

# Quatre espaces de probabilité importants

## 1 L'espace $\Omega$ est fini ou dénombrable.

Dans ce cas on suppose habituellement que la tribu des évènements  $\mathcal{A}$  est  $\mathcal{P}(\Omega)$ , l'ensemble de toutes les parties de  $\Omega$ . Par exemple, si  $\Omega$  est formé de 2 éléments notés  $a$  et  $b$ , alors  $\mathcal{P}(\Omega)$  est constitué des 4 sous ensembles suivants: l'ensemble vide  $\emptyset$ , les deux singletons  $\{a\}$  et  $\{b\}$  et  $\Omega = \{a,b\}$  lui même. Plus généralement, on a le fait suivant:

**Proposition 2.1** Si un ensemble  $\Omega$  a un nombre fini  $N$  d'éléments, alors l'ensemble des parties de  $\Omega$ :  $\mathcal{P}(\Omega)$  a  $2^N$  éléments.

**Démonstration** On procède par récurrence sur  $N$ . C'est trivial pour  $N = 1$  ou  $0$ . Si c'est vrai pour  $N$ , considérons

$$\Omega = \{a_1, \dots, a_N, a_{N+1}\} \text{ et } \Omega' = \{a_1, \dots, a_N\}.$$

Les parties de  $\Omega$  se partagent en deux catégories:

Catégorie 1: celles qui ne contiennent pas  $a_{N+1}$ .

Catégorie 2: celles qui contiennent  $a_{N+1}$ .

Il est clair que la catégorie 1 est égale à  $\mathcal{P}(\Omega')$  et que la catégorie 2 est en bijection avec  $\mathcal{P}(\Omega')$ , la bijection étant obtenue en ajoutant  $a_{N+1}$  aux éléments de  $\mathcal{P}(\Omega')$ . Comme d'après l'hypothèse de récurrence  $\mathcal{P}(\Omega')$  a  $2^N$  éléments, on en conclut que  $\mathcal{P}(\Omega)$  a  $2^N + 2^N = 2^{N+1}$  éléments, et la récurrence est étendue.

**Proposition 2.2** Si  $\Omega$  est infini dénombrable, alors  $\mathcal{P}(\Omega)$  est infini non dénombrable.

**Démonstration** La démonstration est analogue à la démonstration de Cantor. Sans perte de généralité on suppose  $\Omega$  égal à l'ensemble  $\mathbf{N}$  des entiers positifs ou nuls. Si  $X \subset \mathbf{N}$ , on lui associe la fonction indicatrice  $\mathbf{1}_X$  définie sur  $\mathbf{N}$  et à valeurs 0 ou 1 par  $\mathbf{1}_X(k) = 1$  si  $k \in X$  et  $\mathbf{1}_X(k) = 0$  si  $k \notin X$ . Remarquons aussi qu'inversement, si une fonction  $f$  définie sur  $\mathbf{N}$  est à valeurs 0 ou 1, alors c'est une indicatrice d'ensemble, c'est-à-dire qu'il existe  $X$  tel que  $f = \mathbf{1}_X$ : il s'agit de  $X = \{k \in \mathbf{N}; f(k) = 1\}$ .

Montrons alors la proposition par l'absurde en supposant que  $\mathcal{P}(\mathbf{N})$  soit dénombrable, c'est-à-dire qu'il existe une application bijective  $n \mapsto X_n$  de  $\mathbf{N}$  sur  $\mathcal{P}(\mathbf{N})$ . Alors la fonction  $f$  définie sur  $\mathbf{N}$  et à valeurs 0 ou 1 par

$$f(k) = 1 - \mathbf{1}_{X_k}(k)$$

est l'indicateur de quelque sous ensemble  $X_n$  de  $\mathbf{N}$  et donc pour tout  $k$  de  $\mathbf{N}$  on a

$$\mathbf{1}_{X_n}(k) = 1 - \mathbf{1}_{X_k}(k),$$

ce qui est une contradiction si  $k = n$ .

Les probabilités sont alors décrites par le résultat suivant

**Proposition 2.3** Soit  $\Omega$  un ensemble fini ou dénombrable. Soit  $x \mapsto p_x$  une application de  $\Omega$  dans les réels  $\geq 0$  telle que

$$\sum_{x \in \Omega} p_x = 1.$$

Pour tout  $A \subset \Omega$ , notons alors

$$P(A) = \sum_{x \in A} p_x.$$

Alors  $(\Omega, \mathcal{P}(\Omega), P)$  est un espace de probabilité. Inversement, toute probabilité  $P$  sur  $(\Omega, \mathcal{P}(\Omega))$  est du type précédent, avec  $p_x = P(\{x\})$ .

**Remarque** Si  $\Omega$  est fini, la proposition est évidente. Si  $\Omega$  est dénombrable, les sommes ci dessus quand  $A$  est dénombrable ont la signification suivante: puisque  $A$  est dénombrable, on peut numéroter ses éléments, c'est-à-dire qu'il existe une application bijective  $n \mapsto x_n$  de  $\mathbf{N}$  sur  $A$ .  $P(A)$  est alors défini rigoureusement comme la somme de la série  $\sum_{n=0}^{\infty} p_{x_n}$ . Toutefois, ce nombre ne dépend que de  $A$ , et non de la numérotation particulière de  $A$  choisie par  $n \mapsto x_n$ , grâce au théorème suivant sur les séries, que nous admettrons, ainsi que la proposition elle même:

**Théorème 2.4** Si la série  $\sum_{n=0}^{\infty} u_n$  est absolument convergente de somme  $S$ , et si  $n \mapsto \sigma(n)$  est une bijection de  $\mathbf{N}$  sur lui même, alors  $\sum_{n=0}^{\infty} u_{\sigma(n)}$  est aussi absolument convergente et de somme  $S$ .

