

Distributions univariées

Mathématiques Générales B
Université de Genève

Sylvain Sardy

17 avril 2008

1. Variables aléatoires

Définition de v.a. réelle : une fonction définie sur l'ensemble des résultats possibles, appelé ensemble fondamental ou univers Ω , d'une expérience aléatoire

$$X : \Omega \longrightarrow X(\Omega) \subset \mathbb{R}.$$

Exemples :

- On jette deux dés, et on considère $X =$ la somme des deux chiffres.
- On joue à pile ou face 10 fois, et on considère $X =$ le nombre de Pile.
- On joue au loto, et on considère $X =$ le nombre de gagnants.
- On jette un dé jusqu'à ce qu'on gagne (le 6 sort), et on considère $X =$ nombre de fois où le dé est jeté.

- On joue au loto, et on considère X = la somme gagnée par un joueur.
- On mesure sur le Pont du Mont Blanc la vitesse X des véhicules.

Deux types de variable aléatoire :

- **Discrète** quand $X(\Omega) = \{x_1, x_2, \dots\}$ est fini ou dénombrable.
- **Continue** quand $X(\Omega)$ est un intervalle de \mathbb{R} .

Deux types de distribution :

- **Discrète** définie par une fonction de probabilité/fréquence : $P(X = x_i)$.
- **Continue** définie par une fonction de densité $f(x)$ telle que

$$P(a \leq X \leq b) = \int_a^b f(x) dx.$$

Un très grand nombre de distribution a été défini et étudié, et sert à modéliser des phénomènes aléatoires :

- Discrète : **Uniforme discrète** (equiprobabilité), **Bernouilli**, **Binomiale**, **Géométrique**, **Hyper-géométrique**, **Poisson**, Multinomiale, Binomiale-Négative, etc.
- Continue : **Uniforme**, **Gaussienne/Normale**, **Chi-deux**, **Exponentielle**, Student, Cauchy, Log-Normale, Beta, Gamma, Weibull, F, Pareto, Rayleigh, Rice, Fisher-Tippett, etc.

On va en définir quelques-unes, puis on étudiera dans un prochain chapitre quelques propriétés (espérance et variance).

2. Distributions discrètes

Distribution uniforme discrète

Une expérience a n réalisations équiprobables x_1, x_2, \dots, x_n , où n est finie.
Alors

$$P(X = x_i) = \frac{1}{n} \quad \text{pour tout } i.$$

Exemple : un dé.

1) A quoi ressemble le graphique de la fonction de probabilité uniforme discrète ?

2) Vérifie-t-on $\sum_i P(X = x_i) = 1$?

Hypergéométrique(N, D, n)

Une population finie de N objets en contient D défectueux. On en envoie n et on note K le nombre d'objets défectueux dans l'échantillon envoyé. Puisqu'il s'agit d'un échantillon sans remise, on sait par l'analyse combinatoire que

$$P(K = k) = \frac{C_{D,k} C_{N-D,n-k}}{C_{N,n}}.$$

Exemple : tableau de contingence

	Envoyé	Non-envoyé	Total
Défectueux	k	$D-k$	D
Non-défectueux	$n-k$	$N-n-D+k$	$N-D$
Total	n	$N-n$	N

Bernoulli(p)

(James Bernoulli 1654–1705)

Une expérience a $n = 2$ réalisations possibles : soit 0 (échec/défectueux), soit 1 (succès), et

$$P(X = 1) = 1 - P(X = 0) = p.$$

Exemple : une pièce de monnaie, toute expérience aléatoire avec un succès (1) et un échec (0).

1) 2)

Géométrique(p)

On répète une expérience de Bernoulli jusqu'à ce qu'un succès arrive. Soit N le nombre d'essais nécessaires, alors

$$P(N = n) = (1 - p)^{n-1}p, \quad n = 1, 2, \dots$$

1) 2)

Binomiale(n,p)

On réalise une expérience de Bernoulli n fois de façon indépendante. On s'intéresse au nombre S de succès

$$P(S = k) = \binom{n}{k} p^k (1 - p)^{n-k} \quad \text{pour } k \in \{0, 1, 2, \dots, n\}.$$

(Démonstration dans le cours précédent)

Le support de la (distribution) Binomiale est fini : $\{0, 1, 2, \dots, n\}$.

