


Rastreamento

Conceitos, Técnicas e Implementação

Siome Klein Goldenstein


`siome@ic.unicamp.br`

Instituto de Computação - UNICAMP




Conteúdo

- Modelagem de Sistemas.
- Incertezas.
- Introdução à Rastreamento.
- Métodos de Rastreamento.




Parte I: Modelagem de Sistemas



Modelagem de Sistemas


- **Modelagem de Sistemas.**
 - ◆ Modelagem por Estados.
 - ◆ Dinâmica de um Sistema.
- Incertezas.
- Introdução à Rastreamento.
- Métodos de Rastreamento.



O que é um Sistema?

Um Sistema ...


- é caixa preta que possui propriedades ou características distintas;



O que é um Sistema?

Um Sistema ...


- é caixa preta que possui propriedades ou características distintas;
- possui um conjunto de propriedades mutáveis e um de propriedades constantes;



O que é um Sistema?

Um Sistema ...


- é caixa preta que possui propriedades ou características distintas;
- possui um conjunto de propriedades mutáveis e um de propriedades constantes;
- possui um comportamento autônomo se deixado em paz;



O que é um Sistema?

Um Sistema ...

- é caixa preta que possui propriedades ou características distintas;
- possui um conjunto de propriedades mutáveis e um de propriedades constantes;
- possui um comportamento autônomo se deixado em paz;
- reage à estímulos externos.




Descrição de um Sistema

Necessitamos de uma abstração matemática para sua descrição!

O modelo matemático deve ...

- descrevê-lo o mais precisamente o possível;




Descrição de um Sistema

Necessitamos de uma abstração matemática para sua descrição!

O modelo matemático deve ...

- descrevê-lo o mais precisamente o possível;
- ser tratável;




Descrição de um Sistema

Necessitamos de uma abstração matemática para sua descrição!

O modelo matemático deve ...


- descrevê-lo o mais precisamente o possível;
- ser tratável;
- ser o mais simples e sucinto o possível.



Estático e Dinâmico


Podemos decompor a abstração matemática de um sistema em duas partes:

1. Descrição Instantânea do sistema
2. Descrição da evolução do sistema, com e sem interferências externas.



Estados: Descrição Instantânea

Utilizamos um conjunto de n variáveis, que podem ser agrupadas e representadas em um vetor.




Estados: Descrição Instantânea

Utilizamos um conjunto de n variáveis, que podem ser agrupadas e representadas em um vetor.


O Sistema está completamente determinado no momento t através de

$$\vec{x}_t \in \mathbb{R}^n.$$



Dinâmica, sem interferência

Podemos modelar o comportamento dinâmico de sistemas de dois modos:




Dinâmica, sem interferência

Podemos modelar o comportamento dinâmico de sistemas de dois modos:

- Contínuo \longrightarrow Sistema Dinâmico:

$$t \in \mathbb{R} \quad \longrightarrow \quad \frac{d\vec{x}}{dt} = f(\vec{x}_t, t).$$



Dinâmica, sem interferência

Podemos modelar o comportamento dinâmico de sistemas de dois modos:


- Contínuo \longrightarrow Sistema Dinâmico:

$$t \in \mathbb{R} \quad \longrightarrow \quad \frac{d\vec{x}}{dt} = f(\vec{x}_t, t).$$

- Discreto \longrightarrow Equações de Diferença:

$$t = k.\Delta T \quad \longrightarrow \quad \vec{x}_{k+1} = f(\vec{x}_k, n).$$


$(k \in \mathbb{N} \text{ e } \Delta T \in \mathbb{R})$



Exemplo Contínuo I:

Movimento Contínuo Uniformemente Variado

$$x' = v \quad \text{e} \quad v' = k$$




Exemplo Contínuo I:

Movimento Contínuo Uniformemente Variado

$$x' = v \quad \text{e} \quad v' = k$$

- Aceleração constante: $a = k, \quad k \in \mathbb{R};$




Exemplo Contínuo I:

Movimento Contínuo Uniformemente Variado

$$x' = v \quad \text{e} \quad v' = k$$

- Aceleração constante: $a = k, \quad k \in \mathbb{R};$
- Velocidade: $v = kt;$




Exemplo Contínuo I:

Movimento Contínuo Uniformemente Variado

$$x' = v \quad \text{e} \quad v' = k$$

- Aceleração constante: $a = k, \quad k \in \mathbb{R};$
- Velocidade: $v = kt;$
- Posição: $x = \frac{1}{2}kt^2.$