### Exercices sur 2.1.

1. Soit  $\lambda > 0$ . Soit  $P$  la probabilité définie sur  $(\mathbf{N}, \mathcal{P}(\mathbf{N}))$  par

$$P(\{n\}) = e^{-\lambda} \frac{\lambda^n}{n!}.$$

Soit  $A$  l'ensemble des nombres pairs. Calculer  $P(A)$ . Soit  $N$  un entier, montrer que

$$P(\{0, 1, \dots, N\}) = 1 - \int_0^\lambda e^{-t} \frac{t^N}{N!} dt$$

(Méthode: considérer les deux membres comme des fonctions de  $\lambda$  dont on montrera qu'elles ont même valeur pour  $\lambda = 0$  et même dérivée).

2. Soit  $P$  la probabilité définie sur  $(\mathbf{N}^*, \mathcal{P}(\mathbf{N}^*))$  par  $P(\{n\}) = 2^{-n}$ . Calculer la probabilité de tirer un nombre  $n > 3$ ; un nombre  $n$  multiple de 3; un nombre dont le reste est 3 si on le divise par 4.

## 2 Le cas équiprobable.

Considérons le cas particulier de la Proposition 2.3 où  $\Omega$  a un nombre fini  $N = |\Omega|$  d'éléments et où tous les  $p_x$  sont égaux (et donc égaux à  $1/N$ .) Dans ce cas, si  $A \subset \Omega$  on a

$$P(A) = \frac{|A|}{|\Omega|} = \frac{\text{nombre de cas favorables}}{\text{nombre de cas possibles}}.$$

Pour exploiter cette égalité, il est nécessaire de posséder quelques principes généraux de dénombrement d'ensembles et de fonctions contenus dans les deux prochains théorèmes. Si  $E$  et  $F$  sont des ensembles, on note par  $E \times F$  leur produit cartésien, c'est-à-dire l'ensemble des couples  $(x, y)$  tels que  $x \in E$  et  $y \in F$ . On note par  $F^E$  l'ensemble des fonctions  $f$  définies sur  $E$  et à valeurs dans  $F$ . Si  $E$  est fini et est de taille  $n = |E|$  et si  $k$  est un entier avec  $0 \leq k \leq n$  on note par  $\mathcal{P}_k(E)$  l'ensemble des parties de  $E$  de taille  $k$ .

### Théorème 2.5

1. Si  $E$  et  $F$  sont des ensembles finis, alors  $|E \times F| = |E| \times |F|$ . Plus généralement, si  $F_1, \dots, F_n$  sont des ensembles finis:  $|F_1 \times \dots \times F_n| = |F_1| \times \dots \times |F_n|$ . Ensuite  $|F^E| = |F|^{|E|}$ . Enfin, si  $p = |F| \geq n = |E|$ , le nombre de fonctions *injectives* de  $E$  vers  $F$  est  $p(p-1)(p-2) \dots (p-n+1)$ . En particulier, le nombre de fonctions *bijectives* de  $E$  vers  $E$ , appelées *permutations* de  $E$ , est égal à  $n!$
2. Si  $E$  est fini et est de taille  $n = |E|$  et si  $k$  est un entier avec  $0 \leq k \leq n$  alors

$$|\mathcal{P}_k(E)| = C_n^k = \frac{n!}{k!(n-k)!} = \frac{n(n-1) \dots (n-k+1)}{k!}.$$

### Démonstration

1. La première formule est évidente: si  $e_1, \dots, e_n$  et  $f_1, \dots, f_p$  sont les éléments de  $E$  et  $F$ , le nombre de couples  $(e_i, f_j)$  est  $np$ . L'extension à  $n$  facteurs est immédiate également. Cette extension est ensuite appliquée au cas particulier où tous les ensembles  $F_j$  sont égaux au même ensemble  $F$ . Si  $|E| = n$ , il y a alors bijection entre  $F^E$  et  $F \times \dots \times F$  ( $n$  fois). D'où  $|F^E| = |F| \times \dots \times |F| = |F|^n = |F|^{|E|}$ . Quant au nombre de fonctions injectives, la formule donnée se justifie facilement: on identifie  $E$  à  $(1, 2, \dots, n)$ , et l'image de 1 peut occuper  $p$  positions, l'image de 2 peut occuper une des  $p-1$  positions restantes, l'image de 3 une des  $p-2$  positions restantes, etc. Faire  $E = F$  pour le nombre de permutations de  $E$  (on rappelle que si  $|E| = |F|$  avec  $E$  fini, alors une fonction  $f$  de  $E$  vers  $F$  est injective si et seulement si elle est surjective).
2. Rappelons pour cette partie la formule de Pascal:

**Proposition 2.6** Si  $k$  est un entier avec  $1 \leq k \leq n$  on a

$$C_n^{k-1} + C_n^k = C_{n+1}^k.$$

**Démonstration**

$$C_n^{k-1} + C_n^k = \frac{n!}{(k-1)!(n-k)!} \left[ \frac{1}{n-k+1} + \frac{1}{k} \right] = \frac{(n+1)!}{k!(n+1-k)!} = C_{n+1}^k.$$

Pour prouver 2) on observe que c'est trivial pour  $k = 0$ , puis on fixe  $k > 0$  et on montre 2) par récurrence sur  $n$ . C'est trivial pour  $n = k$ . Supposons enfin 2) vrai pour  $n$  et supposons que  $E$  ait  $n + 1$  éléments, qu'on prend égaux à  $1, 2, \dots, n + 1$  sans perte de généralité. Soit aussi  $E'$  l'ensemble des  $n$  premiers entiers. On partage alors les éléments de  $\mathcal{P}_k(E)$  en deux catégories:

Catégorie 1: ceux qui ne contiennent pas  $n + 1$ .

