

Sexo

e **Redes Neurais**

Introdução às Redes Neurais Artificiais e aplicações

Luiz P. Calôba.

caloba@ufrj.br, www.lps.ufrj.br/~caloba

PEP - 2010

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




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

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



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

Mapeador não linear, universal


E a memória,
onde está ?



nas sinapses !





Memória:




E o aprendizado ? Alteração das sinapses !

Redes Neurais *FeedForward*, “Backpropagation”



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



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

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:



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
 $\mathbf{X}_1$ $\mathbf{X}_2$


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

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


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

Neural TB


Adicionar Paciente
Buscar/Editar/Remover

Seja bem-vindo! [logout]

Formulário de entrada de dados dos pacientes

Nome:	John Howards		
Data de Nascimento:	/	/	(dd/mm/aaaa) ☐ O paciente não sabe especificar
Idade:	anos		
Sexo:	☐ Masculino	☐ Feminino	
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:			

Internet 100%





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. Roitblatt, et al. Dolphin Echolocation: Identification of returning echoes using a counterpropagation network. *Proc. IJCNN*. © 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.^{1,3}
apolin@coe.ufrj.br

P. R. S. Mendonça.¹
mendonca@coe.ufrj.br

R. O. Chaves.¹
chaves@coe.ufrj.br

L. P. Calôba.^{1,2}
caloba@coe.ufrj.br

Time Segment Permutation




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

Resultados:

Percentual de acertos

Apresentação dos Sons

Exemplos	School	Vega
Tipo de processo	% acertos	
Som Criptografado	≈ 0	≈ 0
Simulated Ann. e Busca exaustiva	73	91
Som Original	100	100

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.

Material desta palestra em:

www.lps.ufrj.br/~caloba/PEP2010.pdf