



# Sinais

Curso de **Processamento de Imagens e Sinais Biológicos**  
PISB - 2017

Cap. 1 : K. Najarian and R. Splinter, **Biomedical Signal and Image Processing** CRC Press - Taylor & Francis Group, 2006

**Aura Conci**

# O que é um Sinal ?

- Def.: **um Sinal 1D** é uma seqüência de números que descreve a variação de alguma variável.
- A ordem do número no sinal determina a ordem da medida no tempo ou no elemento que é feita a medição.

Exemplos:

- Variações da temperatura em um fio metálico;
- Umidade relativa de cada dia no ano;
- Sinais biológicos de EEG , ECG, EMG, etc..

# Os sinais podem ser:

- Analógicos:

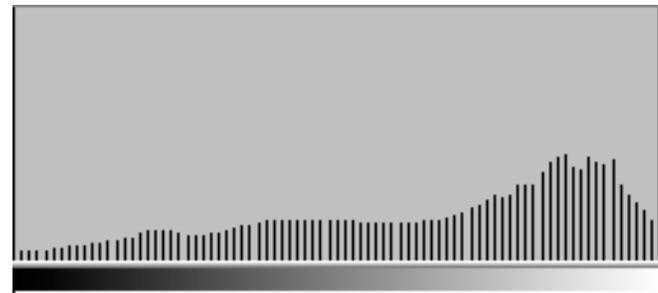
$$y = f(x) , \text{ onde } t \text{ é um numero Real}$$

*É variável é medida continuamente*

- Discretos:

$$g(nT_s) ,$$

A variável  $g$  é medida ou amostrado em múltiplos,  $n$ , do período de amostragem  $T^s$



- Digitais , é um sinal discreto definido em um certo intervalo e cujo valor da variável pode assumir um conjunto finito de valores (geralmente  $2^n$ )

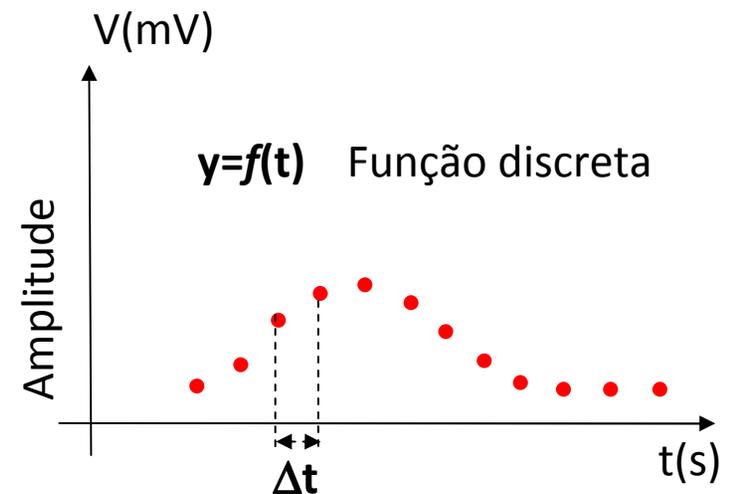
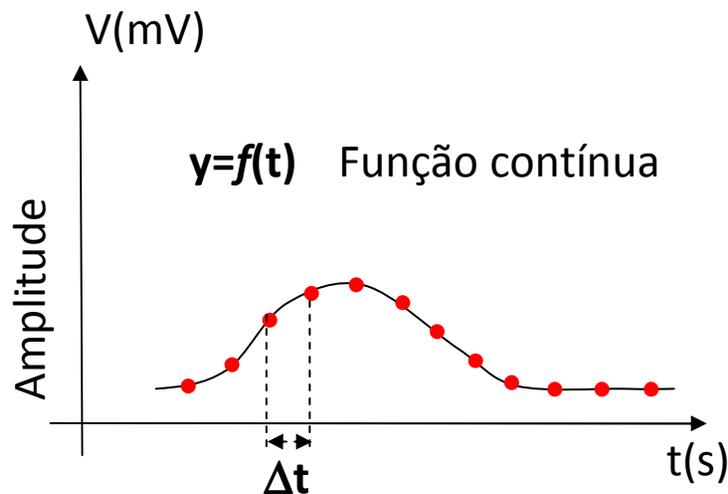
# Processamento digital do sinal (PDS ou DSP)

## Principais etapas do PDS

### Amostragem

- Coletar amostras do sinal cada um tempo fixo  $\Delta t$  chamado “intervalo de amostragem (*mseg*)”.
- A quantidade de amostras selecionadas em um segundo chamado “frequência de sample, de amostragem ou  $F_s$  (Hz)”

$$\Delta t = \frac{1}{F_s}$$



# Unidade de freqüência

- O **hertz** (símbolo **Hz**) é a unidade de medida do Sistema Internacional (SI), a qual expressa, em termos de ciclos por segundo, a freqüência de um evento periódico.

Rotações por segundo

(segundo<sup>-1</sup> ou 1/ segundo).

**Discretização** - conversão do sinal na forma contínua em uma representação discreta.

**Reconstrução** - processo inverso da discretização.

**Codificação** - a partir da representação discreta do sinal, gera um conjunto de dados representativos (dados estes que podem ser transformados no formato de arquivos).

**Decodificação** - processo oposto à codificação no qual acessam-se informações codificadas na forma de uma representação discreta.

$$y = f(x).$$

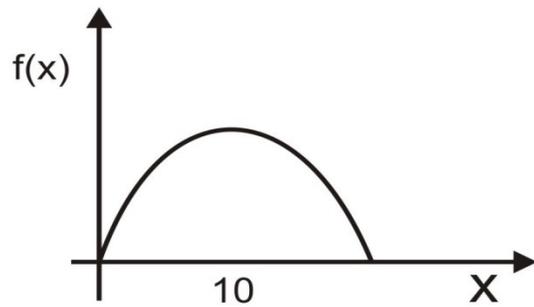
# Discretização

A forma de representar o mundo contínuo ou uma função contínua no computador é discretizando-a.

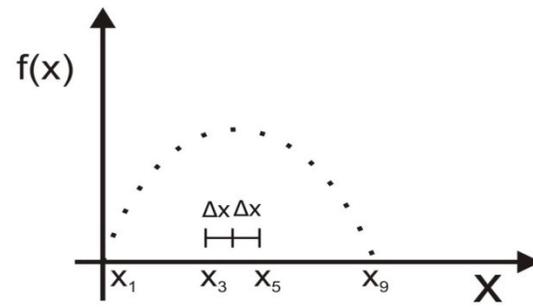
# Reconstrução

A operação que a partir dos valores discretos retorna uma aproximação do contínuo inicial é chamada de reconstrução.

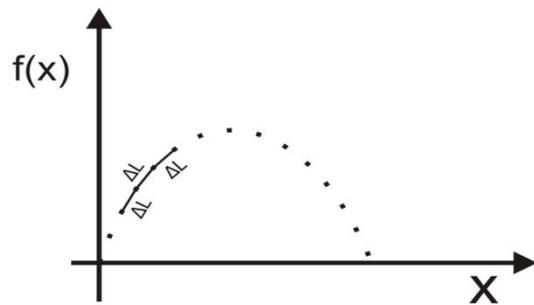
$$y = f(x).$$



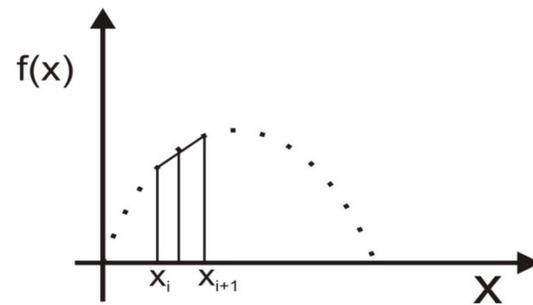
Representação Contínua



Representação Discreta a Intervalos Constantes em  $x$



Amostragem a Intervalos Constantes em Relação a Distância entre os pontos  $(x, f(x))$



Reamostragem Criando Valores Intermediários por Interpolação Linear por Pares de Valores Anteriores

## Formas de Representação de um sinal

$$y = f(x).$$

# Analógico - > Digitais

Para que sejam representadas no meio digital, seu comportamento analógico (contínuo) tem que ser convertido numa série de valores discretos (descontínuos).

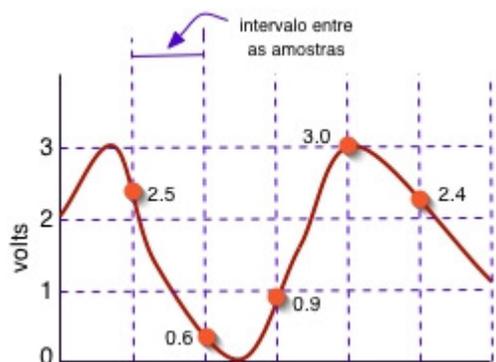
Esses valores são números (dígitos) que representam amostras (samples em inglês)

# Amostragem

A conversão do sinal analógico para o digital é realizada por uma sequência de amostras da variação de voltagem do sinal original.

Cada amostra é arredondada para o número mais próximo da escala usada e depois convertida em um número digital binário (formado por "uns" e "zeros") para ser armazenado.

As amostras são medidas em intervalos fixos.



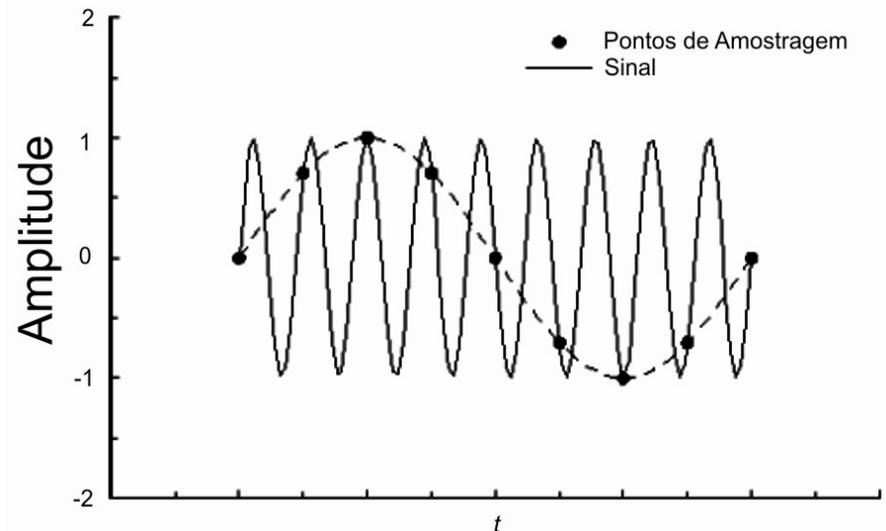
valores das amostras				
2.5	0.6	0.9	3.0	2.4
valores quantizados				
2	0	1	3	2
valores convertidos em digitos binários				
10	00	01	11	10

O número de vezes em que se realiza a amostragem em uma unidade de tempo é a taxa de amostragem

## Quando se tem equivalencia entre analógico e discreto

(valores pequenos de intervalo de tempo? )

Ocorre problemas quando a frequência de amostragem é inferior à frequência de Nyquist.



Pode ocorrer que

o sinal digitalizado fique completamente diferente do sinal original

devido a sua baixa frequência de amostragem.

# Teorema de Nyquist

A taxa de amostragem deve ser pelo menos duas vezes a maior frequência que se deseja registrar.

Esse valor é conhecido como frequência de Nyquist.

Ao se tentar reproduzir o sinal em uma frequência menor do que a frequência de Nyquist ocorre o fenômeno de *aliasing* (ou *foldover* )

# Curiosidade:

/naikwist/, em sueco: [ny:kvist];

- Nyquist nasceu em Stora Kill, Värmland, Suécia.

Seus pais tiveram muitos filhos: Elin, Teresia, Astrid, Selma, Harry, Theodor, Aemelie, Olga, Maria e Axel.

