




Universidade Federal do Espírito Santo  
Centro de Ciências Agrárias – CCENS UFES  
Departamento de Computação



# Máquina Linear

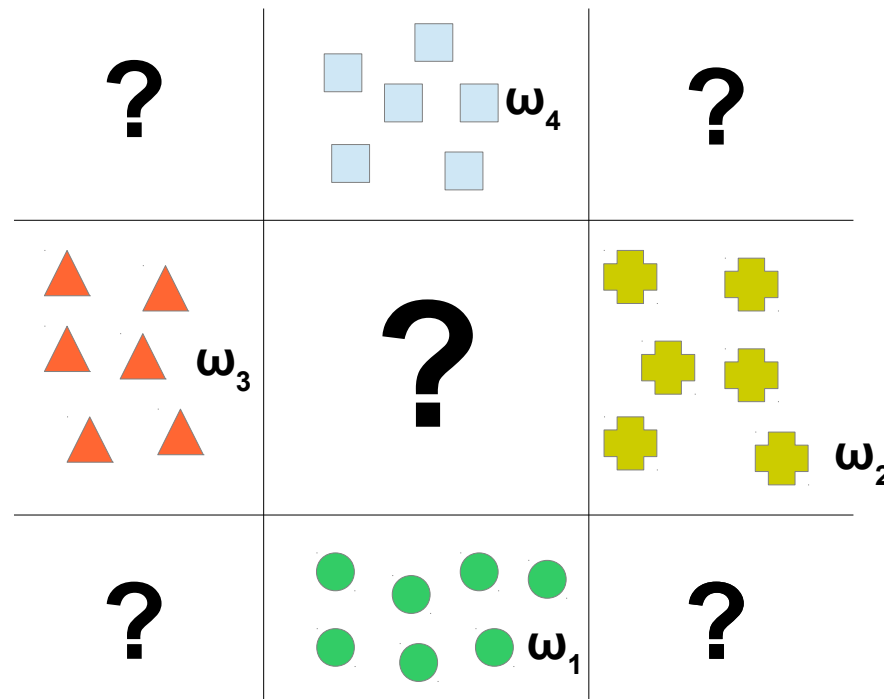
## **Redes Neurais Artificiais**

Site: <http://jeiks.net>

E-mail: [jacsonrcsilva@gmail.com](mailto:jacsonrcsilva@gmail.com)


# Máquina Linear

- Caso multi-classes:  $c$  classes  $\omega_1, \dots, \omega_c$ .
  - Para cada classe  $\omega_i$ ,  
deve-se agrupar todos os padrões  $\{\phi^{(k)}\}$ ,  $1 \leq k \leq n$   
com  $\phi^{(k)} \notin \omega_i$  em uma classe “não- $\omega_i$ ” e  
gerar  $c-1$  planos que separam  $\omega_i$  de “não- $\omega_i$ ”,  $i=1, \dots, c$ .
  - Problema:  
existirão regiões ambíguas, sem classes definidas (“?”)



