

**Master IAD**  
**Module MI009 – RFIDEC**  
**Transparents de cours**

**année 2012–2013**

*Christophe Gonzales*



# RFIDEC — cours 1 : Rappels de probas/stats (1/3)

Christophe Gonzales

LIP6 – Université Paris 6, France

## Modalités de contrôle

- Pas de contrôle continu
- Note finale d'UE en trois parties :
  - 1 Examen écrit en milieu de semestre (35%)
  - 2 Examen écrit en fin de semestre (35%)
  - 3 Contrôle sur machine (30%)


## Introduction à la reconnaissance des formes

### *Reconnaissance des formes*

Algorithmes  $\implies$  reconnaissance automatique de régularités,  
de motifs dans un amas de données.


Utilisation de ces motifs pour des tâches (classification, etc)

*Exemple :*



*Image* = données (pixels)    *Classification* = reconnaître le chiffre

## Exemple : problème d'ajustement (1/5)



### Observations

$(x_1, t_1)$

$\vdots$

$(x_{10}, t_{10})$

$\Rightarrow$  courbe  $\sin(2\pi x) \Rightarrow$  estimation de  $t_{11}$

$\Rightarrow$  reconnaissance de la courbe verte

## Exemple : problème d'ajustement (2/5)

**Idée :** estimer la courbe verte par un polynôme :

$$y(x, \mathbf{w}) = w_0 + w_1x + w_2x^2 + \dots + w_Mx^M = \sum_{j=0}^M w_jx^j$$

$\Rightarrow$  **Problèmes :**

- déterminer les « meilleurs » coefficients  $w_j$
- déterminer la « meilleure » valeur de  $M$

« meilleur »  $\Rightarrow$  critère d'optimalité


*critère d'optimalité possible*

Minimiser une **fonction d'erreur** mesurant l'inadéquation entre la courbe  $y(x, \mathbf{w})$  et les points observés :

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^{10} [y(x_i, \mathbf{w}) - t_i]^2$$

## Exemple : problème d'ajustement (3/5)

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^{10} [y(x_i, \mathbf{w}) - t_i]^2$$



## Exemple : problème d'ajustement (4/5)

**Problème 1 :**  $\mathbf{w}^*$  tel que  $\mathbf{w}^* = \min_{\mathbf{w}} E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^{10} [y(x_i, \mathbf{w}) - t_i]^2$


$E(\mathbf{w})$  fonction quadratique en  $\mathbf{w} \implies$  1 seule solution

$$\implies \frac{dE(\mathbf{w})}{d\mathbf{w}} = 0$$

$\implies$  résoudre un système linéaire

**Problème 2 :** Choix de  $M \implies$  sélection de modèle

## Exemple : problème d'ajustement (5/5)



## Plan général du cours

- 1 Introduction et rappels de proba/stat
- 2 Estimations ponctuelles à partir d'échantillons
- 3 Intervalles de confiance, tests d'hypothèses
- 4 Tests d'ajustement et maximum de vraisemblance
- 5 MAP et apprentissage non paramétrique
- 6 Régression linéaire
- 7 Clustering (K-means, Kohonen)
- 8 Classification bayésienne
- 9 Classification gaussienne
- 10 Classifieur linéaire : LDA, perceptron

- ① Introduction à la statistique descriptive
- ② vocabulaire de stat descriptive
- ③ distributions et représentations
- ④ indicateurs de « moyenne »
- ⑤ indicateurs de dispersion

## Intro à la statistique descriptive

### Statistique

- recueil de données
- traitement de ces données
- l'exploitation (interprétation, prévision, etc) sort du cadre de la stat descriptive

### Principe de la statistique descriptive

- des amas de données
- stat descriptive  $\implies$  synthèse, résumé d'informations

données synthétiques  $\implies$  exploitation



pas forcément besoin de probabilités

## Exemple

Salaires de cadres masculins (exprimés en k€)


18	10	12	12	10	14	14	14	12	12	16	18	10
16	16	12	12	14	14	14	14	12	16	14	14	16
12	10	18	12	18	18	14	14	14	12	16	14	16
10	16	16	14	14	14	12	16	16	14	14	12	14

Salaires de cadres féminins (exprimés en k€)

16	16	14	14	14	14	10	12	12	08	20	14	14
14	20	14	12	12	16	10	10	18	10	16	12	12
14	18	12	12	16	08	14	10	12	14	12	16	14

**Question :** Les hommes sont-ils mieux payés que les femmes ?

## Vocabulaire (1/3)



### Définitions

- **population (statistique)** : ensemble des objets (ou personnes) sur lesquels porte l'étude
- **individu** : chaque élément de la population

## Vocabulaire (2/3)

	caractère	modalité	
	Individu		
	Age	57 ans	) caractères quantitatifs variables statistiques
	Taille :	1m80	
	Prof :	militaire	) caractères qualitatifs
	Grade :	Colonel	
	caractère ordinal		

### Définitions


- **Caractères** : critères d'étude de la population
- **Modalités** : les valeurs que peuvent prendre les caractères
- **Caractère quantitatif ou Variable statistique** : ensemble de modalités = des nombres + échelle mathématique
- **Caractère qualitatif ou Variable catégorielle** : caractère non quantitatif
- **Caractère ordinal** : les modalités sont ordonnées

## Vocabulaire (3/3)

	Individu		
	Age :	57 ans	— variable discrète
	Taille :	1m80	— variable continue
	Prof :	militaire	
	Grade :	Colonel	

### Définitions sur les variables statistiques

- **Variable discrète** : définie sur un espace discret (par exemple des entiers)
- **Variable continue** : définie sur un continuum (toutes les valeurs numériques d'un intervalle)



## Effectifs, fréquences et distributions

### Quelques définitions

- $X$  : caractère défini sur une population de  $N$  individus
- $\{x_1, \dots, x_I\}$  modalités de  $X$
- $N_i =$  effectif de  $x_i$   
= nombre d'individus pour lesquels  $X$  a pris la valeur  $x_i$
- fréquence ou effectif relatif :  $f_i = \frac{N_i}{N}$
- distribution de  $X$  : ensemble des couples  $\{(x_1, f_1), (x_2, f_2), \dots\}$


### Idée :

calculer la distribution des caractères sur l'amas de données  
 $\implies$  résume les informations importantes

## Diagrammes en bâtons


### Définition du diagramme en bâtons

- caractère  $X$  de distribution  $\{(x_1, f_1), (x_2, f_2), (x_3, f_3), \dots\}$
- diagramme en bâtons = graphe dans lequel on associe à chacune des modalités  $x_i$  (représentées sur l'axe horizontal) un bâton de hauteur  $f_i$
- représentation en colonnes : idem mais en élargissant les bâtons




## Application du diagramme en bâtons

XY AXJ BYRJMYJ, MQQMUVVXYJ GXR NCBWJR N' UYX  
 LMBY N' PCLLX XJ BGR XAVBDBVXYJ, XY IMAX NU  
 AMYNXGMFVX, RUV GX QGMJVX NU LUV NU QMGMBR  
 VCEMG.



## Problèmes des diagrammes en bâtons

Salaires des cadres masculins (en k€)								
19,6	12,5	17,7	18,8	19,1	14,7	21,9	22,5	21,8
20,1	16,2	20,5	12,2	25,4	20,9	21,2	15,5	21,3
17,9	25,0	14,4	21,7	18,3	16,7	23,0	17,0	24,3
27,0	27,7	18,0	17,5	23,7	21,6	13,8	22,2	19,2
20,2	15,1	19,6	17,2	23,3	24,0			



variables continues  $\Rightarrow$  diagramme en bâtons inutilisable

## Discrétisation

**Idée force** : utiliser les diagrammes en bâton ssi la taille de la population  $\gg$  au nombre de modalités des caractères

sinon  $\Rightarrow$  discrétiser le caractère

### Discrétisation

regrouper toutes les modalités appartenant à certains intervalles dans des **classes** de données

### Caractéristiques d'une classe


- $C$  : la classe  $[a, b[$
- **centre** de la classe  $C$  :  $c = \frac{a+b}{2}$
- **amplitude** de la classe  $C$  :  $h = b - a$

### Exemple de discrétisation (1/3)

Salaires des cadres masculins (en k€)								
19,6	12,5	17,7	18,8	19,1	14,7	21,9	22,5	21,8
20,1	16,2	20,5	12,2	25,4	20,9	21,2	15,5	21,3
17,9	25,0	14,4	21,7	18,3	16,7	23,0	17,0	24,3
27,0	27,7	18,0	17,5	23,7	21,6	13,8	22,2	19,2
20,2	15,1	19,6	17,2	23,3	24,0			

Classe de salaire	effectif	fréq.	Classe de salaire	effectif	fréq.
[12000, 14000[	3	3/42	[20000, 22000[	8	8/42
[14000, 16000[	4	4/42	[22000, 24000[	7	7/42
[16000, 18000[	7	7/42	[24000, 26000[	4	4/42
[18000, 20000[	7	7/42	[26000, 28000[	2	2/42

Diagramme  
en colonnes :




### Exemple de discrétisation (2/3)

Salaires des cadres masculins (en k€)								
19,6	12,5	17,7	18,8	19,1	14,7	21,9	22,5	21,8
20,1	16,2	20,5	12,2	25,4	20,9	21,2	15,5	21,3
17,9	25,0	14,4	21,7	18,3	16,7	23,0	17,0	24,3
27,0	27,7	18,0	17,5	23,7	21,6	13,8	22,2	19,2
20,2	15,1	19,6	17,2	23,3	24,0			

Classe de salaire	effectif	fréq.	Classe de salaire	effectif	fréq.
[12000, 17000[	9	9/42	[20000, 21000[	4	4/42
[17000, 18000[	5	5/42	[21000, 22000[	6	6/42
[18000, 19000[	3	3/42	[22000, 28000[	11	11/42
[19000, 20000[	4	4/42			


Diagramme  
en colonnes :



### Exemple de discrétisation (3/3)


Première discrétisation :

Diagramme  
en colonnes :



Deuxième discrétisation :

Diagramme  
en colonnes :



N'utiliser le diagramme en colonnes que pour des discrétisations uniformes


# Histogrammes

## Définition d'un histogramme


graphe dont l'axe des abscisses représente les modalités et qui associe à chaque classe de modalités un rectangle dont la base correspond aux bornes de cette classe et dont la hauteur est égale à :

$$\text{hauteur} = \frac{\text{fréquence}}{\text{base}}.$$

⇒ la fréquence d'une classe est égale à la surface de son rectangle



## Synthèse d'histogrammes ?



### Caractéristiques statistiques :

- localisation sur l'axe des  $X$  ⇒ moyenne, médiane, mode
- étendue ⇒ écart-type, variance


## La moyenne

### Moyenne d'une variable statistique discrète

- $X$  : variable statistique discrète
- modalités :  $\{x_1, x_2, \dots, x_l\}$
- population de  $N$  individus
- **Moyenne de  $X$**  :  $\mu_X = \sum_{i=1}^l f_i x_i = \frac{1}{N} \sum_{i=1}^l N_i x_i$

### Moyenne d'une variable statistique continue

- $Y$  : variable statistique continue
- modalités regroupées en  $l$  classes de centres  $\{y_1, y_2, \dots, y_l\}$
- population de  $N$  individus
- **Moyenne de  $Y$**  :  $\mu_Y = \sum_{i=1}^l f_i y_i = \frac{1}{N} \sum_{i=1}^l N_i y_i$



## Propriétés de la moyenne

### Propriété 1

- $X$  : variable statistique
- $Y = aX + b$ , où  $a$  et  $b$  sont des nombres réels
- $\mu_Y = a\mu_X + b$

### Propriété 2

- $X$  : variable statistique
- $n$  sous-populations distinctes  $S_1, \dots, S_n$  de  $N_1, \dots, N_n$  individus
- $\mu_i$  la moyenne de  $X$  sur la  $i^{\text{ème}}$  sous-population
- $\mu_X$  : moyenne de  $X$  sur la population  $S = S_1 \cup S_2 \cup \dots \cup S_n$

$$\mu_X = \frac{\sum_{i=1}^n N_i \mu_i}{\sum_{i=1}^n N_i}.$$

## Médiane d'une variable statistique discrète

- *moyenne* = valeur centrale des modalités
- *médiane* = valeur de la variable pour laquelle la moitié de la population a une modalité inférieure à cette valeur et l'autre moitié en a une supérieure

### Médiane d'une variable statistique discrète

- $X$  : variable statistique discrète, modalités :  $\{x_1, \dots, x_I\}$
- population de  $N$  individus
- **médiane** de  $X$  = tout nombre  $\delta$  tel que :

$$\sum_{i \in \{j: x_j < \delta\}} N_i \leq N/2 \quad \text{et} \quad \sum_{i \in \{j: x_j > \delta\}} N_i \leq N/2$$

## Exemples

variable statistique $X$						
modalité	0	1	2	3	4	5
effectif	2	3	4	5	3	2

Données triées
0, 0, 1, 1, 1, 2, 2, 2, 2, 3, 3, 3, 3, 3, 4, 4, 4, 4, 5, 5


variable statistique $X$						
modalité	0	1	2	3	4	5
effectif	2	3	4	4	3	2

Données triées
0, 0, 1, 1, 1, 2, 2, 2, 2, 3, 3, 3, 3, 3, 4, 4, 4, 4, 5, 5

## Médiane d'une variable statistique continue

### Médiane d'une variable statistique continue

- $X$  : variable statistique continue
- **Médiane** = le nombre  $\delta$  tel que les aires situées de part et d'autre de ce nombre dans l'histogramme représentant  $X$  sont égales



## Les quantiles

### Quantile d'une variable discrète

- $X$  : variable statistique discrète, modalités  $\{x_1, \dots, x_j\}$
- population de  $N$  individus
- **quantile d'ordre  $\alpha$**  = tout nombre  $\delta$  tel que :

$$\sum_{i \in \{j: x_j < \delta\}} N_i \leq \alpha N \quad \text{et} \quad \sum_{i \in \{j: x_j > \delta\}} N_i \leq (1 - \alpha)N$$

### Quantile d'une variable continue

- $X$  : variable statistique continue
- **quantile d'ordre  $\alpha$**  = le nombre  $\delta$  tel que les aires situées de part et d'autre de ce nombre dans l'histogramme représentant  $X$  sont égales respectivement à  $\alpha \times$  aire totale et  $(1 - \alpha) \times$  aire totale

## Principaux quantiles



Principaux quantiles	
valeur de $\alpha$	nom du quantile d'ordre $\alpha$
1/2	médiane
$i/4$ ( $i = 1, 2, 3$ )	$i^{\text{ème}}$ quartile
$i/5$ ( $i = 1, 2, 3, 4$ )	$i^{\text{ème}}$ quintile
$i/10$ ( $i = 1, 2, \dots, 9$ )	$i^{\text{ème}}$ décile
$i/100$ ( $i = 1, \dots, 99$ )	$i^{\text{ème}}$ centile