Exemplo Contínuo I:

Movimento Contínuo Uniformemente Variado


$$x' = v \quad \text{e} \quad v' = k$$

- Aceleração constante: $a = k$, $k \in \mathbb{R}$;
- Velocidade: $v = kt$;
- Posição: $x = \frac{1}{2}kt^2$.

$$\vec{x}_t = \begin{pmatrix} x \\ v \end{pmatrix} \quad \text{e} \quad \frac{d\vec{x}}{dt} = \begin{pmatrix} v \\ k \end{pmatrix}$$

Exemplo Discreto I

Logo Turtle



Exemplo Discreto I


Logo Turtle

$$\vec{x}_k = \begin{pmatrix} x \\ y \\ \theta \\ v \\ \theta' \end{pmatrix},$$

Exemplo Discreto I

Logo Turtle

$$\vec{x}_k = \begin{pmatrix} x \\ y \\ \theta \\ v \\ \theta' \end{pmatrix}, \quad \vec{x}_{k+1} = \begin{pmatrix} x + \Delta T v \cos \theta \\ y + \Delta T v \sin \theta \\ \theta + \Delta T \theta' \\ v \\ \theta' \end{pmatrix}.$$




Com Interferência...

- Contínuo \longrightarrow Sistema Dinâmico:

$$\frac{d\vec{x}}{dt} = f(\vec{x}_t, t).$$

- Discreto \longrightarrow Equações de Diferença:

$$\vec{x}_{k+1} = f(\vec{x}_k, k).$$



Com Interferência...


- Contínuo \longrightarrow Sistema Dinâmico:

$$\frac{d\vec{x}}{dt} = f(\vec{x}_t, t).$$

- Discreto \longrightarrow Equações de Diferença:

$$\vec{x}_{k+1} = f(\vec{x}_k, k).$$

Uma série de variáveis externas, $\vec{u}_t \in \mathbb{R}^m$, podem alterar a dinâmica do sistema. Podem estar tanto sob, como também fora, do controle do usuário.



Com Interferência...


- Contínuo \longrightarrow Sistema Dinâmico:

$$\frac{d\vec{x}}{dt} = f(\vec{x}_t, \vec{u}_t, t).$$

- Discreto \longrightarrow Equações de Diferença:

$$\vec{x}_{k+1} = f(\vec{x}_k, \vec{u}_k, k).$$

Uma série de variáveis externas, $\vec{u}_t \in \mathbb{R}^m$, podem alterar a dinâmica do sistema. Podem estar tanto sob, como também fora, do controle do usuário.



Exemplo Contínuo I:


Bala de Canhão

X


$$\vec{x}_t = \begin{pmatrix} p_x \\ p_y \\ v_x \\ v_y \\ a_y \end{pmatrix} \quad \frac{d\vec{x}}{dt} = \begin{pmatrix} v_x \\ v_y \\ 0 \\ a_y \\ -g \end{pmatrix}$$

Se temos $p_{x0}, p_{y0}, \theta_0,$ e $v_0,$

$$\vec{x}_0 = \begin{pmatrix} p_{x0} \\ p_{y0} \\ v_0 \cos \theta_0 \\ v_0 \sin \theta_0 \\ -g \end{pmatrix}$$




Parte II: Estados e Incertezas




Modelagem de Sistemas

- Modelagem de Sistemas.
- Estados como Incertezas.
- Introdução à Rastreamento.
- Métodos de Rastreamento.



Incertezas


É necessário representar incertezas.



Incertezas

É necessário representar incertezas.


- Intervalos;



Incertezas

É necessário representar incertezas.


- Intervalos;
- Variáveis Aleatórias ...



Incertezas

É necessário representar incertezas.


- Intervalos;
- Variáveis Aleatórias ...
 - ◆ com distribuição paramétrica;



Incertezas


É necessário representar incertezas.

- Intervalos;
- Variáveis Aleatórias ...
 - ◆ com distribuição paramétrica;
 - ◆ com distribuição não-paramétrica.



Definições Básicas

- Espaço de Amostragem;
- Evento;
- Medida de Probabilidade.




Espaço de Amostragem

Um conjunto Ω de objetos ω .

