seguinte equação de atualização

$$\hat{x}_k^{posteriori} = \hat{x}_k^{priori} + \frac{P^{priori} H^T}{R} \left(z_k - H \hat{x}_k^{priori} \right)$$

• Atualização da covariância

A melhor covariância P quando se tem medida z_k é aquela que zera o erro entre medida e variável:

$$\text{erro} = (x - \hat{x}^{\text{posteriori}})$$

Cuja medida estatística está na matriz de covariância (a barra significa média):

$$P = \overline{(x - \hat{x}^{\text{posteriori}})(x - \hat{x}^{\text{posteriori}})}$$

A melhor estimativa é conseguida substituindo a relação de atualização

$\hat{x}_k^{\text{posteriori}}$ do estado na equação acima. A relação linear que surge é:

$$P^{\text{posteriori}} = P^{\text{priori}} - \frac{P^{\text{priori}} H^T}{H P^{\text{priori}} H^T + R}$$

A matriz R é a inversa da matriz de covariância do erro do sensor de medida.

O Filtro de Kalman

Priori = (-) Posteriori = (+)

Equação de Propagação:

$$\hat{\mathbf{x}}_k^- = \mathbf{A} \cdot \hat{\mathbf{x}}_{k-1}^+$$

propagação do estado

$$\mathbf{P}_k^- = \mathbf{A} \cdot \mathbf{P}_{k-1}^+ \cdot \mathbf{A}^T + \mathbf{C} \cdot \mathbf{Q} \cdot \mathbf{C}^T$$

propagação da covariância do estado

Equação de Atualização:

$$\mathbf{K}_k = \mathbf{P}_k^- \cdot \mathbf{H}^T \cdot (\mathbf{H} \cdot \mathbf{P}_k^- \cdot \mathbf{H}^T + \mathbf{R})^{-1}$$

ganho do filtro

$$\mathbf{P}_k^+ = \mathbf{P}_k^- - \mathbf{K}_k \cdot \mathbf{H} \cdot \mathbf{P}_k^-$$

atualização da matriz de covariância do estado

$$\hat{\mathbf{x}}_k^+ = \hat{\mathbf{x}}_k^- + \mathbf{K}_k \cdot [\mathbf{z}_k - \mathbf{H} \cdot \hat{\mathbf{x}}_k^-]$$


atualização do estado

Quando o Filtro Falha

1. Modelamento errado do estado

- Se a matriz de perturbação Q do estado for mal dimensionada em relação ao problema real o que acontece?


$$\hat{\mathbf{x}}_{k+1}^- = \underbrace{\mathbf{A}\hat{\mathbf{x}}_k^-}_{\text{Modelo}} + \mathbf{A}\mathbf{K}_k \underbrace{(\mathbf{y}_k - \mathbf{H}\hat{\mathbf{x}}_k^-)}_{\text{Medida}}$$



$$\begin{aligned} \mathbf{P}_k^- &= \mathbf{A}\mathbf{P}_{k-1}^+ \mathbf{A}^T + \mathbf{C}\mathbf{Q}\mathbf{C}^T \\ \mathbf{K}_k &= \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H}\mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1} \\ \hat{\mathbf{x}}_k^+ &= \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{y}_k - \mathbf{H}\hat{\mathbf{x}}_k^-) \end{aligned}$$

$$\mathbf{Q} \downarrow \Rightarrow \mathbf{P}_k^- \downarrow \Rightarrow \mathbf{K}_k \downarrow \Rightarrow \hat{\mathbf{x}}_k^+ \approx \hat{\mathbf{x}}_k^-$$

Resultado




**Sinal estimado
Errado!**

Sinal real

2. Se o ruído de medida é muito menor que a perturbação no estado, ou seja, se $R \ll \ll Q$.

Significa que o sensor é totalmente confiável, pois:


$R \downarrow \Rightarrow K \uparrow \Rightarrow$ **O filtro não filtra, acompanha as medidas de perto, pois são confiáveis!**



3. Se o ruído de estado é muito menor que o ruído de medida, ou seja, se $Q \ll R$.

Significa que o sensor não é confiável, pois:


$Q \downarrow \Rightarrow K \downarrow \Rightarrow$ **O filtro só usa o modelo e filtra tudo.
Abandona as Medidas, pois $K \rightarrow 0$!**




4. Se a matriz de covariância da perturbação do estado inicial $P(0)$ for muito baixa.

Ela significa a memória do filtro. Se $P(0)$ é baixa, o filtro não tem “memória” e demora a “enxergar” acontecimentos futuros.

