


- $d$  unità di ingresso, dimensione dei dati in ingresso  $\vec{x} \equiv (x_1, \dots, x_d)$   
( $d + 1$  se si include la soglia nel vettore dei pesi  $\vec{x}' \equiv (x_0, x_1, \dots, x_d)$ )
- $N_H$  unità nascoste (con output  $\vec{y} \equiv (y_1, \dots, y_{N_H})$ )
- $c$  unità di output, dimensione dei dati in output  $\vec{z} \equiv (z_1, \dots, z_c)$
- $c$ , dimensione dei dati desiderati  $\vec{t} \equiv (t_1, \dots, t_c)$
- $w_{ji}$  peso dalla unità di ingresso  $i$  alla unità nascosta  $j$
- $w_{kj}$  peso dalla unità nascosta  $j$  alla unità di output  $k$

La funzione errore, considerando che si hanno  $c$  unità di output, diventa

$$E[\vec{w}] = \frac{1}{2cN_{Tr}} \sum_{(\vec{x}^{(p)}, \vec{t}^{(p)}) \in Tr} \sum_{k=1}^c \left( t_k^{(p)} - z_k(\vec{x}^{(p)}) \right)^2$$

# Calcolo del gradiente per i pesi di una unità di output

Fissiamo gli indici  $\hat{k}$  e  $\hat{j}$ :



$$\begin{aligned}
 \frac{\partial E}{\partial w_{\hat{k}\hat{j}}} &= \frac{\partial}{\partial w_{\hat{k}\hat{j}}} \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)})^2 \\
 &= \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \frac{\partial}{\partial w_{\hat{k}\hat{j}}} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)})^2 \\
 &= \frac{1}{2cN_{Tr}} \sum_{p \in Tr} 2(t_{\hat{k}}^{(p)} - z_{\hat{k}}^{(p)}) \frac{\partial}{\partial w_{\hat{k}\hat{j}}} (t_{\hat{k}}^{(p)} - z_{\hat{k}}^{(p)}) \\
 &= \frac{1}{cN_{Tr}} \sum_{p \in Tr} (t_{\hat{k}}^{(p)} - z_{\hat{k}}^{(p)}) \frac{\partial}{\partial w_{\hat{k}\hat{j}}} (t_{\hat{k}}^{(p)} - \sigma(\vec{w}_{\hat{k}} \cdot \vec{y}^{(p)})) \\
 &= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} (t_{\hat{k}}^{(p)} - z_{\hat{k}}^{(p)}) \sigma'(\vec{w}_{\hat{k}} \cdot \vec{y}^{(p)}) y_{\hat{j}}^{(p)}
 \end{aligned}$$



# Calcolo del gradiente per i pesi di una unità nascosta

Fissiamo gli indici  $\hat{j}$  e  $\hat{i}$ :


$$\frac{\partial E}{\partial w_{\hat{j}\hat{i}}} = \frac{\partial}{\partial w_{\hat{j}\hat{i}}} \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)})^2$$

$$= \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c \frac{\partial}{\partial w_{\hat{j}\hat{i}}} (t_k^{(p)} - z_k^{(p)})^2$$

$$= \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c 2(t_k^{(p)} - z_k^{(p)}) \frac{\partial}{\partial w_{\hat{j}\hat{i}}} (-z_k^{(p)})$$


$$= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) \frac{\partial}{\partial w_{\hat{j}\hat{i}}} \sum_{j=1}^{N_H} w_{kj} y_j^{(p)}$$

$$= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) w_{k\hat{j}} \frac{\partial}{\partial w_{\hat{j}\hat{i}}} y_{\hat{j}}^{(p)}$$



$$= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) w_{k\hat{j}} \sigma'(\vec{w}_{\hat{j}} \cdot \vec{x}^{(p)}) \frac{\partial}{\partial w_{\hat{j}\hat{i}}} (\vec{w}_{\hat{j}} \cdot \vec{x}^{(p)})$$









