

Mots de longueur donnée à base de P lettres, et fonction génératrice

Considérons les mots de longueur n à base de P lettres, avec n entier positif.

1) Combien existe-t-il de tels mots ?

La première lettre du mot est l'une des P lettres, soit P cas. A chaque fois il en est de même pour la deuxième lettre, et ainsi de suite. Le nombre des mots est P^n .

2) Combien existe-t-il de mots de longueur n ne contenant qu'une seule lettre ? Combien s'ils n'ont que deux lettres différentes ?

Si les mots sont tous formés avec la même lettre répétée, il y a P mots, autant qu'il y a de lettres possibles.

Si les mots de longueur n contiennent seulement deux lettres différentes, ce qui impose $n \geq 2$, on commence par choisir ces deux lettres, soit C_P^2 cas. Une fois les deux lettres choisies, il s'agit de former tous les mots ne contenant qu'elles. Il existe 2^n mots à base de deux lettres, mais parmi eux il faut enlever ceux qui ne contiennent qu'une seule des deux lettres, soit deux mots. Finalement le nombre de mots recherchés est $C_P^2 (2^n - 2)$.

3) On suppose dans cette question que $n = P$. Combien existe-t-il de mots contenant toutes les lettres ? Combien en existe-t-il contenant exactement K des P lettres ?

Les mots de longueur P contenant les P lettres ne sont autres que les permutations de P éléments, leur nombre est $P!$.

Supposons maintenant qu'ils contiennent K lettres, avec K entre 1 et P . Commençons par choisir K lettres parmi P , soit C_P^K cas. Puis plaçons-nous dans un de ces cas. Pour connaître le nombre des mots ayant K lettres données, plaçons-nous dans le contexte de la formule du crible, en considérant K propriétés, la propriété i , avec i entre 1 et K , signifiant que la lettre i n'est pas présente dans le mot. Le nombre des mots recherchés est :

$$S_0 - S_1 + S_2 - \dots + (-1)^K S_K$$

(nous utilisons les notations du livre *Combien 1-Combinatoire, chapitre sur la formule du crible*).

Ici $S_0 = K^P$, $S_1 = C_K^1(K-1)^P$, $S_2 = C_K^2(K-2)^P$, ..., $S_{K-1} = C_K^{K-1}(K-(K-1))^P$, $S_K = 0$.
D'où le nombre de mots :

$$C_P^K (K^P - C_K^1(K-1)^P + C_K^2(K-2)^P - \dots + (-1)^{K-1} C_K^{K-1}(K-(K-1))^P)$$

Par exemple pour $P = 4$, le nombre des mots est $4^4 = 256$, et ils se divisent en quatre catégories:

- ceux contenant une seule des 4 lettres, soit 4 mots

- ceux contenant exactement deux lettres, soit $C_4^2 (2^4 - 2) = 84$
 - ceux contenant exactement trois lettres, soit $C_4^3 (3^4 - 3 \cdot 2^4 + 3) = 144$
 - ceux contenant les quatre lettres, soit $C_4^4 (4^4 - 4 \cdot 3^4 + 6 \cdot 2^4 - 4) = 24$
- Le nombre moyen de lettres présentes dans ces mots est 2,7.

Remarquons au passage la formule : $\sum_{j=0}^P (-1)^j C_P^j (P-j)^P = P!$

4) On suppose dorénavant que les mots sont fabriqués au hasard. Cela revient à prendre une urne contenant P boules numérotées de 1 à P , et à effectuer n tirages successifs avec remise de la boule à chaque fois, ces tirages étant équiprobables. En notant les numéros des boules successivement tirées, on retrouve les mots de longueur n à base de P lettres. On appelle $Y(n)$ la variable aléatoire correspondant au nombre de lettres (numéros) présentes dans ces mots de longueur n .

a) Calculer les probabilités $p(Y(n) = 1)$ et $p(Y(n) = 2)$.

Chaque mot a autant de chances d'être obtenu qu'un autre. Dans ce contexte d'équiprobabilité, la probabilité est le nombre de cas favorables sur le nombre de cas possibles. En utilisant les résultats du 1° et du 2°, on trouve :

$$p(Y(n) = 1) = \frac{P}{P^n} = \frac{1}{P^{n-1}}$$

$$p(Y(n) = 2) = \frac{C_P^2 (2^n - 2)}{P^n}$$

b) Calculer $p(Y(n) = n)$ lorsque n est inférieur ou égal à P .

