

## Lezione 9

Ugo Vaccaro

Abbiamo già visto che la entropia  $H(X)$  di una v.c.  $X$  può essere vista come una misura dell'incertezza media a priori che abbiamo sui valore che la variabile casuale (v.c.)  $X$  potrà assumere. In questa lezione vedremo un'ulteriore interpretazione dell'entropia  $H(X)$  di un v.c.  $X$ . Tale interpretazione è collegata al seguente problema: data una v.c.  $X$  con distribuzione  $\mathbf{p} = (p_1, p_2, \dots, p_n)$ , come possiamo in pratica realizzare un esperimento che abbia esiti  $x_1, x_2, \dots, x_n$  con probabilità  $p_1, p_2, \dots, p_n$ , rispettivamente? Ovviamente, il tutto dipende dalle risorse a nostra disposizione. Effettuiamo un'ipotesi minimale al riguardo, ovvero supponiamo di avere a nostra disposizione solo una moneta bilanciata che genera TESTA (o, equivalentemente, 0), e CROCE (o, equivalentemente, 1), con probabilità  $1/2$  ciascuno. Consideriamo il seguente esempio.

**Esempio 1** *Avendo a disposizione una moneta bilanciata, vogliamo generare la seguente variabile casuale  $X$ :*


$$X = \begin{pmatrix} a & b & c \\ 1/2 & 1/4 & 1/4 \end{pmatrix}$$

*Un metodo potrebbe essere il seguente. Lanciamo la moneta, se esce 0 poniamo  $X = a$ , se esce 1 rilanciamo una seconda volta la moneta. Se esce 10 dai due lanci poniamo  $X = b$ , se esce 11 dai due lanci poniamo  $X = c$ . È chiaro che questo metodo dà  $P\{X = a\} = 1/2, P\{X = b\} = 1/4, P\{X = c\} = 1/4$ , come desideravamo. Qual è il numero medio di lanci (bits 0 e 1) che abbiamo effettuato? Esso sarà pari a  $1 \times (1/2) + 2 \times (1/4) \times 2 \times (1/4) = 1.5$ . Guarda caso,  $H(X) = (1/2) \log 2 + (1/4) \log 4 + (1/4) \log 4 = 1.5$ .*

Per descrivere un generico algoritmo per generare distribuzioni di probabilità attraverso lanci di monete, utilizziamo una struttura ad albero, che è semplicemente un modo per “ricordare” gli esiti dei lanci della moneta. Quindi, un algoritmo di generazione è rappresentato da un albero in cui:


1. ogni nodo, tranne le foglie (che hanno zero figli), ha esattamente 2 figli (tali alberi vengono detti *completi*);
2. ogni foglia è etichettata con uno dei valori  $x$  assunti dalla variabile casuale  $X$  che vogliamo generare;
3. la regola è che ogni lancio di moneta che ha esito 0 ci fa andare dal nodo corrente dell'albero al suo figlio sinistro ed ogni lancio di moneta che ha esito 1 ci fa andare dal nodo corrente dell'albero al suo figlio destro. Quando arriviamo su di una foglia “emettiamo” il valore  $x$  ad essa associato e ripartiamo dalla radice.

Tale rappresentazione è perfettamente generale, e permette di descrivere un qualunque algoritmo di generazione di variabili casuali. L'albero per la generazione della variabile casuale dell'**Esempio 1** ottenuto attraverso il metodo appena descritto sarebbe:



Ci possono essere più alberi che generano la stessa variabile casuale. Ad esempio, anche quest'albero genera la

variabile casuale dell'**Esempio 1**



Questo secondo albero, però, usa in media 2 lanci di moneta per generare ciascun valore della v.c.  $X$ , quindi è peggiore dell'albero precedente che usava solo 1.5 lanci in media.