Exemplos:


- Os seis lados de um dado.
- Alguns pontos sobre uma reta.
- O intervalo fechado $[0, 1]$ dos Reais.
- Todos os pontos do plano \mathbb{R}^2 .
- Todas as funções $f : \mathbb{R} \rightarrow \mathbb{R}$.



Evento

Um subconjunto de amostras de Ω . Utiliza-se geralmente letras maiúsculas (A, B, \dots), com uma definição concisa:

$$A = \{\omega : \text{condição necessária sobre } \omega\}$$




Evento

Um subconjunto de amostras de Ω . Utiliza-se geralmente letras maiúsculas (A, B, \dots), com uma definição concisa:

$$A = \{\omega : \text{condição necessária sobre } \omega\}$$

- $\Omega \triangleq$ lados do dado, e $A = \{\omega : \text{num}(\omega) < 5\}$.




Evento

Um subconjunto de amostras de Ω . Utiliza-se geralmente letras maiúsculas (A, B, \dots), com uma definição concisa:

$$A = \{\omega : \text{condição necessária sobre } \omega\}$$

- $\Omega \triangleq$ lados do dado, e $A = \{\omega : \text{num}(\omega) < 5\}$.
- $\Omega \triangleq \mathbb{R}^2$, e $A = \{\omega : x^2 + y^2 \leq 1\}$.




Evento

Um subconjunto de amostras de Ω . Utiliza-se geralmente letras maiúsculas (A, B, \dots), com uma definição concisa:

$$A = \{\omega : \text{condição necessária sobre } \omega\}$$


- $\Omega \triangleq$ lados do dado, e $A = \{\omega : \text{num}(\omega) < 5\}$.
- $\Omega \triangleq \mathbb{R}^2$, e $A = \{\omega : x^2 + y^2 \leq 1\}$.
- $\Omega \triangleq f : \mathbb{R} \rightarrow \mathbb{R}$, e
 $A = \{\omega : 2 \leq \int_{-\infty}^{\infty} f^2(t) dt \leq 2.5\}$.



Eventos: Algumas Definições I

Complemento de A :


$$A' \triangleq \{\omega : \omega \text{ não está em } A\}.$$



Eventos: Algumas Definições II

União de A e B :


$$A \cup B \triangleq \{\omega : \omega \text{ está em } A \text{ ou está em } B\}.$$



Eventos: Algumas Definições III

Interseção de A e B :

$$AB \triangleq \{\omega : \omega \text{ está em } A \text{ e está em } B\}.$$




Eventos: Propriedades I

$$A \cup A' = \Omega,$$

$$AA' = \emptyset = \Omega',$$

$$A\Omega = A.$$




Eventos: Propriedades II

$$(AB)' = A' \cup B',$$


$$(A \cup B)' = A'B',$$

$$A \cup B = (AB') \cup (AB) \cup (A'B).$$



Eventos: Propriedades III


- Comutativa $\begin{cases} A \cup B = B \cup A \\ AB = BA \end{cases}$
- Associativa $\begin{cases} A \cup (B \cup C) = (A \cup B) \cup C \\ A(BC) = (AB)C \end{cases}$
- Distributiva $\begin{cases} A(B \cup C) = (AB) \cup (AC) \\ A \cup (BC) = (A \cup B)(A \cup C). \end{cases}$



Medida de Probabilidade

Associação de números Reais com eventos em Ω .


- $\Omega \triangleq$ lados do dado e $A_i \triangleq \{\omega : \omega = \text{Lado}_i\}$,
 $P[A_i] \triangleq \frac{1}{6}$,
- $\Omega \triangleq [0, 1]$ e $A_l \triangleq \{\omega : 0 < \omega \leq l\}, l \leq 1$,
 $P[A_l] = l$.
- $\Omega \triangleq f : \mathbb{R} \rightarrow \mathbb{R}$ e $A_x \triangleq \{\omega : 0 \leq f(\omega) \leq x\}$,
 $P[A_x] = 1 - e^{-x}$.




Propriedades da Medida

1. $P[\Omega] = 1$.
2. Cada evento A_i está associado a um único número $P[A_i]$ tal que $0 \leq P[A_i] \leq 1$.
3. Se $AB = \emptyset$, então $P[A \cup B] = P[A] + P[B]$.

