

Course outline

- 1 Introduction
- 2 L'incertitude
- 3 Qu'est-ce qu'une probabilité ?
- 4 Probabilité conditionnelle et indépendance stochastique
- 5 Variable aléatoire et loi de probabilité : le cas univarié
- 6 Variable aléatoire et loi de probabilité : le cas bivarié
- 7 Simulations
- 8 Quelques remarques importantes pour finir...

1 Introduction

2 **L'incertitude**

3 Qu'est-ce qu'une probabilité ?

4 Probabilité conditionnelle et indépendance stochastique

5 Variable aléatoire et loi de probabilité : le cas univarié

6 Variable aléatoire et loi de probabilité : le cas bivarié

7 Simulations

8 Quelques remarques importantes pour finir...

Incertitude, modélisation et statistique appliquée

Lindley (2006)

"Uncertainty is everywhere and you cannot escape from it."

- Quand le modélisateur-statisticien cherche à décrire, expliquer et/ou prédire un système biologique ou physique complexe, son **incertitude** peut être importante
 - ▶ Données de terrain et/ou expérimentales **peu nombreuses** et/ou **peu informatives**
 - ▶ **Fluctuations non contrôlables** du système étudié en l'état de connaissances actuelles
 - ▶ Incertitude sur certaines quantités inconnues **non observables**
- Encore **trop souvent négligée ou mal prise en compte** par le scientifique
 - ▶ ⇒ Estimations et/ou prédictions potentiellement fausses !
- **Prendre en compte "proprement" l'incertitude** dans l'analyse d'un système aléatoire
 - ▶ ⇒ Peut conduire à des estimations et/ou prédictions approximativement correctes !

L'incertitude est partout ! (1/3)



Lancer d'un dé... Alea Jacta est !

- Quelle face s'affichera au terme du lancer d'un dé ?
- Lancers consécutifs \Rightarrow **Résultats différents régis par le hasard...**
 - ▶ Exemple : 10 lancers \Rightarrow 2 4 3 6 1 6 1 3 5 1



Mesurer le diamètre d'une pastèque

- Plusieurs mesures de la même pastèque \Rightarrow **Résultats différents** (qualité de l'appareil de mesure, rigueur des observateurs)
- Plusieurs mesures de pastèques issues d'un même champ \Rightarrow **Résultats différents** (variabilité du diamètre)



Temps mis pour se rendre à son travail le matin

- 5 jours consécutifs la semaine dernière \Rightarrow **Résultats différents**
 - ▶ 22 min, 35 min, 21 min, 30 min, 25 min
- **Aléa** lié par exemple à l'occurrence ou non d'embouteillages, d'incidents de voyageurs, de grèves,...

L'incertitude est partout ! (2/3)



Nombre de chromosomes dicentriques dans 1 cellule irradiée à 1 Gray

- Plusieurs mesures pour une même cellule ⇒ **Résultats différents** (rigueur des observateurs)
- Plusieurs mesures de cellules irradiées à la même dose de 1 Gray ⇒ **Résultats différents** (variabilité biologique et physique)




Collecter l'âge au décès de 100 mineurs d'uranium (décédés)

- **Variabilité inter-individuelle** de l'âge au décès : styles de vie différents, différentes expositions professionnelles, environnementales, médicales aux rayonnements ionisants et autres pathogènes, prédispositions familiales, ...

Notions d'aléa et d'expérience aléatoire

Qu'appelle-t-on "aléa" ?

Aléa vient du latin *alea* qui signifie "jeu de dés". Il peut être vu comme **la cause de la part imprévisible** des résultats d'une expérience qui, même dans des conditions expérimentales supposées identiques, peut donner lieu à des résultats différents



Expérience aléatoire

Expérience plus ou moins complexe :

- dont on ne peut prévoir par avance le résultat \Rightarrow Résultat **incertain**
- qui peut être **répétée indéfiniment**

Notions d'expérience aléatoire et d'événements (1/2)

Univers des possibles

Ensemble (fini, infini dénombrable, infini non dénombrable) de tous les résultats possibles d'une expérience aléatoire (généralement noté Ω)

Ex.	Expérience aléatoire	Ω
1	Jet d'un dé	$\{1, 2, 3, 4, 5, 6\}$
2	Comptage du nombre de chromosomes dicentriques dans 500 cellules irradiées à 1 Gray	\mathbb{N}
3	Mesure du diamètre d'une pastèque	\mathbb{R}^+
4	Temps de trajet maison-travail	\mathbb{R}^+

Notions d'expérience aléatoire et d'événements (2/2)

Événement aléatoire

Assertion ou proposition logique relative au résultat d'une expérience aléatoire. On lui associe tous les résultats (sous-ensemble de Ω) de l'épreuve pour lesquels il est réalisé :

