

Entropia

Gianluca Amato

Corso di Laurea Specialistica in Economia Informatica
Università “G. D'Annunzio” di Chieti-Pescara
anno accademico 2005-2006

Il Concetto di Entropia

- L'entropia è un concetto legato al grado di “disordine” in un sistema.
- Il concetto è usato in vari settori delle scienze:
 - fisica (in particolare nella termodinamica)
 - teoria dell'informazione

Entropia e teoria dell'informazione

Teoria dell'Informazione (1)

- Entropia legata al concetto di “misura dell'informazione”
- Esperimento X1:
 - 4 possibili risultati: a, b, c, d equiprobabili
 - vogliamo memorizzare il risultato su un elaboratore: che codice utilizzare?

| <i>Probabilità</i> | <i>Risultati</i> | <i>Codice binario</i> |
|--------------------|------------------|-----------------------|
| $\frac{1}{4}$ | a | 00 |
| $\frac{1}{4}$ | b | 01 |
| $\frac{1}{4}$ | c | 10 |
| $\frac{1}{4}$ | d | 11 |

- 2 bit per risultato

Teoria dell'Informazione (2)

- Esperimento X2:
 - 4 risultati **non** equiprobabili

| <i>Probabilità</i> | <i>Risultati</i> | <i>Codice binario</i> |
|--------------------|------------------|-----------------------|
| $\frac{1}{2}$ | a | 0 |
| $\frac{1}{4}$ | b | 10 |
| $\frac{1}{8}$ | c | 110 |
| $\frac{1}{8}$ | d | 1110 |

- codice con un numero di bit variabili
 - lunghezza media: $\frac{1}{2} * 1 + \frac{1}{4} * 2 + \frac{1}{8} * 3 + \frac{1}{8} * 4 = \frac{15}{8}$
 - la lunghezza media è minore di 2!!
- questo codice per l'esperimento X1?
 - lunghezza media $\frac{5}{2}$

Teoria dell'Informazione (3)

- Alcune domande che vengono fuori:
 - Perché per X1 sono necessari due bit mentre per X2 si può fare di meglio?
 - X2 contiene “meno informazione” di X1
 - E` possibile fare ancora meglio per l'esperimento X2 ?
- A queste domande risponde la **teoria dell'informazione**.

Entropia di un esperimento finito

- Sia X un esperimento con un numero finito di possibili risultati e_1, \dots, e_q .
- La probabilità che l'evento e_i si verifichi è p_i .
- Entropia dell'esperimento X :

$$H(X) = H(p_1, p_2, \dots, p_q) = - \sum_{i=1}^q p_i \log(p_i)$$

- Perché questa definizione?

Proprietà della funzione H (1)

- H è continua sulle p_i
 - piccole modifiche delle probabilità causano piccole modifiche della incertezza dell'esperimento
- se X e X' hanno q e q' risultati equiprobabili e $q < q'$, allora:

$$H(X)=H(1/q,\dots,1/q) < H(1/q',\dots,1/q')=H(X')$$

- più risultati possibili abbiamo maggiore è l'incertezza dell'esperimento

Proprietà della funzione H (2)

- Se l'esperimento X è scomposto in due esperimenti successivi, il risultato non cambia:

$$\begin{array}{ccc} & & e_1 \\ & & 1/2 \\ & e_1 & \\ 1/2 & & \\ & & e_2 \\ & & 2/3 \\ & e_2 & \\ 1/3 & & \\ & & e_3 \\ & & 1/3 \\ 1/6 & & \\ & e_3 & \\ H(1/2, 1/3, 1/6) & & H(1/2, 1/2) + 1/2 * H(1/3, 2/3) \end{array}$$

– i due valori sono uguali

Caratterizzazione di H

- Le uniche funzioni che soddisfano le proprietà di cui ai lucidi precedenti sono (al variare di C):

$$H_C(p_1, p_2, \dots, p_q) = -C \sum_{i=1}^q p_i \log(p_i)$$

- Fissiamo $C=1$ e chiamiamo **bit** l'unità di misura corrispondente a questa scelta.
- Se X è un esperimento, un qualunque codice per X che sia unicamente decifrabile avrà una lunghezza media $n \geq H(X)$.
 - nell'esperimento X_1 l'entropia è 2 per cui tutti i codici possibili avranno lunghezza media ≥ 2 .
 - nell'esperimento X_2 l'entropia è $14/8$, il codice fornito ha lunghezza media $15/8$: forse si può migliorare
 - basta cambiare il codice del risultato C in 111.

