

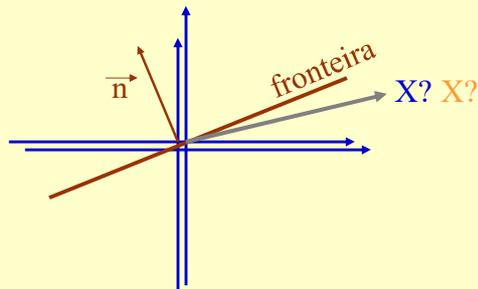
## Entendendo porque MLPs implementam ...

- A) Qualquer fronteira de separação entre duas classes, através de um banco de separadores lineares adequado – temos pois um separador genérico
- B) Qualquer cálculo lógico combinatório / qualquer circuito digital combinatório - aliás, isto ajuda na conjunção genérica dos elementos de separação linear, para a implementação do separador genérico acima mencionado, como visto em sala de aula

Prof. Emilio Del Moral Hernandez

2

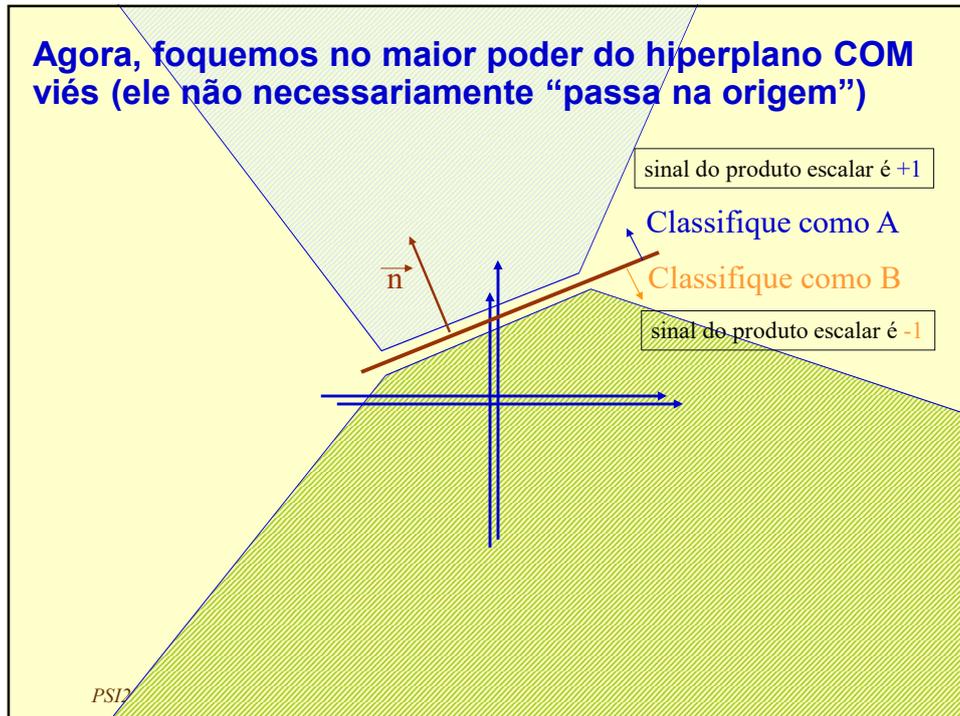
**Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)**



3

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

3



4

*Em lousa...*

*Conciliando “ $(X-PP).N > 0?$ ”*

*com*

*o Perceptron de Rosenblatt:*

$$y = \text{signal}(W.X - \text{viés})$$

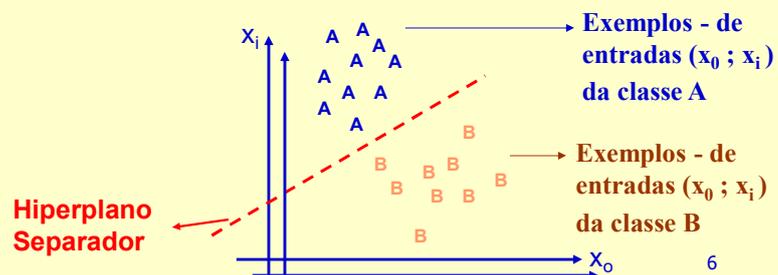
5

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

5

## O Perceptron de Frank Rosenblatt ("o original"): $y = \text{signal}(\sum w_i x_i - \theta)$

- Viabiliza a classificação de padrões com separabilidade linear
- O algoritmo de aprendizado adapta os Ws de forma a encontrar o hiperplano de separação adequado
- Aprendizado por conjunto de treinamento

