

# TEOREMA DELLA CODIFICA DI SORGENTE PER CODICI BLOCCO-BLOCCO (B-B)

Sia  $\delta' > 0$ . Sorgente (s.s.m.)  $\mathcal{S}$

Parte diretta: Se fissiamo il tasso  $R \geq H_D(\mathcal{S}) + \delta'$ , allora esiste una famiglia di codici <sup>(B-B)</sup> per  $\mathcal{S}^n$ ,  $C^1, C^2, \dots, C^n, \dots$ ,  
con una probabilità  $P_{err}^{(n)}$  tale che  $\lim_{n \rightarrow \infty} P_{err}^{(n)} = 0$

Parte inversa: Se  $R \leq H_D(\mathcal{S}) - 2\delta'$ , allora per qualunque famiglia di codici B-B per  $\mathcal{S}^n$ , la prob.  $P_{err}^{(n)}$  è tale che  $\lim_{n \rightarrow \infty} P_{err}^{(n)} = 1$ .

Cosa succede per  $n$  finito?

# CODICI DI SORGENTE (Cap. 5)

Codici B-LV.  
(simbolici)  
( $n=1$ )

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

$$B = \{b_1, \dots, b_D\}$$

Lunghezze delle  $\{w_i\}$

$$p = (p_1, \dots, p_k)$$

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

$$L = \{l_1, \dots, l_k\}$$

Codice C  $\rightarrow$  il tasso  $R(C) = \frac{E[L]}{1} = E[L]$ .

Esempio: Codifica di Shannon-Fano: associa ad ogni  $a_i$  una parola di codice di lunghezza  $l_i = \lceil -\log_D p_i \rceil$ .

Esempio.  $A = \{a, b, c, d, e, f\}$

$$p = (4/16, 4/16, 3/16, 2/16, 2/16, 1/16)$$

$$D = 2 \quad (B = \{0, 1\})$$

$$l_a = \lceil -\log_2 4/16 \rceil = \lceil \log_2 4 \rceil = 2$$

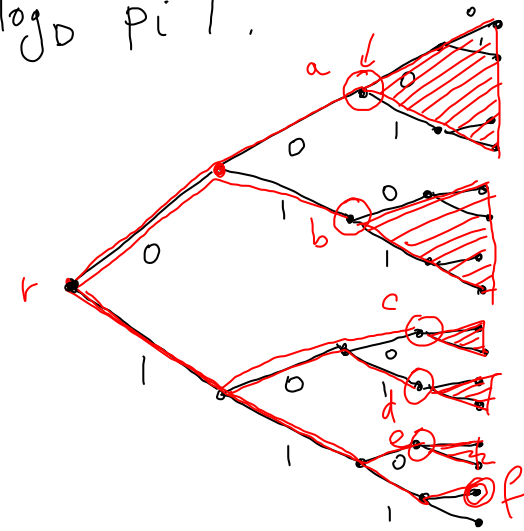
$$l_b = 2$$

$$l_c = 3$$

$$l_d = 3$$

$$l_e = 3$$

$$l_f = 4$$



a	00
b	01
c	100
d	101
e	110
f	1110
	111

$$\varphi: \mathcal{M} \rightarrow B^+$$

$$\begin{aligned} E[L] &= 4/16 \cdot 2 + 4/16 \cdot 2 + 3/16 \cdot 3 + 2/16 \cdot 3 + 2/16 \cdot 3 + 1/16 \cdot 4 \\ &= 41/16 \end{aligned}$$


In questo esempio, la codifica di Shannon-Fano non è ottima.

(Codice  $C^*$  è ottimo in una classe di codici

se  $R(C^*) \leq R(C)$  per ogni codice  $C$  nella classe).

Se modifico la codifica di  $f$ :  $\varphi(f) = 111$ , ottengo  $E[L] = 40/16 < 41/16$ .

