


Neuronät (= neuralt nätverk)

= flervariabelfunktion $f(\bar{x})$ som är en sammansättning av flera enkla funktioner: $f(\bar{x}) = (f_2 \circ \dots \circ f_2 \circ f_1)(\bar{x}) = f_2(\dots f_2(f_1(\bar{x})), \dots)$. L = antal lager.

Varje \bar{f}_j är i sig en sammansättning av en linjär eller affin avbildning $A_j \bar{x} + \bar{b}_j$ och en enkel olinjär σ .

linjär
affin

Låt $\sigma(t) = (t)_+ = \max(t, 0) = \begin{cases} t, & t \geq 0 \\ 0, & t < 0 \end{cases}$ och sätt



$$\bar{\sigma}(\bar{x}) = \begin{pmatrix} \sigma_1(t_{11}, \dots, t_{1n}) \\ \vdots \\ \sigma_n(t_{n1}, \dots, t_{nn}) \end{pmatrix} \stackrel{\text{def}}{=} \begin{pmatrix} \sigma(t_{11}) \\ \vdots \\ \sigma(t_{nn}) \end{pmatrix} = \begin{pmatrix} t_{11} \\ \vdots \\ t_{nn} \end{pmatrix}_+ \quad \text{Ex } \bar{\sigma}\left(\begin{pmatrix} -1 \\ 2 \\ -3 \\ 4 \end{pmatrix}\right) = \begin{pmatrix} -1 \\ 2 \\ -3 \\ 4 \end{pmatrix}_+ = \begin{pmatrix} 0 \\ 2 \\ 0 \\ 4 \end{pmatrix}$$

Ex Likt neuronät $y = f(\bar{x}) = (f_3 \circ \bar{f}_2 \circ \bar{f}_1)(\bar{x})$ ($L=3$)

$$A_1 = \begin{pmatrix} 2 & -1 \\ 1 & 1 \end{pmatrix}, \bar{b}_1 = \begin{pmatrix} -1 \\ 2 \end{pmatrix}, A_2 = \begin{pmatrix} 1/2 & 1 \\ -3 & 0 \end{pmatrix}, A_3 = (1, -1, 1)$$


$$\bar{f}_1(\bar{x}) = (A_1 \bar{x} + \bar{b}_1)_+, \bar{f}_2(\bar{u}) = (A_2 \bar{u})_+, f_3(\bar{v}) = A_3 \bar{v}$$

$$\text{För t.ex. } \bar{x} = \begin{pmatrix} 2 \\ 1 \end{pmatrix} \in \mathbb{R}^2 \text{ förs } \bar{u} = \bar{f}_1(\bar{x}) = (A_1 \begin{pmatrix} 2 \\ 1 \end{pmatrix} + \bar{b}_1)_+ = \begin{pmatrix} 2 \\ 5 \end{pmatrix}_+ = \begin{pmatrix} 2 \\ 5 \end{pmatrix} \Rightarrow$$

$$\bar{v} = \bar{f}_2(\bar{u}) = \bar{f}_2(\bar{f}_1(\bar{x})) = (A_2 \begin{pmatrix} 2 \\ 5 \end{pmatrix})_+ = \begin{pmatrix} 7 \\ 4 \\ -1 \end{pmatrix}_+ = \begin{pmatrix} 7 \\ 4 \\ 0 \end{pmatrix} \Rightarrow$$

$$y = f_3(\bar{v}) = f_3(\bar{f}_2(\bar{f}_1(\bar{x}))) = A_3 \bar{v} = (1, -1, 1) \begin{pmatrix} 7 \\ 4 \\ 0 \end{pmatrix} = 3, \text{ så } f\left(\begin{pmatrix} 2 \\ 1 \end{pmatrix}\right) = 3$$

Grafisk repr.



Här hitta bra neuronät för viss tillämpning? Utnyttja att man har träningsdata, för visst antal givna \bar{x} vet man vad $y = f(\bar{x})$ ska bli (övervakad inlärning). Man vill bestämma alla matriser och vektorer i nätet så att felet

$$l = \frac{1}{N} \sum_{j=1}^N \left(\underbrace{f(\bar{x}^{(j)})}_{\substack{\text{utvärde som nätet ger} \\ \text{då } \bar{x}^{(j)} \text{ matas in}}} - \underbrace{y^{(j)}}_{\substack{\text{önskat utvärde då } \bar{x}^{(j)} \text{ matas in}}} \right)^2$$

minimeras (minstakvadratproblem)
 N = antal träningspunkter [andra l kan väljas]

