

# Revisão de estatística

- O objetivo desta aula é apresentar técnicas e conceitos básicos de estatística que são comumente empregados em processamento de sinais.
- A ideia é revisar alguns princípios que são necessários para a compreensão das ferramentas serão apresentadas ao longo do curso
- Para complementar o que foi visto em sala sugere-se a leitura do livro: *Random data: Analysis and Measurement Procedures*. Dos autores: J. S. Bendat; A. G. Piersol.

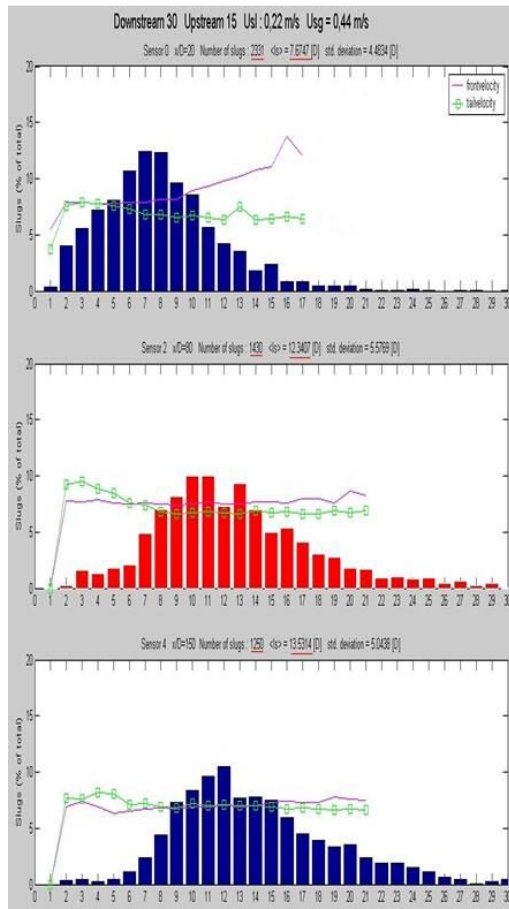
# Função densidade de probabilidade (PDF)

- O comportamento estatístico de diversos processos físicos e eventos pode ser associado à distribuições de probabilidade
- A compreensão e modelagem do problema pode ser bastante facilitada com a análise estatística
- Logo, o uso dessas ferramentas é muito útil para o processamento e análise de sinais
- Existem diversas particularidades, com relação a convergência e detalhes da amostragem dos dados para se representar de maneira adequada uma população.  
Esse conteúdo não é abordado nessa aula de conceitos básicos. Por isso, é importante utilizar referências do curso.

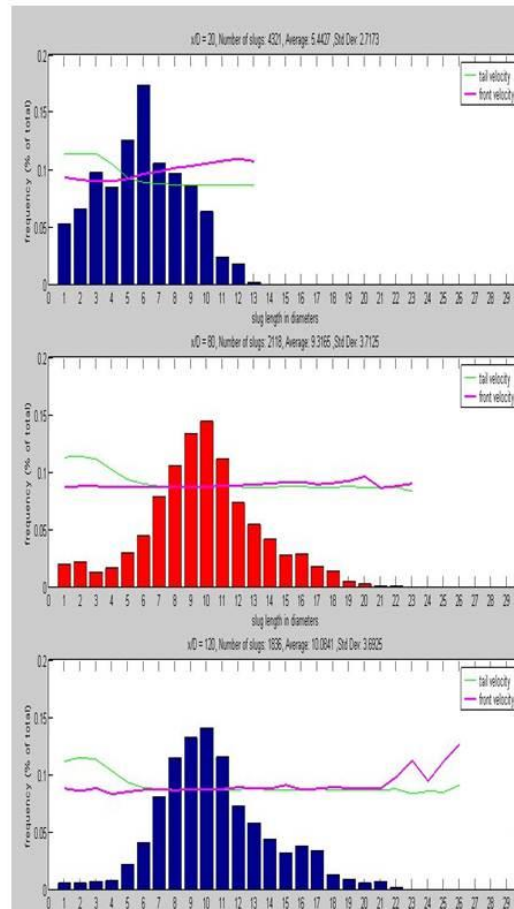
# Exemplo (exploração de óleo e gás)

## Slug length distributions. Normal slug flow




Experiments



Computations






Stratified flow upstream



Slug length in diameters

## Exemplo (cálculo de incerteza)

- No cálculo de incerteza de medições é necessário associar a incerteza de cada variável medida a um tipo de distribuição estatística. Exemplos:
- Normal: Maioria dos casos de grandezas contínuas
- LogNormal: Falha ou projeções de durabilidade. Eventos tendem a ser distorcidos na extremidade da distribuição.
- Binomial: comum em situações que envolvem somente duas possibilidades. Ex.: Cara/Coroa; Transmissão de informação digital



# Função densidade de probabilidade (PDF)

- Assumindo  $x(k)$  como uma variável de interesse qualquer. A função de densidade de probabilidade, contínua, para essa variável pode ser expressa como:

$$p(x) = \lim_{\Delta x \rightarrow 0} \left[ \frac{\text{Prob}[x < x(k) < x + \Delta x]}{\Delta x} \right]$$


- A função  $p(x)$  mostra a probabilidade de se encontrar diferentes valores de  $x(k)$  dentro de uma faixa de valores possíveis de  $x$ .
- Logo, por definição:

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

# Função densidade de probabilidade (PDF)

- Para dados discretos a função densidade de probabilidade pode ser ilustrada graficamente por um histograma
- Ex.: Medição de uma variável qualquer

