

Le reti neurali

Alberto Borghese

Università degli Studi di Milano
Laboratory of Applied Intelligent Systems (AIS-Lab)
Dipartimento di Scienze dell'Informazione
borghese@dsi.unimi.it



A.A. 2006-2007

1/44

<http://homes.dsi.unimi.it/~borghese>



Sommario



Dal neurone artificiale alle reti neurali

L'apprendimento in reti di perceptroni

Esempio con unità lineari ed accenno ad unità non-lineari

A.A. 2006-2007

2/44

<http://homes.dsi.unimi.it/~borghese>



Brains cause minds (J. Searle)



Le reti neurali

Se il neurone biologico consente l'intelligenza, perché non dovrebbe consentire l'intelligenza artificiale un neurone sintetico?

“.. a neural network is a system composed of *many simple processing elements* operating in *parallel* whose function is determined by *network structure, connection strengths*, and the *processing performed at computing elements* or nodes. ... Neural network architectures are inspired by the architecture of biological nervous systems, which use many simple processing elements operating in parallel to obtain high computation rates”. (DARPA, 1988)....



A cosa servono?



Le reti neurali offrono i seguenti specifici vantaggi nell'elaborazione dell'informazione:

- Apprendimento basato su esempi (non è richiesta l'elaborazione di un modello aderente alla realtà)
- Autoorganizzazione dell'informazione nella rete
- Robustezza ai guasti (codifica ridondante dell'informazione)
- Funzionamento in tempo reale (realizzazione HW)
- Basso consumo (0.5nW ÷ 4nW per neurone, 20W per il SN).



A.A. 2006-2007

5/44

<http://homes.dsi.unimi.it/~borgnese>



Cosa sono le reti neurali artificiali?



- Le reti neurali sono algoritmi non lineari per l'**approssimazione** di soluzioni di problemi dei quali non esiste un modello preciso (o se esiste è troppo oneroso computazionalmente), mediante l'utilizzo di esempi (dati e uscite) oppure per classificazioni. Connessioni con il dominio della statistica. *Modelli semi-parametrici.*
- Sono un capitolo importante negli argomenti di intelligenza artificiale.
- Da un altro punto di vista possono essere utilizzate per lo studio delle reti neurali naturali, ovvero dei processi cognitivi.

A.A. 2006-2007

6/44

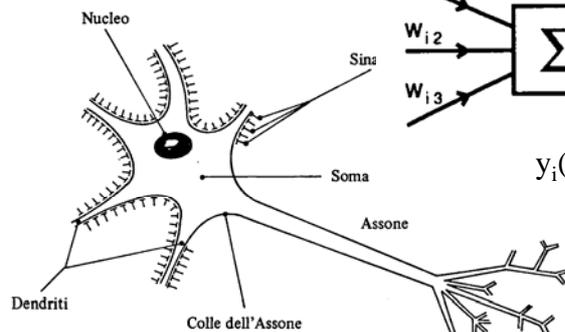
<http://homes.dsi.unimi.it/~borgnese>



Il neurone artificiale



- *Potenziale di azione (tutto o nulla).*
- *Integrazione nel soma.*
- *Soglia di attivazione.*



McCulloch-Pitts (1943)

$$y_i(t+1) = \Theta(w_{ij}u_j(t) - \mu_i)$$

$$\Theta(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{altrimenti} \end{cases}$$

$$-1 < x < +1$$

Neurone come elemento di calcolo universale: in grado di calcolare qualsiasi funzione logica (cioè implementabile in un computer).

A.A. 2006-2007

7/44

<http://homes.dsi.unimi.it/~borgnese>



Critica al modello di McCulloch-Pitts



- I neuroni reali non possono essere ridotti ad un dispositivo a soglia. Lo spike ha la sua forma continua che ha una durata di qualche millisecondo.
- Il tempo di propagazione lungo i dendriti non viene considerato.
- La variazione delle forma d'onda del potenziale di membrana lungo il dendrita non viene considerata.
- Gli input non sono sincroni.
- Le interazioni tra input non sono lineari.
- I pesi sono supposti costanti.