- Événement certain : Ω / Événement impossible : \emptyset
- Événement simple (ou élémentaire)

Ex.	Un événement aléatoire	Un événement impossible
1	Obtenir 2	Obtenir 13
2	Aucun chromosome dicentrique	Nombre négatif de dicentriques
3	Diamètre supérieur à 40 cm	Diamètre négatif
4	Temps de trajet compris entre 5 et 10 minutes	Temps de trajet nul

⇒ Un événement aléatoire est un **événement incertain**

1 Introduction

2 L'incertitude

3 **Qu'est-ce qu'une probabilité ?**

4 Probabilité conditionnelle et indépendance stochastique

5 Variable aléatoire et loi de probabilité : le cas univarié

6 Variable aléatoire et loi de probabilité : le cas bivarié

7 Simulations

8 Quelques remarques importantes pour finir...

Définition axiomatique de Kolmogorov

Soit un univers Ω définissant un ensemble fini d'événements élémentaires possibles, notés $\{\omega_1, \dots, \omega_n\}$, et \mathcal{C} la tribu associée (cf. chapitre 1 page 12).

Axiomatique

Une probabilité \mathbb{P} sur (Ω, \mathcal{C}) est **une fonction** telle que :

- **Axiome 1** : A tout événement A de \mathcal{C} est assigné un nombre réel $\mathbb{P}(A)$ tel que $0 \leq \mathbb{P}(A) \leq 1$;
- **Axiome 2** : La probabilité de l'événement certain Ω est donnée par : $\mathbb{P}(\Omega) = \sum_{i=1}^n \mathbb{P}(\omega_i) = 1$;
- **Axiome 3** (dit règle d'additivité) : toute suite d'événements A_1, A_2, \dots, A_n deux à deux **disjoints** satisfait :

$$\mathbb{P}(A_1 \cup A_2 \cup \dots \cup A_n) = \sum_{i=1}^n \mathbb{P}(A_i). \quad (1)$$

Définitions opérationnelles de la probabilité : la vision "objective"

Etant donné un jeu d'hypothèses fixées par le modélisateur, la probabilité d'un événement est déterminée **de manière unique**

La vision classique (héritée des jeux de hasard)

- Hypothèse : Ω est **fini** + tous les résultats élémentaires sont équiprobables
- Le calcul des probabilités n'est qu'une affaire de dénombrement !
- Probabilité d'un événement A : $P(A) = \frac{\text{Nombre de résultats favorables}}{\text{Nombre de résultats possibles}}$

La vision fréquentiste

- Ω est **fini, infini dénombrable ou continu**
- Idée : Répéter une expérience aléatoire à l'infini !
- Probabilité $\mathbb{P}(A)$ d'un événement A : **limite de la fréquence d'occurrence** de A quand le nombre d'expériences n est très grand
- Exemple (Jet de dé ; A ="Obtenir un nombre pair") :
3 5 6 2 3 4 3 2 2 6 5 2 6 3 1 2 1 3 3 6 (20 tirages successifs)

$$P_{20}(A) = \frac{5 + 1 + 4}{20} = 0.5$$

Définitions opérationnelles de la probabilité : la vision "subjective"

Quel degré de confiance - entre 0 et 1- accorderiez-vous à l'événement :

- E : "Le Portugal a une superficie inférieure ou égale à 80000 km²" ?

Événement incertain non répétable ! ⇒ Deuxième conception opérationnelle

La probabilité "subjective"

- Permet de quantifier **le degré de confiance** d'une personne, basée sur ses connaissances et son opinion, en la réalisation de n'importe quel événement incertain ⇒ **Pas d'unicité !**
- Obéit aux **axiomes de Kolmogorov** : rationalité !
- Peut **varier** d'une personne à l'autre et dans le temps en fonction des connaissances
- Liée à la notion de **pari** : Combien un individu rationnel est prêt à parier pour qu'un événement incertain d'intérêt se réalise ?
- **Concept clé de la statistique bayésienne** : on peut probabiliser des événements non répétables et tout ce qui est incertain !

La probabilité conditionnelle par l'exemple



- Événement A : "Ce mineur d'uranium est décédé d'un cancer du poumon"
- Q1 : Quelle est la probabilité de l'événement incertain A ?

- Événement B : "Ce mineur d'uranium était fumeur"
- Q2 : Quelle est la probabilité de l'événement incertain A (sachant B) ?

L'information complémentaire apportée par l'événement B a sans doute permis d'augmenter le degré de vraisemblance de l'événement A !