=  
Codifica di Fano. Partizioniamo  $A$  in due sottoinsiemi  $A_0$  e  $A_1$ :  $A_0 \cup A_1 = A$   
 $A_0 \cap A_1 = \emptyset$



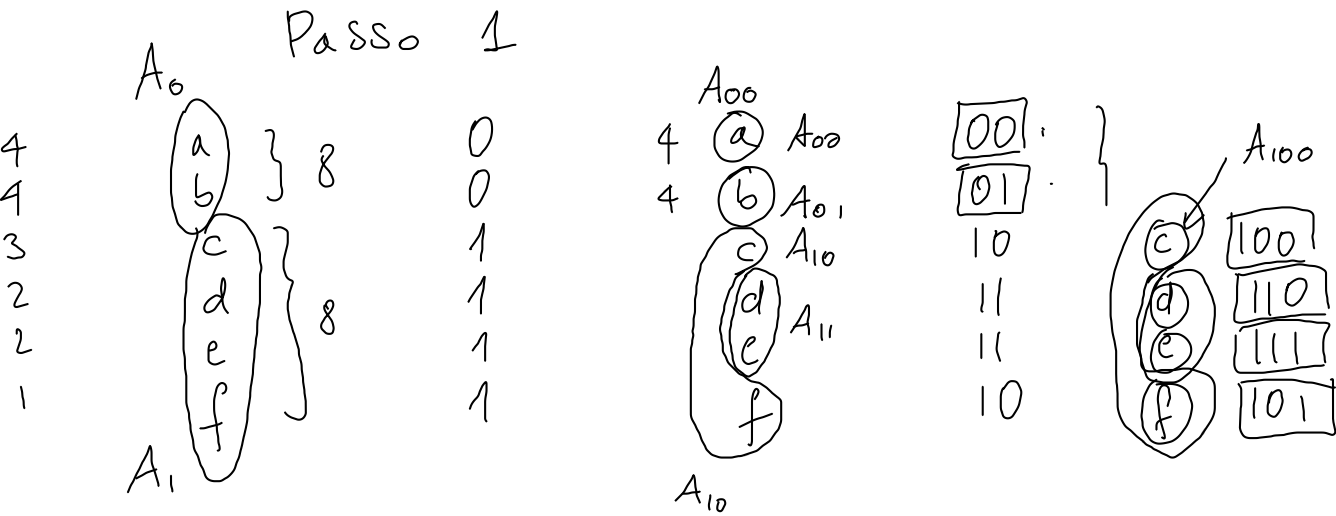
in modo tale da minimizzare  $\left| \sum_{i \in A_0} p_i - \sum_{i \in A_1} p_i \right|$

Continuo: partiziono  $A_0 = A_{00} \cup A_{01}$  sempre con lo stesso criterio

$$A_1 = A_{10} \cup A_{11}$$

finché tutti gli insiemi non contengono un singolo elemento.

Esempio - Stessa sorgente di prima; sei simboli,  $p = \left( \frac{4, 4, 3, 2, 2, 1}{16} \right)$



$E[L] = 2 \cdot \frac{8}{16} + 3 \cdot \frac{8}{16} = \frac{40}{16}$   
 In questo caso, la codifica <sup>di Fano</sup> ha una lunghezza attesa inferiore della codifica di Shannon-Fano.

Pero, in generale, la codifica di Fano non è ottima.

Lemma (5.1). Sia (senza perdita di generalità)  $p_1 \geq p_2 \geq \dots \geq p_k$  (altrimenti riordino)

Allora esiste un codice ottimo  $C^*$  <sup>(nella classe dei codici u.d.)</sup> ra prefisso tale che:

→ (1) Se  $p_j > p_k$  si ha  $l_j \leq l_k$  (e dunque  $l_1 \leq l_2 \leq \dots \leq l_k$ )

→ (2) Se  $l_k = |w_k|$  è la lunghezza massima, esiste un'altra parola di codice  $w_j$  di lunghezza  $l_k$ , e che differisce da  $w_k$  solo per l'ultimo simbolo

Dim. Consideriamo un qualunque codice  $C^*$  ottimo.

Costruiamo un altro codice  $C'$  scambiando  $w_j$  con  $w_k$ .