## Propriété des quantiles

### Propriété

- $X$  : variable statistique
- $Y = aX + b$ , où  $a$  et  $b$  sont des nombres réels
- $\text{médiane}(Y) = a \times \text{médiane}(X) + b$

## Application de la médiane



## Étendue des données

### Étendue d'une variable discrète

- $X$  : variable statistique discrète
- **Étendue** de  $X$  = la différence entre la plus grande modalité de  $X$  et la plus petite modalité

### Étendue d'une variable continue

- $X$  : variable statistique continue
- **Étendue** de  $X$  = la différence entre la borne supérieure de la classe associée à la plus grande valeur observée et la borne inférieure de la classe associée à la plus petite valeur observée

 Mesure de dispersion peu utilisée

## Variance (1/2)

**Idée force** : analyser globalement les déviations entre les valeurs prises sur un individu et la moyenne de la population

### Variance d'une variable discrète

- $X$  : variable statistique discrète, modalités :  $x_1, \dots, x_l$
- population :  $N$  individus
- **Variance** de  $X$  :  $\sigma_X^2 = \sum_{i=1}^l f_i(x_i - \mu_X)^2 = \frac{1}{N} \sum_{i=1}^l N_i(x_i - \mu_X)^2$

### Variance d'une variable continue

- $Y$  : variable statistique continue
- modalités :  $l$  classes de centres  $\{y_1, y_2, \dots, y_l\}$
- population :  $N$  individus
- **Variance** de  $Y$  :  $\sigma_Y^2 = \sum_{i=1}^l f_i(y_i - \mu_Y)^2 = \frac{1}{N} \sum_{i=1}^l N_i(y_i - \mu_Y)^2$

## Variance (2/2)

### Calcul pratique de la variance

$$\begin{aligned}\sigma_X^2 &= \frac{1}{N} \sum_{i=1}^l N_i(x_i - \mu_X)^2 \\ &= \frac{1}{N} \left( \sum_{i=1}^l N_i x_i^2 \right) - \mu_X^2\end{aligned}$$

### Propriété

- $X$  : variable statistique
- $Y = aX + b$ , où  $a$  et  $b$  sont des nombres réels
- $\sigma_Y^2 = a^2 \sigma_X^2$

## Écart-type

*Problème de la variance* : unités différentes des données

$X$  exprimé en  $\text{€}$   $\implies \sigma_X^2$  exprimé en  $\text{€}^2$

### Écart-type


- $X$  : variable statistique (discrète ou continue)
- **Écart-type** de  $X$  :  $\sigma_X$ , la racine carrée de la variance de  $X$

### Propriété

- $X$  : variable statistique
- $Y = aX + b$ , où  $a$  et  $b$  sont des nombres réels
- $\sigma_Y = |a|\sigma_X$

## Propriété de l'écart-type

### Théorème de Bienaymé-Tchébicheff




- $X$  une variable statistique discrète
- moyenne  $\mu_X$  et écart-type  $\sigma_X$
- la proportion de valeurs de  $X$  observées entre  $\mu_X - k\sigma_X$  et  $\mu_X + k\sigma_X$  est strictement supérieure à  $1 - 1/k^2$

- Propriété valable pour les variables statistiques continues : la proportion d'individus pour lesquels la valeur de  $X$  se situe entre  $\mu_X - k\sigma_X$  et  $\mu_X + k\sigma_X$  est strictement supérieure à  $1 - 1/k^2$

$\implies \left\{ \begin{array}{l} \text{plus de 88\% de la population entre } \mu_X - 3\sigma_X \text{ et } \mu_X + 3\sigma_X \\ \text{plus de 96\% de la population entre } \mu_X - 5\sigma_X \text{ et } \mu_X + 5\sigma_X \end{array} \right.$

## Application de l'écart-type



- 1 normaliser l'image du cerveau du patient (SPM : Statistical Parametric Mapping)
- 2 comparer avec la base de patients
- 3 produire l'image comparée
- 4 diagnostiquer la maladie

# RFIDEC — cours 1 : Rappels de probas/stats (2/3)

Christophe Gonzales

LIP6 – Université Paris 6, France

## Plan du cours 1.2

- 1 probabilités : événements, définition
- 2 probabilités conditionnelles
- 3 formule de Bayes
- 4 indépendance, indépendance conditionnelle

## Les probabilités : objectives ou subjectives ? (1/2)

Qu'est-ce qu'une probabilité ?

### *Probabilités subjectives (de Finetti)*

Les probabilités expriment le degré d'incertitude que les **individus** accordent à des événements incertains.

Exemple : dans un journal, « certains observateurs de la vie politique pensent qu'il y a une chance sur quatre pour que la rencontre au sommet ait lieu avant novembre »



$\Rightarrow P(\text{rencontre avant novembre}) = 0,25$

### Probabilités objectives

Les probabilités ne dépendent pas d'appréciations personnelles et doivent être fondées uniquement sur des données **objectives**.

⇒ probas introduites au XVIème, XVIIème et XVIIIème siècles (Cardano, De Moivre, Pascal, Bernoulli, Laplace)



⇒ données fréquentistes

⇒ dans les années 30 : axiomatique de Kolmogorov

## Les probabilités : outil indispensable

### Richard T. Cox



- machine pour gérer des incertitudes
- **Rationalité** :
  - ⇒ probas = seule représentation possible des incertitudes

rationnel = 5 desideratas :

- 1 incertitude d'un événement évaluée de plusieurs manières  
⇒ même résultat
- 2 petites modif d'un événement ⇒ petit changement sur l'incertitude
- 3 représentation universelle : s'applique à tout problème
- 4 évaluer l'incertitude d'un événement ⇒ événement défini sans ambiguïté
- 5 évaluation ⇒ utiliser toutes les infos à disposition


## Vocabulaire

**Exemple** : lancer d'un dé à 6 faces

### Définition

- **événement** : tout ce qui peut se réaliser ou pas à la suite d'une expérience  
*exemple* : « obtenir un 4 », « ne pas obtenir un 4 », « obtenir un chiffre inférieur à 3 »
- **événement certain** : assuré de se produire  
*exemple* : « obtenir un chiffre inférieur à 7 »
- **événement impossible** : ne se produira jamais  
*exemple* : « obtenir un chiffre supérieur à 7 »
- **événement élémentaire** : seulement un seul résultat de l'expérience permet de le réaliser  
*exemple* : « obtenir 4 » mais « obtenir un chiffre pair » = pas élémentaire
- **univers  $\Omega$**  : ensemble des événements élémentaires


# Vocabulaire



## Les événements, des ensembles ?

- événements = sous-ensembles de  $\Omega$
- $\emptyset$  = événement impossible
- $A \cup B$  = événement qui est réalisé si  $A$  ou  $B$  est réalisé
- $C \cap D$  = événement qui est réalisé si  $C$  et  $D$  sont réalisés
- $\overline{C \cup D}$  = complémentaire de  $C \cup D$  dans  $\Omega$   
= événement qui est réalisé ssi  $C \cup D$  ne l'est pas
- $A \cap B = \emptyset$  = 2 événements qui ne peuvent se réaliser simultanément

## Les événements, des ensembles ?



## Définition des probabilités : le cas discret

### Définition des probabilités (Kolmogorov)



- $\Omega$  = ensemble fini ou dénombrable d'événements élémentaires  $e_k, k \in K \subseteq \mathbb{N}$
- $\mathcal{A} = 2^\Omega$  = ensemble des événements
- pour tout  $A \in \mathcal{A}, 0 \leq P(A) \leq 1$
- $P(\Omega) = 1$
- $A = \bigcup_{k \in L} A_k$ , avec  $L$  ensemble dénombrable et,  $\forall j, k \in L, j \neq k, A_j \cap A_k = \emptyset$ ,  
$$P(A) = \sum_{k \in L} P(A_k).$$

$\Rightarrow$  Les probabilités des événements élémentaires déterminent entièrement  $P$

conséquence :  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

## Définition des probabilités : le cas continu (1/3)

Chaque événement élémentaire a une proba = 0

Mais proba d'être dans un intervalle  $\neq 0$

1ère étape : discrétisation


transformer  $\Omega$  en un ensemble dénombrable de classes

*Exemple* : salaires  $\Rightarrow$  8 classes :

$[12K \text{ €}, 14K \text{ €}[$ ,  $[14K \text{ €}, 16K \text{ €}[$ ,  $[16K \text{ €}, 18K \text{ €}[$ ,  $\dots$ ,  $[26K \text{ €}, +\infty[$

## Définition des probabilités : le cas continu (2/3)

Histogramme : surface = fréquence  $\approx$  proba



## Définition des probabilités : le cas continu (3/3)

### Probabilité d'un événement

- fonction de densité
- $P(A)$  = surface délimitée par la fonction de densité dans la zone où les événements sont inclus dans  $A$
- $P(\text{événement élémentaire}) = 0$
- La surface délimitée par la fonction de densité sur tout  $\Omega$  est égale à 1
- Les valeurs prises par la fonction de densité sont  $\geq 0$  partout

## Probabilités conditionnelles (1/5)

### Définition

la probabilité d'un événement  $A$  conditionnellement à un événement  $B$ , que l'on note  $P(A|B)$ , est la probabilité que  $A$  se produise sachant que  $B$  s'est ou va se produire

Problème : comment calculer  $P(A|B)$  ?

$P(A|\Omega) = P(A)$  puisqu'on sait que  $\Omega$  sera réalisé

## Probabilités conditionnelles (2/5)

### Exemple


- Tirer une carte parmi un jeu de 32 cartes
- $\Omega = \{32 \text{ cartes}\}$
- événements :  $A = \text{tirer un roi}$        $B = \text{tirer un cœur}$
- $P(A|B) = ?$

Si  $A$  se produit, sachant que  $B$  s'est aussi produit

$\implies A \cap B$  se produit

$\implies P(A|B) = P(A \cap B|B)$

## Probabilités conditionnelles (3/5)



$\Rightarrow$  on cherche la probabilité que le cercle  $A \cap B$ , qui est inclus dans  $B$ , soit réalisé, sachant que l'événement  $B$  est réalisé

$\Rightarrow P(B) = 1$  et  $B$  peut jouer le rôle d'univers pour  $A \cap B$

## Probabilités conditionnelles (4/5)

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

$$P(A|B) = \frac{|A \cap B|}{|\Omega|} \times \frac{|\Omega|}{|B|} = \frac{P(A \cap B)}{P(B)}.$$

### Définition

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \text{ quand } P(B) > 0$$

## Probabilités conditionnelles (5/5)

$B_k, k \in K$  partition de  $\Omega$

$$A = A \cap \Omega = A \cap \left[ \bigcup_{k \in K} B_k \right] = \bigcup_{k \in K} [A \cap B_k]$$

$$P(A) = \sum_{k \in K} P(A \cap B_k)$$

$$\text{Or } P(A|B_k) = \frac{P(A \cap B_k)}{P(B_k)} \implies P(A \cap B_k) = P(A|B_k)P(B_k)$$

$$P(A) = \sum_{k \in K} P(A|B_k)P(B_k)$$

## Application peu pratique

Paquet 1



Paquet 2



- Dans chaque paquet : des cartes gagnantes et des cartes perdantes
- Dans chaque paquet, tirer 1 carte marron  $\implies$  plus de chance d'avoir une carte gagnante que si on tire une carte bleue

Paquet 3 = paquet 1 + paquet 2



**Pb** : Doit-on choisir une carte bleue ou marron dans le paquet 3 ?

## Application peu pratique — suite

Paquet 1

	Bleue	Marron
Gagnante	1	2
Perdante	3	5

Paquet 2

	Bleue	Marron
Gagnante	5	3
Perdante	2	1

$$P(\text{Gagnante}|\text{Bleue}) = \begin{cases} 1/4 & \text{pour le paquet 1} \\ 5/7 & \text{pour le paquet 2} \end{cases}$$

$$P(\text{Gagnante}|\text{Marron}) = \begin{cases} 2/7 & \text{pour le paquet 1} \\ 3/4 & \text{pour le paquet 2} \end{cases}$$

**Remarque** :  $1/4 < 2/7$  et  $5/7 < 3/4$

$\implies$  pour chaque paquet, choisir de préférence une carte marron

## Application peu pratique — suite

Paquet 3

	Bleue	Marron
Gagnante	6	5
Perdante	5	6

$$P(\text{Gagnante}|\text{Bleue}) = 6/11$$

$$P(\text{Gagnante}|\text{Marron}) = 5/11$$

$\implies$  pour ce paquet, choisir de préférence une carte bleue

## Application peu pratique — fin

Paquet 1			Paquet 2			Paquet 3		
	Bleue	Marron		Bleue	Marron		Bleue	Marron
G	1	2	G	5	3	G	6	5
P	3	5	P	2	1	P	5	6

Calculs pour le paquet 3 :


$$\begin{aligned}
 P(G|Bleue) &= P(G, \text{Paquet 1} | \text{Bleue}) + P(G, \text{Paquet 2} | \text{Bleue}) \\
 &= P(G | \text{Paquet 1}, \text{Bleue}) \times P(\text{Paquet 1} | \text{Bleue}) \\
 &\quad + P(G | \text{Paquet 2}, \text{Bleue}) \times P(\text{Paquet 2} | \text{Bleue}) \\
 &= P(G | \text{Paquet 1}, \text{Bleue}) \times 4/11 \\
 &\quad + P(G | \text{Paquet 2}, \text{Bleue}) \times 7/11 \\
 P(G|Marron) &= P(G | \text{Paquet 1}, \text{Marron}) \times 7/11 \\
 &\quad + P(G | \text{Paquet 2}, \text{Marron}) \times 4/11
 \end{aligned}$$

**!** probas conditionnelles non pondérées par les mêmes poids  
 ⇒ choisir une carte bleue pour le paquet 3

## Théorème de Bayes

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

$$\begin{aligned}
 P(A \cap B) &= P(A|B)P(B) \\
 &= P(B|A)P(A)
 \end{aligned}$$




Théorème de Bayes

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} \quad \forall A, B \text{ tels que } P(A) \neq 0 \text{ et } P(B) \neq 0$$

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

## Monty Hall


<http://www.apprendre-en-ligne.net/random/monty/>



- derrière une des portes = 1 bateau
- derrière les autres portes : des moutons

proba que le bateau se trouve derrière la porte ?

## Monty Hall



L'animateur choisit au hasard une des 2 autres portes qui contient des moutons et l'ouvre.