⇒ Concept de probabilité conditionnelle

Exemple : Cancer du poumon/Fumeur

Table de contingence : table des probabilités jointes (et marginales)

	Cancer du poumon	Pas cancer du poumon	Total ₂
Fumeur	0.012	0.238	0.250
Non Fumeur	0.007	0.743	0.750
Total ₁	0.019	0.981	1

- Probabilité de l'événement A : "Cancer du poumon" : $P(A) = 0.019$
- Probabilité de l'événement B : "Fumeur" : $P(B) = 0.250$
- Calculer $\mathbb{P}(A|B)$

$$\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} = \frac{0.012}{0.250} = 0.048$$

La clé de voûte de la statistique bayésienne : la formule de Bayes

Soient deux événements A et B tels que $\mathbb{P}(A) > 0$. $\mathbb{P}(A|B)$ et $\mathbb{P}(B|A)$ sont reliées par :

$$\mathbb{P}(B|A) = \frac{\mathbb{P}(A|B)\mathbb{P}(B)}{\mathbb{P}(A)}$$

Interprétation bayésienne : *Formule d'inversion des causes*


- Mécanisme d'inversion de relations de conditionnement probabiliste
- Evaluer la probabilité de $B|A$ avec B **la cause** et A **l'effet** quand on connaît la probabilité de $A|B$ et les probabilités marginales de A et B.

Exemple : Cancer du poumon/Fumeur

Calculer la probabilité de l'événement B (Cause : "Fumeur") sachant l'événement A (Effet : "Cancer du poumon")

$$\mathbb{P}(B|A) = \frac{0.048 \times 0.250}{0.019} = \frac{0.012}{0.019} = 0.63$$

La formule des probabilités totales



Soient A_1, A_2, \dots, A_n une partition de l'univers des possibles Ω .
Alors, pour tout événement incertain $E \in \Omega$:

$$\mathbb{P}(E) = \sum_{i=1}^n \mathbb{P}(E \cap A_i) = \sum_{i=1}^n \mathbb{P}(E|A_i)\mathbb{P}(A_i)$$

⇒ Autre expression de la formule de Bayes

$$\mathbb{P}(A_j|E) = \frac{\mathbb{P}(E|A_j)\mathbb{P}(A_j)}{\sum_{i=1}^n \mathbb{P}(E|A_i)\mathbb{P}(A_i)}$$

Exemple : Cancer du poumon/Fumeur

- {"Fumeur", "Non fumeur"} = Partition de Ω

$$\mathbb{P}(A) = \mathbb{P}(A|B)\mathbb{P}(B) + \mathbb{P}(A|C)\mathbb{P}(C) = 0.048 \times 0.250 + 0.009 \times 0.750 = 0.019$$

Notion d'indépendance stochastique

Definition

Deux événements A et B sont indépendants si $\mathbb{P}(A|B) = \mathbb{P}(A)$

- Le fait de savoir que B est réalisé n'apporte aucune information sur A

Propriétés (Généralisables à n événements!)

- A indépendant de $B \iff B$ indépendant de A
- A et B indépendants $\iff \mathbb{P}(A \cap B) = \mathbb{P}(A) \times \mathbb{P}(B)$
- Le modélisateur **suppose** souvent l'indépendance (conditionnelle) des événements qu'il cherche à décrire ou prédire...

Pour quantifier la probabilité conjointe de deux (ou plus de deux) événements, on ne peut multiplier leur probabilité respective qu'après s'être assuré de l'indépendance de ces événements!

La formule des probabilités composées

Que faire quand on souhaite quantifier la probabilité conjointe de deux (ou plus de deux) événements non indépendants stochastiquement ?

Formule des probabilités composées (Pour 2 événements)

Soient A_1 et A_2 deux événements tels que $P(A_1 \cap A_2) \neq 0$. Alors :

$$\mathbb{P}(A_1 \cap A_2) = \mathbb{P}(A_1)\mathbb{P}(A_2|A_1)$$

Formule généralisable à n événements de probabilité jointe non nulle.

Exemple : Cancer du poumon/Fumeur

$$\begin{aligned} & \mathbb{P}(\text{"Fumeur"} \cap \text{"Cancer poumon"}) \\ &= \mathbb{P}(\text{"Fumeur"} | \text{"Cancer poumon"})\mathbb{P}(\text{"Cancer du poumon"}) \\ &= 0.63 \times 0.019 = 0.012 \end{aligned}$$

Attention : Dépendance stochastique ne veut pas dire causalité !

Exemple


Dépendance entre la peinture des enfants et leur niveau de langage mais pas de causalité ! Une troisième variable sous-jacente (appelée facteur de confusion) explique cette dépendance probabiliste : l'âge

Qu'est-ce qu'une variable aléatoire (v.a) ?

