

## Algorithmes On-lines

### Sélectionner $k$ éléments d'un ensemble $S$ de $n$ éléments distincts.

L'objectif de cet exercice est de concevoir un algorithme  $\mathcal{A}$  qui sélectionne  $k$  éléments parmi un ensemble  $S = \{s_1, s_2, \dots, s_n\}$  de  $n$  éléments distincts de façon uniforme. Nous noterons par  $\mathcal{P}_k(S)$  l'ensemble des parties de  $S$  ayant exactement  $k$  éléments. Nous supposons connu que  $C_n^k = \binom{n}{k} = \frac{n!}{k!(n-k)!}$  correspond aux nombres de parties de  $k$  éléments d'un ensemble de  $n$  éléments distincts. En d'autres termes  $|\mathcal{P}_k(S)| = \binom{n}{k}$ .

Soit  $\mathcal{A}$  un algorithme qui retourne une partie de  $k$  éléments parmi  $S$  de façon uniforme. Nous noterons  $X$  pour la variable aléatoire qui désigne la partie de  $S$  retournée par  $\mathcal{A}$ .

**Question 1.** Soit  $C$  une partie de  $S$  de  $k$  éléments. Que vaut la probabilité  $Pr(X = C)$  ?

$Pr(X \in \mathcal{P}_k(S)) = 1$ . Comme les événements  $X = C'$  et  $X = C$  sont disjoints si  $C' \neq C$ , on a  $\sum_{C \in \mathcal{P}_k(S)} Pr(X = C) = 1$ . De plus, comme  $X$  est générée de façon uniforme, on a  $Pr(X = C) = Pr(X = C')$  pour toutes parties  $C'$  et  $C$  de  $S$  ayant  $k$  éléments. Donc

$$\begin{aligned} \sum_{C \in \mathcal{P}_k(S)} Pr(X = C) &= 1 \\ \binom{n}{k} Pr(X = C) &= 1 \\ Pr(X = C) &= \frac{k!(n-k)!}{n!} \end{aligned}$$

**Question 2.** Soit  $s$  un élément de  $S$ . Notons par  $s \in X$  l'événement correspondant au fait que  $s$  est un élément de  $X$ , partie retournée par l'algorithme  $\mathcal{A}$ . Calculer les probabilités suivantes :  $Pr(s \in X | X = C)$ ,  $Pr(s \in X)$ .

$$Pr(s \in X | X = C) = \begin{cases} 1 & \text{si } s \in C \\ 0 & \text{sinon} \end{cases}$$

$$\begin{aligned} Pr(s \in X) &= \sum_{C \in \mathcal{P}_k(S)} Pr(s \in X | X = C) \cdot Pr(X = C) \\ &= \sum_{C \in \mathcal{P}_k(S) \text{ et } s \in C} Pr(s \in X | X = C) \cdot Pr(X = C) \\ &= \frac{\binom{n-1}{k-1}}{\binom{n}{k}} = \frac{\frac{(n-1)!}{(k-1)!(n-1-k+1)!}}{\frac{n!}{k!(n-k)!}} \\ &= \frac{k}{n} \end{aligned}$$

Nous utiliserons une fonction  $Bernoulli(p)$  qui retourne 1 avec probabilité  $p$  sinon retourne la valeur 0.

Considérons l'algorithme  $\mathcal{D}$  :

**Entrée :** Un ensemble  $S = \{s_1, s_2, \dots, s_n\}$  de  $n$  éléments distincts.

**Sortie :** une partie  $X$  ayant  $k$  éléments de  $S$ .

1.  $X \leftarrow \emptyset$ ;
2. pour  $i$  allant 1 à  $n$  faire
  - (a) Si  $i \leq k$ , alors  $X \leftarrow X \cup \{s_i\}$ ;
  - (b) sinon
    - i.  $Z_i \leftarrow Bernoulli(\frac{k}{i})$ ;
    - ii. Si  $Z_i = 1$  alors
      - Choisir un élément  $\ell$  de  $X$  de façon uniforme;
      - $X \leftarrow X \setminus \{\ell\}$ ;
      - $X \leftarrow X \cup \{s_i\}$ ;
3. retourner  $X$

Notons par  $\mathcal{E}(e, i)$  l'évènement que l'élément  $e$  soit dans l'ensemble désigné par la variable  $X$  à la fin de l'itération  $i$ . L'objectif est de calculer la probabilité que l'élément  $e$  soit dans  $X$  à la fin de l'itération  $i$ , en d'autres termes, de calculer la probabilité  $\Pr(\mathcal{E}(e, i))$ .

