


Text Categorization

metodologia di apprendimento mediante approcci statistici e
reti neurali artificiali



Claudio Biancalana

Contatti

Claudio Biancalana
claudio.biancalana@dia.uniroma3.it

www.dia.uniroma3.it/~biancal/


Information Retrieval (IR)

- Indicizzazione e ricerca di documenti testuali
- Ricerca di pagine sul web
- Obiettivo principale è la ricerca **efficace** di documenti rilevanti
- Obiettivo secondario è la ricerca **efficiente** tra un insieme vasto di documenti

Obiettivi IR

- **Input:**
 - Un insieme di documenti testuali scritti in linguaggio naturale.
 - Una stringa rappresentante una query.
- **Output:**
 - Un insieme di documenti ordinati in base alla loro rilevanza alla query.

Sistema IR



Categorizzazione

- **Input:**
 - Una descrizione di una istanza, $x \in X$, dove X è l'istanza linguaggio o spazio dell'istanza.
 - Un numero fissato di categorie:
 $C = \{c_1, c_2, \dots, c_n\}$
- **Output:**
 - La categoria di x : $c(x) \in C$, dove $c(x)$ è una funzione di categorizzazione che ha come dominio X e come codominio C .

Imparare per categorizzare

- Un esempio di apprendimento per una istanza $x \in X$, accoppiata con la sua categoria $c(x)$:
 $\langle x, c(x) \rangle$ con una sconosciuta funzione di categorizzazione, c .
- Sia dato un insieme di esempi di apprendimento, D .
- Trovare una ipotizzata funzione di categorizzazione, $h(x)$, tale che:

$$\forall \langle x, c(x) \rangle \in D : h(x) = c(x)$$

Consistenza

Category Learning Problem (esempio)

- Istanza di linguaggio: $\langle \text{grandezza, colore, forma} \rangle$
 - grandezza $\in \{\text{small, medium, large}\}$
 - colore $\in \{\text{rosso, blu, verde}\}$
 - forma $\in \{\text{quadrato, cerchio, triangolo}\}$
- $C = \{\text{positivo, negativo}\}$

• D :

Esempio	Grand.	Colore	Forma	Categoria
1	small	rosso	cerchio	positivo
2	large	rosso	cerchio	positivo
3	small	rosso	triangolo	negativo
4	large	blu	cerchio	negativo

Text Categorization

- Assegnare documenti ad un insieme fissato di categorie.
- Applicazioni:
 - Pagine web
 - Recommending
 - Classificazioni (Yahoo!)
 - Messaggi su Newsgroup
 - Recommending
 - Filtraggio spam
 - Articoli
 - Giornali personalizzati
 - Email
 - Routing
 - Prioritizing
 - Folderizing
 - Filtraggio spam

Algoritmi di apprendimento

- Lo sviluppo “manuale” di una funzione di text categorization è difficile.
- Algoritmi per l’apprendimento:
 - **Bayesian (naïve)**
 - Reti neurali
 - **Relevance Feedback (Rocchio)**
 - Nearest Neighbor (case based)
 - **Support Vector Machines (SVM)**
 - Basato su regole

Rappresentazione dei documenti

- Una collezione di n documenti può essere rappresentata nel modello come una matrice dei termini del documento.
- Un valore nella matrice corrisponde al “peso” di un termine nel documento; zero significa che il termine non è significativo nel documento o più semplicemente non è presente nel documento.

$$\begin{pmatrix} & T_1 & T_2 & \dots & T_t \\ D_1 & w_{11} & w_{21} & \dots & w_{t1} \\ D_2 & w_{12} & w_{22} & \dots & w_{t2} \\ \vdots & \vdots & \vdots & & \vdots \\ \vdots & \vdots & \vdots & & \vdots \\ D_n & w_{1n} & w_{2n} & \dots & w_{tn} \end{pmatrix}$$

TF*IDF

- Metodologia di rappresentazione dei pesi del vettore per il pattern recognition

