


3.2. Lineární síť (Madaline, Madalina)

! je tvořena jednou vrstvou neuronů s lineární aktivací funkcí



! Pro výstup j -tého neuronu platí: $y_j = \lambda \left(\sum_{i=1}^n w_{ji} x_i + b_j \right)$

8 je strmost aktivační funkce (většinou se volí $\delta=1$)

$\mathbf{x} = [x_1, x_2, \dots, x_j, \dots, x_n]^T$... vstupní vektor

$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \dots & \dots & \dots & \dots \\ w_{m1} & w_{m2} & \dots & w_{mn} \end{bmatrix}$... váhová matice

$\mathbf{b} = [b_1, b_2, \dots, b_j, \dots, b_m]^T$... prahový vektor

$\mathbf{y} = [y_1, y_2, \dots, y_j, \dots, y_m]^T$... výstupní vektor

Poznámky:

1. Výstup každého neuronu je určen lineární kombinací vstupů → ADaptivní Lineární NEuron (Adaline). Lineární sítě se pak označují Madaline (Many ADALINEs).
2. Jakoukoli vícevrstvou lineární sít' lze nahradit ekvivalentní jednovrstvou lineární sítí.

Trénování sítě pomocí učení s učitelem

- ! předpokládá se, že máme k dispozici trénovací množinu, tj. množinu P dvojic [vstup x_p , požadovaný výstup u_p]
- ! chceme nastavit váhy a prahy sítě tak, aby výstup sítě byl pro všechny vstupní vektory z trénovací množiny správný, tzn. aby celková chyba definovaná vztahem

$$E = \sum_{p=1}^P \varepsilon_p = \frac{1}{2} \sum_{p=1}^P \| \mathbf{u}_p - \mathbf{y}_p \|^2$$

byla minimální. Přitom

$\mathbf{y}_p = \lambda (\mathbf{W} \cdot \mathbf{x}_p + \mathbf{b})$ je skutečný výstup sítě pro vstup \mathbf{x}_p ,

\mathbf{u}_p je požadovaný výstup sítě pro vstup \mathbf{x}_p ,

P je počet trénovacích dvojic,

g_p je chyba od p -té trénovací dvojice.

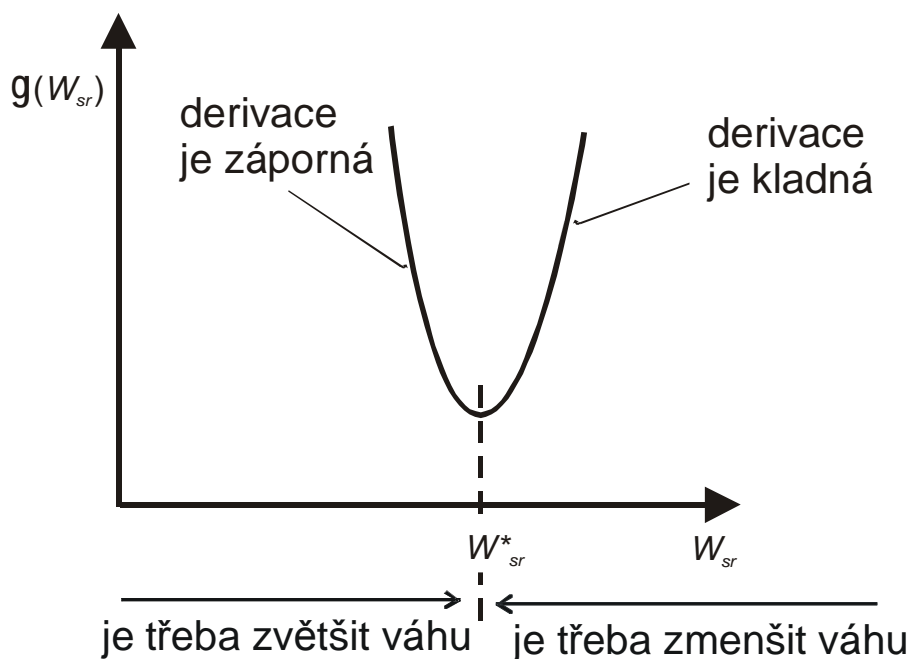
Odvození vztahů pro trénování lineární sítě

- ! Pro konkrétní trénovací dvojici, např. $[\mathbf{x}, \mathbf{u}]$ definujeme dílčí chybu ve tvaru

$$\varepsilon = \frac{1}{2} \|\mathbf{u} - \mathbf{y}\|^2,$$

kde $\mathbf{y} = \lambda(\mathbf{W} \cdot \mathbf{x} + \mathbf{b})$, a chceme změnit váhovou matici a prahový vektor tak, aby se chyba g zmenšila.