Nº Medição	Valor Medido
1	5.3054
2	5.0934
3	4.9581
4	5.125
5	5.0366
6	4.794
7	5.1898
8	5.0614
9	5.027
10	5.103
11	5.0523
12	4.8117
13	4.9675
14	4.9708
15	4.8936



# Função densidade de probabilidade (PDF)

- Para dados discretos a função densidade de probabilidade pode ser ilustrada graficamente por um histograma

$$n_{\text{intervalos}} = 1.87 \cdot (N - 1)^{0.4} + 1$$

Nº Medição	Valor Medido
1	5.3054
2	5.0934
3	4.9581
4	5.125
5	5.0366
6	4.794
7	5.1898
8	5.0614
9	5.027
10	5.103
11	5.0523
12	4.8117
13	4.9675
14	4.9708
15	4.8936

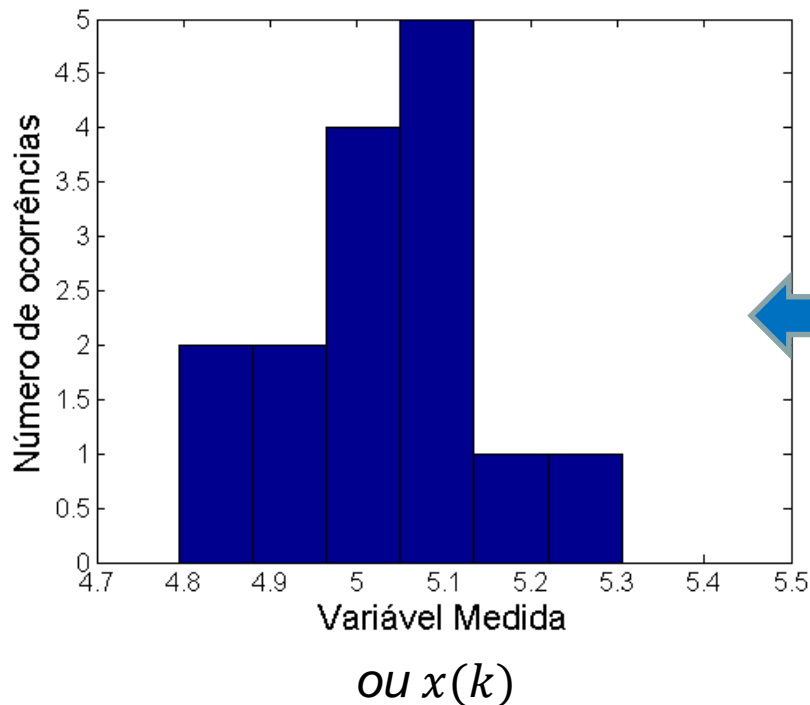


Nº Intervalo	Intervalo	nº ocorrências	nº ocorrências/N $f(n_i)$
1	$4.8 \leq x_i < 4.885$	2	0.13
2	$4.885 \leq x_i < 4.97$	2	0.13
3	$4.97 \leq x_i < 5.055$	4	0.27
4	$5.055 \leq x_i < 5.14$	5	0.33
5	$5.14 \leq x_i < 5.225$	1	0.07
6	$5.225 \leq x_i < 5.31$	1	0.07

# Função densidade de probabilidade (PDF)

- Para dados discretos a função densidade de probabilidade pode ser ilustrada graficamente por um histograma