Choix : conserver la porte 2 ou choisir la porte 1 ?

calculer la proba que le bateau soit derrière la porte 1 ou la 2

## Monty Hall

3 événements élémentaires :

- $B1$  : le bateau est derrière la porte 1
- $B2$  : le bateau est derrière la porte 2
- $B3$  : le bateau est derrière la porte 3

$E$  = événement « l'animateur a choisi, parmi les portes 1 et 3, d'ouvrir la porte 3 »

Choix  $\implies P(B1|E)$  et  $P(B2|E)$

## Monty Hall

$E$  = événement « l'animateur a choisi, parmi les portes 1 et 3, d'ouvrir la porte 3 »

Formule de Bayes :  $P(B1|E) = \frac{P(E|B1)P(B1)}{P(E)}$

- $P(E|B1) = 1$
- $P(B1) = 1/3$
- $P(E) = P(E|B1)P(B1) + P(E|B2)P(B2) + P(E|B3)P(B3)$   
 $= 1 \times 1/3 + 1/2 \times 1/3 + 0 \times 1/3 = 1/2$

$$P(B1|E) = \frac{1 \times 1/3}{1/2} = 2/3$$

$P(B2|E) = 1 - P(B1|E) - P(B3|E) = 1/3$



$$P(B1|E) = 2/3$$

$$P(B2|E) = 1/3$$

## Indépendance probabiliste (1/2)

### Définition de l'indépendance

deux événements  $A$  et  $B$  sont indépendants si :

$$P(A \cap B) = P(A) \times P(B)$$

si  $P(B) > 0$  alors  $P(A|B) = P(A)$

l'indépendance n'est pas une propriété du couple  $(A, B)$  mais du couple  $(\{A, A^c\}, \{B, B^c\})$  :

$A$  et  $B$  sont indépendants  $\implies A$  et  $B^c$  indépendants  
 $\implies A^c$  et  $B$  indépendants  
 $\implies A^c$  et  $B^c$  indépendants

## Indépendance probabiliste (2/2)

### Démonstration :

$A$  et  $B$  sont indépendants  $\implies P(A \cap B) = P(A) \times P(B)$

$$P(A) = P(A \cap B) + P(A \cap B^c)$$

$$\implies P(A \cap B^c) = P(A) - P(A \cap B)$$

$$= P(A) - P(A) \times P(B)$$

$$= P(A) \times [1 - P(B)]$$

$$= P(A) \times P(B^c)$$

## Indépendance conditionnelle

$P(A|B) \approx$  restriction de l'espace  $\Omega$  à  $B$

### Définition de l'indépendance conditionnelle

deux événements  $A$  et  $B$  sont indépendants conditionnellement à  $C$  si :

$$P(A \cap B|C) = P(A|C) \times P(B|C)$$

si  $P(B \cap C) > 0$  alors  $P(A|B, C) = P(A|C)$

l'indépendance conditionnelle n'est pas une propriété du couple  $(A, B)$  mais du couple  $(\{A, A^c\}, \{B, B^c\})$  :

$A$  et  $B$  sont indépendants conditionnellement à  $C$

$\implies A$  et  $B^c$  indépendants conditionnellement à  $C$

$\implies A^c$  et  $B$  indépendants conditionnellement à  $C$

$\implies A^c$  et  $B^c$  indépendants conditionnellement à  $C$

# RFIDEC — cours 1 : Rappels de probas/stats (3/3)

Christophe Gonzales

LIP6 – Université Paris 6, France

## Plan du cours 1.3

- 1 variables aléatoires
- 2 caractéristiques et variables aléatoires
- 2 indépendances de variables aléatoires
- 3 loi binomiale et loi de Poisson
- 4 loi normale

## Variables aléatoires (1/2)

### Exemple

- au début : vous avez 1000 €
- jeu : je tire 3 cartes parmi un jeu de 32 cartes et, suivant le tirage, je vous donne ou vous prend de l'argent :

			
2000 €	500 €	0 €	-1000 €

$$P(2000\text{€}) = P(3 \text{ rois})$$

$$P(\text{gain} \geq 500\text{€}) = P(3 \text{ rois}) + P(2 \text{ rois})$$

## Variables aléatoires (2/2)

### Définition

- $\Omega$  = univers muni d'une loi de proba  $P(\cdot)$
- $\Omega'$  un autre ensemble
- $2^\Omega$  et  $2^{\Omega'}$  = ensemble des sous-ensembles de  $\Omega$  et de  $\Omega'$
- **variable aléatoire** = fonction  $\Gamma$  de  $2^\Omega$  dans  $2^{\Omega'}$  telle que :

$$\Gamma^{-1}(A') \in 2^\Omega \quad \forall A' \in 2^{\Omega'}$$


### Probabilité sur $\Omega'$

loi de proba  $P'(\cdot)$  sur  $\Omega'$  :

$$P'(A') = P(\Gamma^{-1}(A')) \quad \forall A' \in 2^{\Omega'}$$

**notation** :  $P(\Gamma = A') = P(\Gamma^{-1}(A'))$

## Probabilités : retour sur le cas continu (1/2)



$$P(X \in I) = \int_I p(x) dx$$

avec  $P$  = proba et  $p$  = fonction de densité

$\implies$  connaître  $p$  = connaître  $P$


intervalles  $] -\infty, x[ \implies$  fonction de répartition :

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

## Probabilités : retour sur le cas continu (2/2)


- variables bi-dimensionnelles, ou couples de variables, continues,  $(X, Y)$
- densité de probabilité =  $p(x, y)$
- fonction de répartition =  $F(x, y)$
- alors  $\forall x, y$  :

$$F(x, y) = P(X < x, Y < y) = \iint_{\{(x', y') : x' < x, y' < y\}} p(x', y') dx' dy'$$





## Application de l'espérance (3/3)



Nombre de bits et proba ( $\times 100$ ) par caractère

$X_i$	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	$x_{15}$	$x_{16}$
nb bits	6	5	5	4	4	5	5	5	6	2	4	4	4	3	4	4
proba	1	3	2	6	5	4	2	3	1	21	6	5	9	17	7	8

$$\text{Espérance du nombre de bits} = \sum_{i=1}^{16} p_i |\text{nb bits } x_i| = 3,59 < 4$$

## Caractéristiques d'une loi de probabilités (2/3)

### Caractéristiques de dispersion

- **variance** :  $V(X)$  ou  $\sigma^2$  :  
 $X$  discrète :  $\sigma^2 = \sum [x_k - E(X)]^2 p_k$   
 $X$  continue :  $\sigma^2 = \int [x - E(X)]^2 p(x) dx$
- moyenne des carrés des écarts entre les valeurs prises par  $X$  et son espérance  $E(X)$
- **écart-type** :  $\sigma =$  racine carrée de la variance
- variance et donc écart-type n'existent pas toujours

## Caractéristiques d'une loi de probabilités (3/3)

### Propriétés de la variance

- $V(X) = E(X^2) - E(X)^2$
- $\forall X, Y, V(X + Y) = V(X) + V(Y) + 2cov(X, Y)$  où :
  - $cov(X, Y) =$  **covariance** de  $X$  et  $Y$
  - si  $X$  et  $Y$  discrètes et  $p_k = P(X = x_k, Y = y_k)$

$$cov(X, Y) = \sum [x_k - E(X)][y_k - E(Y)] p_k$$

- si  $X$  et  $Y$  continues, de densité  $p(x, y)$ ,

$$cov(X, Y) = \iint [x - E(X)][y - E(Y)] p(x, y) dx dy$$

## Indépendance de deux variables aléatoires (1/3)

### Indépendance de deux variables discrètes

$X$  et  $Y$  sont *indépendantes* si  $\forall x, \forall y$  :

les événements  $X = x$  et  $Y = y$  sont indépendants

- $\forall x, \forall y, P(X = x \cap Y = y) = P(X = x) \times P(Y = y)$
- $\forall x, \forall y \text{ t.q. } P(Y = y) > 0, P(X = x | Y = y) = P(X = x)$
- $\forall y, \forall x \text{ t.q. } P(X = x) > 0, P(Y = y | X = x) = P(Y = y)$

## Indépendance de deux variables aléatoires (2/3)

### Indépendance de deux variables continues

$X$  et  $Y$  sont *indépendantes* si  $\forall I, \forall J$ , intervalles,

les événements  $X \in I$  et  $Y \in J$  sont indépendants

Il suffit que les fonctions de répartition,  $F_X, F_Y$  de  $X$  et  $Y$  et  $F_{XY}$  du couple satisfassent :

$$\forall x, y, F_{XY}(x, y) = F_X(x) \times F_Y(y)$$

ou encore que les densités de probabilité  $p_X, p_Y$  de  $X$  et  $Y$  et  $p_{XY}$  du couple satisfassent :

$$\forall x, y, p_{XY}(x, y) = p_X(x) \times p_Y(y)$$

## Indépendance de deux variables aléatoires (3/3)

### Propriété

La covariance de deux variables indépendantes  $X$  et  $Y$  est toujours nulle

La réciproque est fautive

$$\text{cov}(X, Y) = \iint [x - E(X)][y - E(Y)]p_{XY}(x, y) dx dy$$

$$X \text{ et } Y \text{ indep} \implies p_{XY}(x, y) = p_X(x) \times p_Y(y)$$

$$\implies \text{cov}(X, Y) = \int [x - E(X)]p_X(x) dx \int [y - E(Y)]p_Y(y) dy$$

$$\text{Or } \int [x - E(X)]p_X(x) dx = \int xp_X(x) dx - \int E(X)p_X(x) dx$$

$$= E(X) - E(X) = 0$$

$$\implies \text{cov}(X, Y) = 0 \times 0 = 0$$

## Indépendance mutuelle de $n$ variables (1/3)

### Définition

$n$  variables  $(X_1, X_2, \dots, X_k, \dots, X_n)$

Elles sont **mutuellement indépendantes** si tout événement lié à une partie d'entre elles est indépendant de tout événement lié à toute autre partie disjointe de la précédente

$\implies$  c'est la généralisation naturelle de l'indépendance de deux variables :

des variables discrètes  $(X_1, \dots, X_k, \dots, X_n)$  sont mutuellement indépendantes lorsque :

$$\forall X_k \quad P\left(\bigcap_{k=1}^n X_k = x_k\right) = \prod_{k=1}^n P(X_k = x_k)$$

## Indépendance mutuelle de $n$ variables (2/3)

des variables continues  $(X_1, \dots, X_k, \dots, X_n)$  sont mutuellement indépendantes lorsque  $\forall X_k (k = 1, \dots, n)$  :

$$p_{X_1 \dots X_k \dots X_n}(x_1, \dots, x_k, \dots, x_n) = \prod_{k=1}^n p_{X_k}(x_k)$$

L'indépendance mutuelle de  $n$  variables entraîne leur indépendance deux à deux

 la réciproque n'est pas vraie

## Indépendance mutuelle de $n$ variables (3/3)



- Soit  $n$  dés à 6 faces
- $X_k$  : variable aléatoire indiquant sur quelle face tombe le  $k$ ème dé
- tous les dés sont différents  $\implies X_1, \dots, X_n$  mutuellement indépendantes

$$p_{X_1 \dots X_k \dots X_n}(x_1, \dots, x_k, \dots, x_n) = \prod_{k=1}^n p_{X_k}(x_k)$$

$\implies$  stockage mémoire =  $6n$  au lieu de  $6^n$

$n = 10$	60	60 millions
$n = 20$	120	3,6 millions de milliards

## Indépendance conditionnelle (1/2)

### Indépendance conditionnelle de deux variables discrètes

$X$  et  $Y$  sont **indépendantes conditionnellement à  $Z$**  si  $\forall x, \forall y, \forall z$ , les événements  $X = x$  et  $Y = y$  sont indépendants conditionnellement à  $Z = z$

- $P(X=x \cap Y=y | Z=z) = P(X=x | Z=z) \times P(Y=y | Z=z)$
- si  $P(Y=y | Z=z) > 0$  alors :  
 $P(X=x | Y=y, Z=z) = P(X=x | Z=z)$
- si  $P(X=x | Z=z) > 0$  alors :  
 $P(Y=y | X=x, Z=z) = P(Y=y | Z=z)$

## Indépendance conditionnelle (2/2)

### Indépendance conditionnelle de deux variables discrètes

$X$  et  $Y$  sont **indépendantes conditionnellement à  $Z$**  si :

- $P(X \cap Y | Z) = P(X | Z) \times P(Y | Z)$
- si  $P(Y | Z) > 0$  alors  $P(X | Y, Z) = P(X | Z)$
- si  $P(X | Z) > 0$  alors  $P(Y | X, Z) = P(Y | Z)$

### Interprétation

- Conditionnement = apport de connaissances
- Si l'on connaît la valeur de la variable  $Z$ , alors connaître celle de  $Y$  n'apporte rien sur la connaissance de  $X$



Ces formules s'étendent si  $X$ ,  $Y$  et/ou  $Z$  sont remplacés par des ensembles de variables aléatoires disjoints 2 à 2

## Application des probas conditionnelles (1/2)



- Classe de 40 étudiants
- **assertion** : «il y a au moins 2 étudiants qui sont nés le même jour»

Avez-vous intérêt à parier 10 € que cette assertion est vraie ?

- $X_i \in \{1, \dots, 365\}$  le jour de naissance du  $i$ ème étudiant
- que vaut  $P(\text{tous les } X_i \text{ sont différents})$  ?

## Application des probas conditionnelles (2/2)

$$\begin{aligned}\alpha &= P(\text{tous les } X_i \text{ sont différents}) \\ &= P(X_2 \neq X_1) \times P(X_3 \notin \{X_1, X_2\} | X_2 \neq X_1) \times \\ &\quad P(X_4 \notin \{X_1, X_2, X_3\} | X_2 \neq X_1, X_3 \notin \{X_1, X_2\}) \times \dots \\ &= \prod_{i=2}^{40} P\left(X_i \notin \{X_j : j < i\} \mid \bigwedge_{j < i} X_j \notin \{X_k : k < j\}\right) \\ &= \prod_{i=2}^{40} \frac{365 - (i - 1)}{365} = \prod_{i=1}^{39} \frac{365 - i}{365} \approx 10,87\%\end{aligned}$$

⇒ en choisissant au hasard une classe de 40 étudiants,  
on a 10,87% de chances que l'assertion soit fausse

## Loi de Bernoulli

### Définition

**Épreuve de Bernoulli** = expérience aléatoire qui ne peut prendre que deux résultats (*succès* et *échec*)

$p$  = proba de succès, et  $q = 1 - p$  = proba d'échec.

### Loi de Bernoulli

Variable  $X$  à support  $\mathcal{X} = \{0, 1\}$  telle que :

$$P(X = 1) = p \text{ et } P(X = 0) = 1 - p$$

$$E(X) = p \quad V(X) = p(1 - p)$$

⇒  $X$  = le nombre de succès de l'épreuve de Bernoulli

## Loi binomiale

### Définition

**Épreuve binomiale** = expérience aléatoire telle que :

- 1 on répète  $n$  fois la même épreuve de Bernoulli,
- 2 les probas  $p$  et  $q$  restent inchangées pour chaque épreuve de Bernoulli,
- 3 les épreuves de Bernoulli sont toutes réalisées indépendamment les unes des autres.