Mas nenhum deles foi batizado.

Imigrou para os USA em 1907.

# Segundo o **Teorema de Nyquist**,

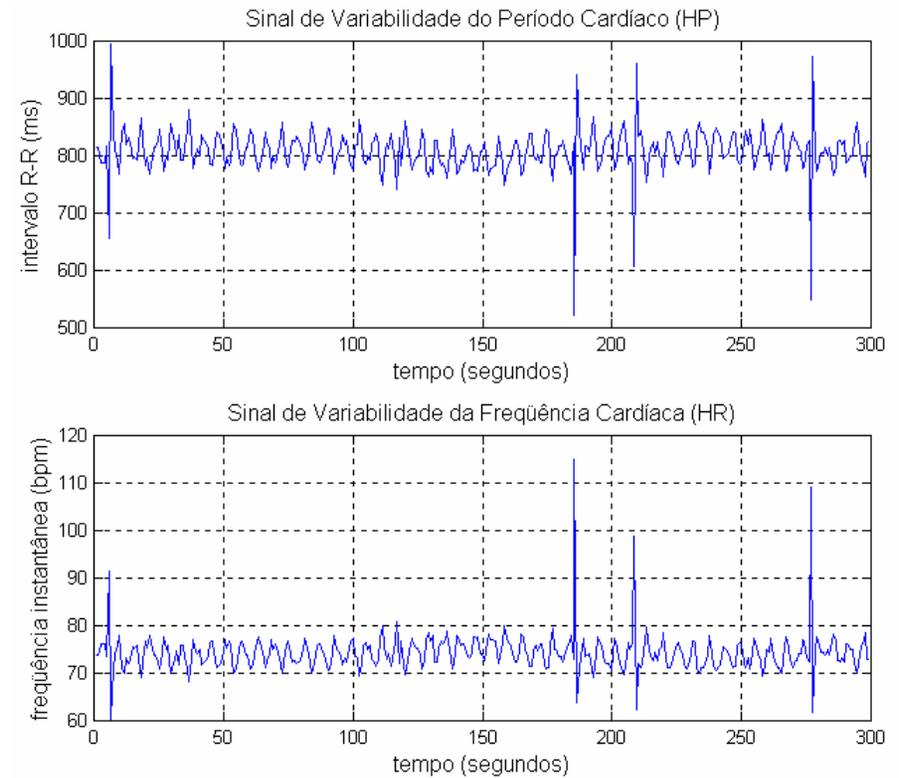
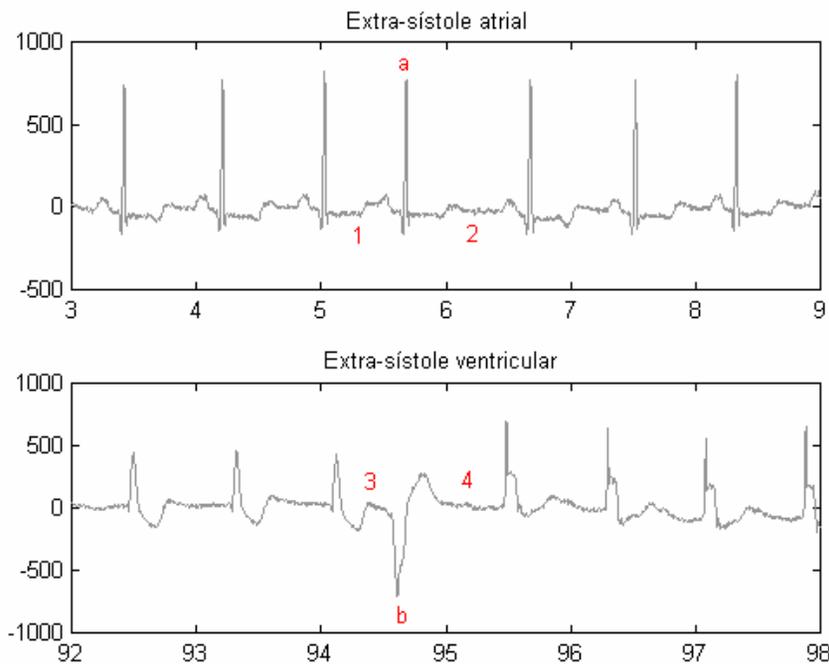
a frequência de amostragem de um sinal analógico, para que possa posteriormente ser reconstituído com o mínimo de perda de informação, deve ser igual ou maior a duas vezes a maior frequência desse sinal.

# Aplicações de sinais

- Em Biomédica 1D – ECG
- +- 20 – EEG
- nD – térmicos – EMG , etc...

# Eletro Cardio Grama - ECG

## Sinais do Coração



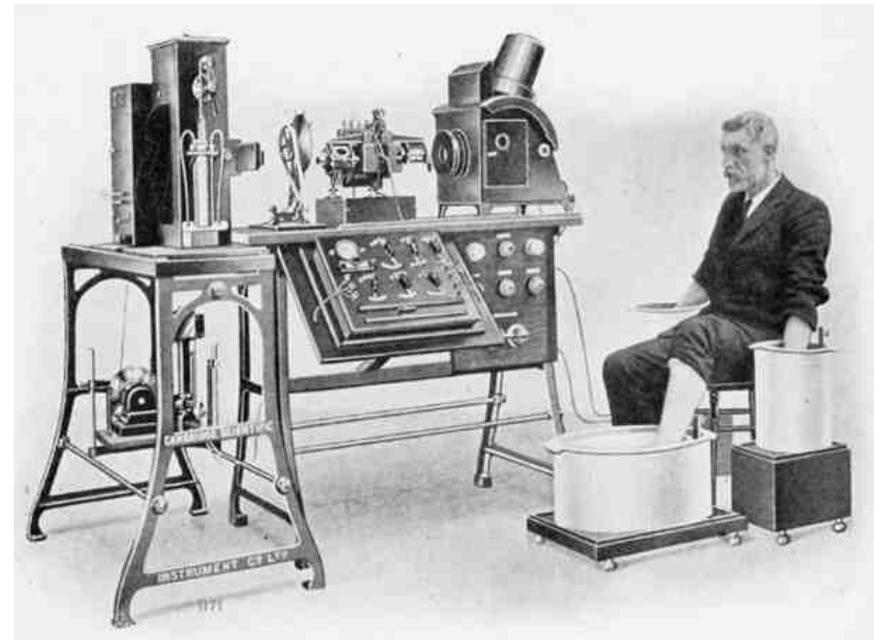
# Sinais multidimensionais nD

- São extensões simples dos sinais 1D;
- São seqüências multidimensionais de números ordenadas em um número maior de dimensões .

## Sinais do Encéfalo

# EEG

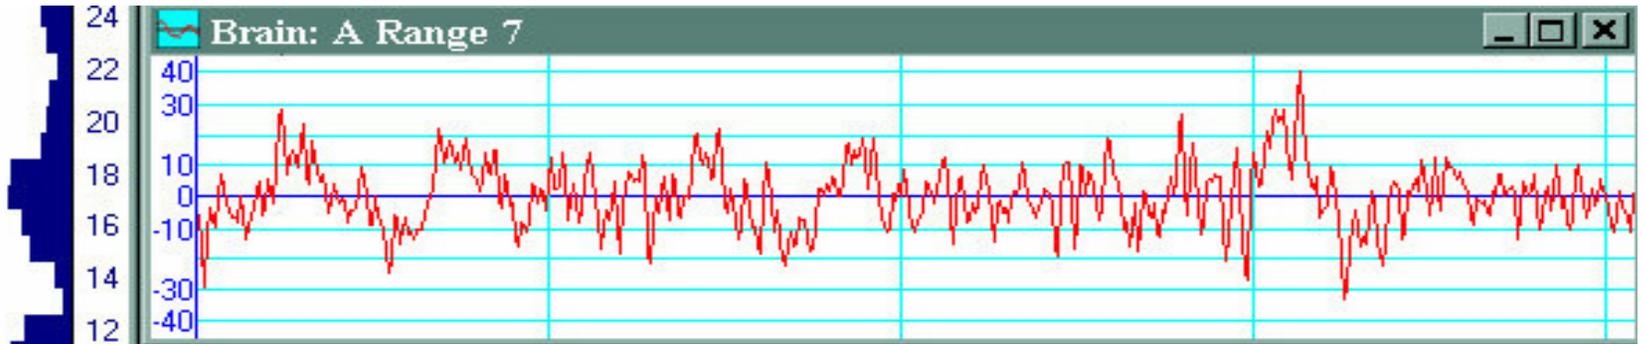
- Em 1929, **Hans Berger** (1873-1921), trabalhando na Universidade de Jena (Alemanha), mostrou que era possível registrar as correntes elétricas geradas no cérebro humano, sem a necessidade de abrir o crânio, e mostrá-las em registro em papel.
- Berger denominou a esta nova forma de registro fisiológico de Eletro Encéfalo Grama (ou EEG);
- Também mostrou (na época) que existiam dois ritmos dominantes:
  - **alfa** (de 8 a 10 ciclos por segundo) e
  - **beta** (de 12 a 20 ciclos por segundo)



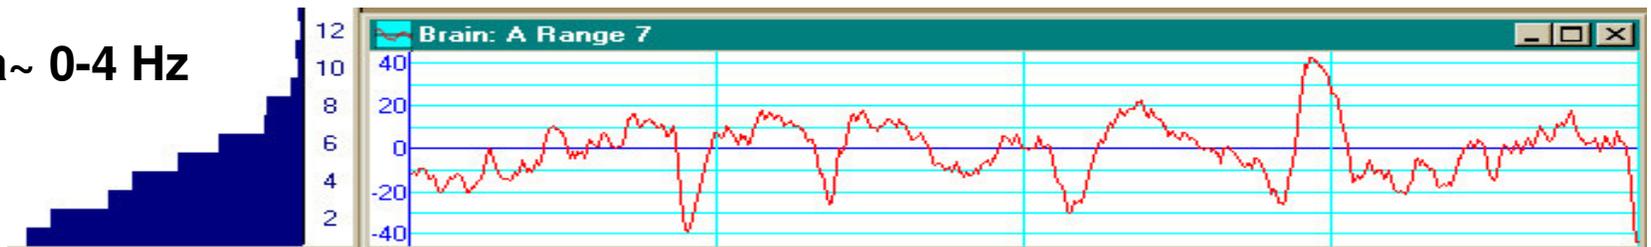
Alfa~ 8-12Hz



Beta~  
16-20Hz

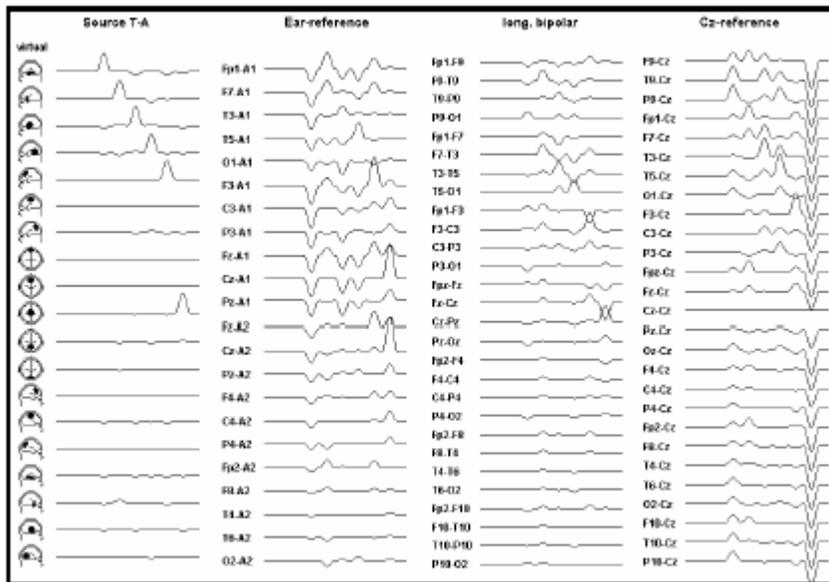


Delta~ 0-4 Hz



Teta~ 4-8Hz





EEG

## Mapeamento Cerebral

obs.:

**A resolução do sinal (no EEG é limitada pela resolução do CAD – conversor analógico digital).**

**Taxa de aquisição do registro.**



# EEG Registro e operação

etapas:

colocação dos elétrodos de referência.

