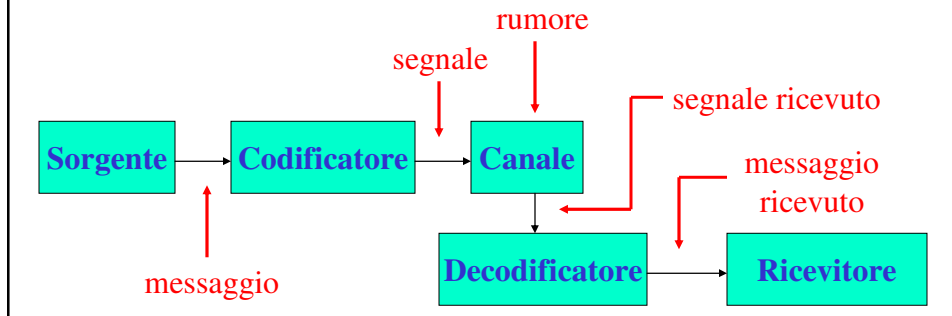


Entropia ed informazione

Primi elementi sulla teoria della misura dell'informazione

Per trasmettere l'informazione è necessaria una **rete di comunicazione**,
che, secondo l'approccio teorico di **Claude E. Shannon** e **Warren Weaver**
(ingegneri presso i Bell Laboratories, USA, 1949),
si può così schematizzare:



Nel trasmettere l'informazione occorre adottare un **criterio di efficienza**:
minima distorsione, massima velocità, minimo costo.

Per tutti i sistemi di comunicazione il **problema fondamentale** consiste nello **stabilire un'adeguata misura dell'informazione**, e nel servirsene per migliorare la loro efficienza.

Cerchiamo di definire quanta informazione è contenuta nell'evento

$$\{X = x\} \quad X \text{ variabile aleatoria}$$

Prima di tutto, è importante capire che in questo contesto il termine informazione non riguarda il contenuto semantico di un messaggio.

Informazione qui significa semplicemente una **misura della libertà di scelta di cui si dispone nello scegliere un messaggio dall'insieme di quelli disponibili**, molti dei quali potranno anche essere privi di significato.

La quantità di informazione I portata dal messaggio $\{X = x\}$ si suppone ragionevolmente che:

1) dipenda dalla probabilità $I \geq p \geq 0$ che X sia uguale a x :

$$I = I(p)$$

2) sia tanto più grande quanto più rara è la sua occorrenza, cioè, in altre parole, I è decrescente in p

3) sia una grandezza non negativa: $I(p) \geq 0$

4) sia additiva rispetto alla somma di messaggi. In altri termini, è naturale supporre che, se X e Y sono 2 v.a. indipendenti:

$$P\{X = x\} = p, P\{Y = y\} = q, P\{X = x, Y = y\} = pq$$

allora deve verificarsi che

$$I(pq) = I(p) + I(q)$$

Dalle 1), 2) e 3) siamo indotti ad ipotizzare una funzione del tipo

$$I \propto \frac{1}{p}$$

Ma dalla 4) si può dedurre subito che per trasformare prodotti in somme occorre ricorrere ai logaritmi; di conseguenza:

$$I \propto \log \frac{1}{p} = -\log p$$

Per quanto riguarda la scelta della base del logaritmo, in generale questa è arbitraria; tuttavia, si preferisce usare 2, con riferimento al sistema binario usato nei calcolatori elettronici.

In questo modo, l'informazione viene misurata in *bit*, ovvero in cifre binarie (*binary digits*)

In definitiva, possiamo affermare che l'informazione I (parziale) contenuta in un singolo messaggio $\{X = x\}$ di probabilità p vale:

$$I(p) = -\log_2 p$$

Consideriamo adesso una v.a. X , che possa assumere i valori

$x_1, x_2, x_3, \dots, x_n$ con probabilità $p_1, p_2, p_3, \dots, p_n$

Si definisce **valore atteso dell'informazione contenuta in X**

oppure

informazione media contenuta in tutti i valori possibili di X

oppure

quantità media di informazione (o di sorpresa) che riceviamo quando osserviamo il valore che X ha assunto oppure

misura d'incertezza a priori di X

$$H(X) = -\sum_{i=1}^n p_i \log_2 p_i \longleftrightarrow H(X) = E[-\log_2 p(X)]$$

La grandezza $H(X)$ è chiamata entropia (di Shannon) di X

Notiamo tre proprietà dell'entropia $H(X)$:

- l'entropia di un "bit casuale" è uguale a 1
- l'entropia è massima quando tutti i valori x_i ($i=1,2,\dots,n$) che può assumere la v.a. X sono equiprobabili:

$$p_i = p = \frac{1}{n}$$

In questo caso si ha che:

$$H(X)_{MAX} = \log_2 n$$

- Se si conosce a priori il messaggio (cioè, il valore che assume la v.a. X), allora $H(X) = 0$

In statistica **l'entropia di Shannon** è utilizzata come **indice di eterogeneità** di un insieme di dati, di frequenza nota, e spesso viene fornita in forma normalizzata, cioè divisa per l'entropia massima.

