

**Introdução às**  
**Redes Neurais Artificiais**  
**e aplicações**

**Luiz P. Calôba.**

[caloba@ufrj.br](mailto:caloba@ufrj.br), [www.lps.ufrj.br/~caloba](http://www.lps.ufrj.br/~caloba)

**Minicurso IC - 2011**

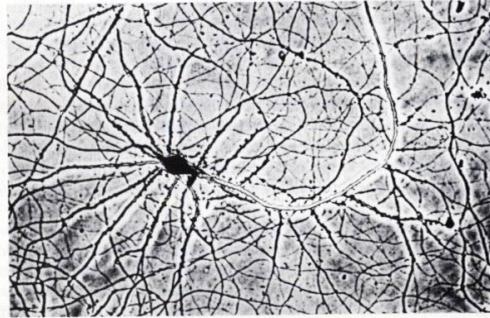
# **Redes Neurais Artificiais**

**O que é isto ?**

**Para que serve ?**

**De onde veio ?**

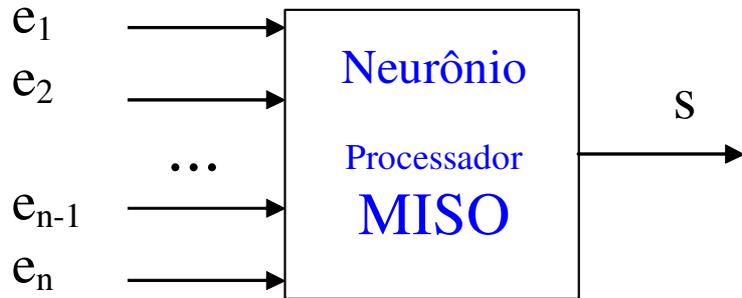
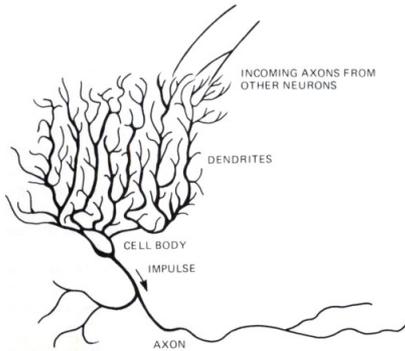
# Neurônio biológico



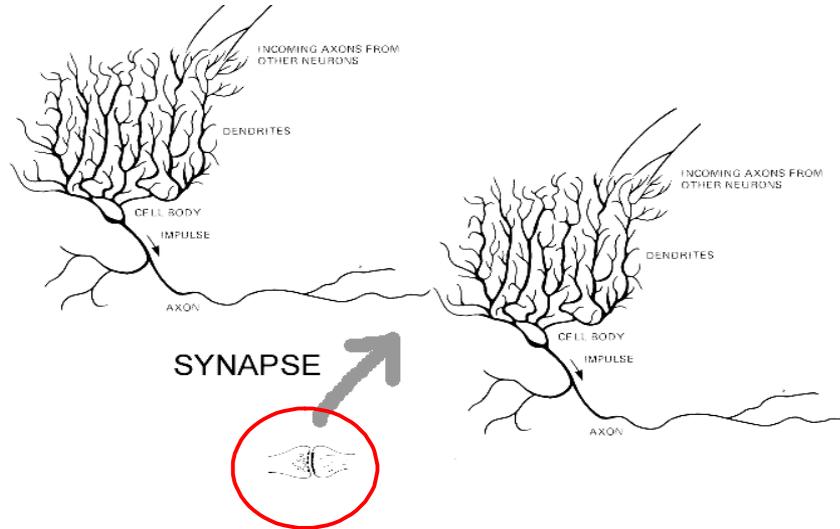
**Figure 1-2a.** A biological neuron magnified 400X with the dendritic tree in the foreground (courtesy of Gary Banker and Aaron Waxman, Univ. of Virginia).



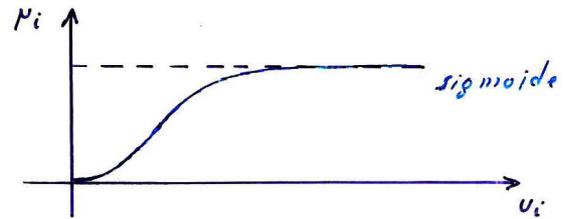
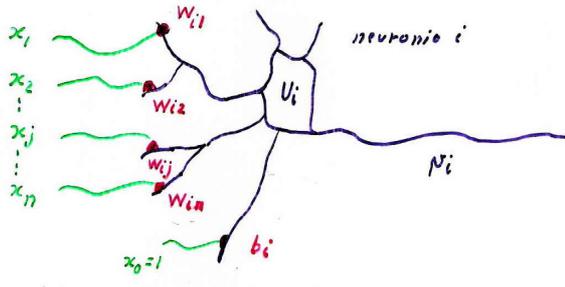
# Neurônio biológico