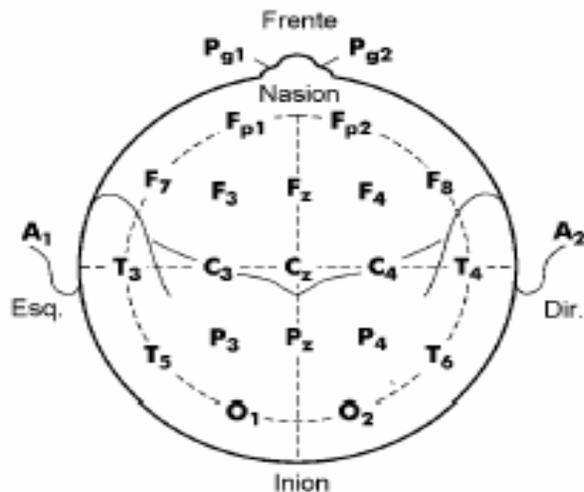
colocação do gel condutor.

calibração dos elétrodos.

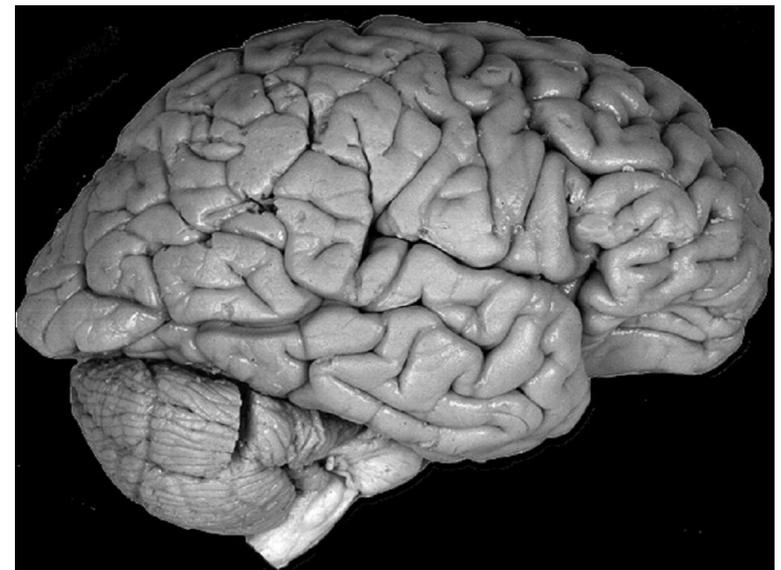
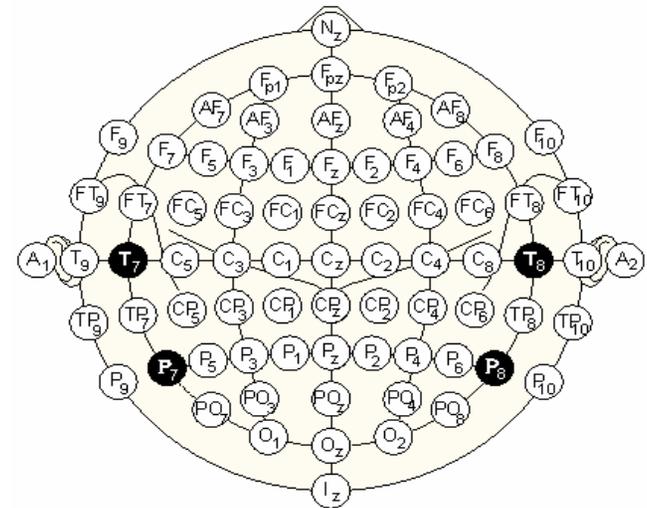
amplificação dos registros.

filtragens.

**Sistema Internacional de posicionamento de eletrodos 10-20 ( Hebert Jasper – 1958 )**



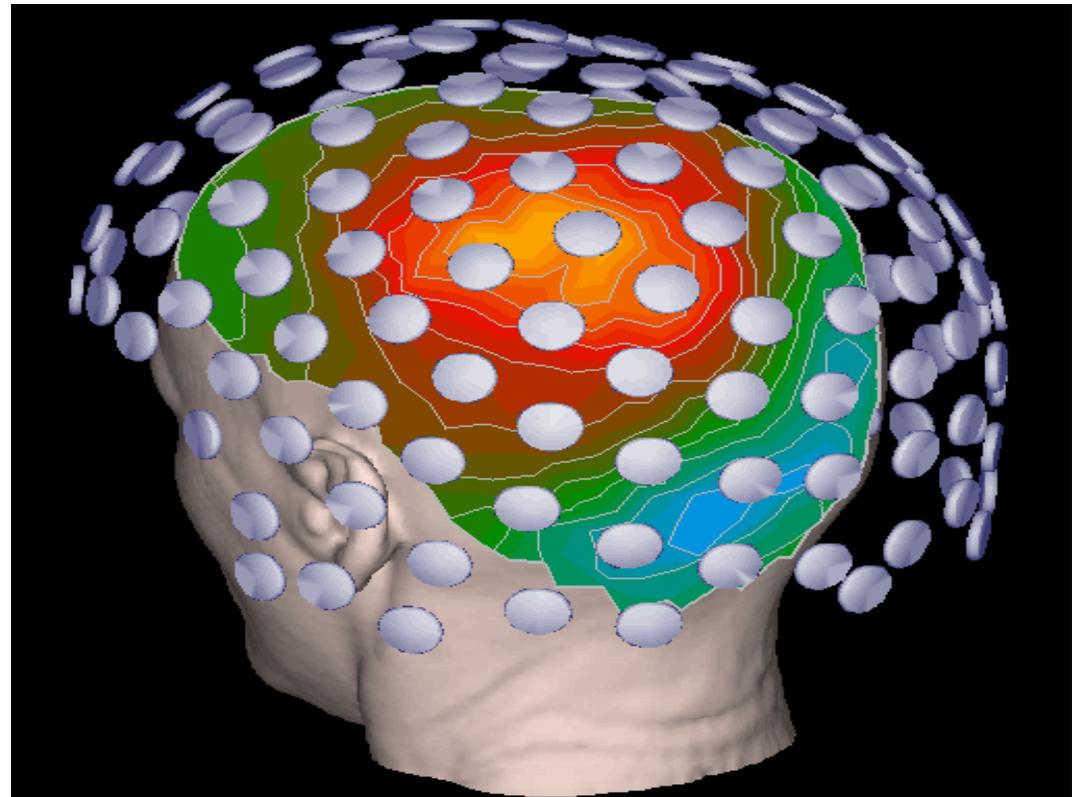
**O sistema 10-10 de colocação de eletrodos.**



# 2D :

## MAPEAMENTO TOPOGRAFICO :

**W. Gray Walter**, em 1936, provou que se fosse usado um grande número de eletrodos sobre a pele da cabeça, era possível identificar atividade elétrica normal e anormal em determinadas áreas do cérebro



# EEG+EMG+ECG

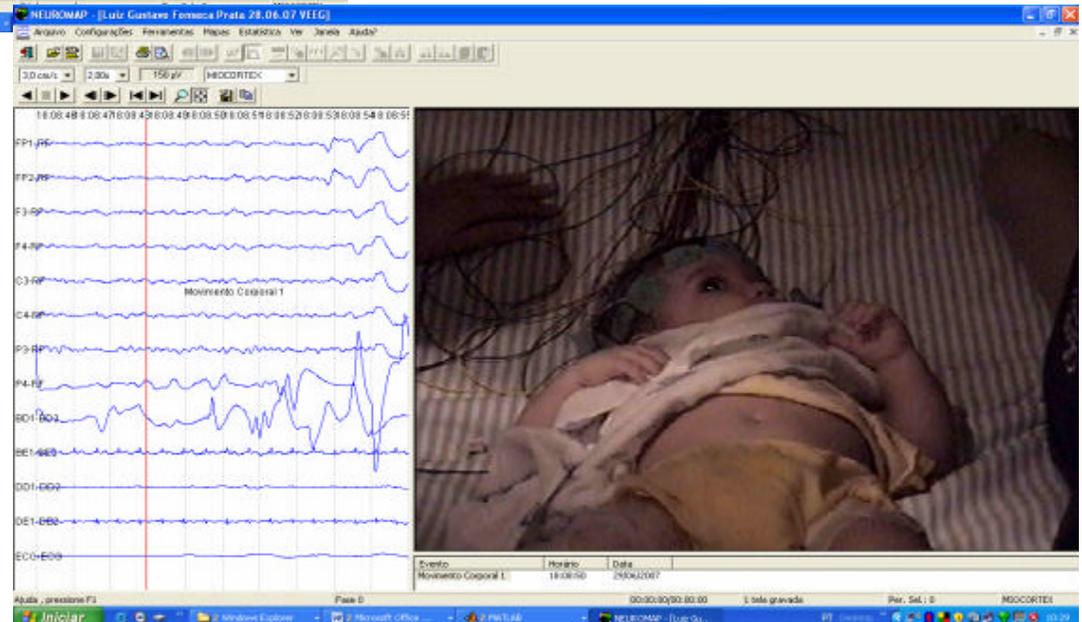


Evolução da seqüência de um espasmo

**Indivíduo adulto**

mioclonia = Contração muscular involuntária breve e brusca

**Criança**, com 8 meses de idade, apresentando um quadro de epilepsia, inicialmente diagnosticada como Síndrome de West



# Imagens após stress térmico ao longo do tempo

- Após o registro das ROIs

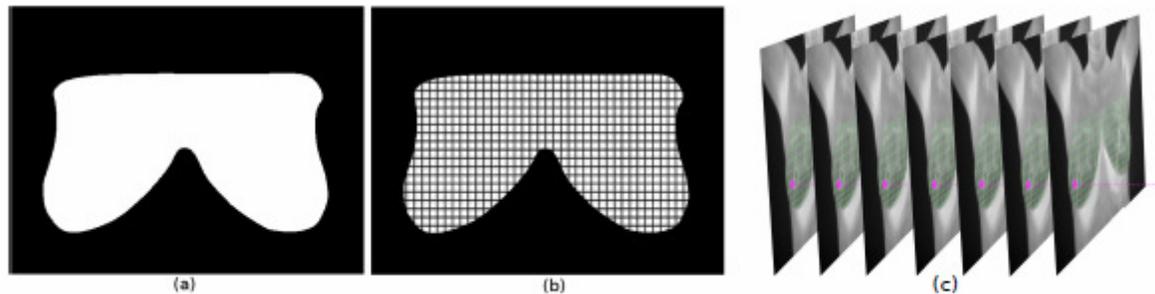


Figura 2. Máscara dividida em uma “malha” de quadrados de tamanho 11x11 pixels e a construção de uma série temporal de temperatura.

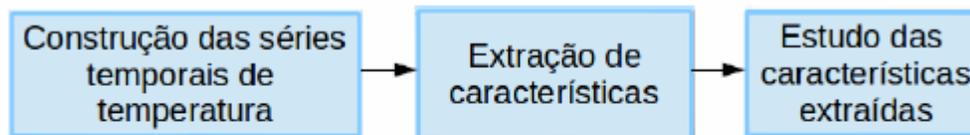


Figura 1. Fluxograma das etapas da metodologia proposta.

