

IE009 - Processamento adaptativo de sinais

Uma das principais finalidades das variadas estratégias de filtragem adaptativa é tentar lidar com as incertezas presentes nos sinais e sistemas práticos. Por isso, é necessário lançar mão da teoria da probabilidade para definir adequadamente a informação que está sendo processada.

Teoria da Probabilidade

• experimento aleatório

- possível de ser repetido sob condições idênticas
- o resultado do experimento em qualquer realização não pode ser pré-determinado antes de sua ocorrência.
- deve haver uma regularidade estatística quando um grande número de realizações do experimento é executado, no sentido que um comportamento médio pode ser observado

Esta regularidade estatística dá origem à noção de frequência relativa.

• Seja Ω o conjunto de todos os possíveis resultados $\omega_i, i=1, \dots, M$ de um experimento aleatório. Um evento A é \forall subconjunto de Ω (elemento, subconjunto ou conjunto de subconjuntos). Se N é o número de realizações do experimento e N_A é o número de ocorrências do evento A , então a frequência relativa é $f = \frac{N_A}{N}$

Neste caso, define-se a probabilidade como $P\{A\} = \lim_{N \rightarrow \infty} N_A/N$.

• Kolmogorov

"A teoria da probabilidade, sendo uma disciplina da matemática, pode e deve ser desenvolvida com base em axiomas, tal como a álgebra e a geometria". (1)

Definição axiomática de probabilidade:

- seja um campo de probabilidade formado pela tripla $\{\Omega, \mathcal{F}, P\}$ onde Ω é o conjunto de todos os resultados possíveis (espaço amostral), \mathcal{F} é um campo que contém todos os eventos possíveis e $P\{A\}$ é a probabilidade do evento A . Esta medida, $P\{A\}$, é um número que satisfaz:

1) $P\{A\} \geq 0$

2) $P\{\Omega\} = 1$

3) Se $A \cap B = \emptyset$ (eventos disjuntos), então $P(A \cup B) = P(A) + P(B)$

Alguns resultados importantes:

• $P\{\bar{A}\} = 1 - P\{A\}$, onde \bar{A} é o complemento do conjunto A .

• $P\{A \cup B\} = P\{A\} + P\{B\} - P\{A \cap B\}$

• Independência: $P\{A \cap B\} = P\{A\} \cdot P\{B\}$

• Prob. condicional: $P\{A|B\} \triangleq \frac{P\{A \cap B\}}{P\{B\}}$

• Lei da probabilidade total: $P\{B\} = \sum_i P\{B \cap A_i\} = \sum_i P\{B|A_i\} \cdot P\{A_i\}$, onde $\{A_i\}$ representa um conjunto contável de eventos mutuamente exclusivos ($A_i \cap A_j = \emptyset$ para $i \neq j$) e exaustivo ($\cup_i A_i = \Omega$).

* Variável Aleatória

É uma função $\Omega \rightarrow \mathbb{R}$ que mapeia cada possível resultado ω_i em um valor $X(\omega_i)$. Por exemplo, no caso do lançamento de uma moeda, $X(\text{CARA}) = +1$ e $X(\text{COROA}) = -1$.


Duas classes: VA discreta - pode assumir um n.º finito de valores (dado)

VA contínua - pode assumir um n.º infinito (não contável de valores (roleta))

Uma V.A. pode ser caracterizada por sua função distribuição de probabilidade, $F_X(x) = P\{X \leq x\}$ ou, equivalentemente, pela função densidade de probabilidade (p.d.f), $f_X(x) = \partial F_X(x) / \partial x$

Exemplo:

VA. contínua





roleta

$$F_{\Theta}(\theta) = P\{\Theta \leq \theta\} = \frac{\pi \cdot \theta}{2\pi\pi} = \frac{\theta}{2\pi}$$

Derivando em relação a θ :

$$f_{\Theta}(\theta) = 1/2\pi$$



Propriedades: * Monotonicamente crescente

* $F_X(-\infty) = 0, F_X(\infty) = 1$


* Sempre não-negativa

* $\int_{-\infty}^{\infty} f_X(x) dx = 1$

$$P\{x_1 < X \leq x_2\} = P\{X \leq x_2\} - P\{X \leq x_1\} = F_X(x_2) - F_X(x_1) = \int_{x_1}^{x_2} f_X(x) dx$$

Exemplo:



VA discreta



$x \in \{1, 2, 3, 4, 5, 6\}$


Dado

A PMF (probability mass function) define $P\{X=x\}$



Se pensássemos em p.d.f, teríamos impulsos nos valores de x em que

- V.A. gaussiana: $f_X(x) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ → totalmente definida pela média (μ) e pela variância (σ^2).