A.A. 2006-2007

8/44

<http://homes.dsi.unimi.it/~borgnese>

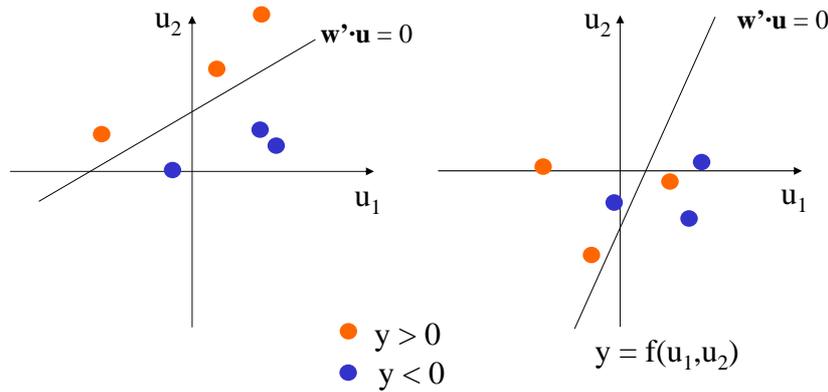


Funzioni linearmente separabili



Linearmente separabile

Non linearmente separabile



A.A. 2006-2007

9/44

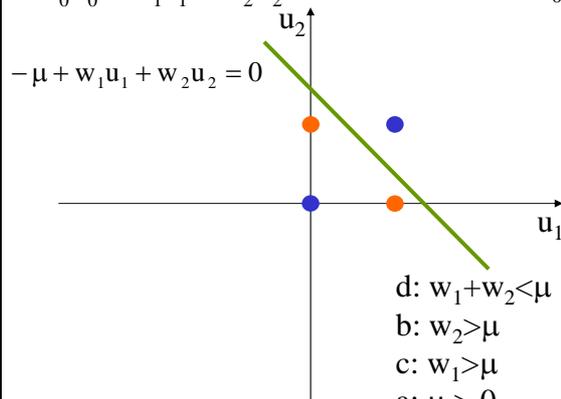
<http://homes.dsi.unimi.it/~borgnese>



La "morte" del neurone di McCulloch-Pitts (Minsky, 1969): XOR



$$w_0 u_0 + w_1 u_1 + w_2 u_2 = 0 \quad w' \cdot u = 0 \quad u_0 = 1$$



● $y(u_1, u_2, 1) = 1$

● $y(u_1, u_2, 1) = -1$

u_1	u_2	y	
0	0	-1	a
0	1	1	b
1	0	1	c
1	1	-1	d

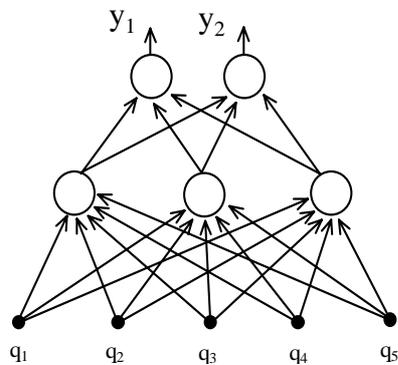
Il sistema di 4 equazioni non è risolvibile.

$w_1, w_2 > \mu$ e $w_1 + w_2 < \mu$ Impossibile!!

A.A. 2000 Si possono imparare solamente funzioni linearmente separabili ghese



Una rete neurale



Livelli di unità di attivazione

Collegamento in cascata

Input convergenti, output divergenti.

Capacità di approssimazione universale

Perceptrone: layered networks



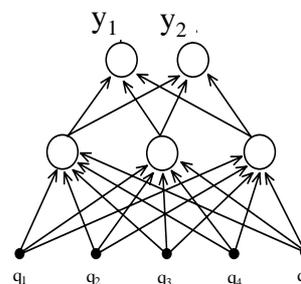
Costituenti delle reti neurali

Un neurone artificiale è costituito da:

- Un insieme di input (provenienti da altri neuroni)
- Un peso che rappresenta l'efficacia ed il segno della sinapsi.
- Una funzione di somma (pesata) degli input.
- Una funzione di attivazione che trasforma gli input nell'output del neurone.

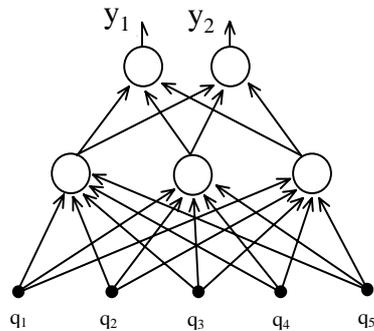
Una rete neurale è costituita da:

- Un insieme di neuroni artificiali.
- La connettività tra neuroni.





Le famiglie di modelli



Spiking neurons. Sono neuroni la cui uscita è il singolo spike. Modellazione realistica (e.g. McCullochPitts).

Connessionismo classico. Uscita compresa tra min – Max. Frequenza di scarica.

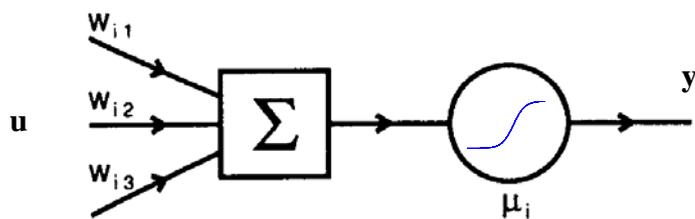
A.A. 2006-2007

13/44

<http://homes.dsi.unimi.it/~borghese>



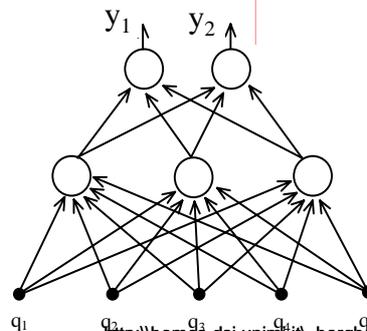
Le unità non lineari



$$y_i = g(w_{ij}u_j - \mu_i)$$

$g(\cdot)$ continua e differenziabile.