# Máquina Linear

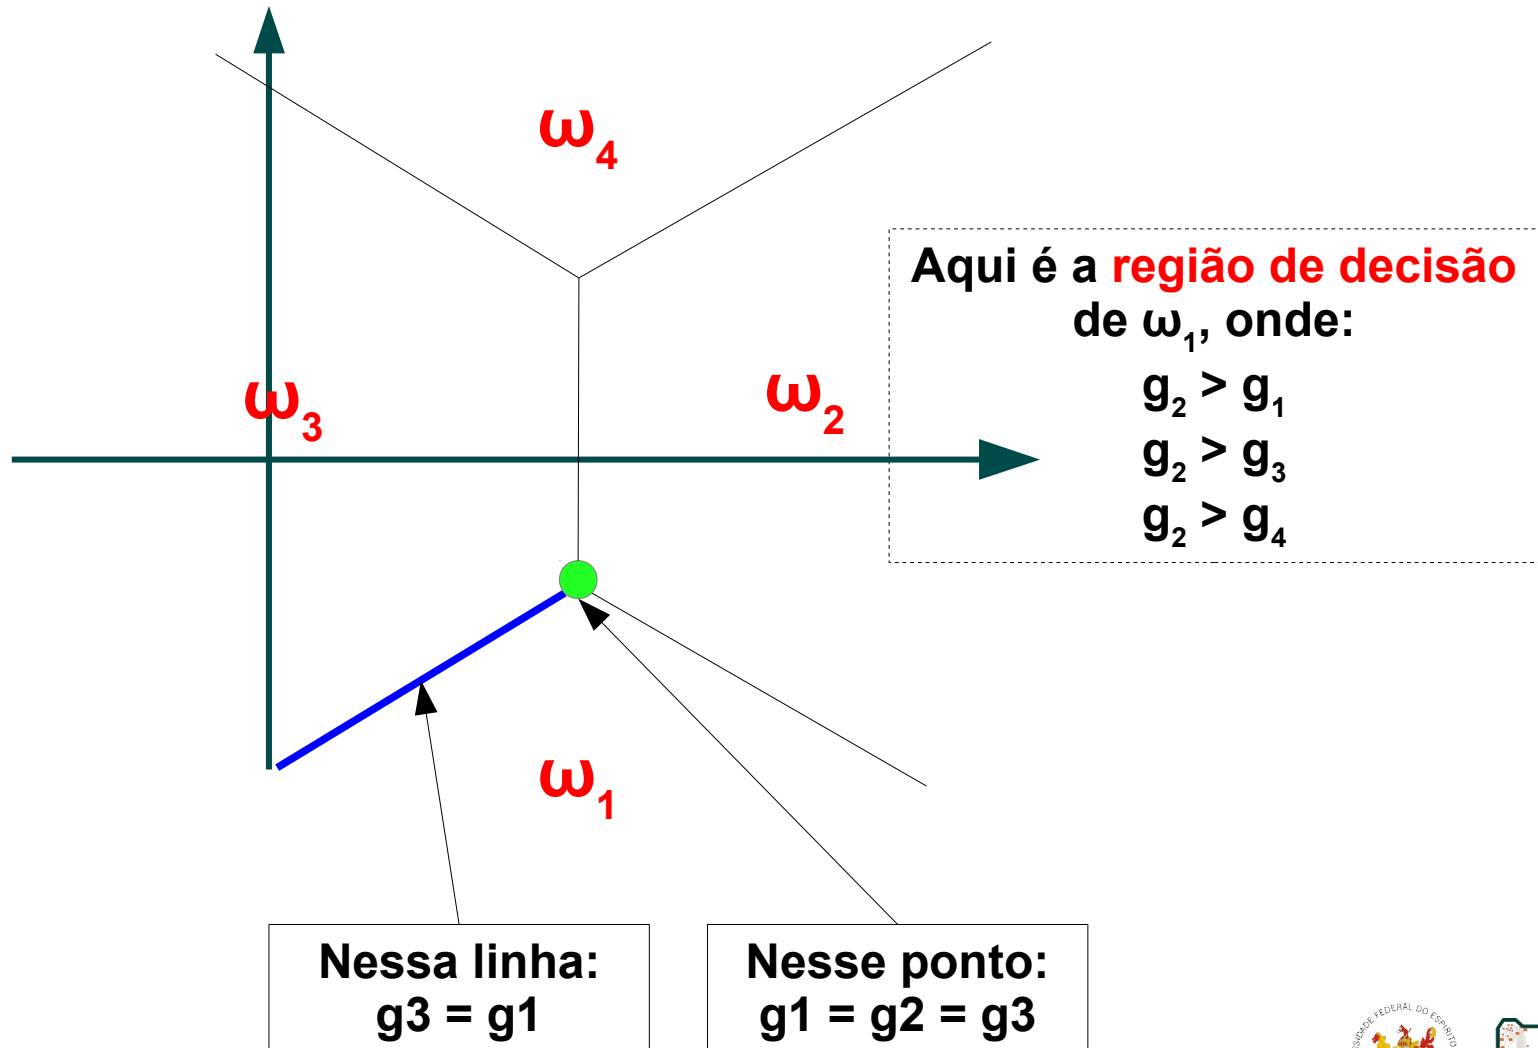
- A solução para isso é construir uma Máquina Linear.
- Suas características:
  - Não possui função de ativação;
  - Possui saída contínua, não sendo a saída de sinal.
  - Não tem ambiguidades, pois a maior saída corresponde a classe selecionada.
  - Ou seja, o neurônio com maior resultado representa a classe.