Catégorie 2: ceux qui contiennent  $n + 1$ .

La catégorie 1 est égale à  $\mathcal{P}_k(E')$  et a donc  $C_n^k$  éléments par l'hypothèse de récurrence. La catégorie 2 est en bijection avec  $\mathcal{P}_{k-1}(E')$  (enlever  $n + 1$  à un membre de la catégorie 2 pour avoir un élément de  $\mathcal{P}_{k-1}(E')$ ) et donc par l'hypothèse de récurrence a  $C_{n-1}^{k-1}$  éléments. La formule de Pascal montre alors que  $\mathcal{P}_k(E)$  a  $C_{n+1}^k$  éléments et la récurrence est étendue.

Voici un exemple d'application du théorème précédent.

**Proposition Anniversaires.**  $n$  personnes sont réunies. Quelle est la probabilité que au moins deux d'entre elles aient le même anniversaire?

On formalise le problème en le simplifiant un peu: on ignore d'abord le problème du 29 février, et on postule donc que l'espace des observablest  $\Omega = F^E$  où  $E$  est l'ensemble des personnes et où  $F$  est l'ensemble des  $p = 365$  jours de l'année: on observe donc la fonction  $f \in \Omega$  qui à chaque personne associe son anniversaire. On postule ensuite qu'on est dans le cas équiprobable, ce qui n'est qu'une approximation: il y a plus d'enfants conçus au printemps et en été qu'en novembre sous nos climats. Finalement, il est plus facile de calculer la probabilité du complémentaire  $A^c$  de l'évènement  $A$  "deux personnes au moins ont le même anniversaire", car c'est la probabilité que la fonction  $f$  soit injective. D'après le théorème 2.5 1), c'est

$$P(A^c) = \frac{1}{365^n} 365(365-1) \cdots (365-n+1) = \prod_{k=1}^{n-1} \left(1 - \frac{k}{365}\right) = \exp \sum_{k=1}^{n-1} \log\left(1 - \frac{k}{365}\right).$$

Si  $n$  n'est pas grand, une évaluation approximative de cette somme se fait en remplaçant  $\log(1 - x)$  par  $-x$  et en utilisant la somme d'une progression arithmétique étudiée en Terminale

$$\sum_{k=1}^{n-1} k = \frac{1}{2}n(n-1) \sim n/2,$$

qui conduit à l'approximation  $P(A^c) \sim \exp(-n/730)$ . Pour voir par exemple pour quel  $n$  on a  $P(A^c) \sim 1/2$  on prend  $n \sim \sqrt{730 \log 2} \sim 23$ . Pour un calcul plus sérieux,

on peut utiliser l'encadrement pour  $0 < x < 1$  :

$$-x - \frac{x}{2(1-x)} < \log(1-x) < -x - \frac{x}{2};$$

La majoration de droite se déduit du développement en série entière, celle de gauche se montre en étudiant la fonction  $x + \frac{x}{2(1-x)} + \log(1-x)$ . On a aussi besoin de la somme des premiers carrés:

$$\sum_{k=1}^{n-1} k^2 = \frac{1}{6}n(2n-1)(n-1) \sim n^3/3,$$

qui s'établit par récurrence. Si  $x \leq (n-1)/365$ , alors  $-1/(1-x) \geq -365/(365-n+1)$ . D'où l'encadrement :

$$-\frac{n(n-1)}{2} \frac{1}{365} - \frac{n(n-1)(2n+1)}{6} \frac{1}{2 \times 365^2} \frac{365}{365-n+1} <$$

$$\log P(A^c) < -\frac{n(n-1)}{2} \frac{1}{365} - \frac{n(n-1)(2n+1)}{6} \frac{1}{2 \times 365^2}.$$

Par exemple, si  $n = 35$  on trouve  $P(A^c) = 0,186...$  Si 35 personnes sont réunies, la probabilité que deux d'entre elles au moins aient le même anniversaire est donc 0,813...

Le prochain théorème sert en particulier à résoudre le problème plus difficile du calcul du nombre de fonctions *surjectives*.

**Théorème 2.7** (Principe d'inclusion-exclusion) Soit  $E$  un ensemble fini et soit  $f$  et  $g$  des fonctions réelles définies sur  $\mathcal{P}(E)$  satisfaisant pour tout  $A \subset E$  :

$$f(A) = \sum_{B \subset A} g(B).$$

Alors pour tout  $A \subset E$  :

$$g(A) = \sum_{B \subset A} (-1)^{|A \setminus B|} f(B).$$

**Démonstration** Si  $C \subset A \subset E$  notons

$$F(A, C) = \sum_{C \subset B \subset A} (-1)^{|A \setminus B|}.$$

Si  $|A \setminus C| = n$ , puisque il y a  $C_n^k$  parties de  $A \setminus C$  de taille  $k$  on peut écrire  $F(A, C) = \sum_{k=0}^n (-1)^k C_n^k$ , qui est à son tour  $(1 + (-1))^n$  à cause de la formule du binôme de Pascal  $(a + b)^n = \sum_{k=0}^n a^{n-k} b^k C_n^k$ . Donc si  $n > 0$ , c'est-à-dire si  $C \neq A$ , on a

$F(A,C) = 0$ . Si  $n = 0$ , c'est-à-dire si  $C = A$  on a  $F(A,C) = 1$ . Calculons alors le second membre de l'égalité à démontrer:

$$\begin{aligned} \sum_{B \subset A} (-1)^{|A \setminus B|} f(B) &= \sum_{B \subset A} (-1)^{|A \setminus B|} \sum_{C \subset B} g(C) = \\ \sum_{C \subset B} g(C) \sum_{C \subset B \subset A} (-1)^{|A \setminus B|} &= \sum_{C \subset B} g(C) F(A,C) = g(A). \end{aligned}$$

La première égalité exploite le lien entre  $f$  et  $g$ , la seconde inverse les sommations par rapport aux indices de sommation  $B$  et  $C$ , la troisième résulte de la définition de  $F(A,C)$ , la quatrième du calcul de  $F$  précédent et fournit le résultat voulu.