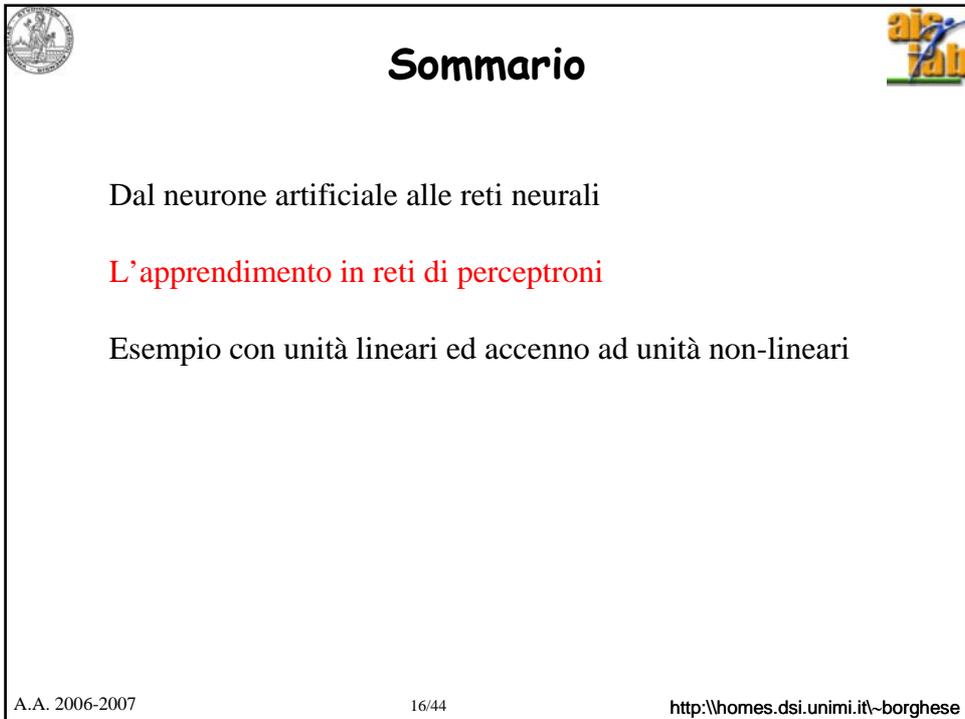
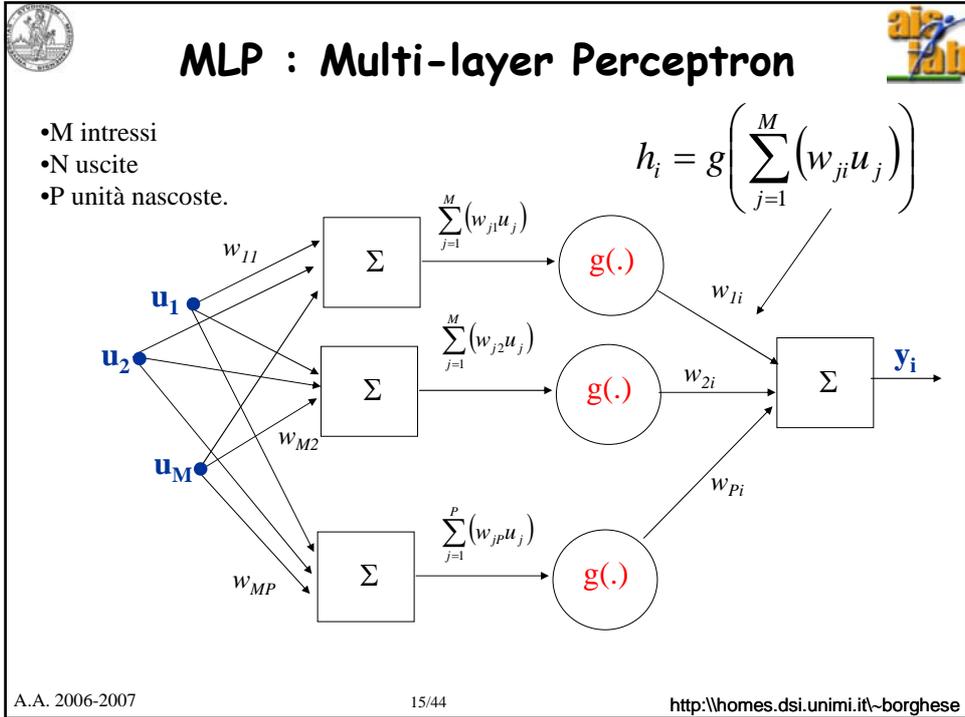
y_i frequenza di scarica.



A.A. 2006-2007

14/44

<http://homes.dsi.unimi.it/~borghese>





Complessità della funzione realizzabile

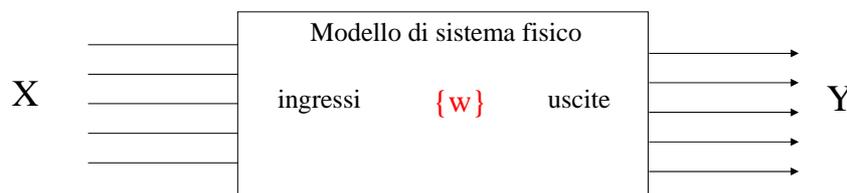


Quanti più neuroni artificiali vengono connessi tanto più la funzione complessiva approssimabile diviene più complessa

$$Y = |y_1, y_2, y_3, \dots, y_n|^T$$

$$y_i = g(X)$$

$$X = |x_1, x_2, x_3, \dots, x_m|^T$$



Reti neurali = approssimatori universali.