In generale, si pone quindi il seguente problema: *data un'arbitraria variabile casuale  $X$ , qual è il minimo numero medio di lanci di moneta necessari e sufficienti per generare  $X$ ?*

Dalla definizione di albero che genera variabili casuali, si evince immediatamente che per ogni foglia  $f$  che appare ad un qualche livello  $k$  dell'albero (ovvero per cui esiste un percorso dalla radice dell'albero ad  $f$  composto da  $k$  rami dell'albero), vale che la probabilità  $P(f)$  della foglia è pari a  $2^{-k}$ . Inoltre, ciò che deve ulteriormente valere per un albero che rappresenta un corretto algoritmo che genera la v.c.  $X$ , è che per ogni valore  $x$  della variabile casuale  $X$  si deve avere:

$$\sum_{f: f \text{ è etichettata con } x} P(f) = P\{X = x\} = P(x). \quad (1)$$

Il numero medio di lanci di monete necessario sarà ovviamente

$$\sum_{f: f \text{ foglie di } T} P(f) \times (\text{livello cui appare la foglia } f \text{ in } T). \quad (2)$$

Denotiamo tale ultima quantità con il simbolo  $E[T]$ . Essa può essere vista come il valor medio dei livelli cui le foglie dell'albero  $T$  appaiono (pesati dalle probabilità delle rispettive foglie), e viene generalmente chiamata *altezza media* di  $T$ .

Per un dato albero  $T$  e foglia  $f$  di  $T$ , denotiamo con  $k(f)$  il livello cui appare  $f$  in  $T$ . Consideriamo la distribuzione di probabilità indotta sulle foglie di  $T$  dai lanci di monete. Come abbiamo già detto, ogni foglia avrà probabilità  $P(f) = 2^{-k(f)}$  per cui l'entropia  $H$  di tale distribuzione sarà pari a

$$H = \sum_{f: f \text{ foglia di } T} 2^{-k(f)} \log \frac{1}{2^{-k(f)}} = \sum_{f: f \text{ foglia di } T} k(f) 2^{-k(f)} = E[T] \quad (3)$$

dove l'ultima eguaglianza è a causa della (2).

Quest'ultimo fatto ha già un'interessante conseguenza. Se la v.c.  $X$  che vogliamo generare è di tipo molto particolare, ovvero per se per ogni valore  $x$  che la v.c.  $X$  può assumere vale che la probabilità  $P\{X = x\}$  è della forma  $2^{-k(x)}$ , per qualche intero  $k(x)$  (tali distribuzioni di probabilità vengono dette *diadiche*), allora un semplice albero  $T$  che genera  $X$  consiste nell'albero completo  $T$  avente una foglia  $f(x)$  associata ad ogni possibile valore  $x$  che la variabile casuale  $X$  può assumere, e la profondità della foglia  $f(x)$  nell'albero è esattamente pari a  $k(x)$  (nell'**Esempio 1** la variabile casuale  $X$  considerata era diadica e l'albero che la generava era ottenuto attraverso la considerazione appena fatta). In più, l'altezza media  $E[T]$  dell'albero  $T$  così ottenuto e che genera  $X$  (e quindi il numero medio di lanci di monete che ci occorrono per generare  $X$  mediante  $T$ ) è esattamente pari all'entropia  $H(X)$  di  $X$  (ciò in virtù della (3)). Studiamo ora il caso *generale* di v.c.  $X$  in cui le probabilità  $P\{X = x\}$  non sono di tipo diadico. Presentiamo prima un risultato intermedio.

**Lemma 1** *Sia  $Y$  una v.c. e  $f$  una funzione. Vale*

$$H(f(Y)) \leq H(Y).$$

Dimostreremo questo risultato in seguito, come conseguenza di risultati più generali. Per il momento, diamo il seguente argomento per convincerci della sua correttezza. Supponiamo che la v.c.  $X$  assuma valori in  $\{x_1, \dots, x_n\}$ .

Innanzitutto, osserviamo che se  $f$  è iniettiva, allora ovviamente la v.c.  $f(Y)$  ha la stessa distribuzione di  $X$  (in quanto la  $f$  non fa altro che “rietichettare” i valori  $y$  assunti dalla  $Y$  nei valori  $f(y)$  assunti dalla  $f(Y)$ , senza cambiare le rispettive probabilità. Se invece  $f$  non è iniettiva, allora esisteranno un certo numero  $k \geq 2$  di valori  $x_{i_1}, \dots, x_{i_k}$  assunti dalla  $X$ , con probabilità  $P\{X = x_{i_1}\} = p(x_{i_1}), \dots, P\{X = x_{i_k}\} = p(x_{i_k})$  rispettivamente, per cui  $f(x_{i_1}) = \dots = f(x_{i_k}) = y$ . Varrà che  $P\{f(X) = y\} = p(x_{i_1}) + \dots + p(x_{i_k})$ . Supponiamo che la  $f$  sia iniettiva sul resto di  $X$ , ovvero su  $X \setminus \{x_{i_1}, \dots, x_{i_k}\}$  (l'argomento si estende facilmente al caso generale, raggruppando in insiemi disgiunti i valori assunti dalla v.c.  $X$  che hanno la stessa immagine secondo la funzione  $f$ ). Allora varrà

