


CODIFICA DI SORGENTE



Messaggi $m \in \mathcal{M}$: probabilità $q(m)$, lunghezza $n(m) \rightarrow$ valore atteso di N

$$E[N] = \sum_{m \in \mathcal{M}} q(m) n(m)$$

Parole di codice $w \in \mathcal{W}$: probabilità $p(w)$, lunghezza $l(w) \rightarrow$ valore atteso di L

$$E[L] = \sum_{w \in \mathcal{W}} p(w) l(w)$$

Tasso del codice : è il rapporto $\frac{E[L]}{E[N]} =: R$

Fattore di compressione : $1/R$

Nel caso di codici \underline{B} - \underline{B} o \underline{B} - \underline{LV} ,

$N = n$ costante

$\rightarrow R = \frac{E[L]}{n}$
 \uparrow lunghezza dei blocchi della sorgente


Vogliamo minimizzare $E[L]$



Problema di Codifica di sorgente: Data una sorgente S ^(stazionaria e senza memoria), individuare un codice

$C = (M, \varphi, W)$ che sia u.d. e a tasso minimo (o approssimativamente minimo)

Codici B-LV. $M = A^n$



$$(D = |B|)$$

Iniziamo da $n=1$. In questo caso, $R = \frac{\mathbb{E}[L]}{n} = \mathbb{E}[L]$

Se $A = \{a_1, \dots, a_k\} = M$

$W = \{w_1, w_2, \dots, w_k\}$

$$R = \mathbb{E}[L] = \sum_{w \in W} p(w) l(w)$$

d.d.p. della sorgente $\rightarrow p = (p_1, \dots, p_k)$

$\underbrace{\quad}_{B^+} \quad \underbrace{\quad}_{B^+} \quad \underbrace{\quad}_{B^+}$

$$= \sum_{i=1}^k p_i l_i$$

Lunghezza: l_1, l_2, \dots, l_k

Teo (3.13) (Teorema di Shannon). Se S è una sorgente stazionaria e senza memoria, con d.d.p. $p = (p_1, \dots, p_k)$, allora la lunghezza attesa delle parole di un qualsunque codice D-ario u.d. è almeno pari all'entropia D-aria della sorgente:

Entropia D-aria

$$\mathbb{E}[L] \geq H_D(p) = - \sum_{i=1}^k p_i \log_D p_i = \frac{H(p)}{\log_2 D}$$

Dim. Consideriamo la d.d.p. $q = (q_1, \dots, q_k) : q_i = \frac{D^{-l_i}}{\sum_{j=1}^k D^{-l_j}} \gg 0$

$$\boxed{\alpha = \sum_{j=1}^k D^{-l_j}} ; q_i = \frac{D^{-l_i}}{\alpha}$$

Scriviamo la divergenza informativa tra p e q :

$$\begin{aligned}
 0 & \stackrel{\text{(Gibbs)}}{\leq} \frac{D(p||q)}{\log_2 D} = \sum_{i=1}^k p_i \log_D \left(\frac{p_i}{q_i} \right) = \sum_i p_i \log_D p_i - \sum_i p_i \log_D \left(\frac{D^{-l_i}}{\alpha} \right) = \\
 & \left(\begin{array}{l} H_0 = \\ \text{se e solo se} \\ p=q \end{array} \right) = -H_D(p) - \sum_i p_i \underbrace{\log_D(D^{-l_i})}_{-l_i} + \sum_i p_i \log_D \alpha = -H_D(p) + \underbrace{\left(\sum_i p_i l_i \right)}_{\mathbb{E}[L]} + \log_D \alpha
 \end{aligned}$$

Per McMillan-Kraft, $\alpha \leq 1 \Rightarrow \log_D \alpha \leq 0$
 $\leftarrow i = \text{se } \alpha = 1$

$$\sum_i p_i l_i \geq H_D(p) - \underbrace{\log_D \alpha}_{\geq 0} \Rightarrow \mathbb{E}[L] \geq H_D(p) \quad \text{QED.}$$