Ω Finito	Ω em \mathbb{R}
$P[A] = \sum_I P_i$	$P[A] = \int_I f(\omega) d(\omega)$
$\sum_{i=1}^k = 1$	$\int_{-\infty}^{\infty} f(\omega) d\omega = 1$



Exemplos de Ω na Reta



Probabilidade Condicional


$$P[A|B] \triangleq \frac{P[AB]}{P[B]}$$

quando $P[B] \neq 0$. Quando $P[A]$ também é não zero

$$P[AB] = P[A|B]P[B] = P[B|A]P[A].$$

Como a interseção de B consigo próprio é ainda B :

$$P[B|B] = 1.$$



Independência Estatística

A e B são independentes quando

$$P[A, B] = P[A]P[B].$$

o que é equivalente a $P[A|B] = P[A]$.


Para três eventos A , B e C , são necessárias:

$$P[A, B] = P[A]P[B]$$

$$P[B, C] = P[B]P[C]$$


$$P[A, C] = P[A]P[C]$$

$$P[A, B, C] = P[A]P[B]P[C].$$



Variáveis Aleatórias


Uma função que mapeia Ω em \mathbb{R} .



Função de Distribuição

$$F_x(\alpha) \triangleq P[\{\omega : x(\omega) \leq \alpha\}]$$


1. $F_x(\alpha) \geq 0$; para $-\infty < \alpha < \infty$.
2. $F_x(-\infty) = 0$.
3. $F_x(+\infty) = 1$.
4. Se $a > b$, $F_x(a) \geq F_x(b)$.
5. Se $a > b$, $F_x(a) - F_x(b) = P[\{\omega : b < x(\omega) \leq a\}]$.



Função de Distribuição II

É uma função monotonicamente crescente, que vai de 0 a 1.

Exemplo do dado:




Função de Distribuição Conjunta

Quando temos mais de um mapeamento de Ω em \mathbb{R} , temos um conjunto coexistente de variáveis aleatórias $\{x_i\}$.

$$F_{x_1, x_2}(\alpha_1, \alpha_2) \triangleq P[\{\omega : x_1(\omega) \leq \alpha_1, x_2(\omega) \leq \alpha_2\}]$$

1. $F_{x_1, x_2}(\alpha_1, \alpha_2) \leq 0$.
2. $F_{x_1, x_2}(-\infty, \alpha) = F_{x_1, x_2}(\alpha, -\infty) = 0$.
3. $F_{x_1, x_2}(\infty, \infty) = 1$.
4. $F_{x_1, x_2}(\infty, \alpha) = F_{x_2}(\alpha)$.
5. $F_{x_1, x_2}(\alpha, \infty) = F_{x_1}(\alpha)$.
6. $a_1 > b_1$ e $a_2 > b_2 \rightarrow F_{x_1, x_2}(a_1, a_2) \geq F_{x_1, x_2}(a_1, b_2) \geq F_{x_1, x_2}(b_1, b_2)$.




Densidade de Probabilidade

$$p_x(\alpha) \triangleq \frac{dF_x(\alpha)}{d\alpha}$$


$$F_x(a) = \int_{-\infty}^a p_x(\beta) d\beta.$$

É necessário um pouco mais de cuidado para lidar com descontinuidades em F_x .



Exemplos de distribuições em \mathbb{R}

- Exponencial;
- Rayleigh;
- Uniforme;
- Cauchy;
- Gaussiana



Transformações de VAs I

$$y = f(x) \implies y(\omega) = f(x(\omega)).$$


Soma com uma constante:

$$y = x + a$$

$$P[\{\omega : y(\omega) \leq \alpha\}] = P[\{\omega : x(\omega) \leq \alpha - a\}]$$

$$F_y(\alpha) = F_x(\alpha - a)$$

$$p_y(\alpha) = p_x(\alpha - a).$$



Transformações de VAs II


Multiplicação por uma constante:

$$y = bx$$

$$P[\{\omega : y(\omega) \leq \alpha\}] = P\left[\left\{\omega : x(\omega) \leq \frac{\alpha}{b}\right\}\right]$$

$$F_y(\alpha) = F_x\left(\frac{\alpha}{b}\right)$$

$$p_y(\alpha) = \frac{1}{|b|} p_x\left(\frac{\alpha}{b}\right).$$



Transformações de VAs III

Soma de duas Variáveis Aleatórias:

$$z = x + y.$$

Quando $y = \beta \implies z = x + \beta \implies p_z(\gamma) = p_x(\gamma - \beta)$, ou também

$$p_z(\gamma|y = \beta) = p_x(\gamma - \beta|y = \beta)$$

Calculamos então densidade conjunta,

$$\begin{aligned} p_{z,y}(\gamma, \beta) &= p_z(\gamma|y = \beta)p_y(\beta) \\ &= p_x(\gamma - \beta|y = \beta)p_y(\beta) \\ &= p_{x,y}(\gamma - \beta, \beta). \end{aligned}$$



