

Codici di Huffman

Si noti che mentre il codice di Shannon è quasi ottimo in media, può essere altamente inefficiente per quanto riguarda la lunghezza delle singole parole di codice. Infatti, consideriamo una sorgente $\mathcal{X} = \{x_1, x_2\}$ con $p(x_1) = 2^{-10}$ e $p(x_2) = 1 - 2^{-10}$. Allora, nel caso di codifica binaria, Shannon produrrà un codice istantaneo c con lunghezze $\ell_c(x_1) = \lceil \log_2 2^{10} \rceil = 10$ e $\ell_c(x_2) = \lceil \log_2 \frac{2^{10}}{2^{10}-1} \rceil = 1$. D'altra parte, un codice istantaneo più ovvio è $c(x_1) = 0$ e $c(x_2) = 1$ con lunghezze $\ell_c(x_1) = 1$ e $\ell_c(x_2) = 1$.

Terminata l'analisi del codice di Shannon, passiamo al problema di trovare il codice istantaneo “ottimo”. Ovvero, dato un modello di sorgente $\langle \mathcal{X}, p \rangle$ con $|\mathcal{X}| = m$, il codice istantaneo D -ario c^* le cui lunghezze $\ell_1^*, \dots, \ell_m^*$, risolvono il problema di ottimizzazione

$$\min_{\ell_1, \dots, \ell_m \in \mathbb{N}} \sum_{i=1}^m p_i \ell_i \quad \text{tale che} \quad \sum_{i=1}^m D^{-\ell_i} \leq 1.$$

Il codice istantaneo ottimo è il codice di Huffman (si veda l'esempio in Figura 1). L'algoritmo per la costruzione del codice nel caso generale $D > 1$ è il seguente:

1. i simboli sorgente vengono ordinati in base alle probabilità;
2. si crea un nuovo modello di sorgente in cui i D simboli meno frequenti sono rimpiazzati da un nuovo simbolo con probabilità pari alla somma delle loro probabilità;
3. se la nuova sorgente contiene più di un simbolo si ricomincia dal passo 1.

L'albero di codifica viene costruito come segue: all'inizio, tutti i simboli sorgente sono foglie. Ogni volta che D simboli vengono rimpiazzati da un nuovo simbolo si crea un albero avente il nuovo simbolo come radice e le radici degli alberi corrispondenti ai simboli rimpiazzati come figli (in ordine arbitrario, quindi il codice di Huffman non è unico). È facile vedere che l'intera procedura richiede un tempo dell'ordine $\mathcal{O}(|\mathcal{X}| \log |\mathcal{X}|)$.

Dato che ad ogni passo la nuova sorgente ha $D - 1$ simboli in meno della sorgente precedente, perché l'algoritmo termini in modo corretto —cioè con una sorgente di esattamente un simbolo— è necessario che $|\mathcal{X}|$ sia divisibile per $D - 1$ col resto di 1. Ovvero, $|\mathcal{X}| = (D - 1)k + 1$ per un qualche intero positivo k . Se non esiste un tale k , allora aggiungiamo alla sorgente un numero sufficiente di simboli “dummy” con probabilità pari a zero.

Procediamo ora a dimostrare l'ottimalità del codice di Huffman nell'ambito dei codici sorgente istantanei. Prima di dimostrare il teorema, dobbiamo però fare una semplice osservazione preliminare. Ovvero: da un codice di Huffman D -ario per una sorgente di $m - D + 1$ simboli possiamo ricavare un codice di Huffman D -ario per una sorgente di m simboli semplicemente sostituendo un simbolo sorgente con D nuovi simboli cosicché le probabilità assegnate ad essi siano tutte più piccole di quelle dei rimanenti $m - D$ vecchi simboli.

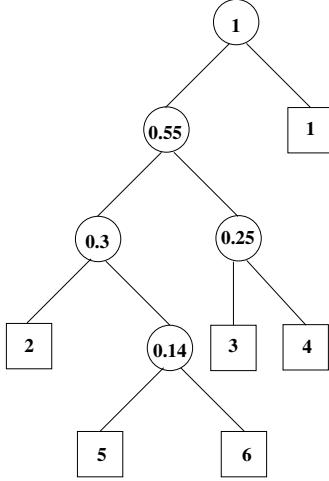


Figura 1: Albero del codice binario di Huffman per la sorgente $\langle \mathcal{X}, p \rangle$ con $\mathcal{X} = \{1, \dots, 6\}$ e probabilità $p_1 = 0.45$, $p_2 = 0.16$, $p_3 = 0.13$, $p_4 = 0.12$, $p_5 = 0.09$ e $p_6 = 0.05$.

