

Neuronové sítě

Spojité neuronové sítě

Příprava dat

Data $\mathbf{X} \in \mathbb{R}^{m \times n}$ je vhodné před spuštěním perceptronu

- standardizovat rozpětím

$$\mathbf{x}_{ij}^{\text{new}} = \frac{\mathbf{X}_{ij} - m_j}{M_j - m_j} \in \langle 0, 1 \rangle$$

$$m_j = \min(\mathbf{X}_{kj}), M_j = \max(\mathbf{X}_{kj})$$

- standardizovat směrodatnou odchylkou

$$\mathbf{x}_{ij}^{\text{new}} = \frac{\mathbf{X}_{ij} - E(\mathbf{X}_{kj})}{S(\mathbf{X}_{kj})} \in N(0, 1)$$

$$E(\mathbf{X}_{kj}) = \frac{1}{m} \sum_{k=1}^m \mathbf{X}_{kj}$$

$$S^2(\mathbf{X}_{kj}) = \frac{1}{m-1} \sum_{k=1}^m (\mathbf{X}_{kj} - E(\mathbf{X}_{kj}))^2$$

Lineárně neseparabilní data

Řešení:


- Síť s jednou či dvěma skrytými vrstvami.
- Rozšíření (vyrovnání) příznakového prostoru

kvadratické


$$x_1, \dots, x_n, x_1^2, x_1 x_2, x_1 x_3, \dots, x_{n-1} x_n, x_n^2$$

kubické


$$x_1, \dots, x_n, x_1^2, x_1 x_2, \dots, x_n^2, x_1^3, x_1^2 x_2, \dots, x_n^3$$



Spojité neuronové sítě





dvouvrstvá síť





třívrstvá síť

Aktivační funkce





$$f(s) = \text{thg}(s)$$



$$s = \sum_{k=0}^n w_k x_k$$



$$f(s) = \frac{s}{1+|s|}$$



$$f(s) = \text{sign}(s) \cdot \ln(1+|s|)$$



$$f(s) = s$$

Klasické umělé neuronové sítě

Dvouvrstvé

vstup \rightarrow sign bipolární perceptron

vstup \rightarrow lin lineární síť

vstup \rightarrow tgh hladký perceptron



Třívrstvé

vstup \rightarrow sign \rightarrow sign síť bipolárních perceptronů

vstup \rightarrow tgh \rightarrow tgh MLP – vícevrstvý perceptron
(Multi Layer Perceptron)

vstup \rightarrow tgh \rightarrow lin MLL – síť s lineárním výstupem



Radial Basis Function network



$$f(s) = e^{-s^2}$$

$$s = \frac{\|\bar{x} - \bar{w}\|}{\sigma}$$

$$\left(\sigma = \frac{1}{2}\right)$$



$$f(s) = e^{-s^2}$$


$$s = \frac{\|\bar{x} - \bar{w}\|}{2}$$

Třivrstvá síť

vstup → gauss → lin

RBF – Radial Basis Function network

Radial Basis Function network



Gradientní metoda

počáteční bod $\bar{x} = (x_1, x_2)$

$$x_1^{\text{new}} = x_1 - \lambda \frac{\partial f}{\partial x_1} \quad \lambda > 0$$

$$x_2^{\text{new}} = x_2 - \lambda \frac{\partial f}{\partial x_2}$$

nevýhody

- pro malé λ je pomalá
- pro velké λ kmitá (přeskakuje řešení)
- nemusíme najít globální minimum

obecný zápis

$$\bar{x}_0 \in \mathbb{R}^n, \lambda > 0$$

$$\bar{x}_{j+1} = \bar{x}_j - \lambda \left(\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right)$$

Stochastická gradientní metoda

$$f(x) = f_1(x) + f_2(x)$$

- minimalizace f_1 a f_2 se stejnou pravděpodobností $\frac{1}{2}$
- minimalizace průměrné hodnoty $\bar{f}(x)$