$$\begin{aligned}
 & \frac{\partial}{\partial w_{\hat{j}\hat{i}}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)})^2 \\
 &= \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c \frac{\partial}{\partial w_{\hat{j}\hat{i}}} (t_k^{(p)} - z_k^{(p)})^2 \\
 &= \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c 2(t_k^{(p)} - z_k^{(p)}) \frac{\partial}{\partial w_{\hat{j}\hat{i}}} (-z_k^{(p)}) \\
 &= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) \frac{\partial}{\partial w_{\hat{j}\hat{i}}} \sum_{j=1}^{N_H} w_{kj} y_j^{(p)} \\
 &= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) w_{k\hat{j}} \frac{\partial}{\partial w_{\hat{j}\hat{i}}} y_{\hat{j}}^{(p)}
 \end{aligned}$$




$$= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) w_{k\hat{j}} \sigma'(\vec{w}_{\hat{j}} \cdot \vec{x}^{(p)}) \frac{\partial}{\partial w_{\hat{j}\hat{i}}} (\vec{w}_{\hat{j}} \cdot \vec{x}^{(p)})$$

$$= -\frac{1}{cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)}) \sigma'(\vec{w}_k \cdot \vec{y}^{(p)}) w_{k\hat{j}} \sigma'(\vec{w}_{\hat{j}} \cdot \vec{x}^{(p)}) x_{\hat{i}}^{(p)}$$

# Phase Forward



# Phase Backward





# Rete con uno strato nascosto e apprendimento stocastico

## Back-Propagation-1hl-stocastico( $Tr, \eta, \text{topologia rete}$ )

- Inizializza tutti i pesi a valori random piccoli
- Finché la condizione di terminazione non è verificata, fai

– Per ogni  $(\vec{x}, \vec{t})$  in  $Tr$ , fai

1. presenta  $\vec{x}$  alla rete e calcola il corrispondente output
2. Per ogni unità di output  $k$

$$\delta_k \leftarrow o_k(1 - o_k)(t_k - o_k)$$




3. Per ogni unità nascosta  $j$

$$\delta_j \leftarrow o_j(1 - o_j) \sum_{k \in \text{outputs}} w_{k,j} \delta_k$$

4. aggiorna tutti i pesi  $w_{p,q}$  della rete

$$w_{s,q} \leftarrow w_{s,q} + \eta \Delta w_{s,q} \quad \text{dove} \quad \Delta w_{s,q} = \begin{cases} \delta_s x_q & \text{se } s \in \text{nascoste} \\ \delta_s y_q & \text{se } s \in \text{outputs} \end{cases}$$

# Esempio di funzione errore



# Discesa di gradiente Batch e Stocastica

## Batch:

Fai finché condizione di terminazione non soddisfatta

1. calcola  $\nabla E_{Tr}[\vec{w}]$
2.  $\vec{w} \leftarrow \vec{w} - \eta \nabla E_{Tr}[\vec{w}]$

## Stocastica (Incrementale):

Fai finché condizione di terminazione non soddisfatta

- Per ogni esempio di apprendimento  $p$  in  $Tr$ 
  1. calcola  $\nabla E_{p \in Tr}[\vec{w}]$
  2.  $\vec{w} \leftarrow \vec{w} - \eta \nabla E_{p \in Tr}[\vec{w}]$

dove

$$E_{Tr}[\vec{w}] \equiv \frac{1}{2cN_{Tr}} \sum_{p \in Tr} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)})^2$$


$$E_{p \in Tr}[\vec{w}] \equiv \frac{1}{2c} \sum_{k=1}^c (t_k^{(p)} - z_k^{(p)})^2$$

La discesa di gradiente *Stocastica* (gradiente istantaneo) può approssimare quella *Batch* (gradiente esatto) con precisione arbitraria se  $\eta$  è sufficientemente piccolo



# Alcuni Problemi ...

- Scelta della topologia della rete  $\rightarrow$  determina lo Spazio delle Ipotesi;
- Scelta del passo di discesa (valore di  $\eta$ ):



- apprendimento lento..., ma calcolo di output veloce
- **MINIMI LOCALI !!**

**Bias Induttivo: sia nella rappresentazione che nella ricerca**

Il seguente teorema stabilisce l'universalità di reti feed-forward come approssimatori di funzioni continue.