Entropia e codici

- Se X è un esperimento, un qualunque codice per X che sia unicamente decifrabile avrà una lunghezza media $n \geq H(X)$.
 - nell'esperimento X_1 l'entropia è 2 per cui tutti i codici possibili avranno lunghezza media ≥ 2 .
 - nell'esperimento X_2 l'entropia è $14/8$, il codice fornito ha lunghezza media $15/8$: forse si può migliorare
 - basta cambiare il codice del risultato C in 111.

Programmi di Compressione

- I programmi di compressione sfruttano il fatto che alcune combinazioni di caratteri sono più probabili di altre.
 - ovvero, l'esperimento “*prendo a caso un file di m bytes dal disco fisso*” ha una entropia inferiore ad $8m$ (come sarebbe se il file fosse generato in modo completamente casuale)
 - vuol dire anche, in ogni sistema di compressione, ci saranno dei file in cui la versione compressa è più grande di quella originaria.

Entropia e statistica

Misure di eterogeneità (1)

- Si chiamano **misure di eterogeneità** quegli indici numerici che tentano di stabilire quanto i possibili valori di un attributo in un insieme di dati sono distribuiti in maniera uniforme.
 - in termini statistici, si parla spesso di collettivo per insieme di dati, caratter per attributo e modalità per un possibile valore di un attributo.
- Si distinguono due casi:
 - **eterogeneità massima**: quando tutte le istanze (unità statistiche) hanno la stessa modalità; .
 - **omogeneità massima**: quando le unità statistiche sono suddivise equamente tra le modalità.

Misure di eterogenità (2)

- Dato un insieme di dati S , indichiamo con $H_S(A)$ l'entropia riferita all'attributo A
 - in caso di eterogeneità massima, l'entropia è 0
 - in caso di omogeneità massima, l'entropia è $\log_2(k)$ dove k è il numero di modalità di A .
- Quando S è chiaro dal contesto, lo ometteremo, scrivendo solo $H(A)$ invece di $H_S(A)$.
- Può essere comodo rapportare l'entropia di un attributo al suo massimo valore possibile:
 - se A è un attributo con k modalità, definiamo l'**entropia relativa** di A come $H^r(A) = H(A) / \log_2(k)$.

Guadagno di Informazione (1)

- Supponiamo di avere un insieme di dati con due attributi A e C. C è di solito chiamato attributo classe, in quanto, nelle applicazioni, è la classe di una istanza che vorremmo predire a partire dagli altri attributi.
- Vogliamo una misura di quanto A è importante nel predire C.
- Se v è una modalità di A, definiamo **l'entropia di C condizionata da A=v** come l'entropia di C per i soli dati in cui A=v.
- Definiamo l'entropia di C condizionata da A come la media delle entropie condizionate per tutte le modalità di A, pesata con la frequenza relativa di tali modalità:

$$H(C|A) = \sum_{i=1}^k f_i \cdot H(C|A=x_i)$$

Guadagno di Informazione (2)

- La $H(C|A)$ misura l'incertezza del valore C quando sono già a conoscenza del valore per A.
- Definisco **guadagno di informazione** di A il valore

$$IG(A) = H(A) - H(C|A)$$

- Più è alto questo valore, maggiore è l'importanza di A per determinare il valore di C
 - in quanto diminuisce di molto l'incertezza su C, quando conosco già il valore di A
- In maniera del tutto analoga si definisce il guadagno di informazione per più di un attributo.

Guadagno di Informazione (3)

- Questa definizione di guadagno di informazione va bene per valori categoriali o numerici discreti, ma non per valori continui.
 - In questo caso, spesso si calcola il guadagno di informazione che si ottiene dividendo l'intervallo di tutti i possibili valori per un attributo A in due sotto-intervalli, in corrispondenza del valore v .

- $IG(A, v)$ definito come la differenza tra
 - l'entropia dell'insieme dei dati iniziali: $H(C)$
 - l'entropia media dopo il partizionamento.

$$H(C|A, v) = \frac{|S_1|}{|S|} H(C|A \leq v) + \frac{|S_2|}{|S|} H(C|A > v)$$

dove S_1 ed S_2 sono gli insiemi delle istanze corrispondenti alle condizioni $A \leq v$ e $A > v$ rispettivamente.

- $IG(A, v) = H(C) - H(C|A, v)$