$$\begin{aligned} H(f(Y)) - H(Y) &= (p(x_{i_1}) + \dots + p(x_{i_k})) \log \frac{1}{p(x_{i_1}) + \dots + p(x_{i_k})} - p(x_{i_1}) \log \frac{1}{p(x_{i_1})} - \dots - p(x_{i_k}) \log \frac{1}{p(x_{i_k})} \\ &= p(x_{i_1}) \log \frac{1}{p(x_{i_1}) + \dots + p(x_{i_k})} + \dots + p(x_{i_k}) \log \frac{1}{p(x_{i_1}) + \dots + p(x_{i_k})} \\ &\quad - p(x_{i_1}) \log \frac{1}{p(x_{i_1})} - \dots - p(x_{i_k}) \log \frac{1}{p(x_{i_k})} \\ &= p(x_{i_1}) \log \frac{p(x_{i_1})}{p(x_{i_1}) + \dots + p(x_{i_k})} + \dots + p(x_{i_k}) \log \frac{p(x_{i_k})}{p(x_{i_1}) + \dots + p(x_{i_k})} \\ &\leq 0 \end{aligned}$$

dove l'ultima disuguaglianza è conseguenza del fatto che gli argomenti del logaritmo sono tutti  $\leq 1$ . Possiamo ora provare il seguente risultato.

**Teorema 1** *Per ogni albero  $T$  che genera la v.c.  $X$ , il numero medio di lanci di monete usate è necessariamente pari almeno all'entropia di  $X$ , ovvero*

$$E[T] \geq H(X). \quad (4)$$

**Dimostrazione.** Dato l'albero  $T$ , sia  $Y$  la variabile casuale con distribuzione di probabilità

$$P = \{P(f) : f \text{ è foglia di } T\},$$

dove ricordiamo  $P(f) = 2^{-k(f)}$  e  $k(f)$  è la profondità della foglia  $f$  nell'albero  $T$ . Per quanto prima osservato, vale che  $H(Y) = E[T]$ . Ora, sulla base delle considerazioni che ci hanno portato alla (1), possiamo osservare la v.c.  $X$  è ottenibile mediante l'applicazione di una funzione  $f$  alla v.c.  $Y$  (di fatto la funzione  $f$  mappa uno o più valori della v.c.  $Y$ , ovvero una o più foglie di  $T$ , in un qualche singolo valore della v.c.  $X$ ). Dal Lemma 1 otteniamo

$$E[T] = H(Y) \geq H(f(Y)) = H(X).$$

□

Quindi, per generare una qualsiasi v.c.  $X$  ci occorrono in media un numero di lanci di moneta pari almeno all'entropia di  $X$ . Ricordiamo che se la v.c.  $X$  assume valori  $x$  con probabilità della forma  $2^{-k(x)}$ , con  $k(x)$  intero, (ovvero se la distribuzione è diadica), allora un albero che genera  $X$  e che usa un numero medio di lanci di moneta proprio pari a  $H(X)$  (e quindi il *migliore* possibile, in virtù del Teorema 1) lo sappiamo costruire.