$P(0)$ muito baixa

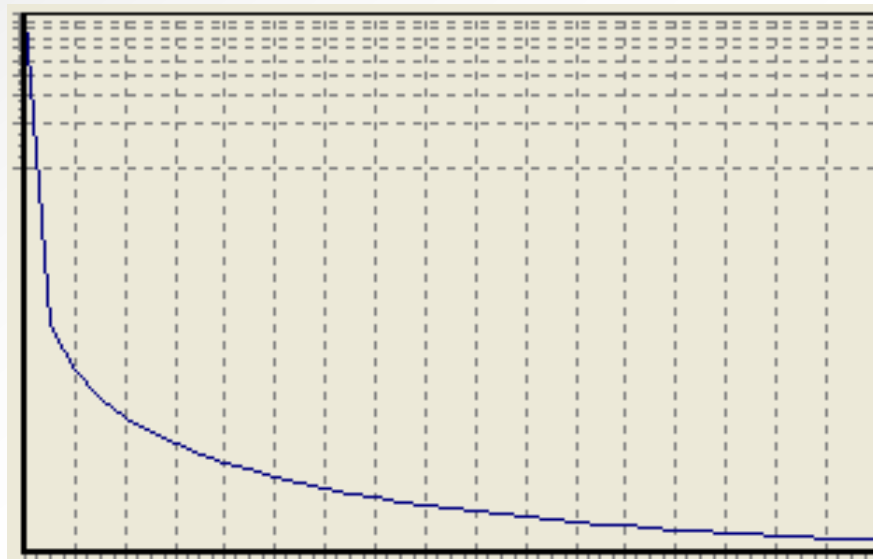


$P(0)$ ideal



Característica ideal da covariância do estado P_k

$P(0)$ alto

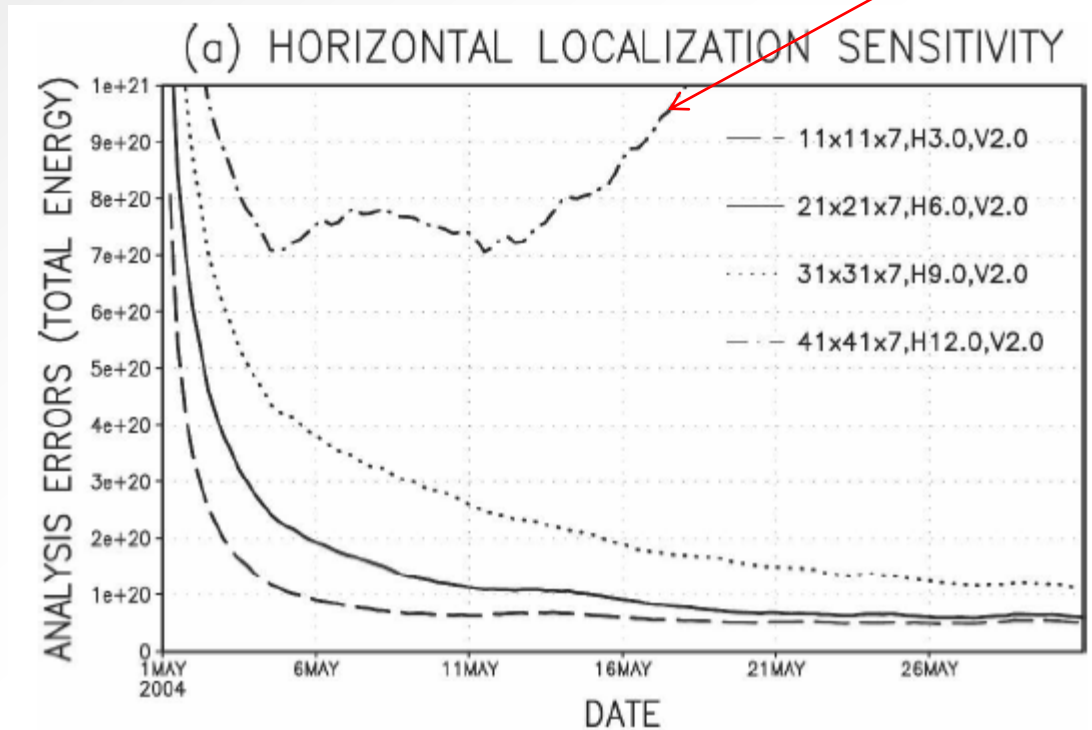


tempo


Covariância do erro de localização horizontal

(Takemasa, Shozo, 2007, pag 3849)