### Loi binomiale de paramètres $n$ et $p$

- $X$  = nombre de succès de l'épreuve binomiale
- $X \sim \mathcal{B}(n, p)$
- $P(X = k) = C_n^k p^k (1 - p)^{n-k}, \forall k = 0, \dots, n$
- $E(X) = np \quad V(X) = np(1 - p)$

## Loi de Poisson

### Définition

- **Loi de Poisson** ou loi des événements rares :  
loi vers laquelle tend la loi binomiale lorsque  $n$  est très grand et  $p$  assez petit
- variable discrète  $X \sim$  loi de POISSON de paramètre  $\lambda > 0$  :  
 $\implies$  les événements élémentaires  $e_k = \langle X = k \rangle$ ,  $k \in \mathbb{N}$ ,  
ont pour probabilités :

$$P(X = k) = \frac{e^{-\lambda} \times \lambda^k}{k!}$$

- $E(X) = \lambda \quad V(X) = \lambda$

$\implies$  s'applique dans le cas d'expériences dont les occurrences sont totalement aléatoires (**sans régularité**) et indépendantes les unes des autres

## Lois géométrique et exponentielle

### Définition : loi géométrique de paramètre $p$

- loi de la variable donnant le nombre d'essais nécessaires pour que se produise un événement de probabilité  $p$
- $P(X = k) = p(1 - p)^{(k-1)}$ ,  $k = 1, \dots, n, \dots$
- $E(X) = \frac{1}{p} \quad V(X) = \frac{1-p}{p^2}$

### Définition : loi exponentielle de paramètre $\lambda$

- a pour support  $\mathbb{N}_+^*$  et pour densité  
 $p(x) = \lambda \exp\{-\lambda x\}$ ,  $x > 0$
- $E(X) = \frac{1}{\lambda} \quad V(X) = \frac{1}{\lambda^2}$
- utilisée en fiabilité : durée de vie de nombreux composants  
 $\lambda =$  *taux de défaillance*  
 $E(X) = \frac{1}{\lambda} =$  *temps moyen entre défaillances*

## Loi normale

 Loi extrêmement importante : souvent une très bonne approximation de la loi réelle


### Définition : loi normale de paramètres $\mu$ et $\sigma^2$

- notée  $\mathcal{N}(\mu, \sigma^2)$
- s'applique pour des variables aléatoires continues
- densité positive sur tout  $\mathbb{R}$  :

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

- $E(X) = \mu \quad V(X) = \sigma^2$

## Fonction de densité de la loi normale




## Loi normale = limite d'autres lois (1/4)

Lancés de dés à 6 faces




⇒ on compte la somme des résultats des dés

Somme pour 1 jet de dé




## Loi normale = limite d'autres lois (2/4)

Somme pour 2 jets de dés




## Loi normale = limite d'autres lois (3/4)

### Somme pour 3 jets de dés



## Loi normale = limite d'autres lois (4/4)

### Somme pour 4 jets de dés



## Loi normale en pratique

### Théorème

$$X \sim \mathcal{N}(\mu; \sigma^2)$$

Alors la variable  $Y = aX + b$  obéit à la loi  $\mathcal{N}(a\mu + b; a^2\sigma^2)$ .

⇒ toute transformée affine d'une variable aléatoire suivant une loi normale suit aussi une loi normale

### Corollaire


●  $X$  une variable aléatoire obéissant à une loi  $\mathcal{N}(\mu; \sigma^2)$

$$\Rightarrow Z = \frac{X - \mu}{\sigma} \text{ suit la loi } \mathcal{N}(0; 1)$$

●  $Z$  suit une loi normale centrée (à cause de la moyenne en 0) réduite (à cause du  $\sigma^2$  égal à 1)

## Table de la loi normale centrée réduite

valeurs dans le tableau  
ci-dessous : les  $\alpha$   
tels que  $P(Z > z_\alpha) = \alpha$



$z_\alpha$	0,00	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
0,0	0,5000	0,4960	0,4920	0,4880	0,4840	0,4801	0,4761	0,4721	0,4681	0,4641
0,1	0,4602	0,4562	0,4522	0,4483	0,4443	0,4404	0,4364	0,4325	0,4286	0,4247
0,2	0,4207	0,4168	0,4129	0,4090	0,4052	0,4013	0,3974	0,3936	0,3897	0,3859
0,3	0,3821	0,3783	0,3745	0,3707	0,3669	0,3632	0,3594	0,3557	0,3520	0,3483
0,4	0,3446	0,3409	0,3372	0,3336	0,3300	0,3264	0,3228	0,3192	0,3156	0,3121
0,5	0,3085	0,3050	0,3015	0,2981	0,2946	0,2912	0,2877	0,2843	0,2810	0,2776
0,6	0,2743	0,2709	0,2676	0,2643	0,2611	0,2578	0,2546	0,2514	0,2483	0,2451
0,7	0,2420	0,2389	0,2358	0,2327	0,2297	0,2266	0,2236	0,2206	0,2177	0,2148
0,8	0,2119	0,2090	0,2061	0,2033	0,2005	0,1977	0,1949	0,1922	0,1894	0,1867
0,9	0,1841	0,1814	0,1788	0,1762	0,1736	0,1711	0,1685	0,1660	0,1635	0,1611
1,0	0,1587	0,1562	0,1539	0,1515	0,1492	0,1469	0,1446	0,1423	0,1401	0,1379
1,1	0,1357	0,1335	0,1314	0,1292	0,1271	0,1251	0,1230	0,1210	0,1190	0,1170
1,2	0,1151	0,1131	0,1112	0,1093	0,1075	0,1056	0,1038	0,1020	0,1003	0,0985
1,3	0,0968	0,0951	0,0934	0,0918	0,0901	0,0885	0,0869	0,0853	0,0838	0,0823
1,4	0,0808	0,0793	0,0778	0,0764	0,0749	0,0735	0,0722	0,0708	0,0694	0,0681
1,5	0,0668	0,0655	0,0643	0,0630	0,0618	0,0606	0,0594	0,0582	0,0571	0,0559
1,6	0,0548	0,0537	0,0526	0,0516	0,0505	0,0495	0,0485	0,0475	0,0466	0,0455
1,7	0,0446	0,0436	0,0427	0,0418	0,0409	0,0401	0,0392	0,0384	0,0375	0,0367
1,8	0,0359	0,0352	0,0344	0,0336	0,0329	0,0322	0,0314	0,0307	0,0301	0,0294
1,9	0,0287	0,0281	0,0274	0,0268	0,0262	0,0256	0,0250	0,0244	0,0239	0,0233


## Loi normale bi-dimensionnelle

Définition : loi normale bi-dimensionnelle

- couple de variables  $(X, Y)$
- densité dans  $\mathbb{R}^2$  :

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \times \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[ \left( \frac{x-\mu_x}{\sigma_x} \right)^2 - 2\rho \frac{(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y} + \left( \frac{y-\mu_y}{\sigma_y} \right)^2 \right] \right\}$$

où  $\rho = \frac{\text{cov}(X, Y)}{\sigma_x\sigma_y} = \text{coefficient de corrélation linéaire}$



# RFIDEC — cours 2 : Échantillons, estimations ponctuelles

Christophe Gonzales

LIP6 – Université Paris 6, France

## Plan du cours n°2


- 1 Lois des grands nombres
- 2 Théorème central-limite
- 3 Estimation ponctuelle à partir d'échantillons
- 4 Biais dans les estimations

## Convergence en probabilité

### Définition

- $(X_n)_{n \in \mathbb{N}}$  : suite de variables
- $a$  : constante
- $(X_n)$  **converge en probabilité** vers  $a$  si, pour tout  $\epsilon > 0$  la probabilité que l'écart absolu entre  $X_n$  et  $a$  dépasse  $\epsilon$  tend vers 0 quand  $n \rightarrow \infty$  :

$$\lim_{n \rightarrow \infty} P(|X_n - a| \geq \epsilon) = 0$$



Aire hachurée tend vers 0 quand  $n \rightarrow \infty$

## Loi faible des grands nombres

### Loi faible

- $(X_n)_{n \in \mathbb{N}}$  est une suite de variables aléatoires :
  - de même loi
  - d'espérance  $m$
  - possédant une variance  $\sigma^2$
  - **deux à deux** indépendantes
- alors la suite des variables  $\bar{X}_n = \frac{\sum_{k=1}^n X_k}{n}$  converge en probabilité vers  $m$

$\bar{X}_n$  est appelée *moyenne empirique*

$$E(\bar{X}_n) = m$$

$$V(\bar{X}_n) = \frac{\sigma^2}{n}$$

**conséquence** : échantillons de grandes tailles  $\implies$  bonne chance d'estimer  $m$

## Convergence presque sûre

### Définition

- $(X_n)_{n \in \mathbb{N}}$  : suite de variables
- $a$  : constante
- $(X_n)$  **converge presque sûrement** vers  $a$  s'il y a une proba 1 que la suite des réalisations des  $X_n$  tende vers  $a$  :

$$P\left(\lim_{n \rightarrow \infty} X_n = a\right) = 1$$



Définition plus exigeante que la convergence en probabilité

## Loi forte des grands nombres

### Loi forte

- $(X_n)_{n \in \mathbb{N}}$  : suite de variables aléatoires
  - de même loi
  - d'espérance  $m$
  - possédant une variance  $\sigma^2$
  - **mutuellement** indépendantes
- alors la suite des variables  $\bar{X}_n = \frac{\sum_{k=1}^n X_k}{n}$  converge presque sûrement vers  $m$

**Interprétation** : échantillon de grande taille  $\implies$  bonne estimation de  $m$

## Définition

- $(X_n)_{n \in \mathbb{N}}$  : suite de variables
- $F_n$  : fonction de répartition de  $X_n$
- $X$  : variable de fonction de répartition  $F$
- La suite  $X_n$  **converge en loi** vers  $X$  lorsque  $F_n(x)$  tend vers  $F(x)$  en tout point de continuité de  $F$

**Notation** :  $X_n \xrightarrow{\text{loi}} X$

# Théorème central-limite

## Théorème central-limite

- $(X_n)_{n \in \mathbb{N}}$  : suite de variables
  - de même loi
  - d'espérance  $\mu$
  - de variance  $\sigma^2$
  - **mutuellement** indépendantes
- alors la suite des moyennes empiriques centrées réduites  $\frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}}$  tend en loi vers la loi normale centrée réduite :

$$\frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \xrightarrow{\text{loi}} \mathcal{N}(0, 1)$$


# Illustration du théorème central-limite (1/4)

Lancés de dés à 6 faces




$$\Rightarrow \begin{cases} X_i = \text{résultat du jet du } i\text{ème dé} \\ \bar{X}_n = \text{somme des résultats des dés} \end{cases}$$

distribution de  $\bar{X}_n$  pour 1 jet de dé




## Illustration du théorème central-limite (2/4)

distribution de  $\bar{X}_n$  pour 2 jets de dés




## Illustration du théorème central-limite (3/4)

distribution de  $\bar{X}_n$  pour 3 jets de dés



## Illustration du théorème central-limite (4/4)

distribution de  $\bar{X}_n$  pour 4 jets de dés



### Statistique inférentielle

#### Hypothèses :

- les données = les observations
- observations  $(x_1, \dots, x_n)$  = réalisation d'une variable aléatoire multidimensionnelle  $X = (X_1, \dots, X_n)$
- observations = *échantillon empirique*
- l'échantillon est tiré suivant une loi  $X_0$
- chaque variable  $X_i$  suit la même loi que  $X_0$

#### But :

- déduire des informations sur  $X_0$

### Exemples :

- sondages électoraux, études de marché
- tests de fiabilité/qualité
- bases de données  $\implies$  diagnostic

### Idée force

Dans moult études statistiques :

- population de grande taille  
 $\implies$  impossible de la connaître précisément
- possibilité de prélever des échantillons

$\implies$  étudier l'échantillon et en déduire les caractéristiques de la population




**caractéristiques** : moyenne  $\mu$ , variance  $\sigma^2$ , proportion de succès  $p$

## Échantillonnage (1/2)

caractéristique de la population  $\Leftarrow$  échantillon

$\Rightarrow$  **problème** : comment prélever l'échantillon ?



### Définition d'un échantillon

**Échantillon** d'une population = sous-ensemble **représentatif** de la population

$\Rightarrow$  composition de l'échantillon due au hasard

## Échantillonnage (2/2)

### Prélèvement d'un échantillon

2 manières de prélever un échantillon aléatoirement :

- 1 **Échantillonnage avec remise** :  
choisir un individu au hasard  
noter la valeur de la variable d'intérêt pour celui-ci  
remettre l'individu dans la population  
réitérer le processus
- 2 **Échantillonnage sans remise** :  
même procédé mais sans remettre dans la population  
les individus sélectionnés

⚠ échantillonnage avec remise  $\Rightarrow$  un individu peut apparaître plusieurs fois dans l'échantillon

⚠ population de grande taille  $\Rightarrow$  avec remise  $\approx$  sans remise

## Estimation de la moyenne d'une population (1/4)

⚠ résultats suivant variables uniquement pour des échantillons **avec remise**

$\Rightarrow$  on va travailler avec des échantillons i.i.d :

### Échantillon i.i.d

- échantillon de  $n$  individus
  - $X_i$  = variable aléatoire « valeur du  $i$ ème individu tiré »
  - les  $X_i$  sont mutuellement indépendants
  - les  $X_i$  ont tous la même distribution
- $\Rightarrow$  les  $X_i$  sont indépendants et identiquement distribués (i.i.d)

échantillons i.i.d  $\Rightarrow$  bonnes propriétés mathématiques

## Estimation de la moyenne d'une population (2/4)

- $X$  variable aléatoire sur l'ensemble de la population
- espérance :  $\mu$ , variance :  $\sigma^2$
- échantillon de  $n$  individus  $\implies$  observation de  $n$  valeurs de  $X$
- $X_i$  : variable aléatoire correspondant au  $i$ ème individu
- échantillon i.i.d  $\implies$  espérance de  $X_i$  :  $\mu$ , variance de  $X_i$  :  $\sigma^2$
- $\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$  = moyenne de l'échantillon

**Problèmes** : que valent  $E(\bar{X})$  et  $V(\bar{X})$  ?

## Estimation de la moyenne d'une population (3/4)

- $$\begin{aligned} E(\bar{X}) &= \frac{1}{n} E(X_1 + X_2 + \dots + X_n) \\ &= \frac{1}{n} (E(X_1) + E(X_2) + \dots + E(X_n)) \\ &= \frac{1}{n} (\mu + \mu + \dots + \mu) = \mu \end{aligned}$$

variables  $X_i$  mutuellement indépendantes  $\implies$

- $$\begin{aligned} V(\bar{X}) &= V\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = \frac{1}{n^2} V(X_1 + X_2 + \dots + X_n) \\ &= \frac{1}{n^2} (V(X_1) + V(X_2) + \dots + V(X_n)) \\ &= \frac{1}{n^2} (\sigma^2 + \sigma^2 + \dots + \sigma^2) = \frac{\sigma^2}{n} \end{aligned}$$

## Estimation de la moyenne d'une population (4/4)

### *Théorème 1*

- $X$  : variable aléatoire
- espérance de  $X$  :  $\mu$ , variance de  $X$  :  $\sigma^2$
- échantillon de taille  $n$  avec remise sur  $X$
- $\bar{X}$  : variable aléatoire « moyenne de l'échantillon »
- Alors :  $E(\bar{X}) = \mu$  et  $V(\bar{X}) = \frac{\sigma^2}{n}$


