

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. 2007-2008

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. 2007-2008

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. 2007-2008

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. 2007-2008

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. 2007-2008

7/44

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



Critica al modello di McCulloch-Pitts



- 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. 2007-2008

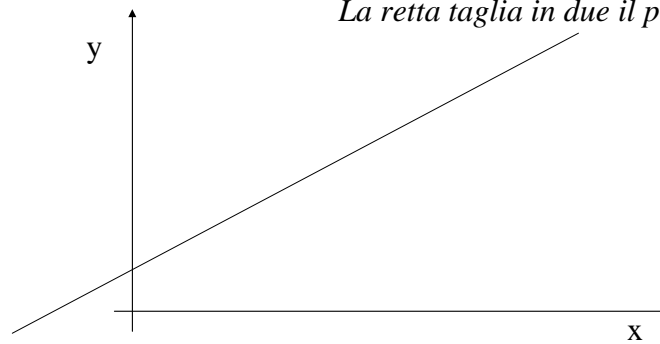
8/44

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



Rappresentazione della retta

La retta taglia in due il piano



$$y = mx + q \quad \text{singolarità se la retta è // } y$$

$$x_2 = mx_1 + q$$

$$w_1x_1 + w_2x_2 + q = 0$$

$$w_0 + w_1x_1 + w_2x_2 = 0 \Leftrightarrow \mathbf{w} \cdot \mathbf{x} = 0 \quad \text{con } x_0 \equiv 1; w_0 = -q$$

A.A. 2007-2008

9/44



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



Funzioni linearmente separabili

Linearmente separabile

Non linearmente separabile



- $y > 0$
- $y < 0$

A.A. 2007-2008

10/44

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

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

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

$-\mu + w_1 u_1 + w_2 u_2 = 0$

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

d: $w_1 + w_2 < \mu$
 b: $w_2 > \mu$
 c: $w_1 > \mu$
 a: $\mu > 0$

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

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.

A.A. 200 Si possono imparare solamente funzioni linearmente separabili ghese

Nuovi modelli di reti neurali

Livelli di unità di attivazione

Collegamento in cascata

Input convergenti, output divergenti.

Capacità di approssimazione universale

Perceptrone: layered networks, flusso unidirezionale dell'elaborazione.

A.A. 2007-2008 12/44 http://homes.dsi.unimi.it/~borghese



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.




A.A. 2007-2008

13/44

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



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. 2007-2008

14/44

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

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. 2007-2008 15/44
<http://homes.dsi.unimi.it/~borghese>

MLP : Multi-layer Perceptron

- M intressi
- N uscite
- P unità nascoste.

$$h_i = g\left(\sum_{j=1}^M (w_{ji}u_j)\right)$$

Unità neurale

A.A. 2007-2008 16/44
<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.



Sommario



Dal neurone artificiale alle reti neurali

L'apprendimento in reti di perceptroni

Esempio con unità lineari ed accenno ad unità non-lineari



I vari tipi di apprendimento



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

Non-supervisionato (learning without a teacher). I neuroni identificano pattern di ingresso simili. 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. 2007-2008

19/44


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



Lo spirito dell'apprendimento supervisionato



La rete opera una trasformazione dallo spazio di input allo spazio di output.



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. 2007-2008

20/44

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



Apprendimento supervisionato

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

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:

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

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



Minimizzazione di funzioni di più variabili

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

$$\text{Gradiente: } \nabla J(w) = \frac{\partial J(\{w\} | \dots)}{\partial w_1} \frac{w_1}{|w_1|} + \frac{\partial J(\{w\} | \dots)}{\partial w_2} \frac{w_2}{|w_2|} + \frac{\partial J(\{w\} | \dots)}{\partial w_3} \frac{w_3}{|w_3|} + \frac{\partial J(\{w\} | \dots)}{\partial w_4} \frac{w_4}{|w_4|} + \dots$$

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.

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

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



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'errore
4. Calcolo dei gradienti
5. Calcolo dell'incremento dei pesi.

Aggiornamento dei pesi.

Aggiornamento dei pesi:

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



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. 2007-2008

25/44

<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 :

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

Errore

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

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

A.A. 2007-2008

26/44

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



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. 2007-2008

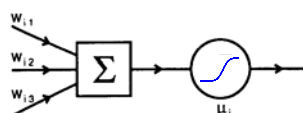
27/44

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



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.

A.A. 2007-2008

28/44

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



Unità lineari, soluzione iterativa



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

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

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

Hebbian learning

δ rule (Hoff, 1960)

A.A. 2007-2008

29/44


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



Esempio - AND (grafica)



Troviamo la soluzione graficamente



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

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

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

$$u_2 + u_1 - 1.5 = 0$$

\Downarrow

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

$$\bullet \quad u_2 + u_1 - 1.5 = 0$$

$$\bullet \quad y(u_1, u_2, 1) = 1$$

$$\bullet \quad y(u_1, u_2, 1) = -1$$

$$w_0 = -1.5$$

$$w_1 = 1$$

$$w_2 = 1$$

Esistono più soluzioni
Separabilità lineare.


A.A. 2007-2008

30/44

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



Esempio di delta rule - I



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

u_1	u_2	y	y^D
-1	-1	-1	-1
-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. 2007-2008

31/44

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




Esempio di delta rule - II



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

$$\eta = 0.2$$



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

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

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

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

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

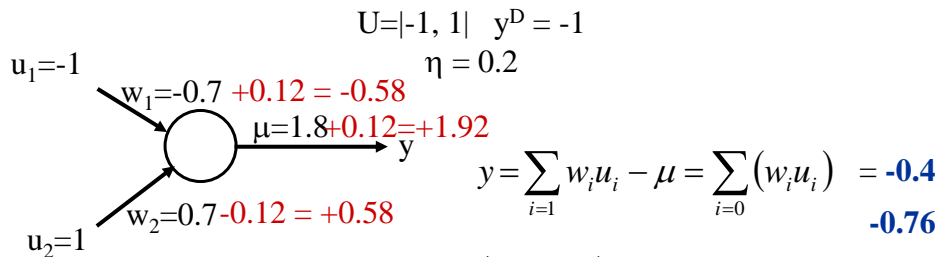
A.A. 2007-2008

32/44

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



Esempio di delta rule - III



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

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

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

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

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

A.A. 20

ese




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. 2007-2008

η può variare durante l'addestramento. p:\whomes.dsi.unimi.it/~borghese



Esempio di delta rule - Cattiva scelta di η



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

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

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

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


A.A. 2007-2008

35/44

<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. 2007-2008

36/44

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



Unità non-lineari, soluzione iterativa



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

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

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

δ rule

A.A. 2007-2008

37/44

<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. 2007-2008

38/44

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



Update dei pesi per funzione logistica



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

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


↗ 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 dalla saturazione.



Un po' di tassonomia




Perceptrone semplice




Perceptrone multistrato

Spesso unità lineari

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



Ricorrente



Ricorrente completamente connessa: autoassociativa (ingresso=stato)



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 unita'.

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



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