Consideriamo ora il caso di v.c. generali, ovvero con distribuzioni non necessariamente diadiche. L'idea è di esprimere ogni probabilità  $P(x)$ , con cui la generica v.c.  $X$  assume valore  $x$ , come somma di potenze di  $1/2$ , ovvero di valori della forma  $2^{-k_1}, 2^{-k_2}, \dots$ . In altri termini, l'idea è di ottenere innanzitutto la rappresentazione del numero  $P(x)$  in base  $1/2$ . Ad esempio, se  $P(x) = 7/8$ , potremmo scrivere  $7/8 = 1/2 + 1/4 + 1/8$ , successivamente potremmo costruire un albero  $T$  che ha una foglia etichettata  $x$  al livello 1 (ovvero di probabilità  $1/2$ ), una foglia etichettata  $x$  al livello 2 (e quindi di probabilità  $1/4$ ), ed infine una foglia etichettata  $x$  al livello 3 (e quindi di probabilità  $1/8$ ). Coticchè, usando l'albero  $T$  e lanciando la moneta bilanciata, arriveremo in una qualsiasi delle tre foglie etichettate  $x$  con probabilità pari a  $1/2 + 1/4 + 1/8 = 7/8$ , che è esattamente la probabilità che la v.c.  $X$  assuma valore  $x$ . Chiaramente, questo procedimento lo possiamo ripetere per ogni valore  $x$  che la

v.c. assume, ed ottenere quindi un albero che genera la corrispondente distribuzione di probabilità  $P = \{P(x) : \forall x \text{ valore assunto da } X\}$ .


**Esempio 2** Sia

$$X = \begin{pmatrix} a & b \\ 2/3 & 1/3 \end{pmatrix}$$

Scrivendo  $2/3$  ed  $1/3$  in binario otteniamo

$$\frac{2}{3} = \frac{1}{2} + \frac{1}{8} + \frac{1}{32} + \dots \quad \frac{1}{3} = \frac{1}{4} + \frac{1}{16} + \frac{1}{64} + \dots$$

e l'albero che genera  $X$  sarebbe



che in questo caso è infinito, in quanto sia la rappresentazione binaria di  $2/3$  che di  $1/3$  ha un numero infinito di termini (ma ciò non ci disturba affatto).



Il seguente Teorema rappresenta il risultato principale della lezione e va sotto il nome di Teorema di Knuth e Yao, dal nome degli scopritori.

**Teorema 2** Il minimo numero medio  $E[T]$  di lanci di moneta richiesto da ogni algoritmo che genera la v.c.  $X$  è tale che

D.E. Knuth

A.C. Yao

$$H(X) \leq E[T] < H(X) + 2,$$

dove  $H(X) = -\sum_x P\{X = x\} \log\{X = x\}$  è l'entropia della v.c.  $X$ .

**Dimostrazione.** La disuguaglianza  $E[T] \geq H(X)$  l'abbiamo già dimostrata nel Teorema 1. Sia  $\mathbf{p} = (p_1, p_2, \dots, p_n)$  la distribuzione di probabilità della v.c.  $X$ . Esprimiamo ogni  $p_i$  come somma di potenze di  $1/2$ . Più precisamente scriviamo

$$p_i = p_i^{(1)} + p_i^{(2)} + \dots \tag{5}$$

dove ogni termine  $p_i^{(j)}$  o è pari a 0 oppure è un'opportuna potenza di  $1/2$ . Usando tutti i termini  $p_i^{(j)}$ , per ogni  $i$  e per ogni  $j$ , scriviamo la nuova distribuzione di probabilità (che può avere un numero infinito di termini ma, ancora, ciò non ci disturba affatto) data da:

$$(p_1^{(1)}, p_1^{(2)}, \dots, p_2^{(1)}, p_2^{(2)}, \dots, p_n^{(1)}, p_n^{(2)}, \dots) \tag{6}$$

e costruiamo un albero completo  $T$  che ha una foglia associata ad ogni una delle potenze di  $1/2$  che compare in (5). Ovvero, se  $p_i^{(j)} = 2^{-k_{ij}}$ , per qualche intero  $k_{ij}$ , allora l'albero  $T$  avrà una foglia alla profondità  $k_{ij}$ . Questa costruzione è sicuramente possibile a causa della Disuguaglianza di Kraft, mostrata nella Lezione 4.<sup>1</sup> Infatti vale

<sup>1</sup>Tecnicamente, abbiamo dimostrato la Disuguaglianza di Kraft nel caso *finito*, ma è semplice verificare che la dimostrazione a suo tempo data funziona anche nel caso infinito.

