

PERCEPTRON


- **Características Básicas**
- **Modelo de Neurônio**
- **Estrutura da Rede**
- **Algoritmo de Aprendizado**

CARACTERISTICAS BASICAS

- Regra de propagação $net_j = \sum_i x_i w_{ij} + \theta_i$
- Função de ativação: Degrau
- Topologia: uma única camada de processadores
- Algoritmo de Aprendizado: $\Delta w_{ij} = \eta x_i (t_j - s_j)$
(supervisionado)
- Valor de Entrada/Saída: Binários

MODELO DO NEURÔNIO

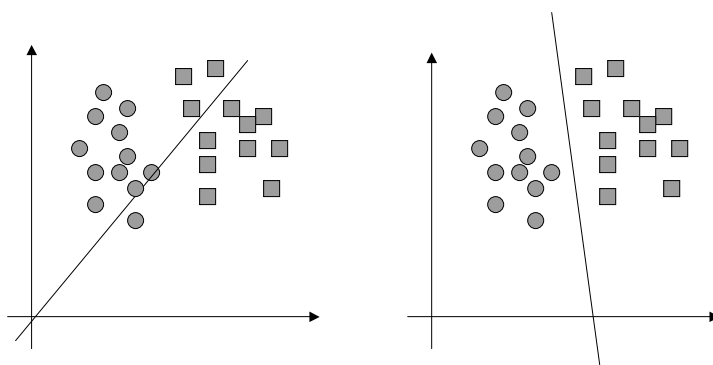
Na sua forma mais simples, o modelo do processador consiste em:



$$s_j = F(\text{net}_j) = F\left(\sum_i x_i w_{ij} + \theta_i\right) = \begin{cases} 1 & \text{net}_j > 0 \\ 0 & \text{net}_j \leq 0 \end{cases}$$

PERCEPTRON

Finalidade do Termo *Bias*:



$$\sum_i x_i w_{ij} = 0 \quad \text{Define um hiperplano passando pela origem}$$

$$\sum_i x_i w_{ij} + \theta_i = 0 \quad \text{Desloca-se o hiperplano da origem}$$

ALGORITMO DE APRENDIZADO

- 1) iniciar os pesos sinápticos com valores randomicos e pequenos ou iguais a zero;
- 2) aplicar um padrão com seu respectivo valor desejado de saída (t_j) e verificar a saída da rede (s_j);
- 3) calcula o erro na saída $E_j = t_j - s_j$;
- 4) se $E_j = 0$, volta ao passo 2;
se $E_j \neq 0$, atualiza os pesos: $\Delta w_{ij} = \eta x_i E_j$;
- 5) volta ao passo 2.

ALGORITMO DE APRENDIZADO

IMPORTANTE

- não ocorre variação no peso se a saída estiver correta;
- caso contrario, cada peso é incrementado de η quando a saída é menor que o target e decrementado de η quando a saída é maior que o target.

$$\Delta w_{ij} = \eta x_i e_j$$

PROCESSO DE APRENDIZADO

- Processo de minimização do erro quadrático pelo método do *Gradiente Descendente*

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}$$

- Cada peso sináptico i do elemento processador j é atualizado proporcionalmente ao *negativo da derivada parcial do erro* deste processador com relação ao peso.

PROCESSO DE APRENDIZADO

Calcula Δw_{ij}

$$\Delta w_{ij} = -\eta \frac{\partial E_p}{\partial w_{ij}} = -\eta \begin{array}{|c|c|} \hline \frac{\partial E_p}{\partial x_j} & \frac{\partial x_j}{\partial w_{ij}} \\ \hline \end{array}$$
$$E_p = \frac{1}{2} \sum_j (t_j - x_j)^2 \qquad x_j = \sum x_i w_{ij} + \theta_j$$
$$2 \times \frac{1}{2} \times (t_j - x_j) (-1) \qquad x_i$$

$$\Delta w_{ij} = -\eta (t_j - x_j) x_i$$

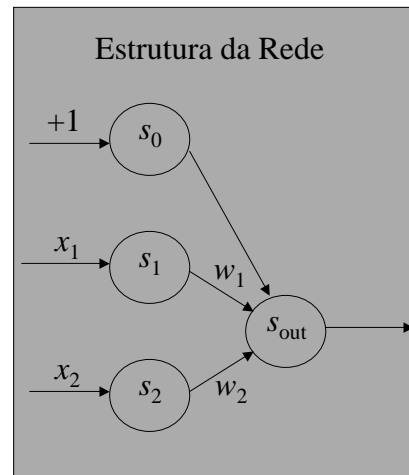
EXEMPLO

Simulação do Operador Lógico AND

AND	x_0	x_1	x_2	t
Entrada 1:	1	0	0	0
Entrada 2:	1	0	1	0
Entrada 3:	1	1	0	0
Entrada 4:	1	1	1	1