### *Corollaire*

- $X$  : variable aléatoire suivant une loi normale  $\mathcal{N}(\mu; \sigma^2)$
- échantillon de taille  $n$  avec remise sur  $X$
- $\bar{X}$  : variable aléatoire « moyenne de l'échantillon »
- Alors :  $\bar{X} \sim \mathcal{N}(\mu; \frac{\sigma^2}{n})$

## Exemple : calcul du handicap au bowling

### Compétition en 2 phases :

- 1ère phase : 6 parties
- calcul du handicap :  
Handicap  $H = (215 - \text{moyenne des 6 parties}) \times 60\%$
- 2ème phase : 6 parties (score + le handicap  $H$ )



- Calcul du handicap  $\implies$  estimation de votre niveau
- 6 parties de la 1ère phase = échantillon de taille 6
- $X_i$  = variable aléatoire « score de la  $i$ ème partie »

idée : scores de l'échantillon  $\implies$  score moyen de la population

## Retour sur l'estimation de la moyenne

**Problème :** que faire si  $X$  ne suit pas une loi normale ?


$\implies$  sauvé grâce au théorème central-limite :

### Théorème 2


- $X$  : variable aléatoire
- espérance de  $X$  :  $\mu$ , variance de  $X$  :  $\sigma^2$
- échantillon de taille  $n$  avec remise sur  $X$
- $n$  suffisamment grand ( $n \geq 30$  si la distribution de  $X$  n'est pas trop dissymétrique,  $n \geq 50$  sinon)
- $\bar{X}$  : variable aléatoire « moyenne de l'échantillon »

• Alors : 
$$\frac{\bar{X} - E(\bar{X})}{\sqrt{V(\bar{X})}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0; 1)$$

## Exemple 1 : la planche de Galton (1/2)



## Exemple 1 : la planche de Galton (2/2)



- chaque niveau  $\implies$  expérience de Bernoulli

- $\implies X \sim$  loi binomiale

- $\implies X \not\sim$  loi normale

- théorème 2  $\implies$

$$\frac{\bar{X} - E(\bar{X})}{\sqrt{V(\bar{X})}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0; 1)$$

## Exemple 2 : analyse des déchets

- Grenelle de l'environnement

- $\implies$  réduction des déchets

- $\implies$  analyse des déchets



- impossible à réaliser sur toute la population

- $\implies$  échantillon de taille 100 :

450	320	320	390	410	415	380	390
440	350	400	380	430	400	375	...

- moyenne de l'échantillon = 390 kg/an/habitant

- $\bar{X}$  : variable aléatoire « moyenne de l'échantillon »

- $\sigma = 20$  supposé connu

- $\bar{X} \sim \mathcal{N}(\mu, \frac{\sigma^2}{n}) \implies$  écart-type de  $\bar{X} = 20/10 = 2$

## Estimation de proportions de succès (1/3)

**Problème :**



- lancement de la Wii  $\implies$  étude de marché

- échantillon de taille  $n \implies$  succès = Wii, échec = PS3

- $p$  = proportion de succès dans toute la population

- $P_i$  : variable aléatoire « succès du  $i$ ème individu »

**Question :** peut-on déduire  $p$  en observant les  $p_i$  ?

## Estimation de proportions de succès (2/3)

**Question :** peut-on déduire  $p$  en observant les  $p_i$  ?

- $p$  = proportion de succès dans la population ( $p$  pas trop petit)
- échantillon i.i.d de taille  $n$  assez grand
- $P_i$  = variable aléatoire « succès du  $i$ ème individu »
- $P_i \sim$  loi binomiale  $\mathcal{B}(1, p)$
- $\bar{P}$  = moyenne de l'échantillon

Théorème central-limite  $\implies \frac{\bar{P} - E(\bar{P})}{\sqrt{V(\bar{P})}} \sim \mathcal{N}(0; 1)$

Or  $\bar{P} \sim \frac{1}{n}\mathcal{B}(n; p) \implies E(\bar{P}) = \frac{np}{n}$  et  $V(\bar{P}) = \frac{p(1-p)}{n}$

## Estimation de proportions de succès (3/3)

**Théorème 3**

- échantillon i.i.d de taille  $n$  assez grand
- $p$  = proportion de succès dans la population ( $p$  pas trop petit)
- $\bar{P}$  = moyenne de l'échantillon

• Alors :  $\frac{\bar{P} - E(\bar{P})}{\sqrt{V(\bar{P})}} = \frac{\bar{P} - p}{\sqrt{\frac{p(1-p)}{n}}} \sim \mathcal{N}(0; 1)$

$\implies$  on peut estimer  $p$  en observant la valeur de  $\bar{P}$

## Application du théorème précédent

**Expert :** 80%



v.s. 20%



- échantillon de 100 personnes  $\implies$  70 Wii et 30 PS3
- Doit-on croire l'expert ?

si  $p = 80\%$  alors Théorème 3  $\implies \frac{\bar{P} - 0,8}{\sqrt{\frac{0,8 \times 0,2}{100}}} = 25(\bar{P} - 0,8) \sim \mathcal{N}(0; 1)$

$\text{Prob}(\bar{P} \leq 0,7) = \text{Prob}(25(\bar{P} - 0,8) \leq 25 \times (0,7 - 0,8))$   
 $= \text{Prob}(25(\bar{P} - 0,8) \leq -2,5) \approx 0,62\%$

## Application au réchauffement climatique

- Avril 2007 : étude tms-sofres / CNRS :  
opinion des gens sur le réchauffement climatique
- 1000 personnes de 15 ans et + interrogées  
⇒ échantillon i.i.d
- 790 pensent qu'il y a un changement climatique
- 210 ne le pensent pas
- $\bar{P}$  : proportion de succès moyenne de l'échantillon
- $p$  : proportion de personnes pensant qu'il y a dérèglement climatique dans la population française



$$\frac{\bar{P} - p}{\sqrt{\frac{p(1-p)}{n}}} \sim \mathcal{N}(0; 1)$$

⇒ estimation de  $p = 79\%$ , écart-type de  $\bar{P} \leq \sqrt{\frac{0.25}{1000}} \approx 0,015$

## Caractéristiques des estimateurs

Transparents précédents ⇒ si échantillon de grande taille  
alors  $\bar{X} \approx \mu \Rightarrow$  estimer  $\mu$  par  $\bar{X}$

### Estimateur non biaisé

- Estimateur  $T$  d'un paramètre  $\theta \Rightarrow$  valeur estimée  $\hat{\theta}$
- $T$  non biaisé si  $E(T) = \theta$

⚠ estimateur biaisé ⇒ on surévalue ou sous-évalue  $\theta$

### Estimateur convergent

- Estimateur  $T$  d'un paramètre  $\theta$
- $T$  convergent si  $E[(T - \theta)^2] \rightarrow 0$  lorsque la taille de l'échantillon ↗

moyenne  $\bar{X}$  et proportion de succès  $\bar{P}$  :  
estimateurs non biaisés et convergents

## Biais : estimation ponctuelle d'une variance (1/5)

- population = 4 nombres {1, 2, 3, 4}
- $\mu = \frac{5}{2}$  et  $\sigma^2 = \frac{5}{4}$
- échantillon de taille 2 avec remise :

échant.	espérance	variance	échant.	espérance	variance
1 1	$E(\bar{X}) = 1$	$V(\bar{X}) = 0$	1 2	$E(\bar{X}) = \frac{3}{2}$	$V(\bar{X}) = \frac{1}{4}$
1 3	$E(\bar{X}) = 2$	$V(\bar{X}) = 1$	1 4	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{9}{4}$
2 1	$E(\bar{X}) = \frac{3}{2}$	$V(\bar{X}) = \frac{1}{4}$	2 2	$E(\bar{X}) = 2$	$V(\bar{X}) = 0$
2 3	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{1}{4}$	2 4	$E(\bar{X}) = 3$	$V(\bar{X}) = 1$
3 1	$E(\bar{X}) = 2$	$V(\bar{X}) = 1$	3 2	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{1}{4}$
3 3	$E(\bar{X}) = 3$	$V(\bar{X}) = 0$	3 4	$E(\bar{X}) = \frac{7}{2}$	$V(\bar{X}) = \frac{1}{4}$
4 1	$E(\bar{X}) = \frac{5}{2}$	$V(\bar{X}) = \frac{9}{4}$	4 2	$E(\bar{X}) = 3$	$V(\bar{X}) = 1$
4 3	$E(\bar{X}) = \frac{7}{2}$	$V(\bar{X}) = \frac{1}{4}$	4 4	$E(\bar{X}) = 4$	$V(\bar{X}) = 0$

- espérance  $\left\{ \begin{array}{l} \text{des moyennes des échantillons} = \mu \\ \text{des variances des échantillons} = \frac{5}{8} \neq \frac{5}{4} \end{array} \right. \Rightarrow$  biais !

## Biais : estimation ponctuelle d'une variance (2/5)

- $X$  : variable aléatoire sur l'ensemble de la population
- $\sigma^2$  : variance de  $X$
- échantillon i.i.d. de taille  $n$
- $X_i$  : variable aléatoire correspondant au  $i$ ème individu
- $x_i$  : valeur observée de  $X_i$
- $\bar{X}$  : variable aléatoire « moyenne sur l'échantillon »
- $\bar{x}$  : valeur observée de  $\bar{X}$
- $s_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \left( \sum_{i=1}^n x_i^2 \right) - \bar{x}^2$
- $s_n^2$  = variance de l'échantillon


**Problème** : pourquoi  $s_n^2$  n'est-il pas un bon estimateur de  $\sigma^2$  ?

## Biais : estimation ponctuelle d'une variance (3/5)

- $S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \left( \sum_{i=1}^n X_i^2 \right) - \bar{X}^2$
- $s_n^2$  est une réalisation de  $S_n^2$
- $E(S_n^2) = E \left( \frac{1}{n} \left( \sum_{i=1}^n X_i^2 \right) - \bar{X}^2 \right) = \frac{1}{n} \left( \sum_{i=1}^n E(X_i^2) \right) - E(\bar{X}^2)$
- Or échantillon i.i.d  $\Rightarrow \forall i, E(X_i^2) = E(X^2)$   
 $\Rightarrow E(S_n^2) = E(X^2) - E(\bar{X}^2)$
- Or  $V(X) = E(X^2) - E(X)^2$  et  $V(\bar{X}) = E(\bar{X}^2) - E(\bar{X})^2 = E(\bar{X}^2) - E(X)^2$   
 $\Rightarrow E(S_n^2) = V(X) + E(X)^2 - V(\bar{X}) - E(X)^2 = V(X) - V(\bar{X})$
- Or échantillon i.i.d  $\Rightarrow V(X) = \sigma^2$  et  $V(\bar{X}) = \frac{\sigma^2}{n}$

$$\Rightarrow E(S_n^2) = \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2$$

## Biais : estimation ponctuelle d'une variance (4/5)



- courbe verte : la population
- courbes rouges : échantillons
- pts bleus : valeurs observées
- variance  $S_n^2$  sous-estimée : mesurée par rapport à la moyenne de l'échantillon au lieu de la moyenne de la population

### Variance corrigée

- $X$  : variable aléatoire sur la population
- $\sigma^2$  : variance de  $X$  sur cette population
- échantillon de taille  $n$  avec remise
- $X_i$  : variable aléatoire correspondant au  $i$ ème individu
- $\bar{X}$  : moyenne des  $X_i$
- alors :  $E\left(\frac{n}{n-1} \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{n}\right) = \sigma^2$
- **Variance corrigée** :  $\frac{n}{n-1}$  fois la variance de l'échantillon  $S_n^2$

# RFIDEC — cours 3 : Intervalles de confiance, tests d'hypothèses, loi du $\chi^2$

Christophe Gonzales

LIP6 – Université Paris 6, France

## Plan du cours n°3

- 1 Intervalles de confiance
- 2 Tests d'hypothèses
- 3 La loi du  $\chi^2$

RFIDEC — cours 3 : Intervalles de confiance, tests d'hypothèses, loi du  $\chi^2$  2/34

## Intervalles de confiance

Estimateur  $T$  d'un paramètre  $\theta \implies$  valeur estimée  $\hat{\theta}$

Problème : peut-on avoir confiance dans l'estimation ponctuelle ?

*Intervalle de confiance*

Un *intervalle de confiance* de niveau  $1 - \alpha$  = intervalle  
 $]a(T), b(T)[$  tel que :

$$\forall \theta \in \Theta, P_{\theta}([a(T), b(T)] \ni \theta) = 1 - \alpha$$



$1 - \alpha$  = proba que l'intervalle contienne  $\theta$

RFIDEC — cours 3 : Intervalles de confiance, tests d'hypothèses, loi du  $\chi^2$  3/34

## Intervalles de confiance : exemple (1/2)

$$X \sim \mathcal{N}(\mu; \sigma^2)$$

échantillon de taille  $n \Rightarrow \bar{X}$  = moyenne

$$\text{théorème central-limite} \Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0; 1)$$

$$\begin{cases} n \text{ très grand} \Rightarrow \text{la valeur observée } \bar{x} \text{ de } \bar{X} \approx \mu \\ n \text{ moins grand} \Rightarrow \bar{x} \not\approx \mu \end{cases}$$

$\Rightarrow$  estimation par intervalle de confiance de niveau 95%

$$\text{loi normale} \Rightarrow P\left(-1,96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1,96\right) = 95\%$$

## Intervalles de confiance : exemple (2/2)

$$P\left(-1,96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1,96\right) = 95\%$$

$$P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = 95\%$$

$$\Rightarrow \text{intervalle de confiance} = \left] \bar{x} - 1,96 \frac{\sigma}{\sqrt{n}}, \bar{x} + 1,96 \frac{\sigma}{\sqrt{n}} \right[$$

 seulement maintenant, on tire un échantillon de taille  $n$

$\Rightarrow$  observation de  $\bar{x}$

$$\Rightarrow \text{on peut calculer} \left] \bar{x} - 1,96 \frac{\sigma}{\sqrt{n}}, \bar{x} + 1,96 \frac{\sigma}{\sqrt{n}} \right[$$

## Intervalles de confiance : autre exemple (1/2)

### Énoncé de l'exemple

- plusieurs centaines de candidats à un examen
- variance sur les notes obtenues  $\approx 16$
- correcteur  $\Rightarrow$  noté 100 copies, moyenne = 8,75
- Problème : moyenne sur toutes les copies de l'examen ?
- hypothèse : les notes suivent une loi normale  $\mathcal{N}(\mu; 16)$