ERRO NO MODELO



O problema da estimativa da temperatura SIMULAÇÃO



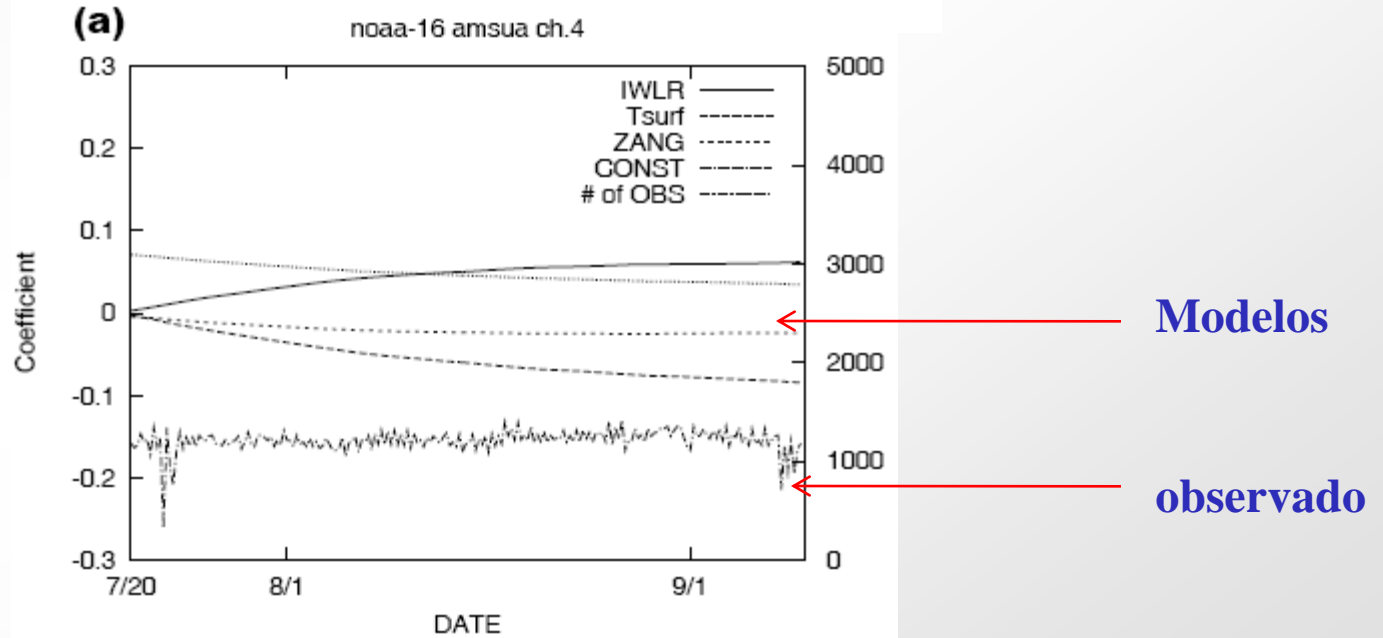

- Dados de temperaturas na localidade dos sensores (satélites, PCD, etc)
- Dados com ruído.
- **O que se desejava?**
 - É possível estimar os dados em tempo real?
 - É possível fazer uma previsão confiável com boa antecedência?
- **Solução:** Filtro de Kalman

Sensores – radiosondas (Takemasa, 2010)

Consultoria
Treinamento

M & V

MARCO ANTONIO LEONEL CAETANO



Modelo Utilizado

$$x_{k+1} = Ax_k + C\omega_k$$

1. Fez –se uma hipótese que **A = 1**.
2. Fez-se a suposição que **C = 1**.
3. O valor de **H = 1** pois só tem um sensor de temperatura.
4. A perturbação aleatória no estado (temperatura) foi **Q = 0,5°C**.
5. O ruído no sensor foi suposto de 10°C, ou variância **R = 100**.
6. A matriz de covariância inicial da perturbação do estado **P(0) = 40**.
7. Finalmente, foi dito ao filtro que a temperatura inicial foi **x(0) = 0 °C**, para obrigar a ter uma alta imprecisão e fazer um aprendizado rápido.
8. O tempo final de simulação para aprendizado e filtragem foi de **t = 100**.

