

**INSTITUTO DE PÓS GRADUAÇÃO – ICPG
GESTÃO DA TECNOLOGIA DA INFORMAÇÃO**

Inteligência Artificial Aplicada a Sistemas de Informação

Prof. Msc. Saulo Popov Zambiasi
(saulopz@gmail.com)

Redes Neurais Artificiais

Fundamentação Biológica, O Neurônio Artificial,
Implementação do Neurônio Artificial, Aprendizado das Redes
Neurais Artificiais.

As Redes Neurais Artificiais (RNA)

- Redes Neurais Artificiais (RNA) são sistemas computacionais baseados conexões.
- Cada um dos nós – neurônios – é interligado a outros para formar um a rede – daí o termo "Rede Neural".
- Inspiração original no cérebro a partir do exame da célula neural.
- No campo da inteligência artificial, as RNAs são sistemas não lineares que tentam imitar o mecanismo de processamento do cérebro animal.

Fundamentação Biológica

A Neurociência busca, através do estudo do conjunto de complexos processos mentais via comportamento das células nervosas, a compreensão de como o cérebro produz a individualidade da ação dos seres encefálicos.

O Cérebro humano

- Rede de mais de 100 bilhões de células nervosas que se interconectam.
- Conexões feitas via conexões sinápticas.
- Produzem:
 - A percepção humana do mundo exterior .
 - O mecanismo de ação e o processo mental do indivíduo.
- As células nervosas se comunicam via transmissão sináptica.


O Cérebro humano

- Os indivíduos encéfalos obtêm informações sobre o seu meio através de vários receptores sensoriais.
- As informações se transformam em percepções ou ordens para atuar no meio em que se encontram.
- Arco reflexo:
 - Ocorre uma percepção pelo indivíduo.
 - Uma resposta é elaborada e interpretada pelos centros nervosos superiores, Arco Reflexo Central.

O Cérebro Humano

- Reflexo de sobrevivência:
 - São respostas imediatas.
 - Não possuem interpretação detalhada e coordenada pela medula espinhal.
 - São denominadas de Arco Reflexo Periférico.
 - Saltar durante um susto.
 - Retirar a mão de uma superfície quente.

O Cérebro Humano




O Cérebro Humano



O Neurônio

- Células Nervosas - unidades básicas do encéfalo.
- São, por si só, muito simples.
- A complexidade está na grande quantidade de conexões de milhares de células nervosa.
- O encéfalo é capaz de gerar comportamentos bastante complexos.
- O potencial de ação para produzir condutas complexas não depende da variedade das células nervosas, mas sim de seu número e de suas conexões.

O Neurônio




Sinapse

- A Sinapse é a comunicação:
 - entre um neurônio e outro,
 - ou entre o neurônio e outros tecidos.
- A condução de um estímulo elétrico pela membrana celular de um neurônio é unidirecional, sempre no sentido dendrito → corpo celular → axônio.
- O elemento que fica antes da comunicação (sinapse) celular é denominado pré-sináptico e o que fica depois de pós-sináptico.

Estímulo Elétrico


Diagrama de um neurônio



Conexões sinápticas

- Fenda sináptica. espaço entre o elemento pré-sináptico e o pós-sináptico é denominado.
- Processo:
 1. O impulso nervoso atinge essas extremidades do axônio
 2. Os neurotransmissores são liberados para a fenda sináptica
 3. Os neurotransmissores se ligam aos receptores da membrana da célula seguinte.
 4. É desencadeado o impulso nervoso.
 5. A propagação continua.


Fenda Sináptica



O Neurônio Artificial

- Modelo simplificado e simulado do neurônio real.
- Características básicas:
 - Adaptação .
 - Representação de conhecimentos baseada em conexões.
- McCulloch & Pitts (1943)
 - Modelaram o cérebro como um sistema computacional.
 - Modelo simplificado do que se sabia então a respeito do neurônio biológico.

Modelo do Neurônio Artificial



Bias

- Também chamadas de tendência
- É um erro sistemático, diferentemente de erro aleatório.
- Um ou mais componentes do erro sistemático podem contribuir para a tendência.
- Uma grande diferença sistemática em relação ao valor de referência aceito reflete-se em um grande valor de tendência.

A Função Net

$$net_i(t) = \sum_{j=1}^N w_{ij} x_j(t)$$

Função de Ativação (fa)

$$\mathbf{x}(t+1) = \text{fa}(\mathbf{x}(t), \text{net}(t))$$

- Neurônio Dinâmico:
 - Os estados futuros são afetados pelo estado atual do neurônio e pelo valor do net de entrada.
 - Neurônio com "memória".
- Neurônio Estático:
 - Função constante.
 - Neurônios sem "memória".
 - O estado atual é igual aos estados anteriores.