- ! Ilustrace závislosti chyby g na jedné konkrétní váze (např. W_{sr})



- ! Záporný gradient určuje směr největšího poklesu, kladný gradient směr největšího růstu. Tzn. že parametry sítě (tj. Váhy a prahy) je rozumné měnit zápornému gradientu

chybové funkce, tj.

$$w_{sr}(k+1) = w_{sr}(k) - c \frac{\partial \varepsilon}{\partial w_{sr}},$$

$C > 0$ je konstanta učení

! Protože

$$\varepsilon = \frac{1}{2} \|\mathbf{u} - \mathbf{y}\|^2 = \frac{1}{2} \sum_{j=1}^m (u_j - y_j)^2 = \frac{1}{2} \sum_{j=1}^m \left[u_j - \lambda \left(\sum_{i=1}^n w_{ji} x_i + b_i \right) \right]^2,$$

Ize odvodit, že $\frac{\partial \varepsilon}{\partial w_{sr}} = -\lambda (u_s - y_s) x_r$. Pak tedy

$$w_{sr}(k+1) = w_{sr}(k) + c \lambda (u_s - y_s) x_r$$

a analogicky

$$b_s(k+1) = b_s(k) + c \lambda (u_s - y_s).$$

Maticově

$$\mathbf{W}(k+1) = \mathbf{W}(k) + c \lambda (\mathbf{u} - \mathbf{y}) \cdot \mathbf{x}^T$$
$$\mathbf{b}(k+1) = \mathbf{b}(k) + c \lambda (\mathbf{u} - \mathbf{y})$$

... Widrow - Hoffovo pravidlo
pro trénování lineárních sítí
(LMS pravidlo ... Least
Mean Square)

Algoritmus trénování lineární sítě

Vstupní podmínky:

Je dána trénovací množina, tj. P dvojic $[\mathbf{x}_p, \mathbf{u}_p]$, $p=1,2,\dots,P$.

\mathbf{x}_p je vstupní vektor dimenze n

\mathbf{u}_p je požadovaný výstupní vektor dimenze m pro vstupní vektor \mathbf{x}_p

Dále je dána strmost aktivační funkce σ .

1. krok - Inicializace

! Váhou matici $\mathbf{W}(1)$ typu $m \times n$ a prahový vektor $\mathbf{b}(1)$ dimenze m inicializujeme malými náhodnými čísly.

! Zvolíme $c > 0$, $E_{\max} \geq 0$ a $TC_{\max} > 0$.

! Stanovíme $k=1$, $p=1$, $q=0$ a $E(0) = 0$.

E_{\max} je maximální povolená chyba, na kterou nebo pod kterou se chceme dostat

TC_{\max} je maximální počet trénovacích cyklů, ve kterých chceme síť natrénovat

q je počet trénovacích cyklů

E je chyba způsobená nesprávnou činností sítě během jednoho trénovacího cyklu

c je konstanta učení

2. krok - Výpočet výstupu

$$\mathbf{x}(k) = \mathbf{x}_p$$

$$\mathbf{y}(k) = \mathbf{W}(k) \mathbf{x}(k) + \mathbf{b}(k)$$

$$\mathbf{u}(k) = \mathbf{u}_p$$

3. krok - Výpočet chyby

$$E(k) = E(k-1) + \frac{1}{2} (\mathbf{u}(k) - \mathbf{y}(k))^T (\mathbf{u}(k) - \mathbf{y}(k))$$

4. krok - Modifikace vah a prahů

$$\mathbf{W}(k+1) = \mathbf{W}(k) + c \lambda (\mathbf{u}(k) - \mathbf{y}(k)) \cdot \mathbf{x}^T(k)$$

$$\mathbf{b}(k+1) = \mathbf{b}(k) + c \lambda (\mathbf{u}(k) - \mathbf{y}(k))$$

5. krok - Konec trénovacího cyklu

Je-li $p < P$ potom $p = p + 1$

$$k = k + 1$$

jdi na krok 2)

jinak $q = q + 1$

jdi na krok 6)

6. krok - Konec trénování

$$E_c(q) = E(k)$$

Je-li $E_c(q) \# E_{\max}$

potom KONEC (sít' se podařilo natrénovat)

jinak je-li $q > TC_{\max}$ potom K O N E C (s í t' s e
nepodařilo natrénovat)

jinak $E(0) = 0$

$$k = k + 1$$

$$p = 1$$

jdi na krok 2)

Poznámky k trénování lineární sítě:

- ! Volba konstanty učení: Malá hodnota konstanty učení zpomaluje proces učení, pro velkou hodnotu hrozí nebezpečí nestability procesu učení.
- ! Vliv strmosti aktivační funkce: Má na proces učení stejný vliv jako konstanta učení → konstantu učení je třeba volit s ohledem na strmost aktivační funkce.
- ! Podobně jako u sítě s binární bipolární aktivační funkcí lze pro výpočet celkové chyby E_c využít též vztah

$$E = \frac{1}{2PM} \sum_{p=1}^P \|\mathbf{u}_p - \mathbf{y}_p\|^2 = \frac{1}{2PM} \sum_{p=1}^P \sum_{m=1}^M (u_{pm} - y_{pm})^2,$$

kde M je počet výstupů sítě, P je počet trénovacích dvojic v trénovací množině a u_{pm} resp. y_{pm} je m -tá složka vektoru \mathbf{u}_p , resp. \mathbf{y}_p . Takto definovaná chyba umožňuje lépe posoudit činnost sítí s různým počtem výstupů a různě velkou trénovací množinou.

- ! Pokud počet trénovacích dvojic trénovací množiny je o jednu větší, než je dimenze vstupního vektoru (tj. $P=n+1$, kde n je počet vstupů sítě), a vstupní vektory trénovací množiny jsou lineárně nezávislé, existuje jediné nastavení vah a prahů s minimální chybou a toto nastavení lze najít řešením soustavy lineárních algebraických rovnic, tzn. bez učení.