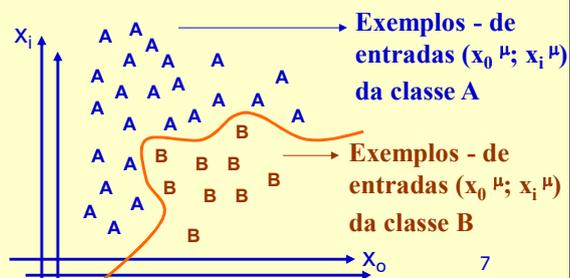


PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

6

## Em cenários mais complicados (e com "exigência" do máximo desempenho) ...

- Não há separabilidade linear (através de hiperplano)
- A linha / ou a hipersuperfície de separação tem que ser algo mais elaborado que um hiperplano

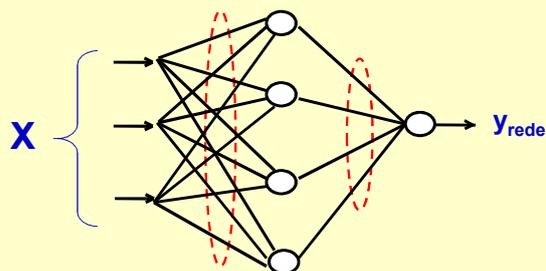


PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

7

## Caso particular de uma rede de uma camada de neurônios escondidos e um neurônio na saída

- lembrete ... Segundo Kolmogorov e Cybenko, esta estrutura simples é suficiente (é um aproximador universal de funções de  $x_1, x_2, x_3, \dots$ )
- Temos nesse caso duas camadas de neurônios e duas camadas de pesos a otimizar durante o treinamento

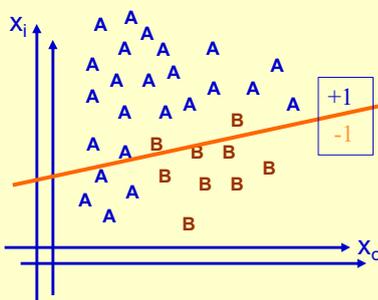


8

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

8

*Qualquer separador linear tem alguma falha,*

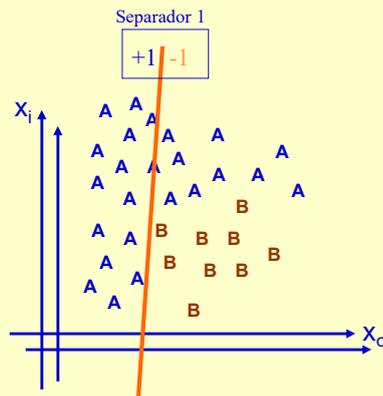


9

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

9

Qualquer separador linear tem alguma falha,

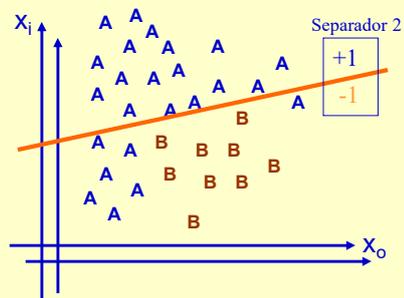


10

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

10

Qualquer separador linear tem alguma falha,

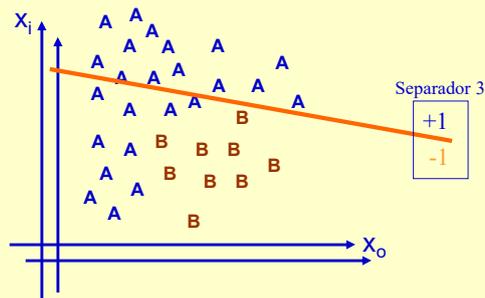


11

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

11

Qualquer separador linear tem alguma falha,

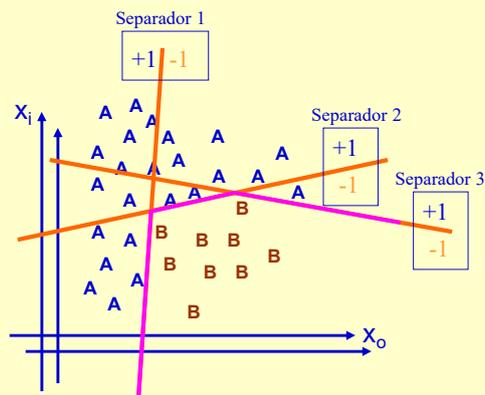


12

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

12

Qualquer separador linear tem alguma falha,



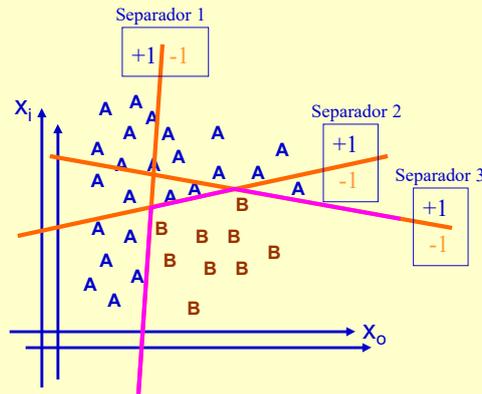
13

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

13

## Cybenko “pelas bordas” ... Conjugando vários separadores lineares para uma fronteira genérica

Cada um dos 3 separadores tem alguma falha,  
Quando considerado isoladamente.



