

Alkalmazott mesterséges intelligencia (AMI)

<http://www.mit.bme.hu/oktatas/targyak/vimibb01>

10. ea. (2023 ősz)

Optimalizálás (tanítás) gradiensmódszerrel

Gyakorlás!

Előadó: Pataki Béla

a fóliák

Dobrowiecki Tadeusz és

Hullám Gábor anyagainak

felhasználásával készültek



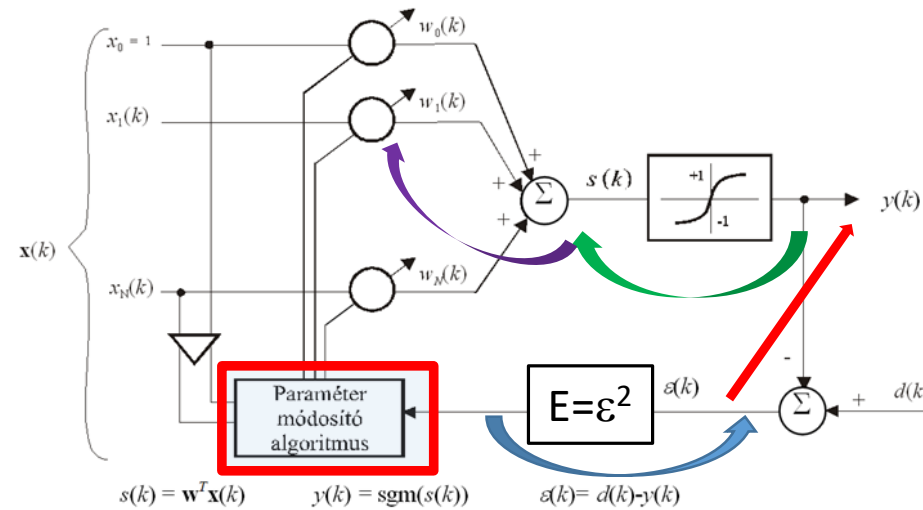
<https://www.esrcheck.com/2023/06/05/artificial-intelligence-ai-experts-sign-statement-on-ai-risk/>

BME I.E. 414, 463-26-79

pataki@mit.bme.hu,

<http://www.mit.bme.hu/general/staff/pataki>

Egyetlen nemlineáris – szigmoid – neuron tanítása gradiensmódszerrel:



$$\mathbf{w} \leftarrow \mathbf{w} - \alpha \frac{\partial E}{\partial \mathbf{w}} \text{ ahol}$$

$$\mathbf{w} = \mathbf{w} - \alpha \cdot \frac{\partial E}{\partial \mathbf{w}}$$

kifejtve a gradienst (láncszabály!)

$$\frac{\partial E}{\partial \mathbf{w}} = \frac{dE}{d\varepsilon} \cdot \frac{d\varepsilon}{dy} \cdot \frac{dy}{ds} \cdot \frac{\partial s}{\partial \mathbf{w}}$$

$$E = \varepsilon^2 = (d - y)^2$$

$$\varepsilon = d - y$$

$$y = f(s) = \text{szigm}(s)$$

$$s = \mathbf{w}^T \mathbf{x}$$

$$\frac{\partial E}{\partial \mathbf{w}} = \frac{dE}{d\varepsilon} \cdot \frac{d\varepsilon}{dy} \cdot \frac{dy}{ds} \cdot \frac{\partial s}{\partial \mathbf{w}} = \frac{dE}{d\varepsilon} \cdot \frac{d\varepsilon}{dy} \cdot \frac{d \text{szigm}(s)}{ds} \cdot \frac{\partial s}{\partial \mathbf{w}}$$

$$2\varepsilon$$

$$-1$$

$$(1 - y) \cdot y$$

$$\mathbf{x}$$


$$\begin{aligned} \mathbf{w}_{új} &= \mathbf{w}_{régi} - \alpha \cdot \frac{\partial E}{\partial \mathbf{w}} = \mathbf{w}_{régi} - 2 \cdot \alpha \cdot \varepsilon \cdot (-1) \cdot (1 - y) \cdot y \cdot \mathbf{x} \\ &= \mathbf{w}_{régi} + 2 \cdot \alpha \cdot \varepsilon \cdot (1 - y) \cdot y \cdot \mathbf{x} \end{aligned}$$

Ha másféle nemlinearitást használunk? A láncszabály „marad”, de a szigmoid deriváltjának helyére az új nemlinearitás deriváltja kerül!

$$\mathbf{w}_{új} = \mathbf{w}_{régi} - \alpha \cdot \frac{\partial E}{\partial \mathbf{w}} = \mathbf{w}_{régi} - \alpha \cdot 2 \cdot \varepsilon \cdot (-1) \cdot (1 - y) \cdot y \cdot \mathbf{x}$$

Ez volt a szigmoid deriváltja, ezt kell lecserélni az újra!