# Comunicação entre neurônios:

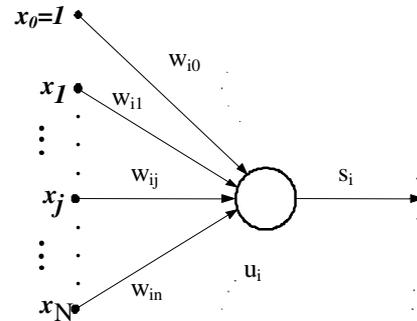


# Neurônio - elemento de processamento

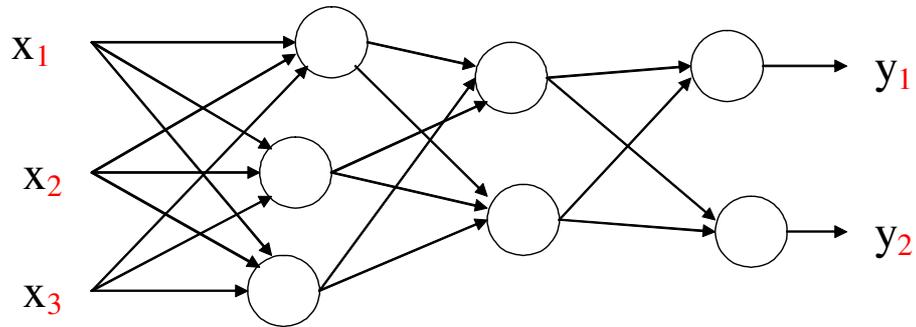


$$u = w_1 x_1 + w_2 x_2 + \dots + w_n x_n$$

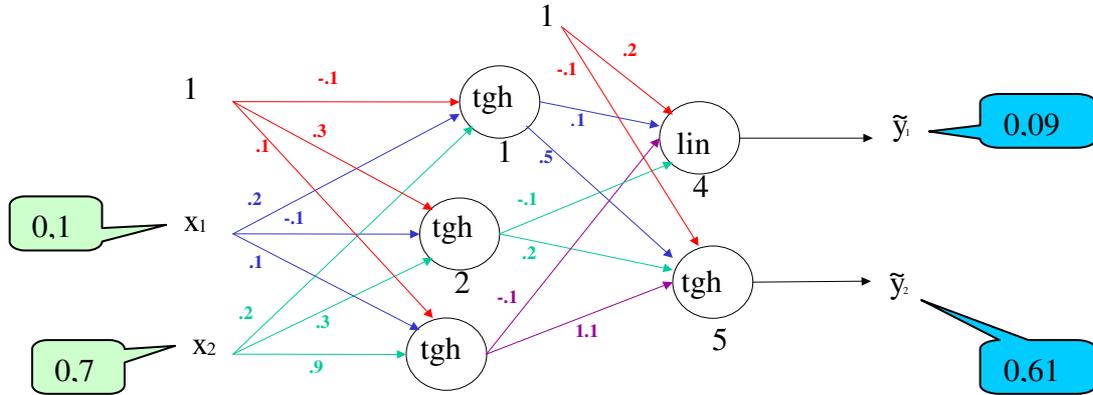
$$\text{saída} = v(u)$$



# Arquitetura da Rede



# Rede Neural



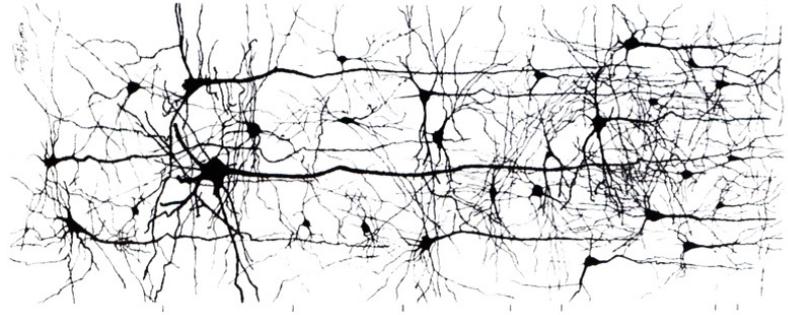
$$\underline{\mathbf{x}} = \begin{bmatrix} 0,1 \\ 0,7 \end{bmatrix}$$

$$\tilde{\mathbf{y}} = \begin{bmatrix} 0,097 \\ 0,614 \end{bmatrix}$$

$$\underline{\tilde{\mathbf{y}}} = \varphi(\underline{\mathbf{x}})$$

**Mapeador não linear, universal**

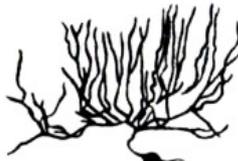
E a memória,  
onde está ?



nas sinapses !