$$n_{\text{intervalos}} = 1.87 \cdot (N - 1)^{0.4} + 1$$

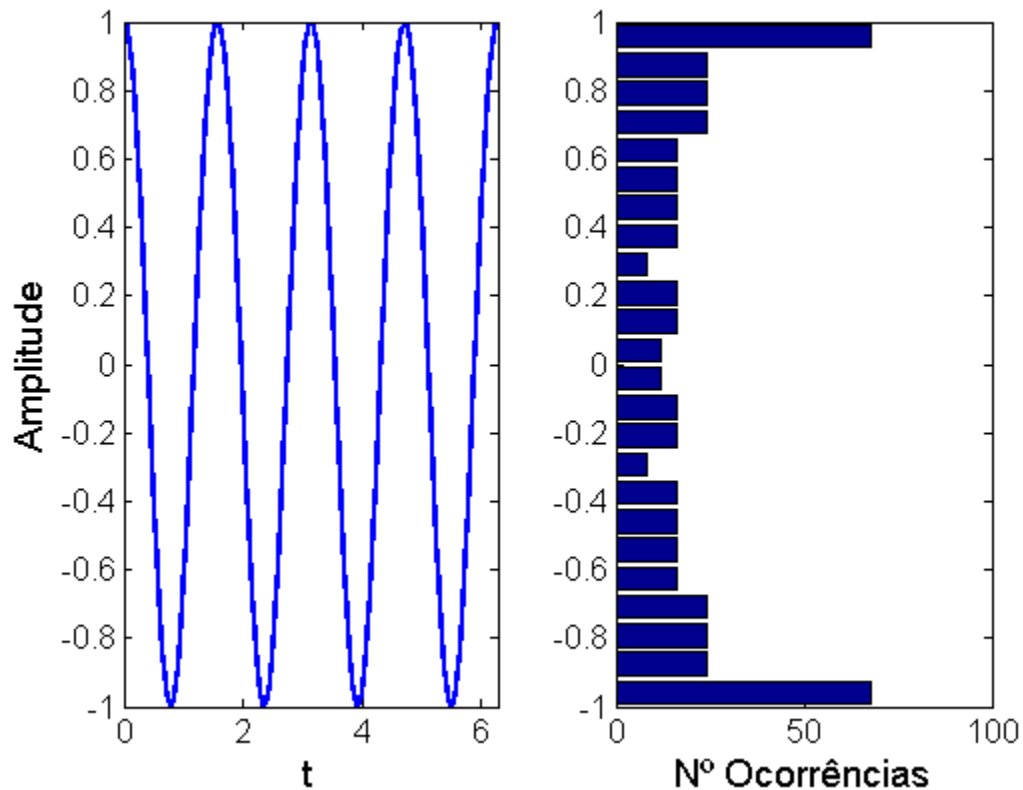


Nº Intervalo	Intervalo	nº ocorrências	nº ocorrências/N
1	$4.8 \leq x_i < 4.885$	2	0.13
2	$4.885 \leq x_i < 4.97$	2	0.13
3	$4.97 \leq x_i < 5.055$	4	0.27
4	$5.055 \leq x_i < 5.14$	5	0.33
5	$5.14 \leq x_i < 5.225$	1	0.07
6	$5.225 \leq x_i < 5.31$	1	0.07




# Função densidade de probabilidade (PDF)

- Exemplo de histogramas para diferentes sinais.
  - Sinal senoidal



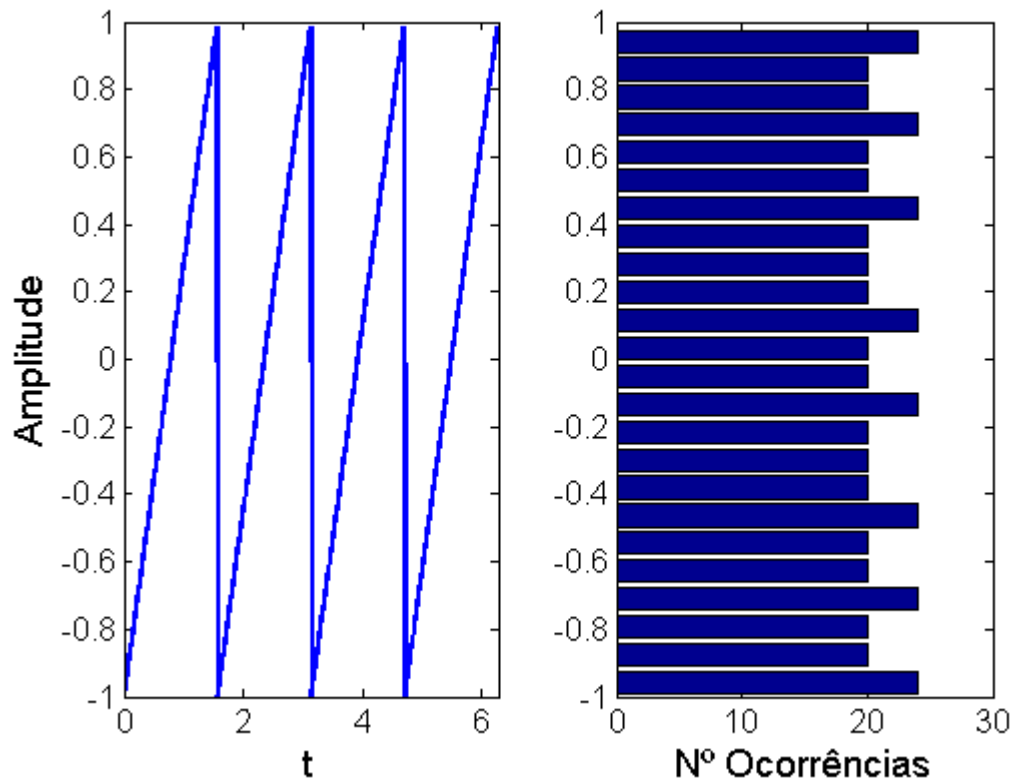
# Função densidade de probabilidade (PDF)

- Exemplo de histogramas para diferentes sinais.
  - Onda quadrada



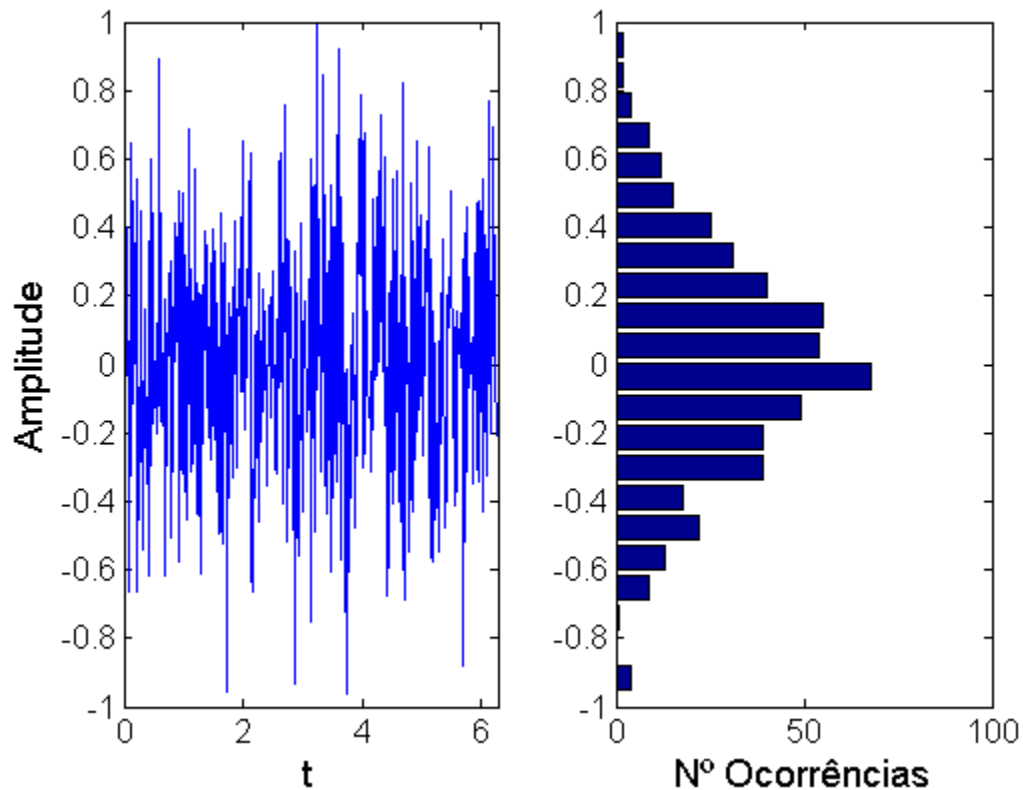
# Função densidade de probabilidade (PDF)