**Question 3.** Quelle est la probabilité ( $\Pr(\mathcal{E}(e, k))$ ) que l'élément  $e$  soit dans  $X$  à la fin de l'itération  $k$  (c'est-à-dire lorsque  $i$  vaut  $k$  dans l'algorithme) ?

$$\Pr(\mathcal{E}(e, k)) = \begin{cases} 1 & \text{si } e \text{ est un des éléments } s_1, s_2, s_3, \dots, s_k \\ 0 & \text{sinon} \end{cases}.$$

**Question 4.** Soit  $s_i$  le  $i$ ème élément de  $S$  avec  $i > k$ .

1. Donner les probabilités suivantes :  $\Pr(Z_i = 1)$  et  $\Pr(Z_i = 0)$ .
2. Quelle est la probabilité que  $s_i$  soit dans  $X$  à la fin de l'itération  $i$  ? (Calculer  $\Pr(\mathcal{E}(s_i, i))$ )

Pour qu'il soit dans  $X$ , il faut que  $Z_i = 1$ , la probabilité qu'il soit dans  $X$  après l'étape  $i$  correspond à la probabilité que  $X_i = 1$ .

$$\Pr(\mathcal{E}(s_i, i)) = \frac{k}{i}.$$

**Question 5.** Soit  $e$  un élément dans  $X$  à la fin de l'itération  $k$ . Quelle est la probabilité ( $\Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k))$ ) qu'il reste dans  $X$  à la fin de l'itération  $k+1$  ? Pour cela, calculer cette probabilité dans les deux cas suivants :

1. sachant que ( $Z_{k+1} = 0$ )
2. sachant que ( $Z_{k+1} = 1$ )

Si l'évènement ( $Z_{k+1} = 0$ ) se réalise, alors aucun élément sera supprimé pendant l'itération  $k + 1$  et l'élément  $e$  sera toujours dans  $X$ . Comme  $\Pr(Z_{k+1} = 0) = \frac{1}{k+1}$ , on a

$$\Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k) \text{ et } Z_{k+1} = 0) = \frac{1}{k+1}$$

Si l'évènement ( $Z_{k+1} = 1$ ) se réalise, un seul élément sera supprimé : il est choisit de façon uniforme. Donc, un élément de  $X$  ne sera pas supprimé avec probabilité  $\frac{k-1}{k}$ .

$$\Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k) \text{ et } Z_{k+1} = 1) = \frac{k-1}{k}$$

Donc :

$$\begin{aligned} \Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k)) &= \Pr(Z_{k+1}=0) \Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k) \text{ et } Z_{k+1}=0) + \Pr(Z_{k+1}=1) \Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k) \text{ et } Z_{k+1}=1) \\ &= 1 \cdot \frac{1}{k+1} + \frac{k-1}{k} \cdot \frac{k}{k+1} \\ &= \frac{k}{k+1} \end{aligned}$$

La première ligne du calcul correspond à la définition de la probabilité conditionnelle. La deuxième est due au fait que  $\Pr(Z_{k+1} = 1) = \frac{k}{k+1}$ .

**Question 6.** Montrer que la probabilité que l'élément  $e$  soit dans  $X$  à la fin de l'itération  $k + 1$  vaut  $\frac{k}{k+1}$  ?

Soit  $e$  un élément dans  $\{s_1, s_2, s_3, \dots, s_k\}$ .

$$\begin{aligned} \Pr(\mathcal{E}(e, k+1)) &= \Pr(\mathcal{E}(e, k)) \Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k)) + \Pr(\text{non}\mathcal{E}(e, k)) \Pr(\mathcal{E}(e, k+1) | \text{non}\mathcal{E}(e, k)) \\ &= 1 \Pr(\mathcal{E}(e, k+1) | \mathcal{E}(e, k)) + \Pr(\mathcal{E}(e, k+1) | \text{non}\mathcal{E}(e, k)) \\ &= \frac{k}{k+1} \end{aligned}$$