Voici deux applications.

**Proposition Nombre de fonctions surjectives.** Si  $|E| = n \geq |F| = p$ , quel est le nombre de fonctions surjectives de  $E$  vers  $F$ ?

Pour répondre on applique le théorème précédent aux fonctions  $f$  et  $g$  définies sur  $\mathcal{P}(F)$  ainsi: si  $A \subset F$ ,  $f(A) = |A|^n$  est le nombre de fonctions de  $E$  vers  $F$  dont l'image est contenue dans  $A$  (on pourrait donc dire tout aussi bien les fonctions de  $E$  vers  $A$ ); et  $g(A)$  est le nombre de fonctions de  $E$  vers  $F$  dont l'image est exactement égale à  $A$  (on pourrait dire les fonctions de  $E$  vers  $A$  qui sont surjectives). On veut donc calculer  $g(F)$ .

Les hypothèses du théorème sont remplies, on a bien en effet  $f(A) = \sum_{B \subset A} g(B)$ . Par conséquent

$$g(F) = \sum_{B \subset F} (-1)^{|F \setminus B|} |B|^n = \sum_{k=0}^p C_p^k (-1)^{p-k} k^n.$$

**Proposition Problème des rencontres.** Si  $E$  a  $n$  éléments, combien y a-t-il de permutations  $\sigma$  de  $E$  sans point fixe, c'est-à-dire telles que pour tout  $j \in E$  on ait  $\sigma(j) \neq j$ ?

On applique le théorème précédent aux fonctions  $f$  et  $g$  définies sur  $\mathcal{P}(E)$  ainsi: si  $A \subset E$ ,  $f(A) = |A|!$  est le nombre de permutations de  $E$  telles que pour tout  $j \in A^c$  on ait  $\sigma(j) = j$ , et  $g(A)$  est le nombre de permutations de  $E$  telles que pour tout  $j \in A^c$  on ait  $\sigma(j) = j$  et pour tout  $j \in A$  on ait  $\sigma(j) \neq j$ . On veut donc calculer  $g(E)$ .

Les hypothèses du théorème sont remplies, on a bien en effet  $f(A) = \sum_{B \subset A} g(B)$ . Par conséquent

$$\begin{aligned} g(E) &= \sum_{B \subset E} (-1)^{|E \setminus B|} |B|! = \\ &= \sum_{k=0}^n C_n^k (-1)^{n-k} k! = \end{aligned}$$

$$n! \sum_{k=0}^n (-1)^{n-k} \frac{1}{(n-k)!} =$$

$$n! \sum_{k=0}^n (-1)^k \frac{1}{k!}.$$

Si  $\Omega$  est l'ensemble des permutations de  $E$  et si il est muni de la probabilité équi-probable, la probabilité pour qu'une permutation aléatoire soit sans point fixe est donc

$$\sum_{k=0}^n (-1)^k \frac{1}{k!},$$

soit approximativement  $e^{-1} = 0,367\dots$  si  $n > 6$ .

### Exercices sur 2.2.

1. Soit des entiers tels que  $2 \leq a \leq b \leq c$ . On tire de façon équiprobable une partie de taille  $a$  de l'ensemble des  $b + c$  entiers  $> 0$ . Calculer la probabilité pour que 0 d'entre eux soient  $> a$ ; pour que 2 d'entre eux exactement soient  $> a$ .
2. Deux dés non pipés sont marqués sur leurs six faces 1,2,2,3,3,4 et 1,3,4,5,6,8 respectivement. On jette une fois ces deux dés et on note par  $A_k$  l'évènement "la somme des points  $i$  du premier dé et des points  $j$  du second est  $k$ ". Calculer pour  $k = 2, 3, \dots, 12$  le nombre  $P(A_k)$ .
3. 12 méchantes fées se penchent sur le berceau des quintuplés et attribuent chacune au hasard à un enfant un défaut. Quel est la probabilité qu'il y ait au moins un enfant parfait?

## 3 Le schéma Succès-Echec.

**Le schéma Succès-Echec fini.** Si une expérience a deux issues, arbitrairement notées succès ( $S$ ) et échec ( $E$ ) et si on la répète  $n$  fois, ce qu'on observe est une suite de longueur  $n$  de  $S$  et de  $E$ . Pour modéliser cela, on introduit l'espace des observables  $\Omega = \{E, S\}^n$  formé des  $2^n$  suites  $\omega = (\omega_1, \dots, \omega_n)$  où les  $\omega_j$  sont égaux à  $E$  ou  $S$ . On munit  $\Omega$  de la tribu  $\mathcal{P}(\Omega)$ . Quant à la probabilité, on se fixe un nombre  $p$  tel que  $0 < p < 1$  qui est la probabilité d'un succès si on n'effectue qu'une fois l'expérience. Introduisons alors l'importante quantité  $X(\omega)$  définie ainsi: si  $\omega = (\omega_1, \dots, \omega_n) \in \Omega$  alors  $X(\omega)$  désigne le nombre de succès que comprend la suite  $\omega$ . Par exemple,  $X(SSES) = 3$ ,  $X(ESEE) = 0$ . Pour  $\omega \in \Omega$  tel que  $X(\omega) = k$  on définit alors  $P(\{\omega\}) = p^k(1-p)^{n-k}$ ; Comme tout évènement  $A \in \mathcal{P}(\Omega)$  est réunion de singletons  $\{\omega\}$  deux à deux disjoints, cela suffit à définir  $P(A)$  et donc la probabilité  $P$  sur  $(\Omega, \mathcal{P}(\Omega))$ .