Fatto 1 Sia c' un codice D -ario di Huffman per la sorgente $\mathcal{X}' = \{x_1, \dots, x_{m-D+1}\}$ con probabilità $p_1 \geq \dots \geq p_{m-D+1}$. Sia \mathcal{X} la sorgente di m simboli $\{x_1, \dots, x_{k-1}, x_{k+1}, \dots, x_{m+1}\}$ ottenuta da \mathcal{X}' togliendo x_k e aggiungendo D nuovi simboli $x_{m-D+2}, \dots, x_{m+1}$ con probabilità $p_{m-D+2}, \dots, p_{m+1}$ tali che $0 < p_{m-D+2}, \dots, p_{m+1} < p_{m-D+1}$ e $p_{m-D+2} + \dots + p_{m+1} = p_k$. Allora il codice

$$c(x) = \begin{cases} c'(x) & \text{se } x \in \{x_1, \dots, x_{k-1}, x_{k+1}, \dots, x_{m-D+1}\}, \\ c'(x_k)i & \text{se } x = x_{m-D+i+2} \text{ per } i = 0, \dots, D-1. \end{cases} \quad (1)$$

è un codice di Huffman per la sorgente \mathcal{X} .

DIMOSTRAZIONE. La dimostrazione è ovvia considerando che il dopo il primo passo nella costruzione del codice di Huffman per \mathcal{X} otteniamo \mathcal{X}' come nuova sorgente. Quindi i due codici differiscono solo per le codifiche ai D simboli $x_{m-D+2}, \dots, x_{m+1}$ che sono quelli meno probabili in \mathcal{X} . Per definizione dell'algoritmo di Huffman, le codifiche dei simboli meno probabili di \mathcal{X} sono definite in termini del codice di Huffman per \mathcal{X}' esattamente come descritto da (1). \square

Teorema 2 Data una sorgente $\langle \mathcal{X}, p \rangle$ e dato $D > 1$, il codice D -ario c di Huffman minimizza $\mathbb{E}[\ell_c]$ fra tutti i codici D -ari istantanei per la medesima sorgente.

DIMOSTRAZIONE. Per semplicità, dimostriamo solo il caso particolare $D = 2$. La dimostrazione del caso generale $D > 1$ è lasciata come esercizio.

Procediamo per induzione su $|\mathcal{X}| = m$. Nel caso base $m = 2$ Huffman è ottimo. Infatti, è facile vedere che l'algoritmo di Huffman produce il codice $c(x_1) = 0$ e $c(x_2) = 1$ che è ottimo per ogni distribuzione di probabilità p su $\{x_1, x_2\}$.

Assumiamo quindi $m > 2$ con l'ipotesi induttiva che Huffman sia ottimo per $k \leq m - 1$. Fissiamo $\langle \mathcal{X}, p \rangle$ arbitraria. Siano $u, v \in \mathcal{X}$ tale che $p(u)$ e $p(v)$ sono minime. Definiamo la sorgente $\langle \mathcal{X}', p' \rangle$ dove $u, v \in \mathcal{X}$ sono rimpiazzati da $z \in \mathcal{X}'$ e dove

$$p'(x) = \begin{cases} p(x) & \text{se } x \neq z, \\ p(u) + p(v) & \text{se } x = z. \end{cases}$$

Sia c' il codice di Huffman per $\langle \mathcal{X}', p' \rangle$. Dato che $|\mathcal{X}'| = m - 1$, c' è ottimo per ipotesi induttiva. Definiamo ora il codice c per \mathcal{X} come

$$c(x) = \begin{cases} c'(x) & \text{se } x \notin \{u, v\}, \\ c'(z)0 & \text{se } x = u, \\ c'(z)1 & \text{se } x = v. \end{cases}$$

Per il Fatto 1, c è di Huffman per $\langle \mathcal{X}, p \rangle$. Vogliamo ora dimostrare che c è anche ottimale. Cominciamo col dimostrare la seguente relazione che ci servirà in seguito

$$\begin{aligned} \mathbb{E}[\ell_c] &= \sum_{x \in \mathcal{X}} \ell_c(x)p(x) \\ &= \sum_{x \in \mathcal{X}'} \ell_{c'}(x)p'(x) - \ell_{c'}(z)p'(z) + \ell_c(u)p(u) + \ell_c(v)p(v) \\ &= \mathbb{E}[\ell_{c'}] - \ell_{c'}(z)p'(z) + (\ell_{c'}(z) + 1)p(u) + (\ell_{c'}(z) + 1)p(v) \\ &= \mathbb{E}[\ell_{c'}] - \ell_{c'}(z)p'(z) + \ell_{c'}(z)p'(z) + p'(z) \\ &= \mathbb{E}[\ell_{c'}] + p'(z). \end{aligned} \tag{2}$$

Per dimostrare l'ottimalità di c consideriamo un altro codice istantaneo c_2 per $\langle \mathcal{X}, p \rangle$ e verifichiamo che $\mathbb{E}[\ell_c] \leq \mathbb{E}[\ell_{c_2}]$. Fissato c_2 , siano $r, s \in \mathcal{X}$ tali che $\ell_{c_2}(r)$ e $\ell_{c_2}(s)$ sono massime.

