


### Esercizio 1 (4 punti)

Si consideri la seguente rete neurale artificiale composta da due perceptron:



Si ricavi la formula di aggiornamento dei pesi della rete. In particolare, si definisca la formula per il peso  $v_1$ .

### Esercizio 2 (6 punti)

Si consideri il seguente modello dato da una mistura di  $K$  distribuzioni:

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k p(\mathbf{x}|k)$$

Dove  $p(\mathbf{x})$  è la probabilità della tupla  $\mathbf{x}$ ,  $\pi_k$  è la probabilità a priori della  $k$ -esima distribuzione, mentre  $p(\mathbf{x}|k)$  è la probabilità condizionata della tupla  $\mathbf{x}$  data la  $k$ -esima distribuzione.

Si supponga che il vettore  $\mathbf{x}$  possa essere suddiviso in due parti tali per cui  $\mathbf{x} = \{\mathbf{x}_a, \mathbf{x}_b\}$ . Dimostrare che la funzione della probabilità condizionata  $p(\mathbf{x}_b|\mathbf{x}_a)$  è a sua volta una mistura di distribuzioni. Definire la complete data likelihood in termini di  $p(\mathbf{x}_b|\mathbf{x}_a)$ .

### Esercizio 3 (3 punti)

Si consideri il seguente insieme di 15 item set frequenti di dimensione 3:

$\{\{1\ 4\ 5\}, \{1\ 2\ 4\}, \{4\ 5\ 7\}, \{1\ 2\ 5\}, \{4\ 5\ 8\}, \{1\ 5\ 9\}, \{1\ 3\ 6\}, \{2\ 3\ 4\}, \{5\ 6\ 7\}, \{3\ 4\ 5\}, \{3\ 5\ 6\}, \{3\ 5\ 7\}, \{6\ 8\ 9\}, \{3\ 6\ 7\}, \{3\ 6\ 8\}\}$

Calcolare il relativo hash tree, sapendo che una foglia dell'albero può contenere al massimo 3 item set, e che la funzione hash è la seguente:

$$\text{hash}(x) = x \bmod 3$$

ovvero il resto della divisione intera tra  $x$  e 3.

# Soluzione

---

## Esercizio 1

La funzione net è la seguente:

$$y = \text{net}(\mathbf{x}) = w_0 + w_1x_1 + w_3x_2 + w_2(v_0 + v_1x_1 + v_2x_2)$$

La funzione di aggiornamento del vettore dei pesi  $\mathbf{w}$  è:

$$\mathbf{w}^{(t+1)} = \mathbf{w}^{(t)} + \Delta\mathbf{w}^{(t)}$$

Dove, usando la funzione sigmoideale:

$$\Delta\mathbf{w}^{(t)} = \eta(\text{class}(\mathbf{x}) - \text{net}(\mathbf{x}))\mathbf{x}$$

con  $\eta$  tasso di learning.

Per ottenere in un processo iterativo un valore ottimale per il calcolo dei pesi, è sufficiente minimizzare il valore atteso dell'errore di predizione, definito come:

$$E[\mathbf{w}] = \frac{1}{2} \sum_x (\text{class}(\mathbf{x}) - \text{net}(\mathbf{x}))^2$$

Questo procedimento può essere svolto iterativamente, con l'obiettivo:

$$E[\mathbf{w}^{(t+1)}] \leq E[\mathbf{w}^{(t)}]$$

Si noti che:

$$\Delta\mathbf{w}^{(t)} = \eta \nabla E[\mathbf{w}^{(t)}]$$

Tramite le serie di Taylor al primo ordine si ottiene:

$$E[\mathbf{w}^{(t+1)}] = E[\mathbf{w}^{(t)}] - \eta \|\nabla E[\mathbf{w}^{(t)}]\|^2$$

Volendoci concentrare su  $v_1$ , il calcolo del gradiente si riduce al calcolo di una derivata.

$$E[v_1^{(t+1)}] = E[v_1^{(t)}] - \eta \left( \frac{\partial}{\partial v_1} E[v_1^{(t)}] \right)^2$$

Dove

$$\frac{\partial}{\partial v_1} E[v_1^{(t)}] = \sum_x [-x_1(\text{class}(\mathbf{x}) - \text{net}(\mathbf{x}))]$$

