



X SEMANA C & T

Introdução às Redes Neurais Artificiais e aplicações

Luiz P. Calôba.

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

Redes Neurais Artificiais

O que é isto ?

Para que serve ?

De onde veio ?

Inteligência Computacional (artificial)

Cognitiva, Simbólica

IA “tradicional”

Evolucionista

AG, Vida Artificial, Enxame, etc.

Conexionista

Redes Neurais Artificiais

Emulam as redes neurais (neurona)
naturais

Redes Neurais Artificiais

Redes Feedforward

Aproximadores e classificadores,

Redes “backpropagation”

Redes Não Supervisionadas


Classificadores

Redes Realimentadas

Otimizadores

Redes Neurais Artificiais



Emulam as redes neurais naturais




Neurônio biológico





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




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

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


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

Mapeador não linear, universal


E a memória,
onde está ?



nas sinapses !





Memória:



E o aprendizado ? Alteração das sinapses !

Parte I - 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:



Simulação de Sistemas:

Planta

$$\underline{\mathbf{x}}^k \longrightarrow \boxed{\varphi} \longrightarrow \underline{\mathbf{y}}^k = \varphi(\underline{\mathbf{x}}^k)$$


Simulador

$$\underline{\mathbf{x}}^k \longrightarrow \boxed{\tilde{\varphi}_{\underline{w}}} \longrightarrow \underline{\tilde{\mathbf{y}}}^k \cong \underline{\mathbf{y}}^k$$


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

$$F(w_i \forall i = 1, \dots) = E_{\forall k=1, \dots, P} \left[|y - \tilde{y}|^2 \right] \quad \text{onde} \quad \tilde{y} = \tilde{y}(w_i \forall i = 1, \dots)$$

Objetivo

encontrar $w_i \forall i = 1, \dots$ tal que



$F(w_i \forall i = 1, \dots)$ seja mínima

solução analítica ? muito complexa.

Solução por métodos numéricos recursivos

Descida continuada

$$\underline{w} \rightarrow \underline{w} + \underline{\Delta w} \quad | \quad F(\underline{w} + \underline{\Delta w}) < F(\underline{w})$$




Que direção garante o decréscimo em F_{in} ?

Pelo método do gradiente descendente o decréscimo é garantido se




$$\Delta w_{jk} = -\alpha \frac{\partial F}{\partial w_{jk}}$$


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: Aproximador

$$\begin{array}{ll} \underline{y} = \varphi(\underline{x}) & \tilde{y} = \varphi(\underline{x}) \\ y = \varphi(x) & \tilde{y} = \varphi(x) \end{array}$$






Demo: Classificador (OCR)




Rede Neural



Robustez

Morte de neurônios



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

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:



Parte II



**Camada de Kohonen,
Rede ART,
Rede Counterpropagation,
SOM, QV**

**Aprendizado não supervisionado,
sem professor,
cego.**

Plasticidade.

Aprendizado sem professor

Aprendizado supervisionado e não-supervisionado




Critério:


classificação por similaridade


Classificação por Similaridade

Classes agrupam elementos `similares` entre si




Classificação por Similaridade

objetos físicos $O_1 O_2$  objetos matemáticos $\underline{x}_1 \underline{x}_2$

similaridade física  similaridade matemática

$$O_1 \approx O_2$$

$$\underline{x}_1 \cong \underline{x}_2 \quad \text{ou} \quad |\underline{x}_1 - \underline{x}_2| \ll$$




Neurônio como **medidor** de similaridade

entre uma entrada $\underline{x}$ e um padrão $\underline{w}_i$

uma outra definição

$$u_i = -\|\underline{x} - \underline{w}_i\|^2 = -d_i^2 \leq 0$$



u_i - medida de similaridade entre $\underline{x}$ e $\underline{w}_i$

$u_i = 0$ distância nula = máxima similaridade

y_i – depende dos outros neurônios


Camada de Kohonen

Template Matching

$$u_i = -d_i^2$$

**maior u_i =
menor distância =
maior similaridade**


u_i é uma medida de similaridade entre $\underline{x}$ e $\underline{w}_i$



Winner-takes-all

$$y_i = 1 \text{ sse } u_i > u_j \quad \forall j \neq i$$

$$y_i = 0 \quad \text{caso contrário}$$




Camada de Kohonen

[versão unidimensional, simplificada (D=0)]

Classe C_i

Padrão $\underline{w}_i$

Indicador y_i






Se $y_i = 1$ então $\underline{x} \in C_i$

pele critério 1 (padrão mais similar a entrada).

Camada de Kohonen


Classificação por similaridade - Treinamento Supervisionado



Camada de Kohonen

Classificação por similaridade - Treinamento não supervisionado

-



Camada de Kohonen

Treinamento não supervisionado

$$\underline{x}(n) \gg \gg \gg y_i = 1$$


$$\begin{aligned}\underline{w}_i(n+1) &= \underline{w}_i(n) + \alpha [\underline{x}(n) - \underline{w}_i(n)] \\ &= (1-\alpha) \underline{w}_i(n) + \alpha \underline{x}(n)\end{aligned}$$

$$\underline{w}_j(n+1) = \underline{w}_j(n) \quad \forall j \neq i$$


O treinamento é dito **competitivo**, porque apenas o neurônio vencedor treina.

Demo


1A



7






Demo: 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




Demo: Exemplo de Compressao

Imagens original e comprimidas

(1x)




(11x)




(15x)







(28x)



Mapas de Kohonen - Redes SOM




Matriz de distâncias - U matrix



Parte III

Redes Realimentadas - redes de Hopfield


Problemas de otimização combinatória



A rede evolui no tempo e estabiliza (para) quando

$$E(\underline{y}) = - \left[\frac{1}{2} \underline{y}^t \underline{W} \underline{y} + \underline{y}^t \underline{I} \right] + c$$

é mínima (função de Lyapunov).



e daí ???

Problemas de otimização combinatória:

Dada uma função objetivo $F(\underline{y})$, $\underline{y} \in \{0,1\}^m$

Deseja-se encontrar $\underline{y}_0 = \text{Minimante } F(\underline{y})$



Rede de Hopfield

Dada uma função $E(\underline{y})$, $\underline{y} \in \{0,1\}^m$


A rede evolui ate que $\underline{y} = \underline{y}_{\min} = \text{Minimante } E(\underline{y})$

A rede de Hopfield resolve problemas de otimização combinatória

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

São mais uma ferramenta,

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 - Haykin, S., “Neural Networks, A Comprehensive Foundation”, Prentice Hall, 1999. Ver também: Haykin, S., “Redes Neurais, Teoria e Prática”, Bookman, 2001.

INNS

International Neural Networks Society



Fim.

Obrigado pelo interesse.

As transparencias desta palestra estão em
www.lps.ufrj.br/~caloba/cefet.leopoldina.pdf