Qualquer transformação linear feita sobre uma VA gaussiana dá origem a uma outra VA gaussiana também.

- Quando temos duas ou mais VAs, falamos em distribuições e densidade conjuntas: $F_{X_1, X_2}(x_1, x_2) = P\{X_1 \leq x_1, X_2 \leq x_2\}$

$$\frac{\partial F_{X_1, X_2}(x_1, x_2)}{\partial x_1 \partial x_2} = f_{X_1, X_2}(x_1, x_2)$$

Se X_1 e X_2 forem independentes,

$$F_{X_1, X_2}(x_1, x_2) = F_{X_1}(x_1) \cdot F_{X_2}(x_2)$$

$$f_{X_1, X_2}(x_1, x_2) = f_{X_1}(x_1) \cdot f_{X_2}(x_2)$$

- Distribuição e densidade condicional:

$$F_{X_1|X_2}(x_1|x_2) = \frac{F_{X_1, X_2}(x_1, x_2)}{F_{X_2}(x_2)} \xrightarrow{\text{Teorema de Bayes}} F_{X_1|X_2}(x_1|x_2) = \frac{F_{X_1}(x_1)}{F_{X_2}(x_2)} \cdot F_{X_2|X_1}(x_2|x_1)$$


- Esperança ou média: $E\{X\} = \int_{-\infty}^{\infty} x f_X(x) dx$

- Variância: $V\{X\} = E\{(X - E\{X\})^2\} = \int_{-\infty}^{\infty} (x - E\{X\})^2 f_X(x) dx$

* Processos Estocásticos

Um processo aleatório $X(t)$ (ou $X(t, \omega_i)$) é a coleção de funções geradas por uma regra que associa uma função $x_i(t)$ a cada possível resultado ω_i de um experimento aleatório, $\omega_i \in \mathbb{R}$.

Espaço Amostral




No caso discreto, usamos a notação $X(n)$ (ou $X(n, \omega_i)$)

- ω está associado ao comportamento estatístico do processo
- n está associado ao comportamento temporal do processo
- se $\omega = \omega_i$ (fixo) $\rightarrow x_i(t)$ = função amostra do processo
- se $t = t_i$ (fixo) $\rightarrow X(t_i, \omega) =$ variável aleatória
- finalmente, se $\omega = \omega_i$ e $t = t_i$, $X(t_i, \omega_i)$ é apenas um número.

Caracterização de um processo aleatório

• Complete: é preciso conhecer as pdf's marginais e conjuntas (duas a duas, três a três, etc) dos V.A.s em todos os instantes de tempo.



K variáveis aleatórias: X_1, X_2, \dots, X_K

$F_{X_1, X_2, \dots, X_K}(x_1, x_2, x_3, \dots, x_k)$ ou $F_{\underline{X}}(\underline{x})$, onde

$\underline{X} = [X_1, X_2, \dots, X_K]^T$ é um vetor aleatório

A distribuição (ou pdf) conjunta que caracteriza o processo é o máximo de informação que podemos ter a seu respeito

Entretanto, é bastante difícil e/ou raro ter esse tipo de conhecimento a respeito do processo estocástico.

• Parcial: baseia-se em medidas estatísticas até 2ª ordem.

- média: $E\{X(n)\} = \int_{-\infty}^{\infty} x(n) f_X(x) dx \rightarrow$ valor médio ou nível DC

- variância: $E\{[X(n) - E\{X(n)\}]^2\} \rightarrow$ espalhamento ou dispersão em torno da média

- autocorrelação: $R_X(n_1, n_2) = E\{X(n_1)X(n_2)\}$

\Rightarrow Estacionariedade: dizemos que um processo estocástico $X(n)$ é estritamente estacionário se o seu comportamento estatístico, representado por $f_{X(n_1), X(n_2), \dots, X(n_k)}(x_1, \dots, x_k)$ não varia com o tempo (ou com a janela de observações):

$$f_{X(n_1), X(n_2), \dots, X(n_k)}(x_1, x_2, \dots, x_k) = f_{X(n_1+m), \dots, X(n_k+m)}(x_1, \dots, x_k)$$

Se a igualdade é verdadeira para $\forall m$, o processo é estacionário no sentido estrito.