En utilisant les deux questions précédentes,

$$\Pr(\mathcal{E}(e, k+1)) = \begin{cases} \frac{k}{k+1} & \text{si } e \text{ est un des éléments } s_1, s_2, s_3, \dots, s_k, s_{k+1} \\ 0 & \text{sinon} \end{cases}$$

Nous allons prouver *par récurrence* grâce aux prochaines questions que la probabilité qu'un élément  $e$  dans  $\{s_1, \dots, s_i\}$  soit dans  $X$  à la fin de l'itération  $i$  vaut  $\frac{k}{i}$  : autrement dit,  $\Pr(\mathcal{E}(e, i)) = \frac{k}{i}$ . La question 6 montre que l'hypothèse de récurrence est vraie pour  $i = k + 1$ . Supposons que l'hypothèse de récurrence est vraie pour  $i$ . Par la suite nous allons prouver qu'elle est vraie pour  $i + 1$ .

**Question 7.** Soit  $e$  un élément dans  $X$  à la fin de l'itération  $i$ . Quelle est la probabilité qu'il reste dans  $X$  à la fin de l'itération  $i + 1$  ? Pour cela, calculer cette probabilité dans les deux cas suivants :

1. sachant que ( $Z_{i+1} = 0$ )

2. sachant que ( $Z_{i+1} = 1$ )

Si l'évènement ( $Z_{i+1} = 0$ ) se réalise, alors aucun élément sera supprimé pendant l'itération  $i$  et l'élément  $e$  sera toujours dans  $X$ . Comme  $\Pr(Z_{i+1} = 0) = \frac{i+1-k}{i+1}$ , on a

$$\Pr(\mathcal{E}(e, i+1) | \mathcal{E}(e, i) \text{ et } Z_{i+1} = 0) = \frac{i+1-k}{i+1}$$

Si l'évènement ( $Z_{i+1} = 1$ ) se réalise, un seul élément sera supprimé : il est choisit de façon uniforme. Donc, un élément  $e$  de  $X$  ne sera pas supprimé avec probabilité  $\frac{i}{i+1}$ .

$$\Pr(\mathcal{E}(e, i+1) | \mathcal{E}(e, i) \text{ et } Z_{i+1} = 1) = \frac{i}{i+1}$$

Donc :

$$\begin{aligned} \Pr(\mathcal{E}(e, i+1) | \mathcal{E}(e, i)) &= \Pr(Z_{i+1} = 0) + \Pr(Z_{i+1} = 1) \Pr(\mathcal{E}(e, i+1) | \mathcal{E}(e, i) \cap Z_{i+1} = 1) \\ &= \frac{i+1-k}{i+1} + \frac{k}{i+1} \frac{k-1}{k} \\ &= \frac{i}{i+1} \end{aligned}$$

**Question 8.** Quelle est la probabilité que l'élément  $e$  soit dans  $X$  à la fin de l'itération  $i+1$  ?

- Si  $e \notin \{s_1, \dots, s_{i+1}\}$ , alors  $\Pr(\mathcal{E}(e, i)) = 0$
- Si  $e \in \{s_1, \dots, s_i\}$ ,

$$\begin{aligned} \Pr(\mathcal{E}(e, i+1)) &= \Pr(\mathcal{E}(e, i+1) | \mathcal{E}(e, i)) \cdot \Pr(\mathcal{E}(e, i)) \\ &= \frac{i}{i+1} \cdot \frac{k}{i} \\ &= \frac{k}{i+1} \end{aligned}$$

- Si  $e = s_{i+1}$ ,  $\Pr(\mathcal{E}(s_{i+1}, i+1)) = \frac{k}{i+1}$

**Question 9.** Quelle est la probabilité que l'élément  $e$  soit dans  $X$  à la fin de l'itération  $n$  ?

Il faut réutiliser la question précédente en focalisant sur  $i+1 = n$ .

- Si  $e \in \{s_1, \dots, s_{n-1}\}$ , alors  $\Pr(\mathcal{E}(e, n)) = \frac{k}{n}$
- Si  $e = s_n$ ,  $\Pr(\mathcal{E}(s_n, n)) = \frac{k}{n}$

**Question 10.** Peut-on adapter l'algorithme  $\mathcal{D}$  en un algorithme on-line ? Justifier votre réponse (si c'est oui, donner l'algorithme, si c'est non, donnez vos raisons) ?

oui : car l'algorithme n'utilise pas le nombre d'éléments de  $S$ .