



Reti Neurali



Reti Neurali in Generale

Bisogna distinguere due motivazioni diverse nello studiare Reti Neurali Artificiali:

1. riprodurre (e quindi comprendere) il cervello umano
 - modellare tutto o almeno parti del cervello umano in modo affidabile
 - riprodurre fedelmente fenomeni neurofisiologici
 - verificare sperimentalmente se il modello proposto riproduce i dati biologici
2. estrarre i principi fondamentali di calcolo utilizzati dal cervello
 - non importa riprodurre il cervello umano, ma solo evincere quali sono i principi fondamentali di calcolo che esso utilizza
 - semplificazioni ed astrazioni del cervello umano sono permesse, anzi, sono lo strumento principale di lavoro
 - produrre un sistema artificiale che sia eventualmente diverso dal cervello umano ma che riproduca alcune delle sue funzioni, magari in modo più veloce ed efficiente (metafora del volo: **aereo** “contro” **uccello**)

A noi interessa la seconda motivazione.

I modelli di Reti Neurali Artificiali proposti in questo ambito sono molteplici e con scopi diversi.

As esempio, esistono modelli per

- l'apprendimento supervisionato (Classificazione, Regressione, Serie Temporali, ...);
- l'apprendimento non supervisionato (Clustering, Data Mining, Self-Organization maps,...);
- realizzare Memorie Associative;
- ...

Tali modelli, in generale, differiscono per

- topologia della rete
- funzione calcolata dal singolo neurone
- algoritmo di apprendimento
- modalità di apprendimento (utilizzo dei dati di apprendimento)

Quando è opportuno utilizzare una Rete Neurale Artificiale ?

- l'input è ad alta dimensionalità (discreto e/o a valori reali)
- l'output è a valori discreti (classificazione) o a valori reali (regressione)
- l'output è costituito da un vettore di valori
- i dati possono contenere rumore
- la forma della funzione target è totalmente sconosciuta
- la soluzione finale non deve essere compresa da un esperto umano ("black-box problem")

Esempi di campi applicativi

- riconoscimento del parlato
- classificazione di immagini
- predizione di serie temporali in finanza
- controllo di processi industriali


Reti Neurali Artificiali

Le Reti Neurali Artificiali si ispirano al cervello umano:


- Il cervello umano è costituito da circa 10^{10} **neuroni** fortemente interconnessi fra loro;
- Ogni neurone possiede un **numero di connessioni** che va da circa 10^4 a circa 10^5 ;
- Il **tempo di risposta** di un neurone è circa **0.001 secondi**;
- Considerando che per **riconoscere il contenuto di una scena** un umano impiega circa **0.1 secondi**, ne consegue che il cervello umano sfrutta pesantemente il **calcolo parallelo**: infatti, in questo caso, non può effettuare più di 100 calcoli seriali [$0.1/0.001=100$].

Neurone Artificiale

Alternativa 1: hard-threshold \rightarrow iperpiano!!



Alternativa 2: neurone sigmoidale \rightarrow funzione derivabile





Reti Neurali Artificiali










Una Rete Neurale Artificiale è un sistema costituito da unità interconnesse che calcolano **funzioni (numeriche) non-lineari**:

- le unità di **input** rappresentano le variabili di ingresso;
- le unità di **output** rappresentano le variabili di uscita;
- le unità di **nascoste** (se ve ne sono) rappresentano variabili interne che codificano (dopo l'apprendimento) le correlazioni tra le variabili di input relativamente al valore di output che si vuole generare.
- sulle connessioni fra unità sono definiti **pesi** adattabili (dall'algoritmo di apprendimento).

Reti Neurali Feed-forward (un solo livello nascosto)



Superficie di Decisione



Singolo Neurone con Hard-Threshold

Singolo Neurone con Hard-Threshold: iperpiani!

$$\mathcal{H} = \{f_{(\vec{w}, b)}(\vec{y}) \mid f_{(\vec{w}, b)}(\vec{y}) = \text{sign}(\vec{w} \cdot \vec{y} + b), \vec{w}, \vec{y} \in \mathbb{R}^n, b \in \mathbb{R}\}$$

che possiamo riscrivere come

$$\mathcal{H} = \{f_{(\vec{w}')}(\vec{y}') \mid f_{(\vec{w}')}(\vec{y}') = \text{sign}(\vec{w}' \cdot \vec{y}'), \vec{w}', \vec{y}' \in \mathbb{R}^{n+1}\}$$

se effettuiamo le seguenti trasformazioni

$$\vec{w}' = [b, \vec{w}]^t \quad \vec{y}' = [1, \vec{y}]^t$$

Faremo riferimento a tale neurone (e all'algoritmo di apprendimento associato) come Perceptron

Problemi: Quale è il potere computazionale di un Perceptron ?

Come definire un algoritmo di apprendimento ?

Funzioni Booleane

Consideriamo input binari e funzioni booleane.

Ogni funzione booleana può essere rappresentata tramite gli operatori **or**, **and**, **not** (in effetti, questo non è necessario se usiamo il **nand** o il **nor**)

Può un Perceptron implementare l'operatore **or** ? **Si !**

Es. $\vec{y}' \in \{0, 1\}^{n+1}$, $w'_0 = -0.5$, $w'_i = 1$, $i = 1, \dots, n$

Può un Perceptron implementare l'operatore **and** ? **Si !**

Es. $\vec{y}' \in \{0, 1\}^{n+1}$, $w'_0 = -n + 0.5$, $w'_i = 1$, $i = 1, \dots, n$

L'operatore **not** si realizza banalmente con un Perceptron con una singola connessione (fare per esercizio).

Esiste una funzione booleana semplice che non può essere realizzata da un Perceptron ?

(l'abbiamo già vista quando abbiamo calcolato la VC-dimension di \mathcal{H} !!)

Apprendimento di funzioni linearmente separabili

Assumiamo di avere esempi di funzioni linearmente separabili.

Algoritmo di Apprendimento per il Perceptron



ingresso: insieme di apprendimento $Tr = \{(\vec{x}, t)\}$, dove $t \in \{-1, +1\}$

1. inizializza il vettore dei pesi \vec{w} al vettore nullo (tutte le componenti a 0);
2. **ripeti**
 - (a) seleziona (a caso) uno degli esempi di apprendimento (\vec{x}, t)
 - (b) **se** $out = sign(\vec{w} \cdot \vec{x}) \neq t$ **allora**

$$\vec{w} \leftarrow \vec{w} + (t - out)\vec{x}$$

Apprendimento per Perceptron

Interpretazione geometrica



Apprendimento per Perceptron

Non necessariamente un singolo passo di apprendimento 2(b) riuscirà a modificare il segno dell'output: potrebbero servire molti passi.

Per rendere più stabile l'apprendimento si aggiunge un coefficiente di apprendimento η

$$\vec{w} \leftarrow \vec{w} + \eta(t - out)\vec{x}$$

con $\eta > 0$ e preferibilmente $\eta < 1$

Questo evita che il vettore dei pesi subisca variazioni troppo "violente" ogni volta che il passo 2(b) viene eseguito, e quindi cerca di evitare che esempi precedentemente ben classificati diventino classificati erroneamente a causa della forte variazione del vettore dei pesi.

Se l'insieme di apprendimento è LINEARMENTE SEPARABILE, si dimostra che l'algoritmo di apprendimento per il Perceptron termina con una soluzione in un numero finito di passi, altrimenti \vec{w} CICLA in un insieme di vettori peso non necessariamente ottimali (cioè che commettono il minimo numero possibile di errori)