TF = frequenza del termine nel documento

$$\text{IDF} = \log (N/n)$$

N= numero totale di documenti nella collezione di training

n = numero di documenti che contengono il termine nella collezione di training

Per ogni termine abbiamo **TF*IDF**

Rappresentazione grafica


Esempio:

$$C_1 = 2T_1 + 3T_2 + 5T_3$$

$$C_2 = 3T_1 + 7T_2 + T_3$$

$$D = 0T_1 + 0T_2 + 2T_3$$

$$C_1 = 2T_1 + 3T_2 + 5T_3$$



- E' C_1 o C_2 più simile a D ?
- Come si misura il grado di similarità? Distanza? Angolo? Proiezione?


Algoritmo rocchio

- Usiamo lo standard di indicizzazione TF/IDF per rappresentare in forma vettoriale i documenti di testo (normalizzati secondo la frequenza massima di un termine)
- Per ogni categoria, viene elaborato un vettore “Prototipo” dalla somma dei vettori di training nella categoria
- Assegnamo il documento di test alla categoria col vettore “prototipo” più vicino mediante la regola di similarità del coseno.

Regole di similarità del coseno

- Si misura il coseno dell'angolo fra due vettori...

$$\text{CosSim}(c_j, d) = \frac{c_j \cdot d}{|c_j| \cdot |d|} = \frac{\sum_{i=1}^t (w_{ij} \cdot w_{iq})}{\sqrt{\sum_{i=1}^t w_{ij}^2 \cdot \sum_{i=1}^t w_{iq}^2}}$$



$$\begin{aligned} C_1 &= 2T_1 + 3T_2 + 5T_3 & \text{CosSim}(C_1, D) &= 10 / \sqrt{(4+9+25)(0+0+4)} = 0.81 \\ C_2 &= 3T_1 + 7T_2 + 1T_3 & \text{CosSim}(C_2, D) &= 2 / \sqrt{(9+49+1)(0+0+4)} = 0.13 \\ D &= 0T_1 + 0T_2 + 2T_3 \end{aligned}$$

Algoritmo Rocchio (apprendimento)

Sia l'insieme delle categorie $\{c_1, c_2, \dots, c_n\}$

For i from 1 to n let $\mathbf{p}_i = \langle 0, 0, \dots, 0 \rangle$ (*inizializzazione*)

For each esempio di training $\langle x, c(x) \rangle \in D$

Let \mathbf{d} = vettore TF/IDF per il doc x

Let $i = j: (c_j = c(x))$

(somma di tutti i vettori in c_i per ottenere \mathbf{p}_i)

Let $\mathbf{p}_i = \mathbf{p}_i + \mathbf{d}$

Algoritmo Rocchio (Test)

Dato un documento di test x

Let \mathbf{d} = vettore TF/IDF per x

Let $m = -2$ (*inizializzazione*)

For i from 1 to n :

(calcola la similarità col vettore prototipo)

Let $s = \text{cosSim}(\mathbf{d}, \mathbf{p}_i)$


if $s > m$

let $m = s$

let $r = c_i$ (*aggiorna il più simile*)

Return class r

Text categorization con Rocchio




Algoritmo di apprendimento Nearest-Neighbor

- L'apprendimento si riduce al modo di immagazzinare le rappresentazioni degli esempi di training in D .
- Test dell'istanza x :
 - Elabora la similarità tra x e tutti gli esempi in D .
 - Assegna ad x la categoria del più simile in D .
- Non si calcolano esplicitamente i prototipi delle categorie.
- Conosciuto anche sotto il nome di:
 - Case-based
 - Memory-based
 - Lazy learning

Metrica per la similarità

- Nearest neighbor si basa su una metrica di similarità (o distanza)
- La più semplice per uno spazio continuo è la distanza euclidea.
- La più semplice per spazi d'istanza m-dimensionali binari è la distanza di Hamming
- Per i testi, la similarità basata sul coseno, per i vettori costruiti mediante indicizzazione TF-IDF, è tipicamente la più efficiente.