- Um sinal para cada grupo de 11x11 pixels da ROI

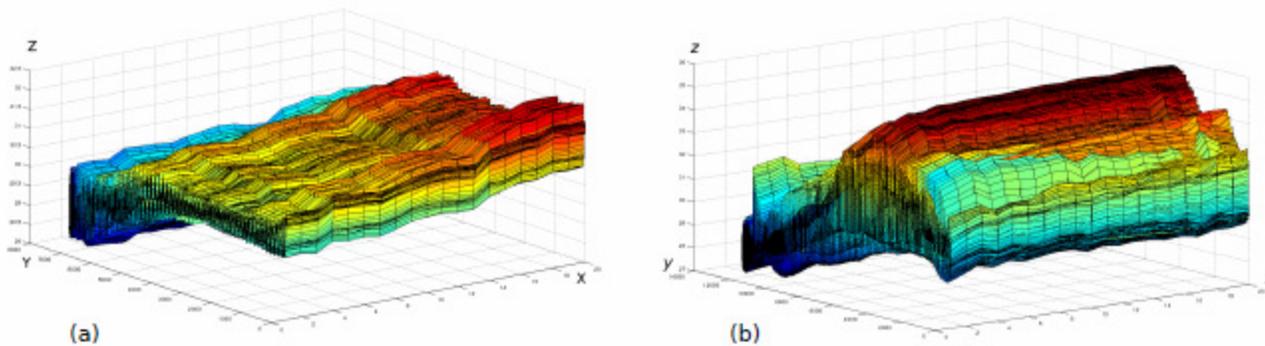


Figura 3. Em (a), sinais térmicos de uma paciente saudável, e em (b), sinais térmicos de uma paciente com câncer.

# Processamento de sinais

- Sinais biológico são bastante complexos e alteração no nível de complexidade geralmente indica alguma anomalia.
- É importante medidas quantitativas da complexidade dos sinais que possibilitam ver suas alterações de complexidade.
- **Análise da Complexidade de sinais 1D** - > cap. 6 : K. Najarian and R. Splinter, **Biomedical Signal and Image Processing** CRC Press - Taylor & Francis Group, 2006

# Processamento digital do sinal (PDS ou DSP)

## Principais etapas após aquisição

### Filtragem

- Eliminação das amostras que são ruído no sinal, exemplo a rede de energia elétrica provoca interferência.
  - No domínio do tempo
    - Moving window (average)
  - No domínio da frequência
    - Passa baixos
    - Passa altos
    - Passa bandas
    - Stop banda

### Tratamento do sinal

- Detecção do início do início e fim das ondas (do ECG por exemplo)
- Detecção da frequência média (cardíaca, cerebral, etc)
- Detecção de irregularidades (arritmias, espasmos, mioclônias)

# Exemplo de Filtragens

## Usadas na detecção de vibração ventricular- VF

### Filtragem do sinal na janela

#### **%1. Levar à linha base**

```
X=X - mean(X);
```

#### **%2. moving averaging 24 Hz (50Hz)**

```
b=[.2 .2 .2 .2 .2]; a=[1];
```

```
X=filtfilt(b,a,X);
```

#### **%4. filtration , lowpass 30 Hz**

```
fh=sfreq/2; % 1/2 sampling rate
```

```
mb=2; % order of filter
```

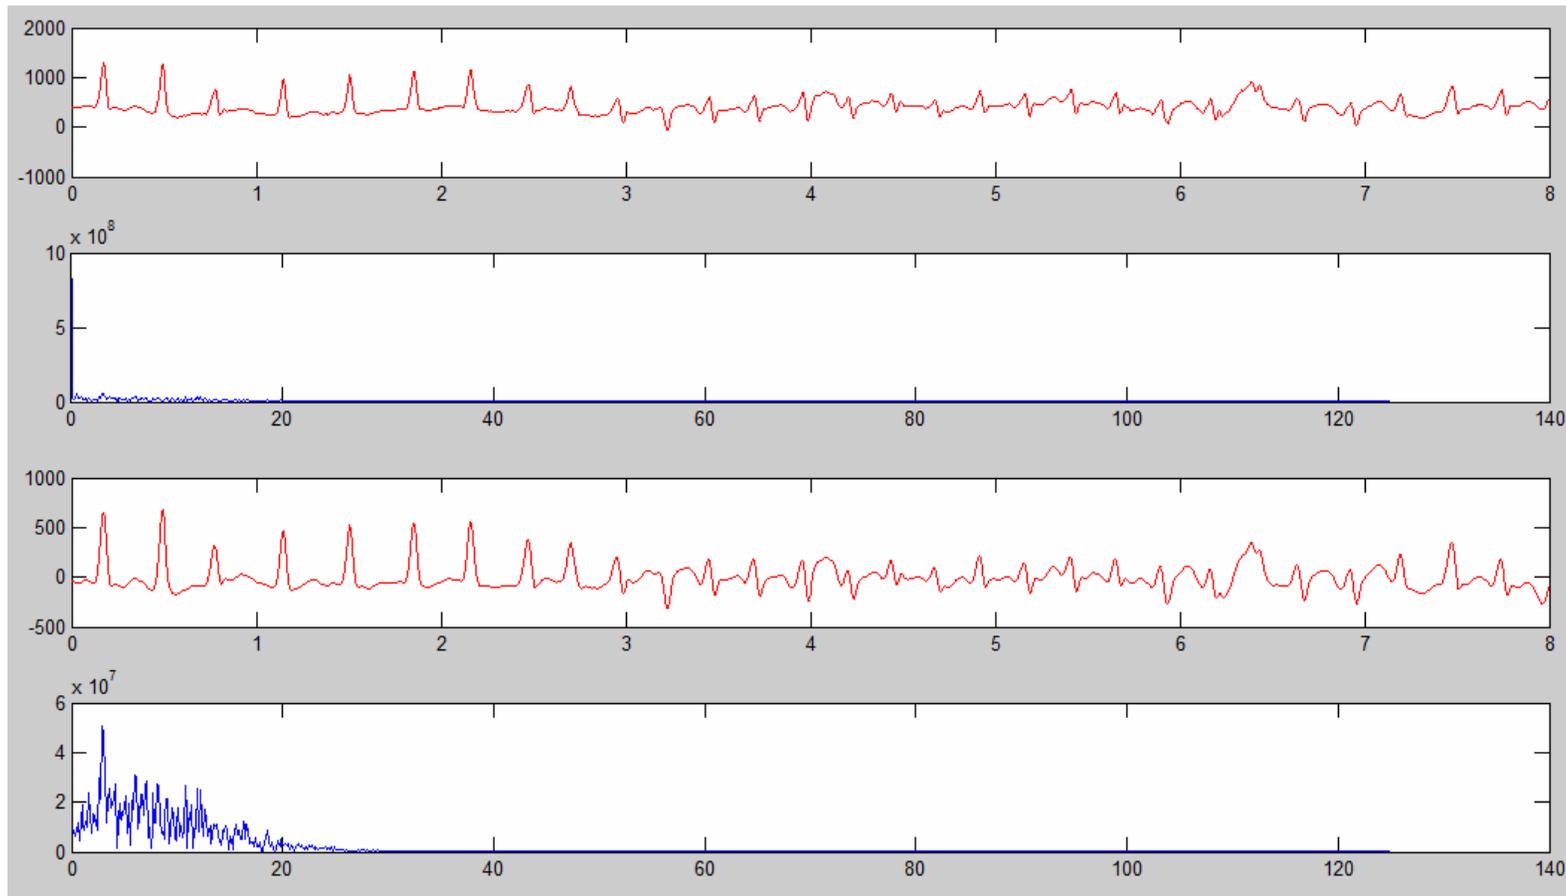
```
[b,a]= butter(mb,30/fh); % 30Hz - cut-off fr
```

```
X=filtfilt(b,a,X);
```