Parmi ces évènements, les plus importants sont les  $\{X = k\}$  ( ceci est une sténographie que nous utiliserons souvent pour écrire brièvement l'évènement  $\{\omega \in$

$\Omega ; X(\omega) = k\}$ ). Voici leur probabilité:

**Proposition 2.9** Pour le schéma Succès Echec fini associé à la probabilité  $p$  d'un succès, si  $X$  est le nombre de succès en  $n$  expériences, alors

$$P(X = k) = C_n^k p^k (1 - p)^{n-k}.$$

**Démonstration** Notons  $A = \{\omega \in \Omega ; X(\omega) = k\}$ . Définissons l'application de  $A$  dans  $\mathcal{P}_k(\{1, 2, \dots, n\})$  par  $\omega \mapsto \{j ; \omega_j = S\}$ . Il est clair que c'est une bijection; donc d'après le Théorème 2.5 b),  $|A| = C_n^k$ . Enfin puisque tous les  $\{\omega\}$  contenus dans  $A$  ont la même probabilité  $p^k(1 - p)^{n-k}$  on obtient

$$P(A) = \sum_{\omega \in A} P(\{\omega\}) = |A| p^k (1 - p)^{n-k} = C_n^k p^k (1 - p)^{n-k}.$$

**Le schéma Succès-Echec infini.** Il s'agit ensuite de modéliser le cas où on veut effectuer un nombre arbitraire d'expériences: par exemple on peut vouloir répéter les essais jusqu'à ce qu'apparaisse 4 succès consécutifs. Une telle modélisation est impossible avec le schéma fini ci dessus, et on prend alors pour espace  $\Omega$  des observables l'ensemble  $\{E, S\}^{\mathbf{N}^*}$  des suites infinies de  $S$  et de  $E$ , en notant par  $\mathbf{N}^*$  l'ensemble des entiers  $> 0$ . Il est clair que  $\Omega$  est en bijection avec les parties de  $\mathbf{N}^*$ , et donc d'après la proposition 2.2  $\Omega$  n'est pas dénombrable. Cela cause une sérieuse difficulté en ce qui concerne la construction de l'espace de probabilité correspondant. On construit la tribu  $\mathcal{A}$  et la probabilité  $P$  par un procédé d'approximation que nous décrivons maintenant.

Fixons l'entier  $n$  et définissons  $\Omega' = \{E, S\}^{\{1, \dots, n\}}$  et  $\Omega'' = \{E, S\}^{\{n+1, n+2, \dots\}}$ , de sorte que  $\Omega = \Omega' \times \Omega''$ , et définissons la tribu suivante de parties de  $\Omega$  :

$$\mathcal{A}_n = \{A \times \Omega'' ; A \in \mathcal{P}(\Omega')\}.$$

Intuitivement, les évènements de  $\mathcal{A}_n$  sont les évènements ne dépendant que de ce qui s'est passé jusqu'à l'instant  $n$ . En particulier, nous avons  $\mathcal{A}_n \subset \mathcal{A}_{n+1}$ .

Si  $\omega' = (\omega_1, \dots, \omega_n) \in \Omega'$  comprend  $k$  succès, définissons la probabilité  $P_n(\{\omega'\} \times \Omega'') = p^k (1 - p)^{n-k}$ . Cela permet donc de définir la probabilité  $P_n$  sur  $\mathcal{A}_n$ . L'espace de probabilité  $(\Omega, \mathcal{A}_n, P_n)$  est presque identique à l'espace du schéma Succès Echec fini décrit ci dessus.

Maintenant, notons

$$\mathcal{A}' = \cup_{n \geq 1} \mathcal{A}_n.$$

La famille  $\mathcal{A}'$  n'est pas une tribu, car ce n'est pas fermé pour la réunion dénombrable. Voici un contre exemple. Soit  $A_n$  l'ensemble des suites  $\omega$  infinies comprenant au moins un succès à l'instant  $n$  ou avant. Alors  $A_n$  est dans  $\mathcal{A}_n$  et donc dans  $\mathcal{A}'$ . Pourtant  $A = \cup_{n \geq 1} A_n$  n'est pas dans  $\mathcal{A}'$ . En effet  $A$  est l'ensemble des suites  $\omega$  infinies comprenant au moins un succès. Mais il n'existe pourtant aucun  $n$  tel que  $A \in \mathcal{A}_n$ , et donc  $A \notin \mathcal{A}'$ . Réaliser cette chose subtile fait progresser dans la compréhension de la théorie. On définit alors la tribu  $\mathcal{A}$  sur  $\Omega$  comme la plus petite tribu contenant  $\mathcal{A}'$ .

