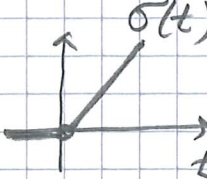


Fö9

Med ett neuronnät menar vi en flervariabelfunktion som är en sammansättning av flera enkla funktioner.

Ex på enkla funktioner: 0 ett neuronnät.

(1) Låt  $\sigma(t) = \begin{cases} t, & t \geq 0 \\ 0, & t < 0 \end{cases}$    $H(t) = \sigma'(t) = \begin{cases} 1, & t > 0 \\ 0, & t < 0 \\ \text{ej def, } & t = 0 \end{cases}$

För vektorer:

$\bar{\sigma}(\bar{t}) = \bar{\sigma} \begin{pmatrix} t_1 \\ \vdots \\ t_n \end{pmatrix} = \begin{pmatrix} \sigma(t_1) \\ \vdots \\ \sigma(t_n) \end{pmatrix}$  av typ  $\mathbb{R}^n \rightarrow \mathbb{R}^n$  med  $H(\bar{t})$

funktionsmatric  $\bar{\sigma}'(\bar{t}) = \begin{pmatrix} \sigma'(t_1) & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & \dots & \sigma'(t_n) \end{pmatrix} = \begin{pmatrix} 0/1 & & & 0 \\ & \ddots & & \\ 0 & & & 0/1 \end{pmatrix}$

Kvadrat. matris med 0 eller 1 på diagonalen.

tillex:  $\bar{\sigma} \begin{pmatrix} -1 \\ 2 \\ -4 \end{pmatrix} = \begin{pmatrix} 0 \\ 2 \\ 0 \end{pmatrix}$   $\bar{\sigma}' \begin{pmatrix} -1 \\ 2 \\ -4 \end{pmatrix} = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix} = H \begin{pmatrix} -1 \\ 2 \\ -4 \end{pmatrix}$

(2)  $\bar{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \in \mathbb{R}^2$ . Låt  $\bar{u} = \bar{f}_1(\bar{x}) = \bar{\sigma} \left( \underbrace{\begin{pmatrix} 2 & -1 \\ 1 & 1 \end{pmatrix}}_{A_1} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \underbrace{\begin{pmatrix} -1 \\ 2 \end{pmatrix}}_{b_1} \right) \in \mathbb{R}^2$

$\bar{v} = (\bar{f}_2 \circ \bar{f}_1)(\bar{x}) = \bar{f}_2(\bar{f}_1(\bar{x})) = \bar{f}_2(\bar{u}) =$   
 $= \bar{\sigma} \left( \underbrace{\begin{pmatrix} 1 & 1 \\ 2 & 0 \\ -3 & 1 \end{pmatrix}}_{A_2} \cdot \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} \right) \in \mathbb{R}^3$


$y = f(\bar{x}) = (\bar{f}_3 \circ \bar{f}_2 \circ \bar{f}_1)(\bar{x}) = \bar{f}_3(\bar{v}) = \underbrace{\begin{pmatrix} 1 & -1 & 1 \end{pmatrix}}_{A_3} \cdot \begin{pmatrix} v_1 \\ v_2 \\ v_3 \end{pmatrix} \in \mathbb{R}$

med  $\bar{x} = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$  fås  $\bar{u} = \bar{\sigma} \left( \begin{pmatrix} 2 & -1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} 2 \\ 1 \end{pmatrix} + \begin{pmatrix} -1 \\ 2 \end{pmatrix} \right) = \begin{pmatrix} 2 \\ 5 \end{pmatrix}$  (linjär)

$\bar{v} = \bar{\sigma} \left( \begin{pmatrix} 1 & 1 \\ 2 & 0 \\ -3 & 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ 5 \end{pmatrix} \right) = \bar{\sigma} \begin{pmatrix} 7 \\ 4 \\ -1 \end{pmatrix} = \begin{pmatrix} 7 \\ 4 \\ 0 \end{pmatrix}$ ,  $y = \begin{pmatrix} 1 & -1 & 1 \end{pmatrix} \cdot \begin{pmatrix} 7 \\ 4 \\ 0 \end{pmatrix} = 3 \Rightarrow \underline{f \left( \begin{pmatrix} 2 \\ 1 \end{pmatrix} \right) = 3}$



Grafisk representation av neuronätet  $f(\bar{x})$ :



I fallet 3 lager  $\bar{u}, \bar{v}, y$ .

