

Exercices sur les algorithmes probabilités

Nom du rédacteur : Johanne Cohen

<https://www.lri.fr/~jcohen/pages/enseignement.html>

## Algorithmes probabilistes : recrutement d'un collaborateur

### Embauche d'un collaborateur.

Cet énoncé de cet exercice se base sur le livre *Introduction to Algorithms* de T. Cormen, C. Leiserson, R. Rivest, and C. Stein à the MIT Press, 2 edition, (2001).

Une société veut recruter un nouvel collaborateur. Il y a  $n$  candidats possibles. Elle interviewe un candidat par jour et elle décide ensuite de l'embaucher ou non.

**Question 1.** La société utilise la procédure suivante :

**Entrée :** une liste de  $n$  candidats

**Sortie :** un candidat

1. La société génère une liste de passage des  $n$  candidats de façon uniforme.
2. La société interviewe le candidat 1 et elle l'embauche
3. pour tous les candidats  $v$  faire
  - (a) La société interviewe le candidat  $v$
  - (b) si le candidat  $v$  est meilleur que celui embauché alors
    - i. La société renvoie le candidat embauché
    - ii. elle embauche le candidat  $v$

Il y a un coût pour interviewer (coût  $c_i$ ) et pour embaucher (coût  $c_h$ ).

**Question 1.1** Donner le coût de la procédure au pire des cas, au meilleur des cas.

Tous les candidats sont interviewés. Le coût pour interviewer pour la société est  $n \times c_i$ . Le coût liés aux embauches successifs de candidat dans cette procédure dépend du rang meilleur candidat.

**Considérons le meilleur des cas.** Le meilleur candidat est le premier de la liste. La société embauche uniquement un candidat. Donc, le coût pour embaucher pour la société est  $c_h$ .

Le coût total de cette procédure est  $n \times c_i + c_h$ .

**Considérons le pire des cas.** Il faut construire une instance où à chaque interview, la société embauche. Pour cela, la listes candidats correspond à une liste triée croissante en fonction de la valeur des candidats.

Le coût total de cette procédure est  $n \times (c_i + c_h)$ .

Maintenant nous allons évaluer le coût moyen de la procédure.

**Question 1.2** Notons  $X_i$  la variable aléatoire indicatrice de l'événement correspondant aux fait que le candidat  $i$  soit embauché durant le processus.

1. Donner la définition formelle.

$$\begin{aligned} X_i &= \mathbb{1}_{\text{le candidat } i \text{ est embauché}} \\ &= \begin{cases} 1 & \text{si le candidat } i \text{ est embauché} \\ 0 & \text{si le candidat } i \text{ n' est pas embauché} \end{cases} \end{aligned}$$

2. Calculer  $\Pr(X_i = 1)$ .

Observons que si le candidat  $i$  est embauché, cela signifie qu'il est le meilleur candidat parmi les  $i$  premiers candidats. Donc  $\Pr(X_i = 1) = \frac{1}{i}$ .

3. Calculer  $E(X_i)$ .

$$E[X_i] = 0 \Pr(X_i = 0) + 1 \Pr(X_i = 1) = \frac{1}{i}.$$

**Question 1.3** Donner le nombre moyen d'embauches dans la la procédure.

Soit  $X$  la variable aléatoire désignant le nombre d'embauches.

$$X = \sum_{i=1}^n X_i \quad (\text{par définition})$$

$$E[X] = \sum_{i=1}^n E[X_i] \quad (\text{par linéarité de la moyenne}),$$

$$E[X] = \sum_{i=1}^n \frac{1}{i} \quad (\text{par la question précédente}),$$

$$E[X] = \ln n + \mathcal{O}(1) \quad (\text{par la définition du nombre harmonique}),$$

**Question 1.4** En déduire le coût moyen de la procédure.

$$\text{Le coût moyen de la procédure} = n \times c_i + E[X]c_h = n \times c_i + (\ln n + \mathcal{O}(1))c_h$$

**Question 2.** Comme chaque interview a un coût pour la société, **la société ne souhaite pas interroger tous les candidats** afin de trouver le candidat le plus compétent. Pour cela, la société est prête à se contenter d'un candidat dont les compétences sont proches du candidat le plus compétent, en échange d'un recrutement unique.

La société utilise la procédure suivante : elle reçoit les candidats. Après avoir rencontré le candidat  $i$ , elle lui attribue un score noté  $score(i)$ . **Ici, nous supposons qu'aucun candidat ne reçoive le même score.** Après avoir vu  $k$  candidats, la société connaît le score le plus élevé (que l'on notera *Meilleur\_score*) des  $k$  premiers candidats. Ensuite la société sélectionnera le premier candidat qui aura un score plus grand que les  $k$  premiers candidats. Voici la procédure dans un pseudo-code :

**Entrée :** deux entiers  $k$ , et  $n$  correspondant le nombre de candidats

**Sortie :** le candidat sélectionné

1.  $Meilleur\_score \leftarrow -\infty$

2. pour tout entier  $t$  allant de 1 à  $k$  faire

(a) si  $score(t) > Meilleur\_score$  alors  $Meilleur\_score \leftarrow score(t)$

3. pour tout entier  $t$  allant de  $k + 1$  à  $n$  faire
  - (a) si  $score(i) > Meilleur\_score$  alors Retourner  $t$
4. Retourner  $n$

**L'ordre du passage des candidats se fait aléatoirement et uniformément.**

**Question 3.** Soit  $B_t$  l'événement que le candidat le plus compétent soit à la place  $t$ . Donner la probabilité  $\Pr(B_t)$  tout en justifiant.