A.A. 2006-2007

17/44

<http://homes.dsi.unimi.it/~borgnese>



I vari tipi di apprendimento



Supervisionato (learning with a teacher). Viene specificato per ogni pattern di input, il pattern desiderato in output.

Non-supervisionato (learning without a teacher). I neuroni verranno associati a pattern di ingresso contigui. Clustering. Mappe neurali.

Apprendimento con rinforzo (reinforcement learning, learning with a distal teacher). L'ambiente fornisce un'informazione del tipo success or fail.

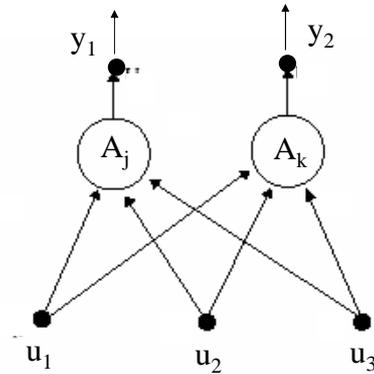
A.A. 2006-2007

18/44

<http://homes.dsi.unimi.it/~borgnese>



Apprendimento



Apprendimento è la modifica dei parametri $\{w_{ij}\}$ e $\{\mu_j\}$ in modo tale che la rete neurale approssimi la trasformazione tra i pattern di input e di output.

$$y_i = g(w_{ij}u_j - \mu_i)$$

A.A. 2006-2007

19/44

<http://homes.dsi.unimi.it/~borgnese>



Apprendimento supervisionato

$$\min_{\{w\}} J(\cdot) \quad J = \|Y^D - g(W^{\text{nuovo}}U)\| \leq \|Y^D - g(W^{\text{vecchio}}U)\|$$

Y^D è l'uscita desiderata nota.

- Si tratta di un problema di minimizzazione di una cifra di merito (J) sullo spazio di parametri W .

Soluzione iterativa (gradiente):

Obiettivo: se esiste una soluzione, trovare ΔW in modo iterativo tale che l'insieme dei pesi W^{nuovo} ottenuto come:

$$W^{\text{nuovo}} = W^{\text{vecchio}} + \Delta W$$

dia luogo a un errore sulle uscite di norma minore che con W^{vecchio}

A.A. 2006-2007

20/44

<http://homes.dsi.unimi.it/~borgnese>



Minimizzazione di funzioni di più variabili



$\min(J\{\mathbf{w}\} | \dots)$ funzione costo od errore

Gradiente:

$$\nabla J(\mathbf{w}) = \frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_1} \frac{w_1}{|w_1|} + \frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_2} \frac{w_2}{|w_2|} +$$

$$\frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_3} \frac{w_3}{|w_3|} + \frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_4} \frac{w_4}{|w_4|} + \dots$$

Modifico il valore dei pesi di una quantità proporzionale alla pendenza della funzione costo rispetto a quel parametro.

Estensione della tecnica del gradiente a più variabili.

$$\Delta \mathbf{w} = -\eta \nabla J(\mathbf{w}) \Leftrightarrow \Delta w_{ij} = -\eta \frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_{ij}}$$

Serve un' **approssimazione iniziale** per i pesi $\mathbf{W}_{ini} = \{w_j\}_{ini}$.



Apprendimento supervisionato tramite gradiente



Coppie input/output note.

Definizione di una funzione costo che misuri l'errore sull'uscita.

Modifica dei valori dei pesi in modo tale che la funzione costo sia minimizzata.

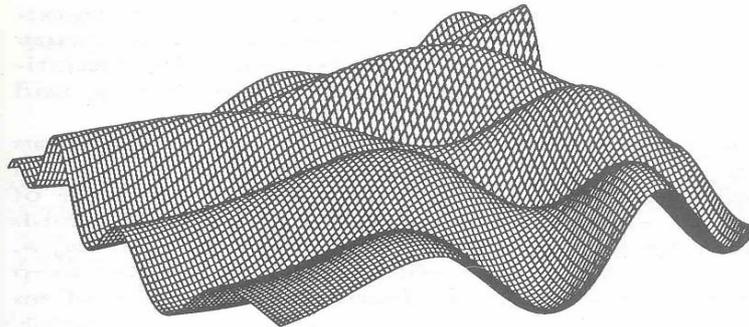
Reti multi-strato hanno elevata capacità computazionale, ma anche elevata complessità.



Problemi nell'apprendimento supervisionato tramite gradiente



- Nota: W_{ini} è generalmente casuale e può condizionare la convergenza degli algoritmi iterativi.
- I problemi di convergenza sono legati all'esistenza di minimi locali del funzionale $J(w | \dots)$



A.A. 2006-2007

23/44

<http://homes.dsi.unimi.it/~borgnese>



La pratica dell'apprendimento supervisionato



Fino a quando l'apprendimento non è stato completato:

1. Presentazione di un pattern di input / output.
2. Calcolo dell'output della rete con il pattern corrente.
3. Calcolo dell'incremento dei pesi.

