

ENSEIRB

Filière Informatique 1ère année 2003/2004
UV IID : Méthodes Statistiques Module IS1 01 : Probabilités et Statistiques
Durée : 3 h le 11/06/2004

Documents de cours et TD autorisés.

Avertissement: Il sera tenu le plus grand compte de la justification des réponses et de la présentation .

Tous les algorithmes demandés seront (naturellement) écrits en L.D.A , clairs et bien commentés .

E est un ensemble d'éléments avec une relation d'ordre total, notée classiquement \leq .
L'algorithme `Rand_Tri` reçoit en entrée une suite de N éléments de E et retourne en sortie la suite triée suivant l'ordre croissant .

Principe de l'algorithme `Rand_Tri` : un élément de la suite (appelé : pivot) est choisi au "hasard" (c'est à dire que chaque élément de la suite a la même probabilité d'être choisi) ; on compare le pivot avec tous les éléments de la suite , ceux qui sont \leq au pivot sont placés avant le pivot et les autres après le pivot ; on obtient ainsi 2 sous suites (éventuellement l'une des deux peut être vide) . On itère ce procédé sur chaque sous suite ainsi formée, tant qu'elles comportent plus d'un élément . Lorsque l'algorithme s'arrête la suite de départ est triée suivant l'ordre croissant .
On s'intéresse à la variable aléatoire N_C nombre de comparaisons effectuées au cours de l'exécution de l'algorithme .

Question préliminaire : le nombre de comparaisons effectuées au cours de l'exécution de l'algorithme dépend naturellement de l'ordre initial de la suite d'entrée, qui n'est pas connu, notons L la loi de l'ordre de la suite d'entrée . Montrer qu'en fait la loi de N_C ne dépend pas de la loi L ; c'est à dire précisément, que : pour tout entier k
 $\text{Prob}(N_C = k, \text{ connaissant l'ordre d'entrée}) = \text{Prob}(N_C = k)$

I. Calcul de l'espérance de N_C , notée $E(N_C)$

- 1) on note $x_i, i=1 \dots N$ les éléments de la suite en sortie de l'algorithme (c.à.d.. triée suivant l'ordre croissant) ; soient i et j tels que $1 \leq i < j \leq N$;
- Dans le cas où $j > i+1$, il existe des éléments x_k entre x_i et x_j ; montrer que la Probabilité qu'au cours de l'exécution de l'algorithme x_i ou x_j aient été choisis comme pivot avant l'un quelconque des x_k pour $i < k < j$, vaut $2/(j-i+1)$. En déduire la Probabilité qu'au cours de l'exécution de l'algorithme, il y ait eu une comparaison entre x_i et x_j .
 - Dans le cas où $j=i+1$, la méthode de calcul ci-dessus n'a plus de sens, cependant, vérifier directement que la formule que vous avez trouvée pour la Probabilité est encore valable .

SUITE AU VERSO

2) on note X_{ij} la variable aléatoire caractéristique de l'événement : "au cours de l'exécution de l'algorithme, il y a eu une comparaison entre x_i et x_j ". Calculer l'espérance de X_{ij} et sa variance. Trouver une relation **très simple** entre N_C et les X_{ij} . A l'aide de cette relation trouver une formule qui donne $E(N_C)$ en fonction de N (vous ne chercherez pas à simplifier cette formule qui contient une double sommation)

3) écrire un algorithme qui calcule $E(N_C)$.

II Estimation de la variance de N_C , notée $Var(N_C)$

Maintenant, on suppose que N le nombre d'éléments des suites triées, est un " grand nombre " du point de vue des statistiques.

1) les variables aléatoires X_{ij} sont elles deux à deux indépendantes ?
Pour calculer $Var(N_C)$, pourquoi ne peut-on utiliser la relation entre N_C et les X_{ij} d'une manière analogue à ce qui a été fait dans I 2) ?

2) on suppose disponible une fonction appelée `rand_tri` qui lance l'exécution de l'algorithme `Rand_Tri` et retourne le nombre de comparaisons effectuées au cours de cette exécution ; écrire un algorithme (après avoir justifié son principe) qui donne une estimation de $Var(N_C)$.

3) vous supposerez que le paramètre `taille_échantillon` (que vous avez du introduire dans l'algorithme écrit en 2)) est supérieur à 100, compléter votre algorithme pour qu'il donne aussi un intervalle de confiance de la forme classique $(0, b)$ pour $Var(N_C)$, au seuil de 0.05.

4) on considère la condition : Probabilité de
(valeur absolue de $[ESTIMATEUR \text{ de } Var(N_C) - Var(N_C)] / Var(N_C) < 0.01$)
> 0.95

écrire un algorithme (en le justifiant) qui détermine la valeur minimum du paramètre `taille_échantillon` qui permet d'obtenir la condition ci dessus.

Ecrire une phrase simple qui traduit intuitivement la condition considérée.