

Exercice 4. Nombre d'occurrences. On se donne un mot

$$\omega = \omega_1 \omega_2 \dots \omega_n$$

de longueur n , constitué de n lettres tirées au hasard avec remise dans un sac. Le sac contient un exemplaire de chaque caractère d'imprimerie (on suppose que ceux-ci sont au nombre de t). On note $N(\omega)$ le nombre d'occurrences du mot CARTAN dans ω . Calculer $\mathbb{E}[N]$. *Questions subsidiaires* : calculer $\text{Var}(N)$. Peut-on appliquer l'inégalité de Hoeffding à N directement ? Indirectement ?

Autre question subsidiaire Soit T le nombre de lettre qu'il faut lire pour enfin observer une occurrence du mot CARTAN Trouver n tel que $\mathbb{P}(T \leq n) \geq 0,99$

On a $N_n = X_1 + X_2 + \dots + X_{n-5}$, avec $X_i \sim \text{Bernoulli}(t^{-6})$, et

$$\text{Cov}(X_i, X_j) = t^{-6} \mathbb{1}_{|i-j|=0} - t^{-12} \mathbb{1}_{|i-j| \leq 5}, \text{ donc}$$

$$\mathbb{E}(N_n) = (n-5)t^{-6} \text{ et } \text{Var}(N_n) = (n-5)t^{-6} - t^{-12}((n-5)^2 - (n-10)(n-11)) = (n-5)t^{-6} - t^{-12}(11n-76)$$

On remarque que $\{T \leq n\} \Leftrightarrow \{N_n \geq 1\} \Leftrightarrow \{N_n - \mathbb{E}[N_n] \geq 1 - \mathbb{E}(N_n)\}$

ou encore $\{T > n\} \Leftrightarrow \{N_n \leq 0\} \Leftrightarrow \{N_n - \mathbb{E}[N_n] \leq -\mathbb{E}[N_n]\}$ Donc on peut utiliser, a priori, Hoeffding ou BT pour démontrer que $\mathbb{P}(T > n) \leq 0,01$ Par exemple, avec BT,

$$\mathbb{P}(T > n) \leq \mathbb{P}(|N_n - \mathbb{E}(N_n)| \geq \mathbb{E}(N_n)) \leq \frac{\text{Var}(N_n)}{\mathbb{E}(N_n)^2} \approx \frac{n(t^{-6} - 11t^{-12})}{n^2 t^{-12}} = \frac{t^6 - 11}{n} \approx \frac{t^6}{n} \leq 0,01$$

à condition que $n \approx 100 t^6$

Utiliser Hoeffding est + délicat car les X_i ne sont pas \perp Plus précisément,

$$\{X_i \perp X_j\} \Leftrightarrow \{|i-j| \geq 6\}$$

Ainsi on peut appliquer Hoeffding séparément aux sommes $S_1, S_2, S_3, \dots, S_6$, définies par

$$S_1 = X_1 + X_7 + X_{13} + \dots, S_2 = X_2 + X_8 + X_{14} + \dots, \dots, \text{ vérifiant } N = S_1 + S_2 + \dots + S_6$$

Chacune des sommes S_i possède entre $\frac{n-10}{6}$ et $\frac{n}{6}$ termes Les S_i vérifient donc, pour $t < 0$,

$$\mathbb{P}(S_i - \mathbb{E}(S_i) \leq -t) \leq \exp(-12t^2/n)$$

Par ailleurs, $N_n - \mathbb{E}(N_n) = \sum_{i=1}^6 S_i - \mathbb{E}(S_i)$, donc

$$\{N_n - \mathbb{E}(N_n) \leq -t\} \Rightarrow \{\exists i, t_1 S_i - \mathbb{E}(S_i) \leq -\frac{t}{6}\},$$

$$\text{et } \mathbb{P}(N_n - \mathbb{E}(N_n) \leq -t) \leq \sum_i \mathbb{P}(S_i - \mathbb{E}(S_i) \leq -\frac{t}{6}) \leq 6 \exp(-t^2/3n)$$

Ainsi, il suffit de s'assurer que

$$\exp(-t^2/3n) \geq 600,$$

pour obtenir la majoration désirée Il suffit pour cela que

$$n \geq 10 + 3 \ln(600) t^6 \approx 20 t^6$$

On gagne donc un facteur 5 sur BT