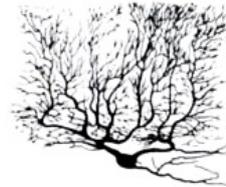
SHARK



TURTLE

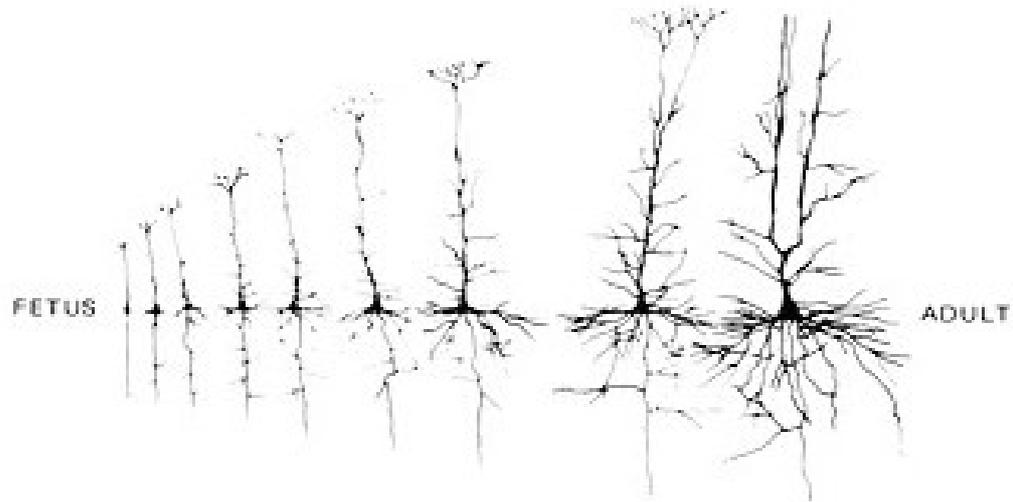


BIRD



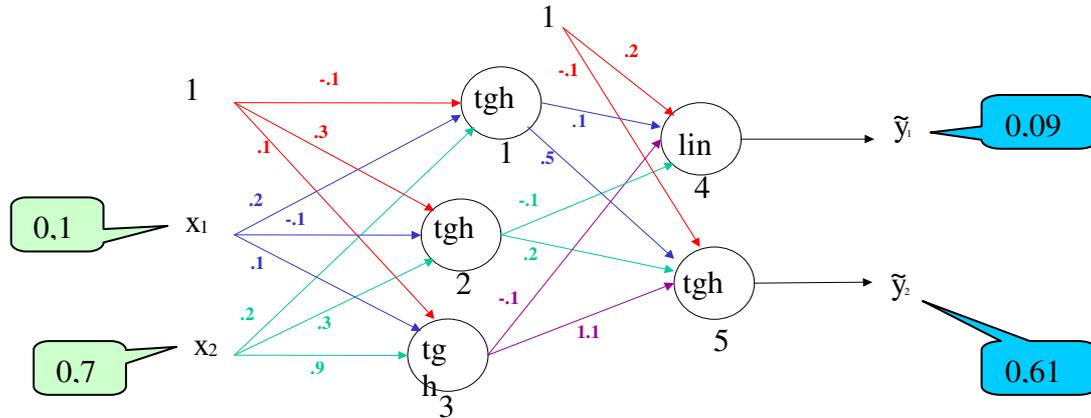
MAN

Memória:

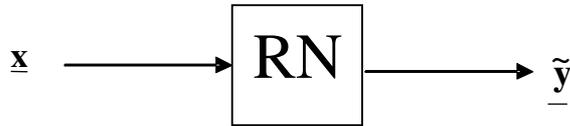


**E o aprendizado ? Alteração das sinapses !**

# Redes Neurais *FeedForward*, “Backpropagation”



$$\underline{x} \longrightarrow \boxed{\text{RN}} \longrightarrow \underline{\tilde{y}} \qquad \underline{\tilde{y}} = \varphi(\underline{x})$$



$$\underline{\tilde{y}} = \varphi(\underline{x})$$

Para que serve ?

Aplicações:

**Simuladores;**

Controladores;

Classificadores;

Reconhecimento de padrões;

Filtragem não linear;

etc...

# Simulação (modelagem) de Sistemas:

Mundo real



Entradas:

- $x_1$  = velocidade atual
- $x_2$  = posição do acelerador
- $x_3$  = posição do freio
- $x_4$  = inclinação
- $x_5$  = número de passageiros
- $x_6$  = etc.

Simulador



Saídas:

- $y_1$  = velocidade após 3 s
- $y_2$  = distância para parar

## Modelagem clássica de um problema:

**Mundo Real**  
objetos físicos



**Representação Matemática**  
dos  
objetos físicos  
por  
objetos matemáticos  
 $\underline{X}_1$   $\underline{X}_2$   
e  
fórmulas