- $K=1$: $f_{X(n)}(x) = f_{X(n+m)}(x) = f_X(x) \rightarrow$ para todos n e m .

- $K=2$: $f_{X(n_1), X(n_2)}(x_1, x_2) = f_{X(0), X(n_2-n_1)}(x_1, x_2) \rightarrow$ para todos n_1 e n_2
e $m = -n_1$

A pdf. conjunta de segunda ordem de um processo estacionário depende somente da diferença de tempo entre as amostras, e não dos instantes particulares de observação.

Consequências: — média constante: $E\{X(n)\} = m_X$

— autocorrelação depende apenas da diferença de tempo: $R_X(m) = E\{X(n)X(n-m)\}$

Opção menos restritiva: Estacionariedade no sentido amplo ou WSS (Wide-Sense Stationary)

• neste caso, as condições impostas são (1) média constante e (2) função de autocorrelação que não depende dos instantes das observações, mas apenas do intervalo de tempo entre elas. Essas duas características são observadas ^{também} em processos estacionários no sentido estrito, conforme vimos anteriormente. Ou seja, estacionariedade implica WSS mas o contrário não é necessariamente verdadeiro.

A caracterização de um processo aleatório, mesmo no contexto mais simples (WSS), requer o cálculo de esperanças estatísticas levando em consideração todos os possíveis resultados ω_i do espaço amostral subjacente. Na prática, porém, temos acesso a um n.º limitado de funções amostra $x_i(t)$. Seria interessante poder, então, substituir médias estatísticas por médias temporais.

Ergodicidade: as médias temporais "equivalem" às médias estatísticas do processo.

• média temporal: $K_1(x, T) = \frac{1}{2T} \int_{-T}^T x(t) dt \rightarrow$ média estatística: $E\{x(t)\} = k_1(x)$
↓
função de variável aleatória \rightarrow é uma VA.

Um processo $X(t)$ é ergódico na média se:

1) $\lim_{T \rightarrow \infty} K_1(x, T) = k_1(x)$

2) $\lim_{T \rightarrow \infty} \text{Var}\{K_1(x, T)\} = 0$

• Autocorrelação: $R_x(\tau, T) = \frac{1}{2T} \int_{-T}^T x(t+\tau)x(t) dt \rightarrow$ estimativa temporal

$X(t)$ é ergódico em relação à função de autocorrelação se:

1) $\lim_{T \rightarrow \infty} R_x(\tau, T) = R_x(\tau)$

2) $\lim_{T \rightarrow \infty} \text{Var}\{R_x(\tau, T)\} = 0$

Ciclostationariedade: as propriedades estatísticas do processo variam com o tempo, mas são periódicas com período T .

$$f_{X(n_1), X(n_2), \dots, X(n_k)}(x_1, x_2, \dots, x_k) = f_{X(n_1+T), X(n_2+T), \dots, X(n_k+T)}(x_1, x_2, \dots, x_k)$$

⇒ Autocorrelação e Densidade Espectral de Potência

• a função de autocorrelação é uma estatística de 2ª ordem que exprime uma similaridade entre duas variáveis aleatórias, $X(n_1)$ e $X(n_2)$, i. e., duas amostras temporais de um processo separadas por um intervalo de tempo m

$R_X(m) = E\{X(n)X^*(n-m)\}$, onde $X(n)$ é um processo estacionário e discreto no tempo.

Para um processo estacionário, $R_X(m)$ é uma função determinística. O tipo de informação presente nela pode ser avaliado também no domínio da frequência por meio da transformada de Fourier de $R_X(m)$.

