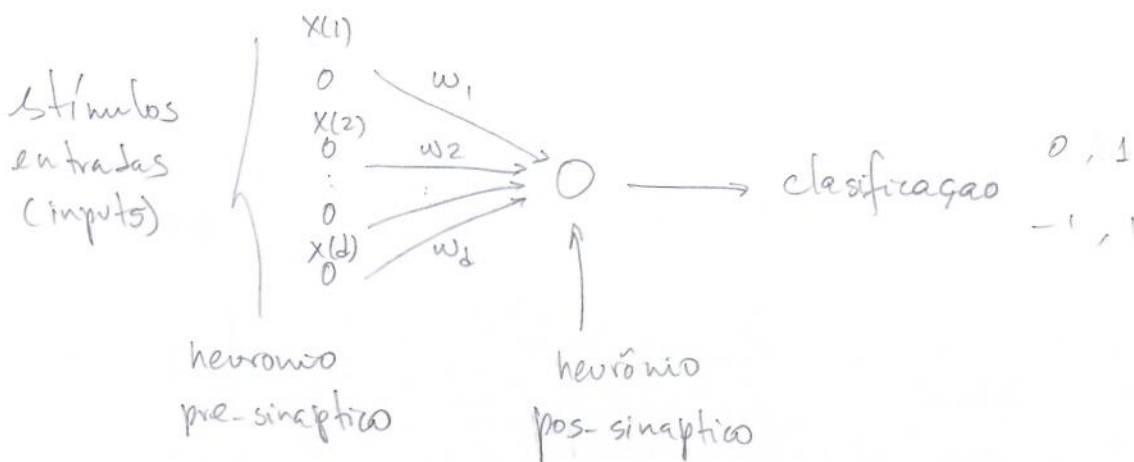


1963 Rosenblatt (Perceptron)

$$X = (x(1), x(2), \dots, x(d)) \quad , \quad x(i) \in \mathbb{R}$$

w_1, w_2, \dots, w_d pesos sinápticos

Potencial de membrana

$$u = \sum_{i=1}^d w_i x(i) \quad , \quad \text{si } u > \theta \text{ dispara}$$

Vamos re-escrever:

$$u - \theta = z \quad , \quad \text{então dispara se } z > 0 \Rightarrow Y = \mathbb{1}_{\{z > 0\}}$$



$$z = w_0 + \underbrace{\sum_{i=1}^d w_i x(i)}_u$$

Classificador $Y = \mathbb{1}_{\{z > 0\}}$, $z = w_0 + \sum_{i=1}^d w_i x(i)$

"Regressão linear"

Regressor linear.

função: $X \mapsto \text{no. real}$



$X = (x(1), \dots, x(d))$ intermediárias

Dada uma amostra de treino $(x_1, y_1), \dots, (x_n, y_n)$ iid onde $x_i = (x_i(1), \dots, x_i(d))$ com $x_i(j) \in \mathbb{R}$ e $y_i \in \{0, 1\}$

o objetivo da rede neural é calibrar automaticamente para fazer a classificação.

↑
escolher os "pesos sinápticos".

Regressão linear:

$\mathcal{X} = \mathbb{R}^d$ X : vector aleatorio
 $\mathcal{Y} = \mathbb{R}$ Y : variavel aleatoria

definidas no mesmo espaço de probabilidade isto é a distribuição conjunta de X e Y está bem definida.

Seja $f: \mathcal{X} \rightarrow \mathcal{Y}$

contínua por pedaço "medível", isto é posso calcular a probabilidade de eventos do tipo $\{x \in \mathcal{X} : f(x) < r\}$.

Risco medio quadrático de f :

$$R(f) = E[(f(X) - Y)^2]$$

Dada uma amostra

$(x_1, y_1), \dots, (x_n, y_n)$ iid com mesma

lei (X, Y)

Desconhecido!
na prática.

$$R_n(f) = \frac{1}{n} \sum_{i=1}^n (f(x_i) - y_i)^2$$

risco empírico.

Classificação


$$\mathbb{1}_{\{w_0 + \sum_{i=1}^d w_i x(i) > 0\}} = H\left(w_0 + \sum_{i=1}^d w_i x(i)\right)$$



H (Heaviside)

Classificação mais suave

$$\sigma(u) = \frac{1}{1 + e^{-u}}$$



$\sigma(u) \rightarrow \begin{cases} 1, & \text{quando } u \rightarrow +\infty \\ 0, & \text{quando } u \rightarrow -\infty \end{cases}$

$$\sigma(u) = 1 - \sigma(-u)$$

$$y \in \{-1, 1\}$$

$$P(Y=y | X) = \frac{1}{1 + e^{-y u(X)}} \quad \text{onde } u(X) = w_0 + \sum_{i=1}^d w_i x(i)$$

$P(Y=1 | X)$ é função crescente de $u(X)$

$P(Y=-1 | X)$ é função decrescente de $u(X)$.

Dada uma amostra $(X_1, Y_1), \dots, (X_n, Y_n)$ iid com

$$X_m \in \mathcal{X} = \mathbb{R}^d, \quad Y_m \in \mathcal{Y} = \{-1, 1\} \quad \text{com}$$

$$P(Y_m = 1 | X) = \frac{1}{1 + e^{-u(X)}}$$

Calcular a verossimilhança da amostra.

6

$$\log P((x_1, y_1), \dots, (x_n, y_n) | x_1, \dots, x_n)$$

$$\log \prod_{i=1}^n P(x_i, y_i) = \log \prod_{i=1}^n \frac{1}{1 + e^{-y_i u(x_i)}}$$

$$= \sum_{i=1}^n [\log(1) - \log(1 + e^{-y_i u(x_i)})]$$

$$= \sum_{i=1}^n \log(1 - e^{-y_i u(x_i)}) = \sum_{i=1}^n \log(1 - e^{-y_i (a + b x_i)})$$

$$u(x) = a + b x$$

↑ ↑
 w_0 w_1

Pergunta: Calcular \hat{a} e \hat{b} que maximizam a verossimilhança da amostra.