$\bar{X}$  = variable aléatoire « moyenne des notes d'un correcteur »

$$\text{théorème central-limite} \Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X} - \mu}{4/10} \sim \mathcal{N}(0; 1)$$

chercher dans la table de la loi normale  $z_{\alpha/2}$  tel que :

$$P\left(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

## Intervalle de confiance : autre exemple (2/2)

$$P\left(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

$1 - \alpha$	intervalle de confiance
50%	$[8,75 - 0,674 \times 0,4; 8,75 + 0,674 \times 0,4] = [8,48; 9,02]$
75%	$[8,75 - 1,15 \times 0,4; 8,75 + 1,15 \times 0,4] = [8,29; 9,21]$
80%	$[8,75 - 1,28 \times 0,4; 8,75 + 1,28 \times 0,4] = [8,24; 9,26]$
90%	$[8,75 - 1,645 \times 0,4; 8,75 + 1,645 \times 0,4] = [8,09; 9,41]$
95%	$[8,75 - 1,96 \times 0,4; 8,75 + 1,96 \times 0,4] = [7,96; 9,53]$
99%	$[8,75 - 2,575 \times 0,4; 8,75 + 2,575 \times 0,4] = [7,72; 9,78]$

## Exemple : analyse des déchets (cf. cours 2)

- Grenelle de l'environnement

⇒ réduction des déchets

⇒ analyse des déchets

⇒ échantillon de taille 100



- $\bar{x}$  : moyenne de l'échantillon = 390 kg/an/habitant

- écart-type  $\sigma = 20$  supposé connu

- $\bar{X} \sim \mathcal{N}(\mu, 4)$

$$\Rightarrow P\left(-Z_{\alpha/2} \leq \frac{\bar{X} - \mu}{2} \leq Z_{\alpha/2}\right) = 1 - \alpha$$

⇒ estimation par intervalle de confiance de niveau  $1 - \alpha$  :

$$]\bar{x} - 2z_{\alpha/2}, \bar{x} + 2z_{\alpha/2}[$$

## Exemple : analyse des déchets (suite)

Estimation par intervalle de confiance de niveau  $1 - \alpha$  :

$$]\bar{x} - 2z_{\alpha/2}, \bar{x} + 2z_{\alpha/2}[$$

$1 - \alpha$	intervalle de confiance
50%	$[390 - 0,674 \times 2; 390 + 0,674 \times 2] = [388,65; 391,35]$
75%	$[390 - 1,15 \times 2; 390 + 1,15 \times 2] = [387,70; 392,30]$
80%	$[390 - 1,28 \times 2; 390 + 1,28 \times 2] = [387,44; 392,56]$
90%	$[390 - 1,645 \times 2; 390 + 1,645 \times 2] = [386,71; 393,29]$
95%	$[390 - 1,96 \times 2; 390 + 1,96 \times 2] = [386,08; 393,92]$
99%	$[390 - 2,575 \times 2; 390 + 2,575 \times 2] = [384,85; 395,15]$

## Exemple du réchauffement climatique (cf. cours 2)

- opinion des gens sur le réchauffement climatique
- 1000 personnes de 15 ans et + interrogées
- 790 pensent qu'il y a un changement climatique
- 210 ne le pensent pas
- $\bar{P}$  : proportion de succès moyenne de l'échantillon
- $p$  : proportion de personnes pensant qu'il y a dérèglement climatique dans la population française



$$\frac{\bar{P} - p}{\sqrt{\frac{p(1-p)}{n}}} \sim \mathcal{N}(0; 1)$$

⇒ estimation par intervalle de confiance de niveau  $1 - \alpha$  :

$$\left] \bar{p} - \sqrt{\frac{p(1-p)}{n}} z_{\alpha/2}; \bar{p} + \sqrt{\frac{p(1-p)}{n}} z_{\alpha/2} \left[ \approx \left] \bar{p} - \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} z_{\alpha/2}; \bar{p} + \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} z_{\alpha/2} \left[$$

## Tests d'hypothèses en statistique classique (1/2)

### Hypothèses

- $\Theta$  = ensemble des valeurs du paramètre  $\theta$
- $\Theta$  partitionné en  $\Theta_0$  et  $\Theta_1$
- **hypothèses** = assertions  $H_0 = " \theta \in \Theta_0 "$  et  $H_1 = " \theta \in \Theta_1 "$
- $H_0$  = **hypothèse nulle**,  $H_1$  = **contre-hypothèse**
- hypothèse  $H_i$  est **simple** si  $\Theta_i$  est un singleton ;  
sinon elle est **multiple**
- test **unilatéral** = valeurs dans  $\Theta_1$  toutes soit plus grandes,  
soit plus petites, que celles dans  $\Theta_0$  ; sinon test **bilatéral**

## Tests d'hypothèses en statistique classique (2/2)

	hypothèse	test
$H_0 : \mu = 4$ $H_1 : \mu = 6$	simple simple	unilatéral
$H_0 : \mu = 4$ $H_1 : \mu > 4$	simple composée	test unilatéral
$H_0 : \mu = 4$ $H_1 : \mu \neq 4$	simple composée	test bilatéral
$H_0 : \mu = 4$ $H_1 : \mu > 3$	simple composée	formulation incorrecte : les hypothèses ne sont pas mutuellement exclusives

## Exemples pratiques d'hypothèses

- association de consommateurs
- échantillon de 100 bouteilles de Bordeaux
- **Pb** : la quantité de vin est-elle bien égale à 75cl ?



- paramètre  $\theta$  étudié =  $\mu = E(X)$
- $X$  = quantité de vin dans les bouteilles
- rôle de l'association  $\implies H_0 : \mu = 75\text{cl}$  et  $H_1 : \mu < 75\text{cl}$

- le mois dernier, taux de chômage = 10%
- échantillon : 400 individus de la pop. active
- **Pb** : le taux de chômage a-t-il été modifié ?



- paramètre étudié =  $p = \%$  de chômeurs
- $H_0 : p = 10\%$  et  $H_1 : p \neq 10\%$

## Tests d'hypothèse

### Définition du test

- test entre deux hypothèses  $H_0$  et  $H_1 =$  **règle de décision**  $\delta$
- règle fondée sur les observations
- ensemble des décisions possibles =  $\mathcal{D} = \{d_0, d_1\}$
- $d_0 =$  "accepter  $H_0$ "
- $d_1 =$  "accepter  $H_1$ " = "rejeter  $H_0$ "

### région critique

- échantillon  $\implies n$ -uplet  $(x_1, \dots, x_n)$  de valeurs (dans  $\mathbb{R}$ )
- $\delta =$  fonction  $\mathbb{R}^n \mapsto \mathcal{D}$
- **région critique** :  $W = \{n\text{-uplets } \mathbf{x} \in \mathbb{R}^n : \delta(\mathbf{x}) = d_1\}$
- région critique = **région de rejet**
- **région d'acceptation** =  $A = \{\mathbf{x} \in \mathbb{R}^n : \delta(\mathbf{x}) = d_0\}$

## Régions critiques

Hypothèses	Règle de décision
$H_0 : \mu = \mu_0$ $H_1 : \mu > \mu_0$	« rejeter $H_0$ si $\bar{x} > c$ », où $c$ est un nombre plus grand que $\mu_0$
$H_0 : \mu = \mu_0$ $H_1 : \mu < \mu_0$	« rejeter $H_0$ si $\bar{x} < c$ », où $c$ est un nombre plus petit que $\mu_0$
$H_0 : \mu = \mu_0$ $H_1 : \mu \neq \mu_0$	« rejeter $H_0$ si $\bar{x} < c_1$ ou $c_2 < \bar{x}$ », où $c_1$ et $c_2$ sont des nombres respectivement plus petit et plus grand que $\mu_0$ , et également éloignés de celui-ci

**Problème** : erreurs dans les décisions prises

## Erreurs dans les décisions

Décision prise \ Réalité	$H_0$ est vraie	$H_1$ est vraie
	$H_0$ est rejetée	mauvaise décision : erreur de type I
$H_0$ n'est pas rejetée	bonne décision	mauvaise décision : erreur de type II

$\alpha$  = risque de première espèce  
 = probabilité de réaliser une erreur de type I  
 = probabilité de rejeter  $H_0$  sachant que  $H_0$  est vraie  
 =  $P(\text{rejeter } H_0 | H_0 \text{ est vraie})$ ,

$\beta$  = risque de deuxième espèce  
 = probabilité de réaliser une erreur de type II  
 = probabilité de rejeter  $H_1$  sachant que  $H_1$  est vraie  
 =  $P(\text{rejeter } H_1 | H_1 \text{ est vraie})$ .

## Exemple de calcul de $\alpha$ (1/2)

### Exemple

- échantillon de taille 25
- paramètre estimé :  $\mu$  d'une variable  $X \sim \mathcal{N}(\mu; 100)$
- hypothèses :  $H_0 : \mu = 10$      $H_1 : \mu > 10$

$$\text{Sous } H_0 : \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X} - 10}{10/5} = \frac{\bar{X} - 10}{2} \sim \mathcal{N}(0; 1)$$

Sous  $H_0$  : peu probable que  $\bar{X}$  éloignée de plus de 2 écarts-types de  $\mu$  (4,56% de chance)

$\Rightarrow$  peu probable que  $\bar{X} < 6$  ou  $\bar{X} > 14$

$\Rightarrow$  région critique pourrait être « rejeter  $H_0$  si  $\bar{x} > 14$  »

## Exemple de calcul de $\alpha$ (2/2)

- échantillon de taille 25
- paramètre estimé :  $\mu$  d'une variable  $X \sim \mathcal{N}(\mu; 100)$
- hypothèses :  $H_0 : \mu = 10$      $H_1 : \mu > 10$
- région critique : « rejeter  $H_0$  si  $\bar{x} > 14$  »


$$\begin{aligned}
 \alpha &= P(\text{rejeter } H_0 | H_0 \text{ est vraie}) \\
 &= P(\bar{X} > 14 | \mu = 10) \\
 &= P\left(\frac{\bar{X} - 10}{2} > \frac{14 - 10}{2} \middle| \mu = 10\right) \\
 &= P\left(\frac{\bar{X} - 10}{2} > 2\right) = 0,0228
 \end{aligned}$$



en principe  $\alpha$  est fixé et on cherche la région critique

## Exemple de test d'hypothèses (1/2)

- filtre de mails sur un serveur mail :



- $X = \text{score} \geq 18000 \implies \text{spam}$  ; historiques des mails  $\implies \sigma_X = 5000$
- le serveur reçoit un envoi en masse de  $n = 400$  mails de  $xx@yy.fr$
- **Problème** :  $xx@yy.fr$  est-il un spammeur ?
- $H_0 : xx@yy.fr = \ll \text{spammeur} \gg$  v.s.  $H_1 : xx@yy.fr \neq \ll \text{spammeur} \gg$
- test :  $H_0 : \mu = 18000$  v.s.  $H_1 : \mu < 18000$  où  $\mu = E(X)$
- règle : si  $\bar{x} < c$  alors rejeter  $H_0$
- 400 mails  $\implies$  théorème central limite  $\implies$  sous  $H_0$  :

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X} - 18000}{5000/\sqrt{400}} = \frac{\bar{X} - 18000}{250} \sim \mathcal{N}(0; 1)$$

## Exemple de test d'hypothèses (2/2)

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X} - 18000}{5000/\sqrt{400}} = \frac{\bar{X} - 18000}{250} \sim \mathcal{N}(0; 1)$$

- choix du risque de première espèce :  $\alpha = 0,01$
- $\alpha = 0,01 = P(\bar{X} < c | \mu = 18000)$ 

$$= P\left(\frac{\bar{X} - 18000}{250} < \frac{c - 18000}{250} \mid \mu = 18000\right)$$


$$= P\left(Z < \frac{c - 18000}{250}\right)$$

$$= P(Z < -2,326)$$

$$\implies \frac{c - 18000}{250} = -2,326 \implies c = 17418,5$$

règle de décision : si  $\bar{x} < 17418,5$ , rejeter  $H_0 \implies$  non spam

## Interprétation de $\alpha$ et $\beta$



## Puissance du test

$$\alpha = P(\text{rejeter } H_0 | H_0 \text{ est vraie})$$

$$\beta = P(\text{rejeter } H_1 | H_1 \text{ est vraie})$$

$\alpha$  et  $\beta$  varient en sens inverse l'un de l'autre

⇒ test = compromis entre les deux risques

$H_0$  = hypothèse privilégiée, vérifiée jusqu'à présent et que l'on n'aimerait pas abandonner à tort

⇒ on fixe un *seuil*  $\alpha_0$  :

- $\alpha \leq \alpha_0$
- test minimisant  $\beta$  sous cette contrainte
- $\min \beta = \max 1 - \beta$

$$1 - \beta = \text{puissance du test}$$

## Exemple de calcul de $\beta$ (1/2)

- échantillon de taille 25
- paramètre estimé :  $\mu$  d'une variable  $X \sim \mathcal{N}(\mu; 100)$
- hypothèses :  $H_0 : \mu = 10$      $H_1 : \mu > 10$
- région critique : « rejeter  $H_0$  si  $\bar{x} > 14$  »

sous  $H_1$  : plusieurs valeurs de  $\mu$  sont possibles

⇒ courbe de puissance du test en fonction de  $\mu$

Supposons que  $\mu = 11$  :

$$\mu = 11 \Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X} - 11}{2} \sim \mathcal{N}(0; 1)$$

## Exemple de calcul de $\beta$ (2/2)

$$1 - \beta(11) = P(\text{rejeter } H_0 | H_1 : \mu = 11 \text{ est vraie})$$


$$= P(\bar{X} > 14 | \mu = 11)$$

$$= P\left(\frac{\bar{X} - 11}{2} > \frac{14 - 11}{2} \mid \mu = 11\right)$$

$$= P\left(\frac{\bar{X} - 11}{2} > 1,5\right) = 0,0668$$

$\mu_1$	$z_1 = \frac{14 - \mu_1}{2}$	$1 - \beta(\mu_1) = P(Z > z_1)$	$\beta(\mu_1)$
10	2,0	0,0228	0,9772
11	1,5	0,0668	0,9332
12	1,0	0,1587	0,8413
13	0,5	0,3085	0,6915
14	0,0	0,5000	0,5000
15	-0,5	0,6915	0,3085
16	-1,0	0,8413	0,1587
17	-1,5	0,9332	0,0668

## Courbe de puissance du test



## Exemple : notes d'examen de RFIDEC (1/3)

- les années précédentes, notes d'examen  $\sim \mathcal{N}(14, 6^2)$
- cette année, correction d'un échantillon de 9 copies :

10	8	13	20	12	14	9	7	15
----	---	----	----	----	----	---	---	----

Les notes sont-elles en baisse cette année ?

- hypothèse  $H_0 = \ll$  la moyenne est égale à 14  $\gg$
- hypothèse  $H_1 = \ll$  la moyenne a baissé, i.e., elle est  $\leq 14$   $\gg$
- test d'hypothèse de niveau de confiance  $1 - \alpha = 95\%$
- $\implies$  déterminer seuil  $c$  tel que  $\bar{x} < c \implies H_1$  plus probable que  $H_0$

## Exemple : notes d'examen de RFIDEC (2/3)

10	8	13	20	12	14	9	7	15
----	---	----	----	----	----	---	---	----

$H_0 : \mu = 14, \sigma = 6$

- sous hypothèse  $H_0$ , on sait que  $\frac{\bar{X} - 14}{\sigma/\sqrt{n}} = \frac{\bar{X} - 14}{2} \sim \mathcal{N}(0; 1)$
- calcul du seuil  $c$  (région de rejet) :  

$$P\left(\frac{\bar{X} - 14}{2} < \frac{c - 14}{2} \mid \frac{\bar{X} - 14}{2} \sim \mathcal{N}(0; 1)\right) = 0,05$$
- Table de la loi normale :  $\frac{c-14}{2} \approx -1,645 \implies c = 10,71$
- **Règle de décision** : rejeter  $H_0$  si  $\bar{x} < 10,71$
- tableau  $\implies \bar{x} = 12$   
 $\implies$  on ne peut déduire que la moyenne a diminué

## Exemple : notes d'examen de RFIDEC (3/3)

Problème : le risque de 2ème espèce est-il élevé ?

