

CODICI DI HUFFMAN

- CONSENTONO FATTORI DI COMPRESSIONE TRA IL 20% E IL 90%
- PROBLEMA: TROVARE UNA CODIFICA DI UN FILE DI CARATTERI IN MODO DA MINIMIZZARNE LA DIMENSIONE

ESEMPIO: FILE DI 100 CARATTERI

CAR.	FREQ.	COD1 (8 BIT)	COD2 (3 bit)	COD3	
a	45	00000000	000	0	45
b	13	00000001	001	101	39
c	12	00000010	010	100	36
d	16	00000011	011	111	48
e	9	00000100	100	1101	36
f	5	00000101	101	1100	20
	100	800 bit	300 bit		224 bit

LUNGHEZZA FISSA

LUNGH. VARIABILE

25% IN MENO

ES. a b a c

COD 2

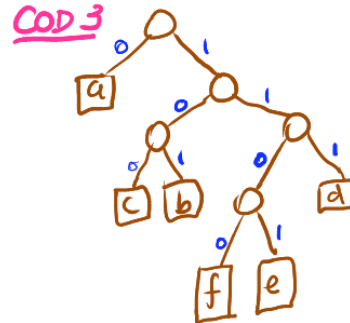

000001000010

COD 3

01010100

ALBERI DI DECODIFICA

CAR.	FREQ.	COD2 (3 bit)	COD3
a	45	000	0
b	13	001	101
c	12	010	100
d	16	011	111
e	9	100	1101
f	5	101	1100



ES.

a b a c

COD2

000 001 000 010

a b a c

COD3

0 101 100 111

a b a c

- CODICI PREFISSI: SONO CODICI IN CUI NESSUNA CODIFICA E' PREFISSO DI UN'ALTRA CODIFICA

ESEMPIO DI CODICE NON PREFISSO



a	0	0
b	01	b c c c c c
c	11	

ESEMPIO DI CODICE NON PREFISSO **AMBIGUO**

a	0	
b	01	
c	1	

ALBERI DI DECODIFICA

CAR.	FREQ.	COD2 (3 bit)	COD3
a	45	000	0
b	13	001	101
c	12	010	100
d	16	011	111
e	9	100	1101
f	5	101	1100



COMPLESSITA' DELLA CODIFICA:

$$B(\text{cod}) = \sum_{c \in C} f(c) |\text{cod}(c)|$$

$$= \sum_{c \in C} f(c) d_{T_{\text{cod}}}(c) \stackrel{\text{def}}{=} B(T_{\text{cod}})$$

T_{cod} : ALBERO DI DECODIFICA
 C : ALFABETO

$f: C \rightarrow \mathbb{N}$
 $d_{T_{\text{cod}}}$: PROFONDITA' IN T_{cod}


PROBLEMA: TRA TUTTI GLI ALBERI DI DECODIFICA RELATIVI AD UN SISTEMA (C, f) (DOVE $f: C \rightarrow \mathbb{N}$) DETERMINARE QUELLO DI COSTO MINIMO, CIOE' L'ALBERO BINARIO DI DECODIFICA T TALE CHE

$$B(T) = \sum_{c \in C} f(c) d_T(c)$$


SIA MINIMO

OSSERVAZIONE: POSSIAMO LIMITARE LA NOSTRA RICERCA AGLI ALBERI BINARI PIENI, QUELLI CIOE' PRIVI DI NODI INTERNI CON MENO DI DUE FIGLI.

OSSERVAZIONE: IL NUMERO DI NODI INTERNI IN UN ALBERO BINARIO PIENO CON m FOGLIE E' $m-1$.



- PER COSTRUIRE UN ALBERO BINARIO PIENO CON m NODI SI POSSONO EFFETTUARE $(m-1)$ OPERAZIONI DI MERGING



$$C_1 \cup C_2 = C$$

$$c \in C_1 \quad d_{T_1}(c) + 1 = d_T(c)$$

$$c \in C_2 \quad d_{T_2}(c) + 1 = d_T(c)$$

$$B(T) = \sum_{c \in C} f(c) \cdot d_T(c)$$


$$= \sum_{c \in C_1} f(c) \cdot d_T(c) + \sum_{c \in C_2} f(c) \cdot d_T(c)$$

$$= \sum_{c \in C_1} f(c) (d_{T_1}(c) + 1) + \sum_{c \in C_2} f(c) (d_{T_2}(c) + 1)$$