- Exemplo de histogramas para diferentes sinais.
  - Onda dente de serra



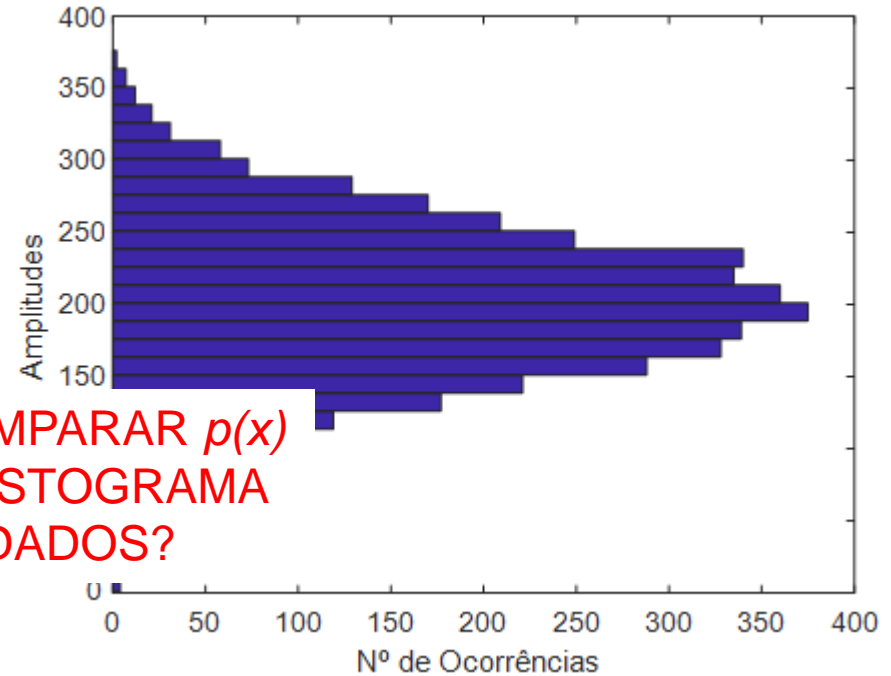
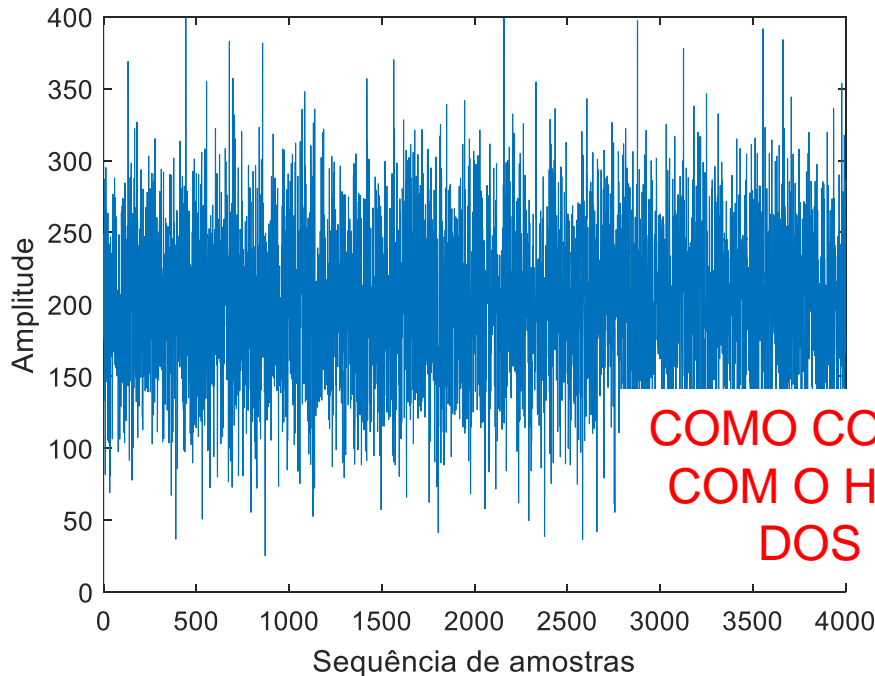
# Função densidade de probabilidade (PDF)

- Exemplo de histogramas para diferentes sinais.
  - Ruído branco (normal ou gaussiano)



# Função densidade de probabilidade (PDF)

➤ Ex.: Distribuição Normal



COMO COMPARAR  $p(x)$   
COM O HISTOGRAMA  
DOS DADOS?

➤ Estimando-se a média ( $\mu$ ) e o desvio padrão ( $\sigma$ ) das amostras e sabendo-se que  $p(x)$  para uma distribuição normal é:

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right]}$$

# Função densidade de probabilidade (PDF)


- Pode-se notar que os histogramas podem ilustrar qualitativamente o conceito de uma PDF
- Por que, então não são considerados como PDF's?
- A amplitude do histograma é normalmente expressa em número de ocorrências e a dispersão da variável  $x(k)$  em valores dimensionais, logo a integral do histograma é diferente de 1.
- Sendo assim, é necessário normalizar o histograma para que ele possa vir a representar uma PDF.