Les cas favorables sont constitués par les mots de longueur n ayant n lettres différentes. Cela revient à prendre les arrangements de n lettres prises parmi P , soit A_P^n . D'où la probabilité :

$$p(Y(n) = n) = \frac{A_P^n}{P^n}$$

c) Etablir une relation de récurrence entre le nombre de mots $M(n+1, k)$ de longueur $n+1$ et ayant exactement k lettres présentes, et les nombres $M(n, k)$ et $M(n, k-1)$ de mots de longueur n et ayant respectivement k et $k-1$ lettres présentes.

Les $M(n+1, k)$ mots se divisent en deux catégories, selon leur dernière lettre, la $n+1$ ème..

- Si la dernière lettre est déjà présente dans le reste du mot qui est de longueur n (avec k lettres présentes), il y a k dernières lettres possibles. On trouve ainsi $M(n, k) k$ mots.

- Si la dernière lettre n'est pas déjà présente dans le reste du mot de longueur n et qui contient $k-1$ lettres différentes, il reste à choisir pour la dernière lettre une lettre autre que les $k-1$, soit $P-k+1$ cas. D'où le nombre de mots $M(n, k-1) (P-k+1)$.

On trouve finalement la relation :

$$M(n+1, k) = k M(n, k) + (P - k + 1)M(n, k - 1)$$

d) En déduire une relation de récurrence entre probabilités

On a, grâce à la relation précédente :

$$\begin{aligned} p(Y(n+1) = k) &= \frac{M(n+1, k)}{P^{n+1}} = \frac{kM(n, k) + (P - k + 1)M(n, k - 1)}{P^{n+1}} \\ &= \frac{k}{P} p(Y(n) = k) + \frac{P - k + 1}{P} p(Y(n) = k - 1) \end{aligned}$$

5) On prend la fonction génératrice $G_n(X)$ associée à la loi de probabilité de Y_n , soit $G_n(X) = \sum_{k=1}^{+\infty} p(Y(n) = k)X^k$, mais comme cette somme infinie se termine par des 0, il suffit de prendre le polynôme en X :

$$G_n(X) = \sum_{k=1}^P p(Y(n) = k)X^k \text{ (quelques-uns des termes de plus haut degré peuvent}$$

aussi être nuls lorsque $n < P$). En utilisant la relation de récurrence précédente, déterminer $G_{n+1}(X)$ en fonction de $G_n(X)$ et de sa dérivée $G'_n(X)$.

Constatons d'abord que $G'_n(X) = \sum_{k=1}^P k p(Y(n) = k)X^{k-1}$. En appliquant la formule

du 4-d :

$$\begin{aligned} G_{n+1}(X) &= \sum_{k=1}^P p(Y(n+1) = k)X^k \\ &= \sum_{k=1}^P \frac{k}{P} p(Y(n) = k)X^k + \sum_{k=1}^P \frac{P - (k - 1)}{P} p(Y(n) = k - 1)X^k \\ &= \frac{X}{P} \sum_{k=1}^P k p(Y(n) = k)X^{k-1} + \sum_{k'=0}^{P-1} \frac{P - k'}{P} p(Y(n) = k')X^{k'+1} \end{aligned}$$

Dans le premier Σ , on voit apparaître la dérivée, et dans le deuxième Σ on a procédé à un changement de variable

$$= \frac{X}{P} G'_n(X) + \sum_{k'=1}^P \frac{P - k'}{P} p(Y(n) = k')X^{k'+1} \quad k' = k - 1.$$

Dans le Σ , on a enlevé le terme avec $k' = 0$, puisqu'il est nul, et l'on a rajouté le terme avec $k' = P$, qui est nul lui aussi. Si l'on fait cela, c'est dans le but de voir apparaître les fonctions génératrices, comme cela va se préciser maintenant, en cassant le Σ en deux.

$$= \frac{X}{P} G'_n(X) + X \sum_{k'=1}^P p(Y(n) = k')X^{k'} - \frac{X^2}{P} \sum_{k'=1}^P k' p(Y(n) = k')X^{k'-1}$$

$$= \frac{X}{P} G'_n(X) + X G_n(X) - \frac{X^2}{P} G'_n(X)$$

$$G_{n+1}(X) = \frac{X - X^2}{P} G'_n(X) + X G_n(X)$$

6) Appelons $E(Y(n))$ la valeur moyenne (ou espérance) de la variable aléatoire $Y(n)$. Utiliser la formule précédente pour trouver une relation de récurrence entre $E(Y(n+1))$ et $E(Y(n))$. Puis donner la formule explicite de $E(Y(n))$.