# Máquina Linear

$g$  é a função discriminativa

$$g_i(\underline{x}; \underline{w}_i, b_i) = \underline{w}_i \cdot \underline{x} + b_i, \quad i=1, \dots, c \in \mathbb{R}$$



# Máquina Linear

- Se  $g_i > g_j$ ,  $i \in \{1, \dots, c\}$ ,  $j = \{1, \dots, c\} \setminus i \Rightarrow \underline{x} \in \omega_i$ .
- Cada classe  $\omega_i$  tem vetor de peso próprio:

$$\underline{w}_i = (w_{i0}, w_{i1}, \dots, w_{id})^T.$$

- Pode ser feito o agrupamento dos pesos  $\underline{w}_i$  como colunas de uma matriz:


$$W_{(d+1) \times c} = (\underline{w}_1 \quad \underline{w}_2 \quad \underline{w}_3 \quad \dots \quad \underline{w}_c) = \begin{pmatrix} w_{10} & & & & w_{c0} \\ w_{11} & \dots & & & w_{c1} \\ \vdots & & & & \vdots \\ w_{1d} & & & & w_{cd} \end{pmatrix}$$

# Cálculo da Máquina Linear

$$g_i(\underline{x}; \underline{w}_i) = \underline{w}_i \cdot \underline{x} = \underline{w}_i^T \underline{x} \in \mathbb{R}$$

$$\underline{g} = \begin{pmatrix} g_1 \\ \vdots \\ g_c \end{pmatrix} \quad \underline{g}(\underline{x}, W) = W^T \underline{x} \in \mathbb{R}^{c \times 1}$$

$$D = \left\{ (\underline{x}^{(k)}, y^{(k)}) \right\}_{k=1}^x$$



$$\underline{x}^{(1)} = \begin{pmatrix} 1 \\ 4 \\ 0,5 \end{pmatrix} \quad y^{(1)} = \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix}$$

$$\underline{x}^{(39)} = \begin{pmatrix} 1 \\ -1 \\ 0,9 \end{pmatrix} \quad y^{(39)} = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \end{pmatrix}$$

# Cálculo da Máquina Linear

- Então, o resultado desejado é:

$$w^T \underline{x}^{(1)} = y^{(1)} \quad \dots \quad w^T \underline{x}^{(\dots)} = y^{(\dots)}$$

- Como obter os valores de  $W$  ?
  - Para obter  $W$ , deve-se isolá-lo. Então:

$$X \cdot W = Y$$

...

# Cálculo da Máquina Linear

- Isolando  $W$ :

$$X \cdot W = Y \mid X^{-1}.$$

$$\Rightarrow X^{-1} X \cdot W = X^{-1} \cdot Y \Leftrightarrow W = X^{-1} \cdot Y$$

- Porém,  $X$  não é uma matriz quadrada e por isso não possui matriz inversa.
- Deve-se então utilizar sua pseudoinversa:

$$X \cdot W = Y \mid X^T.$$

$$X^T X \cdot W = X^T \cdot Y \mid (X^T X)^{-1}.$$

$$(X^T X)^{-1} \cdot (X^T X) \cdot W = (X^T X)^{-1} X^T \cdot Y$$

$$W = X^+ \cdot Y$$

$$X^+ = (X^T X)^{-1} X^T$$



# Exercício

- Com as entradas:  
 $X1 = (-1.0 \ 1.0);$   
 $X2 = ( \ 1.0 \ 3.0);$
- E as saídas:  
 $Y1 = -1;$   
 $Y2 = 1;$
- Calcule os coeficientes de regressão  $W$  através da pseudoinversa da matriz de entradas.
- Antes disso, adicione a coluna do bias nas entradas.