$$f(x) = 2 \frac{f_1(x) + f_2(x)}{2} = 2\bar{f}(x) = \min$$

obecně

$$f(\bar{x}) = f_1(\bar{x}) + \dots + f_m(\bar{x})$$


$$f(\bar{x}) = \sum_{k=1}^m f_k(\bar{x}) = m\bar{f}(\bar{x}) = \min$$

Stochastická gradientní metoda

Algoritmus

- $\bar{x}_0 \in \mathbb{R}^n$, $\lambda_j > 0$, $f(\bar{x}) = \sum_{k=1}^m f_k(\bar{x})$
- $k \in \hat{m}$ náhodné
$$\bar{x}_{j+1} = \bar{x}_j - \lambda_j \left(\frac{\partial f_k}{\partial x_1}, \dots, \frac{\partial f_k}{\partial x_n} \right)$$
- $\lambda_j > 0$, $\sum_{j=0}^{\infty} \lambda_j = \infty$, $\sum_{j=0}^{\infty} \lambda_j^2 < \infty$ (Robins-Moore, 1951)
$$\Rightarrow \lambda_j = \frac{\lambda_0}{1+j}$$

Delta učení



- $y = f(\bar{x}, \bar{w})$

- $y_k = f(\bar{x}_k, \bar{w})$

- $\Delta_k = y_k^* - y_k$

- $p_k(\bar{w}) = \frac{1}{2} \Delta_k^2$

- $P(\bar{w}) = \sum_{k=1}^m p_k(\bar{w}) = \min$

$$P(\bar{w}) = \sum_{k=1}^m p_k(\bar{w}) = \sum_{k=1}^m \frac{1}{2} \Delta_k^2 =$$

$$= \sum_{k=1}^m \frac{1}{2} (y_k^* - y_k)^2 = \sum_{k=1}^m \frac{1}{2} (y_k^* - f(\bar{x}_k, \bar{w}))^2 = \min$$

Delta učení

$$P(\bar{\mathbf{w}}) = \sum_{k=1}^m p_k(\bar{\mathbf{w}}) = \min$$

- $\bar{\mathbf{w}}_0 \in \mathbb{R}^{n+1}$, $\lambda_j > 0$

- $k \in \hat{m}$ náhodné

$$\bar{\mathbf{w}}_{j+1} = \bar{\mathbf{w}}_j - \lambda_j \left(\frac{\partial p_k}{\partial w_0}, \dots, \frac{\partial p_k}{\partial w_n} \right)$$

$$\frac{\partial p_k}{\partial w_i} = \frac{1}{2} \cdot 2 (y_k^* - f(\bar{\mathbf{x}}_k, \bar{\mathbf{w}})) \cdot (-1) \frac{\partial f(\bar{\mathbf{x}}_k, \bar{\mathbf{w}})}{\partial w_i} = -\Delta_k \frac{\partial f}{\partial w_i}, \quad i = 0, 1, \dots, n$$

- $\bar{\mathbf{w}}_{j+1} = \bar{\mathbf{w}}_j + \lambda_j \Delta_k \left(\frac{\partial f_k}{\partial w_0}, \dots, \frac{\partial f_k}{\partial w_n} \right)$


Delta učení

Algoritmus


- $\bar{w}_0 \in \mathbb{R}^{n+1}$ (malé), $\lambda_0 > 0$
- náhodná volba k . vzoru, $\lambda_j = \frac{\lambda_0}{1+j}$
- výpočet y_k a Δ_k
- výpočet citlivosti sítě na váhy
- adaptace vah

Učení hladkého perceptronu

- $y = f(\bar{x}, \bar{w}) = \text{tgh} \left(\sum_{i=0}^n w_i x_i \right)$
- $\frac{\partial \text{tgh} \left(\sum_{i=0}^n w_i x_i \right)}{\partial w_i} = (1 - y^2) x_i$
- $\bar{w}_{j+1} = \bar{w}_j + \lambda_j \Delta_k (1 - y_k^2) \bar{x}_k$



Backpropagation



- vezmeme náhodně vzor $\bar{p} = (\bar{x}, \bar{y}^*)$

- pro výstupy $y_s, s = 1, \dots, p$:

$$\bar{w}^{\text{new}} = \bar{w} + \lambda \underbrace{\Delta_s (1 - y_s^2)}_{d_s} \bar{h}, \quad \Delta_s = y_s^* - y_s, \quad (h_0 = 1)$$

- pro skryté neurony $h_r, r = 1, \dots, H$:

$$\bar{v}^{\text{new}} = \bar{v} + \lambda \delta_r (1 - h_r^2) \bar{x}, \quad \delta_r = \sum_{i=1}^p d_i w_{ri}$$