# Função densidade de probabilidade (PDF)

- Para normalizar um histograma é necessário simplesmente considerar que a frequência de ocorrências (ou  $n^{\circ}$  ocorrências/ $n^{\circ}$  de amostras) é obtido para um dado intervalo.
- Logo, deve-se normalizar a frequência de ocorrências pelo intervalo.
- Calculando-se a média e desvio padrão dos dados é possível comparar, qualitativamente, os dados obtidos com a função densidade de probabilidade correspondente

# Função densidade de probabilidade (PDF)


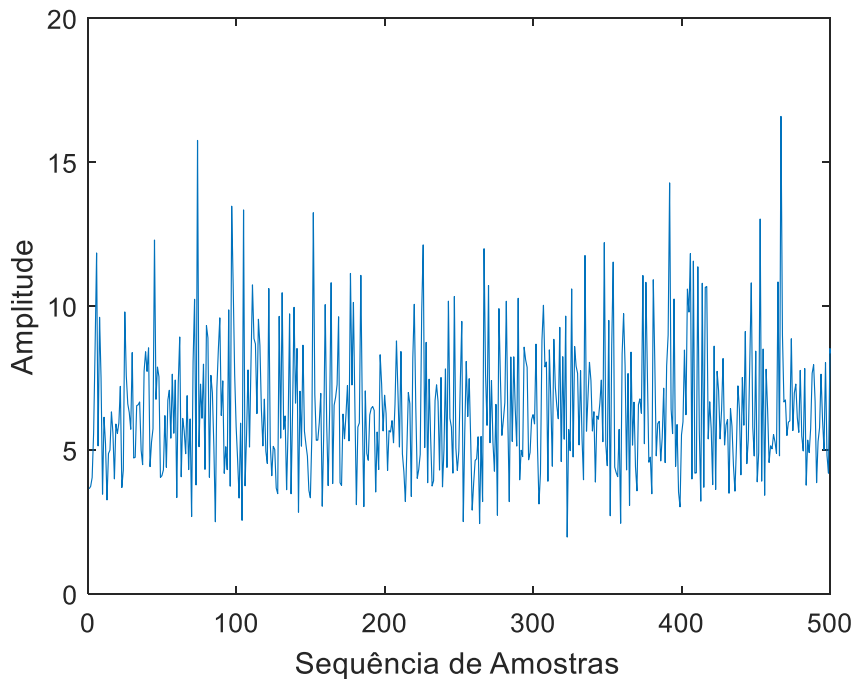
- A figura ilustra a comparação entre uma PDF obtida a partir de uma série de dados e a função  $p(x)$
- Onde  $\Delta x$  é o intervalo escolhido para o cálculo do nº de ocorrências
- Para verificar se o procedimento está correto, pode-se realizar a integral da área do histograma.
- O resultado tem que ser igual a 1





# Função densidade de probabilidade (PDF)

➤ Ex.: Distribuição LogNormal



$$p(x) = \frac{1}{x\sqrt{2\pi\sigma^{*2}}} e^{\left[-\frac{1}{2}\left(\frac{\ln(x)-\mu^*}{\sigma^*}\right)^2\right]}$$



onde

$$\mu^* = \ln\left(\frac{\mu^2}{\sqrt{\sigma + \mu^2}}\right)$$

$$\sigma^{*2} = \ln\left(\frac{\sigma}{\mu^2} + 1\right)$$

# Função densidade de probabilidade (PDF)

➤ Ex.: Distribuição  $\chi^2$



$$p(x) = \frac{1}{2^{k/2}\Gamma(k/2)} x^{\frac{k}{2}-1} e^{-\frac{x}{2}}$$



onde

$$\Gamma(n) = (n - 1)!$$

$$k = \mu$$

# Função densidade de probabilidade (PDF)

➤ Ex.: Distribuição exponencial



$$p(x) = \lambda e^{-\lambda x}$$

onde


$$\lambda = \frac{1}{\mu}$$

# Função densidade de probabilidade (PDF)

- Em alguns casos é possível normalizar os resultados para que sejam comparados com uma distribuição normal de média 0 e desvio padrão unitário

$$p(x) = \left( \frac{n_{\text{ocorrências}}}{N_{\text{amostras}}} \right) / \Delta x ; \quad p(x)_{\text{Normalizada}} = p(x) \cdot \sigma$$

$$x_{\text{normalizado}} = \frac{(x - \mu)}{\sigma}$$






PDF – área sob a curva contínua = 1

# Função densidade de probabilidade (PDF)

➤ Casos com mais de uma variável independente (ex.:  $x, y$ )


podem ter distribuições combinadas:  $p(x, y)$

No exemplo têm-se uma distribuição chi2 em  $x$  e exponencial em  $y$



# Análise básica de sinais – Motivação


- Imagine que o cilindro abaixo, representa um corte transversal de uma tubulação de um riser, por onde escoa um fluido internamente e há uma corrente marinha. O dispositivo dispõe de medidores de deformação da linha e um sensor de velocidade.



# Análise básica de sinais – Motivação

➤ A tubulação oscila e com os dados dos medidores de velocidade e deformação deseja-se saber :

- A oscilação é devida ao escoamento no interior da tubulação ou ao escoamento externo?
- O problema pode ser modelado através de pequenas perturbações (linear)?
- Em algum momento houve falha na leitura dos equipamentos?