Nous pouvons considérer que l'ordre de passage peut se modéliser par un tableau généré de façon uniforme. la probabilité que le candidat le plus compétent soit à la place  $t$  correspond à la probabilité que le maximum d'un tableau généré de façon uniforme soit au rang  $t$ .

$$\Pr(B_t) = 1/n$$

**Question 4.** Soit  $O_t$  l'événement qu'aucun des candidats de la position  $k$  à la position  $t - 1$  soit retenu. Donner la probabilité  $\Pr(O_t)$  tout en justifiant.

Il suffit de remarquer que  $O_t$  se réalise si le maximum du tableau  $T[1, \dots, t - 1]$  se trouve en position  $j$ , avec  $1 \leq j \leq k$ . Donc  $O_t = \bigcup_{t=1}^k B_t$ . Comme ce sont des événements disjoints

$$\Pr(O_t) = \sum_{t=1}^k \Pr(B_t) = \frac{k}{n}$$

Soit  $S_t$  l'événement que le candidat le plus compétent soit à la place  $t$  et qu'il soit retenu.

**Question 5.** Donner la probabilité de l'événement  $S_t$  lorsque  $1 \leq t \leq k$ .

$\Pr(S_t) = 0$  car les  $k$  premiers candidats sont rejetés. En effet dans ce cas là,  $S_t$  ne se réalise jamais.

**Question 6.** montrer que les événements  $O_t$  et  $B_t$  sont indépendants.

Rappelons que

- $O_t$  l'événement qu'aucun des candidats de la position  $k$  à la position  $t - 1$  soit retenu.
- $B_t$  l'événement que le candidat le plus compétent soit à la place  $t$ .

Rappelons que deux événements  $A$  et  $B$  sont indépendants si  $\Pr(B) = \Pr(B|A)$ . Calculons  $\Pr(O_t|B_t) = \Pr(O_t)$ . Il suffit de noter que l'événement  $O_t$  dépend uniquement des scores des candidats à la position 1 à  $t - 1$ .

Calculons  $\Pr(B_t|O_t) = \Pr(B_t)$ . Il suffit de noter que l'événement  $B_t$  dépend uniquement des scores de tous les candidats.

**Question 7.** Montrer que  $\Pr(S_t) = \frac{k}{n(t-1)}$  pour  $t > k$ .

Tout d'abord notons que  $S_t = O_t \cap B_t$  (par définition).

$$\Pr(S_t) = \Pr(O_t \cap B_t) = \Pr(O_t) \cdot \Pr(B_t) = \frac{k}{n(t-1)}.$$

Nous admettrons que  $\ln j - \ln \ell \leq \sum_{i=\ell}^j \frac{1}{i} \leq \ln(j-1) - \ln(\ell-1)$ .

**Question 8.** Soit  $S$  l'événement que le candidat le plus compétent soit retenu.

1. Exprimer  $S$  et  $\Pr(S)$  en fonction des  $S_t$ .

$S = \bigcup_{t=1}^n S_t$ . Comme ce sont des événements disjoints, on a

$$\begin{aligned} \Pr(S) &= \sum_{i=0}^n \Pr(S_i) \\ &= \sum_{i=k+1}^n \Pr(S_i) \quad \text{d'après la question 5} \end{aligned}$$

2. Quelle est la probabilité  $\Pr(S)$  que le meilleur candidat soit sélectionné ? Vous pouvez encadrer cette probabilité.

$$\begin{aligned} \Pr(S) &= \sum_{i=k+1}^n \frac{k}{n(i-1)} \\ &= \frac{k}{n} \sum_{i=k+1}^n \frac{1}{i-1} \quad \text{en sortant la constante de la somme} \\ &= \frac{k}{n} \sum_{i=k}^{n-1} \frac{1}{i} \quad \text{en supprimant le } -1 \\ &= \frac{k}{n} \left( \sum_{i=1}^{n-1} \frac{1}{i} - \sum_{i=1}^{k-1} \frac{1}{i} \right) \quad \text{en faisant apparaître le nombre harmonique} \end{aligned}$$

$$\text{Comme } \ln(n) \leq \sum_{i=1}^{n-1} \frac{1}{i} \leq \ln(n-1) + 1 \text{ et } -\ln(k) \geq -\sum_{i=1}^{k-1} \frac{1}{i} \geq -\ln(k-1) - 1$$

$$\frac{k}{n}(\ln n - \ln k) \leq \Pr(S) \leq \frac{k}{n}(\ln(n-1) - \ln(k-1))$$

**Question 9.** En posant  $k = n/3$ . Donner l'ordre de grandeur de la probabilité  $\Pr(S)$  en sachant que  $\ln a - \ln b = \ln(\frac{a}{b})$  et  $\ln 3 \approx 1.09$ . Quand déduisez-vous ?

Remarquons que  $\frac{k}{n} = 1/3$

$$\frac{k}{n}(\ln n - \ln k) \leq \Pr(S) \quad \text{d'après la question précédente}$$

$$\frac{1}{3}(\ln 3) \leq \Pr(S) \quad \text{en utilisant la relation } k = n/3$$

$$\frac{1}{3}1.09 \leq \Pr(S) \quad \text{en utilisant la relation } \ln 3 \approx 1.09$$

$$\frac{1}{3} < \Pr(S)$$