Ex (mikronät) skapa ett nät $f(\bar{x}) = (f_2 \circ f_1)(\bar{x})$ för $\bar{x} \in \mathbb{R}^2$ där

$$\bar{u} = f_1(\bar{x}) = (A_1 \bar{x} + \bar{b}_1)_+ \in \mathbb{R}^2, \text{ och } y = f_2(\bar{u}) = A_2 \bar{u} \in \mathbb{R}, \text{ så}$$

$$A_1 = \begin{pmatrix} w_1 & w_2 \\ w_3 & w_4 \end{pmatrix} 2 \times 2, \bar{b}_1 = \begin{pmatrix} w_5 \\ w_6 \end{pmatrix} \text{ och } A_2 = (w_7 \ w_8) \text{ söks.}$$

Träningsdata är endast 2 punkter, $\hat{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ inskage $\hat{y} = 1$ ut, $\tilde{x} = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$ skage $\tilde{y} = 5$


Bestäm $\bar{w} = (w_1, \dots, w_8) \in \mathbb{R}^8$ så att

$$l(\bar{w}) = \frac{1}{2} \left((f(\hat{x}; \bar{w}) - \hat{y})^2 + (f(\tilde{x}; \bar{w}) - \tilde{y})^2 \right) = \frac{1}{2} \left((f(\begin{pmatrix} 1 \\ 1 \end{pmatrix}; \bar{w}) - 1)^2 + (f(\begin{pmatrix} 1 \\ -1 \end{pmatrix}; \bar{w}) - 5)^2 \right)$$

nytt skrivsätt för att visa att nätet f också beror på matriserna minimeras

Min finns där $\nabla l(\bar{w}) = (l'_{w_1}, \dots, l'_{w_8}) = \bar{0}$ [nästa föreläsning] men försvårt lösa exakt eller numeriskt (\bar{w} i mycket hög dim.).

Idé: $l(\bar{w})$ ökar snabbast i riktning $-\nabla l(\bar{w})$. Ta steg i denna riktning för att minska $l(\bar{w})$. [brantaste lutning i opt.].



$$\nabla(g^2) = 2g \nabla g \Rightarrow \nabla l(\bar{w}) = (f(\hat{x}; \bar{w}) - \hat{y}) \nabla_{\bar{w}} f(\hat{x}; \bar{w}) + (f(\tilde{x}; \bar{w}) - \tilde{y}) \nabla_{\bar{w}} f(\tilde{x}; \bar{w})$$

Hur beräkna??
grad. på \bar{w} (inte på \bar{x}) ($\nabla \hat{y} = \nabla \tilde{y} = \bar{0}$)

Kedjeregeln för komponent u_k i $\bar{u} = \begin{pmatrix} u_1(t_1, \dots, t_q) \\ \vdots \\ u_m(t_1, \dots, t_q) \end{pmatrix}$

$$\bar{u} \quad \frac{\partial u_k}{\partial t_j} = \frac{\partial u_k}{\partial x_1} \frac{\partial x_1}{\partial t_j} + \dots + \frac{\partial u_k}{\partial x_n} \frac{\partial x_n}{\partial t_j}$$

placerat på rad k i matris placerat kolonn j i matris

kan man då på plats k, j i matris

$$\begin{pmatrix} \frac{\partial u_1}{\partial t_1} & \dots & \frac{\partial u_1}{\partial t_q} \\ \vdots & & \vdots \\ \frac{\partial u_m}{\partial t_1} & \dots & \frac{\partial u_m}{\partial t_q} \end{pmatrix} = \begin{pmatrix} \frac{\partial u_1}{\partial x_1} & \dots & \frac{\partial u_1}{\partial x_n} \\ \vdots & & \vdots \\ \frac{\partial u_m}{\partial x_1} & \dots & \frac{\partial u_m}{\partial x_n} \end{pmatrix} \begin{pmatrix} \frac{\partial x_1}{\partial t_1} & \dots & \frac{\partial x_1}{\partial t_q} \\ \vdots & & \vdots \\ \frac{\partial x_n}{\partial t_1} & \dots & \frac{\partial x_n}{\partial t_q} \end{pmatrix}$$

$$\Rightarrow \frac{\partial(\bar{u})}{\partial(\bar{t})} = \frac{\partial(\bar{u})}{\partial(\bar{x})} \frac{\partial(\bar{x})}{\partial(\bar{t})}$$

mest allmänna kedjeregeln

$$= \frac{\partial(u_1, \dots, u_m)}{\partial(t_1, \dots, t_q)} = \frac{\partial(\bar{u})}{\partial(\bar{t})} = \bar{u}'(\bar{t}) = \frac{\partial(\bar{u})}{\partial(\bar{x})} = \frac{\partial(\bar{x})}{\partial(\bar{t})}$$

beteckn.