## Uma nova maneira de ver:

**Mundo Real**  
objetos físicos



**Representação Neural**

dos  
**objetos físicos**  
por

**sinais biológicos**

e uma  
**estrutura neural**



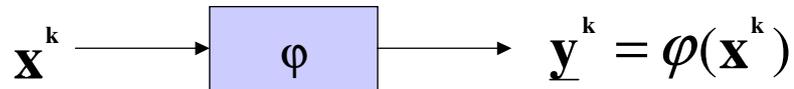
**Representação Matemática**

dos  
**sinais biológicos**  
por  
**objetos matemáticos**  
 $X_1$   $X_2$

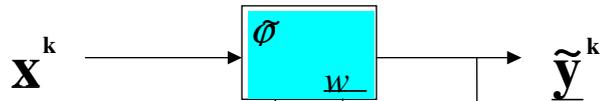
e da  
**estrutura neural**  
por  
**fórmulas conhecidas**

# Simulação de Sistemas:

Planta



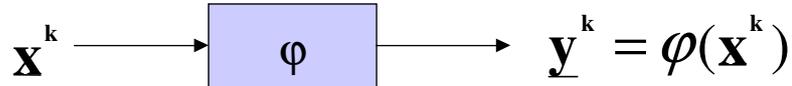
Simulador



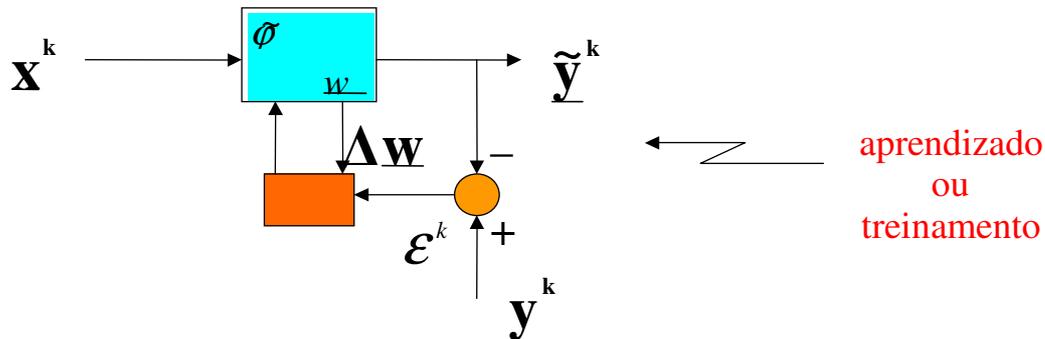
## Aprendizado, Treinamento ou Ajuste do Simulador:

Planta

$$(\mathbf{x}^k, \mathbf{y}^k) \quad k = 1, 2, \dots, P$$



Simulador



**Treinamento = Otimização = Minimização do erro na saída**

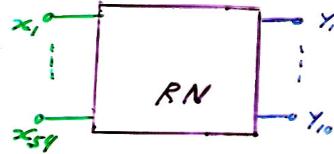
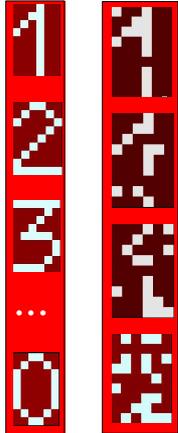
**Função Objetivo à Minimizar = EMQ na saída**

$$F(w_i | i = 1, \dots) = E[(y - \tilde{y})^2]$$

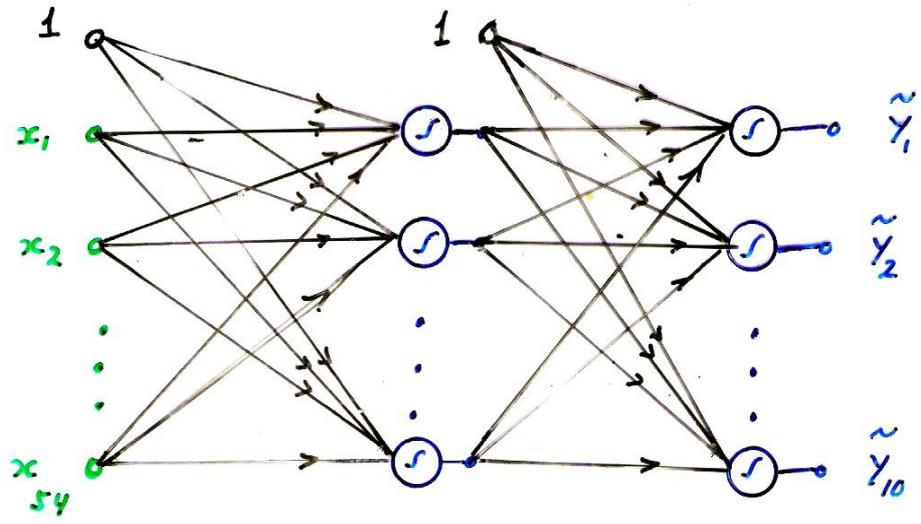
**Método: Gradiente descendente**

$$w_i \xrightarrow{\quad} \Delta w_i = -\alpha \frac{\partial F}{\partial w_i} \xrightarrow{\quad} w_i \leftarrow w_i + \Delta w_i$$