# Representação no domínio da frequência. Transformada de Fourier

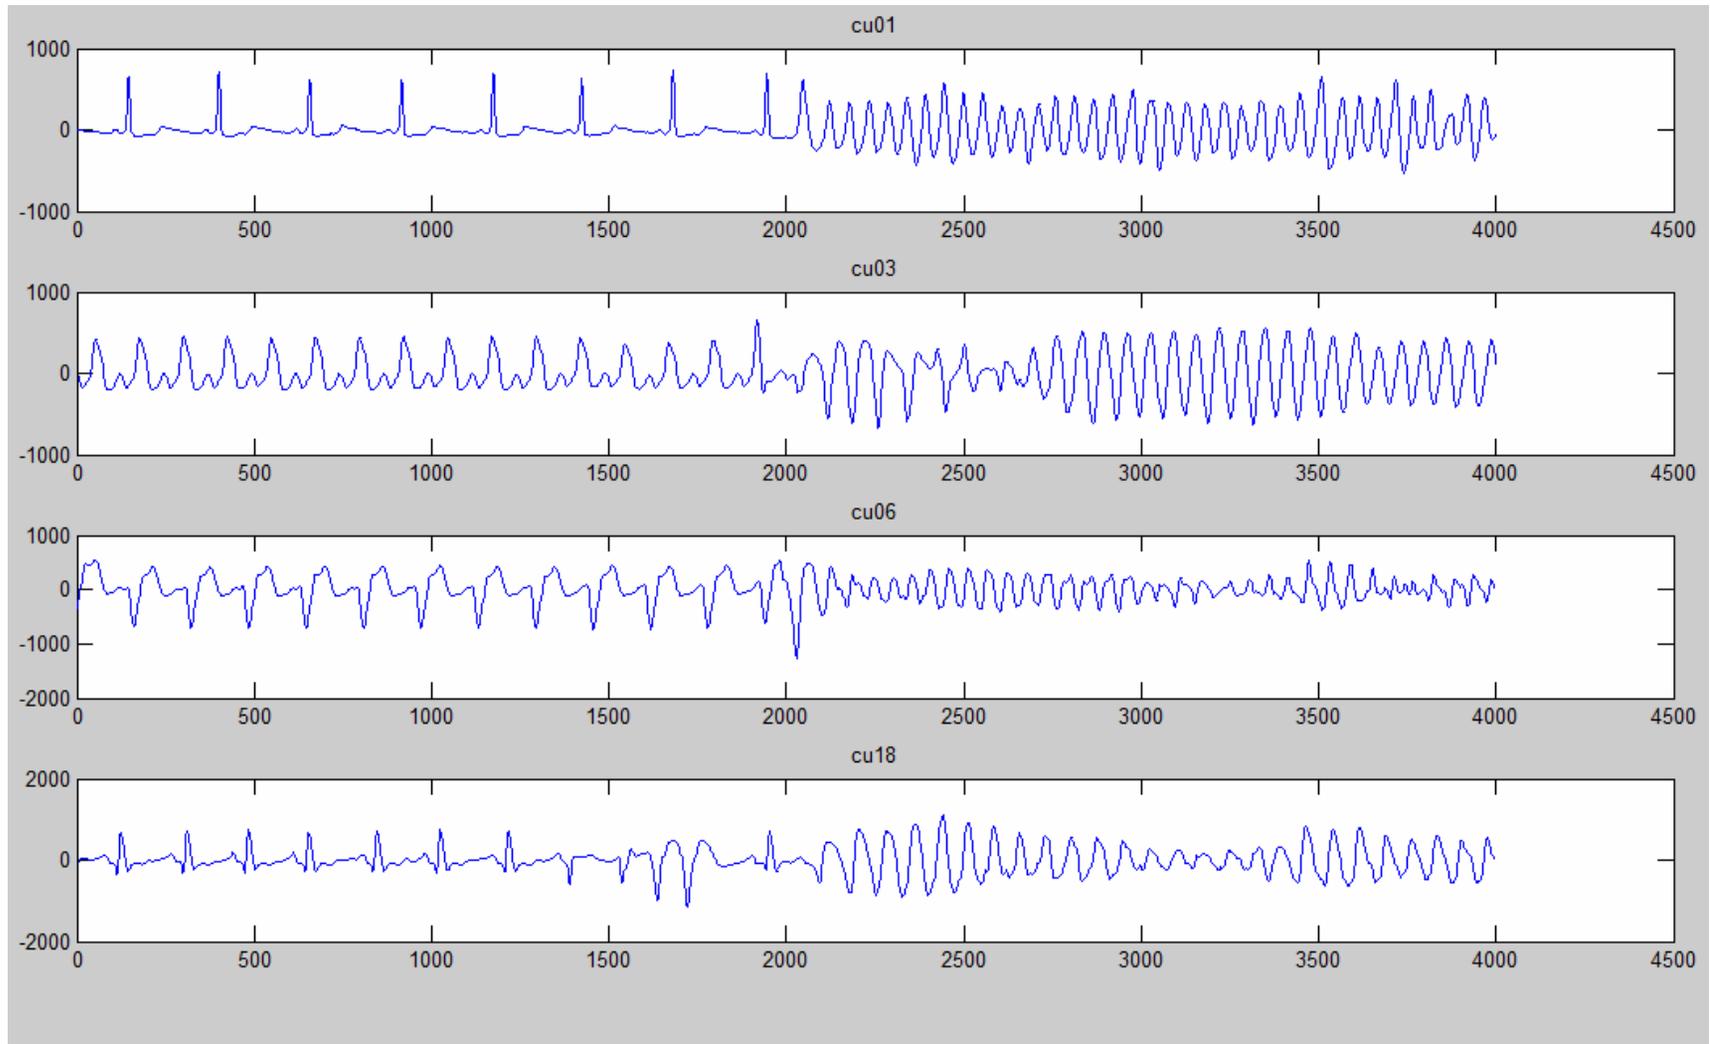
## Transformada de Fourier

Para filtrar determinadas frequências ou caracterizar o sinal



# Detecting of Ventricular Fibrillation (VF) in Real Time

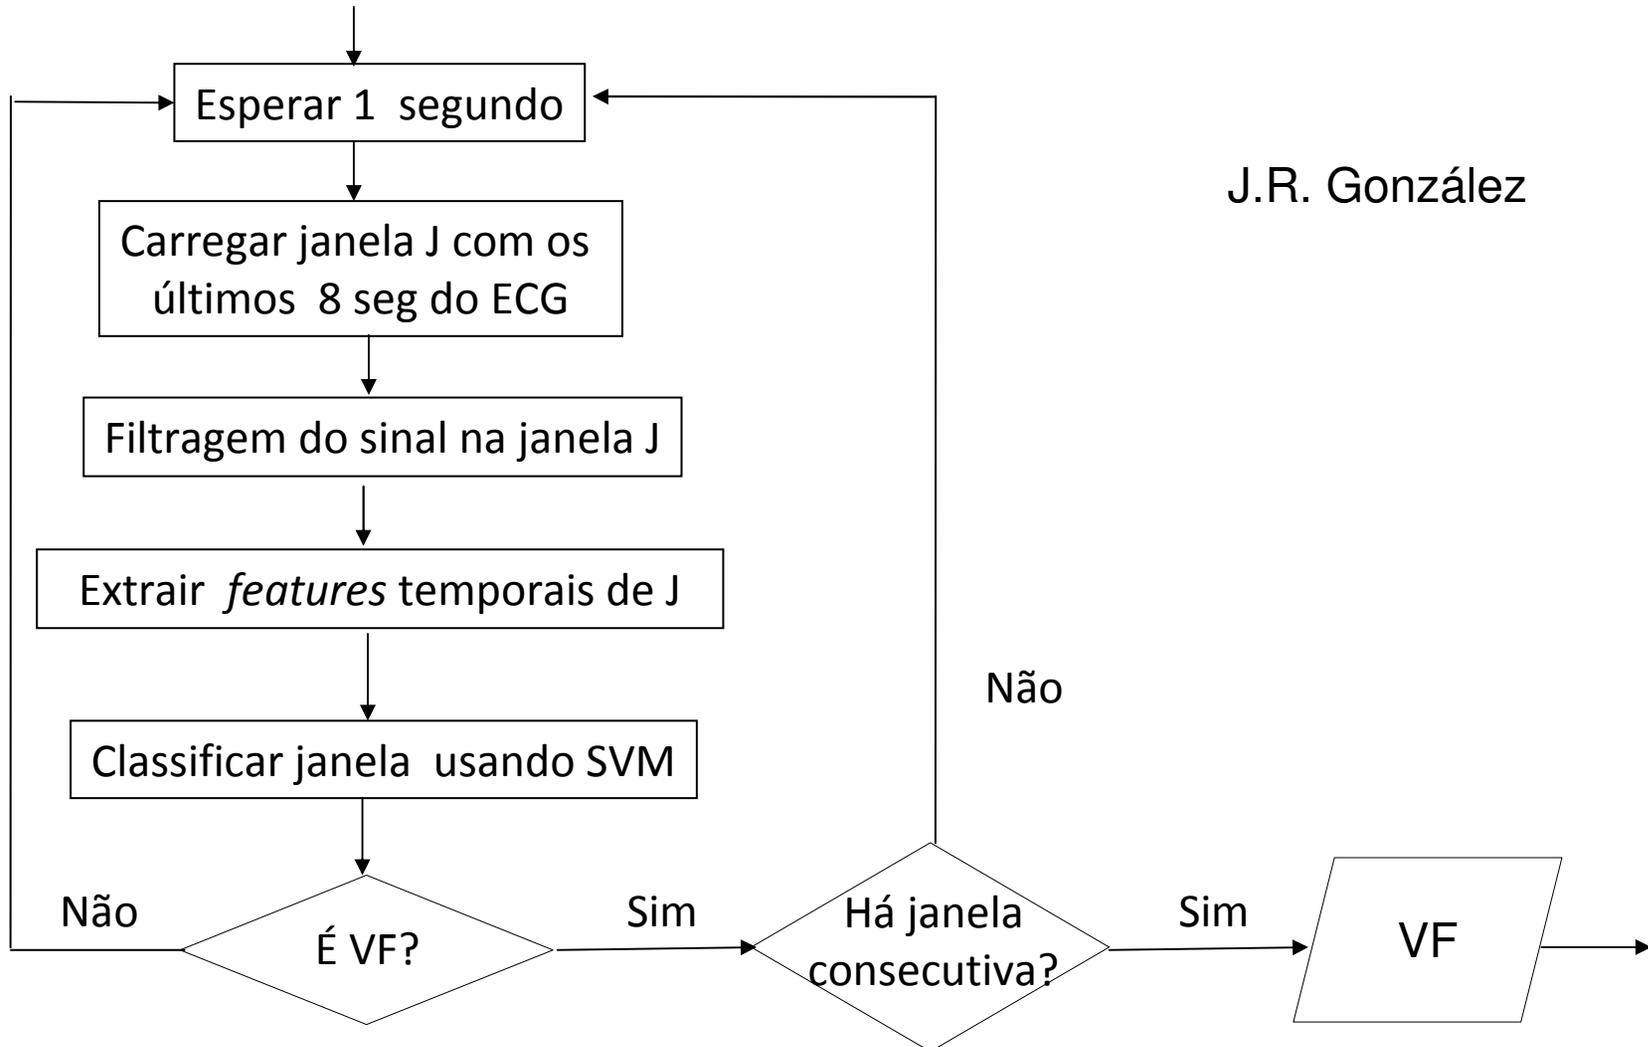
## Transição entre as formas das ondas



# Detecting of Ventricular Fibrillation (VF)

## Algoritmo de detecção de VF

J.R. González



# Exemplo de features (características) temporais em J

Mean absolute value (MAV)  
normalizado

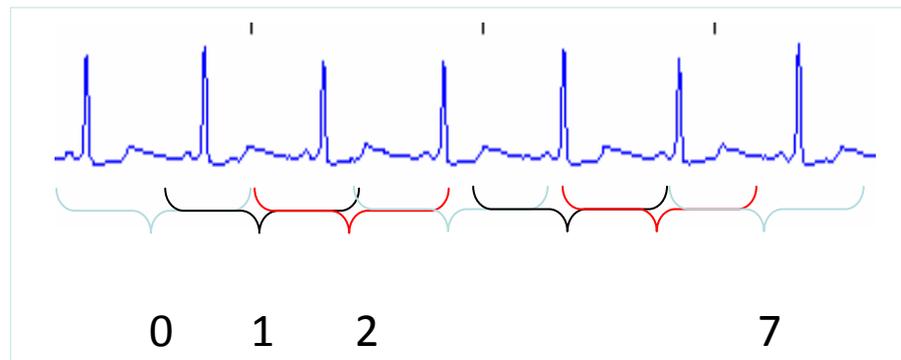
Banco de dados de ECG anotados **MIT-BIT** do repositório de sinais fisiológicos **PhysioBank** de **Physionet**, com codificação específicos e em binário

# Detecting of Ventricular fibrillation in Real Time

## Algoritmo de detecção de VF

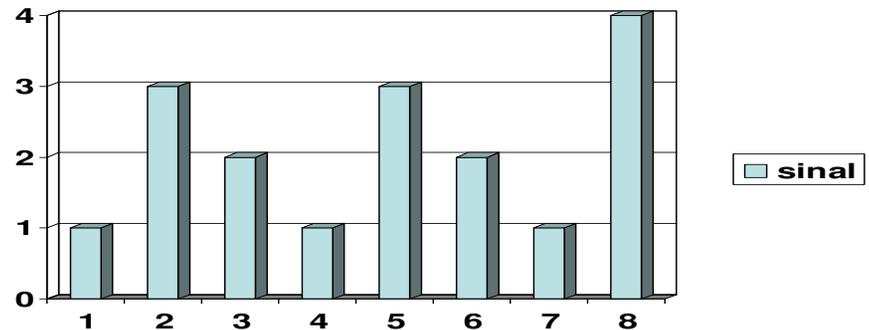
### Mean absolute value (MAV) normalizado (Abu, 2010)

Sub-janelas de 2s a  
distancia de 1s



$$MAV = \frac{1}{N} \sum_{n=0}^{N-1} |x(n)|$$

Exemplificando:



- Se o sinal for definido pela série :  $x_i$   $i= 1, 2, 2, \dots, N$ 
  - » 1, 3, 2, 1, 3, 2, 1, 4
- Então  $N=8$
- A **Mean absolute value (MAV)** será:  $x_i + x_{i-1}$ 
  - »  $1+3+2+1+3+2+1+4 = 17$
  - » A MAV normalizada será:  $17/8 = 2,125$

# The Short Time Average Energy (STE)

shown in Equation (5),

$$STE = \sum_{m=0}^{M-1} x^2(m) \quad (5)$$

is a simple and vastly used feature for segmentation

## the **Low Feature-Value Ratio (LFVR)**

was used to characterize signal and background noises and is given by Equation (7):

$$LFVR = \frac{1}{2N} \sum_{n=0}^{N-1} [\sin(0,5avSTE - STE(n)) + 1] \quad (7)$$

where  $avSTE$  is the average  $STE$  in the total number of frames or waves considered.

# The Root Mean Square (RMS)

value measures the signal energy and is defined by Equation (4):

$$RMS = \sqrt{\frac{1}{M} \sum_{m=0}^{M-1} x^2(m)} \quad (4)$$

where  $M$  is the number of samples and  $x(m)$  is the signal of the sound.