Matriserna kallas functionalmatriser.

$$\underline{E} \times \bar{f}(\bar{x}; \bar{w}) = \underbrace{\begin{pmatrix} w_1 & w_2 \\ w_3 & w_4 \end{pmatrix}}_A \underbrace{\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}}_{\bar{x}} + \underbrace{\begin{pmatrix} w_5 \\ w_6 \end{pmatrix}}_{\bar{b}} = \begin{pmatrix} w_1 x_1 + w_2 x_2 + w_5 \\ w_3 x_1 + w_4 x_2 + w_6 \end{pmatrix}$$

$$\Rightarrow \frac{\partial \bar{f}}{\partial \bar{x}} = \begin{pmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} \end{pmatrix} = \begin{pmatrix} w_1 & w_2 \\ w_3 & w_4 \end{pmatrix} = A \text{ och } \frac{\partial \bar{f}}{\partial \bar{w}} = \begin{pmatrix} \frac{\partial f_1}{\partial w_1} & \dots & \frac{\partial f_1}{\partial w_6} \\ \frac{\partial f_2}{\partial w_1} & \dots & \frac{\partial f_2}{\partial w_6} \end{pmatrix} = \begin{pmatrix} \overbrace{x_1} & \overbrace{x_2} & 0 & 0 & 1 & 0 \\ 0 & 0 & \overbrace{x_1} & \overbrace{x_2} & 0 & 1 \end{pmatrix} = M(\bar{x}) = \text{diagonal, 0/1 på diagonalen}$$

$$\sigma(t) = (t)_+ \text{ har } \sigma'(t) = H(t) = \begin{cases} 1 & t > 0 \\ 0 & t < 0 \end{cases} \Rightarrow \bar{\sigma}(E) = \begin{pmatrix} t_1 \\ \vdots \\ t_n \end{pmatrix} \text{ har } \frac{\partial \bar{\sigma}}{\partial \bar{E}} = \begin{pmatrix} H(t_1) & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & H(t_n) \end{pmatrix}$$

Åter till mikronätet:

$$\text{Söker } \nabla_{\bar{w}} f(\bar{x}; \bar{w}) = \left(\frac{\partial y}{\partial w_1}, \dots, \frac{\partial y}{\partial w_6} \right)$$

$$y = A_2 \bar{u} = \begin{pmatrix} w_7 & w_8 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} = w_7 u_1 + w_8 u_2 \Rightarrow \frac{\partial (y)}{\partial (w_7, w_8)} = \begin{pmatrix} \frac{\partial y}{\partial w_7} & \frac{\partial y}{\partial w_8} \end{pmatrix} = (u_1, u_2) = \bar{u}^T$$

$$\text{Låt } \bar{E} = A_1 \bar{x} + \bar{b}_1 \text{ så } \bar{u} = (\bar{E})_+ \Rightarrow \frac{\partial (y)}{\partial (w_1, \dots, w_6)} \uparrow \frac{\partial (y)}{\partial \bar{u}} \frac{\partial \bar{u}}{\partial \bar{E}} \frac{\partial \bar{E}}{\partial (w_1, \dots, w_6)}$$

kedjeregeln $= A_2 = H(\bar{E}) = M(\bar{x}) \Rightarrow 1 \times 6$ matris
Zängler $1 \times 2 \quad 2 \times 2 \quad 2 \times 6$

$$\Rightarrow \nabla_{\bar{w}} f(\bar{x}; \bar{w}) = \underbrace{(A_2 H(\bar{E}) M(\bar{x}))}_{0 \text{ komp.}} \underbrace{\bar{u}^T}_{2 \text{ komp.}}$$

Väljett startnät (startpunkt i \mathbb{R}^8), t.ex. $\bar{w}^{(0)} = \underbrace{(1, -1, 2, 1)}_{A_1}, \underbrace{(1, -2, 2, 1)}_{A_2}$

så $A_1 = \begin{pmatrix} 1 & -1 \\ 2 & 1 \end{pmatrix}, \bar{b}_1 = \begin{pmatrix} 1 \\ -2 \end{pmatrix}, A_2 = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$ till att börja med

Forbättra nätet genom ett steg längs $-\nabla l(\bar{w})$. Kör igenom träningspunkterna:

$$\hat{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \Rightarrow \hat{E} = A_1 \hat{x} + \hat{b}_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \hat{u} = (\hat{E})_+ = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, f(\hat{x}, \bar{w}^{(0)}) = A_2 \hat{u} = 3, \text{ jämför önskat } \hat{y} = 1$$