Pour définir enfin la probabilité  $P$  sur  $\mathcal{A}$ , on fait l'observation essentielle suivante: on a non seulement  $\mathcal{A}_n \subset \mathcal{A}_{n+1}$ , mais de plus la restriction de  $P_{n+1}$  au sous ensemble  $\mathcal{A}_n$  de  $\mathcal{A}_{n+1}$ , qui était le domaine de définition de  $P_{n+1}$ , coïncide avec  $P_n$ . Par conséquent, il existe une fonction universelle  $P'$  définie sur  $\mathcal{A}'$  telle que pour tout  $A \in \mathcal{A}'$  on ait  $P'(A) = P_n(A)$  pour tous les  $n$  tels que  $A \in \mathcal{A}_n$ . A partir de ce point, les choses cessent d'être élémentaires, et nous sommes obligés d'admettre le théorème suivant, dont la démonstration est donnée en troisième année d'université:

**Théorème 2.10** Il existe une et une seule probabilité  $P$  sur  $\mathcal{A}$  telle que pour tout  $A \in \mathcal{A}'$  on ait  $P(A) = P'(A)$ .

On peut ainsi démontrer l'idée intuitive qu'un évènement de probabilité strictement positive, même petite, finit toujours par arriver. Plus précisément, si  $A$  est l'ensemble des  $\omega \in \Omega$  comprenant au moins un succès, alors  $P(A) = 1$ . En effet, si  $B_n$  est l'ensemble des  $\omega \in \Omega$  comprenant au moins un succès avant l'instant  $n$  ou à l'instant  $n$ , alors  $A = \cup_{n \geq 1} B_n$  et  $B_n \subset B_{n+1}$ . Par continuité monotone (Th. 1.3, (2)) on a donc  $\lim P(B_n) = P(A)$ . Comme  $P(B_n^c) = (1-p)^n$  tend vers 0, on a le résultat. Plus généralement on peut montrer que toute séquence  $a$  finie donnée à l'avance ( par exemple SSEESSEESSEESSEE, ou le codage en binaire d'une fable de La Fontaine) finira par arriver. Plus précisément:

**Théorème 2.11** Soit  $a = (a_1, \dots, a_n) \in \{E, S\}^n$  une suite fixée de longueur  $n$  de succès et d'échecs, et soit

$$A = \{\omega \in \Omega ; \text{il existe } N \geq 0 \text{ avec } \omega_{N+1} = a_1, \dots, \omega_{N+n} = a_n\}.$$

Alors  $P(A) = 1$ .

**Démonstration** Soit  $k$  le nombre de  $S$  dans la suite  $a$ . Notons

$$A_N = \{\omega \in \Omega ; \omega_{N+1} = a_1, \dots, \omega_{N+n} = a_n\}.$$

Alors  $P(A_N) = p^k(1-p)^{n-k}$  par définition de  $P$ . Introduisons  $B_m = \cup_{j=0}^{m-1} A_{jn}$ . Alors  $B_m \subset B_{m+1}$  et

$$A = \cup_{N \geq 0} A_N \supset B = \cup_{m \geq 0} B_m.$$

On a de plus

$$P(B_m^c) = P(\cap_{j=0}^{m-1} A_{jn}^c) = (1 - p^k(1-p)^{n-k})^m \rightarrow_{m \rightarrow \infty} 0.$$

Par continuité monotone, on a donc  $P(B^c) = 0$ . D'où  $1 = P(B) \leq P(A) = 1$ .

## 4 Le cas où $\Omega = \mathbf{R}$ .

Ce cas est naturellement le plus important de tous. La tribu mise sur  $\mathbf{R}$  est la tribu de Borel  $\mathcal{B}$  définie à la section 1 comme la plus petite tribu contenant les intervalles

(ouverts, fermés, semi ouverts, demi droites) Parmi ses éléments, les boréliens, les seuls qu'on aura concrètement à manipuler sont les réunions d'intervalles.

Pour décrire les probabilités sur  $(\mathbb{R}, \mathcal{B})$ , introduisons une définition importante:

**Définition** Soit  $F$  une fonction de  $\mathbb{R}$  dans  $\mathbb{R}$ . On dit que  $F$  est une *fonction de répartition* si elle satisfait aux trois propriétés suivantes:

- $F$  est croissante (au sens large);
- $\lim_{x \rightarrow -\infty} F(x) = 0$  et  $\lim_{x \rightarrow +\infty} F(x) = 1$ ;
- $F$  est continue à droite en tout point  $x$ , c'est-à-dire  $\lim_{h \searrow 0} F(x+h) = F(x)$ .

On a alors le théorème fondamental suivant:

**Théorème 2.12** Soit  $P$  une probabilité sur  $(\mathbb{R}, \mathcal{B})$ . Soit  $F_P$  la fonction réelle définie par

$$F_P(x) = P(]-\infty, x]).$$

Alors  $F_P$  est une fonction de répartition. Inversement, si  $F$  est une fonction de répartition, alors il existe une et une seule probabilité sur  $(\mathbb{R}, \mathcal{B})$  telle que  $F_P = F$ .

**Démonstration** Si  $x < y$ , alors  $A = ]-\infty, x] \subset B = ]-\infty, y]$ , et donc  $F_P(x) = P(A) \leq P(B) = F_P(y)$ . Ensuite, si  $(x_n)$  tend vers  $-\infty$  en décroissant et si  $A_n = ]-\infty, x_n]$ , alors  $A_n \supset A_{n+1}$  et  $\bigcap_{n \geq 1} A_n = \emptyset$ ; par continuité monotone  $P(A_n)$  tend vers 0. Donc  $\lim_{n \rightarrow \infty} F_P(x_n) = 0$ . Comme ceci est vrai quelle que soit la suite  $(x_n)$  tendant vers  $-\infty$  en décroissant, on en déduit  $\lim_{x \rightarrow -\infty} F_P(x) = 0$ . De même, si  $(y_n)$  tend vers  $+\infty$  en croissant et si  $B_n = ]-\infty, y_n]$ , alors  $B_n \subset B_{n+1}$  et  $\bigcup_{n \geq 1} B_n = \mathbb{R}$ ; par continuité monotone  $P(B_n)$  tend vers  $P(\mathbb{R}) = 1$  et on a  $\lim_{y \rightarrow +\infty} F_P(y) = 1$ .