- Grandeur mathématique prenant différents états ou valeurs de **manière imprévisible** mais avec une certaine **régularité d'occurrence**
- La régularité en question est décrite à travers une **loi (ou distribution) de probabilité**.
- Ingrédient de base de tout modèle probabiliste
- **Application** assignant à chaque résultat élémentaire d'une expérience aléatoire une valeur, un état ou un intervalle de valeurs avec une certaine probabilité

x_i est la réalisation de la v.a. X pour l'événement élémentaire ω_i (seulement) :

$$\mathbb{P}(X = x_i) = \mathbb{P}(\{\omega \in \Omega | X(\omega) = x_i\}) = p_i$$



Exemple : Variables aléatoires catégorielles ordonnées

Variables discrètes prenant un **nombre fini d'états possibles naturellement ordonnés** (mais non associés à un nombre)

Le choix d'une cuisson de viande rouge : cru/saignant/rosé/bien cuit

v.a. : Choix de cuisson du steak haché dans la population française

> Cru :	0.05
> Saignant :	0.10
> Rosé :	0.37
> Bien cuit :	0.28
> Ne mange pas de steak haché :	0.20





(1) recenser les états élémentaires exclusifs possibles

(2) affecter une probabilité à chaque état (valeur comprise entre 0 et 1)

(3) S'assurer que la somme totale des probabilités affectées soit égale à 1!

Loi de probabilité de la v.a. choix d'une cuisson de viande rouge



Notions d'espérance et de variance : cas d'une v.a. discrète valuée

- Espérance mathématique de X : $\mathbb{E}(X) = \mu = \sum_{i=1}^n x_i p_i$
- Variance de X : $\text{Var}(X) = \sum_{i=1}^n (x_i - \mu)^2 p_i$
- Ecart-type de X : $\sigma = \sqrt{\text{Var}(X)}$

Propriétés utiles

- $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$
- $\mathbb{E}(aX + b) = a\mathbb{E}(X) + b$ (a et b constantes)
- $\text{Var}(aX + b) = a^2 \text{Var}(X)$ (a et b constantes)




Quelques lois de probabilité discrètes(1/2)

	Support	PMF ^(a)	Param	E ^(b)	Var ^(c)
Bernoulli	$\{0, 1\}$	$P(X = 1) = p$	$p \in [0, 1]$	p	$p(1-p)$
Binomial	$k \in \{0, \dots, n\}$	$\frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}$	$n \in \mathbb{N}, p \in [0, 1]$	np	$np(1-p)$
Poisson	$k \in \mathbb{N}$	$e^{-\lambda} \frac{\lambda^k}{k!}$	$\lambda \in]0, +\infty[$	λ	λ
Geometric	$k \in \mathbb{N}^*$	$(1-p)^{k-1} p$	$p \in [0, 1]$	$\frac{1}{p}$	$\frac{1-p}{p^2}$

- (a) -> Loi de probabilité (PMF); (b) -> Espérance; (c) -> Variance

Quel contexte d'utilisation ?

Quelques lois de probabilité discrètes (2/2)



Variables aléatoires continues

Variables prenant une **infinité non dénombrable de valeurs possibles**
(e.g., toutes les valeurs dans un intervalle borné ou non de \mathbb{R})

- Le log₁₀ de la concentration initiale en *Escherichia Coli* dans un steak surgelé
- La température minimale de croissance d'une bactérie
- La dose cumulée annuelle de gaz radon inhalée par un mineur d'uranium dans le cadre de son activité professionnelle
- La taille d'un individu

Comment leur assigner une loi de probabilité ? (1/3)

Une montre tombe en panne. La position exacte de la grande aiguille au moment de l'arrêt est une variable aléatoire X continue. Les positions possibles sont l'ensemble des angles entre 0° et 360° . Il y a un nombre infini non dénombrable de possibilités et on veut leur attribuer une probabilité.



Comment spécifier la loi de probabilité de X ?



Une solution possible: Au lieu d'attribuer à chaque valeur possible une probabilité, une probabilité est associée à **chaque intervalle de valeurs!**

Exemple: Pour tous réels a et b compris entre 0 et 360

$$P(a \leq X \leq b) = \frac{b - a}{360}$$

Comment leur assigner une loi de probabilité ? (2/3)

☛ Via la spécification de la fonction de répartition

v.a. **X**: Position exacte de la grande aiguille d'une montre à l'arrêt

$$F(x) = P(X \leq x) = \frac{x}{360}$$

(1) Associer une **probabilité $F(x)$** d'être inférieur ou égal à x à chaque réel x

↔ Spécifier la fonction de répartition de X :

(fonction **croissante continue** à valeurs dans $[0, 1]$ tel que la limite en $-\infty$ est 0 et en $+\infty$ est 1)

Comment leur assigner une loi de probabilité ? (3/3)

Via la spécification de la densité de probabilité

v.a. **X** : Position exacte de la grande aiguille d'une montre à l'arrêt

Entre 0 et 360 degrés

$$f(x) = \frac{1}{360}$$

(1) définir un support de valeurs possibles

(2) Associer une **densité de probabilité** $f(x)$ à chaque point x du support.
 (fonction positive dont l'aire sous la courbe est égale à 1)

Densité de probabilité et fonction de répartition sont deux fonctions permettant de **caractériser** la loi de probabilité d'une v.a. continue X .