Função de Saída (fs)

- Qualquer função contínua e monotônica crescente, tal que:

$$\mathbf{x \in R \ e \ y(x) \in [-1,1]}$$

- Função Linear

$$\mathbf{y(x) = ax}$$

- Função Sigmoidal ou Logística

$$\mathbf{y(x) = 1 / (1 + e^{-kx})}$$

- Função Tangente Hiperbólica


$$\mathbf{y(x) = \tanh(kx) = (1 - e^{-kx}) / (1 + e^{-kx})}$$

Implementação do Neurônio Artificial

- Resolução de portas lógicas

x1	x2	Or	and	xor
0	0	0	0	1
0	1	1	0	0
1	0	1	0	0
1	1	1	1	1

Modelo Esquemático



Domínio

- Domínio de $w = [-1, 1]$
- Domínio de $x = [0, 1]$
- Domínio de $y = [0, 1]$

- Onde:
 - w representa o peso da conexão.
 - x é o valor de entrada.
 - y é o valor de saída.

Execução

$$net = \sum_{i=0}^n x_i w_i$$

Diagram illustrating the execution of a neural network calculation. The equation $net = \sum_{i=0}^n x_i w_i$ is shown. The term x_i is labeled as "entrada" (input) with an arrow pointing to it. The term w_i is labeled as "peso" (weight) with an arrow pointing to it.


Função de Transferência

Se ($\text{net} > 0$) então

$$y = 1$$

Senão

$$y = 0$$



Fórmula de Treinamento

$$w_i = w_i + \Delta w_i$$

$$\Delta w_i = \eta (t-y) x_i$$

ou

$$w_i = w_i + \eta (t-y) x_i$$

Diagram illustrating the components of the weight update formula:

- w_i (new weight) → novo peso
- w_i (current weight) → peso atual
- η (learning rate) → ritmo de aprendizado
ex: 0,1
- $(t-y)$ (error) → objetivo - saída
- x_i (input) → entrada i

Algoritmo de Treinamento

Início

Atribuir pesos aleatórios

Laço

Para cada exemplo fazer

Executar exemplo

Se saída incorreta então fazer

Modificar pesos (w)

Fim se

Fim para

Repetir até (todas saídas corretas) ou (terminar N épocas)

Fim

Caso: Treinamento porta OR

Exemplos – conjunto de valores de treinamento, com entradas e respectivas saídas.

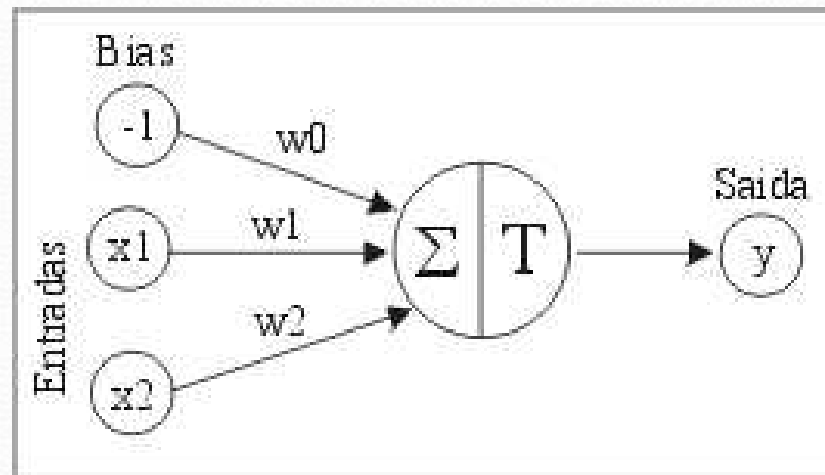
- 1- Entradas 0 e 0 - saída 0
- 2- Entradas 0 e 1 - saída 1
- 3- Entradas 1 e 0 - saída 1
- 4- Entradas 1 e 1 - saída 1

Estado inicial

$x_0 = -1$, $w_0 = 0,7$ (bias)

$x_1 = 0$, $w_1 = -0,3$

$x_2 = 1$, $w_2 = 0,4$



Executando Exemplo 1

1- Entradas 0 e 0 - saída 0

$$\text{Net} = x_0 \times w_0 + x_1 \times w_1 + x_2 \times w_2.$$

$$\text{Net} = (-1) \times 0,7 + 0 \times (-0,3) + 0 \times 0,4$$

$$\text{Net} = -0,7$$

FT = se net > 0 então y = 1 senão y = 0

Portanto y = 0 (Corresponde à saída).