che

$$1 = \sum_{i=1}^n p_i = \sum_{i=1}^n \sum_{j \geq 1} p_i^{(j)} = \sum_{i=1}^n \sum_{j \geq 1: p_i^{(j)} > 0} 2^{-k_{ij}},$$

quindi un albero con foglie nelle giuste profondità  $k_{ij}$  esiste. Sia  $Y$  la v.c con distribuzione di probabilità data dalla (6). Poichè la distribuzione (6) è diadica, sappiamo dalla (3) che

$$E[T] = H(Y). \quad (7)$$

Ora, la v.c che vogliamo generare è funzione della v.c.  $Y$ , nel senso che per ottenere  $X$  da  $Y$  etichettiamo tutte le foglie aventi probabilità  $p_i^{(j)}$  che appaiono nell'espansione (5) di  $p_i$  con lo stesso valore  $x_i$  della v.c.  $X$ , ovvero con il valore  $x_i$  che ha probabilità di occorrere pari a  $p_i$ . Osserviamo che

$$H(Y) = - \sum_{i=1}^n \sum_{j \geq 1} p_i^{(j)} \log p_i^{(j)} = \sum_{i=1}^n \sum_{j: p_i^{(j)} > 0} j 2^{-j}$$

in quanto, come abbiamo più volte detto, ogni  $p_i^{(j)}$  o è 0 oppure è una potenza di  $1/2$ . Sia

$$T_i = \sum_{j: p_i^{(j)} > 0} j 2^{-j} \quad \text{cosicchè} \quad H(Y) = \sum_{i=1}^n T_i. \quad (8)$$

Notiamo che per ogni probabilità  $p_i$  possiamo sempre trovare un numero naturale  $n_i$  tale che  $2^{-(n_i-1)} > p_i \geq 2^{-n_i}$ , ovvero

$$n_i - 1 < -\log p_i \leq n_i, \quad (9)$$

per cui  $p_i^{(j)} > 0$  solo se  $j \geq n_i$ , e quindi possiamo riscrivere  $T_i$  come

$$T_i = \sum_{j: j \geq n_i, p_i^{(j)} > 0} j 2^{-j}.$$

Ricordando che

$$\forall i = 1, \dots, n \quad p_i = \sum_{j: j \geq n_i, p_i^{(j)} > 0} 2^{-j}$$

passiamo a provare che

$$T_i < -p_i \log p_i + 2p_i. \quad (10)$$

Calcolando la differenza tra  $T_i$  e  $-p_i \log p_i + 2p_i$  otteniamo:

$$\begin{aligned}
T_i + p_i \log p_i - 2p_i &< T_i - p_i(n_i - 1) - 2p_i && \text{(dalla (9))} \\
&= T_i - (n_i - 1 + 2)p_i \\
&= \sum_{j:j \geq n_i, p_i^{(j)} > 0} j2^{-j} - (n_i + 1) \sum_{j:j \geq n_i, p_i^{(j)} > 0} 2^{-j} \\
&= \sum_{j:j \geq n_i, p_i^{(j)} > 0} (j - n_i - 1)2^{-j} \\
&= -2^{-n_i} + 0 + \sum_{j:j \geq n_i + 2, p_i^{(j)} > 0} (j - n_i - 1)2^{-j} \\
&= -2^{-n_i} + \sum_{k:k \geq 1, p_i^{(k+n_i+1)} > 0} k2^{-(k+n_i+1)} && \text{(cambiando variabili nella somma)} \\
&\leq -2^{-n_i} + \sum_{k:k \geq 1} k2^{-(k+n_i+1)} && \text{(estendendo la somma su tutti i termini)} \\
&= -2^{-n_i} + 2^{-(n_i+1)} \sum_{k:k \geq 1} k2^{-k} \\
&= -2^{-n_i} + 2^{-(n_i+1)} \times 2 && \text{(essendo } \sum_{k:k \geq 1} k2^{-k} = 2) \\
&= 0.
\end{aligned}$$

e quindi la (10) è vera. Ricordando, dalla (7) e (8), che

$$E[T] = H(Y) = \sum_{i=1}^n T_i,$$

otteniamo dalla (10) appena provata che che

$$E[T] = \sum_{i=1}^n T_i < -\sum_{i=1}^n (p_i \log p_i - 2p_i) = -\sum_{i=1}^n p_i \log p_i + 2 \sum_{i=1}^n p_i = H(X) + 2.$$

Con questo la prova del Teorema è completata. □