**Teorema** Sia  $\varphi(\cdot)$  una funzione continua monotona crescente, limitata e noncostante. Si indichi con  $I_n$  l'ipercubo n-dimensionale  $[0, 1]^n$  e lo spazio delle funzioni continue su esso definite sia  $C(I_n)$ . Data una qualunque funzione  $f \in C(I_n)$  e  $\varepsilon > 0$ , allora esiste un intero  $M$  e insiemi di costanti reali  $\alpha_i, \theta_i$ , e  $w_{ij}$ , dove  $i = 1, \dots, M$  e  $j = 1, \dots, n$  tale che  $f(\cdot)$  possa essere approssimata da

$$F(x_1, \dots, x_n) = \sum_{i=1}^M \alpha_i \varphi\left(\sum_{j=1}^n w_{ij} x_j - \theta_i\right) \quad (1)$$

in modo tale che

$$|F(x_1, \dots, x_n) - f(x_1, \dots, x_n)| < \varepsilon \quad (2)$$

per tutti i punti  $[x_1, \dots, x_n] \in I_n$ .




Notare che qualunque funzione sigmoideale soddisfa le condizioni imposte nel teorema su  $\varphi(\cdot)$ . Inoltre, l'equazione (1) rappresenta l'output di una rete multistrato descritta come segue

1. la rete ha  $n$  nodi di input ed un singolo strato di unità nascoste con  $M$  unità; gli input sono denotati da  $x_1, \dots, x_n$ .
2. l' $i$ -esima unità ha associati i pesi  $w_{i1}, \dots, w_{in}$  e soglia  $\theta_i$ .
3. l'output della rete è una combinazione lineare degli output delle unità nascoste, dove i coefficienti della combinazione sono dati da  $\alpha_1, \dots, \alpha_M$ .

Quindi, data una tolleranza  $\varepsilon$ , una rete con un unico strato nascosto può approssimare una qualsiasi funzione in  $C(I_n)$ .

Si noti che il teorema afferma solo l'esistenza di una rete e non fornisce alcuna formula per il calcolo del numero  $M$  di unità nascoste necessarie per approssimare la funzione target con la tolleranza desiderata.