$$= \sum_{c \in C_1} f(c) d_{T_1}(c) + \sum_{c \in C_1} f(c)$$

$$+ \sum_{c \in C_2} f(c) d_{T_2}(c) + \sum_{c \in C_2} f(c)$$

$$= B(T_1) + B(T_2) + \sum_{c \in C} f(c)$$



$$C_1 \cup C_2 = C$$


$$c \in C_1 \quad d_{T_1}(c) + 1 = d_T(c)$$

$$c \in C_2 \quad d_{T_2}(c) + 1 = d_T(c)$$

$$B(T) = B(T_1) + B(T_2) + \sum_{c \in C} f(c)$$

$$\Delta B = B(T) - (B(T_1) + B(T_2))$$

$$= \sum_{c \in C} f(c) \quad \leftarrow \text{COSTO DELL'OPERAZIONE DI MERGING DI } T_1 \text{ E } T_2$$




14
30
25
55
100
224

PER INDUZIONE SULL'ALTEZZA DI T , SI DIMOSTRA CHE:

$B(T) =$ SOMMA DEI COSTI DI TUTTE LE OPERAZIONI DI MERGING


CASO BASE: $height(T) = 0 \quad B(T) = 0$

PASSO INDUTTIVO:



$$\begin{aligned}
 B(T) &= B(T_1) + B(T_2) + \sum_{c \in C} f(c) \\
 &= \sum \text{merging}(T_1) \\
 &\quad + \sum \text{merging}(T_2) \\
 &\quad + \text{costo-merging}(T_1, T_2) \\
 &= \sum \text{merging}(T)
 \end{aligned}$$

ESEMPIO:



$$\begin{array}{r}
 14 + \\
 30 + \\
 25 + \\
 55 + \\
 \hline
 100 \\
 \hline
 224
 \end{array}$$

- UNA POSSIBILE STRATEGIA "GREEDY" PER COSTRUIRE UN ALBERO DI COSTO MINIMO CONSISTE NELL'EFFETTUARE LE OPERAZIONI DI MERGING DI COSTO MINIMO

HUFFMAN (C, f)

$n := |C|$

$Q := \text{make_queue}(C, f)$

for $i := 1$ to $n-1$ do

- SI ALLOCHI UN NUOVO NODO INTERNO z

$\text{left}[z] := x := \text{EXTRACT_MIN}(Q)$

$\text{right}[z] := y := \text{EXTRACT_MIN}(Q)$

$f[z] := f[x] + f[y]$

$\text{INSERT}(Q, z, f)$

return $\text{EXTRACT_MIN}(Q)$

COMPLESSITA'


$(2n-1)$ EXTRACTMIN $O(n \log n)$


$(n-1)$ INSERT $O(n \log n)$

BUILDHEAP $O(n)$

$O(n \log n)$

ESEMPIO






LOWER-BOUND SULLA COMPLESSITA': $\Omega(m \lg n)$

$$\begin{cases} F(0) = 1 \\ F(1) = 1 \\ F(m) = F(m-1) + F(m-2) \end{cases}$$

a	00000
b	00001
c	0001
d	001
e	01
f	1



CORRETTEZZA DELL'ALGORITMO DI HUFFMAN

LEMMA SIA C UN ALFABETO E $f: C \rightarrow \mathbb{N}$ UNA FUNZIONE FREQUENZA.

SIANO x ED y I DUE CARATTERI IN C DI FREQUENZA MINIMA.

ALLORA ESISTE UN CODICE OTTIMO PREFISSO PER C IN CUI LE CODIFICHE DI x ED y DIFFERISCONO SOLO PER L'ULTIMO BIT.

DIM. SIANO a E b DUE CARATTERI RESIDENTI SU FOGLIE SORELLE DI PROFONDITA' MASSIMA IN UN ALBERO OTTIMO T .

SUPPONIAMO CHE $f(a) \leq f(b)$ E $f(x) \leq f(y)$.
ALLORA: $f(x) \leq f(a)$ E $f(y) \leq f(b)$.

SIA T' L'ALBERO OTTENUTO DA T SCAMBIANDO I CARATTERI a ED x .



