

Codice di Shannon-Fano	(asintoticamente ottimo; non è ottimo per n finito)	} Basati su una descrizione statistica della sorgente S
Codice di Fano	(può dare talvolta risultati migliori per n fissato)	
Codice di Huffman	(è ottimo per ogni n finito)	

Possiamo avere codici efficienti senza conoscere la d.p. di S ?

$A = \{x_1, \dots, x_k\}$ una stringa $\vec{x} = (x_{i_1}, x_{i_2}, \dots, x_{i_n})$ ha tipo esatto (n_1, n_2, \dots, n_k)

dove $n_i = \#$ occorrenze di x_i in \vec{x} (es.: $A = \{a, b\}$, $\vec{x} = aba$, tipo $(2, 1)$)

A^n ($|A^n| = K^n$)

A^n è partizionato in classi di equivalenza date dai tipi esatti.


Il numero di classi di equivalenza è denotato con Γ_n . $\Gamma_n \leq (n+1)^k$

$\rightarrow \Gamma_n \leq (n+1)^k$ in quanto $0 \leq n_i \leq n$ (per ogni $i = 1, \dots, k$). (Nota: ovviamente $\sum_{i=1}^k n_i = n$)

Denoto con $T_{\vec{x}}$ il tipo esatto della n -pla \vec{x} .

$$|T_{\vec{x}}| = \binom{n}{n_1, n_2, \dots, n_k} = \frac{n!}{n_1! \cdot n_2! \cdot \dots \cdot n_k!}$$

Coefficiente
multinomiale



Codifica multinomiale: per codificare una n -pla \vec{x} , si usa la parola a lungh. variabile

$$\varphi(\vec{x}) = \varphi_p(T_{\vec{x}}) * \varphi_s(\vec{x})$$

\uparrow \uparrow
 prefisso suffisso
 (dipende solo (dipende da \vec{x})
 dal tipo)

- $\varphi_p(T_{\vec{x}})$ è il numero d'ordine (lessicografico) di $T_{\vec{x}}$ (identifica il tipo)
- $\varphi_s(\vec{x})$ è il numero d'ordine di \vec{x} all'interno di $T_{\vec{x}}$ (identifica \vec{x} all'interno del suo tipo)

Chiamiamo : $l_p = |\varphi_p|$ la lunghezza del prefisso (costante) → è una codifica B-LV
 $l_s(\vec{x}) = |\varphi_s(\vec{x})|$ la lunghezza del suffisso (variabile)

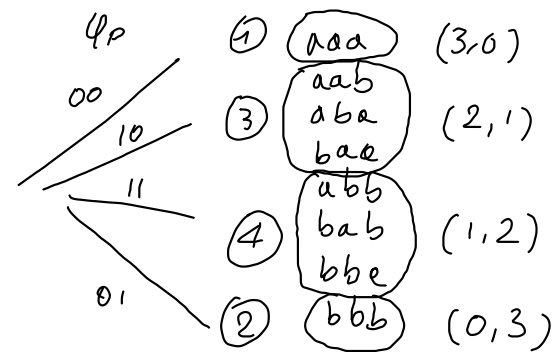
Deve essere

$$D^{l_p} \geq \Gamma_n \quad \Rightarrow \quad l_p = \lceil \log_D \Gamma_n \rceil$$

$$D^{l_s(\vec{x})} \geq |T_{\vec{x}}| \quad \Rightarrow \quad l_s(\vec{x}) = \lceil \log_D |T_{\vec{x}}| \rceil$$

Esempio: $A = \{a, b\}$, $B = \{0, 1\}$ ($D=2; K=2$); $n=3$.