Például cseréljük le ReLU-ra!

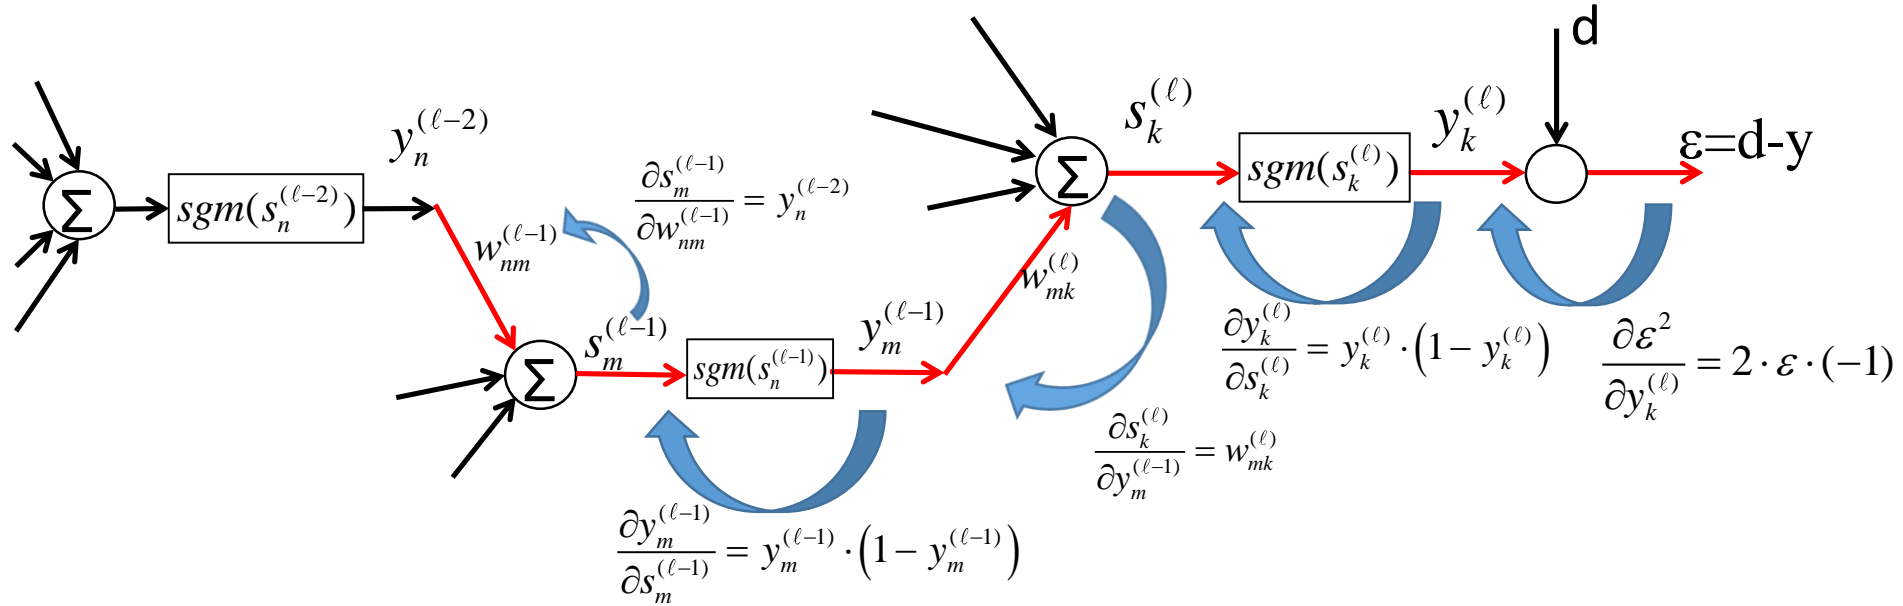


Legyen erre a tanítóminta-bemenetre a kívánt válasz $d= +1$. Ha w_{21} -et gradiensmódszerrel tanítjuk, akkor mekkora lesz a tanításnál használt gradiens?

Tanítás: hibavisszaterjesztés (backpropagation) algoritmus

A deriválás láncszabálya:

$$\frac{\partial \varepsilon^2}{\partial w_{nm}^{(\ell-1)}} = \frac{\partial \varepsilon^2}{\partial y_k^{(\ell)}} \cdot \frac{\partial y_k^{(\ell)}}{\partial s_k^{(\ell)}} \cdot \frac{\partial s_k^{(\ell)}}{\partial y_n^{(\ell-1)}} \cdot \frac{\partial y_n^{(\ell-1)}}{\partial s_n^{(\ell-1)}} \cdot \frac{\partial s_n^{(\ell-1)}}{\partial w_{nm}^{(\ell-1)}}$$




$$E = \varepsilon^2 = (d - y_k^{(\ell)})^2 \qquad y_n^{(\ell-1)} = \text{sigmoid}(s_n^{(\ell-1)})$$

$$y_k^{(\ell)} = \text{sigmoid}(s_k^{(\ell)}) \qquad s_n^{(\ell-1)} = w_{0n}^{(\ell-1)} \cdot 1 + w_{1n}^{(\ell-1)} y_1^{(\ell-2)} + \dots + w_{nm}^{(\ell-1)} y_n^{(\ell-2)} + \dots$$

$$s_k^{(\ell)} = w_{0k}^{(\ell)} \cdot 1 + w_{1k}^{(\ell)} y_1^{(\ell-1)} + \dots + w_{mk}^{(\ell)} y_m^{(\ell-1)} + \dots + w_{Mk}^{(\ell)} y_M^{(\ell-1)}$$