A densidade espectral de potência de $X(n)$ é definida como a transformada de Fourier de $R_X(m)$:

$$S_X(e^{j\omega}) = \mathcal{F}\{R_X(m)\} = \sum_{m=-\infty}^{\infty} R_X(m) e^{-j\omega m}, \quad \omega \in [-\pi, \pi]$$

Analogamente:

$$R_X(m) = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_X(e^{j\omega}) e^{j\omega m} d\omega \quad \text{para } m \in \mathbb{Z}$$


Autocovariância: $C_X(m) = E\{[X(n) - m_X][X(n-m) - m_X]\}$, $m_X = E\{X(n)\}$

• quando $R_X(m) = 0$, temos a condição de ortogonalidade; quando $C_X(m) = 0$, falamos de descorrelação.

• $\sigma_X^2 = \text{variância de } X(n) = C_X(0)$.

• $R_X(0) = E\{X^2(n)\} = \text{valor quadrático médio de } X(n)$.

* Filtragem de um processo estocástico WSS



A saída $Y(n)$ do sistema linear e invariante com o tempo também será um processo estocástico. É possível relacionar as propriedades estatísticas de $Y(n)$ com as de $X(n)$.

• MÉDIA: $E\{Y(n)\} = E\left\{\sum_{k=-\infty}^{\infty} h(k) x(n-k)\right\}$

$$= \sum_{k=-\infty}^{\infty} h(k) E\{X(n-k)\}$$

$$m_Y = \sum_{k=-\infty}^{\infty} h(k) \cdot m_X = \underline{H(0) \cdot m_X},$$

onde m_X é a média do processo de entrada $X(n)$ e

$$H(f) = \sum_{n=-\infty}^{\infty} h(n) e^{-j2\pi f n} \quad \text{e} \quad H(0) = H(f)|_{f=0}$$

• AUTOCORRELAÇÃO:

$$E\{Y(n)Y(n+k)\} = E\left\{\sum_{i=-\infty}^{\infty} h(i)x(n-i) \sum_{j=-\infty}^{\infty} h(j)x(n+k-j)\right\}$$

$$= \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} h(i)h(j) \underbrace{E\{x(n-i)x(n+k-j)\}}_{R_X(k-j+i)}$$

Logo, podemos escrever:

$$E\{Y(n)Y(n+k)\} = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} h(i)h(j) R_X([k+i]-j)$$

$$= \sum_{i=-\infty}^{\infty} h(i) \sum_{j=-\infty}^{\infty} h(j) R_X([k+i]-j)$$

Seja $g(n) = h(n) * R_x(n) = \sum_{m=-\infty}^{\infty} h(m) R_x(n-m)$. Então:

$$E\{Y(n)Y(n+k)\} = \sum_{i=-\infty}^{\infty} h(i) \sum_{j=-\infty}^{\infty} h(j) R_x((k+i)-j)$$

$$R_y(-k) = \sum_{i=-\infty}^{\infty} h(i) g(k+i)$$

Trocando o índice do somatório por $l = -i$:

$$R_y(-k) = \sum_{l=-\infty}^{\infty} h(-l) g(k-l)$$

$$R_y(-k) = h(-k) * g(k)$$

Como $g(k) = h(k) * R_x(k)$, chegamos a $R_y(-k) = h(-k) * h(k) * R_x(k)$
 Como $Y(n)$ real $\rightarrow R_y(k) = R_y(-k)$

• DENSIDADE ESPECTRAL DE POTÊNCIA:

$$S_y(f) = \mathcal{F}\{R_y(k)\} = \mathcal{F}\{h(-k) * h(k) * R_x(k)\}$$

Como $\mathcal{F}\{h(k)\} = H(f)$, $\mathcal{F}\{h(-k)\} = H^*(f)$ e $\mathcal{F}\{R_x(k)\} = S_x(f)$, temos:

$$S_y(f) = H(f) H^*(f) S_x(f) \Rightarrow \boxed{S_y(f) = |H(f)|^2 S_x(f)}$$

OBSERVAÇÃO: Se $X(n)$ for um processo aleatório gaussiano, $Y(n)$ também será gaussiano.