Peso inicial: $w_0 = 0$, $w_1 = 0$, $w_2 = 0$

Taxa de aprendizado: $\eta = 0.5$



EXEMPLO

1ª Cicle

$$\begin{aligned} \text{Entrada 1: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 0 \times 0 + 0 \times 0) = f(0) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 2: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 0 \times 1 + 0 \times 0) = f(0) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 3: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 0 \times 0 + 0 \times 1) = f(0) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 4: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 0 \times 1 + 0 \times 1) = f(0) = 0 \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = 0 + 0.5 \times (1 - 0) \times 1 = 0.5$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 0 + 0.5 \times (1 - 0) \times 1 = 0.5$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0 + 0.5 \times (1 - 0) \times 1 = 0.5$$

EXEMPLO

2ª Ciclo

$$\begin{aligned} \text{Entrada 1: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0.5 \times 1 + 0.5 \times 0 + 0.5 \times 0) = f(0.5) = 1 \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = 0.5 + 0.5 \times (0 - 1) \times 1 = 0$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 0.5 + 0.5 \times (0 - 1) \times 0 = 0.5$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0.5 + 0.5 \times (0 - 1) \times 0 = 0.5$$

$$\begin{aligned} \text{Entrada 2: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 0.5 \times 0 + 0.5 \times 1) = f(0.5) = 1 \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = 0 + 0.5 \times (0 - 1) \times 1 = -0.5$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 0.5 + 0.5 \times (0 - 1) \times 0 = 0.5$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0.5 + 0.5 \times (0 - 1) \times 1 = 0$$

EXEMPLO

2ª Ciclo

$$\begin{aligned} \text{Entrada 3: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-0.5 \times 1 + 0.5 \times 1 + 0 \times 0) = f(0) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 4: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-0.5 \times 1 + 0.5 \times 1 + 0 \times 1) = f(0) = 0 \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = -0.5 + 0.5 \times (1 - 0) \times 1 = 0$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 0.5 + 0.5 \times (1 - 0) \times 1 = 1$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0 + 0.5 \times (1 - 0) \times 1 = 0.5$$

EXEMPLO

3ª Ciclo

$$\begin{aligned} \text{Entrada 1: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 1 \times 0 + 0.5 \times 0) = f(0) = 0 \quad \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 2: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(0 \times 1 + 1 \times 0 + 0.5 \times 1) = f(0.5) = 1 \quad \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = -0.5 + 0.5 \times (0 - 1) \times 1 = -1$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 1 + 0.5 \times (0 - 1) \times 0 = 1$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0.5 + 0.5 \times (0 - 1) \times 1 = 0$$

EXEMPLO

3ª Ciclo

$$\begin{aligned} \text{Entrada 3: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 1 + 0 \times 0) = f(0) = 0 \quad \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 4: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 1 + 0 \times 1) = f(0) = 0 \quad \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = -1 + 0.5 \times (1 - 0) \times 1 = -0.5$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 1 + 0.5 \times (1 - 0) \times 1 = 1.5$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0 + 0.5 \times (1 - 0) \times 1 = 0.5$$

EXEMPLO

4ª Ciclo

$$\begin{aligned} \text{Entrada 1: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-0.5 \times 1 + 1.5 \times 0 + 0.5 \times 0) = f(-0.5) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 2: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-0.5 \times 1 + 1.5 \times 0 + 0.5 \times 1) = f(0) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 3: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-0.5 \times 1 + 1.5 \times 1 + 0.5 \times 0) = f(1) = 1 \implies s_{\text{out}} \neq t \end{aligned}$$

$$w_0 = w_0 + (t - s_{\text{out}})x_0 = -0.5 + 0.5 \times (0 - 1) \times 1 = -1$$

$$w_1 = w_1 + (t - s_{\text{out}})x_1 = 1.5 + 0.5 \times (0 - 1) \times 1 = 1$$

$$w_2 = w_2 + (t - s_{\text{out}})x_2 = 0.5 + 0.5 \times (0 - 1) \times 0 = 0.5$$

$$\begin{aligned} \text{Entrada 4: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 1 + 0.5 \times 1) = f(0.5) = 1 \implies s_{\text{out}} = t \end{aligned}$$