# Sonoros de voz ou outros com essa característica:



# The feature **Zero Crossing Rate (ZCR)**

is defined by the number of signals changes in Equation (1):

$$ZCR = \frac{1}{M-1} \sum_{m=0}^{M-1} | \text{sign}(x(m)) - \text{sign}(x(m-1)) | \quad (1)$$

where  $M$  is the number of samples in the window and  $\text{sign } x(m) = 1$  if  $x(m) > 0$  as well as  $\text{sign } x(m) = 0$  if  $x(m) < 0$ . This feature, regarding an adequate window, can identify voice in an arbitrary sound

# The **High Feature-Value Ratio** (HFVR)

is also vastly employed to differentiate voice and music in an audio file and is defined by Equation (6):

$$HFVR = \frac{1}{2N} \sum_{n=0}^{N-1} [\sin(ZCR(n) - 1,5avZCR) + 1]$$

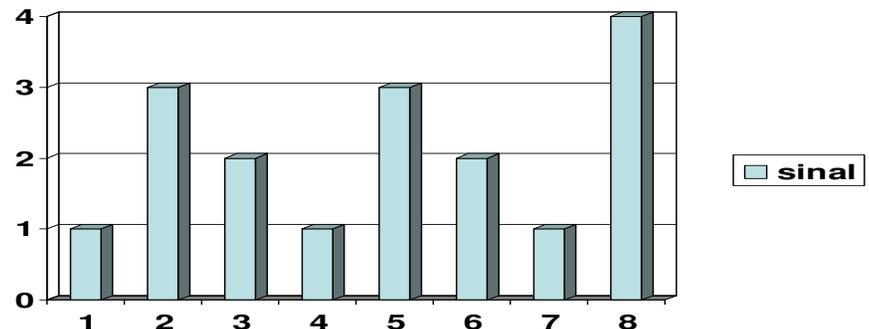
where  $N$  is the total number of frames considered and  $avZCR$  is the average of the  $ZCR$  of the considered window.

# Somatorio $\Sigma$ equivale a uma integral $\int$

- O que equivale a  
diferenciais Ou  
Derivadas?

Variações do sinal

Exemplificando:



- Se o sinal for definido pela série :  $x_i$   $i= 1, 2, 2,\dots,N$ 
  - » 1, 3, 2, 1, 3, 2, 1, 4
- Então  $N=8$
- A **variação de primeira ordem** será:  $d_i = x_i - x_{i-1}$ 
  - » 2,-1,-1, 2,-1,-1, 3
- A **variação de segunda ordem** será:  $g_i = d_i - d_{i-1}$ 
  - » -3, 0, 3, -3, 0, 4

Usando o sinal,  $x_i$ , sua variação de primeira ordem,  $d_i$ , e segunda ordem,  $g_i$ , calcula-se os seguintes 3 números:

$$S_0 = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}}, \quad (6.3)$$

$$S_1 = \sqrt{\frac{\sum_{i=2}^{N-1} d_i^2}{N-1}}, \quad (6.4)$$

$$S_2 = \sqrt{\frac{\sum_{i=3}^{N-2} g_i^2}{N-2}}, \quad (6.5)$$

Calculando para o sinal exemplo teremos:

- Para o Somatório dos sinais consecutivos ao quadrado:
- $(1+9+4+1+9+4+1+16)/8 = 45/8$
- De modo que a primeira expressão resultará: 2,372

Calculando para o sinal exemplo teremos:

- Para o Somatório da diferença dos sinais consecutivos ao quadrado:
- $(4+1+1+4+1+1+1+9)/7 = 21/7$
- De modo que a segunda expressão resultará: 1,732

Calculando para o sinal exemplo teremos:

- Para o Somatório da diferença da diferença dos sinais consecutivos ao quadrado:
- $(9+0+9+9+0+16)/6 = 43/6$
- De modo que a terceira expressão resultará: 2,677

# Complexidade do Sinal

– é definida pela expressão:

$$\text{Signal Complexity} = \sqrt{\frac{S_2^2}{S_1^2} - \frac{S_1^2}{S_0^2}} \quad (6.6)$$

Calculando para o sinal exemplo teremos:

Complexidade do Sinal

=1,312

# Mobilidade do Sinal

$$\text{Signal Mobility} = \frac{S_1}{S_0} \quad (6.7)$$

These two measures are heavily used in biomedical **signal** processing, especially in processing of EEGs, ECG, and electromyograms (EMGs) signals as described in Part II of this book.

Calculando para o sinal exemplo teremos:

Mobilidade do Sinal

$$= 0,730$$

# Em sinais 2D ou nD

- Essas medidas podem ser computadas para cada um dos múltiplos canais.
- Em imagens podem fazer sentido computá-los, para a direção horizontal e vertical

# Por exemplo : pequena Imagem

Imagem 4x8=32 *pixels* em *grayscale* para efeito de cálculo.

4	4	4	4	64	64	128	128
4	4	4	4	64	64	128	128
4	4	16	16	128	128	128	128
4	4	16	16	128	128	128	128

as medidas anteriores podem ser computadas para um dos canais RGB, para a direção horizontal como se a imagem fosse um grande *array* 1D

# Teste rápido e individual:

- Como você calcularia todas as medidas de sinais vistas até aqui para esse pequena imagem?
- Vamos ver quantas você consegue calcular em meia hora?

# Entropia

$$H(z) = - \sum_{j=1}^J P(a_j) \cdot \log P(a_j)$$

**Shannon 1948 => quantidade de informação (quanto maior mais informação)**

- A informação é modelada como um processo probabilístico sendo tratada como um evento aleatório,  $E$ .
- Sua ocorrência é definida com  $p(E)$  que também representa a sua probabilidade.
- Em imagem,  $E$  é o tom ou cor que a imagem possui e  $p(E)$  o número de *pixels* deste mesmo tom ou cor dividido pelo número total de *pixels* da imagem.
- Em um sinal esse cálculo pode ser feito por janelas.

# Por exemplo : na Imagem

Imagem 4x8=32 *pixels* em *grayscale* para efeito de cálculo.

4	4	4	4	64	64	128	128
4	4	4	4	64	64	128	128
4	4	16	16	128	128	128	128
4	4	16	16	128	128	128	128

Contando a ocorrência de cada *grayscale*  $\sum p(i) = 1$

Cor:	Total:	Probabilidade:
4	12	$12 / 32 = 3 / 8$
16	4	$4 / 32 = 1 / 8$
64	4	$4 / 32 = 1 / 8$
128	12	$12 / 32 = 3 / 8$

$$H(z) = - \sum_{j=1}^J P(a_j) \cdot \log P(a_j)$$



# Incerteza ou entropia

quantidade média de informação perdida :

(se o log for na base 2 a unidade será em bits)

Menor possível = zero (todos os pixels no mesmo tom)

Maior possível (todos os tons tem mesmo numero de pixels)

$$H(Pa) = -\sum_{i=1}^J p(a_j) \log p(a_j)$$

# calculando

$$H(z) = -\frac{P(4)}{P(128)} * \log_2(P(4)) - \frac{P(16)}{P(128)} * \log_2(P(16)) - \frac{P(64)}{P(128)} * \log_2(P(64)) - \frac{P(128)}{P(128)} * \log_2(P(128))$$

$$H(z) = -[3/8 * \log_2(3/8) + 1/8 * \log_2(1/8) + 1/8 * \log_2(1/8) + 3/8 * \log_2(3/8)] =$$

$$H(z) = -[3/4 * \log_2(3/8) + 1/4 * \log_2(1/8)] =$$

$$H(z) = -[3/4 * (\log_2(3) - \log_2(8)) + 1/4 * (\log_2(1) - (\log_2(8)))] =$$

$$H(z) = -[3/4 * (\log_2(3) - 3) + 1/4 * (0 - 3)] =$$

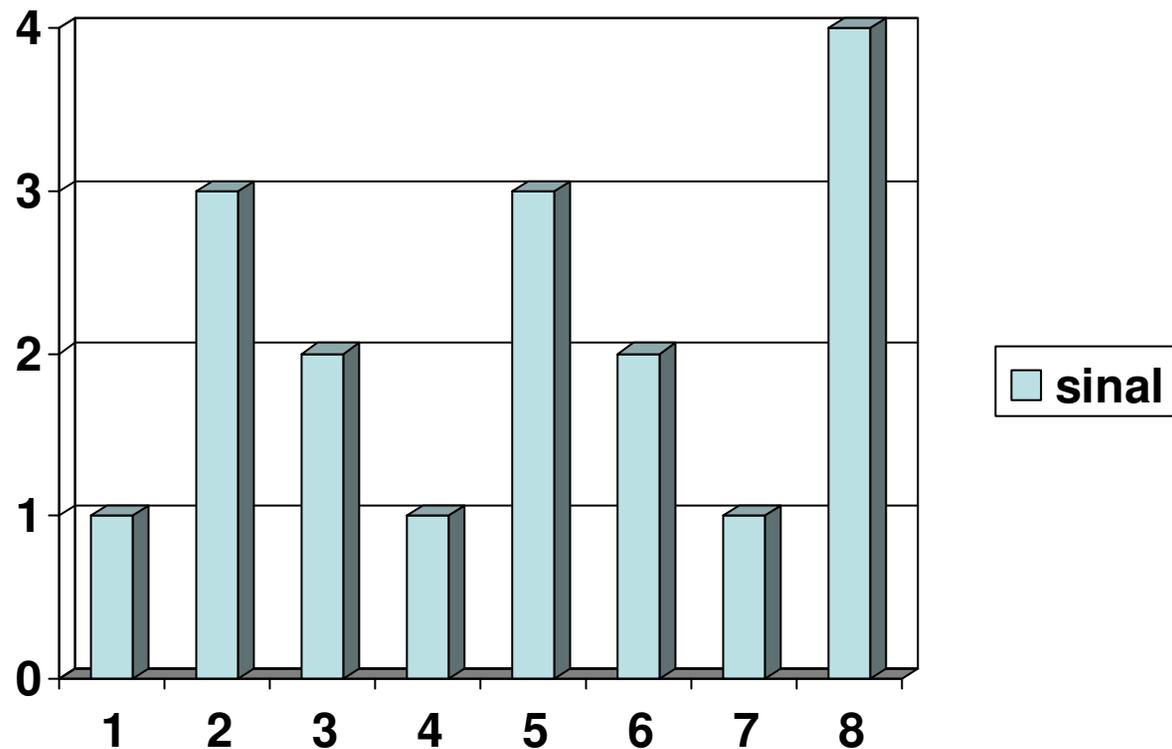
$$H(z) = -[3/4 * (\log(3)/\log(2) - 3) - 3/4] =$$

$$H(z) = -3/4 [(\log(3)/\log(2) - 3) - 1] =$$

$$H(z) = -3/4 [\log(3)/\log(2) - 4] = 3/4 [4 - (\ln(3)/\ln(2))] = 1.81 \text{ bits/pixel}$$

# Continuando o teste rápido e individual:

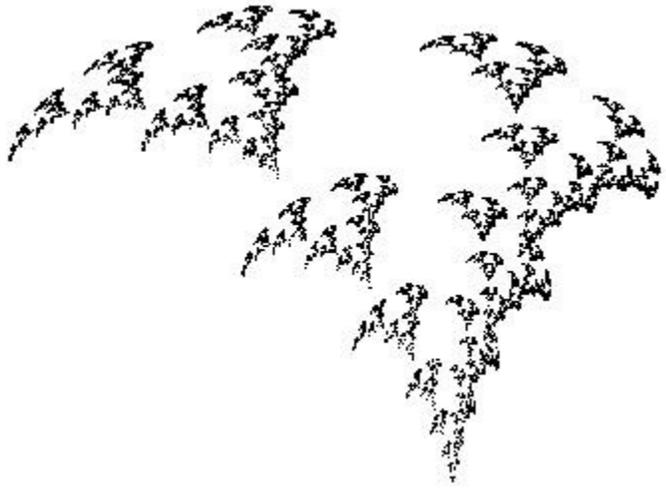
Agora você, qual a entropia do janela de sinal do inicio desta aula?



