

Perceptron: $y = f\left(\sum_i x_i w_i + v\right)$ $\rightarrow t \in \{0, 1\}$

$$w(t+1) = w(t) + \alpha \cdot (x_i \cdot (d_i - t))$$

Convergence:

$$\cos \rho = \frac{\vec{w}^* \cdot \vec{w}_{t+1}}{\|\vec{w}_{t+1}\|} \rightarrow \geq \vec{w}^* \cdot \vec{w}_0 + (t+1)\delta$$

$$\delta = \min \{ \vec{w}^* \cdot \vec{p} : \forall p \in P' \}$$

$$\|\vec{w}_{t+1}\|^2 \leq \|\vec{w}_0\|^2 + (t+1)$$

$\rightarrow$ protože p' je normalizovaná

$$\cos \rho \geq \frac{\vec{w}^* \cdot \vec{w}_0 + (t+1)\delta}{\sqrt{\|\vec{w}_0\|^2 + (t+1)}}$$

- jelikož $\cos x \leq 1 \forall x$ a $\delta > 0 \Rightarrow$ máme to s $\sqrt{t}$, takže musím po konečné množině hodnot najít tu maximální hodnotu t . X

BP-network:

Minimizing: $E = \frac{1}{2} \sum_p \sum_j (y_{jp} - t_{jp})^2$

deneme sigmoida $\sim f(x)$

$$\text{sigm}'(\xi_j) = \lambda y_j \cdot (1 - y_j)$$

update rule: $w_{ij}(t+1) = w_{ij}(t) + \Delta_E w_{ij}(t)$

$$\Delta_E w_{ij}(t) = -\frac{\partial E}{\partial w_{ij}} = -\frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}}$$

$\rightarrow$ chain-rule

$\rightarrow$ momentum techniques

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_i + \alpha_m (w_{ij}(t) - w_{ij}(t-1))$$

output: $(d_j - y_j) \cdot \lambda y_j \cdot (1 - y_j)$

hidden: $(\sum_k \delta_k w_{jk}) \cdot \lambda y_j \cdot (1 - y_j)$

$\Delta_E w_{ij} = -\frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}} = -\frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \xi_j} \cdot y_i = -\frac{\partial E}{\partial \xi_i} \cdot f'(\xi_j) \cdot y_i = -(y_j - d_j) \cdot f'(\xi_j) \cdot y_i$

$f'(\xi_j)$ y_i

$$\Delta_E w_{ij} = -\frac{\partial E}{\partial w_{ij}} = -\left(\sum_k \frac{\partial E}{\partial \xi_k} \cdot \frac{\partial \xi_k}{\partial y_j} \right) \cdot \frac{\partial y_j}{\partial \xi_j} \cdot \frac{\partial \xi_j}{\partial w_{ij}} = -\left(\sum_k \frac{\partial E}{\partial \xi_k} \cdot \frac{\partial}{\partial y_j} \cdot \sum_j w_{kj} y_j \right) \cdot \dots$$

$$= -\left(\sum_k \frac{\partial E}{\partial \xi_k} \cdot w_{jk} \right) \cdot f'(\xi_j) \cdot y_i = -\left(\sum_k \delta_k w_{jk} \right) \cdot f'(\xi_j) \cdot y_i$$

$y_j = f(\xi_j) = \frac{1}{1 + e^{-\lambda \xi_j}}$, where $\xi_j = \sum_i w_{ij} \cdot y_i$

$\rightarrow$ that all serves as an input to another layer...

Adm Gmd:

adaptive weight updates:

$$A_i(t+1) = A_i(t) + \left(\frac{\partial E}{\partial w_i} \right)^2$$

$$w_i(t+1) = w_i(t) - \frac{\alpha}{\sqrt{A_i}} \cdot \frac{\partial E}{\partial w_i}$$

ten, že si špe parametry, kde hodně chybíme!
a podle toho upravuje váhy.

Second-order - alg's:

$$E(\bar{w} + \bar{h}) \approx E(\bar{w}) + \nabla E(\bar{w})^T \bar{h} + \frac{1}{2} \bar{h}^T \nabla^2 E(\bar{w}) \bar{h}$$

derivace podle $\bar{h}$:

$$\frac{\partial E(\bar{w} + \bar{h})}{\partial \bar{h}} \approx \nabla E(\bar{w}) + \bar{h}^T \nabla^2 E(\bar{w})$$

tohle můžeme být nějaký systém

$$\bar{h} = - \left(\nabla^2 E(\bar{w}) \right)^{-1} \cdot \nabla E(\bar{w})$$

pseudo-newton:

$$w_i^{(k+1)} = w_i^{(k)} - \frac{\nabla_i E(\bar{w})}{\frac{\partial^2 E(\bar{w})}{\partial w_i^2}}$$

uvážij pouze diagonály

Quickprop:

$$w_i^{(k+1)} = w_i^{(k)} + \underbrace{\Delta^{(k)}}_{\Delta^{(k-1)} w_i} - \frac{\frac{\nabla_i E^{(k)}}{\Delta^{(k-1)} w_i} - \frac{\nabla_i E^{(k-1)}}{\Delta^{(k-1)} w_i}}{\frac{\partial^2 E(w_i)}{\partial w_i^2}}$$


aproximace

$$\int_0^1 |f(x) - g'(x)| dx < \varepsilon$$

$[0,1]$ rozdělím na N

$$q_N(x) = \min \{ f(x') : x' \in [x_i, x_{i+1}], x_i \leq x < x_{i+1} \}$$

$$E_N = \int_0^1 |f(x) - q_N(x)| dx \quad \text{protože } f(x) \geq q_N(x) \Rightarrow E_N = \int_0^1 f(x) dx - \int_0^1 q_N(x) dx$$



Asociativní paměť:

$$\vec{e} = \vec{x}^T \cdot W, \text{ hledáme takové } W, \text{ že } XW = Y \rightarrow \text{takže chci něco jako } W = X^{-1} \cdot Y$$

Se zpětnou vazbou:

$$\text{Hledám fixed point, že } \vec{e}_j = \vec{e}_j \cdot W \rightarrow \text{definice stabilního stavu.}$$

Eigenvalue Automata

podmínka v matici n -nezávislých vlastních vektorů, pak platí:

$$\vec{x}^i \cdot W = \lambda_i \vec{x}^i$$

$\Rightarrow$ podmínka je B.Ú.N.O. λ_n největší, takže se po konečné množině iterací stane $\vec{x}^i$ autovektorem.

Asociativní učení

- přesně tyto autovektory si chci zapamatovat.

Hebbian learning