Enfin, si  $h_n \searrow 0$ , soit  $C_n = ]\infty, x + h_n]$ . Alors  $C_n \supset C_{n+1}$  et  $\bigcap_{n \geq 1} C_n = ]\infty, x]$ . Par continuité monotone on a donc  $\lim_{n \rightarrow +\infty} F(x + h_n) = F_P(x)$ , d'où la continuité à droite annoncée de la fonction  $F_P$ .

Nous admettrons la réciproque, qui est la partie difficile.

Commentaires: Ce résultat est assez rassurant: bien qu'on connaisse mal la tribu  $\mathcal{B}$ , et donc les probabilités définies dessus, il y a en fait bijection entre l'ensemble de toutes les probabilités sur  $\mathbb{R}$  et l'ensemble moins abstrait de toutes les fonctions de répartition. Mais la démonstration complète est réservée à la 3<sup>ème</sup> année.

La fonction de répartition permet de calculer les probabilités de tous les intervalles. Pour simplifier, adoptons la notation pour la limite à gauche en  $x$  de la fonction croissante  $F$ :

$$F(x-0) = \lim_{h \nearrow 0} F(x+h).$$

**Proposition 2.13** Soit  $F$  la fonction de répartition d'une probabilité  $P$  sur  $(\mathbb{R}, \mathcal{B})$ . Alors

- $P(]-\infty, x]) = F(x-0)$ ,  $P(]x, +\infty[) = 1 - F(x)$ ,  $P([x, +\infty[) = 1 - F(x-0)$ .

- Pour  $a \leq b$ ,  $P(]a,b]) = F(b) - F(a)$ ,  $P([a,b]) = F(b - 0) - F(a - 0)$ .
- $P(]a,b]) = F(b - 0) - F(a)$ ,  $P([a,b]) = F(b) - F(a - 0)$  et en particulier

$$P(\{a\}) = F(a) - F(a - 0).$$

**Démonstration** La première égalité s'obtient en considérant  $A_n = ]-\infty, x + h_n]$ , où  $h_n$  est  $< 0$  et croît vers 0. Alors  $A_n \subset A_{n+1}$  et  $\cup_{n \geq 1} A_n = ]-\infty, x[$ . Par convergence monotone l'égalité s'ensuit. Les deux suivantes s'obtiennent par passage au complémentaire. La suivante découle de l'égalité

$$]-\infty, b] = ]-\infty, a] \cup ]a, b],$$

et du fait que au second membre les deux ensembles sont disjoints. De même

$$]-\infty, b[ = ]-\infty, a[ \cup ]a, b[$$

fournit l'égalité suivante grâce à la première égalité de la liste. Laissons les dernières en exercice.

Donnons maintenant des exemples de fonctions de répartition

**Définition Fonctions de répartition à densité.** Soit  $f$  une fonction positive définie sur  $\mathbb{R}$  qui ait des discontinuités au plus en un nombre fini de points  $a_1 < a_2 < \dots < a_N$  et qui soit telle que les intégrales  $\int_{a_i}^{a_{i+1}} f(x)dx$  convergent et satisfassent

$$\sum_{i=0}^N \int_{a_i}^{a_{i+1}} f(x)dx = 1,$$

avec la convention  $a_0 = -\infty$  et  $a_{N+1} = +\infty$ .

On définit alors la fonction  $F$  par  $F(x) = \int_{-\infty}^x f(t)dt$ . Il est clair que  $F$  est une fonction de répartition. Ici, elle est de plus continue et, d'après le théorème fondamental du calcul intégral, elle satisfait  $F'(x) = f(x)$  pour tout  $x \notin \{a_1, \dots, a_N\}$ . La fonction  $f$  s'appelle alors la *densité* de la fonction de répartition  $F$ .

Par exemple  $f_1(x) = \frac{1}{2}e^{-|x|}$ ,  $f_2(x) = \frac{1}{\pi} \frac{1}{1+x^2}$ ,  $f_3(x) = 0$  si  $x \leq 0$  et  $f_3(x) = \frac{1}{\sqrt{\pi x}} e^{-x}$  si  $x > 0$ , qu'il est plus rapide de définir par

$$f_3(x) = \frac{1}{\sqrt{\pi x}} e^{-x} \mathbf{1}_{]0, \infty[}(x),$$

où  $\mathbf{1}_E(x) = 1$  si  $x \in E$  et  $\mathbf{1}_E(x) = 0$  sinon: la fonction  $\mathbf{1}_E$  s'appellera désormais l'*indicateur* de l'ensemble  $E$ . Dernier exemple:

$$f_4(x) = \mathbf{1}_{]0,1]}(x).$$

Dans ces exemples,  $N = 0$  pour  $f_1$  et  $f_2$ ,  $N = 1$  pour  $f_3$  et  $N = 2$  pour  $f_4$ .