Aggiornamento dei pesi.

Aggiornamento dei pesi:

- Per trial (ogni pattern)
- Per epoca (ogni insieme di pattern).

A.A. 2006-2007

24/44

<http://homes.dsi.unimi.it/~borgnese>



Funzione costo per unità di attivazione continue



Possiamo derivare una regola di apprendimento di spirito **Hebbiano** per una qualsiasi funzione di attivazione continua. Consideriamo un perceptrone ad un livello.

$$y = g\left(\sum_{j=1} w_{ij} u_j - \mu_i\right) = g\left(\sum_{j=0} (w_{ij} u_j)\right)$$

Si tratta di un problema di minimizzazione di una cifra di merito, J , sullo spazio di parametri W :

$$E(w) = \left\| \underbrace{y^D - g(W^{\text{nuovo}} U)}_{\text{Errore}} \right\| \leq \left\| y^D - g(W^{\text{vecchio}} U) \right\|$$

Errore

Devo trovare $\{w\}$: $E(w)$ è minimo.

$$E(\mathbf{w}) = \frac{1}{2} \sum_p \left[\sum_j (y_{jp}^D - y_{jp})^2 \right] = \frac{1}{2} \sum_p \left[\sum_j \left(y_{jp}^D - g\left(\sum_i w_{ij} u_{ip}\right) \right)^2 \right]$$



Sommario



Dal neurone artificiale alle reti neurali

L'apprendimento in reti di perceptroni

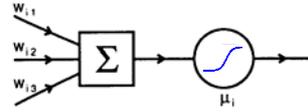
Esempio con unità lineari ed accenno ad unità non-lineari



Unità di attivazione lineari



$$y_j = g \left(\sum_{i=1}^M w_{ij} u_i - \mu_j \right) = g \left(\sum_{i=0}^M (w_{ij} u_i) \right)$$



Caso lineare ($g = 1$):

$$y_j = \sum_i w_{ij} u_i - \mu_j = \sum_i (w_{ij} u_i) \quad \implies \quad \mathbf{Y} = \mathbf{W} \mathbf{U}$$

Soluzione di un sistema lineare nei pesi!!

Condizione di risolubilità: \mathbf{W} di rango massimo \rightarrow
 $\{w\}$ sono linearmente indipendenti.



Unità lineari, soluzione iterativa



$$J = E(\mathbf{w}) = \frac{1}{2} \sum_p \left[\sum_j (y_{jp}^D - y_{jp})^2 \right] = \frac{1}{2} \sum_p \sum_j \left(y_{jp}^D - \left(\sum_i w_{ij} u_{ip} \right) \right)^2$$

$$\Delta w_{ij} = -\eta \frac{\partial}{\partial w_{ij}} \frac{1}{2} \sum_j \left(y_j^D - \left(\sum_i w_{ij} u_i \right) \right)^2$$

$$\Delta w_{ij} = +\eta \sum_j \left(y_j^D - \left(\sum_i w_{ij} u_i \right) \right) u_i = +\eta (y_j^D - y_j) u_i$$

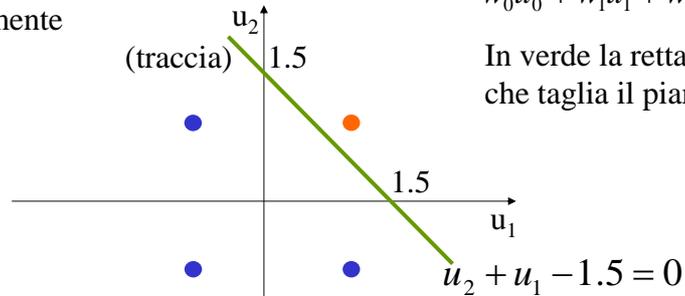
Hebbian learning

δ rule (Hoff, 1960)



Esempio - AND (grafica)

Troviamo la soluzione graficamente



$$w_0 u_0 + w_1 u_1 + w_2 u_2 = 0$$

In verde la retta $\mathbf{w}^T \mathbf{u} = 0$ che taglia il piano $u_1 u_2$.

$$u_2 + (w_1 / w_2) u_1 + w_0 / w_2 = 0$$

$$u_2 + u_1 - 1.5 = 0$$

⇓

$$w_1 / w_2 = 1 \quad w_0 / w_2 = -1.5 \quad \Rightarrow \quad w_2 = k \quad w_1 = k \quad w_0 = -1.5 * k$$

- $y(u_1, u_2, 1) = 1$
- $y(u_1, u_2, 1) = -1$

Esistono più soluzioni
Separabilità lineare.