SI HA:

$$\begin{aligned} B(T) - B(T') &= \sum_{c \in C} f(c) d_T(c) - \sum_{c \in C} f(c) d_{T'}(c) \\ &= f(a) d_T(a) + f(x) d_T(x) - f(a) d_{T'}(a) - f(x) d_{T'}(x) \\ &= f(a) d_T(a) + f(x) d_T(x) - f(a) d_T(x) - f(x) d_T(a) \\ &= f(a) (d_T(a) - d_T(x)) - f(x) (d_T(a) - d_T(x)) \\ &= (f(a) - f(x)) (d_T(a) - d_T(x)) \geq 0 \end{aligned}$$

POICHE':

- $c \in C \setminus \{a, x\} \rightarrow d_T(c) = d_{T'}(c)$
- $d_{T'}(a) = d_T(x)$
- $d_{T'}(x) = d_T(a)$

- SIA T'' L'ALBERO OTTENUTO DA T' SCAMBIANDO I CARATTERI b ED y ,

- ANALOGAMENTE A QUANTO VISTO PRIMA, SI HA:

$$B(T') - B(T'') \geq 0$$

- PERTANTO: $B(T) - B(T'') \geq 0$, DA CUI

$$B(T) \geq B(T'')$$

- POICHE' T E' OTTIMO, $B(T'') \geq B(T)$, E QUINDI

$B(T'')$ E' ANCH'ESSO OTTIMO

- INOLTRE IN T'' I CARATTERI x E y RISIEDONO SU FOGLIE SORELLE E QUINDI I LORO CODICI DIFFERISCONO SOLO PER L'ULTIMO BIT. ■

LEMMA

- SIA C UN ALFABETO E $f: C \rightarrow \mathbb{N}$ UNA FUNZIONE FREQUENZA.
 - SIANO x ED y I DUE CARATTERI IN C DI FREQUENZA MINIMA.
 - SIA $C' = (C \setminus \{x, y\}) \cup \{z\}$, CON $z \notin C$.
 - SIA $f': C' \rightarrow \mathbb{N}$ TALE CHE:
$$f'(c) = \begin{cases} f(c) & \text{SE } c \neq z \\ f(x) + f(y) & \text{SE } c = z \end{cases}$$
 - SIA T' UN ALBERO OTTIMO PER (C', f') .
 - SIA T L'ALBERO OTTENUTO DA T' SOSTITUENDO LA FOGLIA z CON UN NODO INTERNO AVENTE COME FIGLI DUE FOGLIE ETICHETTATE CON x ED y , RISPETTIVAMENTE.
- ALLORA T E' OTTIMO PER (C, f) .

DIM. SI HA:

$$\begin{aligned} B(T) &= \sum_{c \in C} f(c) d_T(c) = \sum_{c \in (C \setminus \{x, y\})} f(c) d_T(c) + f(x) d_T(x) + f(y) d_T(y) \\ &= \sum_{c \in (C \setminus \{x, y\})} f'(c) d_{T'}(c) + f(x) (d_{T'}(z) + 1) + f(y) (d_{T'}(z) + 1) \\ &= \sum_{c \in (C \setminus \{x, y\})} f'(c) d_{T'}(c) + f'(z) d_{T'}(z) + f(x) + f(y) \\ &= \sum_{c \in C'} f'(c) d_{T'}(c) + f(x) + f(y) \\ &= B(T') + f(x) + f(y) \end{aligned}$$

DA CUI: $B(T') = B(T) - f(x) - f(y)$

- SE T NON FOSSE OTTIMO PER (C, f) , ESISTEREBBE UN ALBERO T'' OTTIMO PER (C, f) TALE CHE:
 $B(T'') < B(T)$.
- GRAZIE AL LEMMA PRECEDENTE, POSSIAMO SUPPORRE CHE x E y SI TROVINO SU FOGLIE SORELLE IN T'' .
- SIA T''' OTTENUTO DA T'' , SOSTITUENDO IL PADRE DI x E y CON UNA FOGLIA z CON FREQUENZA $f(x) + f(y)$.
- ALLORA:

$$\begin{aligned}
 B(T''') &= B(T'') - f(x) - f(y) \\
 &< B(T) - f(x) - f(y) \\
 &= B(T')
 \end{aligned}$$
- CONTRADDICENDO L'OTTIMALITA' DI T' PER (C, f) .
- PERTANTO T E' OTTIMO PER (C, f) . ■