

**Termo avanzada**

**Guía 3: entropía e información**

---

# Entropía

# Definición

Experimento aleatorio con  $M$  resultados posibles, distribución de probabilidad  $p$ . **Entropía** de esta distribución:

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

**La entropía mide el grado de incertidumbre acerca del resultado del experimento**, porque es mínima cuando el resultado se conoce con certeza y máxima cuando se desconoce completamente.

# Significado

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

# Significado

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Certeza**  $\Rightarrow S = 0$

# Significado

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Certeza**  $\Rightarrow S = 0$

$$\log 1 = 0 \quad 0 \log 0 = \lim_{\epsilon \rightarrow 0} \epsilon \log \epsilon = 0$$

# Significado

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Certeza**  $\Rightarrow S = 0$

$$\log 1 = 0 \quad 0 \log 0 = \lim_{\epsilon \rightarrow 0} \epsilon \log \epsilon = 0$$

- **Cualquier**  $p \Rightarrow S \geq 0$

# Significado

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Certeza**  $\Rightarrow S = 0$

$$\log 1 = 0 \quad 0 \log 0 = \lim_{\epsilon \rightarrow 0} \epsilon \log \epsilon = 0$$

- **Cualquier**  $p \Rightarrow S \geq 0$

$$0 \leq p(r) \leq 1$$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p$**   $\Rightarrow S \leq \log M$ .

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p \Rightarrow S \leq \log M$ .** Clave:  $\log x \leq x - 1$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p \Rightarrow S \leq \log M$ .** Clave:  $\log x \leq x - 1$

$$S(p) - \log M$$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p \Rightarrow S \leq \log M$ .** Clave:  $\log x \leq x - 1$

$$S(p) - \log M = S(p) - \sum_{r=1}^M p(r) \log M$$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p \Rightarrow S \leq \log M$ .** Clave:  $\log x \leq x - 1$

$$S(p) - \log M = S(p) - \sum_{r=1}^M p(r) \log M = - \sum_{r=1}^M p(r) \log[Mp(r)]$$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p$**   $\Rightarrow S \leq \log M$ . *Clave:*  $\log x \leq x - 1$

$$\begin{aligned} S(p) - \log M &= S(p) - \sum_{r=1}^M p(r) \log M = - \sum_{r=1}^M p(r) \log[Mp(r)] \\ &= \sum_{r=1}^M p(r) \log \left[ \frac{1}{Mp(r)} \right] \end{aligned}$$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p \Rightarrow S \leq \log M$ .** Clave:  $\log x \leq x - 1$

$$\begin{aligned} S(p) - \log M &= S(p) - \sum_{r=1}^M p(r) \log M = - \sum_{r=1}^M p(r) \log[Mp(r)] \\ &= \sum_{r=1}^M p(r) \log \left[ \frac{1}{Mp(r)} \right] \leq \sum_{r=1}^M p(r) \left[ \frac{1}{Mp(r)} - 1 \right] \end{aligned}$$

$$S(p) = - \sum_{r=1}^M p(r) \log p(r)$$

- **Máxima incertidumbre:**  $p(r) = 1/M \Rightarrow S = \log M$
- **Cualquier  $p \Rightarrow S \leq \log M$ .** Clave:  $\log x \leq x - 1$

$$\begin{aligned} S(p) - \log M &= S(p) - \sum_{r=1}^M p(r) \log M = - \sum_{r=1}^M p(r) \log[Mp(r)] \\ &= \sum_{r=1}^M p(r) \log \left[ \frac{1}{Mp(r)} \right] \leq \sum_{r=1}^M p(r) \left[ \frac{1}{Mp(r)} - 1 \right] = 0 \end{aligned}$$

La varianza no mide eso también?

## La varianza no mide eso también?

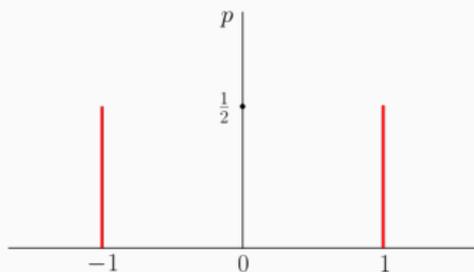
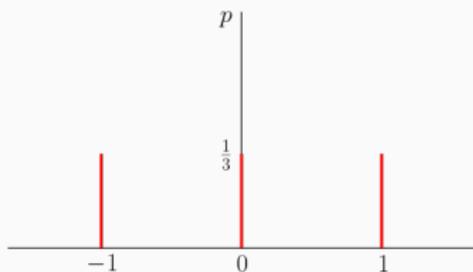
No.

