

Question 1. À chaque seconde un singe appuie au hasard sur une touche du clavier. Combien de temps θ se passera-t-il en moyenne pour que le mot ABRACADABRA apparaisse à l'écran ?

Soient Σ un alphabet fini de $m := |\Sigma|$ lettres, $\mathbf{p} := p_1 \cdots p_k$ un mot de $k \geq 1$ lettres formé sur Σ , et \mathcal{T} l'ensemble des mots sur Σ terminant par \mathbf{p} et ne comportant aucune autre occurrence de \mathbf{p} . Il s'agit de déterminer la longueur moyenne d'un mot de \mathcal{T} , autrement dit de calculer

$$\theta := \sum_{w \in \mathcal{T}} \frac{|w|}{m^{|w|}} = \sum_{n=0}^{+\infty} \frac{nt_n}{m^n},$$

où $t_n, n \geq 0$, est le nombre de mots de \mathcal{T} de longueur n . Pour cela nous allons expliciter la somme de la série génératrice $T(X) := \sum_{n=0}^{+\infty} t_n X^n$. En effet, $\theta = \frac{1}{m} T'(\frac{1}{m})!$

Soient \mathcal{S} l'ensemble des mots sur Σ ne comportant aucune occurrence de \mathbf{p} , et $S(X)$ la série génératrice associée :

$$S(X) := \sum_{w \in \mathcal{S}} X^{|w|} := \sum_{n=0}^{+\infty} s_n X^n,$$

où $s_n, n \geq 0$, est le nombre de mots de \mathcal{S} de longueur n . Notons que \mathcal{S} contient le mot vide ε ($s_0 = 1$) et que les ensembles \mathcal{S} et \mathcal{T} sont disjoints. Nous allons chercher un système à deux équations reliant $S(X)$ et $T(X)$.

Première équation. Nous avons

$$\mathcal{S} \sqcup \mathcal{T} = \{\varepsilon\} \sqcup (\mathcal{S} \cdot \Sigma).$$

Démonstration. Si $w \in \mathcal{S}$, alors soit $w = \varepsilon$, soit w est de la forme $w = w'a$ avec $a \in \Sigma$ et $w' \in \mathcal{S}$ (sinon w contiendrait une occurrence de \mathbf{p}). De même, si $w \in \mathcal{T}$, alors w est de la forme $w = w'a$ avec $a \in \Sigma$ et $w' \in \mathcal{S}$ (sinon w contiendrait au moins deux occurrences de \mathbf{p}). Réciproquement, si $w = \varepsilon$ alors $w \in \mathcal{S}$, et si $w = w'a$ avec $a \in \Sigma$ et $w' \in \mathcal{S}$, alors a termine ou non une occurrence de \mathbf{p} , donc $w \in \mathcal{S} \sqcup \mathcal{T}$.

D'où

$$\begin{aligned} S(X) + T(X) &= \sum_{w \in \mathcal{S} \sqcup \mathcal{T}} X^{|w|} \\ &= 1 + \sum_{w \in \mathcal{S} \cdot \Sigma} X^{|w|} \\ &= 1 + \sum_{w' \in \mathcal{S}} \sum_{a \in \Sigma} X^{|w'|+1} \\ &= 1 + mX \sum_{w' \in \mathcal{S}} X^{|w'|} \\ S(X) + T(X) &= 1 + mXS(X). \end{aligned} \tag{1}$$

Deuxième équation. Soit I l'ensemble des indices $i \in \{1, \dots, k\}$ tels que \mathbf{p} commence et termine à la fois par $p_1 \cdots p_i$, c'est-à-dire $p_1 \cdots p_i = p_{k-i+1} \cdots p_k$ (notons que I contient nécessairement k). Alors

$$\mathcal{S} \cdot \{\mathbf{p}\} = \mathcal{T} \cdot \left(\bigsqcup_{i \in I} \{p_{i+1} \cdots p_k\} \right).$$

Démonstration. Soit $w = w_1 \cdots w_n \in \mathcal{S} \cdot \{\mathbf{p}\}$. Soit $i := \max\{1 \leq \ell \leq k \mid w_1 \cdots w_{n-k+\ell} \text{ termine par } \mathbf{p}\}$. Alors $w_1 \cdots w_{n-k+i} \in \mathcal{T}$, et comme w termine par \mathbf{p} nous avons

$$\begin{aligned} p_1 \cdots p_i p_{i+1} \cdots p_k &= w_{n-k+1} \cdots w_{n-k+i} w_{n-k+i+1} \cdots w_n \\ &= p_{k-i+1} \cdots p_k p_{i+1} \cdots p_k, \end{aligned}$$

donc $p_1 \cdots p_i = p_{k-i+1} \cdots p_k$. Ainsi $i \in I$ et $w \in \mathcal{T} \cdot \{p_{i+1} \cdots p_k\}$.

Réciproquement, soit $w \in \mathcal{T} \cdot \{p_{i+1} \cdots p_k\}$ avec $i \in I$. Alors w est de la forme

$$\begin{aligned} w &= \underbrace{[w' p_1 \cdots p_{k-i}][p_{k-i+1} \cdots p_k][p_{i+1} \cdots p_k]}_{\in \mathcal{T}} \\ &= \underbrace{w' p_1 \cdots p_{k-i}}_{\in \mathcal{S}} \cdot \mathbf{p}. \end{aligned} \tag{car } i \in I$$

D'où

$$\begin{aligned}
 X^k S(X) &= \sum_{w \in \mathcal{S} \cdot \{\mathbf{p}\}} X^{|w|} \\
 &= \sum_{\substack{i \in I \\ w \in \mathcal{T}}} X^{k-i} X^{|w|} \\
 &= \left(\sum_{i \in I} X^{k-i} \right) \left(\sum_{w \in \mathcal{T}} X^{|w|} \right) \\
 X^k S(X) &=: c(X) T(X). \tag{2}
 \end{aligned}$$

Conclusion. En multipliant (1) par X^k , et en utilisant (2), nous avons donc

$$c(X) T(X) + X^k T(X) = X^k + m X c(X) T(X),$$

soit

$$T(X) = \frac{X^k}{X^k + (1 - mX)c(X)}.$$

Par conséquent

$$\theta = \frac{1}{m} T' \left(\frac{1}{m} \right) = \frac{1}{m} \left(\frac{km^{1-k}}{m^{-k}} - m^{-k} \frac{km^{1-k} - mc\left(\frac{1}{m}\right)}{m^{-2k}} \right) = m^k c \left(\frac{1}{m} \right) = \sum_{i \in I} m^i.$$

Si $\Sigma = \{A, \dots, Z\}$ et $\mathbf{p} = \text{ABRACADABRA}$, alors $m = 26$, $k = 11$, $I = \{1, 4, 11\}$. Ainsi

$$\theta = 26^{11} + 26^4 + 26 \approx 3 \text{ milliards d'années.}$$

Références. [FS]

190 Méthodes combinatoires, problèmes de dénombrement.

[FS] Philippe FLAJOLET et Robert SEDGEWICK : *Analytic Combinatorics*.