# Demo: OCR

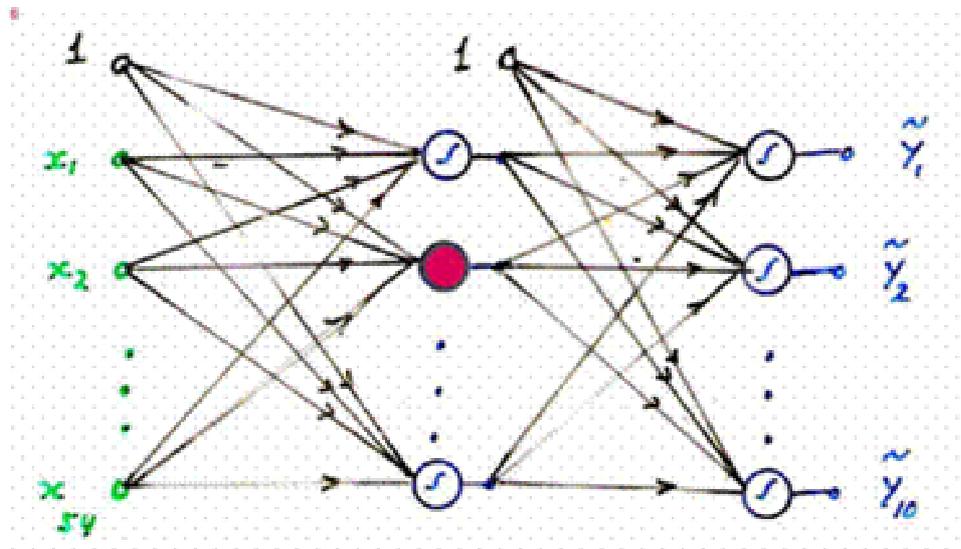


# Rede Neural



# Robustez

## Morte de neurônios



# NeuralTB

## Sistema de Apoio ao Diagnóstico de Tuberculose Bacteriana

HU & COPPE / UFRJ

NeuralTB - Preencha todos os campos do formulário abaixo - Windows Internet Explorer

http://www04.lps.ufrj.br/~neuraltb/sistema/formAdicionaPaciente.html

NeuralTB - Preencha todos os campos do formulário abaixo

### Neural TB

Adicionar Paciente  
Buscar/Editar/Remover

Seja bem-vindo! [logout]

Nome:

Data de Nascimento:  /  /  (dd/mm/aaaa)  O paciente não sabe especificar

Idade:  anos

Sexo:  Masculino  Feminino  Ignorado

Tosse:  Presente  Ausente  Ignorado

Hemoptóico:  Sim  Não  Ignorado

Sudorese Noturna:  Presente  Ausente  Ignorado

Febre:  Presente  Ausente  Ignorado

Emagrecimento:  Presente  Ausente  Ignorado

Dispnéia:  Presente  Ausente  Ignorado

Anorexia:  Presente  Ausente  Ignorado

Fuma Atualmente:  Sim  Não  Ignorado

TB extrapulmonar:  Sim  Não  Ignorado

Internação Hospitalar:  Sim  Não  Ignorado

SIDA:  Sim  Não  Ignorado

Observações Finais:

Formulário de entrada de dados dos pacientes

http://www04.ips.ufrj.br/~neuraitb/cgi-bin/geraGraficoDeGrupo/cgi?grupo=2&raio=0.715501&id=0

Resultado

## Marcos Gomes Silva



**Legenda**

- Alto risco
- Médio risco
- Baixo risco
- Densidade de pacientes
- Paciente cadastrado

**DADOS DO PACIENTE**

**Data de nascimento:** XX/XX/1992  
**Idade:** 15  
**Sexo:** Masculino  
**Tosse:** Ignorado  
**Hemoptóico:** Ignorado  
**Sudorese:** Ignorado  
**Febre:** Ignorado  
**Emagrecimento:** Ignorado  
**Dispnéia:** Ignorado  
**Anorexia:** Ignorado  
**Fuma Atualmente:** Ignorado  
**TB Extrapulmonar:** Ignorado  
**Internação Hospitalar:** Ignorado  
**SIDA:** Ignorado  
**Grupo de Risco:** Alto

**Paciente tuberculoso a nível de 92.1%**

Concluído

Internet | Modo Protegido: Ativado

100%

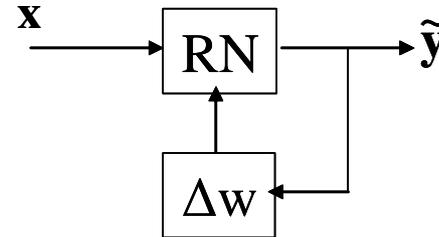
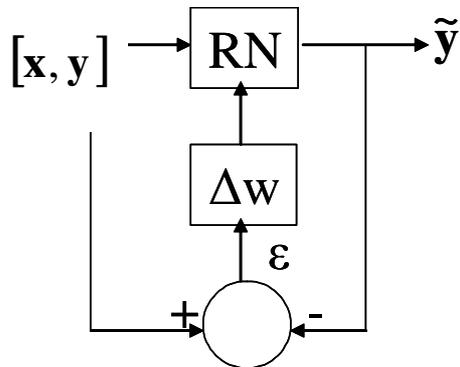
Saída da RN: probabilidade e grupo de risco