EXEMPLO

5ª Ciclo

$$\begin{aligned} \text{Entrada 1: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 0 + 0.5 \times 0) = f(-1) = 0 \implies s_{\text{out}} = t \end{aligned}$$


$$\begin{aligned} \text{Entrada 2: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 0 + 0.5 \times 1) = f(-0.5) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 3: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 1 + 0.5 \times 0) = f(0) = 0 \implies s_{\text{out}} = t \end{aligned}$$

$$\begin{aligned} \text{Entrada 4: } s_{\text{out}} &= f(w_0x_0 + w_1x_1 + w_2x_2) \\ &= f(-1 \times 1 + 1 \times 1 + 0.5 \times 1) = f(0.5) = 1 \implies s_{\text{out}} = t \end{aligned}$$

$$w_0 = -1, w_1 = 1, w_2 = 0.5$$

INTERPRETAÇÃO GEOMÉTRICA



Linha de Decisão:


$$x_1 w_1 + x_2 w_2 = -\theta$$



$$x_1 + 0.5 x_2 = 1$$

O PROBLEMA DO OU-EXCLUSIVO (XOR)


PONTO	X_1	X_2	Saída
A_0	0	0	0
A_1	0	1	1
A_2	1	0	1
A_3	1	1	0



De acordo com a definição do neurônio: $x = F(x_1 w_1 + x_2 w_2 + \theta)$

$$y = x_1 w_1 + x_2 w_2 + \theta \rightarrow \begin{cases} \text{se } y \geq 0 \rightarrow x = 1 \\ \text{se } y < 0 \rightarrow x = 0 \end{cases}$$

A rede perceptron divide o plano $X_1 \times X_2$ em duas regiões (através da reta y).




O PROBLEMA DO OU-EXCLUSIVO (XOR)

Conclusão

- mudando-se os valores de w_1 , w_2 e θ , muda-se a inclinação e a posição da reta;
- entretanto é impossível achar uma reta que divide o plano de forma separar os pontos A_1 e A_2 de um lado e A_0 e A_3 de outro
- redes de 1 única camada só representam **funções linearmente separáveis**

O PROBLEMA DO OU-EXCLUSIVO (XOR)




O PROBLEMA DO OU-EXCLUSIVO (XOR)

Minsky & Papert provaram que este problema pode ser solucionado adicionando-se uma outra camada intermediária de processadores- Multi-Layer Perceptron (MLP)

O PROBLEMA DO OU-EXCLUSIVO (XOR)

Exemplo:



$$w_{11} = w_{12} = w_{21} = w_{22} = +1$$

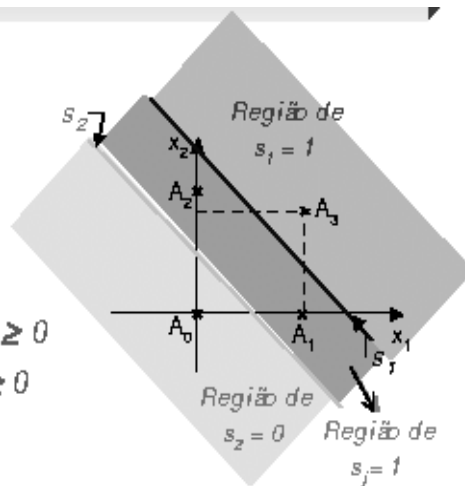
$$s_j = 1 \rightarrow s_1 w_{1j} + s_2 w_{2j} + \theta_j \geq 0$$

$$-2s_1 + s_2 - 0.5 \geq 0$$

$$-2s_1 + s_2 \geq 0.5$$




s_1 é inibitório
 s_2 é excitatório



O PROBLEMA DO OU-EXCLUSIVO (XOR)

Pontos	Entradas			Saída
A	-1	-1	1	-1
B	-1	1	-1	1
C	1	-1	-1	1
D	1	1	1	-1

*Problema
Linearmente
Separável*



UMA OBSERVAÇÃO

- Redes Neurais de múltiplas camadas só oferecem vantagens sobre as de uma única camada se existir uma função de ativação não-linear entre as camadas.

Camada Escondida: $y_1 = x_0 W_1$

$$x_1 = k_1 y_1$$

Camada de Saída: $x_2 = k_2 y_2 = k_2 (x_1 W_2)$

$$= k_2 ((k_1 y_1) W_2)$$

$$= k_2 ((k_1 x_0 W_1) W_2)$$

$$= k_2 k_1 (x_0 W_1) W_2$$

$$= K x_0 (W_1 W_2)$$

$$= K x_0 W$$

Equivalente a uma única camada

MULTI-LAYER PERCEPTRON

- Redes de apenas uma camada só representam funções linearmente separáveis
- Redes de múltiplas camadas solucionam essa restrição
- O desenvolvimento do algoritmo Back-Propagation foi um dos motivos para o ressurgimento da área de redes neurais