## Esercizio 2

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k p(\mathbf{x}|k) = p(\mathbf{x}_b, \mathbf{x}_a) = \sum_{k=1}^K \pi_k p(\mathbf{x}_b, \mathbf{x}_a|k)$$

Ma:

$$p(\mathbf{x}_b, \mathbf{x}_a) = p(\mathbf{x}_b | \mathbf{x}_a) p(\mathbf{x}_a)$$

quindi:

$$p(\mathbf{x}_b | \mathbf{x}_a) p(\mathbf{x}_a) = \sum_{k=1}^K \pi_k p(\mathbf{x}_b | \mathbf{x}_a, k) p(\mathbf{x}_a | k)$$

Da cui:

$$p(\mathbf{x}_b | \mathbf{x}_a) = \frac{1}{p(\mathbf{x}_a)} \sum_{k=1}^K \pi_k p(\mathbf{x}_b | \mathbf{x}_a, k) p(\mathbf{x}_a | k) = \sum_{k=1}^K \frac{p(\mathbf{x}_b | \mathbf{x}_a, k) p(\mathbf{x}_a | k) \pi_k}{p(\mathbf{x}_a)}$$

Dal teorema di Bayes:

$$\frac{p(\mathbf{x}_a | k) \pi_k}{p(\mathbf{x}_a)} = p(k | \mathbf{x}_a)$$

Quindi:

$$p(\mathbf{x}_b | \mathbf{x}_a) = \sum_{k=1}^K p(\mathbf{x}_b | \mathbf{x}_a, k) p(k | \mathbf{x}_a)$$

Che è una mistura.

Procediamo con il calcolo della complete data likelihood.

$$L(\theta | \mathbf{x}_1, \dots, \mathbf{x}_n) = \prod_{i=1}^n p(\mathbf{x}_i) = \prod_{i=1}^n \sum_{k=1}^K \pi_k p(\mathbf{x}_i | k)$$

Sfruttando le proprietà del logaritmo possiamo calcolare la log-likelihood

$$\log L(\theta | \mathbf{x}_1, \dots, \mathbf{x}_n) = \sum_{i=1}^n \log \left( \sum_{k=1}^K \pi_k p(\mathbf{x}_i | k) \right)$$

Introduciamo delle variabili latenti  $y_{ik}$  tali per cui  $y_{ik} = 1$  se l' $i$ -esima tupla è generata dalla  $k$ -esima componente, 0 altrimenti.

$$\log L(\theta | \mathbf{x}_1, \dots, \mathbf{x}_n) = \sum_{i=1}^n \log \left( \sum_{k=1}^K y_{ik} \pi_k p(\mathbf{x}_i | y_{ik}, k) \right)$$

UNICAL - Facoltà di Ingegneria  
Corso di Laurea Specialistica in Ingegneria Informatica  
Corso di Data Mining e Scoperta di Conoscenza  
Appello del 16/03/2011

Supponendo che ogni vettore  $\mathbf{x}_i$  sia generato da una sola componente possiamo trasformare la log-likelihood in:

$$\log L(\theta | \mathbf{x}_1, \dots, \mathbf{x}_n) = \sum_{i=1}^n \sum_{k=1}^K y_{ik} \log(\pi_k p(\mathbf{x}_i | y_{ik}, k)) = \sum_{i=1}^n \sum_{k=1}^K y_{ik} (\log(p(\mathbf{x}_i | y_{ik}, k)) + \log(\pi_k))$$

In termini di  $p(\mathbf{x}_b | \mathbf{x}_a)$  si ottiene:

$$\begin{aligned} \log L(\theta | \mathbf{x}_1, \dots, \mathbf{x}_n) &= \sum_{i=1}^n \sum_{k=1}^K y_{ik} (\log(p(\mathbf{x}_{b_i}, \mathbf{x}_{a_i} | y_{ik}, k)) + \log(\pi_k)) \\ &= \sum_{i=1}^n \sum_{k=1}^K y_{ik} (\log(p(\mathbf{x}_{b_i} | \mathbf{x}_{a_i}, y_{ik}, k)) + \log(p(\mathbf{x}_{a_i} | y_{ik}, k)) + \log(\pi_k)) \end{aligned}$$

**Esercizio 3**