3 Nearest Neighbor Illustration (Euclidian Distance)



K Nearest Neighbor per testi

Training:

For each each esempio di training $\langle x, c(x) \rangle \in D$

Calcola il corrispondente vettore TF-IDF, \mathbf{d}_x , per il doc x

Test dell'istanza y :

Calcola il vettore TF-IDF \mathbf{d} per il doc y

For each $\langle x, c(x) \rangle \in D$

Let $s_x = \text{cosSim}(\mathbf{d}, \mathbf{d}_x)$

Ordina gli esempi, x , in D al decrescere di s_x

Let $N =$ I primi k esempi in D . *(ottiene così i vicini più simili)*


Return la classe con più esempi in N

Nearest Neighbor per testi




Rocchio: anomalia

- I prototipi possono avere problemi con categorie disgiunte.



Nearest Neighbor

- Nearest Neighbor tende ad avere in tal caso un comportamento migliore.



Metodi bayesiani

- Apprendere e classificare mediante approcci probabilistici
- Il teorema di bayes gioca un ruolo critico nell'apprendimento e classificazione.

Categorizzazione Bayesiana

- Sia l'insieme delle categorie $\{c_1, c_2, \dots, c_n\}$
- Sia E una descrizione di un'istanza
- Determinare il grado di appartenenza di E per ogni c_i
- $P(E)$ può essere determinata solo se le categorie sono complete e disgiunte.

$$P(c_i | E) = \frac{P(c_i)P(E | c_i)}{P(E)}$$

$$P(E) = \sum_{i=1}^n P(c_i)P(E | c_i)$$

$$\sum_{i=1}^n P(c_i | E) = \sum_{i=1}^n \frac{P(c_i)P(E | c_i)}{P(E)} = 1$$

Categorizzazione Bayesiana

- E' necessario sapere:
 - $P(c_i)$
 - $P(E | c_i)$
- $P(c_i)$ sono facilmente stimati dai dati.
 - se n_i degli esempi in D sono in c_i , allora $P(c_i) = n_i / |D|$
- Se si assume che le caratteristiche di una istanza siano indipendenti data la categoria c_i

$$P(E | c_i) = P(e_1 \wedge e_2 \wedge \cdots \wedge e_m | c_i) = \prod_{j=1}^m P(e_j | c_i)$$

Esempio

- $C = \{\text{allergia, raffreddore, salute}\}$
- $e_1 = \text{starnuto}; e_2 = \text{tosse}; e_3 = \text{febbre}$
- $E = \{\text{starnuto, tosse, } \neg \text{febbre}\}$

Prob	salute	raffreddore	allergia
$P(c_i)$	0.9	0.05	0.05
$P(\text{starnuto} c_i)$	0.1	0.9	0.9
$P(\text{tosse} c_i)$	0.1	0.8	0.7
$P(\text{febbre} c_i)$	0.01	0.7	0.4

Esempio (continua)

Probabilità	Salute	Raffreddore	Allergia
$P(c_i)$	0.9	0.05	0.05
$P(\text{starnuto} c_i)$	0.1	0.9	0.9
$P(\text{tosse} c_i)$	0.1	0.8	0.7
$P(\text{febbre} c_i)$	0.01	0.7	0.4