Puissance du test pour une moyenne de 12

- $H_1$  : la moyenne est égale à 12
- Puissance du test =  $1 - \beta(12)$ 
  - =  $P(\text{rejeter } H_0 | H_1)$
  - =  $P\left(\bar{X} < 10,71 \mid \frac{\bar{X}-12}{2} \sim \mathcal{N}(0; 1)\right)$
  - =  $P\left(\frac{\bar{X}-12}{2} < -0,645 \mid \frac{\bar{X}-12}{2} \sim \mathcal{N}(0; 1)\right)$
  - $\approx 25,95\%$ .

## Lemme de Neyman-Pearson (1/2)

Cas :  $\Theta_0 = \{\theta_0\}$      $\Theta_1 = \{\theta_1\}$

- Échantillon  $(x_1, \dots, x_n)$  de taille  $n$
- Échantillon  $\implies$  les  $x_i$  = réalisations de variables aléatoires  $X_i$
- Échantillon i.i.d.  $\implies$  les  $X_i$  sont mutuellement indépendants  
 $\implies P(X_1 = x_1, \dots, X_n = x_n | \theta = \theta_k) = \prod_{i=1}^n P(X_i = x_i | \theta = \theta_k)$

*Vraisemblance d'un échantillon*

- $x = (x_1, \dots, x_n)$  : échantillon de taille  $n$
- $L(x, \theta_k)$  = Vraisemblance de l'échantillon
- $L(x, \theta_k)$  = proba d'obtenir **cet** échantillon sachant que  $\theta = \theta_k$

$$L(x, \theta_k) = P(x_1, \dots, x_n | \theta = \theta_k) = \prod_{i=1}^n P(x_i | \theta = \theta_k)$$

## Lemme de Neyman-Pearson (2/2)

Cas :  $\Theta_0 = \{\theta_0\}$      $\Theta_1 = \{\theta_1\}$

*Lemme de Neyman-Pearson*

- il existe toujours un test (aléatoire) le plus puissant de seuil donné  $\alpha_0$
- c'est un test du rapport de vraisemblance :

$$\frac{L(x, \theta_0)}{L(x, \theta_1)} > k \implies x \in A \text{ (accepter } H_0)$$

$$\frac{L(x, \theta_0)}{L(x, \theta_1)} < k \implies x \in W \text{ (rejeter } H_0)$$

$$\frac{L(x, \theta_0)}{L(x, \theta_1)} = k \implies \delta(x) = \rho \text{ (accepter } H_0 \text{ avec proba } 1 - \rho$$

$H_1$  avec proba  $\rho$ )

- $k$  et  $\rho$  déterminés de façon unique par  $\alpha = \alpha_0$

## Loi du $\chi^2$ (1/3)

- population  $\implies$  répartie en  $k$  classes

$p_1$	$p_2$	$p_3$		$p_k$
-------	-------	-------	--	-------

- hypothèse : répartition dans les classes connues  
 $\implies p_r =$  proba qu'un individu appartienne à la classe  $c_r$
- échantillon de  $n$  individus
- $N_r =$  variable aléatoire « nombre d'individus tirés de classe  $c_r$  »
- Chaque individu  $\implies p_r$  chances d'appartenir à la classe  $c_r$   
 $\implies X_i^r =$  v.a. succès si l'individu  $i$  appartient à la classe  $c_r$   
 $\implies X_i^r \sim \mathcal{B}(1, p_r)$   
 $\implies N_r \sim \mathcal{B}(n, p_r)$   
 $\implies N_r \sim$  loi normale quand  $n$  grand

## Loi du $\chi^2$ (2/3)

- population  $\implies$  répartie en  $k$  classes

$p_1$	$p_2$	$p_3$		$p_k$
-------	-------	-------	--	-------

- $p_r =$  proba qu'un individu appartienne à la classe  $c_r$
- échantillon de  $n$  individus
- $N_r =$  v.a. « nb d'individus tirés de classe  $c_r$  »  $\sim$  loi normale

$$D_{(n)}^2 = \sum_{r=1}^k \frac{(N_r - n.p_r)^2}{n.p_r}$$

$\implies D_{(n)}^2 =$  somme des carrés de  $k$  v.a.  $\sim$  lois normales

- $D_{(n)}^2 =$  écart entre théorie et observation
- $D_{(n)}^2$  tend en loi, lorsque  $n \rightarrow \infty$ , vers une loi du  $\chi_{k-1}^2$


## Loi du $\chi^2$ (3/3)

### Loi du $\chi^2$

- loi du  $\chi_r^2 =$  la loi de la somme des carrés de  $r$  variables indépendantes et de même loi  $\mathcal{N}(0, 1)$
- espérance =  $r$
- variance =  $2r$

## Table de la loi du $\chi^2$

valeurs dans le tableau  
ci-dessous : les  $c_{n,\alpha}$   
tels que  $P(Z > c_{n,\alpha}) = \alpha$



$n \setminus \alpha$	0,995	0,99	0,975	0,95	0,90	0,10	0,05	0,025	0,01	0,005
1	0,00004	0,0002	0,001	0,0039	0,0158	2,71	3,84	5,02	6,63	7,88
2	0,0100	0,0201	0,0506	0,103	0,211	4,61	5,99	7,38	9,21	10,6
3	0,0717	0,115	0,216	0,352	0,584	6,25	7,81	9,35	11,3	12,8
4	0,207	0,297	0,484	0,711	1,06	7,78	9,49	11,1	13,3	14,9
5	0,412	0,554	0,831	1,15	1,61	9,24	11,1	12,8	15,1	16,7
6	0,676	0,872	1,24	1,64	2,20	10,6	12,6	14,4	16,8	18,5
7	0,989	1,24	1,69	2,17	2,83	12,0	14,1	16,0	18,5	20,3
8	1,34	1,65	2,18	2,73	3,49	13,4	15,5	17,5	20,1	22,0
9	1,73	2,09	2,70	3,33	4,17	14,7	16,9	19,0	21,7	23,6
10	2,16	2,56	3,25	3,94	4,87	16,0	18,3	20,5	23,2	25,2

# RFIDEC — cours 4 : Tests d'ajustement, apprentissage de paramètres

Christophe Gonzales

LIP6 – Université Paris 6, France

## Plan du cours n°4

- 1 Tests d'ajustement
- 2 Tests d'indépendance
- 3 Application aux réseaux bayésiens
- 4 Maximum de vraisemblance

## Tests d'ajustement

### Définition

- test d'ajustement = test  $\implies$  2 issues possibles :
  - 1 acceptation de l'hypothèse que l'échantillon observé est tiré selon une certaine loi
  - 2 rejet de l'hypothèse 1
- contre-hypothèse : ne précise pas de quelle autre loi l'échantillon aurait pu être tiré

## Tests d'ajustement II : le retour du $\chi^2$

- population répartie en  $k$  classes
- échantillon de taille  $n \implies$  répartition =  $(n_1, \dots, n_k)$
- supposons l'échantillon tiré selon la loi multinomiale  $(p_1, \dots, p_k)$   
 $\implies (n_1, \dots, n_k) \approx (n.p_1, \dots, n.p_k)$

$$\text{Rappel : } D_{(n)}^2 = \sum_{r=1}^k \frac{(N_r - n.p_r)^2}{n.p_r} \sim \chi_{k-1}^2$$


- $d^2$  valeur prise par  $D_{(n)}^2$   
 $\implies$  si échantillon tiré selon  $(p_1, \dots, p_k)$  alors  $d^2$  petit
- table de la loi du  $\chi^2 \implies d_\alpha^2$  tel que  $P(\chi_{k-1}^2 > d_\alpha^2) = \alpha$   
 $\implies$  règle de décision : si  $d^2 < d_\alpha^2$  alors OK

## Tests d'ajustement en pratique

### Mise en place d'un test d'ajustement

- 1 population répartie en  $k$  classes
- 2 échantillon de taille  $n \implies$  répartition =  $(n_1, \dots, n_k)$
- 3 on vérifie si l'échantillon tiré selon la loi  $(p_1, \dots, p_k)$  :
  - A choix du risque de première espèce  $\alpha$
  - B calcul de  $d^2 = \sum_{r=1}^k \frac{(n_r - n.p_r)^2}{n.p_r}$
  - C lecture dans une table de  $d_\alpha^2$  tel que  $P(\chi_{k-1}^2 > d_\alpha^2) = \alpha$
  - D si  $d^2 < d_\alpha^2$  alors règle de décision :  
 $(p_1, \dots, p_k)$  est la loi selon laquelle est tiré l'échantillon  
 sinon l'échantillon est tiré selon une autre loi

## Exemple de test d'ajustement (1/3)



- observations =  $\bullet = \{(x_i, y_i)\}$
- **Problème** : les  $\bullet$  proviennent-ils de points situés sur la courbe  $y = \sin(x)$  mais observés avec un bruit gaussien ?

$$\implies \text{problème : } T_i = Y_i - \sin(x_i) \sim \mathcal{N}(0, 1) ?$$

observations des  $t_i$ , réparties en 8 classes :

$t_i$	$]-\infty; -3[$	$[-3; -2[$	$[-2; -1[$	$[-1; 0[$	$[0; 1[$	$[1; 2[$	$[2; 3[$	$[3; +\infty[$
$N_r$	1	2	13	35	30	15	3	1

## Exemple de test d'ajustement (2/3)

Rappel :  $T_i \sim \mathcal{N}(0, 1)$

$t_j$	$] -\infty; -3[$	$[-3; -2[$	$[-2; -1[$	$[-1; 0[$	$[0; 1[$	$[1; 2[$	$[2; 3[$	$[3; +\infty[$
$N_r$	1	2	13	35	30	15	3	1
$n.p_r$	0.14	2.14	13.59	34.13	34.13	13.59	2.14	0.14

$$\Rightarrow d^2 = \sum_{r=1}^8 \frac{(n_r - n.p_r)^2}{n.p_r} \approx 11.61$$

pour  $\alpha = 0.05$ ,  $P(\chi_7^2 > d_\alpha^2) = \alpha \Rightarrow d_\alpha^2 = 14.1$

$\Rightarrow d^2 < d_\alpha^2 \Rightarrow$  règle de décision :

l'échantillon est bien tiré selon  $\sin(x)$ + un bruit gaussien

## Exemple de test d'ajustement (3/3)

Nouvel échantillon :

$t_j$	$] -\infty; -3[$	$[-3; -2[$	$[-2; -1[$	$[-1; 0[$	$[0; 1[$	$[1; 2[$	$[2; 3[$	$[3; +\infty[$
$N_r$	2	2	12	35	30	15	3	1
$n.p_r$	0.14	2.14	13.59	34.13	34.13	13.59	2.14	0.14

$$\Rightarrow d^2 = \sum_{r=1}^8 \frac{(n_r - n.p_r)^2}{n.p_r} \approx 31.20$$

pour  $\alpha = 0.05$ ,  $P(\chi_7^2 > d_\alpha^2) = \alpha \Rightarrow d_\alpha^2 = 14.1$

$\Rightarrow d^2 > d_\alpha^2 \Rightarrow$  règle de décision :

l'échantillon n'est pas tiré selon  $\sin(x)$ + un bruit gaussien

## Exemple de test d'ajustement (1/2)

- péage d'autoroute : 10 cabines
- nombre de clients / cabine sur une heure :



N° cabine	1	2	3	4	5	6	7	8	9	10
Nb clients	24	14	18	20	23	13	23	24	23	18

Clients distribués uniformément sur l'ensemble des cabines ?

$\Rightarrow$  test d'ajustement, niveau de confiance :  $1 - \alpha = 95\%$

- $H_0 = \ll$  la répartition des clients est uniforme  $\gg$
- $H_1 = \ll$  la répartition n'est pas uniforme  $\gg$
- $H_0 \Rightarrow$  20 clients / cabine (uniforme)

## Exemple de test d'ajustement (2/2)

- $X_i$  : variable « effectif » recensé pour la  $i$ ème cabine

- Statistique d'ajustement :  $D^2 = \sum_{i=1}^{10} \frac{(X_i - 20)^2}{20}$

- $D^2 \sim \chi_9^2$

- $\alpha = 0,05 = P(\text{rejeter } H_0 | H_0 \text{ est vraie})$

$$= P(D^2 > d_\alpha | D^2 \sim \chi_9^2)$$

$$\implies d_\alpha = 16,9$$

- calcul de la valeur de  $d$  observée sur l'échantillon :

$$d^2 = \frac{1}{20} [(14 - 20)^2 + (24 - 20)^2 + (18 - 20)^2 + (20 - 20)^2 + (23 - 20)^2 + (13 - 20)^2 + (23 - 20)^2 + (18 - 20)^2 + (24 - 20)^2 + (23 - 20)^2] = 7,6.$$

$\implies$  estimation : répartition uniforme

## Tests d'indépendance (1/3)

- 2 caractères  $X$  et  $Y$

- classes de  $X$  :  $A_1, A_2, \dots, A_I$

- classes de  $Y$  :  $B_1, B_2, \dots, B_J$

- échantillon de taille  $n$

- tableau de contingence :

$X \setminus Y$	$B_1$	$B_2$	$\dots$	$B_j$	$\dots$	$B_J$
$A_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1j}$	$\dots$	$n_{1J}$
$A_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2j}$	$\dots$	$n_{2J}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$		$\vdots$
$A_i$	$n_{i1}$	$n_{i2}$	$\dots$	$n_{ij}$	$\dots$	$n_{iJ}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$		$\vdots$
$A_I$	$n_{I1}$	$n_{I2}$	$\dots$	$n_{Ij}$	$\dots$	$n_{IJ}$

## Tests d'indépendance (2/3)

$X \setminus Y$	$B_1$	$B_2$	$\dots$	$B_j$	$\dots$	$B_J$	total
$A_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1j}$	$\dots$	$n_{1J}$	$n_{1\cdot}$
$A_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2j}$	$\dots$	$n_{2J}$	$n_{2\cdot}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$A_i$	$n_{i1}$	$n_{i2}$	$\dots$	$n_{ij}$	$\dots$	$n_{iJ}$	$n_{i\cdot}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$A_I$	$n_{I1}$	$n_{I2}$	$\dots$	$n_{Ij}$	$\dots$	$n_{IJ}$	$n_{I\cdot}$
total	$n_{\cdot 1}$	$n_{\cdot 2}$	$\dots$	$n_{\cdot j}$	$\dots$	$n_{\cdot J}$	$n$

$$\frac{n_{ij}}{n} = P(X \in A_i, Y \in B_j)$$

$$P(X \in A_i) = \frac{n_{i\cdot}}{n} = \frac{\sum_{j=1}^J n_{ij}}{n} \quad \text{et} \quad P(Y \in B_j) = \frac{n_{\cdot j}}{n} = \frac{\sum_{i=1}^I n_{ij}}{n}$$