Obs Om enkla funktioner av givna som i ex ovan så kan man "lätt" hitta värdena av den sammansatta funktionen.

Huvudproblem är hur man kan hitta ett neuronäts element som passar en viss tillämpning dvs alla matriser i alla lager ( $A, b$  etc)? (Varje lager är linjärt/affint följt av  $\sigma$ )

Metod: man utnyttjar att man har "träningsdata" för ett antal  $\bar{x}$  med givna värden  $y$   $\underline{0}$  linjär algebra / fler variabel analys. (se nedan).

EX Vi har 2 träningspunkter:  $\hat{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$  med  $\hat{y} = 1$   $\underline{0}$   
 $\tilde{x} = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$  med  $\tilde{y} = 5$ .


Vi söker ett neuronät med 2 lager:  $f(\bar{x}) = (f_2 \circ \bar{f}_1)(\bar{x})$ , där

$\bar{f}_1(\bar{x}) = \sigma(A_1 \cdot \bar{x} + \bar{b}_1)$   $\underline{0}$   $f_2(u) = A_2 \cdot u$ , här

$A_1$  ( $2 \times 2$ ),  $\bar{b}_1$  ( $2 \times 1$ ),  $A_2$  ( $1 \times 2$ ). Alltså:

$$\bar{f}_1(\bar{x}) = \bar{u} = \sigma \left( \underbrace{\begin{pmatrix} w_1 & w_2 \\ w_3 & w_4 \end{pmatrix}}_{A_1} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \underbrace{\begin{pmatrix} w_5 \\ w_6 \end{pmatrix}}_{\bar{b}_1} \right)$$

$$f_2(\bar{u}) = y = (w_7 \ w_8) \cdot \begin{pmatrix} u_1 \\ u_2 \end{pmatrix}$$



$$y = f(\bar{x}) = f_2(\bar{u}) = f_2(\bar{f}_1(\bar{x})) = (f_2 \circ \bar{f}_1)(\bar{x})$$

Man letar efter  $A_1, \bar{b}_1, A_2$ .

Bilda vektorn  $(w_1, w_2, \dots, w_8) \in \mathbb{R}^8$ .

Vi söker alltså  $\bar{w}$  som ska anpassas till träningsdata

Obs  $\bar{f}_1$  kan anses bero på  $w_1 \dots w_6$   $\underline{0}$   $f_2 = w_7, w_8$ .



Vi ska skriva  $f(\bar{x}, \bar{w})$  i stället för  $f(\bar{x})$ .

Vi minstakvadrat anpassat matriseras till träningsdata:  
( $w_1, \dots, w_8$ )

minimera 
$$l(\bar{w}) = \frac{1}{2} \left( \underbrace{(f(\hat{x}, \bar{w}) - \hat{y})^2}_{d_1(\bar{w})} + \underbrace{(f(\tilde{x}, \bar{w}) - \tilde{y})^2}_{d_2(\bar{w})} \right) \quad (1)$$

Obs Minproblem: (a) lös ekv  $\nabla l(\bar{w}) = \bar{0}$ , (c) Kolla stationära punkter  
(i praktiken omöjligt att utföra)

I stället använder man -grad  $l(\bar{w})$  metod.

Obs. 
$$\nabla l(\bar{w}) = \frac{1}{2} \nabla (d_1(\bar{w})^2 + d_2(\bar{w})^2) = \sum_{i=1}^2 d_i(\bar{w}) \cdot \nabla_{\bar{w}} f(\hat{x}/\tilde{x}, \bar{w}) \quad (2)$$
  
(derivator på  $\bar{w}$ )

Algorithm: Ta startpunkt  $\bar{w}_0 \in \mathbb{R}^8$  (vilken som helst) läs  $l(\bar{w}_0)$

Obs  $l$  avtar snabbast i riktning  $-\nabla l(\bar{w}_0)$ .


Ta steg från  $\bar{w}_0$  i den rikt. till ny punkt  $\bar{w}_1$ .

läs av  $l(\bar{w}_1)$ . Ta nytt steg i rikt.  $-\nabla l(\bar{w}_1)$  till

ny punkt  $\bar{w}_2$  o så vidare. Stanna då  $l(\bar{w}_k)$

(efter  $k$ -steg) acceptabelt litet.