2- Entradas 0 e 1 - saída 1

3- Entradas 1 e 0 - saída 1

4- Entradas 1 e 1 - saída 1

Executando Exemplo 2

1- Entradas 0 e 0 - saída 0

2- Entradas 0 e 1 - saída 1

$$\text{Net} = x_0 \times w_0 + x_1 \times w_1 + x_2 \times w_2.$$

$$\text{Net} = (-1) \times 0,7 + 0 \times (-0,3) + 1 \times 0,4$$

$$\text{Net} = -0,7 + 0,4 = -0,3 = 0$$

FT = se net > 0 então y = 1 senão y = 0

Portanto y = 0 (Não corresponde à saída).

Necessário treinamento

3- Entradas 1 e 0 - saída 1

4- Entradas 1 e 1 - saída 1

Treinando

$$w_i = w_i + N(t - y)x_i$$

$$w_0 = 0,7 + 0,1(1 - 0) * (-1) = 0,6$$

$$w_1 = -0,3 + 0,1(1 - 0) * 0 = -0,3$$

$$w_2 = 0,4 + 0,1(1 - 0) * 1 = 0,5$$

$$w_i = w_i + \eta (t - y) x_i$$

Diagram illustrating the weight update formula with labels:

- w_i (left): novo peso
- w_i (middle): peso atual
- η : ritmo de aprendizado
ex: 0,1
- $(t - y)$: objetivo
- x_i (top right): saída
- x_i (bottom right): entrada i

Executando Exemplo 3

1- Entradas 0 e 0 - saída 0

2- Entradas 0 e 1 - saída 1

3- Entradas 1 e 0 - saída 1

$$\text{Net} = x_0 \times w_0 + x_1 \times w_1 + x_2 \times w_2.$$

$$\text{Net} = (-1) \times 0,6 + 1 \times (-0,3) + 0 \times 0,5$$

$$\text{Net} = -0,6 + -0,3 = -0,9 = 0$$

FT = se net > 0 então y = 1 senão y = 0

Portanto y = 0 (Não corresponde à saída).

Necessário treinamento

4- Entradas 1 e 1 - saída 1

Treinando

$$w_i = w_i + N(t - y)x_i$$

$$w_0 = 0,6 + 0,1(1 - 0) * (-1) = 0,5$$

$$w_1 = -0,3 + 0,1(1 - 0) * 0 = -0,3$$

$$w_2 = 0,5 + 0,1(1 - 0) * 1 = 0,6$$

$$w_i = w_i + \eta (t - y) x_i$$

Diagram illustrating the weight update formula with labels:

- w_i (left): novo peso
- w_i (middle): peso atual
- η : ritmo de aprendizado
ex: 0,1
- $(t - y)$: objetivo
- x_i (left): saída
- x_i (right): entrada i

Executando Exemplo 4

- 1- Entradas 0 e 0 - saída 0
- 2- Entradas 0 e 1 - saída 1
- 3- Entradas 1 e 0 - saída 1
- 4- Entradas 1 e 1 - saída 1

$$\text{Net} = x_0 \times w_0 + x_1 \times w_1 + x_2 \times w_2.$$

$$\text{Net} = (-1) \times 0,5 + 1 \times (-0,3) + 1 \times 0,6$$


$$\text{Net} = -0,5 + -0,3 + 0,6 = -0,1 = 0$$

FT = se net > 0 então y = 1 senão y = 0

Portanto y = 0 (Não corresponde à saída).

Necessário treinamento

Redes Neurais Artificiais




Tipos de Aprendizado

- Supervisionado:
 - Com professor.
 - Testa a saída com o valor esperado.
 - Propaga o erro para as camadas anteriores.
- Não supervisionado:
 - Não há um professor.
 - Não há um valor a ser comparado.
 - Modifica os pesos apenas baseando-se nos sinais das entradas e saídas