Transformações de VAs IV

Soma de duas Variáveis Aleatórias:


$$z = x + y.$$

Integrando em y para achar p_z :

$$p_z(\gamma) = \int_{-\infty}^{\infty} p_{x,y}(\gamma - \beta, \beta) d\beta.$$

que quando x e y são independentes, x


$$p_z(\gamma) = \int_{-\infty}^{\infty} p_x(\gamma - \beta) p_y(\beta) d\beta.$$



Valor Esperado (Esperança)

$$E[x] = \sum_j x_j P[x_j]$$

$$E[x] \triangleq \int_{-\infty}^{\infty} \alpha p_x(\alpha) d\alpha.$$




Teorema Fundamental da Esperança

$$x = g(y)$$

$$E[x] = \int_{-\infty}^{\infty} g(\beta) p_y(\beta) d\beta$$

$$\bar{x} = E[g(y)] = \overline{g(y)}$$




Momentos de x

O n -ésimo momento central de x é definido por

$$E[(x - \bar{x})^n] \triangleq \int_{-\infty}^{\infty} (\alpha - \bar{x})^n p_x(\alpha) d\alpha.$$

Em \mathbb{R} :

- Primeiro Momento, Média.
- Segundo Momento, Variância (dispersão).
- Terceiro Momento (simetria).




Gaussiana em \mathbb{R}^n

Em \mathbb{R}^2 ,

$$p_{x_1, x_2}(\alpha_1, \alpha_2) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left[-\frac{(\alpha_1^2 - 2\rho\alpha_1\alpha_2 + \alpha_2^2)}{2(1-\rho^2)}\right].$$

Em \mathbb{R}^n , construímos uma matriz de covariância

$$\Lambda_x = \begin{pmatrix} \lambda_{11} & \cdots & \lambda_{1n} \\ \vdots & \ddots & \vdots \\ \lambda_{n1} & \cdots & \lambda_{nn} \end{pmatrix} \implies p_x(\alpha) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Lambda_x|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}\alpha\Lambda_x^{-1}\alpha^\top\right).$$




Transformação Linear

$$y = Ax$$


onde $y \in \mathbb{R}^m$, $x \in \mathbb{R}^n$ e $A \in \mathbb{R}^m \times \mathbb{R}^n$.

Já que a densidade da soma de variáveis aleatórias independentes é a convolução de suas densidades,

$$\Lambda_y = A\Lambda_x A^\top.$$




Parte III: Conceitos Básicos




Modelagem de Sistemas

- Modelagem de Sistemas.
- Incertezas.
- Introdução à Rastreamento.
 - ◆ Representação Probabilística.
 - ◆ Bayes em Ação.
- Métodos de Rastreamento.



Representação Probabilística

1. Modelo probabilístico da dinâmica do sistema.
2. Observação do estado do sistema.
3. Correção (fusão de dados).




Modelo da Dinâmica

Se, no instante de tempo i , nosso sistema é representado pelo vetor de estado $\vec{x}_i \in \mathbb{R}^n$, a dinâmica pode ser descrita como

$$P(\vec{x}_i) = P(\vec{x}_i | \vec{x}_0, \vec{x}_1, \dots, \vec{x}_{i-1}).$$

Uma forma de modelar a dinâmica de forma mais simples é

$$P(\vec{x}_i) = P(\vec{x}_i | \vec{x}_{i-1}).$$



Observação

No caso do modelo determinístico,


$$\vec{y}_i = g(\vec{x}_i),$$

e no caso probabilístico,

$$P(\vec{y}_i) = P(\vec{y}_i | \vec{x}_i).$$

O que precisamos é:

$$P(\vec{x}_i) = P(\vec{x}_i | \vec{y}_i).$$




Etapa de Predição

\vec{x}_i depende de tudo que foi observado até então,

$$P(\vec{x}_i) = P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_i).$$

A predição de $P'(\vec{x}_i)$ é


$$\begin{aligned} P'(\vec{x}_i) &\triangleq P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_{i-1}) \\ &= \int P(\vec{x}_i, \vec{x}_{i-1} | \vec{y}_1, \dots, \vec{y}_{i-1}) d\vec{x}_{i-1} \\ &= \int P(\vec{x}_i | \vec{x}_{i-1}, \vec{y}_1, \dots, \vec{y}_{i-1}) P(\vec{x}_{i-1} | \vec{y}_1, \dots, \vec{y}_{i-1}) d\vec{x}_{i-1} \\ &= \int P(\vec{x}_i | \vec{x}_{i-1}) P(\vec{x}_{i-1}) d\vec{x}_{i-1}. \end{aligned}$$