$E = \{\text{starnuto, tosse, } \neg \text{febbre}\}$

$$P(\text{salute} | E) = (0.9)(0.1)(0.1)(0.99)/P(E) = 0.0089/P(E)$$

$$P(\text{raffreddore} | E) = (0.05)(0.9)(0.8)(0.3)/P(E) = 0.01/P(E)$$

$$P(\text{allergia} | E) = (0.05)(0.9)(0.7)(0.6)/P(E) = 0.019/P(E)$$

Categoria più probabile: allergia

$$P(E) = 0.089 + 0.01 + 0.019 = 0.0379$$

$$P(\text{salute} | E) = 0.23$$

$$P(\text{raffreddore} | E) = 0.26$$

$$P(\text{allergia} | E) = 0.50$$

Algoritmo di apprendimento Naïve Bayes

Let V = il vocabolario di tutte le parole nei documenti in D

For each categoria $c_i \in C$

Let D_i = il sottoinsieme di documenti in D
nella categoria c_i

$$P(c_i) = |D_i| / |D|$$

Let T_i = la concatenazione di tutti i documenti in D_i

Let n_i = il numero totale delle occorrenze in T_i

For each parola $w_j \in V$

Let n_{ij} = il numero di occorrenze di w_j in T_i

$$\text{Let } P(w_i | c_i) = (n_{ij} + 1) / (n_i + |V|)$$

Algoritmo di test Naïve Bayes

Dato un documento di test X

Let n = numero di occorrenze in X

Return categoria:


$$\operatorname{argmax}_{c_i \in C} P(c_i) \prod_{i=1}^n P(a_i | c_i)$$

dove a_i l'occorrenza della parola nella *i-esima* posizione in X

Reti neurali


- Una rete neuronale consiste in un pool di semplici processi elementari che comunicano fra loro spedendosi segnali attraverso numerose connessioni pesate

Neurone artificiale




Percettrone

- Una rete a strato singolo consiste in uno o più neuroni di output, ognuno dei quali è connesso con un fattore peso w_{ij} a tutti gli input x_i .



Percettrone

- Nel caso più semplice abbiamo solo due input e un solo output. L'output del neurone è:

$$y = f\left(\sum_{i=1}^2 w_i x_i + b\right)$$


The diagram illustrates a simple perceptron. It consists of three cyan circular nodes. Two nodes on the left represent input nodes, each with a black arrow pointing towards a central node on the right, which represents the output node. A green arrow points to the central node from above, indicating the activation function. A black arrow points away from the central node to the right, representing the output.

- Supponiamo la seguente funzione di attivazione


$$f = \begin{cases} 1 & \text{if } s > 0 \\ -1 & \text{if } s \leq 0 \end{cases}$$

Percettrone

- In questa semplice rete (il neurone) può essere usato per separare gli input in due classi.
- La separazione nelle due classi è data da

$$w_1 x_1 + w_2 x_2 + b = 0$$

Percettrone



Learning

- I pesi della rete neurale sono modificati durante la fase di learning

$$w_{ij}(t + 1) = w_{ij}(t) + \Delta w_{ij}$$

$$b_{ij}(t + 1) = b_{ij}(t) + \Delta b_{ij}$$

Learning

- Si parte con pesi casuali
- Dalla coppia di input $(\mathbf{x}, d(\mathbf{x}))$:
se $y \neq d(x)$ allora modifica il peso mediante la formula:

$$\Delta w_{ij} = d(x)x_i$$

NB Regola del gradiente discendente


$$\Delta w_{ij} = -\gamma \frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial w_{ij}} \quad \frac{\partial y_i}{\partial w_{ij}} = x_j \quad \frac{\partial E}{\partial y_i} = -(d_i - y_i) = \delta_i \quad \Delta w_{ij} = \gamma \delta_i x_j$$


Categorizzazione e perceptroni

- Un perceptrone per ogni categoria
- Learning sui documenti di training della sua categoria
- Durante la fase di test, il perceptrone fornisce un valore VERO/FALSO sull'appartenenza del vettore rappresentativo il documento alla categoria

Valutare la categorizzazione

- Esistono due parametri accettati dalla comunità IR



RECALL: $|R_a|/|R|$ **PRECISION:** $|R_a|/|A|$

Valutare la categorizzazione

- **PRECISION**
 - L'abilità nel restituire i documenti che sono più rilevanti.
- **RECALL**
 - L'abilità nel restituire tutti i documenti rilevanti dell'intero dominio.
- **F-Measure**

$$F = \frac{2PR}{P + R} = \frac{2}{\frac{1}{R} + \frac{1}{P}}$$