\Rightarrow MATRIZ DE AUTOCORRELAÇÃO

Considerando M amostras de um processo $X(n)$, podemos construir o vetor $\underline{X}(n) = [X(n) \ X(n-1) \ \dots \ X(n-M+1)]^T \rightarrow M$ variáveis aleatórias

$$R_x = E\{\underline{X}(n) \underline{X}^H(n)\}$$

$$= E\left\{ \begin{bmatrix} X(n) \\ \vdots \\ X(n-M+1) \end{bmatrix} \cdot \begin{bmatrix} X^*(n) & \dots & X^*(n-M+1) \end{bmatrix} \right\}$$

$$R_X = \begin{bmatrix} E\{X(n)X^*(n)\} = R_X(0) & E\{X(n)X^*(n-1)\} = R_X(+1) & \dots & R_X(M-1) \\ E\{X(n-1)X^*(n)\} = R_X(-1) & E\{X(n-1)X^*(n-1)\} = R_X(0) & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ R_X(-(M-1)) & \dots & \dots & R_X(0) \end{bmatrix}$$

Se $X(n)$ é complexo, R_X é hermitiana pois $R_X = R_X^H$.

Se $X(n)$ é real, R_X é simétrica pois $R_X(i) = R_X(-i)$.

Ruído Branco:

É um processo aleatório WSS composto por uma sequência de variáveis aleatórias desconhecidas, todas com a mesma variância.

- Ruído branco gaussiano (WGN)

Sequência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d.) com p.d.f. marginal gaussiana

$$X(n) \sim N(0, \sigma^2) \text{ para } -\infty < n < \infty$$

Por ser i.i.d., o processo é estacionário.

$$\begin{aligned} f_{X(n_1), X(n_2), \dots, X(n_N)}(x_1, x_2, \dots, x_N) &\stackrel{\text{indep.}}{=} f_{X(n_1)}(x_1) f_{X(n_2)}(x_2) \dots f_{X(n_N)}(x_N) \\ &= \prod_{i=1}^N f_{X(n_i)}(x_i) \\ &= \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x_i^2}{2\sigma^2}\right) \\ &= \frac{1}{(2\pi\sigma^2)^{N/2}} \cdot \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^N x_i^2\right) \end{aligned}$$

A média do WGN é nula em todos os instantes de observação.


Autoconjugação:

$$R_x(k) = E\{X(n)X(n-k)\} \stackrel{\text{IND}}{=} E\{X(n)\} \cdot E\{X(n-k)\} = \begin{cases} E\{X^2(n)\} = \sigma^2, & k=0 \\ 0 & , k \neq 0 \end{cases}$$

$$\therefore \boxed{R_x(k) = \sigma^2 \cdot \delta(k)}$$

PSD:

$$\boxed{S_x(\omega) = \mathcal{F}\{R_x(k)\} = \sigma^2}, \quad -\pi < \omega < \pi$$

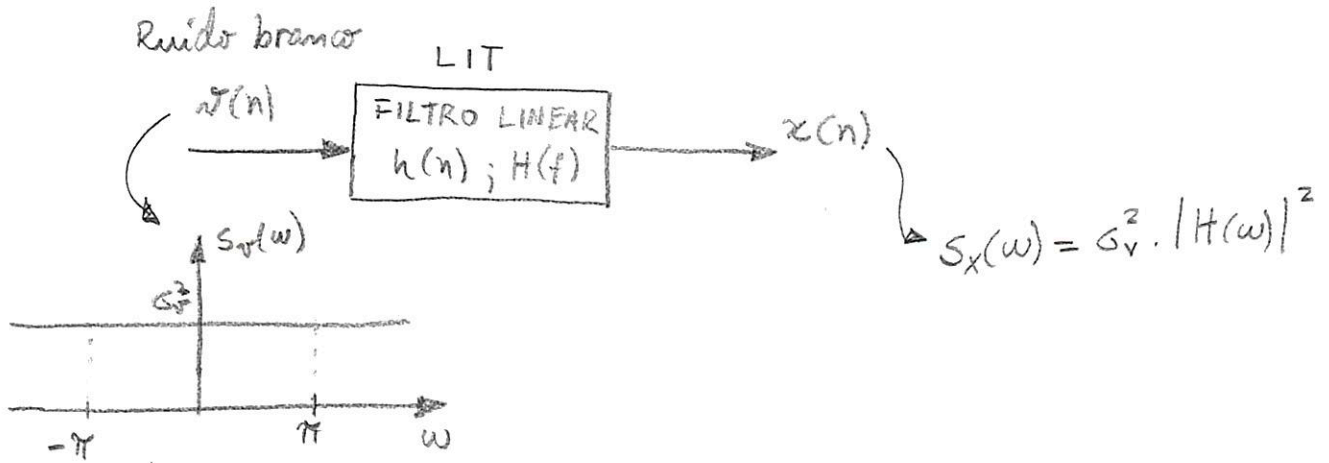


Matriz de autocorrelação:

$$\underline{X(n)} = [X(n) \ X(n-1) \ \dots \ X(n-M)]^T$$

$$R_x = E\{\underline{X(n)}\underline{X(n)}^H\} = \sigma^2 \cdot \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & \vdots \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} = \sigma^2 \cdot \underline{I}_M //$$