## La varianza no mide eso también?

No. Ejemplo: experimento con tres resultados posibles, 0 y  $\pm 1$ , y dos distribuciones de probabilidad.

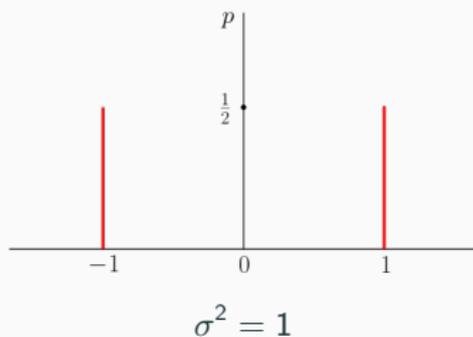
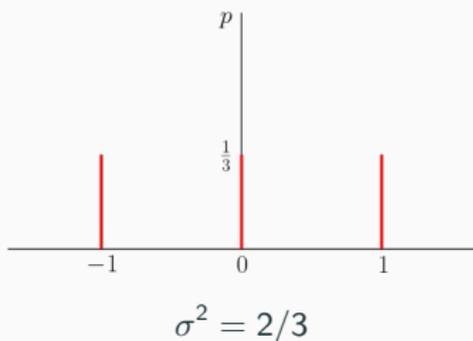
## La varianza no mide eso también?

No. Ejemplo: experimento con tres resultados posibles, 0 y  $\pm 1$ , y dos distribuciones de probabilidad.



## La varianza no mide eso también?

No. Ejemplo: experimento con tres resultados posibles, 0 y  $\pm 1$ , y dos distribuciones de probabilidad.



## Entropía condicional

## Definición

Dos experimentos,  $A$  y  $B$ ,  $p(\alpha|\beta)$  probabilidad de que el resultado de  $A$  sea  $\alpha$  dado que el de  $B$  es  $\beta$ .

# Definición

Dos experimentos,  $A$  y  $B$ ,  $p(\alpha|\beta)$  probabilidad de que el resultado de  $A$  sea  $\alpha$  dado que el de  $B$  es  $\beta$ . **Entropía condicional** de  $A$  dado  $B$ :

$$S(A|B) = \sum_{\beta} p(\beta) S(p(\cdot|\beta))$$

# Definición

Dos experimentos,  $A$  y  $B$ ,  $p(\alpha|\beta)$  probabilidad de que el resultado de  $A$  sea  $\alpha$  dado que el de  $B$  es  $\beta$ . **Entropía condicional** de  $A$  dado  $B$ :

$$S(A|B) = \sum_{\beta} p(\beta)S(p(\cdot|\beta)) = - \sum_{\alpha,\beta} p(\beta)p(\alpha|\beta) \log p(\alpha|\beta)$$

# Definición

Dos experimentos,  $A$  y  $B$ ,  $p(\alpha|\beta)$  probabilidad de que el resultado de  $A$  sea  $\alpha$  dado que el de  $B$  es  $\beta$ . **Entropía condicional** de  $A$  dado  $B$ :

$$\begin{aligned} S(A|B) &= \sum_{\beta} p(\beta) S(p(\cdot|\beta)) = - \sum_{\alpha, \beta} p(\beta) p(\alpha|\beta) \log p(\alpha|\beta) \\ &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)} \end{aligned}$$

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

# Propiedades

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

# Propiedades

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$S(A|B) - S(A)$$

# Propiedades

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$S(A|B) - S(A) = S(A|B) + \sum_{\alpha} p(\alpha) \log p(\alpha)$$

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$\begin{aligned} S(A|B) - S(A) &= S(A|B) + \sum_{\alpha} p(\alpha) \log p(\alpha) \\ &= S(A|B) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha) \end{aligned}$$

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$\begin{aligned} S(A|B) - S(A) &= S(A|B) + \sum_{\alpha} p(\alpha) \log p(\alpha) \\ &= S(A|B) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha) \\ &= \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} \end{aligned}$$

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$\begin{aligned} S(A|B) - S(A) &= S(A|B) + \sum_{\alpha} p(\alpha) \log p(\alpha) \\ &= S(A|B) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha) \\ &= \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} \\ &\leq \sum_{\alpha, \beta} p(\alpha, \beta) \left[ \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} - 1 \right] \end{aligned}$$

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$\begin{aligned} S(A|B) - S(A) &= S(A|B) + \sum_{\alpha} p(\alpha) \log p(\alpha) \\ &= S(A|B) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha) \\ &= \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} \\ &\leq \sum_{\alpha, \beta} p(\alpha, \beta) \left[ \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} - 1 \right] = 0 \end{aligned}$$