Notions d'espérance et de variance : cas d'une v.a. continue

Espérance mathématique: Soit X une v.a. continue prenant ses valeurs sur un intervalle réel D , son espérance (si elle existe) est le nombre:

$$E(X) = \mu = \int_D x \cdot f(x) dx$$

Somme \rightarrow Intégrale

Coefficients de pondération

Variance et écart-type: Soit X une v.a. continue prenant ses valeurs sur un intervalle réel D , sa variance (si elle existe) est le nombre:

$$Var(X) = \sigma^2 = \int_D (x - \mu)^2 \cdot f(x) dx$$


$$\sigma = \sqrt{Var(X)}$$

Quelques propriétés utiles:

- $Var(X) = E(X^2) - E(X)^2$
- $E(aX+b) = aE(X)+b$ (a et b constantes)
- $Var(aX+b) = a^2Var(X)$ (a et b constantes)

Caractéristiques d'une densité de probabilité (1/3)

Cas d'une densité de probabilité **symétrique**




Caractéristiques d'une densité de probabilité (2/3)

Le α quantile (on parle aussi de percentile) d'une loi de probabilité est la valeur q_α telle que la probabilité qu'une v.a. X suivant cette distribution lui soit inférieure ou égale est égale à α .


$$P(X \leq q_\alpha) = \alpha$$

Représentation graphique des quantiles / percentiles à **10-30-70-90 %** à partir d'une densité de probabilité (a) et d'une fonction de répartition (b)

(a) Densité de probabilité de la V.A. taille d'un individu



(b) Fonction de répartition de la V.A. taille d'un individu




Caractéristiques d'une densité de probabilité (3/3)

- **Médiane=Quantile 50%** $P(X \leq q_{0.5}) = P(X \geq q_{0.5}) = 0.5$



Ne pas confondre espérance et médiane!


Exemple: Cas **dissymétrique** vers la droite: **espérance > médiane**



Deux écueils à éviter

- Dans le cas d'une v.a. continue X :
 - On ne sait pas attribuer une probabilité à une valeur x donnée
 - La densité de probabilité en un point n ' est pas nécessairement comprise entre 0 et 1 (c'est une dérivée!)

Densité de probabilité d'une v.a. normale
d'espérance 0 et d'écart-type 0.1



Quelques densités de probabilité continues (1/3)

	Support	PDF ^(a)	Param	E ^(b)	Var ^(c)
Normal	$x \in \mathbb{R}$	$\frac{1}{\sigma\sqrt{2\pi}} \exp^{-\frac{(x-\mu)^2}{2\sigma^2}}$	$\mu \in \mathbb{R}, \sigma > 0$	μ	σ^2
Beta	$x \in [0, 1]$	$\frac{x^{\alpha-1}(1-x)^{\beta-1}}{B(\alpha,\beta)}$	$\alpha > 0, \beta > 0$	$\frac{\alpha}{\alpha+\beta}$	$\frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}$
Expo*	$x \in \mathbb{R}^+$	$\lambda \exp^{-\lambda x}$	$\lambda > 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$
Gamma	$x \in \mathbb{R}^+$	$\frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp^{-\beta x}$	$\alpha > 0, \beta > 0$	$\frac{\alpha}{\beta}$	$\frac{\alpha}{\beta^2}$
LogN**	$x \in \mathbb{R}^+$	$\frac{1}{x\sigma\sqrt{2\pi}} \exp^{-\frac{(\ln(x)-\mu)^2}{2\sigma^2}}$	$\mu \in \mathbb{R}, \sigma > 0$	$e^{\mu + \frac{\sigma^2}{2}}$	$(e^{\sigma^2} - 1)e^{(2\mu + \sigma^2)}$

Remarques :

- (a) -> Densité de probabilité ; (b) -> Espérance ; (c) -> Variance
- * -> Loi exponentielle ; ** -> Loi log-normale






Quel contexte d'utilisation ?