Notera $H(\hat{E}) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, M(\hat{x}) = \begin{pmatrix} 1 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 1 & 0 & 1 \end{pmatrix}$ kan läsas av

$$\tilde{x} = \begin{pmatrix} 1 \\ -1 \end{pmatrix} \Rightarrow \tilde{E} = A_1 \tilde{x} + \tilde{b}_1 = \begin{pmatrix} 3 \\ -1 \end{pmatrix}, \tilde{u} = (\tilde{E})_+ = \begin{pmatrix} 3 \\ 0 \end{pmatrix}, f(\tilde{x}, \bar{w}^{(0)}) = A_2 \tilde{u} = 6, \text{ jämför } \tilde{y} = 5$$

Notera $H(\tilde{E}) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, M(\tilde{x}) = \begin{pmatrix} 1 & -1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & -1 & 0 & 1 \end{pmatrix}$

Detta ger $l(\bar{w}^{(0)}) = \frac{1}{2} ((3-1)^2 + (6-5)^2) = 2.5$ fel med startnät, och

$$\nabla l(\bar{w}^{(0)}) = (3-1) \cdot \underbrace{(A_2 H(\hat{E}) M(\hat{x}), \hat{u}^T)}_{(2, 2, 1, 1, 2, 1, 1, 1)} + (6-5) \cdot \underbrace{(A_2 H(\tilde{E}) M(\tilde{x}), \tilde{u}^T)}_{(2, -2, 0, 0, 3, 0, 3, 0)} = (6, 2, 2, 2, 6, 2, 5, 2)$$

Flytta till nästa punkt (nytt nät) $\bar{w}^{(1)} = \bar{w}^{(0)} - \eta \nabla l(\bar{w}^{(0)}) =$

$$= \underbrace{(0.7, -1.1, 1.9, 0.9)}_{\text{ny } A_1}, \underbrace{(0.7, -2.1, 1.75, 0.9)}_{\text{ny } A_2}$$

$\eta = 0.05$, svårt val
bästa steglösning

Nytt nät $A_1 = \begin{pmatrix} 0.7 & -1.1 \\ 1.9 & 0.9 \end{pmatrix}$, $\bar{b}_1 = \begin{pmatrix} 0.7 \\ -2.1 \end{pmatrix}$, $A_2 = (1.75 \ 0.9)$

Samma steg som ovan

$\hat{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ ger $\hat{z} = \begin{pmatrix} 0.3 \\ 0.7 \end{pmatrix}$, $\hat{u} = \begin{pmatrix} 0.3 \\ 0.7 \end{pmatrix}$, $f(\hat{x}, \bar{w}^{(1)}) = 1.155$ H- och M-matriser som ovan

$\tilde{x} = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$ $\tilde{z} = \begin{pmatrix} 2.5 \\ -2.1 \end{pmatrix}$, $\tilde{u} = \begin{pmatrix} 2.5 \\ 0 \end{pmatrix}$, $f(\tilde{x}, \bar{w}^{(1)}) = 4.375$

Ger $l(\bar{w}^{(1)}) \approx 0.21$ stor förbättring

$\nabla l(\bar{w}^{(1)}) \approx (\dots)$

$\bar{w}^{(2)} = \bar{w}^{(1)} - 0.05 \nabla l(\bar{w}^{(1)}) \approx (0.74, \dots, 0.89) \Rightarrow$ nytt nät har

$A_1 \approx \begin{pmatrix} 0.74 & -1.17 \\ 1.89 & 0.89 \end{pmatrix}$, $\bar{b}_1 \approx \begin{pmatrix} 0.74 \\ -2.11 \end{pmatrix}$, $A_2 \approx (1.83, 0.89)$

med $l(\bar{w}^{(2)}) \approx 0.09$ ny förbättring

Fortsätt till $l(\bar{w}^{(k)})$ acceptabelt litet. Då har man sitt färdiga neuronnät som kan användas för att studera $y = f(\bar{x})$ för \bar{x} med okända y -värden. Man har tränat eller lärt upp nätet.

Alt enkelt koda. Användning av kedjeregeln kallas inom AI för "back propagation algorithm". Djupare nät kräver kedjeregeln i fler steg: $A_L H_{L-1} A_{L-1} \dots A_{j+1} H_j M_j$ för derivator på matriselement i lager j , $j \geq 1$. Vår σ kallas ReLU i AI. Många fler aspekter, tillämpningar, problem, terminologi etc ses på utblick 27/4 10-12