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

- $S(A|B) \leq S(A)$

$$\begin{aligned} S(A|B) - S(A) &= S(A|B) + \sum_{\alpha} p(\alpha) \log p(\alpha) \\ &= S(A|B) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha) \\ &= \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} \\ &\leq \sum_{\alpha, \beta} p(\alpha, \beta) \left[ \frac{p(\alpha)p(\beta)}{p(\alpha, \beta)} - 1 \right] = 0 \end{aligned}$$

- $S(A|BC) \leq S(A|B)$

## Relación con la entropía

$$S(A|B) = - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)}$$

## Relación con la entropía

$$\begin{aligned} S(A|B) &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)} \\ &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha, \beta) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\beta) \end{aligned}$$

## Relación con la entropía

$$\begin{aligned} S(A|B) &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)} \\ &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha, \beta) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\beta) \\ &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha, \beta) + \sum_{\beta} p(\beta) \log p(\beta) \end{aligned}$$

## Relación con la entropía

$$\begin{aligned} S(A|B) &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log \frac{p(\alpha, \beta)}{p(\beta)} \\ &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha, \beta) + \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\beta) \\ &= - \sum_{\alpha, \beta} p(\alpha, \beta) \log p(\alpha, \beta) + \sum_{\beta} p(\beta) \log p(\beta) \\ &= S(AB) - S(B) \end{aligned}$$

## Reescribamos las propiedades

$$S(A|B) = S(AB) - S(B)$$

## Reescribamos las propiedades

$$S(A|B) = S(AB) - S(B)$$

- $S(A|B) \leq S(A) \Leftrightarrow S(AB) \leq S(A) + S(B)$

## Reescribamos las propiedades

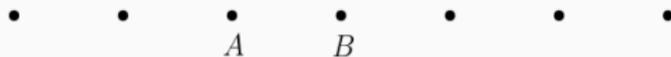
$$S(A|B) = S(AB) - S(B)$$

- $S(A|B) \leq S(A) \Leftrightarrow S(AB) \leq S(A) + S(B)$  **Subaditividad**

## Reescribamos las propiedades

$$S(A|B) = S(AB) - S(B)$$

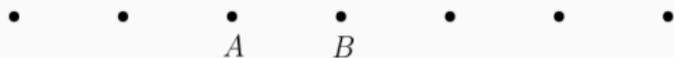
- $S(A|B) \leq S(A) \Leftrightarrow S(AB) \leq S(A) + S(B)$  **Subaditividad**



## Reescribamos las propiedades

$$S(A|B) = S(AB) - S(B)$$

- $S(A|B) \leq S(A) \Leftrightarrow S(AB) \leq S(A) + S(B)$  **Subaditividad**



- $S(A|BC) \leq S(A|B) \Leftrightarrow S(ABC) + S(B) \leq S(AB) + S(BC)$

## Reescribamos las propiedades

$$S(A|B) = S(AB) - S(B)$$

- $S(A|B) \leq S(A) \Leftrightarrow S(AB) \leq S(A) + S(B)$  **Subaditividad**



- $S(A|BC) \leq S(A|B) \Leftrightarrow S(ABC) + S(B) \leq S(AB) + S(BC)$   
**Subaditividad fuerte**

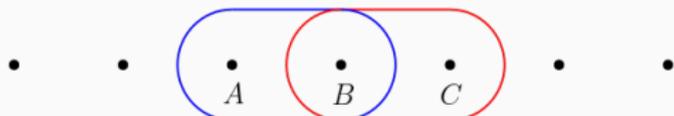
# Reescribamos las propiedades

$$S(A|B) = S(AB) - S(B)$$

- $S(A|B) \leq S(A) \Leftrightarrow S(AB) \leq S(A) + S(B)$  **Subaditividad**



- $S(A|BC) \leq S(A|B) \Leftrightarrow S(ABC) + S(B) \leq S(AB) + S(BC)$   
**Subaditividad fuerte**



# Información

# Incertidumbre e información

A mayor incertidumbre, mayor es la información que nos va a dar el resultado del experimento  $\Rightarrow$  **La entropía mide información.**

# Incertidumbre e información

A mayor incertidumbre, mayor es la información que nos va a dar el resultado del experimento  $\Rightarrow$  **La entropía mide información.**

Shannon (*A mathematical theory of communication*, 1948) formula esto de manera cuantitativa.

## Entropía de una fuente de mensajes

Fuente de mensajes,  $p_N$  distribución de probabilidad correspondiente a los mensajes de  $N$  caracteres.