Verifichiamo la prima proprietà dell'entropia $H(X)$:

• l'entropia di un "bit casuale" è uguale a 1:

x_i	p_i
0	$1/2$
1	$1/2$

$$H(X) = -\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{2} \log_2 \frac{1}{2}$$

$$H(X) = -\log_2 \frac{1}{2} = -(-1) = +1$$

Verifichiamo una parte della seconda proprietà dell'entropia $H(X)$:

• se i valori che può assumere la v.a. X sono equiprobabili, allora:

x_i	p_i
x_1	$1/m$
x_2	$1/m$
\vdots	\vdots
x_m	$1/m$

$$H(X) = -\sum_{i=1}^m p_i \log_2 p_i$$

$$H(X) = -m \frac{1}{m} \log_2 \frac{1}{m} = -\log_2 \frac{1}{m}$$

$$H(X) = -\log_2 1 + \log_2 m = \log_2 m$$

SI DIMOSTRA CHE $= H(X)_{\text{MAX}}$

Esempio 1			
Messaggio	$\{X = x_1\}$	$\{X = x_2\}$	$\{X = x_3\}$
Probabilità del messaggio	$\frac{1}{2}$	$\frac{1}{3}$	$\frac{1}{6}$
Contenuto di informazione del messaggio	$-\log_2 \frac{1}{2} = 1$	$-\log_2 \frac{1}{3} = 1.58$	$-\log_2 \frac{1}{6} = 2.58$
<p>Quanto vale $H(X)$ \equiv misura dell'informazione media dell'insieme dei messaggi nel suo complesso?</p> $H(X) = \frac{1}{2}(1) + \frac{1}{3}(1.58) + \frac{1}{6}(2.58) = 1.46 \text{ bit}$			

Esempio 2
<p>Trovare l'entropia massima di un messaggio costituito da 5 lettere, essendo il numero totale di lettere nell'alfabeto uguali a 32.</p> <p>Il numero di messaggi possibili composti da 5 lettere, anche tutte uguali, è dato dal numero di disposizioni con ripetizione di 32 lettere a gruppi di 5:</p> $D_{32,5}^r = 32^5$ <p>Dato che si suppone che ogni messaggio abbia la stessa probabilità di verificarsi (messaggi equiprobabili), allora l'entropia massima è:</p> $H(X)_{MAX} = \log_2 32^5 = 5 \log_2 32 = 5 \times 5 = 25 \text{ bit}$ <p>Si noti che, essendo a priori tutti i messaggi equiprobabili, l'informazione parziale contenuta in un singolo messaggio è uguale all'informazione media:</p> $I_{x_i} = -\log_2 p_{x_i} = -\log_2 \frac{1}{32^5} = \log_2 32^5 = 25 \text{ bit}$

Ridondanza

L'alfabeto, nel caso della lingua inglese, contiene 26 lettere più l'intervallo fra parole contigue, cioè 27 simboli.

Allora, il repertorio di *messaggi* più elementare di tale lingua è costituito da 27 simboli.

Se si assume che la probabilità di ogni messaggio (simbolo) sia la stessa, l'entropia è data da:

$$H_{massima} = \log_2 27 = 4.76 \text{ bit}$$

In altre parole, sono necessari circa 5 bit per codificare ogni simbolo:

00000, 00001, 00010, 00100, 00111,

Tuttavia, l'effettiva quantità di informazione trasmessa da ogni lettera è in realtà minore, perché le diverse lettere non compaiono con uguale frequenza. Ad esempio,

$p(a)=0.06$, $p(b)=0.01$, $p(c)=0.02$, $p(d)=0.03$, $p(e)=0.1$,

Allora, l'entropia diventa:

$$H = -\sum_{i=1}^{27} p_i \log_2 p_i = 4 \text{ bit}$$

Ancora una volta, ci si rende conto che l'effettiva quantità di informazione trasmessa da ogni lettera è molto più bassa, a causa di un'importante proprietà comune a tutte le lingue e chiamata **ridondanza**. Ad esempio,

- la probabilità di q-u è praticamente 1
- la probabilità di j-x è praticamente 0
- la probabilità di tio-n è molto elevata
- la probabilità di oug-k è minima

Attraverso una serie di esperimenti si arriva a stabilire che l'effettiva quantità di informazione trasmessa da ogni lettera è

$$H_{\text{effettiva}} \approx 2 \text{ bit}$$

Possiamo quindi assumere come misura della libertà relativa di scelta dei simboli rispetto alla massima possibile il seguente rapporto, detto anche **entropia relativa** del messaggio:

$$\frac{H_{\text{effettiva}}}{H_{\text{massima}}} = \frac{2}{4.76} = 0.42$$

Adesso possiamo definire **la ridondanza**:

$$\text{ridondanza} = 1 - \frac{H_{\text{effettiva}}}{H_{\text{massima}}} = 0.58$$

In definitiva, la **ridondanza rappresenta la percentuale di informazione del messaggio che rimane automaticamente definita dai vincoli statistici della lingua.**