A pótzh 2. feladata: tanítsuk w_{21} -et gradiensmódszerrel

Neurális hálózatunk három – szigmoid nemlinearitással felépített – neuronból áll. Tanításra a hibavisszaterjesztés (BP) *gradiens módszert* használjuk, a kimeneti négyzetes hibára optimalizálva. A következő lépésben az $x_1 = -0,5$; $x_2 = +0,5$ mintával tanítunk, amelyhez tartozó kívánt válasz $+0,1$. Az eddigi tanítási lépések során kialakult – a megoldáshoz szükséges – súlyok és az adott bementre előálló értékek az ábrán láthatók.



Mi lesz a w_{21} súly (az ábrán szaggatott vonallal jelölve) új értéke a tanítási lépés után, ha a tanítási faktor (bátorsági faktor) értéke $0,5$?

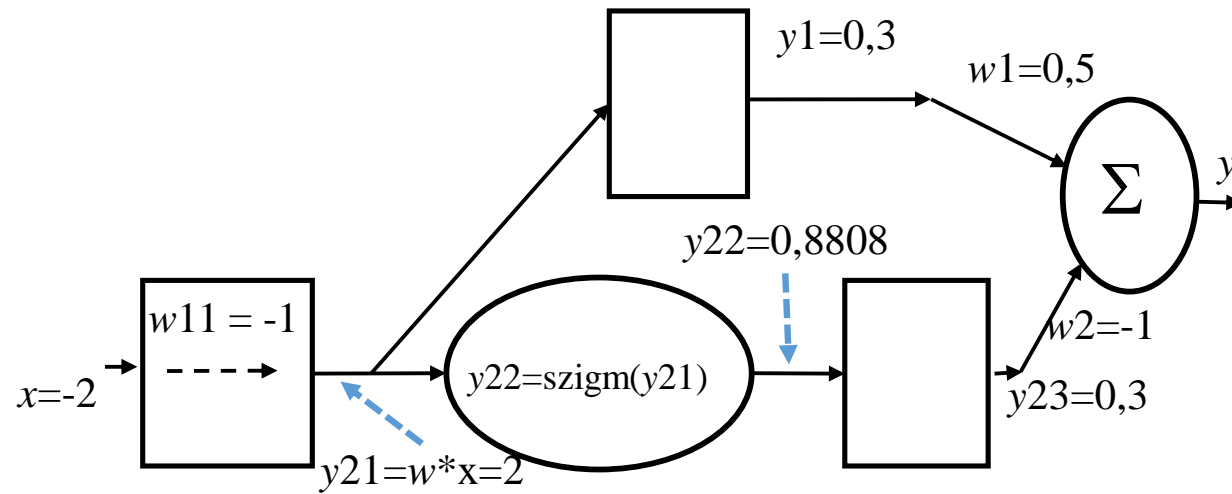
Fel kell írni a megoldást paraméteresen is [$w_{21új} = f(w_{21}, z, y, s, \dots)$ – mint ahogy az $F=ma$ Newton törvényt felírjuk betűkkel], és a számítás is szükséges! A pusztá végeredmény 0 pontot ér!

Segítség: az adott minta előreterjesztése során ennél a mintánál a következő értékek alakultak ki:

$$s_2 = w_{20} \cdot x_0 + w_{21} \cdot x_1 + w_{22} \cdot x_2 = 0,8 \quad ; \quad z_2 = \frac{1}{1 + e^{-s_2}} = 0,69 \quad ; \quad s = w_1 \cdot z_1 + w_2 \cdot z_2 = 0,213$$

$$y = \frac{1}{1 + e^{-s}} = 0,5530 \quad ; \quad \text{továbbá szigmoid nemlinearitásra: } K = \frac{1}{1 + e^{-L}} \rightarrow \frac{dK}{dL} = K \cdot (1 - K)$$

Mekkora lesz w_{11} új értéke a gradiensmódszerrel történő tanítás után, ha a tanítómintánk $x=-2$, $d=0$, és a tanítási (bátorsági) faktor $0,1$?



$$\frac{dy_1}{dy_{21}} = -2$$

$$\frac{dy_{23}}{dy_{22}} = +0,5$$