# Entropía de una fuente de mensajes

Fuente de mensajes,  $p_N$  distribución de probabilidad correspondiente a los mensajes de  $N$  caracteres. Entropía de esta distribución:

$$S_N = - \sum_{m=1}^{M_N} p_N(m) \log p_N(m)$$

# Entropía de una fuente de mensajes

Fuente de mensajes,  $p_N$  distribución de probabilidad correspondiente a los mensajes de  $N$  caracteres. Entropía de esta distribución:

$$S_N = - \sum_{m=1}^{M_N} p_N(m) \log p_N(m)$$

(si  $A$  es el número de caracteres distintos,  $M_N = A^N$ ).

# Entropía de una fuente de mensajes

Fuente de mensajes,  $p_N$  distribución de probabilidad correspondiente a los mensajes de  $N$  caracteres. Entropía de esta distribución:

$$S_N = - \sum_{m=1}^{M_N} p_N(m) \log p_N(m)$$

(si  $A$  es el número de caracteres distintos,  $M_N = A^N$ ).

**Entropía por caracter de la fuente:**

$$s = \lim_{N \rightarrow \infty} \frac{S_N}{N}$$

# Entropía de una fuente de mensajes

Fuente de mensajes,  $p_N$  distribución de probabilidad correspondiente a los mensajes de  $N$  caracteres. Entropía de esta distribución:

$$S_N = - \sum_{m=1}^{M_N} p_N(m) \log p_N(m)$$

(si  $A$  es el número de caracteres distintos,  $M_N = A^N$ ).

**Entropía por caracter de la fuente:**

$$s = \lim_{N \rightarrow \infty} \frac{S_N}{N}$$

**Shannon:**  $s$  (calculando el log en base 2) es el mínimo número de bits por caracter para codificar los mensajes de la fuente.

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N)$$

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N) = p_1(x_N)$$

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N) = p_1(x_N)$$

La entropía por carácter en esta aproximación se denota  $s_1$ , y sólo involucra  $p_1$ .

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N) = p_1(x_N)$$

La entropía por carácter en esta aproximación se denota  $s_1$ , y sólo involucra  $p_1$ .

- **Orden 2:** suponer que el proceso de generación de mensajes es de Markov,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N | x_{N-1})$$

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N) = p_1(x_N)$$

La entropía por caracter en esta aproximación se denota  $s_1$ , y sólo involucra  $p_1$ .

- **Orden 2:** suponer que el proceso de generación de mensajes es de Markov,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N | x_{N-1}) = \frac{p_2(x_{N-1}, x_N)}{p_1(x_{N-1})}$$

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N) = p_1(x_N)$$

La entropía por caracter en esta aproximación se denota  $s_1$ , y sólo involucra  $p_1$ .

- **Orden 2:** suponer que el proceso de generación de mensajes es de Markov,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N | x_{N-1}) = \frac{p_2(x_{N-1}, x_N)}{p_1(x_{N-1})}$$

La entropía por caracter en esta aproximación se denota  $s_2$ , y sólo involucra  $p_1$  y  $p_2$ .

# Aproximaciones

Mensaje de  $N$  caracteres:  $m = (x_1, \dots, x_N)$

- **Orden 1:** suponer que los caracteres son independientes,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N) = p_1(x_N)$$

La entropía por carácter en esta aproximación se denota  $s_1$ , y sólo involucra  $p_1$ .

- **Orden 2:** suponer que el proceso de generación de mensajes es de Markov,

$$p(x_N | x_1, \dots, x_{N-1}) = p(x_N | x_{N-1}) = \frac{p_2(x_{N-1}, x_N)}{p_1(x_{N-1})}$$

La entropía por carácter en esta aproximación se denota  $s_2$ , y sólo involucra  $p_1$  y  $p_2$ .

- Y así sucesivamente.

Shannon muestra que  $\lim_{n \rightarrow \infty} s_n = s$

# Aproximaciones

Shannon muestra que  $\lim_{n \rightarrow \infty} s_n = s$

Además, subaditividad fuerte  $\Rightarrow s_{n+1} \leq s_n$

# Aproximaciones

Shannon muestra que  $\lim_{n \rightarrow \infty} s_n = s$

Además, subaditividad fuerte  $\Rightarrow s_{n+1} \leq s_n \Rightarrow$  Las  $s_n$  dan una cota superior para  $s$ , que es mejor cuanto mayor sea  $n$ .

# Moby Dick

## Qué hay que hacer?

Calcular la entropía por caracter de Herman Melville (o mejor dicho sus aproximaciones  $s_1$ ,  $s_2$  y  $s_3$ ) a partir de Moby Dick.

Para eso, van a tener que calcular  $p_1$ ,  $p_2$  y  $p_3$ , y eso se hace contando cuántas veces aparece cada caracter, bigrama y trigrama en Moby Dick.