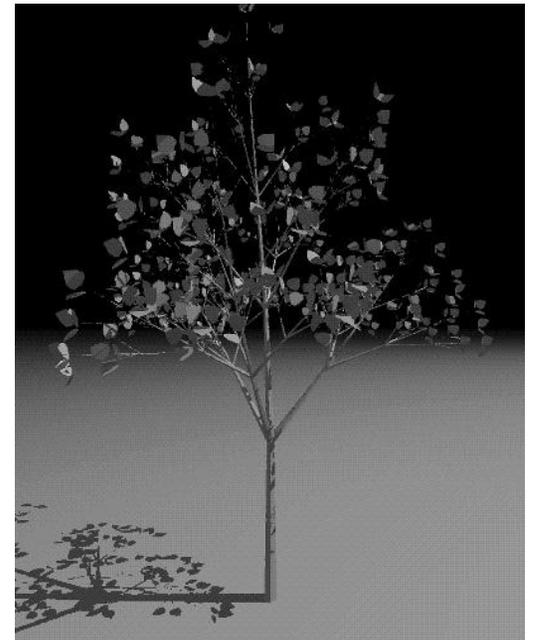
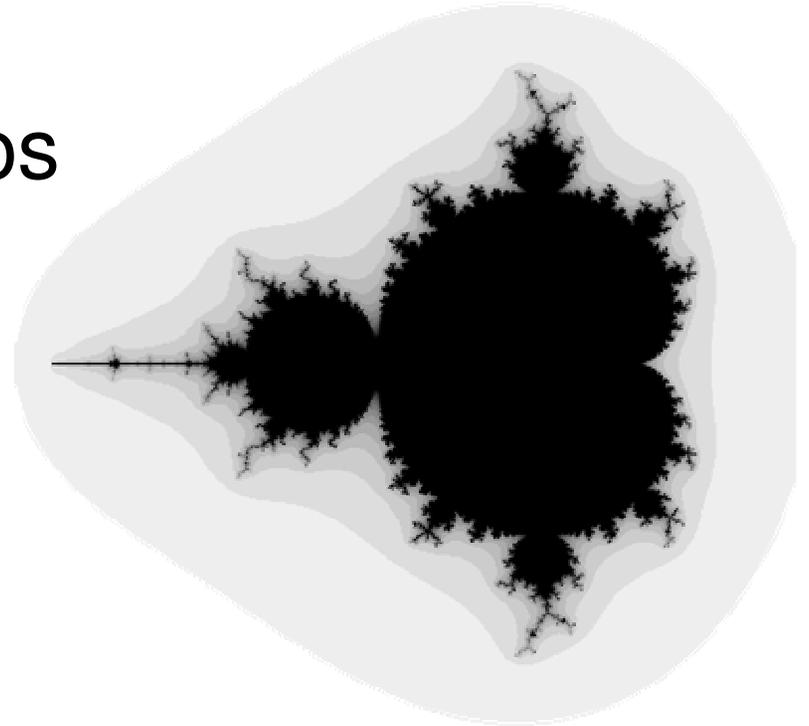
# *Geometria Fractal*

- Estuda subconjuntos complexos de espaços métricos.
- Na geometria de fractais determinísticos, os objetos estudados são subconjuntos gerados por transformações geométricas simples do próprio objeto nele mesmo.
- O objeto fractal é composto por partes reduzidas dele próprio

exemplos

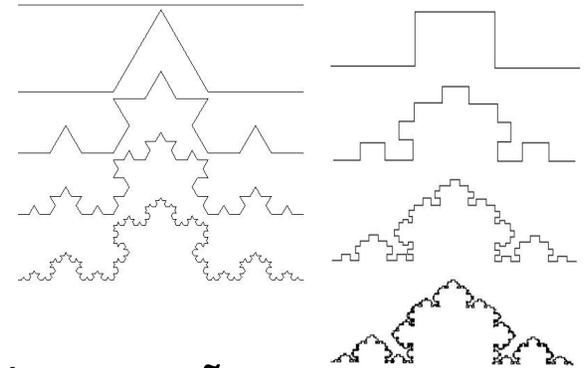


Randomicos x deterministicos



# Exemplos determinísticas

## Curvas de KOCH:



- Proposta por Von Koch em 1904, tem a seguinte geração:
- desenhe uma linha e a divida em 3 partes iguais  
( $d = 1/3 * r$  , onde  $d$ = escala da reta e  $r$ = comprimento inicial )  
depois faça o terço central da reta ser substituindo por :
  - 2 pedaços, repita o processo infinitamente (tridaic)
  - Ou
  - 3 pedaços, repita o processo infinitamente (quadric)

# Dimensão Euclidiana – objetos euclidianos

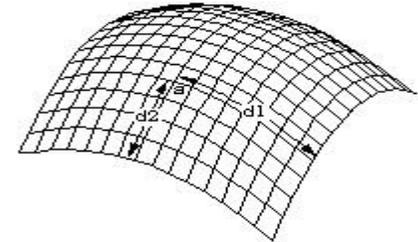
Um objeto de 1 dimensão (por exemplo uma linha),  
pode ser dividido em N partes , cada parte será idêntica a anterior multiplicada  
por um fator elevado a 1:

$$( N * r^1 = 1 ).$$

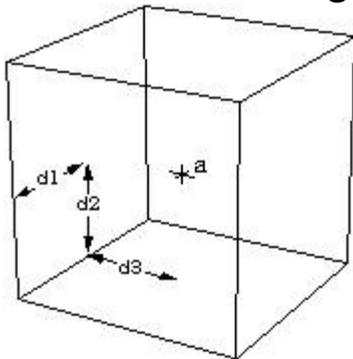


- Um objeto de 2 dimensões (por exemplo um quadrado), cada parte será  
idêntica a anterior multiplicada por um fator elevado a 2:

$$( N * r^2 = 1 ).$$



- Um objeto de 3 dimensões (por exemplo um cubo), cada parte será idêntica a  
anterior e a original multiplicada por um fator elevado a 3:



$$( N * r^3 = 1 )$$

# *Pode-se então repensar a definição de Dimensão Euclidiana para que seja*

Um objeto terá dimensão  $d$  , se ao ser dividido em  $N$  partes , cada parte será idêntica a anterior multiplicada por um fator de escala  $r$  elevado a  $d$ :

$$N * r^d = 1$$

$$\text{Ou } N = 1 / r^d = ( 1 / r )^d$$

- Aplicando log em ambos os lados:

$$\log N = \log ( 1 / r )^d$$

$$\log N = d \log ( 1 / r )$$

$$d = \log N / \log (1/r)$$

# Dimensão fractal

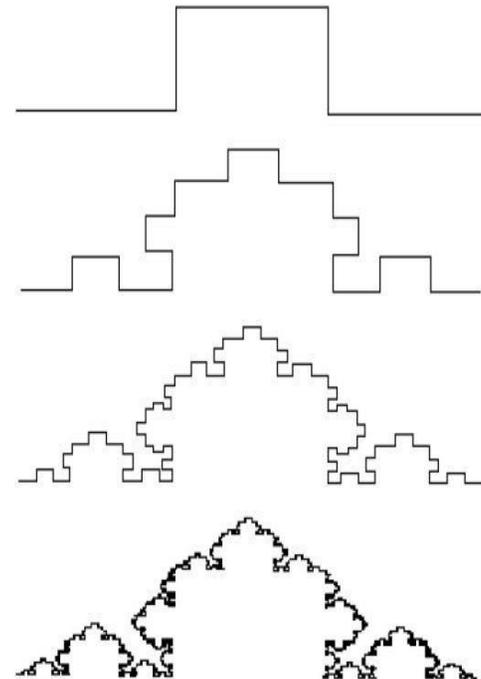
$$DF = \log N / \log (1/r)$$

**Mede o qual é  
complexa a fractal  
em relação ao  
espaço Euclidiano  
que pertence**

**Curva quádrupla de  
Koch**

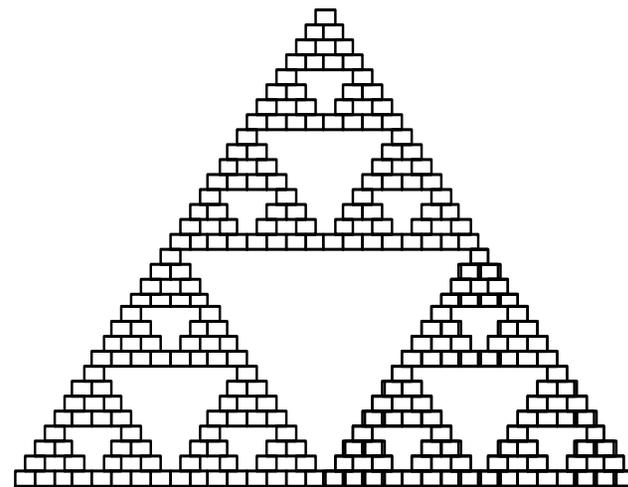
$$DF = \log 5 / \log 3 =$$

1,4649735207179271671970404076786



Dimensão fractal  $DF = \log N / \log (1/r)$

## Triângulo de Sierpinski



DF do Triângulo de Sierpinski:

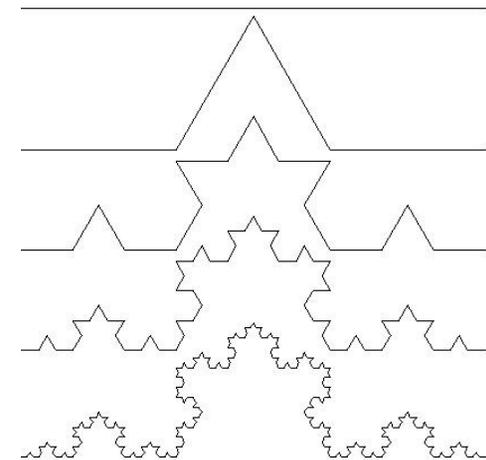
$$DF = \log 3 / \log 2 =$$

1,5849625007211561814537389439478

Dimensão fractal  $DF = \log N / \log (1/r)$

- **Curva triadic de Koch**

$$DF = \log 4 / \log 3 =$$



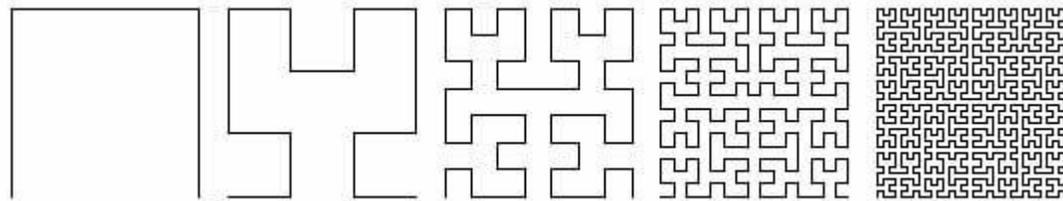
1,2618595071429148741990542286855

# *Curva de Peano.*

- Conhecida também como "curva de Hilbert" é mostrada na figura abaixo

Dimensão fractal  $DF = \log N / \log (1/r)$

$$DF = \log 4 / \log 2 = 2$$



# Curiosidades

- Benoit Mandelbrot introduziu o termo Fractal em 1975 para denominar uma classe especial de objetos e formas definidas recursivamente que produzem imagens reais ou imaginadas.
- Ou seja: Uma estrutura geométrica ou física tendo uma forma irregular ou fragmentada em todas as escalas de medição.