## Exemplos de aplicações:

- Modelagem de um Conversor Siderúrgico da CSN
- Modelagem de plantas de destilarias da Petrobras
- Previsão de atraso no pagamento por clientes (pessoas e instituições)
- Previsão do PIB brasileiro
- Previsão de volatilidade de opções Telebrás
- Previsão de demanda de pico de energia
- Identificação do locutor e do conteúdo da locução
- Identificação da confiabilidade de informantes
- Identificação de patologias em eletrocardiogramas
- Identificação de malignidade em anomalias na mama
- Classificação de defeitos em soldas via radiografia ou ultra-som
- Detecção de defeitos em dutos e risers para transporte de petróleo

# Aprendizado sem professor

## Aprendizado supervisionado e não-supervisionado



**Critério:**

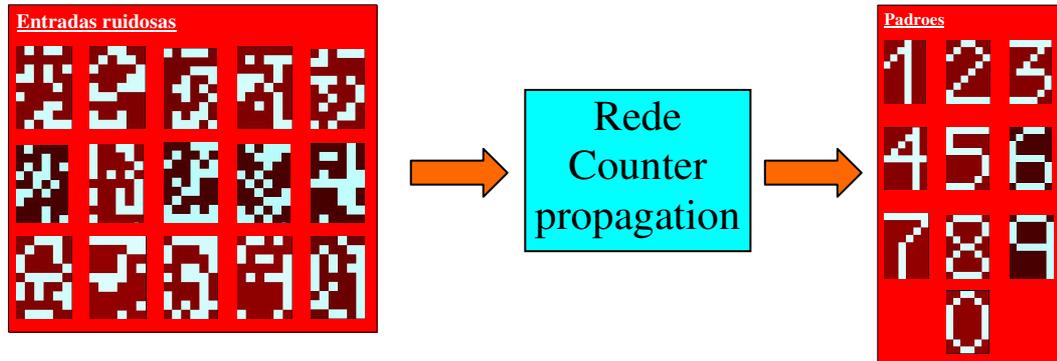
**classificação por similaridade**

# Classificação por Similaridade

Classes agrupam elementos `similares` entre si

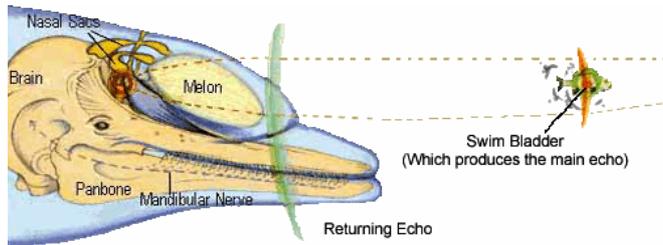
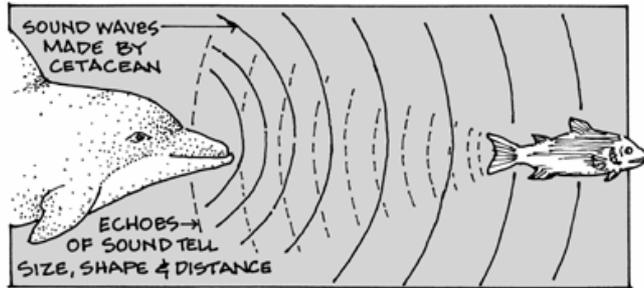


## Ex: OCR: Figuras com ruído

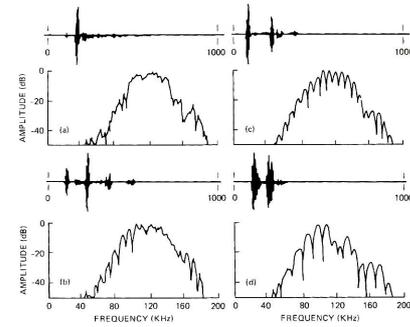
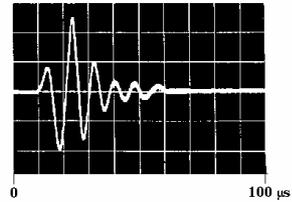


# Detecção de padrões desconhecidos

## Ex 1: Dolphin Ecolocation



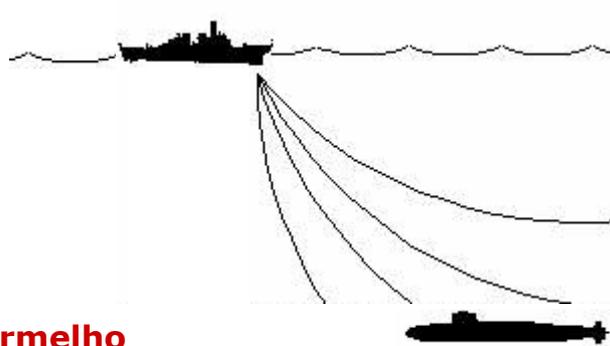
## Time to frequency patterns:



**Figure 10-11.** Amplitude display and Fourier transform for each item in the dolphin echolocation experiment. (From H. L. Roitblat, et al. Dolphin Echolocation: Identification of returning echoes using a counterpropagation network. *Proc. JCNN*. © 1989 IEEE.)