Por ejemplo, en el mensaje 'ah re':

- Caracteres: 'a', 'h', ' ', 'r', 'e'
- Bigramas: 'ah', 'h ', ' r', 're'
- Trigramas: 'ah ', 'h r', ' re'

# Algunas referencias

- El paper original de Sannon:

<http://people.math.harvard.edu/~ctm/home/text/others/shannon/entropy/entropy.pdf>

- Un paper posterior donde calcula  $s_1$ ,  $s_2$  y  $s_3$  a partir de las frecuencias tabuladas de los  $n$ -gramas en inglés:

[https://www.princeton.edu/~wbialek/rome/refs/shannon\\_51.pdf](https://www.princeton.edu/~wbialek/rome/refs/shannon_51.pdf)

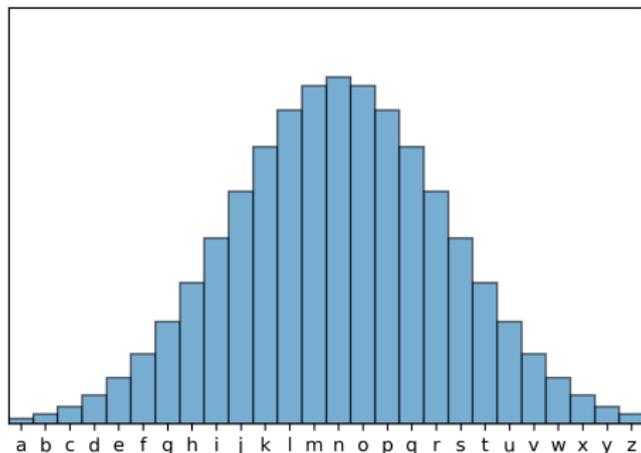
- Una página donde van a encontrar las frecuencias de los  $n$ -gramas en varios idiomas, para que puedan chequear sus resultados:

<http://practicalcryptography.com/cryptanalysis/letter-frequencies-various-languages/>

En esta página no se contabilizan los espacios, así que para poder comparar deberán eliminar los espacios de sus archivos.

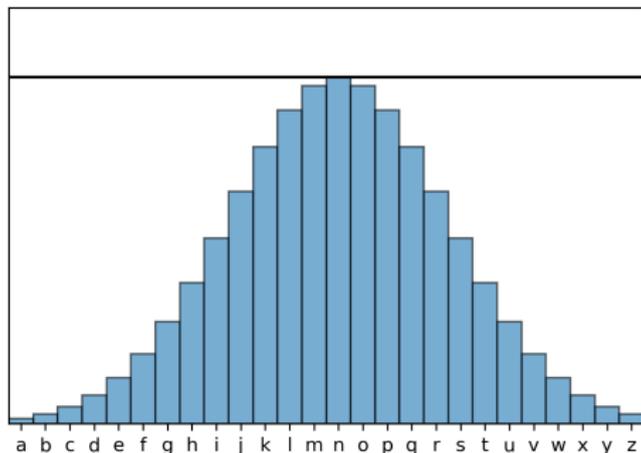
## Apéndice

Para los que quieran hacer el ítem (f). Cómo generar letras distribuidas con la distribución que queramos?



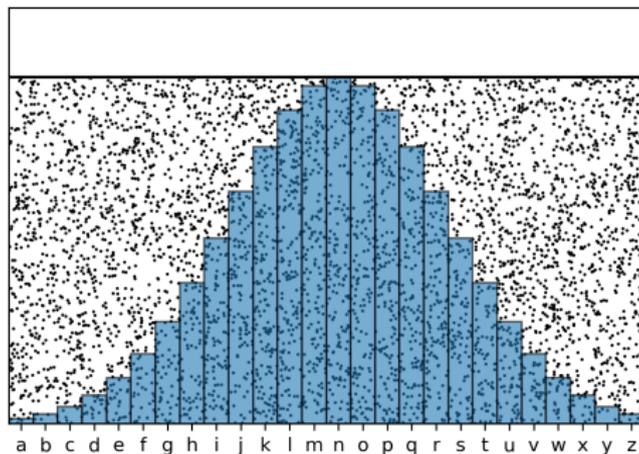
## Apéndice

Para los que quieran hacer el ítem (f). Cómo generar letras distribuidas con la distribución que queramos?



# Apéndice

Para los que quieran hacer el ítem (f). Cómo generar letras distribuidas con la distribución que queramos?



# Apéndice

Para los que quieran hacer el ítem (f). Cómo generar letras distribuidas con la distribución que queramos?