Etapa de Correção - I

Combina as informações de $P'(\vec{x}_i)$ e de $P(\vec{x}_i|\vec{y}_i)$ para achar


$$P(\vec{x}_i) \triangleq P(\vec{x}_i|\vec{y}_1, \dots, \vec{y}_i)$$




Etapa de Correção - II

$$\begin{aligned} P(\vec{x}_i) &\triangleq P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_i) = \frac{P(\vec{x}_i, \vec{y}_1, \dots, \vec{y}_i)}{P(\vec{y}_1, \dots, \vec{y}_i)} \\ &= \frac{P(\vec{y}_i | \vec{x}_i, \vec{y}_1, \dots, \vec{y}_{i-1}) P(\vec{x}_i, \vec{y}_1, \dots, \vec{y}_{i-1})}{P(\vec{y}_1, \dots, \vec{y}_i)} \\ &= \frac{P(\vec{y}_i | \vec{x}_i, \vec{y}_1, \dots, \vec{y}_{i-1}) P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_{i-1}) P(\vec{y}_1, \dots, \vec{y}_{i-1})}{P(\vec{y}_1, \dots, \vec{y}_i)} \\ &= \frac{P(\vec{y}_i | \vec{x}_i) P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_{i-1}) P(\vec{y}_1, \dots, \vec{y}_{i-1})}{\int P(\vec{x}_i, \vec{y}_1, \dots, \vec{y}_i) d\vec{x}_i} \end{aligned}$$

$$P(\vec{x}_i) = \frac{P(\vec{y}_i | \vec{x}_i) P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_{i-1})}{\int P(\vec{y}_i | \vec{x}_i) P(\vec{x}_i | \vec{y}_1, \dots, \vec{y}_{i-1}) d\vec{x}_i}$$




Parte IV: Filtros Preditivos



Modelagem de Sistemas

- Modelagem de Sistemas.
- Incertezas.
- Introdução à Rastreamento.
- Métodos de Rastreamento.
 - ◆ Filtro de Kalman.
 - ◆ Filtro de Particulas.
 - ◆ Filtro *Unscented*.




Estimando um valor

Temos um resistor, com valor de fábrica


$$x = 15\Omega \pm 10\%.$$

Utilizaremos diversos multímetros para fazer leituras deste valor ...




Varias medidas determinísticas de uma mesma quantidade...

- Após a primeira medida: $\hat{m}_1 = y_1$.




Varias medidas determinísticas de uma mesma quantidade...

- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{y_1 + y_2}{2}$.



Varias medidas determinísticas de uma mesma quantidade...

- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{y_1+y_2}{2}$.
- Após a terceira medida: $\hat{m}_3 = \frac{y_1+y_2+y_3}{3}$.



Varias medidas determinísticas de uma mesma quantidade...


- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{y_1+y_2}{2}$.
- Após a terceira medida: $\hat{m}_3 = \frac{y_1+y_2+y_3}{3}$.
- ...

Varias medidas determinísticas de uma mesma quantidade...

- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{y_1 + y_2}{2}$.
- Após a terceira medida: $\hat{m}_3 = \frac{y_1 + y_2 + y_3}{3}$.
- ...


- Após n medidas :

$$\hat{m}_n = \frac{y_1 + y_2 + \dots + y_n}{n}$$




Recursivamente

- Após a primeira medida: $\hat{m}_1 = y_1$.




Recursivamente

- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{1}{2}\hat{m}_1 + \frac{1}{2}y_2$.



Recursivamente

- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{1}{2}\hat{m}_1 + \frac{1}{2}y_2$.
- Após a terceira medida: $\hat{m}_3 = \frac{2}{3}\hat{m}_2 + \frac{1}{3}y_3$.