Metoden kallas brantaste lutning i optimering.



Hur beräknar man  $\nabla l(\bar{w})$ ?

I (2) ser vi att det behövs partiella derivator av  $f(\hat{x}, \bar{w})$  o  $f(\tilde{x}, \bar{w})$  m a p  $w_1, \dots, w_8$ .  
man hittar dem m h a Kedjeregeln.



Beräkningar:

1. Funktionsalmatriser i neuronätet:

Låt  $\bar{z} = A_1 \bar{x} + \bar{b}_1$  (affin)  $\Rightarrow \bar{z}'(\bar{x}) = \frac{\partial \bar{z}}{\partial \bar{x}} = A_1$ ,

Låt  $\bar{u} = \sigma(\bar{z}) \Rightarrow \bar{u}'(\bar{z}) = \frac{\partial \bar{u}}{\partial \bar{z}} = H(\bar{z})$ .

$y = A_2 \cdot \bar{u}$  (linjär)  $\Rightarrow \frac{\partial y}{\partial \bar{u}} = A_2$

2. Derivator på olika  $w_j$  (direkta)

$w_1, \dots, w_6$  :  $\bar{z} = \begin{pmatrix} w_1 & w_2 \\ w_3 & w_4 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \begin{pmatrix} w_5 \\ w_6 \end{pmatrix} = \begin{pmatrix} w_1 x_1 + w_2 x_2 + w_5 \\ w_3 x_1 + w_4 x_2 + w_6 \end{pmatrix} \Rightarrow$

$\frac{\partial(z_1, z_2)}{\partial(w_1, \dots, w_6)} = \begin{pmatrix} x_1 & x_2 & 0 & 0 & 1 & 0 \\ 0 & 0 & x_3 & x_4 & 0 & 1 \end{pmatrix} = M(\bar{x})$

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

3. Derivator av  $y$  på  $w_1, \dots, w_6$  med kedjeregeln

$\frac{\partial y}{\partial(w_1, \dots, w_6)} = \frac{\partial y}{\partial \bar{u}} \cdot \frac{\partial \bar{u}}{\partial \bar{z}} \cdot \frac{\partial \bar{z}}{\partial(w_1, \dots, w_6)} = A_2 \cdot H(\bar{z}) \cdot M(\bar{x})$

Nu starta algoritmen. Välj en startpunkt i  $R^8$ ,

till ex.  $\bar{w}_0 = \left( \underbrace{1, -1, 2, 1}_{A_1}, \underbrace{1, -2}_{\bar{b}_1}, \underbrace{2, 1}_{A_2} \right)$ , d. v. s.

vi har neuronät med  $A_1 = \begin{pmatrix} 1 & -1 \\ 2 & 1 \end{pmatrix}$ ,  $\bar{b}_1 = \begin{pmatrix} 1 \\ -2 \end{pmatrix}$ ,  $A_2 = (2, 1)$ .

Beräkna  $\mathcal{L}(\bar{w}_0)$  (se (1)): börja med  $f(\hat{x}, \bar{w}_0) = f(\tilde{x}, \bar{w}_0)$ .

Obs  $\hat{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \Rightarrow \hat{z} = A_1 \hat{x} + \bar{b}_1 = \begin{pmatrix} 1 & -1 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \begin{pmatrix} 1 \\ -2 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \Rightarrow \hat{u} = \sigma(\hat{z}) = \sigma\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right) = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$

$\Rightarrow f(\hat{x}, \bar{w}_0) = A_2 \cdot \hat{u} = (2, 1) \begin{pmatrix} 1 \\ 1 \end{pmatrix} = 3$ . Vi ville 1.

Notera att  $H(\hat{z}) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = M(\bar{x}) = \begin{pmatrix} 1 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 1 & 0 & 1 \end{pmatrix}$ .

$\tilde{x} = \begin{pmatrix} 1 \\ -1 \end{pmatrix} \Rightarrow \tilde{z} = \begin{pmatrix} 1 & -1 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} 1 \\ -1 \end{pmatrix} + \begin{pmatrix} 1 \\ -2 \end{pmatrix} = \begin{pmatrix} 3 \\ -1 \end{pmatrix} \Rightarrow \tilde{u} = \sigma(\tilde{z}) = \begin{pmatrix} 3 \\ 0 \end{pmatrix} \Rightarrow$

$f(\tilde{x}, \bar{w}_0) = A_2 \cdot \tilde{u} = (2, 1) \begin{pmatrix} 3 \\ 0 \end{pmatrix} = 6$ . Vi ville 5.