Quelques densités de probabilité continues (2/3)

- Si $X \sim \text{LogN}(\mu, \sigma^2)$ alors $\ln(X) \sim N(\mu, \sigma^2)$
 - ▶ Moyenne dite géométrique de la loi lognormale : e^μ
 - ▶ Ecart-type dit géométrique de la loi lognormale : e^σ

- Si $X \sim \text{Beta}(a, b)$
 - ▶ a peut s'interpréter comme un nombre de succès, b comme un nombre d'échecs et $a + b$ comme une taille virtuelle d'échantillon
 - Choisir $a=10$ et $b=5$ fournit un état de connaissance a priori équivalent à un échantillon virtuel de taille 15 comprenant $a=10$ succès
 - ▶ $Y = y_{\min} + (y_{\max} - y_{\min}) \times X$ suit une loi **beta généralisée** de paramètres a et b et de support donné par l'intervalle réel $[y_{\min}, y_{\max}]$

Quelques densités de probabilité continues (3/3)




- 1 Introduction
- 2 L'incertitude
- 3 Qu'est-ce qu'une probabilité ?
- 4 Probabilité conditionnelle et indépendance stochastique
- 5 Variable aléatoire et loi de probabilité : le cas univarié
- 6 Variable aléatoire et loi de probabilité : le cas bivarié**
- 7 Simulations
- 8 Quelques remarques importantes pour finir...

Variabes aléatoires vectorielles

- Une v.a. peut être **vectorielle** :
 - masse et taille d'un individu
 - masse et âge d'un individu
 - sexe, IMC, âge d'un individu
 - concentrations de différentes espèces de bactéries

Nuage de points (simulés) pour le couple de v.a. masse vs taille d'un individu



Cas bivarié discret : Loi de probabilité jointe (1/2)

Exemple : Cancer du poumon/Fumeur

Soit (X,Y) la paire de variables aléatoires ("Statut de la maladie", "Statut fumeur")

	Cancer du poumon	Pas de cancer du poumon
Fumeur	0.012	0.238
Non Fumeur	0.007	0.743

Comment définir la loi de probabilité jointe du couple (X,Y) ?

- 1 Recenser tous les couples d'états élémentaires exclusifs possibles
- 2 Affecter une probabilité à chaque couple d'états (valeur comprise entre 0 et 1)
- 3 S'assurer que la somme totale des probabilités affectées soit égale à 1 !

Cas bivarié discret : Loi de probabilité jointe (2/2)

Soit (X, Y) une paire de variables aléatoires discrètes

Loi de probabilité jointe

Fonction associant à chaque couple de valeurs possibles (x_i, y_j)
($i = 1, \dots, I, j = 1, \dots, J$) de (X, Y) sa probabilité :

$$p_{ij} = P(X = x_i \cap Y = y_j)$$

tel que $\sum_{i=1}^I \sum_{j=1}^J p_{ij} = 1$

Cas bivarié discret : : Lois de probabilité marginales (1/2)

Exemple : Cancer du poumon/Fumeur

Soit (X,Y) la paire de variables aléatoires ("Statut de la maladie", "Statut fumeur")
 Quelles sont les lois de probabilités marginales des v.a. X et Y ?

	Cancer poumon	Pas cancer poumon	Marginale Y
Fumeur	0.012	0.238	0.25
Non fumeur	0.007	0.743	0.75
Marginale X	0.019	0.981	1

Soit (X,Y) une paire de variables aléatoires discrètes

Loi de probabilité marginale de X

Fonction associant à tous les états/valeurs possibles x_i de X sa probabilité :

$$P(X = x_i) = \sum_{j=1}^J P(X = x_i \cap Y = y_j) \text{ (Loi des probabilités totales !)}$$

Même principe pour la loi marginale de Y

Cas bivarié discret : : Lois de probabilité marginales (2/2)

Attention ! Les lois marginales de X et Y ne suffisent pas à définir la loi jointe du couple (X,Y)

	Cancer poumon	Pas cancer poumon	Marginale Y
Fumeur	0.012 -0.01	0.238 +0.01	0.25
Non fumeur	0.007 +0.01	0.743 -0.01	0.75
Marginale X	0.019	0.981	1

... Sauf si on ajoute l'hypothèse d'indépendance : $p_{ij} = p_i p_j$!

Cas bivarié discret : : Lois de probabilité conditionnelles (2/2)

Exemple : Cancer du poumon/Fumeur

Soit (X,Y) la paire de variables aléatoires ("Statut de la maladie", "Statut fumeur")
Quelle est la loi de probabilité conditionnelle de Y sachant X ?

