

Deep Learning

Neurônio MP e Perceptron

Lucas Silveira Kupssinskü

Machine Learning Theory and Applications Laboratory
PUCRS

agosto de 2026

Overview

1. Introdução
2. Neurônio MP
3. Perceptron
4. O problema XOR

Visão Geral

1. Introdução

2. Neurônio MP

3. Perceptron

4. O problema XOR

Bioinspiração

- Quando não sabemos como fazer algo podemos copiar!
- Temos diversos exemplos de inteligência na natureza
- Computação Bioinspirada
 - Algoritmos Genéticos
 - Computação Evolutiva
 - Redes Neurais Artificiais...



Visão Geral

1. Introdução

2. Neurônio MP

3. Perceptron

4. O problema XOR

MP Neuron¹

- Importância histórica por ser o primeiro modelo computacional de um neurônio
- Possibilitou mapear a lógica proposicional em neurônios artificiais
- Possível origem do termo *neurônio artificial* e *redes neurais artificiais*
- Modelo matemático, sem implementação concreta em um dispositivo computacional





Figura: Warren S. McCulloch (à direita) e Walter Pitts (à esquerda).


¹Warren S McCulloch e Walter Pitts. "A logical calculus of the ideas immanent in nervous activity". Em: [The bulletin of mathematical biophysics](#) 5 (1943), pp. 115–133.

MP Neuron – Funcionamento


- Entradas binárias
- Estímulos podem ser:
 - Excitatórios: Ativos quando a entrada é Verdadeira
 - Inibitórios: Ativos quando a entrada é Falsa
- Neurônio dispara quando a quantidade de estímulos excitatórios ultrapassa um limiar θ




MP Neuron – Exemplo como *AND*



MP Neuron – Exemplo como *OR*



MP Neuron – Entrada inibitória X_0 *AND* NOT X_1



Visão Geral

1. Introdução

2. Neurônio MP

3. Perceptron

4. O problema XOR

Perceptron

Frank Rosenblatt² fez algumas modificações no Neurônio MP

$$\hat{y} = \varphi(\mathbf{X}\boldsymbol{\theta}^\top)$$

- Entradas são números reais
- Cada entrada é ponderada por um parâmetro
- Existe um algoritmo de aprendizado para definir $\boldsymbol{\theta}$
- Função de ativação $\varphi(z) = \text{sinal}(z) = \begin{cases} +1, & z \geq 0 \\ -1, & z < 0 \end{cases}$

²F Rosenblatt. "The perceptron: a probabilistic model for information storage and organization in the brain". en. Em: [Psychol. Rev.](#) 65.6 (nov. de 1958), pp. 386–408.

Perceptron

“(...) identities of this sort must be *learned* (...) the number of functional units in the storage system or memory, should be less than the number of forms or memories to be retained.”³

³F Rosenblatt. “The perceptron: a probabilistic model for information storage and organization in the brain”. en. Em: Psychol. Rev. 65.6 (nov. de 1958), pp. 386–408.

Perceptron

- Classificador de imagens
- Resolução 20×20
- 400 fotocélulas capturavam a imagem
- Pesos eram controlados por potenciômetros




Figura: Frank Rosenblatt e o Perceptron


Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Assuma $\mathbf{X}^{(i)}$ com primeira componente igual a 1 (truque do bias)
- 2: Inicialize os pesos $\boldsymbol{\theta}$ aleatoriamente
- 3: **while** existirem observações mal classificadas **do**
- 4: Selecione $\mathbf{X}^{(i)}$ tal que $\text{sinal}(\mathbf{X}^{(i)} \boldsymbol{\theta}^\top) \neq y^{(i)}$
- 5: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + y^{(i)} \mathbf{X}^{(i)}$
- 6: **end while**

Algoritmo de Aprendizado do Perceptron (PLA)



- Vamos ver um exemplo de treinamento com base no conjunto de dados abaixo
- À direita teremos uma representação do espaço de *features* junto da fronteira de decisão

X_1	X_2	y
1	1	1
-1	1	1
1	-1	1
-1	-1	-1



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Assuma $\mathbf{X}^{(i)}$ com primeira componente igual a 1 (truque do bias)
- 2: Inicialize os pesos θ aleatoriamente
- 3: **while** existirem observações mal classificadas
do
- 4: Selecione $\mathbf{X}^{(i)}$ tal que $\text{sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq y^{(i)}$
- 5: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + y^{(i)}\mathbf{X}^{(i)}$
- 6: **end while**





Algoritmo de Aprendizado do Perceptron (PLA)