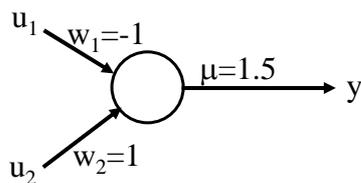
A.A. 2006-2007

29/44

<http://homes.dsi.unimi.it/~borgnese>



Esempio di delta rule - I



$$U = [-1, 1] \quad y^D = -1$$

$$\eta = 0.2$$

u_1	u_2	y^D
-1	-1	-1
-1	1	-1
1	-1	-1
1	1	1

$$y = \sum_{i=1} w_i u_i - \mu = \sum_{i=0} (w_i u_i) = (-1)(-1) + (1)(1) - 1.5 = 0.5 \gg -1$$

$$u_0 = -1 \quad w_0 = \mu$$

A.A. 2006-2007

30/44

<http://homes.dsi.unimi.it/~borgnese>

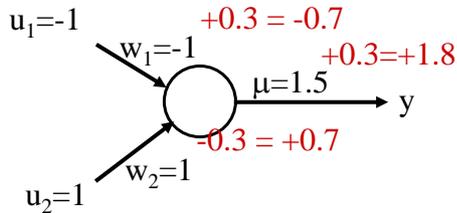


Esempio di delta rule - II



$$U = \{-1, 1\} \quad y^D = -1$$

$$\eta = 0.2$$



$$y = \sum_{i=1} (w_i u_i - \mu) =$$

$$\sum_{i=0} (w_i u_i) = -0.4 > -1$$

$$\Delta w_{ij} = +\eta (y_j^D - y_j) u_i$$

$$\Delta \mu = \Delta w_0 = \eta (y_i^D - y_i) u_0 = \eta (-1 - 0.5)(1) = +0.30$$

$$\Delta w_1 = \eta (y_i^D - y_i) u_1 = \eta (-1 - 0.5)(-1) = +0.30$$

$$\Delta w_2 = \eta (y_i^D - y_i) u_2 = \eta (-1 - 0.5)(1) = -0.30$$

A.A. 2006-2007

31/44

<http://homes.dsi.unimi.it/~borgnese>

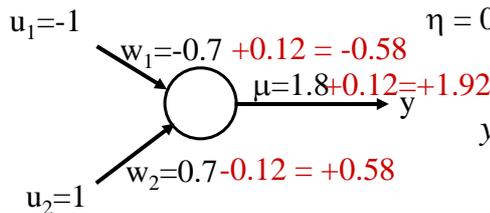


Esempio di delta rule - III



$$U = \{-1, 1\} \quad y^D = -1$$

$$\eta = 0.2$$



$$y = \sum_{i=1} w_i u_i - \mu = \sum_{i=0} (w_i u_i) = -0.4$$

$$-0.76$$

$$\Delta w_{ij} = +\eta (y_i^D - y_i) u_j$$

$$\Delta \mu = \Delta w_0 = \eta (y_i^D - y_i) u_0 = \eta (-1 - (-0.4))(1) = +0.12$$

$$\Delta w_1 = \eta (y_i^D - y_i) u_1 = \eta (-1 - (-0.4))(-1) = +0.12$$

$$\Delta w_2 = \eta (y_i^D - y_i) u_2 = \eta (-1 - (-0.4))(1) = -0.12$$

Che relazione c'è tra i pesi e la retta che separa le uscite positive da quelle negative?

A.A. 20

35e

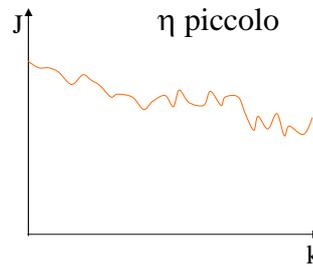
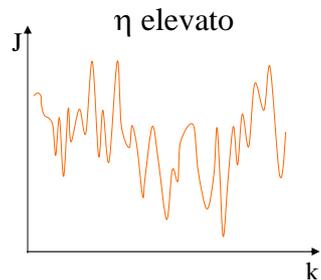


Ruolo di η – learning rate

$$\Delta w_{ij} = +\eta(y_j^D - y_j)u_i$$

Calmiera il Δw_{ij} per evitare che :

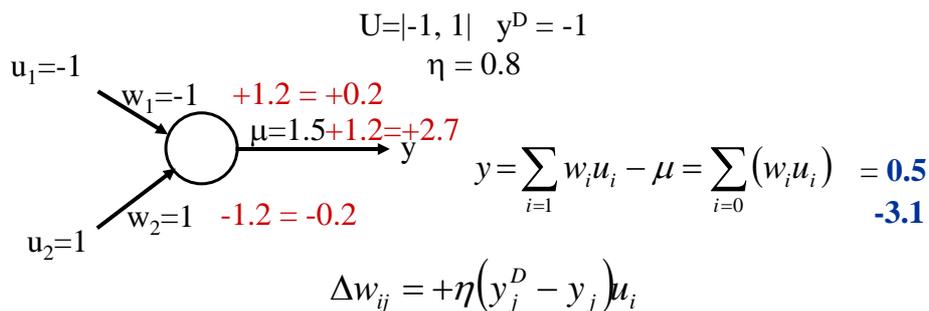
- Un peso sia specifico di un'unità ingresso-uscita.
- Oscillazioni durante l'apprendimento senza convergenza.