Esaminiamo ora le posizioni delle foglie r e s nell'albero di codifica per c_2 (che esiste perché c_2 è istantaneo). Se r e s sono fratelli, non facciamo nulla. Se r o s hanno un fratello (diciamo r ha un fratello f), allora possiamo scegliere r e f tali che $\ell_{c_2}(r)$ e $\ell_{c_2}(f)$ sono massime invece di r e s . Se invece né r né s hanno un fratello nell'albero, allora possiamo sostituire alla codifica di ciascun nodo la codifica del padre finché ci riportiamo nella situazione in cui r e s hanno entrambi un fratello. Così facendo riduciamo $\mathbb{E}[\ell_{c_2}]$. Quindi, senza perdita di generalità, possiamo assumere che c_2 sia tale che r e s sono fratelli.

Ora trasformiamo c_2 in un codice \tilde{c}_2 per la stessa sorgente scambiando la codifica di u con quella di r e la codifica di v con quella di s . Ovvero,

$$\tilde{c}_2(x) = \begin{cases} c_2(x) & \text{se } x \notin \{u, v, r, s\}, \\ c_2(u) & \text{se } x = r, \\ c_2(r) & \text{se } x = u, \\ c_2(v) & \text{se } x = s, \\ c_2(s) & \text{se } x = v. \end{cases}$$

Ora esaminiamo la differenza fra la lunghezza media di \tilde{c}_2 e c_2 ,

$$\begin{aligned}
\mathbb{E}[\ell_{\tilde{c}_2}] - \mathbb{E}[\ell_{c_2}] &= \sum_{x \in \mathcal{X}} p(x) (\ell_{\tilde{c}_2}(x) - \ell_{c_2}(x)) \\
&= p(r)\ell_{c_2}(u) + p(u)\ell_{c_2}(r) + p(s)\ell_{c_2}(v) + p(v)\ell_{c_2}(s) \\
&\quad - p(u)\ell_{c_2}(u) - p(r)\ell_{c_2}(r) - p(v)\ell_{c_2}(v) - p(s)\ell_{c_2}(s) \\
&= \underbrace{(p(r) - p(u))}_{\geq 0} \underbrace{(\ell_{c_2}(u) - \ell_{c_2}(r))}_{\leq 0} + \underbrace{(p(s) - p(v))}_{\geq 0} \underbrace{(\ell_{c_2}(v) - \ell_{c_2}(s))}_{\leq 0} \\
&\leq 0.
\end{aligned}$$

I segni delle differenze sono determinati dalla scelta di u, v, r, s in quanto

$$\max\{p(u), p(v)\} \leq \min\{p(r), p(s)\} \quad \min\{\ell_{c_2}(r), \ell_{c_2}(s)\} \geq \max\{\ell_{c_2}(u), \ell_{c_2}(v)\}.$$

Quindi abbiamo dimostrato che $\mathbb{E}[\ell_{\tilde{c}_2}] \leq \mathbb{E}[\ell_{c_2}]$.

Notiamo ora che, dopo lo scambio con r e s , u e v sono diventati fratelli in \tilde{c}_2 . Quindi esiste $w \in \{0, 1\}^*$ tale che $\tilde{c}_2(u) = w0$ e $\tilde{c}_2(v) = w1$. Allo scopo di applicare l'ipotesi induttiva, introduciamo un codice c'_2 per $\langle \mathcal{X}', p' \rangle$ definito come segue

$$c'_2(x) = \begin{cases} \tilde{c}_2(x) & \text{se } x \neq z, \\ w & \text{se } x = z. \end{cases}$$

Possiamo allora scrivere, ricordando che $p'(z) = p(u) + p(v)$,

$$\begin{aligned}
\mathbb{E}[\ell_{\tilde{c}_2}] &= \sum_{x \in \mathcal{X}' : x \neq z} p'(x)\ell_{\tilde{c}_2}(x) + p(u)(\ell_{c'_2}(z) + 1) + p(v)(\ell_{c'_2}(z) + 1) \\
&= \sum_{x \in \mathcal{X}' : x \neq z} p'(x)\ell_{\tilde{c}_2}(x) + p'(z)\ell_{c'_2}(z) + p'(z) \\
&= \mathbb{E}[\ell_{c'_2}] + p'(z).
\end{aligned}$$

Ricordando allora le diseguaglianze precedentemente ottenute, e utilizzando l'ipotesi induttiva per stabilire $\mathbb{E}[\ell_{c'}] \leq \mathbb{E}[\ell_{c'_2}]$, prossiamo quindi scrivere

$$\mathbb{E}[\ell_c] = \mathbb{E}[\ell_{c'}] + p'(z) \leq \mathbb{E}[\ell_{c'_2}] + p'(z) = \mathbb{E}[\ell_{\tilde{c}_2}] \leq \mathbb{E}[\ell_{c_2}].$$

Questo conclude la dimostrazione. \square