## Pattern determination

## Ex 2: Sonar Passivo



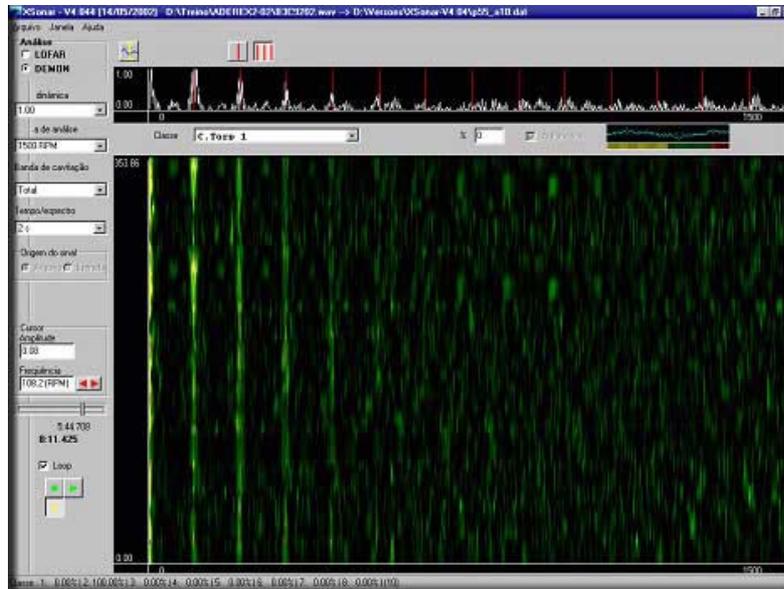
## A Caçada Ao Outubro Vermelho

(The Hunt For Red October)



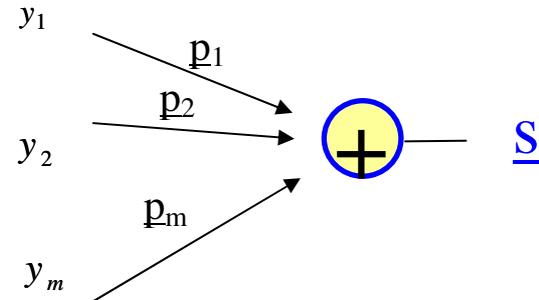
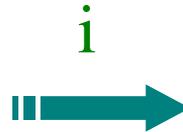
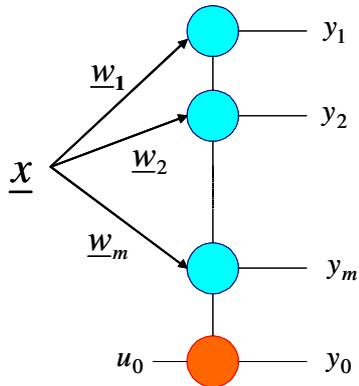
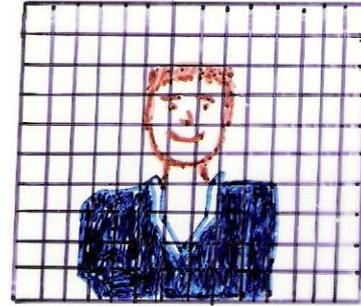
## Classificador de Contatos Sonar (IPqM / UFRJ):

Classificação de alvos via análises Lowfar e Demon do ruído irradiado utilizando-se **reconhecimento de padrões através de redes neurais**.



# Compressão de informações

## Compressão de imagens



## Exemplo de Compressao

### Imagens original e comprimidas

(1x)



(11x)



(15x)

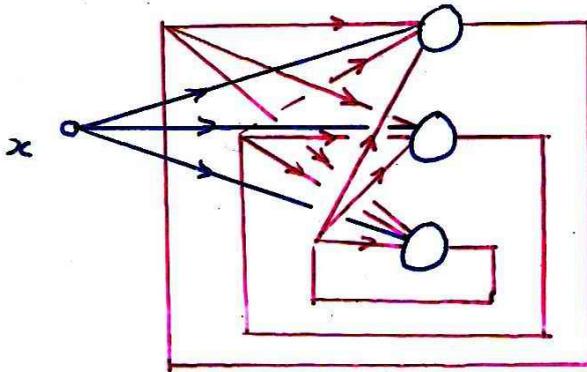


(28x)