Il est important de ne pas confondre les deux fonctions  $F$  et  $f$ . Pour les exemples ci dessus de densités, les fonctions de répartition correspondantes seront respectivement

$$F_1(x) = \frac{1}{2}e^x \text{ pour } x \leq 0, F_1(x) = 1 - \frac{1}{2}e^{-x},$$

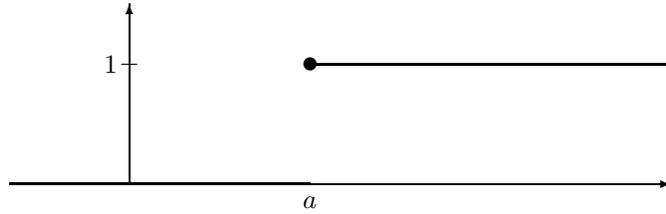
$$F_2(x) = \frac{1}{2} + \frac{1}{\pi} \arctan x,$$

$F_4(x) = 0$  pour  $x \leq 0$ ,  $F_4(x) = x$  pour  $0 \leq x \leq 1$ ,  $F_4(x) = 1$  pour  $1 \leq x$ , ( $F_3(x)$  ne peut s'exprimer de façon élémentaire).

**Définition La probabilité  $\delta_a$  de Dirac.** Si  $a$  est un réel, il s'agit de la probabilité sur  $\mathbf{R}$  définie par  $\delta_a(A) = 0$  si  $a \notin A$ , et  $\delta_a(A) = 1$  si  $a \in A$ . Appliquant ceci à  $A = ] - \infty, x]$ , on obtient la fonction de répartition

$$F_{\delta_a}(x) = 0 \text{ pour } x < a, F_{\delta_a}(x) = 1 \text{ pour } a \leq x.$$

Voici son graphe



Si  $a = 0$ , cette fonction s'appelle l'échelon de Heaviside. Les travaux de 1894 de cet ingénieur électricien sont à la source de la théorie moderne des distributions. Cette théorie permet par exemple de donner un sens à la dérivation de la fonction ci dessus: c'est la probabilité de Dirac  $\delta_a$  qui jouerait alors le rôle de la dérivée.

**Définition Probabilité discrète sur un nombre fini de points.** Soit  $N$  un entier  $> 0$ , soit  $a_1 < a_2 < \dots < a_N$  des réels et soit  $p_1, \dots, p_N$  des nombres positifs tels que  $p_1 + \dots + p_N = 1$ . On considère la probabilité sur  $\mathbf{R}$  définie par

$$P = p_1\delta_{a_1} + \dots + p_N\delta_{a_N}.$$

En d'autres termes, si  $A$  est un borélien:

$$P(A) = p_1\delta_{a_1}(A) + \dots + p_N\delta_{a_N}(A) = \sum_{j; a_j \in A} p_j.$$

En particulier, si  $A = ] - \infty, x]$ , on obtient la fonction de répartition

$$F_P(x) = \sum_{j; a_j \leq x} p_j,$$

dont le graphe est celui d'une fonction en escalier croissante, où le saut en  $a_j$  est égal à  $p_j$ . Ce cas revient un peu au cas où  $\Omega$  n'avait qu'un nombre fini de points, puisqu'ici  $P$  est concentrée sur  $\{a_1, \dots, a_N\}$ .

Si on remplace la suite finie précédente par un ensemble dénombrable de  $\mathbf{R}$ , l'extension est facile.

**Définition Probabilité discrète.** On s'intéresse à l'ensemble dénombrable formé des points d'une suite  $(a_n)$  telle que  $a_1 < a_2 < \dots < a_n < \dots$  et soit  $p_n$  des nombres positifs tels que  $\sum_1^\infty p_n = 1$ . On formera la probabilité  $P$  définie pour tout Borélien  $A$  par

$$P(A) = \sum_1^\infty p_n \delta_{a_n}(A),$$

dont la fonction de répartition est en escalier croissante avec une infinité de points de discontinuités.

**Définition Type mixte.** On rencontre un peu rarement des fonctions de répartition de la forme  $F = \lambda G + (1 - \lambda)H$  où  $G$  est une fonction de répartition à densité, comme vu à l'exemple 1, où  $H$  est une fonction de répartition d'une probabilité discrète, comme vu aux exemples 2, 3 ou 4, et où  $0 < \lambda < 1$ . Si  $H$  a une discontinuité en  $a$  de saut  $p$ , alors  $F$  a une discontinuité en  $a$  de saut  $(1 - \lambda)p$ .

#### Exercices sur 2.4.

1. Calculer la densité des fonctions de répartition suivantes:  
 $F_1(x) = 0$  si  $x \leq 0$  et  $F_1(x) = 1 - \exp(-x)$  si  $x > 0$ ;  
 $F_2(x) = 0$  si  $x \leq 1$  et  $F_2(x) = 1 - \frac{1}{x^a}$  si  $x > 1$  (avec  $a > 0$ ).
2. Calculer la fonction de répartition de la densité suivante:  
 $f(x) = 1/2$  si  $-2 < x < -1$ ,  $f(x) = 1/2$  si  $1 < x < 2$ , et 0 ailleurs.
3. On note par  $[x]$  la partie entière du nombre réel  $x$ , c'est-à-dire l'entier  $n$  tel que  $n \leq x < n + 1$ . Par exemple  $[\sqrt{2}] = 1$ ,  $[-\sqrt{2}] = -2$ ,  $[3] = 3$ . On considère la probabilité discrète de fonction de répartition  $F(x) = 0$  si  $x < 0$  et  $F(x) = 1 - \frac{1}{2^{|x|+1}}$  si  $x \geq 0$ . Tracer le graphe de  $F$ . Calculer les probabilités des événements suivants:  
 $A_1 = \{0\}$ ,  $A_2 = \{1, 2\}$ ,  $A_3 = \{4, 5, \dots\}$ .