

# A geometria do perceptron de Rosenblatt

José Jorge de Souza Silva<sup>1</sup>

Instituto Federal de Educação, Ciência e Tecnologia - IFPB (Campus Cajazeiras)

Larissa Soares de Sousa<sup>2</sup>

Instituto Federal de Educação, Ciência e Tecnologia - IFPB (Campus Cajazeiras)

Vinicius Martins Teodosio Rocha<sup>3</sup>

Instituto Federal de Educação, Ciência e Tecnologia - IFPB (Campus Cajazeiras)

**Resumo.** Os algoritmos de Redes Neurais se tornaram praticamente onipresentes na discussões sobre Inteligência Artificial. Apresentamos aqui o Perceptron de Rosenblatt, um dos algoritmos elementares que desencadearam a construção das redes neurais multicamadas, e exploramos a interpretação geométrica que fundamenta o funcionamento do algoritmo.

**Palavras-chave.** Inteligência Artificial, Perceptron, Geometria Analítica

## 1 O perceptron de Rosenblatt

O princípio do perceptron de Rosenblatt, introduzido em [3], tem como objetivo, dado um conjunto finito  $X \subset \mathbb{R}^n$  particionado em dois conjuntos  $X_+$  e  $X_-$ , encontrar um hiperplano  $\pi$  de  $\mathbb{R}^n$  que separa os conjuntos  $X_+$  e  $X_-$ . A existência de tal hiperplano é garantida sempre que os fechos convexos de  $X_+$  e  $X_-$  são disjuntos, veja [2]. Nesse caso diremos que tais conjuntos são *linearmente separáveis*. A partir disso, pode-se fazer previsões quanto a classe de pontos não previamente classificados (isto é, fora de  $X$ ) de acordo com a posição relativa ao hiperplano  $\pi$ . Descrevemos aqui o Perceptron e apresentamos sua interpretação geométrica, bem como o teorema que garante sua convergência.

**O algoritmo** Após uma escolha de ordem para os pontos em  $X$ , denote por  $x^{(i)} = (x_1, x_2, \dots, x_n)$  seu  $i$ -ésimo elemento. Defina  $y^{(i)} = \begin{cases} +1 & \text{se } x^{(i)} \in X_+ \\ -1 & \text{se } x^{(i)} \in X_- \end{cases}$ . Tomamos inicialmente  $w \in \mathbb{R}^n$  e  $b \in \mathbb{R}$  arbitrários, chamados de *vetor de pesos* e *bias* (usualmente tomados ambos nulos). O objetivo é atualizar  $w$  e  $b$  a medida que percorremos o conjunto  $X$  (possivelmente mais de uma vez) de forma que, ao final do processo, se  $X_+$  e  $X_-$  são linearmente separáveis,  $w$  e  $b$  determinam um hiperplano  $\pi_{w,b}$  que separa tais conjuntos. Para a verificação, calculamos, para cada  $i \in \{0, \dots, |X|\}$ , o valor de  $\alpha = x^{(i)} \cdot w + b$ . O sinal de  $\alpha$  determina a posição relativa entre o hiperplano  $\pi_{w,b}$  e o ponto  $x^{(i)}$  (veja a interpretação geométrica abaixo). Comparando o sinal de  $\alpha$  com o valor de  $y^{(i)}$  podemos concluir quando o hiperplano classifica corretamente o ponto  $x^{(i)}$  dado. Se a classificação for correta seguimos para o ponto seguinte  $x^{(i+1)}$ , caso contrário, atualizamos  $w$  e  $b$  da seguinte forma:  $w \leftarrow (w + y^{(i)}x^{(i)})$  e  $b \leftarrow b + y^{(i)}$ . Dessa forma, com o novo vetor de pesos, a classificação se aproxima da real. De fato, se  $x^{(i)} \in X$  foi classificado incorretamente, para o novo peso e o novo bias temos