1) Illustration de la Binomiale

2)

Poisson(λ)

(Siméon-Denis Poisson 1781 – 1840)

Exemples de phénomènes modélisables avec une distribution de Poisson :

- le nombre de voiture passant à un certain point d'une autoroute pendant une unité de temps.
- le nombre d'erreur d'orthographe par page
- le nombre d'appel téléphonique à une centrale d'appels.
- le nombre de fois qu'un server internet est visité par minute.
- le nombre de mutations d'une certaine séquence d'ADN après une certaine dose de radiation.
- le nombre de particules émises par un objet radioactif pendant une minute.
- le nombre de pins dans une forêt feuillus/épineux.
- le nombre de virus pouvant infecter une cellule.
- le nombre de rayon gamma sur un capteur pendant un interval de temps

Modélise la probabilité qu'un nombre X d'évènements aléatoires arrivent pendant une période de temps (ou d'espace) t d'un processus de Poisson :

- les évènements arrivent avec un taux constant λ ,
- les évènements sont indépendants de la date de l'évènement qui vient de se produire.

$$P(X = k) = \exp(-\lambda t) \frac{(\lambda t)^k}{k!}.$$

Contrairement à la Binomiale, le support de la Poisson n'est pas fini $\{0, 1, 2, \dots\}$.

1) Illustration du processus de Poisson et de la distribution Poisson

2) (Série de Taylor : $\exp(x) = \sum_{i=0}^{\infty} \frac{x^i}{i!}$)

Approximation de la distribution Binomiale par la distribution de Poisson

La loi des évènements rares : Soit $S_n \sim \text{Binomiale}(n, p_n)$. Si $p_n \rightarrow 0$ et $\lambda_n = np_n \rightarrow \lambda$ quand $n \rightarrow \infty$, alors

$$P(S_n = k) \rightarrow \exp(-\lambda) \frac{\lambda^k}{k!}.$$

En d'autres termes, si un grand nombre d'évènements indépendants a une faible probabilité individuelle de succès, alors le nombre total de succès a approximativement une distribution de Poisson.

Démonstration :

$$P(S_n = 0) = (1 - p_n)^n = \left(1 - \frac{\lambda_n}{n}\right)^n \rightarrow \exp(-\lambda)$$


car $\lambda_n \rightarrow \lambda$ quand $n \rightarrow \infty$.

$$\begin{aligned} P(S_n = k) &= C_{n,k} \left(\frac{\lambda_n}{n}\right)^k \left(1 - \frac{\lambda_n}{n}\right)^{n-k} \\ &= \frac{n(n-1)\cdots(n-k+1)}{n^k} \frac{\lambda_n^k}{k!} \left(1 - \frac{\lambda_n}{n}\right)^n \left(1 - \frac{\lambda_n}{n}\right)^{-k} \\ &\rightarrow \end{aligned}$$

□

Illustration de la convergence

Application : Chaque pixel de cette image reflète un comptage de rayon gamma pendant une unité de temps pour une région de l'univers.



Application : On jette deux dés 12 fois et s'intéresse à $D =$ le nombre de fois où un double Six apparaît.

On connaît la distribution exacte de D n'est-ce pas ?

- Que vaut $P(D = k)$ quand $k = 0$?

L'approximation par la distribution de Poisson donne :

$$P(D = 0) \approx \exp(-1/3) = 0.7165.$$

• Que vaut $P(D = k)$ quand $k = 2$? L'approximation par la distribution de Poisson donne :

$$P(D = 2) \approx \exp(-1/3) \left(\frac{1}{3}\right)^2 \frac{1}{2!} = 0.0398$$

Application : Les compagnies aériennes pratiquent l'overbooking. Supposons qu'elles vendent 200 tickets pour 198 places et que la probabilité qu'un passager ne se présente pas est de 1%. En utilisant l'approximation de Poisson, quelle est la probabilité qu'il y a une place pour toutes les personnes qui se sont présentées.

Soit S le nombre total de passagers qui ne se présentent pas. On s'intéresse à $P(S \geq 2) = 1 - (P(S = 0) + P(S = 1))$. Or $S \sim \text{Bin}(n, p)$, où $n = 200$ est grand et $p = 0.01$ est petit. On peut donc utiliser l'approximation Poisson(λ) avec $\lambda = np = 2$ et


$$\begin{aligned} P(S \geq 2) &\approx 1 - \exp(-2) - \exp(-2)2^1/1! \\ &= 1 - 3\exp(-2). \end{aligned}$$

3. Distributions continues

Une v.a. X a une distribution continue avec **fonction de densité** $f(x)$ si pour tout a et b :

$$P(a \leq X \leq b) = \int_a^b f(x)dx.$$

Géométriquement, $P(a \leq X \leq b)$ est l'aire sous la courbe f entre a et b .



La fonction de densité $f(x)$ en x joue le rôle de $P(X = x)$ même si $P(X = x) = 0$ pour une distribution continue. En effet :

$$P(x \leq X \leq X + \Delta x) = \int_x^{x+\Delta x} f(y)dy \approx f(x)\Delta x$$

quand Δx est petit. Donc quand $\Delta x \rightarrow 0$, $P(x \leq X \leq X + \Delta x) \rightarrow P(X = x) = 0$.

Par contre $f(x)$ renseigne sur la vraisemblance de trouver X proche de x .