Recursivamente


- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{1}{2}\hat{m}_1 + \frac{1}{2}y_2$.
- Após a terceira medida: $\hat{m}_3 = \frac{2}{3}\hat{m}_2 + \frac{1}{3}y_3$.
- ...

Recursivamente

- Após a primeira medida: $\hat{m}_1 = y_1$.
- Após a segunda medida: $\hat{m}_2 = \frac{1}{2}\hat{m}_1 + \frac{1}{2}y_2$.
- Após a terceira medida: $\hat{m}_3 = \frac{2}{3}\hat{m}_2 + \frac{1}{3}y_3$.
- ...

- Após n medidas :


$$\hat{m}_n = \frac{n-1}{n}\hat{m}_{n-1} + \frac{1}{n}y_n.$$



Usando Distribuições

Usando distriuições Gaussianas:


$$N(-2,1) \quad \text{e} \quad N(2,1)$$



Usando Distribuições

Usando distriuições Gaussianas:


$$N(-2,1) \quad \text{e} \quad N(2,1)$$



Usando Distribuições

Usando distriuições Gaussianas:

$$N(-2,1) \quad \text{e} \quad N(2,1)$$




$$N\left(0, \frac{1}{2}\right)$$

Usando Distribuições


Usando distriuições Gaussianas:

$$N(-2,1) \quad \text{e} \quad N(2,1)$$

$$N(-2,1) \quad \text{e} \quad N(2,3)$$




$$N\left(0, \frac{1}{2}\right)$$




Usando Distribuições

Usando distriuições Gaussianas:


$$N(-2,1) \text{ e } N(2,1)$$



$$N(-2,1) \text{ e } N(2,3)$$




$$N\left(0, \frac{1}{2}\right)$$



Usando Distribuições


Usando distriuições Gaussianas:

$$N(-2,1) \text{ e } N(2,1)$$




$$N\left(0, \frac{1}{2}\right)$$

$$N(-2,1) \text{ e } N(2,3)$$




$$N\left(-1, \frac{3}{4}\right)$$



Kalman Filter

$$\begin{cases} \vec{x}_k &= \Phi_{k-1} \vec{x}_{k-1} + \vec{w}_{k-1} \\ \vec{z}_k &= H_k \vec{x}_k + v_k \end{cases}$$


- \vec{x}_k é o vetor de estados, de dimensão n , e Φ_k é a matriz de transição ($n \times n$).



Kalman Filter

$$\begin{cases} \vec{x}_k &= \Phi_{k-1} \vec{x}_{k-1} + \vec{w}_{k-1} \\ \vec{z}_k &= H_k \vec{x}_k + v_k \end{cases}$$


- \vec{x}_k é o vetor de estados, de dimensão n , e Φ_k é a matriz de transição ($n \times n$).
- \vec{w}_k é um ruído branco de dimensão n com covariância $E[\vec{w}_k \vec{w}_i^\top] = \begin{cases} Q_k, & i = k \\ 0 & i \neq k. \end{cases}$



Kalman Filter

$$\begin{cases} \vec{x}_k &= \Phi_{k-1} \vec{x}_{k-1} + \vec{w}_{k-1} \\ \vec{z}_k &= H_k \vec{x}_k + v_k \end{cases}$$


- \vec{x}_k é o vetor de estados, de dimensão n , e Φ_k é a matriz de transição ($n \times n$).
- \vec{w}_k é um ruído branco de dimensão n com covariância $E[\vec{w}_k \vec{w}_i^T] = \begin{cases} Q_k, & i = k \\ 0 & i \neq k. \end{cases}$
- \vec{z}_k é o vetor observações (dim. m), e H_k é a matriz de observação ideal ($m \times n$).



Kalman Filter

$$\begin{cases} \vec{x}_k &= \Phi_{k-1} \vec{x}_{k-1} + \vec{w}_{k-1} \\ \vec{z}_k &= H_k \vec{x}_k + v_k \end{cases}$$

- \vec{x}_k é o vetor de estados, de dimensão n , e Φ_k é a matriz de transição ($n \times n$).
- \vec{w}_k é um ruído branco de dimensão n com covariância $E[\vec{w}_k \vec{w}_i^\top] = \begin{cases} Q_k, & i = k \\ 0 & i \neq k. \end{cases}$
- \vec{z}_k é o vetor observações (dim. m), e H_k é a matriz de observação ideal ($m \times n$).
- \vec{v}_k é um ruído branco de dimensão m com covariância $E[\vec{v}_k \vec{v}_i^\top] = \begin{cases} R_k, & i = k \\ 0 & i \neq k. \end{cases}$



Predição

Para predição utilizamos apenas a primeira equação do sistema:

$$\vec{x}'_k = \Phi_{k-1} \vec{x}_{k-1} + \vec{w}_{k-1}$$

onde $\hat{x}_{k-1} = E[\vec{x}_{k-1}]$, $P_{k-1} = E[(\vec{x}_{k-1} - \hat{x}_{k-1})(\vec{x}_{k-1} - \hat{x}_{k-1})^\top]$.