$\Gamma_3 = 4$ perché ho 4 tipi esatti; $\lceil \log_2 4 \rceil = 2$



Z	Tipo	n-ple	$l_S(\vec{x})$	φ_P	$\varphi_S(\vec{x})$ (stringa vuota)	$\varphi(\vec{x})$
1	(3,0)	aaa	$\lceil \log_2 1 \rceil = 0$	00	—	00
2	→ (0,3)	bbb	$\lceil \log_2 1 \rceil = 0$	01	—	01
3	→ (2,1)	aab	$\lceil \log_2 3 \rceil = 2$	10	00	1000
		= aba	=	10	01	1001
		= baa	=	10	10	1010
4	(1,2)	bba	$\lceil \log_2 3 \rceil = 2$	11	00	1100
		= bab	=	11	01	1101
		= abb	=	11	10	1110

Codice multinomiale non è ottimo per n finito

ma è asintoticamente ottimo ($n \rightarrow \infty$)

Cosa succede asintoticamente? ($n \rightarrow \infty$)

$$E[L^{(n)}] = \sum_{\text{tutte le n-ple } \vec{x}} p(\vec{x}) (l_p + l_s(\vec{x})) \stackrel{\sum p(\vec{x})=1}{=} l_p + \sum_{\vec{x}} p(\vec{x}) l_s(\vec{x})$$

$$= \lceil \log_D \Gamma_n \rceil + \sum_{j=1}^{\Gamma_n} \underbrace{\sum_{\vec{x} \in T_j} p(\vec{x})}_{\text{non dipende da } \vec{x}} \cdot \lceil \log_D |T_j| \rceil$$

$$= \lceil \log_D \Gamma_n \rceil + \sum_{j=1}^{\Gamma_n} \lceil \log_D |T_j| \rceil \cdot \left(\sum_{\vec{x} \in T_j} p(\vec{x}) \right)$$

$\Pr(T_j)$

$$= \lceil \log_D \Gamma_n \rceil + \sum_{j=1}^{\Gamma_n} \Pr(T_j) \cdot \lceil \log_D |T_j| \rceil$$

Probabilità complessiva
del tipo T_j :
 $\Pr[X \in T_j]$

$$< 1 + \log_D \Gamma_n + 1 + \sum_{j=1}^{\Gamma_n} \Pr(T_j) \log_D |T_j|$$


$$< 2 + K \log_D (n+1) + \sum_{j=1}^{\Gamma_n} \Pr(T_j) \log_D |T_j|$$

?
 $\rightsquigarrow H(S)$

$$\lceil x \rceil < 1 + x$$

$$\Gamma_n \leq (n+1)^K$$

Introduco una v.a. Z intera che rappresenta
il numero d'ordine del tipo della seq. \vec{x}




Consideriamo l'entropia condizionata:

$$H(\vec{X} | Z) = \sum_{j=1}^n \Pr[Z=j] H(\vec{X} | Z=j) = \sum_j \Pr(T_j) H(\vec{X} | Z=j)$$

Tutte le n-ple di tipo esatto j sono equiprobabili, quindi

$$H(\vec{X} | Z=j) = \log_D |T_j| \Rightarrow H(\vec{X} | Z) = \sum_j \Pr(T_j) \log_D |T_j|$$



$$\rightarrow E[L^{(n)}] < 2 + K \log_D (n+1) + H(\vec{X} | Z)$$

$$\leq 2 + K \log_D (n+1) + H(\vec{X})$$

$$= 2 + K \log_D (n+1) + n H(S)$$

(in ipotesi di stazionarietà e assenza di memoria)

Il tasso è

$$\frac{E[L^{(n)}]}{n} < \frac{2}{n} + K \frac{\log_D (n+1)}{n} + \frac{n}{n} H(S) \xrightarrow{n \rightarrow \infty} H(S)$$

quindi la codifica è asintoticamente ottimale.


Codifica universale: non dipende dalle d.p. della sorgente

Codifica Ziv-Lempel (altro esempio di codice universale)

(LZ77) → numerose varianti (LZ77, LZ78, LZW, ...)
formati .zip, .gzip

Codifica "strutturale": basata sulla struttura della concatenazione dei simboli

Stringa $s = (s_1, s_2, \dots)$ sequenza di simboli sull'alfabeto A ($|A|=K$)



N : dimensione della finestra

$L (< N)$: numero di simboli massimo codificato ad ogni passo

Sia $s[i, j] = (s_i, s_{i+1}, \dots, s_j)$

Per ogni $i = 1, 2, \dots, N-L$ sia $L(i)$

il più grande intero tale che $s[i, i+L(i)-1] = s[j+1, \dots, j+L(i)]$