# DF para sinais

- Diversas aproximações em 1D e 2D
- Para 1D é muito usada a DF proposta por Takeo Higuchi
- Seção 6.2.2 do livro do curso p. 113:

# Dimensão de Takeo Higuchi

---

## 6.2.2 FRACTAL DIMENSION

Fractal dimension, which is frequently used in analysis of biomedical signals such as EEGs and ECGs, is a nonlocal measure that describes the **complexity** of the fundamental patterns hidden in a **signal**. Fractal dimension can also be considered a measure of the self-similarity of a **signal**. Assume we have printed a **signal** on a piece of paper and have a number of magnifiers with different zoom powers. First, we look at the entire **signal** without a magnifier and observe the **signal** pattern. Then, we focus only on a portion of the **signal** and use a magnifier. In biological and biomedical signals, we often notice that the observed pattern viewed with the magnifier has a high degree of similarity to the entire **signal**. If we continue focusing on smaller and smaller portions of the **signal** using magnifiers with higher and higher zoom powers, we observe more or less similar patterns. This proves the self-similarity of the biomedical signals. Fractal dimension is a measure that quantitatively assesses the self-similarity of a **signal**. Since almost all biomedical signals are to some degree self-similar, evaluating the fractal dimension allows us to distinguish between the healthy and diseased signals.

---

# Dimensão de Takeo Higuchi

In the **signal** processing literature, several methods are introduced to estimate the fractal dimension. Among all the fractal-based **complexity** measures, the Higuchi algorithm is one of the most accurate and efficient methods to estimate self-similarity. Here, we briefly describe the estimation of fractal dimension using the Higuchi algorithm.

From a time-series  $X$  with  $N$  points, first a set of  $k$  subseries with different resolutions are formed; that is, a set of  $k$  new time series  $X_k$  are defined as

$$X_k^m : x(m), x(m+k), x(m+2k), \dots, x\left(m + \left[\frac{N-m}{k}\right]k\right) \quad (6.8)$$

where  $m$  indicates the initial time indices ( $m = 1, 2, 3, \dots, k$ ). The length of the curve  $X_k^m$ ,  $l(k)$ , is then calculated as

# Dimensão de Takeo Higuchi

- Nesta expressão do nosso livro texto há um erro de notação. A expressão correta é a dada ao lado.
- $k$  representa a resolução do sinal da sub série
- $m$  representa o início da sub série
- O último termo indica que não faz sentido ter sub séries com  $m > k$

Consider  $x(1), x(2), \dots, x(N)$  the time sequence to be analyzed. Construct  $k$  new time series  $x_m^k$  as

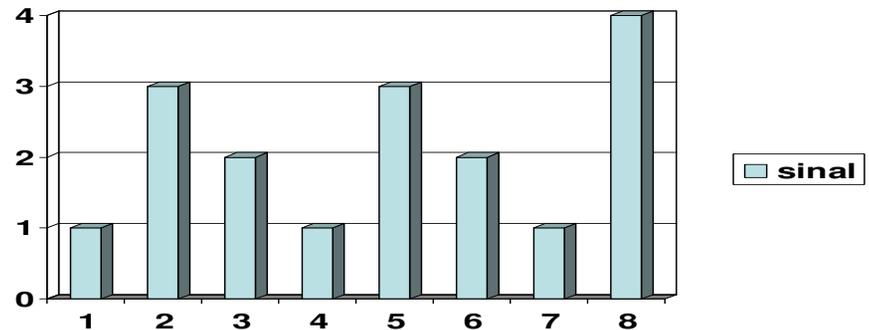
$$x_m^k = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor k\right) \right\}, \quad \text{for } m = 1, 2, \dots, k$$

where  $m$  indicates the initial time value,  $k$  indicates the discrete time interval between points (delay), and  $\lfloor a \rfloor$  means integer part of  $a$ . For each of the curves or time series  $x_m^k$  constructed, the average length  $L_m(k)$  is computed as

$$L_m(k) = \frac{\sum_{i=1}^{\lfloor (N-m)/k \rfloor} |x(m+ik) - x(m+(i-1)k)| (i-1)}{\left\lfloor \frac{N-m}{k} \right\rfloor k} \quad (\text{N-1})$$

where  $N$  is the total length of the data sequence  $x$  and  $(N-1)/\lfloor (N-m)/k \rfloor k$  is a normalization factor. An average length is computed for all time series having the same delay (or scale)  $k$ , as the mean of the  $k$  lengths  $L_m(k)$  for  $m = 1, \dots, k$ . This procedure is repeated for each  $k$  ranging from 1 to  $k_{\max}$ ,

# Exemplificando:

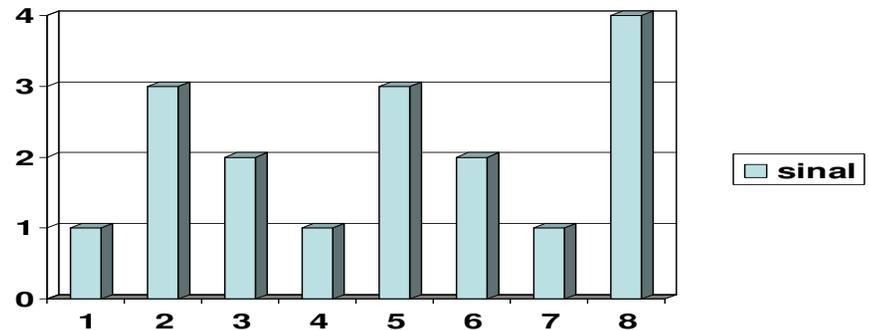


- Se o sinal for definido pela série  $x(k,m):=x(1,1)$ :
  - » 1, 3, 2, 1, 3, 2, 1, 4
- Então  $N=8$
- Com resolução  $k = 2$  as sub séries possíveis são
- $x(k,m):=x(2,1)$ : 1, 2, 3, 1,
- $x(k,m):=x(2,2)$ : 3, 1, 2, 4
- Com resolução  $k = 3$  as sub séries possíveis são
- $x(k,m):=x(3,1)$ : 1, 1, 1
- $x(k,m):=x(3,2)$ : 3, 3, 4
- $x(k,m):=x(3,3)$ : 2, 2,

# Dimensão de Takeo Higuchi

- Depois de se definir as series, passa-se a entendê-las como curvas e calcula-se seu comprimento nas diversas resoluções e a partir de todos os possíveis pontos de início.
- *Os comprimentos das curvas não normalizadas, é dado pelas somatórias das diferenças entre os valores de elementos consecutivos em módulo .*
- *Como os números de elementos das séries e suas distâncias são diferentes, esses comprimentos devem depois ser normalizados .*

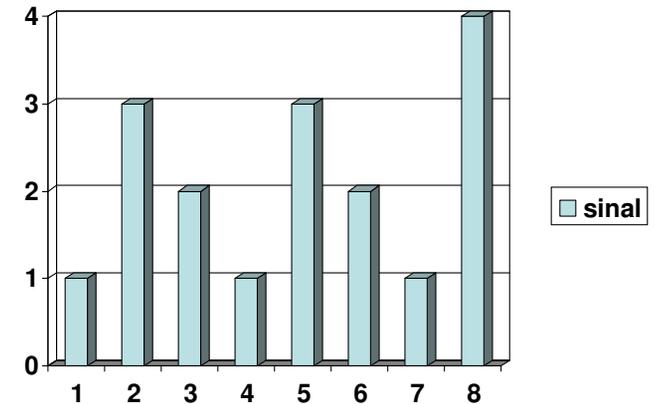
No exemplo:



- Para a série de resolução 1 temos o comprimento  $L(k,m) := L(1,1)$ :  
»  $2 + 1 + 1 + 2 + 1 + 1 + 3 = 11$
- Com resolução  $k = 2$  os cumprimentos das sub séries possíveis são  
 $L(k,m) := L(2,1) : 1 + 1 + 2 = 4$   
 $L(k,m) := L(2,2) : 2 + 1 + 2 = 5$
- O fator de normalização de cada uma delas é  $7/7$ ;  $7/6$  e  $7/6$  respectivamente
- Na resolução  $k=2$  faz-se uma média de modo que  $L(2) = 4,5 \times 7/6 = 5,25$

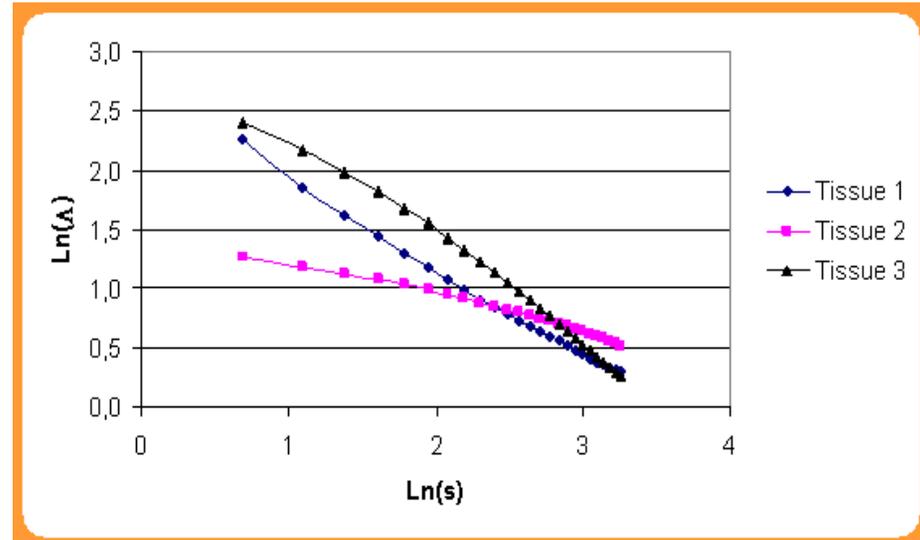
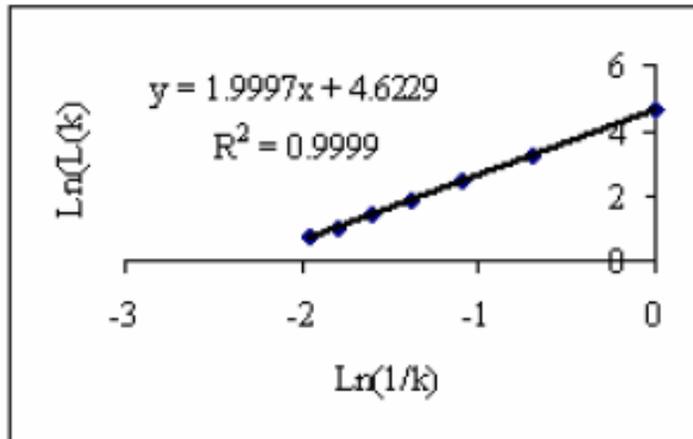
No exemplo:

- com os valores de  $k$  e  $L(k)$  plota-se os gráficos de  $\log L(k) \times \log k$  ou  $\ln L(k) \times \ln k$  e ajusta-se a melhor reta para os diversos valores.
- a inclinação desta reta será a dimensão fractal pelo algoritmos de Higuchi, ou dimensão de Higuchi



$k$	$L(k)$	$\ln(k)$	$\ln L(k)$	$\text{Log}(k)$	$\text{Log } L(k)$
1	11	2,39	0	1,04	0
2	5,25	1,65	0,693	0,72	0,301

A dimensão é obtida de gráficos como



-----  
para nosso teste rápido:  
mesmo usando só 2 pontos quanto ficaria a DF  
Do exemplo que estamos trabalhando?

# Referencias

- Marcilene. S. FONSECA, Érick Oliveira RODRIGUES, Angel SANCHEZ and Aura CONCI, **Mining videos based on color, shape and sound content**, International Workshop on Multimedia and Signal Processing - STU FEI, April 22-23, 2015, Smolenice castle, Slovakia, [Redžúr 2015](#)

José Ramón González Montero, Aura Conci, Yanexys Pupo Toledo, Leonardo Nardi, Frédéric Lebon, **On the efficiency of some signal descriptors to identify normal or abnormal cardiac rhythms**, REDŽUR 2017 | 11th International Workshop on Multimedia Information and Communication Technologies | 19 May 2017, Bratislava, Slovakia, pp. 51-54.

download em:

[//www2.ic.uff.br/~aconci/pub2017.html](http://www2.ic.uff.br/~aconci/pub2017.html)