Abbiamo uguaglianza : $\mathbb{E}[L] = H_D(p)$

se e solo se : $p = q$ e $\alpha = 1$

ovvero : $p_i = D^{-l_i}$ per ogni $i = 1, \dots, K$

(distribuzione D-adica)

Esempio :

(a_1, a_2, a_3, a_4)

$p = (\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{8})$ $D = 2$

$2^{-1}, 2^{-2}, 2^{-3}, 2^{-3}$

$l_1 = 1, l_2 = 2, l_3 = 3, l_4 = 3$

$$\rightarrow \text{Ho } \mathbb{E}[L] = \frac{1}{2} \cdot 1 + \frac{1}{4} \cdot 2 + \frac{1}{8} \cdot 3 + \frac{1}{8} \cdot 3 = 1 + \frac{3}{4} = \frac{7}{4}$$

$$\text{e } H_D(p) = \frac{7}{4}.$$

Se \overline{p} è uniforme, cioè $p_i = \frac{1}{K}$, per $i = 1, 2, \dots, K$, allora $\mathbb{E}[L] \geq H_D(p) = \log_D K$

In particolare, se $D = K$, $\log_D K = 1 \rightarrow$ non posso sperare in un fattore di compressione ≥ 1

La differenza $r \triangleq \mathbb{E}[L] - H_D(p) \geq 0$

è detta ridondanza del codice.

Esistono codici con un tasso prossima all'entropia D-aria?

Se riuscissi ad avere $l_i \approx -\log_D p_i$

allora $\mathbb{E}[L] \approx -\sum_i p_i \log_D p_i = H_D(p)$ e $r \approx 0$

Un approccio è di porre

$$l_i = \lceil -\log_D p_i \rceil \leftarrow \text{parte intera superiore}$$

(codifica di Shannon-Fano).

Teo (3.14). ^{"Parte positive"} (Teorema di codifica di sorgente per codici B-LV simbolici)

Se S è una sorgente con dd.p. p , esiste un codice D-ario a prefisso

tale che $\mathbb{E}[L] < H_D(p) + 1$.

Dim. Definisco $l_i = \lceil -\log_D p_i \rceil$. Tali lunghezze soddisfano McMillan-Kraft, in quanto:


$$\sum_{i=1}^k D^{-\lceil -\log_D p_i \rceil} \leq 1 \quad \checkmark$$

$$\lceil x \rceil \geq x$$

→ //

$$\sum_{i=1}^k D \log_D p_i$$

$$\sum_{i=1}^k p_i = 1$$



⇒ Quindi esiste un codice a prefisso (quindi anche u.d.)

che ha parole di codice di lunghezza l_1, l_2, \dots, l_k .

$$E[L] = \sum_{i=1}^k p_i l_i < \sum_{i=1}^k p_i (1 - \log_D p_i) = \overbrace{\sum_{i=1}^k p_i}^{=1} - \sum_{i=1}^k p_i \log_D p_i = 1 + H_D(p) \quad \text{QED.}$$

Esempio in cui $\mathbb{E}[L]$ è arbitrariamente vicino a $H_0(p) + 1$:

$$A = \{0, 1\}, \quad p = \begin{matrix} p(0) & p(1) \\ (\varepsilon, & 1 - \varepsilon) \end{matrix} \quad \text{per qualche } \varepsilon \in (0, 1)$$

La lunghezza media $\mathbb{E}[L]$ è necessariamente ≥ 1 . (sia l_1 che l_2 sono ≥ 1)

$$H_0(p) = -\varepsilon \log_2 \varepsilon - (1 - \varepsilon) \log_2 (1 - \varepsilon) = h_\varepsilon(\varepsilon) \xrightarrow{\varepsilon \rightarrow 0} 0$$

$$\underbrace{\mathbb{E}[L]}_{\approx 1} \approx \underbrace{H_0(p)}_{\approx 0} + 1 \quad ; \quad H_0(p) + 1 - \mathbb{E}[L] \xrightarrow{\varepsilon \rightarrow 0} 0$$



$n > 1$