Allora  $0 \leq \mathbb{E}[L'] - \mathbb{E}[L^*] = \sum_i p_i l'_i - \sum_i p_i l_i =$

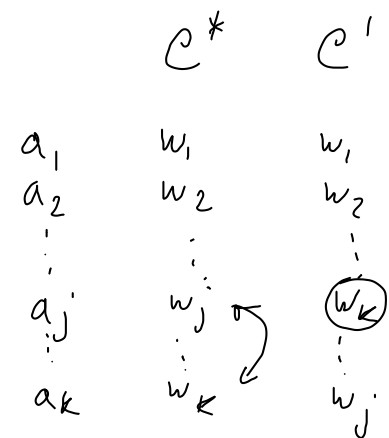
per ipotesi,  $C^*$  è ottimo  
 $\mathbb{E}[L^*] \leq \mathbb{E}[L']$

$$= p_j l_k + p_k l_j - (p_j l_j + p_k l_k)$$

$$= p_j (l_k - l_j) - p_k (l_k - l_j) =$$

$$= (p_j - p_k) (l_k - l_j)$$

$\underbrace{p_j - p_k}_{> 0 \text{ per ipotesi}} \underbrace{(l_k - l_j)}_{\text{Deve essere } \geq 0} \Rightarrow l_k \geq l_j$



$\left. \begin{matrix} 01001 \\ 01000 \end{matrix} \right\} \text{ quelle}$

Essendo  $C^*$  u.d., esso soddisfa la disuguaglianza di McMillan-Kraft.

Quindi esiste un codice a prefisso con le stesse lunghezze di  $C^*$ .

Se non esistesse  $w_j$  con  $|w_j| = |w_k|$ ,



si potrebbe elidere l'ultimo di  $w_k$ , senza violare la proprietà del prefisso.

Ma il codice sarebbe a lunghezza attesa inferiore a prima.

Quindi esiste  $w_{k-1}$  con  $|w_{k-1}| = |w_k|$ .

Costruisco una sorgente "ridotta"  $\mathcal{S}^{(k-1)}$

aggregando i due simboli  $a_k$  e  $a_{k-1}$  di probabilità minima.



Posso ottenere un codice a prefisso per  $\mathcal{S}^{(k)}$

partendo da un codice a prefisso per  $\mathcal{S}^{(k-1)}$ ;

Sia  $w'_{k-1}$  la parola di codice per  $a'_{k-1}$ ; ottengo  $w_{k-1} = w'_{k-1} \cdot 0$ ,  $w_k = w'_{k-1} \cdot 1$

Teorema 5.1. Se il codice a prefisso  $\mathcal{C}^{(k-1)}$  è ottimo per la sorgente ridotta  $\mathcal{S}^{(k-1)}$ , allora il codice  $\mathcal{C}^{(k)}$  descritto come sopra è ottimo per la sorgente  $\mathcal{S}^{(k)}$ .

Dim. Se il codice a prefisso  $\mathcal{C}^{(k-1)}$  è ottimo per  $\mathcal{S}^{(k-1)}$

$$\begin{aligned}
 R(\mathcal{C}^{(k)}) &= \mathbb{E}[L(\mathcal{S}^{(k)})] = \sum_{i=1}^k p_i l_i = \sum_{i=1}^{k-2} p_i l_i + (p_{k-1} l_{k-1}) + (p_k l_k) \\
 &= \sum_{i=1}^{k-2} p_i l_i + \underbrace{(p_{k-1} + p_k)}_{p_{k-1}'} l_k \quad \begin{array}{l} \text{prob. del simbolo} \\ \text{aggregato} \end{array}
 \end{aligned}$$

$$= \sum_{i=1}^{k-2} p_i l_i + p_{k-1}' \cdot (l_{k-1}' + 1)$$

$$= \underbrace{\sum_{i=1}^{k-2} p_i l_i + p_{k-1}' l_{k-1}'}_{\mathbb{E}[L(\mathcal{S}^{(k-1)})]} + p_{k-1}'$$

$$\mathbb{E}[L(\mathcal{S}^{(k-1)})]$$

$$\text{" } R(\mathcal{C}^{(k-1)})$$

↑ non dipende da come scelgo il codice  $\mathcal{C}^{(k-1)}$

⇒ minimizzare  $R(\mathcal{C}^{(k)})$  è equivalente  
a "  $R(\mathcal{C}^{(k-1)})$