Processos obtidos a partir da filtração de um ruído branco



a) Processo de média móvel (MA)

$$x(n) = a_0 v(n) + a_1 v(n-1) + \dots + a_{M-1} v(n-M+1) = \sum_{i=0}^{M-1} a_i v(n-i)$$

$$X(z) = H(z) V(z) \Rightarrow H(z) = a_0 + a_1 z^{-1} + \dots + a_{M-1} z^{-(M-1)}$$

↳ filtro FIR (somente zeros)

b) Processo autoregressivo (AR)

$$x(n) = b_1 x(n-1) + b_2 x(n-2) + \dots + b_Q x(n-Q) + v(n)$$

↳ autoregressão de $x(n)$

$$H(z) = \frac{1}{(1 - b_1 z^{-1} - b_2 z^{-2} - \dots - b_Q z^{-Q})} \Rightarrow \text{Filtro IIR (somente pólos)}$$

c) Processo autoregressivo com média móvel (ARMA)

$$x(n) = a_0 v(n) + \dots + a_M v(n-M) + b_1 x(n-1) + \dots + b_Q x(n-Q)$$

$$H(z) = \frac{a_0 + a_1 z^{-1} + \dots + a_M z^{-M}}{1 - b_1 z^{-1} - \dots - b_Q z^{-Q}} \Rightarrow \text{pólos e zeros}$$

Processo AR

$$x(n) = -b_1 x(n-1) + b_2 x(n-2) + \dots + b_k x(n-k) + v(n)$$

$$x(n) - \sum_{i=1}^k b_i x(n-i) = v(n)$$

Multiplicando por $x^*(n-l)$ e calculando a esperança dos dois lados da equação, temos:

$$\underbrace{E\{x(n)x^*(n-l)\}}_{R_x(l)} - \sum_{i=1}^k b_i \underbrace{E\{x(n-i)x^*(n-l)\}}_{R_x(l-i)} = E\{v(n)x^*(n-l)\}$$

Note que $E\{v(n)x^*(n-l)\} = 0$ quando $l > 0$ pois,

neste caso, $v(n)$ e $x(n-l)$ são independentes e, como $E\{v(n)\} = 0$,

$E\{v(n)\} E\{x^*(n-l)\} = 0$. Assim,

$$R_x(l) = \sum_{i=1}^k b_i R_x(l-i), \quad l > 0$$

A partir deste resultado, podemos construir o seguinte sistema

de equações:

$$\underbrace{\begin{bmatrix} R_x(0) & R_x(1) & \dots & R_x(k-1) \\ R_x(1) & R_x(0) & \dots & R_x(k-2) \\ \vdots & \vdots & \ddots & \vdots \\ R_x(k-1) & R_x(k-2) & \dots & R_x(0) \end{bmatrix}}_{\substack{\text{matriz de autocorrelações de } x(n) \\ R_x}} \underbrace{\begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_k \end{bmatrix}}_{\underline{b}} = \underbrace{\begin{bmatrix} R_x(1) \\ R_x(2) \\ \vdots \\ R_x(M) \end{bmatrix}}_{\underline{r_x}} \left. \begin{array}{l} \rightarrow l=1 \\ \rightarrow l=2 \\ \vdots \\ \rightarrow l=M \end{array} \right\} \begin{array}{l} \text{Equações} \\ \text{de} \\ \text{Yule-Walker} \end{array}$$

$R_x \underline{a} = \underline{r}_x \Rightarrow \underline{a} = R_x^{-1} \underline{r}_x \rightarrow$ coeficientes do filtro que
gera um processo com auto-correlação $R_x(n)$ a partir de um
ruído branco.