Qual é o valor de \hat{x}'_k e de P'_k ?

Predição

Para predição utilizamos apenas a primeira equação do sistema:


$$\vec{x}'_k = \Phi_{k-1} \vec{x}_{k-1} + \vec{w}_{k-1}$$

onde $\hat{x}_{k-1} = E[\vec{x}_{k-1}]$, $P_{k-1} = E[(\vec{x}_{k-1} - \hat{x}_{k-1})(\vec{x}_{k-1} - \hat{x}_{k-1})^\top]$.

Qual é o valor de \hat{x}'_k e de P'_k ?

$$\hat{x}'_k = \Phi_{k-1} \hat{x}_{k-1}$$

$$P'_k = \Phi_{k-1} P_{k-1} \Phi_{k-1}^\top + Q_{k-1}$$




Correção

Temos uma observação: Gaussiana com média y_k e covariância R_k .

Melhor estimativa será uma “média ponderada”

$$\vec{x}_k \sim (1 - K)\text{predição} + K \text{observação}$$

reinterpretamos como



Correção


Temos uma observação: Gaussiana com média y_k e covariância R_k .

Melhor estimativa será uma “média ponderada”

$$\vec{x}_k \sim (1 - K)\text{predição} + K \text{observação}$$

reinterpretamos como

$$\vec{x}_k \sim \text{predição} + K(\text{observação} - \text{predição})$$




Correção II

Efetivamente

$$\hat{x}_k = \hat{x}'_k + K_k(\vec{y}_k - H_k \hat{x}'_k)$$

e

$$P_k = (I - K_k H_k) P'_k$$



Correção II

Efetivamente


$$\hat{x}_k = \hat{x}'_k + K_k(\vec{y}_k - H_k \hat{x}'_k)$$

e

$$P_k = (I - K_k H_k) P'_k$$

Para obtermos estabilidade numérica:


$$P_k = (I - K_k) P'_k (I - K_k)^T + K_k R_k K_k^T$$



Filtro de Kalman

1. Predição:

$$\hat{x}'_k = \Phi_{k-1} \hat{x}'_{k-1}$$
$$P'_k = \Phi_{k-1} P_{k-1} \Phi_{k-1}^\top$$



Filtro de Kalman

1. **Predição:** $\hat{x}'_k = \Phi_{k-1} \hat{x}'_{k-1}$
 $P'_k = \Phi_{k-1} P_{k-1} \Phi_{k-1}^\top$

2. **Peso:** $P'_k H_k^\top (H_k P'_k H_k^\top + R_k)^{-1}$




Filtro de Kalman

1. **Predição:** $\hat{x}'_k = \Phi_{k-1} \hat{x}'_{k-1}$
 $P'_k = \Phi_{k-1} P_{k-1} \Phi_{k-1}^\top$

2. **Peso:** $P'_k H_k^\top (H_k P'_k H_k^\top + R_k)^{-1}$

3. **Correção:** $\hat{x}_k = \hat{x}'_{k-1} + K_k (\vec{y}_k - H_k \hat{x}'_{k-1})$
 $P_k = (I - K_k) P'_k (I - K_k)^\top + K_k R_k K_k^\top$



Voltando ao exemplo trivial

Estimar um valor estático a partir de múltiplas medidas.

$$\begin{cases} x_k = x_{k-1} + w_k \\ y_k = x_k + v_k \end{cases}$$



Exemplo trivial

Predição: $\hat{x}'_k = \hat{x}_{k-1}$
 $P'_k = P_{k-1} + Q$

Peso: $K_k = \frac{P'_k}{P'_k + R}$

Correção: $\hat{x}_k = \hat{x}'_k + K_k(y_k - \hat{x}'_k)$
 $P_k = (I - K_k)P'_k$