Filtro

Equação de Propagação:

$$\hat{x}_k^- = \hat{x}_{k-1}^+ \quad \text{-----} \quad \mathbf{x(0)=0}$$

$$P_k^- = P_{k-1}^+ + 0,5 \quad \text{-----} \quad \mathbf{P(0)=40}$$

Equação de Atualização:

$$K_k = \frac{P_k^-}{P_k^- + 100}$$

$$P_k^+ = (1 - K_k)P_k^-$$

$$\hat{x}_k^+ = \hat{x}_k^- + K_k \cdot [z_k - \hat{x}_k^-]$$

Simulando os dados do sensor


$$real(i) = 16 - 1,23 \cos\left(\frac{\pi i}{350}\right) - 0,86 \sin\left(\frac{\pi i}{350}\right) + 5\omega$$

onde w é ruído branco com média zero e desvio padrão 1

```

1 - clear all
2 - %===== Lendo os dados reais =====
3 - for i=1:100
4 -     real(i)=16-1.23*cos(pi*i/350)-0.86*sin(pi*i/350)+5*randn;
5 - end
6 -
7 - z=real;

```



Inicializando o filtro

```

8      %=====Inicialização do Filtro de Kalman =====
9      xa(1)=0;
10     sigma1=0.5;
11     a=1;
12     c=1;
13     H=1;
14     %.....matriz de covariancia do estado
15     pa(1)=40;
16     %..... covariancia do ruído do estado
17     sigma1=0.5;
18     %..... covariancia do ruído de medida do sensor
19     R=100;
20     %..... tempo de filtragem do FK
21     tempsimul=100;

```

A caixa do Filtro de Kalman


```

24      %//////////////////////////////////// FILTRO DE KALMAN //////////////////////////////////////
25 -   for i=2:tempsimul
26 -       t(i)=i;
27
28       %{ PROPAGAÇÃO}
29       %{ =====}
30 -         xp(i)=a*xa(i-1);
31 -         p(i)=a*pa(i-1)*a+c*sigma1*c;
32       %{ =====}
33       %{ ATUALIZAÇÃO}
34
35 -         KK(i)=p(i)*H/(H*p(i)*H+R);
36 -         pa(i)=p(i)-KK(i)*H*p(i);
37 -         xa(i)=xp(i)+KK(i)*(z(i)-H*xp(i));
38 -     end
39
40
41     %===== GRAFICOS =====
42 -     plot(t,z(1:tempsimul),'-b',t,xa,'-r')
43


```

100 pontos

— medida
— estimado




A Covariância do estado (temperatura)



O filtro de Kalman “aprendeu” com 20 dados!!

Cenário 2: Sensor com mais ruído – Sinal mais filtrado


erro = 22,36°C
R=erro² = 500



**Valoriza o modelo pois
medidas menos
Confiáveis !**

Cenário 3: Covariância com maior incerteza


$P(0) = 400$
 $R = 100$



**Ajusta mais rápido
às medidas. Elas
tem mais valor do
que o modelo!**

Cenário 4: Ruído de sensor super-baixo

$P(0) = 40$
 $R = 1$



**Esquece o modelo pois
a melhor estimativa é a
medida do sensor**

MATHEMATICS
IN SCIENCE
AND
ENGINEERING

Volume 141

Stochastic Models,
Estimation,
and Control
Volume 1

Peter S. Maybeck

**Probability,
Random Variables,
and Stochastic
Processes**

Third Edition


Athanasios Papoulis

BIBLIOGRAFIA

**INTRODUCTION TO
RANDOM SIGNALS
AND APPLIED
KALMAN FILTERING**

WITH MATLAB EXERCISES
AND SOLUTIONS

THIRD EDITION



SOFTWARE INCLUDED

**ROBERT GROVER BROWN
PATRICK Y. C. HWANG**