On sait que $E(Y(n)) = G'_n(1)$. Comme on a aussi besoin de $E(Y(n+1)) = G'_{n+1}(1)$, on est amené à dériver la formule précédente.

$$G'_{n+1}(X) = \frac{X - X^2}{P} G''_n(X) + \frac{1 - 2X}{P} G'_n(X) + X G'_n(X) + G_n(X)$$

Faisons maintenant $X = 1$. La dérivée seconde a le bon goût de disparaître, et on sait aussi que $G_n(1) = 1$. Il reste :

$$\begin{aligned} E(Y(n+1)) &= -\frac{1}{P} E(Y(n)) + E(Y(n)) + 1 \\ &= \frac{P-1}{P} E(Y(n)) + 1 \end{aligned}$$

On reconnaît la relation de récurrence d'une suite arithmético-géométrique, de la forme $u_{n+1} = q u_n + 1$, avec $q = \frac{P-1}{P}$. Son point fixe est égal à P . Introduisons la suite

(v_n) telle que $v_n = u_n - P$. Par soustraction, on trouve :

$$\begin{aligned} u_{n+1} &= q u_n + 1 \\ \frac{P}{P} &= q \frac{P}{P} + 1 \end{aligned}$$

$v_{n+1} = q v_n$ La suite (v_n) est géométrique, sa forme explicite est $v_n = q^{n-1} v_1$ avec $v_1 = u_1 - P$. Ainsi $u_n - P = q^{n-1} (u_1 - P)$ ou $u_n = q^{n-1} (u_1 - P) + P$. Avec ici $u_1 = E(Y(1)) = 1$, l'espérance est égale à :

$$E(Y(n)) = \left(\frac{P-1}{P} \right)^{n-1} (1-P) + P = P - \frac{(P-1)^n}{P^{n-1}} = P \left(1 - \left(\frac{P-1}{P} \right)^n \right)$$

7) On prend ici $n = P$. Faire le programme qui permet d'avoir $E(Y(P))$. Pour cela on réalise un grand nombre NBE d'expériences. Chaque expérience consiste à faire P tirages répétés avec remise dans une urne qui contient P boules numérotées de 1 à P . A chaque fois, on compte le nombre de numéros différents obtenus. En cumulant ces résultats de chaque expérience, et en divisant ce cumul par le nombre NBE d'expériences, on trouve la moyenne demandée $E(Y(P))$. Constater expérimentalement que le rapport $E(Y(P)) / P$ décroît lorsque P augmente, en ayant tendance à se stabiliser sur une valeur limite que l'on précisera.

Au cours de chaque expérience de P tirages, on utilise un tableau *fait*[] mis initialement à 0. Lorsqu'un numéro i est tiré, on met la case *fait*[i] à 1. Lorsque les P tirages sont effectués, la somme des 1 de ce tableau donne le nombre de numéros différents. On trouvera ci-dessous la partie stratégique du programme.

On se donne le nombre d'expériences NBE, ainsi que la valeur de P. Comme les numéros vont de 1 à P, le tableau *fait*[] doit être déclaré `int fait[P+1]`, la case 0 étant inoccupée.

```
cumul=0;
for(experience=0;experience<NBE;experience++)
  { for(i=1;i<=P;i++) fait[i]=0;
```

```

for(tirage=1; tirage<=P; tirage++)
  { numero=1+random(P); fait[numero]=1; }
compteur=0;
for(i=1;i<=P;i++) if (fait[i]==1) compteur++;
cumul+=(float)compteur;
}
moyenne=cumul/(float)NBE;
printf("\nN= %3.d valeur moyenne/P=: %3.4f ",P,moyenne/(float)P);

```

Le rapport $E(Y(P)) / P$ passe de 0,65 pour $P = 10$, à 0,634 pour $P = 100$, et 0,6324 pour $P = 500$. Il se stabilise sur une valeur de cet ordre.

8) Calculer la valeur limite de $E(Y(P)) / P$ en utilisant le résultat du 6°.

On sait que $E(Y(P)) = P \left(1 - \left(\frac{P-1}{P}\right)^P\right)$ ou $\frac{E(Y(P))}{P} = \left(1 - \left(\frac{P-1}{P}\right)^P\right)$.

Or $\left(\frac{P-1}{P}\right)^P = e^{P \ln\left(1 - \frac{1}{P}\right)}$ et l'on sait que pour P grand : $\ln\left(1 - \frac{1}{P}\right) \approx -\frac{1}{P}$. Ainsi

$\left(\frac{P-1}{P}\right)^P$ tend vers $\frac{1}{e}$. Le rapport $\frac{E(Y(P))}{P}$ tend vers $1 - \frac{1}{e}$, soit 0,6321.

Remarque finale : On savait que l'utilisation de fonctions génératrices était particulièrement efficace dans les problèmes de temps d'attente. On a là un exemple différent, où à défaut d'être connue explicitement, la fonction génératrice permet de calculer l'espérance.