Notera att  $H(\tilde{z}) = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} = M(\tilde{x}) = \begin{pmatrix} 1 & -1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & -1 & 0 & 1 \end{pmatrix} \Rightarrow$

$\mathcal{L}(\bar{w}_0) = \frac{1}{2} ((3-1)^2 + (6-5)^2) = 2,5$ .  $\leftarrow$  Felet med detta nät.



(5)

$$\begin{aligned} \text{Se (2)}: \quad \nabla \ell(\bar{w}_0) &= d_1(\bar{w}_0) \cdot (A_2 \cdot H(\hat{z}) \cdot M(\hat{x}), \hat{u}^t) + \\ &\quad d_2(\bar{w}_0) \cdot (A_2 \cdot H(\tilde{z}) \cdot M(\tilde{x}), \tilde{u}^t) = \\ &= 2 \cdot \underbrace{\left( \begin{pmatrix} 2,1 \\ 0,1 \end{pmatrix} \cdot \begin{pmatrix} 1,0 \\ 0,1 \end{pmatrix} \cdot \begin{pmatrix} 1,1 & 0,0 & 1,0 \\ 0,0 & 1,1 & 0,1 \end{pmatrix} \right)}_{(2,2,1,1,2,1), 1,1} + 1 \cdot \underbrace{\left( \begin{pmatrix} 2,1 \\ 0,0 \end{pmatrix} \cdot \begin{pmatrix} 1,0 \\ 0,0 \end{pmatrix} \cdot \begin{pmatrix} 1,1 & 0,0 & 1,0 \\ 0,0 & 1,1 & 0,1 \end{pmatrix} \right)}_{(2,-2,0,0,2,0), 3,0} = \end{aligned}$$

= (6, 2, 2, 2, 6, 2, 5, 2). Ta ett steg i minus denna riktning.

$$\Rightarrow \bar{w}_1 = \bar{w}_0 - \eta \cdot \nabla \ell(\bar{w}_0). \quad \text{Valj } \eta = 0.05 \text{ till ex.}$$

$$\begin{aligned} \Rightarrow \bar{w}_1 &= (1, -1, 2, 1, 1, -2, 2, 1) - 0.05 \cdot (6, 2, 2, 2, 6, 2, 5, 2) = \\ &= \underbrace{(0.7, -1.1, 1.9, 0.9)}_{\text{ny } A_1}, \underbrace{(0.7, -2.1)}_{\bar{b}_1}, \underbrace{(1.75, 0.9)}_{A_2} \end{aligned}$$

Vi har då nytt neuronät där matriserna ändrats till

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

Bättre än gamla nätet? Kolla  $\ell(\bar{w}_1)$ :

$$\hat{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \text{ ger } \hat{z} = \begin{pmatrix} 0.3 \\ 0.7 \end{pmatrix}, \quad \hat{u} = \begin{pmatrix} 0.3 \\ 0.7 \end{pmatrix}, \quad f(\hat{x}, \bar{w}_1) = 1.155$$

$$\tilde{x} = \begin{pmatrix} 1 \\ -1 \end{pmatrix} \text{ ger } \tilde{z} = \begin{pmatrix} 2.5 \\ -1.1 \end{pmatrix}, \quad \tilde{u} = \begin{pmatrix} 2.5 \\ 0 \end{pmatrix}, \quad f(\tilde{x}, \bar{w}_1) = 4.375 \Rightarrow$$

$$\ell(\bar{w}_1) = \frac{1}{2} \left( (1.155 - 1)^2 + (4.375 - 5)^2 \right) \approx 0.21 < 2.5 = \ell(\bar{w}_0)!$$

förbättring.

Fortsätt på samma sätt till  $\ell(\bar{w}_k)$  så lika ett nät

är köjd. Då har man sitt neuronät  $f(\bar{x})$  klart.

man kan tränat eller lärt upp det o man

kan nu sätta nya  $\bar{x}$  (ej träningsdata) o se vad

$y = f(\bar{x})$  blir.

Se mer om detta på kursens hemsida.