A.A. 2006-2007 η può variare durante l'addestramento. [p:\homes.dsi.unimi.it/~borgnese](http://homes.dsi.unimi.it/~borgnese)



Esempio di delta rule - Cattiva scelta di η



$$\Delta \mu = \Delta w_0 = \eta(y_i^D - y_i)u_0 = \eta(-1 - 0.5)(1) = +1.2$$

$$\Delta w_1 = \eta(y_i^D - y_i)u_1 = \eta(-1 - 0.5)(-1) = +1.2$$

$$\Delta w_2 = \eta(y_i^D - y_i)u_2 = \eta(-1 - 0.5)(1) = -1.2$$

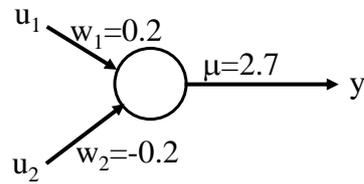
A.A. 2006-2007

34/44

<http://homes.dsi.unimi.it/~borgnese>



Esempio di specializzazione sui pattern a, b, c



u_1	u_2	y^D	
-1	-1	-1	a
-1	1	-1	b
1	-1	-1	c
1	1	1	d

a $y = \sum_{i=1} w_i u_i - \mu = \sum_{i=0} (w_i u_i) = (0.2)(-1) + (-0.2)(1) - 2.7 = -3.1$

b $y = \sum_{i=1} w_i u_i - \mu = \sum_{i=0} (w_i u_i) = (0.2)(-1) + (-0.2)(1) - 2.7 = -2.9$

c $y = \sum_{i=1} w_i u_i - \mu = \sum_{i=0} (w_i u_i) = (0.2)(1) + (-0.2)(-1) - 2.7 = -2.3$

d $y = \sum_{i=1} w_i u_i - \mu = \sum_{i=0} (w_i u_i) = (0.2)(1) + (-0.2)(1) - 2.7 = -2.7$

Errato su d. Specializzazione su a, b, c

A.A. 2006-2007

35/44

<http://homes.dsi.unimi.it/~borgnese>



Unità non-lineari, soluzione iterativa



$$J = E(\mathbf{w}) = \frac{1}{2} \sum_p \left[\sum_j (y_{jp}^D - y_{jp})^2 \right] = \frac{1}{2} \sum_p \left[\sum_j \left(y_{jp}^D - g \left(\sum_i w_{ij} u_{ip} \right) \right)^2 \right]$$

$$\Delta w_{ijp} = -\eta \frac{\partial}{\partial w_{ij}} \frac{1}{2} \sum_j \left(y_{jp}^D - g \left(\sum_i w_{ij} u_{ip} \right) \right)^2 =$$

$$\eta \sum_j \left(y_{jp}^D - g \left(\sum_i w_{ij} u_{ip} \right) \right) g' \left(\sum_i w_{ij} u_{ip} \right) u_i = +\eta \underbrace{\left(y_{jp}^D - y_{jp} \right) g' \left(\sum_i w_{ij} u_{ip} \right)}_{\delta \text{ rule}} u_{ip}$$

δ rule

A.A. 2006-2007

36/44

<http://homes.dsi.unimi.it/~borgnese>



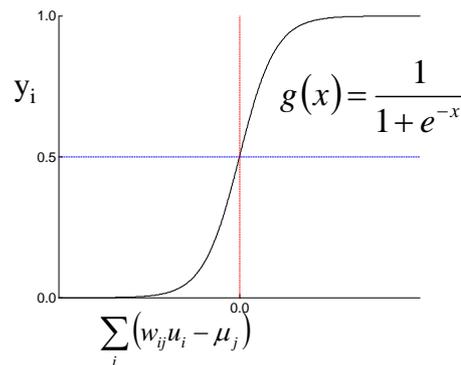
Perceptrone con unità di attivazione logistiche



$$g'(x) = g(x) \cdot (1 - g(x))$$

$$y_j = g\left(\sum_i w_{ij} u_i - \mu_j\right)$$

$$\begin{aligned} g'(x) &= \frac{e^{-x}}{(1 + e^{-x})^2} = \\ &= \frac{1}{1 + e^{-x}} \left(1 - \frac{1}{1 + e^{-x}}\right) = \\ &= g(x)(1 - g(x)) \end{aligned}$$



A.A. 2006-2007

37/44

<http://homes.dsi.unimi.it/~borgnese>



Update dei pesi per funzione logistica



$$J = E(\mathbf{w}) = \frac{1}{2} \sum_p \left[\sum_j (y_{jp}^D - y_{jp})^2 = \frac{1}{2} \sum_j \left(y_{jp}^D - g\left(\sum_i w_{ij} u_{ip}\right) \right)^2 \right]$$

$$\Delta w_{ijp} = +\eta \sum_j (y_{jp}^D - g(\cdot)) g'(\cdot) u_i = +\eta \underbrace{(y_{jp}^D - y_j) y_j (1 - y_j)}_{\delta \text{ rule}} u_{ip}$$

δ rule

NB $y_i \in [0, 1]$. Per $y_i = 0$ o $y_i = 1$ non c'è apprendimento anche se l'uscita è sbagliata. Quando si verifica questa situazione?

Si cerca di mantenere le unità lontane della saturazione.

A.A. 2006-2007

38/44

<http://homes.dsi.unimi.it/~borgnese>

Un po' di tassonomia

Perceptrone semplice: A diagram showing three input nodes connected to three output nodes, each labeled 'MCP'.

Perceptrone multistrato: A diagram showing three input nodes connected to two hidden nodes (labeled 'MCP') which are then connected to one output node (labeled 'MCP').