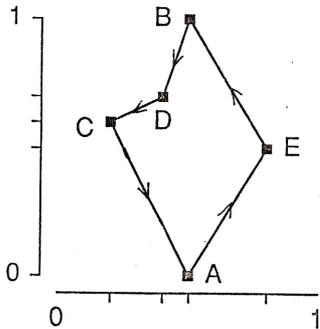
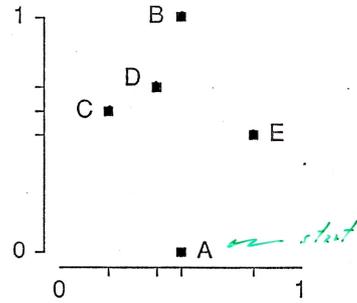


# Problemas de otimização combinatória

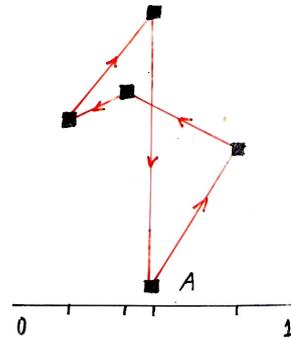
## Redes Realimentadas - redes de Hopfield



# Caixeiro Viajante:

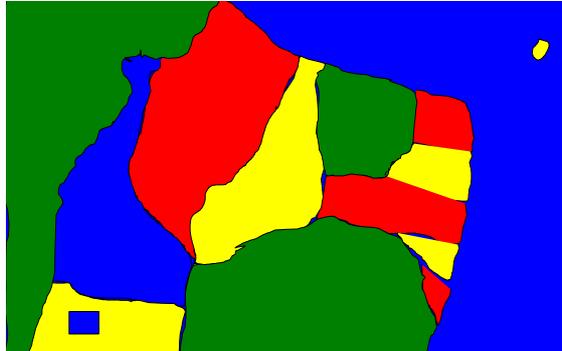


Solução ótima

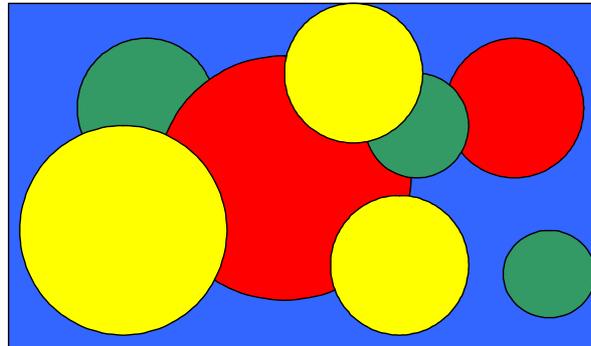


Vizinho mais próximo

## O problema das Quatro cores:



## Demo 4 cores:



# CRYPTANALYSIS OF SPEECH SIGNALS CIPHERED BY TSP USING ANNEALED HOPFIELD NEURAL NETWORK AND GENETIC ALGORITHMS

J. A. Apolinário Jr.<sup>1,3</sup>  
apolin@coe.ufrj.br

P. R. S. Mendonça.<sup>1</sup>  
mendonca@coe.ufrj.br

R. O. Chaves.<sup>1</sup>  
chaves@coe.ufrj.br

L. P. Calôba.<sup>1,2</sup>  
caloba@coe.ufrj.br

## Time Segment Permutation

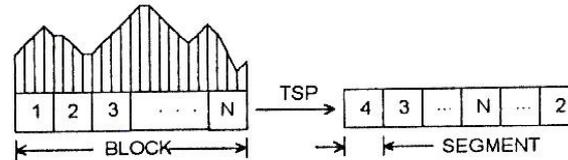


Fig. 1 - Speech signal divided in blocks and segments.

## Resultados:

Percentual de acertos

Apresentação dos Sons

<b>Exemplos</b>	<b>School</b>	<b>Vega</b>
<b>Tipo de processo</b>	<b>% acertos</b>	
<b>Som Criptografado</b>	<b><math>\approx 0</math></b>	<b><math>\approx 0</math></b>
<b>Simulated Ann. e Busca exaustiva</b>	<b>73</b>	<b>91</b>
<b>Som Original</b>	<b>100</b>	<b>100</b>

## Últimos Comentários

### Redes Neurais

**Modelam sistemas e fenômenos que não somos capazes de modelar**

**Tem capacidade de aprender sózinhas**

**Resolvem problemas de otimização**

**mas não são a panacéia universal !!**

## Quando usar ?

Existe um algoritmo satisfatório ?

**SIM - então use o algoritmo**

**NÃO - então pense em usar redes neurais**

## Como usar ?

**Emular em PC** ( 99% dos casos)

**Para saber mais:**

- 1 – Ivan Silva, I.; Spatti, D. e Flauzini, R. - "Redes Neurais Artificiais para engenharia e ciências aplicadas", Artliber,2010
- 2 -Wasserman, P. – “Neural Computing”, Van Nostrand Reinhold, 1989, Cap 1-6.
- 3 - Sarle, W.S. - <ftp://ftp.sas.com/pub/neural/FAQ.html> - uma página com muitas informações interessantes.

INNS

*International Neural Networks Society*



*Fim.*

*Obrigado pelo interesse.*