	Cancer du poumon	Pas cancer du poumon
Fumeur	0.63	0.24
Non fumeur	0.37	0.76
Total	1.0	1.0

Soit (X,Y) une paire de variables aléatoires discrètes

Loi conditionnelle de X sachant $Y = y_j$


Fonction associant à tous les états/valeurs possibles x_i de X sa probabilité :

$$P(X = x_i | Y = y_j) = \frac{P(X=x_i \cap Y=y_j)}{P(Y=y_j)}$$

Même principe pour la loi conditionnelle de Y sachant $X = x_i$

La loi multinomiale - une loi de probabilité discrète multivariée

Contexte d'utilisation : n expériences aléatoires indépendantes, m résultats possibles de probabilité p_i ($i \in 1, \dots, m$).



Support	$n_i \in \{0, \dots, n\}$ with $\sum_{i=1}^m n_i = n$
PMF ^(a)	$\frac{n!}{n_1! \dots n_m!} p_1^{n_1} \dots p_m^{n_m}$
Param	$n \in \mathbb{N}^*$, p_1, \dots, p_m with $\sum_{i=1}^m p_i = 1$
$E(N_i)^{(b)}$	np_i
$Var(N_i)^{(c)}$	$np_i(1 - p_i)$
$Cov(N_i, N_j)^{(d)}$	$-np_i p_j$ if $i \neq j$

- (a) -> Loi de probabilité jointe
- (b) -> Espérance ; (c) -> Variance
- (d) -> Covariance

Qu'en est-il dans le cas continu ? (2/2)

Plus formellement...

Fonction de répartition du couple (X,Y): Fonction associant à toutes les valeurs possibles (x, y) la probabilité:

$$F_{XY}(x, y) = P(X \leq x \cap Y \leq y)$$

Densité jointe du couple (X,Y) (si elle existe): $f_{XY}(x, y) = \frac{\partial^2 F_{XY}}{\partial x \partial y}$

Densité marginale de X: $f_X(x) = \int f_{XY}(x, y) dy$

Densité conditionnelle de Y sachant X=x₀:

$$g(y|x_0) = \frac{f_{XY}(x_0, y)}{f_X(x_0)}$$

⇒ Plus il y a de v.a., plus les intégrales à calculer sont complexes...

La loi normale multivariée

Support	$x \in R^n$
PDF ^(a)	$\frac{1}{(2\pi)^{n/2} \det(\Sigma)^{1/2}} e^{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)}$
Param	$\mu = (\mu_1, \dots, \mu_n) \in R^n, \Sigma$
$E^{(b)}$	μ
$Var^{(c)}$	Σ

- (a) -> Densité de probabilité jointe
- (b) -> Espérance ; (c) -> Variance
- Σ : $n \times n$ matrice de variance-covariance, semi-définie positive

- 1 Introduction
- 2 L'incertitude
- 3 Qu'est-ce qu'une probabilité ?
- 4 Probabilité conditionnelle et indépendance stochastique
- 5 Variable aléatoire et loi de probabilité : le cas univarié
- 6 Variable aléatoire et loi de probabilité : le cas bivarié
- 7 Simulations**
- 8 Quelques remarques importantes pour finir...

Avant d'assigner une loi de probabilité, à quoi faut-il réfléchir ?



- Au type (discrète/continu) de la grandeur d'intérêt
- Au support de valeurs possibles de la grandeur d'intérêt
- Aux valeurs centrales de la grandeur d'intérêt
- Aux valeurs les plus probables de la grandeur d'intérêt
- A la symétrie (ou pas) de la distribution
- A l'épaisseur des queues
- A une transformation préalable de la v.a.

Comment simuler des réalisations d'une variable aléatoire ? (1/2)

- La simulation de v.a. occupe **une place centrale** en **statistique bayésienne**
 - ▶ Le plus souvent, on cherche à simuler des réalisations de v.a. selon :
 - la **loi a posteriori** des paramètres d'un modèle probabiliste (cf. Eric et Samuel)
 - la **loi prédictive a posteriori** des grandeurs observables (cf. Eric, Samuel, David)
- Etre capable de simuler des réalisations d'une v.a.
 - ⇔ Connaître sa loi de probabilité

Comment simuler des réalisations d'une variable aléatoire ? (2/2)

- Générer des nombres aléatoires suppose d'être capable de générer une suite de nombres dont il est très difficile de dériver des **propriétés déterministes**
- ⇒ La plupart des logiciels de calculs modernes permettent de **générer des séquences de nombres dites pseudo-aléatoires**
 - ▶ Suite de nombres aléatoires "artificiels" obtenus, en pratique, à partir d'algorithmes récursifs ayant des propriétés déterministes

x_0 (état initial = graine)

$$x_{n+1} = w(x_n)$$







- ▶ La suite générée est périodique : l'objectif est d'obtenir la plus longue période !
- ▶ R, Python, SAS, Excel, ... possèdent leur propre générateur de nombres pseudo-aléatoires