**COMO VOCÊ FARIA PARA TENTAR  
RESPONDER ALGUMA DESSAS  
PERGUNTAS?**

# Covariância e coeficiente de correlação

- Nos casos com mais de uma variável independente (ex.:  $x, y$ ) a densidade de probabilidade combinada pode ser expressa como:  $p(x, y) = p(x)p(y)$

- Onde

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(x, y) dx dy = 1$$

- O valor esperado para para uma função contínua  $g(x, y)$  de duas variáveis  $x(k)$  e  $y(k)$  é dado por

$$E[g(x, y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) p(x, y) dx dy = 1$$

- No caso da função  $g(x, y)$  ser simplesmente o produto das variáveis independentes, sem a média



# Covariância e coeficiente de correlação

- No caso onde a função  $g(x,y)$  é simplesmente o produto das variáveis independentes, subtraídas das respectivas médias, tem-se:

$$g(x, y) = [x(k) - \mu_x][y(k) - \mu_y]$$



- Assim, tem-se a covariância.
- Pode-se notar que se  $x(k)=y(k)$ , tem-se a variância de  $x(k)$
- Para dados amostrados, a integral de  $g(x,y)p(x,y)$  pode ser escrita na forma de somatório:

$$\text{cov}(x, y) = \sum_{j=1}^N \frac{(x_j - \mu_x)(y_j - \mu_y)}{N}$$

# Covariância e coeficiente de correlação

➤ Covariância (medida da correlação entre 2 sinais).



$$\text{cov}(X, Y) = \sum_{j=1}^N \frac{(X_j - \mu_X)(Y_j - \mu_Y)}{N}$$



# Covariância e coeficiente de correlação

➤ Covariância (medida da correlação entre 2 sinais).


$$\text{cov}(X, Y) = \sum_{j=1}^N \frac{(X_j - \mu_X)(Y_j - \mu_j)}{N}$$



# Covariância e coeficiente de correlação

➤ Covariância (medida da correlação entre 2 sinais).

$$\text{cov}(X, Y) = \sum_{j=1}^N \frac{(X_j - \mu_X)(Y_j - \mu_Y)}{N}$$



A covariância só é diferente de zero quando os sinais x e y tiverem alguma correlação

# Covariância e coeficiente de correlação

- Pode-se deduzir, facilmente, uma relação entre covariância e os desvios padrões de  $x$  e  $y$ .

$$\text{cov}(x, x) = E[(x(k) - \mu_x)^2] = \sigma_x^2$$

$$\text{cov}(y, y) = E[(y(k) - \mu_y)^2] = \sigma_y^2$$

$$E[\sqrt{(x(k) - \mu_x)^2 (y(k) - \mu_y)^2}] = \sqrt{\sigma_x^2 \sigma_y^2} = \sigma_x \sigma_y$$

- Logo, o máximo valor que a covariância pode assumir, ocorre quando somente o produto entre as variâncias é considerado. Logo, a covariância pode ser normalizada por esse produto, assumindo valores entre -1 e 1. Essa razão é conhecida como coeficiente de correlação (c.c)

$$\text{c. c} = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y}$$

# Covariância– notação matricial

- Para o cálculo da covariância entre múltiplos dados, conforme ilustrado na matriz  $x$ , é conveniente utilizar a notação matricial.

$$x = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \dots & x_{1p} \\ x_{21} & x_{22} & x_{23} & \dots & x_{2p} \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & x_{n3} & \dots & x_{np} \end{bmatrix};$$

- Nesse caso, é necessário criar uma matriz dos desvios. O vetor das médias de cada coluna ( $j$ ) é dado por  $x_{mj}$  (assumindo dados estão dispostos em colunas, e  $1_n$  é um vetor de  $n \times 1$  )

$$x_{mj} = \left( \bar{x}_1, \bar{x}_2, \bar{x}_3, \dots, \bar{x}_p \right) = \frac{1}{n} 1_n' x_j$$

# Covariância– notação matricial

- A partir da média pode-se calcular a matriz de diferenças através da relação:

$$x_d = x - 1_n x_m = \begin{bmatrix} x_{11} - \bar{x}_1 & x_{12} - \bar{x}_2 & x_{13} - \bar{x}_3 & \dots & x_{1p} - \bar{x}_p \\ x_{21} - \bar{x}_1 & x_{22} - \bar{x}_2 & x_{23} - \bar{x}_3 & \dots & x_{2p} - \bar{x}_p \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1} - \bar{x}_1 & x_{n2} - \bar{x}_2 & x_{n3} - \bar{x}_3 & \dots & x_{np} - \bar{x}_p \end{bmatrix};$$

- Com isso a matriz de covariâncias pode ser reescrita na forma


$$\text{COV} = \frac{1}{n} x_d' x_d = \begin{bmatrix} \sigma_{11}^2 & \text{COV}_{12} & \text{COV}_{13} & \dots & \text{COV}_{1p} \\ \text{COV}_{21} & \sigma_{22}^2 & \text{COV}_{23} & \dots & \text{COV}_{2p} \\ \dots & \dots & \dots & \dots & \dots \\ \text{COV}_{n1} & \text{COV}_{n2} & \text{COV}_{n3} & \dots & \sigma_{np}^2 \end{bmatrix};$$

# Coeficiente de assimetria (skewness)

- É uma medida para quantificar a assimetria de um sinal. É comum a utilização para se identificar saturação de um sinal devido a efeitos não lineares. Ex.: ondas se aproximando da praia