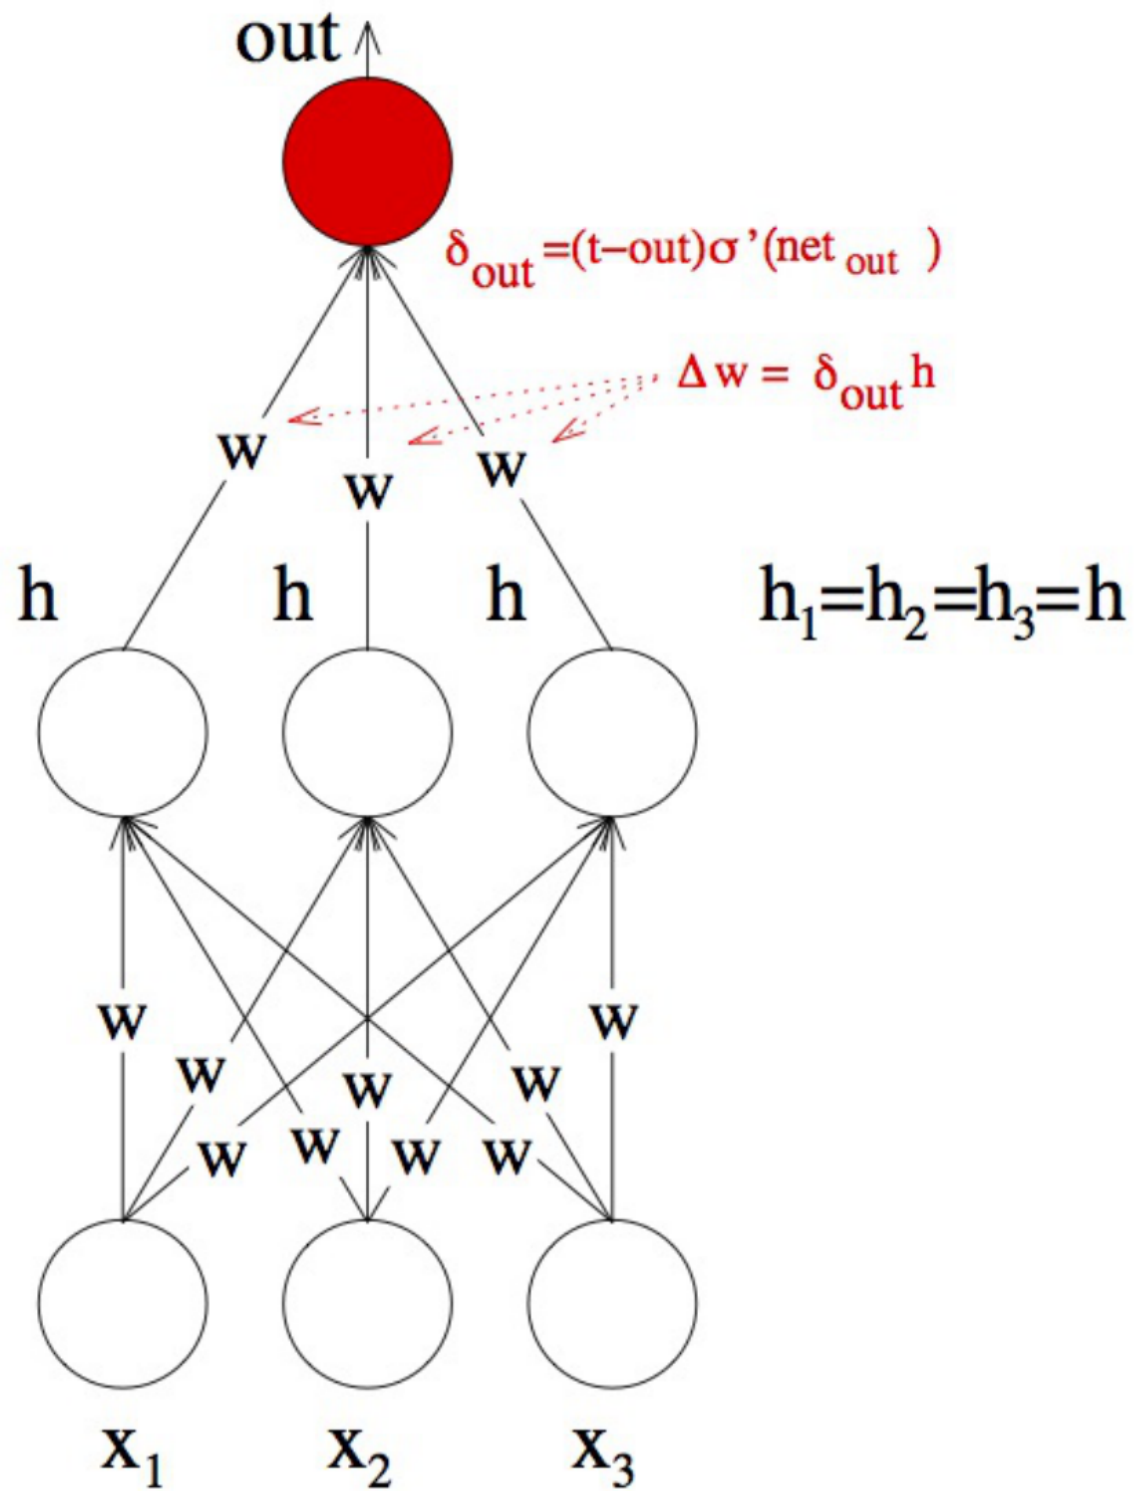




$$h_1 = h_2 = h_3$$



$$h_2 = h_3$$







h

n  
( $net_h$ )