- ➔ 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
- do**
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**

$$\boldsymbol{\theta}^\top = [-1, -1, -1]$$

$$\mathbf{x}_0 = 1$$





Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- ➔ 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**

$$\boldsymbol{\theta}^\top = [-1, -1, -1]$$

$$\mathbf{x}_0 = 1$$





Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3:  Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**

$$\theta^\top = [-1, -1, -1]$$



$$x_0 = 1$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**



$$\theta^\top = [0, -2, 0] = [-1, -1, -1] + [1, -1, 1]$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- ➔ 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**



$$\theta^\top = [0, -2, 0]$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3:  Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**



$$\theta^\top = [0, -2, 0]$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**



$$\boldsymbol{\theta}^\top = [1, -1, 1] = [0, -2, 0] + [1, 1, 1]$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- ➔ 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**



$$\theta^\top = [1, -1, 1]$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3:  Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**

$$\theta^\top = [1, -1, 1]$$





Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**

$$\boldsymbol{\theta}^\top = [2, 0, 0] = [1, -1, 1] + [1, 1, -1]$$



$$\mathbf{X}_0 = 1$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- ➔ 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**



$$\boldsymbol{\theta}^\top = [2, 0, 0]$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
do
- 3:  Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)} \theta^\top) \neq y^{(i)}$
- 4: Atualize: $\theta \leftarrow \theta + y^{(i)} \mathbf{X}^{(i)}$
- 5: **end while**

$$\theta^\top = [2, 0, 0]$$





Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
 do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**

$$\boldsymbol{\theta}^\top = [1, 1, 1] = [2, 0, 0] + (-1)[1, -1, -1]$$



$$\mathbf{x}_0 = 1$$



Algoritmo de Aprendizado do Perceptron (PLA)

- 1: Inicialize os pesos θ aleatoriamente
- ➔ 2: **while** existirem observações mal classificadas
do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{ sinal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**



$$\boldsymbol{\theta}^\top = [1, 1, 1]$$



Algoritmo de Aprendizado do Perceptron (PLA)


- 1: Inicialize os pesos θ aleatoriamente
- 2: **while** existirem observações mal classificadas
 do
- 3: Selecione $\mathbf{X}^{(i)}$ tal que $\text{senal}(\mathbf{X}^{(i)}\boldsymbol{\theta}^\top) \neq \mathbf{y}^{(i)}$
- 4: Atualize: $\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \mathbf{y}^{(i)}\mathbf{X}^{(i)}$
- 5: **end while**

$$\boldsymbol{\theta}^\top = [1, 1, 1]$$



Considerações sobre o PLA

- Descoberto empiricamente
- Intuição geométrica: produto escalar
 - positivo quando $\alpha < 90^\circ$
 - negativo quando $\alpha > 90^\circ$
- A regra de atualização de θ ajusta o ângulo do vetor de pesos em relação às instâncias
- Sempre converge para problemas linearmente separáveis




Visão Geral

1. Introdução
2. Neurônio MP
3. Perceptron
- 4. O problema XOR**


Limitação do Perceptron

- O Perceptron é um modelo linear (traça um hiperplano como fronteira de decisão)
- Marvin Minsky e Seymour Papert salientaram essa limitação com o problema XOR⁴




⁴Marvin Minsky e Seymour Papert. "Perceptron: an introduction to computational geometry". Em: [The MIT Press, Cambridge, expanded edition 19.88](#) (1969), p. 2.

Vamos observar esses dois Perceptrons




X_1	X_2	y
-1	-1	
-1	1	
1	-1	
1	1	




X_1	X_2	y
-1	-1	
-1	1	
1	-1	
1	1	

Vamos observar esses dois Perceptrons



OR



X_1	X_2	y
-1	-1	-1
-1	1	1
1	-1	1
1	1	1





AND:

X_1	X_2	y
-1	-1	-1
-1	1	-1
1	-1	-1
1	1	1



Resolvendo XOR



Resolvendo XOR



Resolvendo XOR



Resolvendo XOR

- Quando organizamos vários Perceptrons em camadas chamamos de *MultiLayer Perceptron* (MLP)
- PLA não funciona para MLP
- Essa limitação minou o interesse por redes neurais durante anos (Inverno da IA)
- Para treinar um MLP vamos precisar usar retropropagação de erros (*backpropagation*) e descida de gradiente (*gradient descent*)

Leituras Recomendadas

- Capítulo 1: Y.S. Abu-Mostafa, M. Magdon-Ismail e H.T. Lin.
Learning from Data: A Short Course. AMLBook.com, 2012. ISBN: 978-1-60049-006-4
- Capítulo 1: Simon Haykin. Neural networks and learning machines, 3/E. Pearson Education India, 2009

Referências

- [1] Y.S. Abu-Mostafa, M. Magdon-Ismail e H.T. Lin. Learning from Data: A Short Course. AMLBook.com, 2012. ISBN: 978-1-60049-006-4.
- [2] Simon Haykin. Neural networks and learning machines, 3/E. Pearson Education India, 2009.
- [3] Warren S McCulloch e Walter Pitts. “A logical calculus of the ideas immanent in nervous activity”. Em: The bulletin of mathematical biophysics 5 (1943), pp. 115–133.
- [4] Marvin Minsky e Seymour Papert. “Perceptron: an introduction to computational geometry”. Em: The MIT Press, Cambridge, expanded edition 19.88 (1969), p. 2.
- [5] F Rosenblatt. “The perceptron: a probabilistic model for information storage and organization in the brain”. en. Em: Psychol. Rev. 65.6 (nov. de 1958), pp. 386–408.