**AJUDA A RESPONDER  
ALGUMA DAS PERGUNTAS?**

$$skewness = \frac{\frac{1}{N} \sum_{j=1}^N (X_j - \mu_X)^3}{\left( \sqrt{\frac{1}{N} \sum_{j=1}^N (X_j - \mu_X)^2} \right)^3}$$






# Curtose (Kurtosis)

- É uma medida do grau de espalhamento da distribuição de probabilidades. Isso faz com que seja útil para identificar dados espúrios (outliers) em uma sequência de dados.

$$Curtose = \frac{\frac{1}{N} \sum_{j=1}^N (X_j - \mu_X)^4}{\left( \frac{1}{N} \sum_{j=1}^N (X_j - \mu_X)^2 \right)^2}$$

**AJUDA A RESPONDER  
ALGUMA DAS PERGUNTAS?**



# Regressão linear

Regressão (Método dos Mínimos Quadrados)

Aproximação polinomial de ordem  $m$  dos dados:

$$f(x) = y = a_0 + a_1x + a_2x^2 + a_3x^3 \dots a_mx^m$$

A relação polinomial deve ser encontrada para um conjunto de  $N$  pontos de dados [da forma  $(x_i, y_i)$ ].

Dedução para eq. do 1º grau:

$$f(x) = y = a_0 + a_1x$$

onde  $y$  é a resultado da equação de ajuste e  $a_0$  e  $a_1$  são, respectivamente, os coeficientes linear e angular.

O desvio do ajuste pode ser dado por:

$$\Delta^2 = \sum (Y_i - y)^2$$

onde  $Y_i$  é um dos pontos medidos e  $y_i$  o ponto fornecido pelo ajuste

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

$$\Delta^2 = \sum (Y_i - y)^2$$

O objetivo é obter coeficientes que minimizem a soma dos erro quadrados, de modo que:

$$\frac{\partial \Delta^2}{\partial a_1} = \frac{\partial}{\partial a_1} \sum (Y_i - y)^2 = \frac{\partial}{\partial a_1} \sum (Y_i - a_1 x - a_0)^2 = 0$$

$$= \frac{\partial}{\partial a_1} \sum (Y_i^2 - 2Y_i a_1 x - 2Y_i a_0 + a_1^2 x^2 + 2a_1 x a_0 + a_0^2) = 0$$

$$= 2 \sum (Y_i - a_1 x - a_0)(-x) = 0$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

$$\Delta^2 = \sum (Y_i - y)^2$$

O objetivo é obter coeficientes que minimizem a soma dos erro quadrados, de modo que:

$$\frac{\partial \Delta^2}{\partial a_0} = \frac{\partial}{\partial a_0} \sum (Y_i - y)^2 = \frac{\partial}{\partial a_0} \sum (Y_i - a_1 x - a_0)^2 = 0$$

$$= \frac{\partial}{\partial a_0} \sum (Y_i^2 - 2Y_i a_1 x - 2Y_i a_0 + a_1^2 x^2 + 2a_1 x a_0 + a_0^2) = 0$$

$$= 2 \sum (Y_i - a_1 x - a_0)(-1) = 0$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Resolvendo para  $a_0$ :

$$\sum Y_i - a_1 \sum x - na_0 = 0$$

$$a_0 = \frac{\sum Y_i - a_1 \sum x}{n}$$

E substituindo para encontrar  $a_1$ :

$$\sum Y_i x - a_1 \sum x^2 - a_0 \sum x = 0$$

$$\sum Y_i x - a_1 \sum x^2 - \frac{(\sum Y_i - a_1 \sum x)}{n} \sum x = 0$$

$$a_1 = \frac{\sum Y_i \sum x - n \sum Y_i x}{(\sum x)^2 - n \sum x^2}$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Erro padrão do ajuste (1ª ordem):

$$S = \sqrt{\frac{\Delta^2}{N-2}} \rightarrow S = \sqrt{\frac{\sum (Y_i - y)^2}{N-2}}$$

$$S_{a0} = S \sqrt{\frac{\sum x^2}{n \sum x^2 - (\sum x)^2}} \quad S_{a1} = S \sqrt{\frac{n}{n \sum x^2 - (\sum x)^2}}$$

De maneira simplificada, é possível estimar um intervalo de confiança para os dados em torno do ajuste a partir do erro padrão experimental

$$\pm t_{N-1,P} \frac{S}{\sqrt{N}} (\%P)$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Existe uma solução para o problema envolvendo produto de matrizes, na forma:

$$a = (x^T x)^{-1} x^T y$$

Onde o expoente T se refere a transposta da matriz e -1 a inversa, com as matrizes  $x, y$  e  $a$  sendo :

$$y = \begin{bmatrix} y_0 \\ y_1 \\ \dots \\ y_n \end{bmatrix}; \quad x = \begin{bmatrix} 1 & x_0 \\ 1 & x_1 \\ \dots & \dots \\ 1 & x_n \end{bmatrix}; \quad a = \begin{bmatrix} a_0 \\ a_1 \end{bmatrix}$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Existe uma solução para o problema envolvendo produto de matrizes, na forma:

$$a = (x^T x)^{-1} x^T y$$

Prova :

$$x^T x = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_0 & x_1 & \dots & x_n \end{bmatrix} \cdot \begin{bmatrix} 1 & x_0 \\ 1 & x_1 \\ \dots & \dots \\ 1 & x_n \end{bmatrix} = \begin{bmatrix} n & \sum x \\ \sum x & \sum x^2 \end{bmatrix}$$

$$x^T y = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_0 & x_1 & \dots & x_n \end{bmatrix} \cdot \begin{bmatrix} y_0 \\ y_1 \\ \dots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum y \\ \sum xy \end{bmatrix}$$



# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Existe uma solução para o problema envolvendo produto de matrizes, na forma:

$$a = (x^T x)^{-1} x^T y$$

Prova :

$$(x^T x)^{-1} = \frac{1}{n \sum x^2 - (\sum x)^2} \begin{bmatrix} \sum x^2 & -\sum x \\ -\sum x & n \end{bmatrix}$$

Substituindo:

$$(x^T x)^{-1} x^T y = \frac{1}{n \sum x^2 - (\sum x)^2} \begin{bmatrix} \sum x^2 & -\sum x \\ -\sum x & n \end{bmatrix} \cdot \begin{bmatrix} \sum y \\ \sum xy \end{bmatrix}$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Existe uma solução para o problema envolvendo produto de matrizes, na forma:

$$a = (x^T x)^{-1} x^T y$$

Prova :

$$(x^T x)^{-1} x^T y = \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} = \frac{1}{n \sum x^2 - (\sum x)^2} \begin{bmatrix} \sum x^2 \sum y - \sum x \sum xy \\ - \sum x \sum y + n \sum xy \end{bmatrix}$$

Equação encontrada anteriormente:

$$a_1 = \frac{\sum Y_i \sum x - n \sum Y_i x}{(\sum x)^2 - n \sum x^2}$$

# Regressão linear

➤ Regressão (Método dos Mínimos Quadrados)

Polinômios de mais alta ordem também podem ser ajustados usando essa operação:

$$a = (x^T x)^{-1} x^T y$$

Só que nesses casos as matrizes ficam:

$$y = \begin{bmatrix} y_0 \\ y_1 \\ \dots \\ y_n \end{bmatrix}; \quad x = \begin{bmatrix} 1 & x_0 & x_0^2 & \dots & x_0^m \\ 1 & x_1 & x_1^2 & \dots & x_1^m \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_n & x_n^2 & \dots & x_n^m \end{bmatrix}; \quad a = \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ \dots \\ a_m \end{bmatrix}$$

Regressões de múltiplas variáveis também podem ser obtidas


# Regressão linear

## ➤ Exemplos

### ➤ Regressão (Método dos Mínimos Quadrados)

O método pode ser aplicado para a regressão de diversas funções, para isso é necessário somente encontrar uma escala adequada para os dados.

Ex.:  $y = ax^b$




# Regressão linear

## ➤ Exemplos

### ➤ Regressão (Método dos Mínimos Quadrados)

O método pode ser aplicado para a regressão de diversas funções, para isso é necessário somente encontrar uma escala adequada para os dados.

Ex.:  $y = ae^{bx}$




# Regressão linear

## ➤ Exemplos

### ➤ Regressão (Método dos Mínimos Quadrados)

O método pode ser aplicado para a regressão de diversas funções, para isso é necessário somente encontrar uma escala adequada para os dados.

$$\text{Ex.: } y = \frac{x}{a + bx}$$




# Regressão linear

## ➤ Exemplos

### ➤ Regressão (Método dos Mínimos Quadrados)

O método pode ser aplicado para a regressão de diversas funções, para isso é necessário somente encontrar uma escala adequada para os dados.

Ex.:  $y = 1 - e^{-bx}$





# Regressão linear

## ➤ Exemplos

### ➤ Regressão (Método dos Mínimos Quadrados)

O método pode ser aplicado para a regressão de diversas funções, para isso é necessário somente encontrar uma escala adequada para os dados.

$$\text{Ex. } y = a + b\sqrt{x}$$





# Exercícios em sala que devem ser finalizados e entregues na aula seguinte

Os dados para os exercícios estão disponíveis no site do curso

- Questão 1) Construir PDF's a partir de séries de dados (1D e 2D);
- Guia para demais tarefas:

Acessar os dados do arquivo fornecido. Para isso, o arquivo 'exercício.mat' deve ser copiado para o diretório corrente do matlab. Para carregar os dados digite no workspace o comando: `load('exercicio')`

---

## Mapa de variáveis

- time = vetor de tempo dos sinais (cada posição do vetor indica o instante em que o dado foi amostrado)
- signal = 4 diferentes tipos de sinais para serem classificados como: determinísticos periódicos ou transientes, aleatórios estacionários ergódicos, aleatórios estacionários não-ergódicos, e aleatórios não estacionários).
  - signal\_seq = sequência de 100 formas de onda para serem analisadas
  - ref\_signal = sinal de referência para comparação com a sequência de sinais amostrados
  - x\_1D, y\_1D = dados para ajuste de uma curva de uma calibração (1D e 2D)  
x1\_2D, x1\_2D e y\_2D

# Guia para o trabalho

- Questão 2) Mostrar gráfico dos sinais salvos na variável `signal` e classifica-los (ex. para visualizar o 1º. sinal: `plot(time,signal(:,1))` )
- Questão 3) Encontrar dentre as 100 formas de onda contidas na variável `signal_seq` qual se correlaciona mais com o sinal de referência (`ref_signal`).

Obs: Os dados de cada uma das 100 formas de onda estão salvos em uma coluna da variável `signal_seq`. (ex. para acessar os dados da 1ª forma de onda: `signal_seq(:,1)`).

- Questão 4) Fazer ajuste dos dados usando mínimos quadrados
  - a) Ajustar os dados `x_1D` e `y_1D` a uma função polinomial de 1ª ordem. Mostrar valor dos coeficientes linear e angular do ajuste.
  - b) Ajustar os dados `x2_1D` e `y2_1D` a uma função do tipo:  $y=x/(a+b*x)$ .
  - c) Ajustar os dados `x1_2D`, `x2_2D` e `y_2D` a uma função do tipo:  
 $y=a+b*x1+c*x1*x2+d*x3$