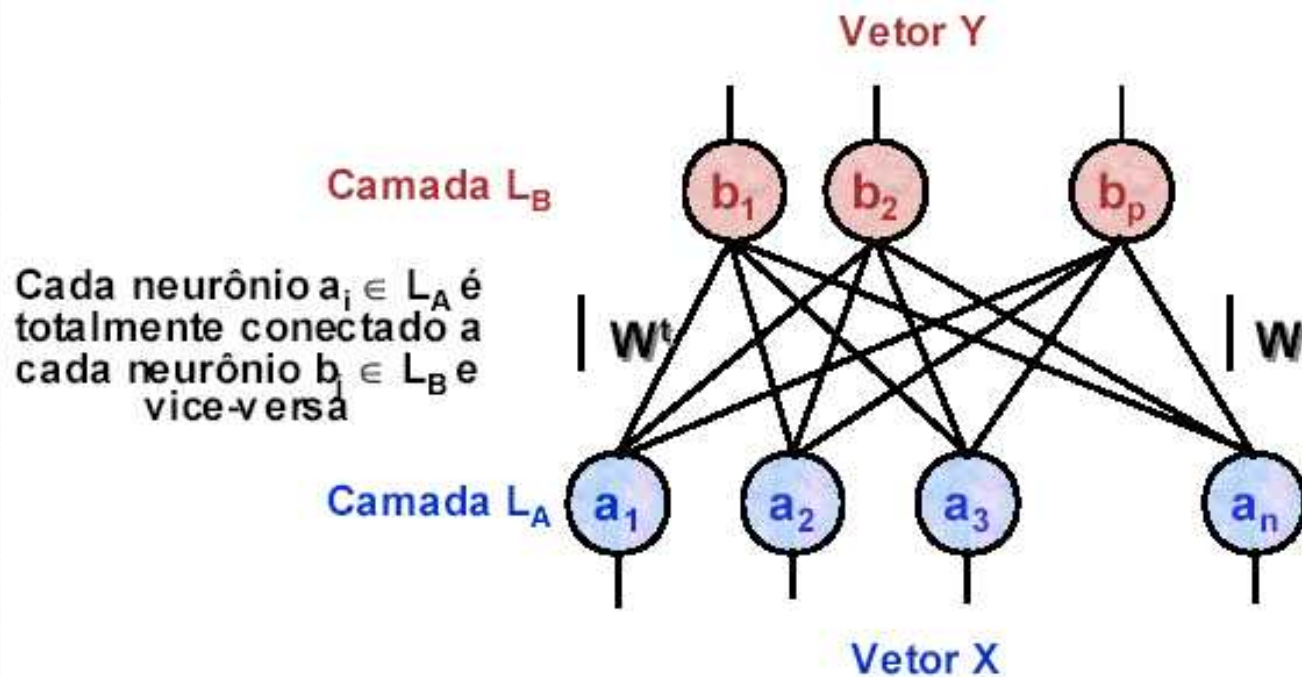
Tipos de RNAs

- Multilayer Perceptron
- BAM - *Bidirectional Associative Memory*
- Kohonen – Mapas auto-organizáveis

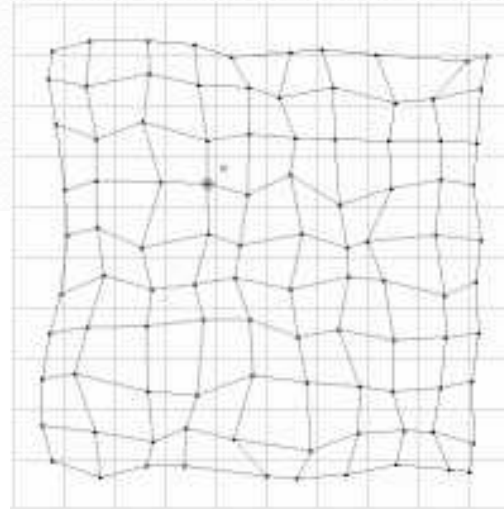
Multilayer Perceptron



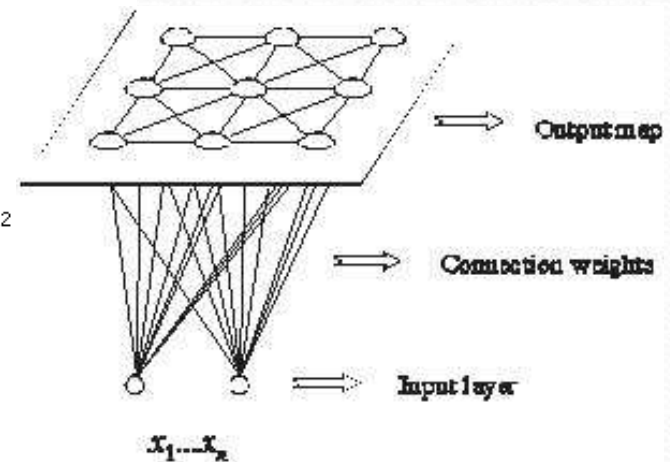

BAM - Bidirectional Associative Memory



Kohonen



distribution



**INSTITUTO DE PÓS GRADUAÇÃO – ICPG
GESTÃO DA TECNOLOGIA DA INFORMAÇÃO**

Inteligência Artificial Aplicada a Sistemas de Informação

Prof. Msc. Saulo Popov Zambiasi
(saulopz@gmail.com)