Définition Toute fonction f telle que

1. $f(x) \geq 0$ pour tout x

2. $\int_{-\infty}^{+\infty} f(x)dx = 1$

est une fonction de densité.

Définition Toute variable aléatoire (discrète, continue ou mixte) a une fonction de répartition

$$F(x) = P(X \leq x).$$

Si X a une fonction de densité f , alors

$$F(x) = P(-\infty < X \leq x) = \int_{-\infty}^x f(y)dy.$$

Donc F est la primitive de f telle que $F(+\infty) = 1$.

Pac conséquent $F'(x) = f(x)$. Donc F est une fonction non-décroissante.

Utilité de la fonction de répartition F

De nombreuses tables et softwares donnent $F(x)$ pour des valeurs de x :

Table

Caclulateur

Dans R : ppois, punif, pnorm, pchisq, ...

De plus $\{X \leq b\} = \{X \leq a\} \cup \{a < X \leq b\}$, et les deux ensembles sont disjoints donc

$$P(X \leq b) = P(X \leq a) + P(a < X \leq b).$$

Connaitre F suffit pour calculer

$$P(a < X \leq b) = F(b) - F(a).$$

Uniform $U(a, b)$ Une distribution dont la densité est constante sur un intervalle borné (a, b) :

$$f(x) = \begin{cases} \frac{1}{b-a} & a < x < b \\ 0 & \text{sinon} \end{cases} .$$

- 1) Graphe de la densité ?
- 2) La constante $c = \frac{1}{b-a}$ satisfait la condition d'une densité que $\int_a^b c \, dx = 1$.
- 3) Fonction de répartition F et son graphe.

Exponential $\text{Exp}(\lambda)$

$$f(x) = \begin{cases} \lambda \exp(-\lambda x) & x \geq 0 \\ 0 & \text{sinon} \end{cases} .$$

Cette distribution est souvent utilisée pour modéliser le temps d'attente entre des évènements, par exemple le temps entre l'arrivée de deux clients successifs dans une banque.

- 1)
- 2)
- 3)

La distribution Gaussienne/Normale standard : $N(0, 1)$

$$f(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right).$$

1) 2) Soit $I = \int \exp\left(-\frac{1}{2}x^2\right)dx$. Donc

$$I^2 = \int \exp\left(-\frac{1}{2}x^2\right)dx \int \exp\left(-\frac{1}{2}y^2\right)dy = \iint \exp\left(-\frac{1}{2}(x^2 + y^2)\right) dx dy.$$

En changeant de variables et en passant en coordonnées polaires

$$\begin{cases} x = r \cos \theta \\ y = r \sin \theta \end{cases},$$

qui est une bijection de $(x, y) \in (-\infty, \infty) \times (-\infty, \infty)$ dans $(r, \theta) \in (0, \infty) \times [0, 2\pi]$

alors

$$\begin{vmatrix} \frac{\partial x}{\partial r} & \frac{\partial x}{\partial \theta} \\ \frac{\partial y}{\partial r} & \frac{\partial y}{\partial \theta} \end{vmatrix} = r,$$

donc

$$I^2 = \int_0^\infty \int_0^{2\pi} \exp\left(-\frac{1}{2}r^2\right) r \, d\theta \, dr. \quad \square$$

3)

4. Fonctions d'une variable aléatoire

Motivation : Supposons que $X \sim N(0, 1)$.

- Quelle est la distribution de $Y = \mu + \sigma X$, où $\sigma > 0$?

$$P(Y \leq y) = P(\mu + \sigma X \leq y) = P(X \leq (y - \mu)/\sigma) = ?$$

On appelle cette distribution la $N(\mu, \sigma^2)$.

- Quelle est la distribution de $Y = X^2$?

$$P(Y \leq y) = P(X^2 \leq y) = P(|X| \leq \sqrt{y}) = P(-\sqrt{y} \leq X \leq \sqrt{y}) = ?,$$

d'où on dérive la fonction de densité. On appelle cette distribution la χ_1^2 (la distribution chi-deux à 1 degré de liberté).

Théorème : Supposons que X a une fonction de densité f définie sur (a, b) , que $r : (a, b) \rightarrow (\alpha, \beta)$ est continue et strictement croissante, et que $s : (\alpha, \beta) \rightarrow (a, b)$ est la fonction inverse de r ($s = r^{-1}$). Alors $Y = r(X)$ a pour densité

$$g(y) = f(s(y)) s'(y) \quad y \in (\alpha, \beta).$$

Ce théorème s'applique-t-il aux deux exemples précédents ?

Suppose que X a une fonction de répartition F strictement croissante. Quelle est la distribution de $Y = F(X)$?

Inversement si $U \sim U(0, 1)$, quelle est la distribution de $Y = F^{-1}(U)$?