Solução coletiva:

Decisão por A =

A segundo Sep. 1

OR

A segundo Sep. 2

OR

A segundo Sep. 3

Em outros casos, o cálculo lógico pode ser mais complexo, mas ORs, NORs, NOTs, ANDs e NANDs, sempre darão conta do recado! (Karnaugh)

14

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

14

## Discutindo em lousa o neurônio camaleão e como diferentes combinações de seus w's levam a diferentes mapeamentos entre entrada e saída ...

- *Neurônios lineares ... será que podemos especular sobre modelagens variáveis??*

Façamos em lousa:

- *E sobre discriminadores lineares relacionados com o Ex1) ? ...*

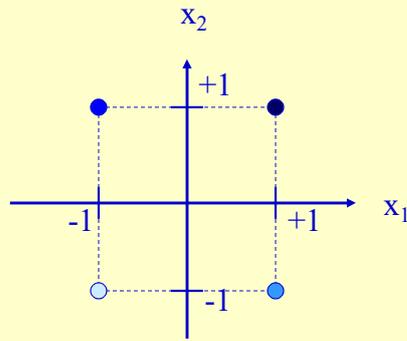
ORs, NORs, NOTs, ANDs e NANDs, de 2 entradas.

- *E sobre algumas portas lógicas que citamos em várias ocasiões? ... análise de como implementá-las (com o uso prático importante em classificação, discutido mais adiante)*

15

**Implementemos algumas portas digitais de 2 entradas,  $x_1$  e  $x_2$ , com o neurônio camaleão ...**

$$y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$$



**Domínio dos X possíveis ... 4 valores:  
(-1,-1), (-1,+1), (+1,-1) e (+1,+1)**

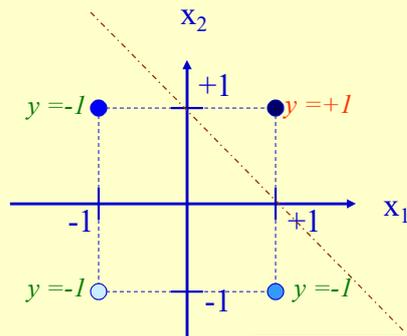
16

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

16

**Implementemos algumas portas digitais de 2 entradas,  $x_1$  e  $x_2$ , com o neurônio camaleão ...**

*façamos uma porta AND:*  $y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$



$$y_{\text{neurônio}} = \text{tgh}(1000 \cdot [1 \cdot x_1 + 1 \cdot x_2 - 1])$$

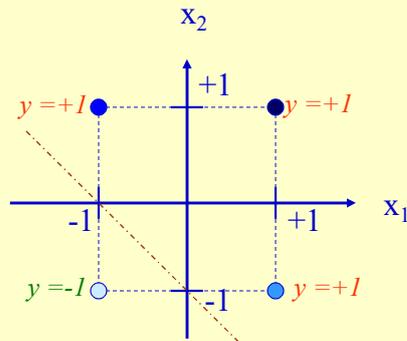
17

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

17

**Implementemos algumas portas digitais de 2 entradas,  $x_1$  e  $x_2$ , com o neurônio camaleão ...**

façamos uma porta OR:  $y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$



$$y_{\text{neurônio}} = \text{tgh}(1000 \cdot [1 \cdot x_1 + 1 \cdot x_2 + 1])$$

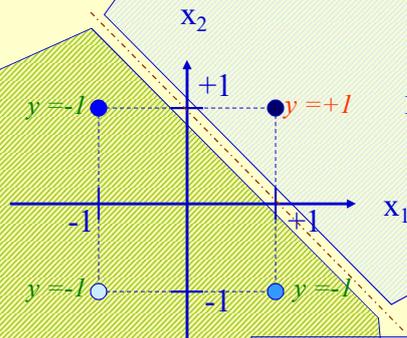
18

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

18

**Digressão .... O que acontece se em vez de entradas digitais tivermos entradas analógicas nas portas lógicas?? !!! ...**

... uma porta AND "semianalógica":  $y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$



ENTRADAS COM VALORES ANALÓGICOS!

$$y_{\text{neurônio}} = \text{tgh}(1000 \cdot [1 \cdot x_1 + 1 \cdot x_2 - 1])$$

19

Moral Hernandez – © 2015-16

19