# Algoritmo di Huffman, (caso binario)

- Ordina i simboli per probabilità non crescenti
- Accorpa i 2 simboli meno probabili
- Trova ricorsivamente un codice (ottimo) per  $S^{(k-1)}$
- Estendi il codice  $S^{(k-1)}$  apponendo '0'/'1' per distinguere i simboli  $a_{k-1}$  e  $a_k$  alla parole di codice per il simbolo aggregato.

(La codifica di Huffman è ottima nella classe dei codici u.d.:

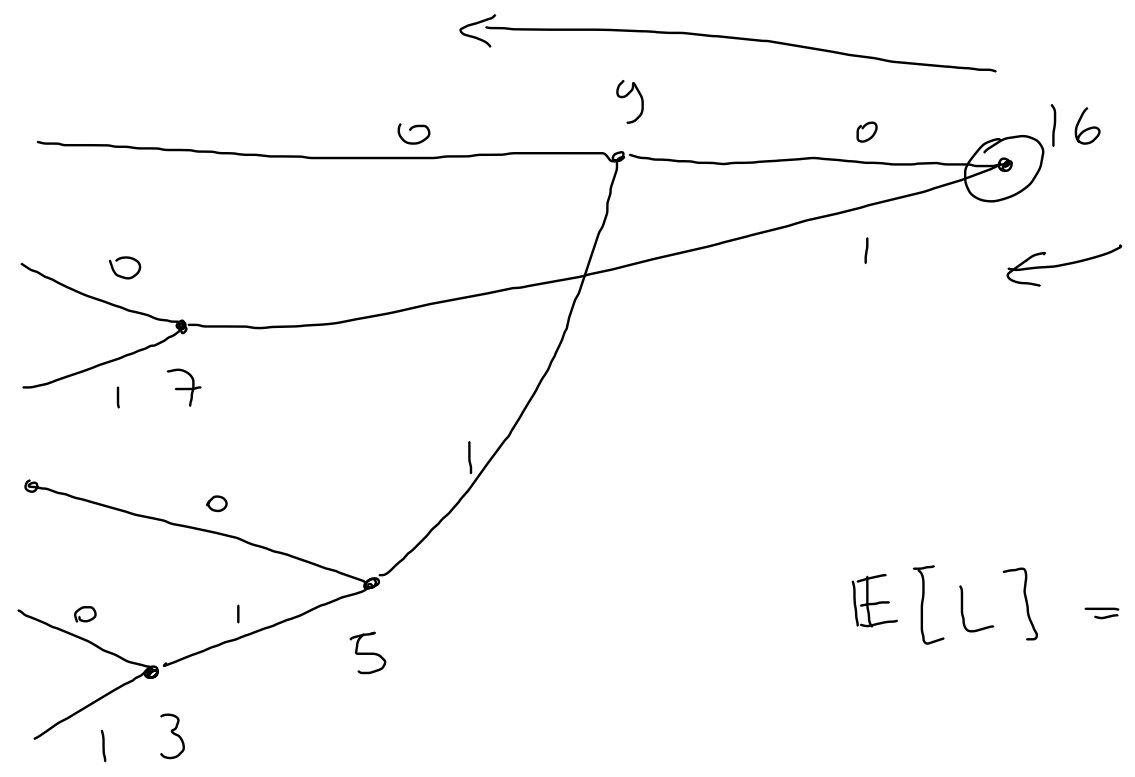
$$R(C^{\text{Huff.}}) \leq R(C) \quad \forall C \text{ u.d.}$$

Esempio,  $A = \{a, b, c, d, e, f\}$





00	a	4
10	b	4
11	c	3
010	d	2
0110	e	2
0111	f	1



$$E[L] = 40/16$$