Simuler sous R : quelques commandes

Categorical	<code>sample(x, size, replace, prob)</code>
Bernoulli(π)	<code>rbinom(n,size=1,prob=π)</code>
Binomial(N, π)	<code>rbinom(n,size=N,prob=π)</code>
Poisson(λ)	<code>rpois(n,lambda= λ)</code>
Geometric(π)	<code>rgeom(n,prob=π)</code>
Normal(μ, σ)	<code>rnorm(n, mean = μ, sd = σ)</code>
Uniform(a, b)	<code>runif(n,min=a, max=b)</code>
Beta(a, b)	<code>rbeta(n, shape1=a, shape2=b, ncp = 0)</code>
Expo(λ)	<code>rexp (n, rate=λ)</code>
Gamma(a, b)	<code>rgamma(n, shape=a, rate = b, scale = 1/rate)</code>
Multinomial	<code>rmultinom(n, size, prob)</code>

Exemple : La loi de Poisson


Combien de tirages aléatoires indépendants sont nécessaires pour "bien" représenter la loi de Poisson de paramètre $\lambda = 2$?



Qu'est-ce qu'un modèle probabiliste ?


- Représentation mathématiques **approchée mais utile** d'un système aléatoire (biologique, physique,...) étant donné un état de connaissances du (des) modélisateur(s) (cf. cours Eric et David)
- Représentation limitée à un certain contexte mais qui doit être **suffisamment flexible** pour s'adapter à différents scenarii
 - ▶ **Modèle paramétrique** : un ensemble fini de paramètres inconnus θ permettent de décrire le système d'intérêt. (Contexte de l'école)

Comment construire un modèle probabiliste ?



- Identifier les **variables aléatoires** dont on souhaite décrire les fluctuations
- Identifier les quantités fixes inconnues, appelées (**paramètres**) et les quantités supposées connues (**covariables, constantes**)
- Spécifier les **relations de conditionnement** entre les variables aléatoires et les paramètres
- Proposer des **lois de probabilité** pour quantifier ces relations
 - ▶ Exemple : **Le modèle d'observations** décrit les **fluctuations des variables aléatoires observables Y** sachant les paramètres θ et les covariables X

Ne pas confondre modélisation probabiliste et inférence statistique !




MODELISATION PROBABILISTE N'IMPLIQUE PAS DONNÉES !

Si les paramètres θ sont connus, le modèle probabiliste \mathcal{P}_θ permet de **simuler des réalisations "plausibles"** $y_n=(y_1, \dots, y_n)$ de la v.a Y (appelée "**variable réponse**").

- **(Forward) Propagation d'incertitude** : Quantifier/décrire l'incertitude sur les variables réponse du modèle en propageant notamment l'incertitude inhérente aux paramètres d'entrée du modèle
- Simulations Monte-Carlo, prédictions, ...

Ne pas confondre modélisation probabiliste et inférence statistique !



INFERENCE STATISTIQUE IMPLIQUE DONNEES

⇒ Des réalisations $y_n=(y_1, \dots, y_n)$ de la v.a. Y **sont observées** (échantillon de données).

Principal objectif : Proposer des valeurs "possibles" et quantifier l'incertitude d'estimation associée pour les paramètres inconnus θ (les causes) étant donné les données observées (conséquences) $y_n=(y_1, \dots, y_n)$ of Y

- **(Backward) Inverse uncertainty quantification** => Démarche inverse par rapport à la modélisation et la simulation
- Estimation



Peut-on réellement définir un modèle physique qui permette de **prédire exactement** quelle face de ce dé non pipé apparaîtra après un lancer, étant donné les conditions expérimentales initiales ?



Peut-on réellement définir un modèle physique qui permette de **prédire exactement** quelle face de ce dé non pipé apparaîtra après un lancer, étant donné les conditions expérimentales initiales ?

Quand le mécanisme physique sous-jacent est trop complexe...

Variabilité naturelle : une première "interprétation" de l'incertitude

- Incertitude **inévitable** et inhérente à de nombreux systèmes biologiques, physiques, environnementaux,...
- Dûe à des **fluctuations incontrôlables (aléa !)** du système et de son environnement, en l'état actuel des connaissances
- Aussi appelée "Incertitude par essence", "Incertitude aléatoire" ou "Incertitude stochastique"
- ⇒ **Incertitude irréductible** d'une grandeur (observable ou non)

Exemples

- **Erreur de mesure** (ubiquitaire en science observationnelle comme l'épidémiologie) peut être interprétée comme de la variabilité (due à un manque de précision de l'appareil de mesure, à la variabilité de rigueur des observateurs. . .)
- N'importe quelle **grandeur de terrain ou expérimentale** est généralement sujette à variabilité