---

<sup>1</sup>jorge.souza@academico.ifpb.edu.br

<sup>2</sup>larissa.soares@academico.ifpb.edu.br

<sup>3</sup>vinicius.rocha@ifpb.edu.br

$$(w + y^{(i)}x^{(i)}) \cdot x^{(i)} + (b + y^{(i)}) = \alpha + y^{(i)}\|x^{(i)}\|^2 + y^{(i)} \begin{cases} > \alpha & \text{se } y^{(i)} = +1 \\ < \alpha & \text{se } y^{(i)} = -1 \end{cases}$$

O comportamento do Perceptron em cada iteração está resumido em 1. Destacamos que o hiperplano  $\pi_{w,b}$  pode não classificar corretamente todos os pontos após o conjunto  $X$  ser percorrido uma única vez. Em geral, é necessário que esse ciclo — chamado de *época* — seja feito diversas vezes. O Teorema 2.1 fornece uma estimativa para essas repetições.

Tabela 1: Comportamento do perceptron

Classe	sinal( $\alpha y^{(i)}$ )	Classificação	Atualização
$X_+$	$\alpha y^{(i)} \geq 0$	Correta	não ocorre
$X_+$	$\alpha y^{(i)} < 0$	Incorreta	$w \leftarrow (w + y^{(i)}x^{(i)})$ , $b \leftarrow b + y^{(i)}$

## 2 Interpretação geométrica

Dado  $w = (w_1, \dots, w_n) \in \mathbb{R}^n$  e  $b \in \mathbb{R}$ . Definimos o *hiperplano* associado a  $w$  e  $b$ , denotado por  $\pi_{w,b}$ , como o conjunto dos pontos  $x = (x_1, \dots, x_n) \in \mathbb{R}^n$  satisfazendo  $\sum_{i=1}^n w_i x_i + b = 0$ .

Lembremos que podemos classificar a posição relativa entre dois vetores em  $\mathbb{R}^n$ , de acordo com o ângulo  $\theta$  formado entre eles, em três casos:  $\theta < \frac{\pi}{2}$ ,  $\theta = \frac{\pi}{2}$  e  $\frac{\pi}{2} < \theta < \pi$ , para seu produto interno positivo, negativo ou zero, resp. (veja [4]). O sinal de  $\alpha$  calculado no algoritmo fornece portanto a posição relativa entre o ponto  $x^{(i)}$  e o hiperplano  $\pi_{w,b}$ , como ilustrado nas figuras a seguir ( $n = 2$ ).




Figura 1: Inicialização




Figura 2: Quinta atualização




Figura 3: Convergência

A convergência do perceptron é garantida pelo Teorema de Rosenblatt (veja [1, Sec. 1.3]).

**Teorema 2.1** (Teorema da Convergência do Perceptron) Seja  $X = X_+ \cup X_- \subset \mathbb{R}^n$  finito com  $X_+$  e  $X_-$  linearmente separáveis. Então Perceptron de Rosenblatt converge (no sentido de não haver mais atualizações) após uma quantidade  $n_{\max}$  de iterações, onde  $n_{\max}$  é uma constante dependente do comprimento máximo dos vetores em  $X$  e do máximo das margens (distância mínima entre um hiperplano separador de  $X_+$  e  $X_-$  e os pontos de  $X$ ).

## Referências

- [1] Haykin, S. *Neural networks and learning machines*, 3a. edição. Hamilton, Pearson, 1999.
- [2] Hyperplane separation theorem. *Wikipedia*, 2021. Disponível em: [https://en.wikipedia.org/wiki/Hyperplane\\_separation\\_theorem](https://en.wikipedia.org/wiki/Hyperplane_separation_theorem). Acesso em: 27 de abr. de 2021.
- [3] Rosenblatt, F. *The Perceptron - a perceiving and recognizing automaton*(1957) Report 85-460-1. Cornell Aeronautical Laboratory.
- [4] Winterle, P. *Vetores e geometria analitica*, 1a. edição. São Paulo, Pearson Makron Books, 2000.