Ricorrente: A diagram showing three input nodes connected to two hidden nodes (labeled 'MCP') which are then connected to one output node (labeled 'MCP'). A feedback loop with a delay element τ connects the output back to the hidden nodes.

Ricorrente completamente connessa: autoassociativa (ingresso=stato): A diagram showing two input nodes connected to two hidden nodes (labeled 'MCP') which are then connected to two output nodes (labeled 'MCP'). Each hidden node is connected to each output node. A feedback loop with a delay element τ connects the output back to the hidden nodes.

Spesso unità lineari

Oltre input/output si definiscono anche unità nascoste (**hidden units**)

A.A. 2006-2007 39/44 <http://homes.dsi.unimi.it/~borgnese>

Riassunto - topologia

I neuroni connessioneisti sono basati su:

- Ricevere una somma pesata degli ingressi.
- Trasformarla secondo una funzione non-lineare (scalino o logistica)
- Inviare il risultato di questa funzione all'uscita o ad altre unità'.

Le reti neurali sono topologie ottenute connettendo tra loro i neuroni in modo opportuno e riescono a calcolare funzioni molto complesse.

A.A. 2006-2007 40/44 <http://homes.dsi.unimi.it/~borgnese>



Riassunto - Apprendimento



Algoritmi iterativi per adattare il valore dei parametri (pesi).

Definizione di una funzione costo che misura la differenza tra valore fornito e quello desiderato.

Algoritmo (gradiente) che consente di aggiornare i pesi in modo da minimizzare la funzione costo.

Training per pattern (specializzazione) o per epoche.



Problemi



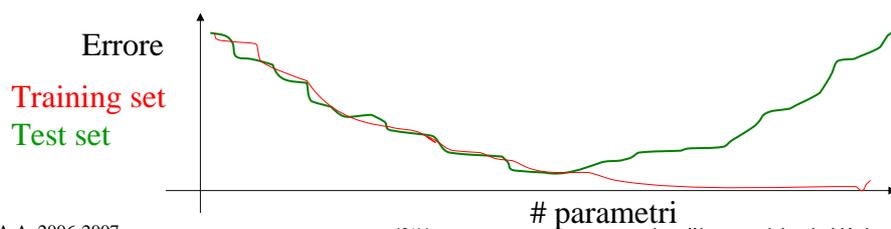
Quando si termina l'algoritmo di apprendimento?

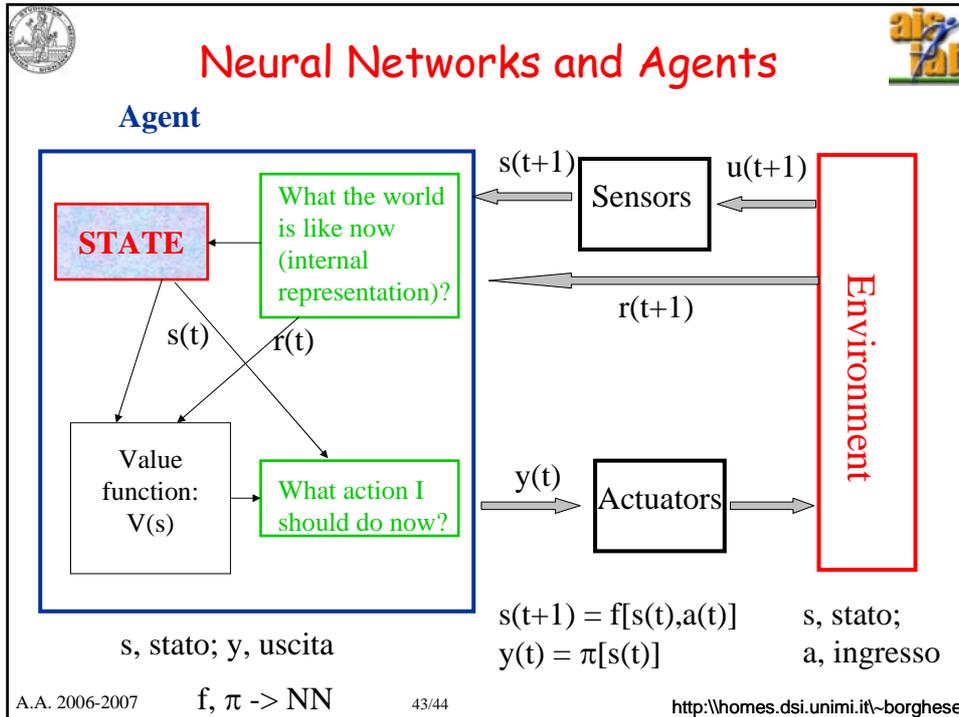
Bootstrap – Vengono estratti pattern con ripetizioni.

Cross-Validation - Errore sull'insieme di training =
Errore sull'insieme di test.

Utilizzare lo “structural risk” invece dell’”empirical risk”.

Si vuole evitare che la rete si specializzi troppo sui pattern di training e non sia in grado di interpolare.





Sommario

Dal neurone artificiale alle reti neurali

L'apprendimento in reti di perceptroni

Esempio con unità lineari ed accenno ad unità non-lineari

A.A. 2006-2007 44/44 <http://homes.dsi.unimi.it/~borgnese>