$X$  et  $Y$  indépendants  $\implies P(X \in A_i, Y \in B_j) = P(X \in A_i) \times P(Y \in B_j)$

## Tests d'indépendance (3/3)

$X \setminus Y$	$B_1$	$B_2$	$\dots$	$B_j$	$\dots$	$B_J$	total
$A_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1j}$	$\dots$	$n_{1J}$	$n_{1\cdot}$
$A_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2j}$	$\dots$	$n_{2J}$	$n_{2\cdot}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$A_i$	$n_{i1}$	$n_{i2}$	$\dots$	$n_{ij}$	$\dots$	$n_{iJ}$	$n_{i\cdot}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$A_I$	$n_{I1}$	$n_{I2}$	$\dots$	$n_{Ij}$	$\dots$	$n_{IJ}$	$n_{I\cdot}$
total	$n_{\cdot 1}$	$n_{\cdot 2}$	$\dots$	$n_{\cdot j}$	$\dots$	$n_{\cdot J}$	$n$

$$X \text{ et } Y \text{ indépendants} \implies \frac{n_{ij}}{n} = \frac{n_{i\cdot}}{n} \times \frac{n_{\cdot j}}{n} \implies n_{ij} = \frac{n_{i\cdot} \times n_{\cdot j}}{n}$$

$$\chi^2_{(I-1) \times (J-1)} = \sum_{i=1}^I \sum_{j=1}^J \frac{(n_{ij} - \frac{n_{i\cdot} n_{\cdot j}}{n})^2}{\frac{n_{i\cdot} n_{\cdot j}}{n}}$$

## Exemple de test d'indépendance (1/2)

- notes d'examen de RFIDEC  $\implies$  3 classes :

$C_1$	$C_2$	$C_3$
note < 8	note $\in [8, 12[$	note $\geq 12$



- $X$  : variable aléatoire « note 1ère session »
- $Y$  : variable aléatoire « note 2ème session »

X et Y sont-elles des variables aléatoires indépendantes ?

- sélection d'un échantillon de 100 notes :

$X \setminus Y$	$C_1$	$C_2$	$C_3$
$C_1$	2	13	6
$C_2$	11	27	13
$C_3$	3	17	8

## Exemple de test d'indépendance (2/2)

Test d'indépendance de niveau de confiance 90%

- calcul des marginales :

$X \setminus Y$	$C_1$	$C_2$	$C_3$	total
$C_1$	2	13	6	21
$C_2$	11	27	13	51
$C_3$	3	17	8	28
total	16	57	27	

- tableau obtenu si  $X$  et  $Y$  sont indépendants :

$X \setminus Y$	$C_1$	$C_2$	$C_3$
$C_1$	3.36	11.97	5.67
$C_2$	8.16	29.07	13.77
$C_3$	4.48	15.96	7.56

- calcul de la statistique  $d^2$  :  $d^2 = 2,42$
- $D^2 \sim \chi^2_4 \implies d^2_\alpha = 7,78 \implies d^2 < d^2_\alpha \implies$  indépendance

## Rappel sur l'indépendance conditionnelle

### Indépendance conditionnelle de deux variables discrètes

$X$  et  $Y$  sont *indépendantes* conditionnellement à  $Z$  si :

- $P(X \cap Y|Z) = P(X|Z) \times P(Y|Z)$
- si  $P(Y|Z) > 0$  alors  $P(X|Y, Z) = P(X|Z)$
- si  $P(X|Z) > 0$  alors  $P(Y|X, Z) = P(Y|Z)$

### Interprétation

- Conditionnement = apport de connaissances
- Si l'on connaît la valeur de la variable  $Z$ , alors connaître celle de  $Y$  n'apporte rien sur la connaissance de  $X$



Ces formules s'étendent si  $X$ ,  $Y$  et/ou  $Z$  sont remplacés par des ensembles de variables aléatoires disjoints 2 à 2

## Application en informatique

- $n$  variables aléatoires  $X_1, \dots, X_n$
- $P(X_n, \dots, X_1) = P(X_n|X_{n-1}, \dots, X_1)P(X_{n-1}, \dots, X_1)$
- Par récurrence :

$$P(X_n, \dots, X_1) = P(X_1) \times \prod_{i=2}^n P(X_i|X_1, \dots, X_{i-1})$$

- $\forall i, \{X_1, \dots, X_{i-1}\} = L_i \cup K_i$ , où  $L_i \cap K_i = \emptyset$  et  $X_i$  indépendant de  $L_i$  conditionnellement à  $K_i$

- Alors :

$$P(X_n, \dots, X_1) = P(X_1) \times \prod_{i=2}^n P(X_i|K_i)$$

- Tables de proba  $P(X_i|K_i)$  plus petites que  $P(X_i|X_1, \dots, X_{i-1})$

## Exemple d'application (1/5)

### Exemple de la dyspnée (Lauritzen & Spiegelhalter (88))

La **dyspnée** peut être engendrée par une **tuberculose**, un **cancer des poumons**, une **bronchite**, par plusieurs de ces maladies, ou bien par aucune.

Un séjour récent en **Asie** augmente les chances de tuberculose, tandis que **fumer** augmente les risques de cancer des poumons. Des **rayons X** permettent de détecter une tuberculose ou un cancer.

Un patient éprouve des difficultés à respirer. Dans quelle mesure peut-on dire qu'il est atteint de dyspnée ?

### Variables aléatoires :

- D : dyspnée : oui/non
- C : cancer : oui/non
- A : Asie : oui/non
- R : rayons X : positif/négatif
- T : tuberculose : oui/non
- B : bronchite : oui/non
- F : fumer : oui/non

## Exemple d'application (2/5)

*Exemple de la dyspnée (Lauritzen & Spiegelhalter (88))*

La dyspnée peut être engendrée par une tuberculose, un cancer des poumons, une bronchite, par plusieurs de ces maladies, ou bien par aucune. Un séjour récent en Asie augmente les chances de tuberculose, tandis que fumer augmente les risques de cancer des poumons. Des rayons X permettent de détecter une tuberculose ou un cancer. Un patient éprouve des difficultés à respirer. Dans quelle mesure peut-on dire qu'il est atteint de dyspnée ?

$$P(D, R, T, C, B, A, F) = P(D|R, T, C, B, A, F) \times P(R, T, C, B, A, F)$$

$$\text{Or } P(D|R, T, C, B, A, F) = P(D|T, C, B)$$

$$\implies P(D, R, T, C, B, A, F) = P(D|T, C, B) \times P(R, T, C, B, A, F)$$

## Exemple d'application (3/5)

*Exemple de la dyspnée (Lauritzen & Spiegelhalter (88))*

La dyspnée peut être engendrée par une tuberculose, un cancer des poumons, une bronchite, par plusieurs de ces maladies, ou bien par aucune. Un séjour récent en Asie augmente les chances de tuberculose, tandis que fumer augmente les risques de cancer des poumons. Des rayons X permettent de détecter une tuberculose ou un cancer. Un patient éprouve des difficultés à respirer. Dans quelle mesure peut-on dire qu'il est atteint de dyspnée ?

$$P(D, R, T, C, B, A, F) = P(D|T, C, B) \times P(R, T, C, B, A, F)$$

$$\text{or } P(R, T, C, B, A, F) = P(R|T, C, B, A, F) \times P(T, C, B, A, F)$$

$$\text{et } P(R|T, C, B, A, F) = P(R|T, C)$$

$$\implies P(D, R, T, C, B, A, F) = P(D|T, C, B) \times P(R|T, C) \times P(T, C, B, A, F)$$

## Exemple d'application (4/5)

*Exemple de la dyspnée (Lauritzen & Spiegelhalter (88))*

La dyspnée peut être engendrée par une tuberculose, un cancer des poumons, une bronchite, par plusieurs de ces maladies, ou bien par aucune. Un séjour récent en Asie augmente les chances de tuberculose, tandis que fumer augmente les risques de cancer des poumons. Des rayons X permettent de détecter une tuberculose ou un cancer. Un patient éprouve des difficultés à respirer. Dans quelle mesure peut-on dire qu'il est atteint de dyspnée ?

$$P(D, R, T, C, B, A, F) = P(D|T, C, B) \times P(R|T, C) \times P(T, C, B, A, F)$$

$$P(T|C, B, A, F) = P(T|A)$$

$$P(D, R, T, C, B, A, F) = P(D|T, C, B) \times P(R|T, C) \times P(T|A) \times P(C, B, A, F)$$

.....

$$= P(D|T, C, B) \times P(R|T, C) \times P(T|A) \times P(C|F) \times P(B|F) \times P(A) \times P(F)$$

$$P(D, R, T, C, B, A, F) = P(D|T, C, B) \times P(R|T, C) \times P(T|A) \times P(C|F) \times P(B|F) \times P(A) \times P(F)$$

Si toutes les variables ont 10 valeurs possibles :

$P(D, R, T, C, B, A, F)$  nécessite une table de  $10^7$  éléments


formule décomposée nécessite :

$$10000 + 1000 + 3 \times 100 + 2 \times 10 = 11320 \text{ éléments}$$

## Qu'est-ce qu'un réseau bayésien ?

### Définition d'un réseau bayésien

- 1 un graphe sans circuit :



qui représente une décomposition de la loi jointe :

$$P(A, B, C, D, E, F) = P(F|E)P(E|B, D)P(D|C)P(C)P(B|A)P(A)$$

- 2 À chaque nœud  $X$  du graphe est associée sa probabilité conditionnellement à ses parents.


## Quelques applications des réseaux bayésiens

### diagnostic

- diagnostic de panne
- sûreté de fonctionnement
- filtrage de spams

### prédiction


- modélisation de joueurs
- prévisions boursières



## Diagnostic : une voiture bayésienne (1/3)




- RB conduit une voiture
- but : rester au milieu de la route



Problème : effectuer rapidement les calculs

## Diagnostic : une voiture bayésienne (2/3)



*décomposition :*

$$P(\text{AngRoues} | \text{AngVTg}, \text{DistC})$$


$$P(\text{AngVTg} | \text{TgR}, \text{AngV})$$

$$P(\text{TgR})P(\text{AngV})P(\text{DistC})$$

*Principe de fonctionnement de la voiture*

- calculer  $P(\text{AngRoues})$  puis tirer selon cette loi une action
- calculer  $\text{Argmax } P(\text{AngRoues})$
- calculs  $\implies$  éliminer les variables une par une

## Diagnostic : une voiture bayésienne (3/3)



*décomposition :*

$$P(\text{AngRoues} | \text{AngVTg}, \text{DistC})$$

$$P(\text{AngVTg} | \text{TgR}, \text{AngV})$$

$$P(\text{TgR})P(\text{AngV})P(\text{DistC})$$



## Vraisemblance d'un échantillon : le cas discret

- Paramètre à estimer :  $\theta$
- Échantillon  $\mathbf{x} = (x_1, \dots, x_n)$  de taille  $n$
- Échantillon  $\implies$  les  $x_i$  = réalisations de variables aléatoires  $X_i$
- Échantillon i.i.d.  $\implies$  les  $X_i$  sont mutuellement indépendants

$$\implies P(X_1 = x_1, \dots, X_n = x_n | \theta = \theta) = \prod_{i=1}^n P(X_i = x_i | \theta = \theta)$$

### Vraisemblance d'un échantillon dans le cas discret

- $L(\mathbf{x}, \theta)$  = Vraisemblance de l'échantillon
- $L(\mathbf{x}, \theta)$  = proba d'obtenir **cet** échantillon sachant que  $\theta = \theta$

$$L(\mathbf{x}, \theta) = P(x_1, \dots, x_n | \theta = \theta) = \prod_{i=1}^n P(x_i | \theta = \theta)$$

## Vraisemblance d'un échantillon : le cas continu

- Paramètre à estimer :  $\theta$
- Échantillon  $\mathbf{x} = (x_1, \dots, x_n)$  de taille  $n$
- Échantillon i.i.d.  $\implies$  les  $X_i$  sont mutuellement indépendants
- $p$  : fonction de densité

$$\implies p(X_1 = x_1, \dots, X_n = x_n | \theta = \theta) = \prod_{i=1}^n p(X_i = x_i | \theta = \theta)$$

### Vraisemblance d'un échantillon dans le cas continu

- $L(\mathbf{x}, \theta)$  = Vraisemblance de l'échantillon
- $L(\mathbf{x}, \theta) = p(x_1, \dots, x_n | \theta = \theta) = \prod_{i=1}^n p(x_i | \theta = \theta)$

## Exemple de vraisemblance (1/2)

- pièce de monnaie :  $P(\text{Pile}) = 0,75$  et  $P(\text{Face}) = 0,25$
- jet de la pièce  $\implies$  expérience de Bernoulli
- paramètre  $\theta$  = proba de Pile =  $0,75 = \theta$



- échantillon 1 : 

P	P	F	F	P	P	F	P	P	P
---	---	---	---	---	---	---	---	---	---

$$\begin{aligned} \implies L(\mathbf{x}, \theta) &= \prod_{i=1}^7 P(\text{Pile} | \theta) \times \prod_{i=1}^3 P(\text{Face} | \theta) \\ &= 0,75^7 \times 0,25^3 \approx 0,002086 \end{aligned}$$

- échantillon 2 : 

F	F	P	P	F	F	P	F	F	F
---	---	---	---	---	---	---	---	---	---

$$\begin{aligned} \implies L(\mathbf{x}, \theta) &= \prod_{i=1}^3 P(\text{Pile} | \theta) \times \prod_{i=1}^7 P(\text{Face} | \theta) \\ &= 0,75^3 \times 0,25^7 \approx 0,000026 \end{aligned}$$

## Exemple de vraisemblance (2/2)

- pièce de monnaie :  $P(\text{Pile}) = ???$  et  $P(\text{Face}) = ???$
- paramètre  $\theta$  = proba de Pile = ???
- échantillon : 

P	P	F	F	P	P	F	P	P	P
---	---	---	---	---	---	---	---	---	---

$$\Rightarrow L(\mathbf{x}, \theta) = \prod_{i=1}^7 P(\text{Pile}|\theta) \times \prod_{i=1}^3 P(\text{Face}|\theta)$$

- $\theta_1 = 0,75 \Rightarrow L(x, \theta_1) = 0,75^7 \times 0,25^3 \approx 0,002086$
  - $\theta_2 = 0,5 \Rightarrow L(x, \theta_2) = 0,5^7 \times 0,5^3 \approx 0,000976$
  - $\theta_3 = 0,25 \Rightarrow L(x, \theta_3) = 0,25^7 \times 0,75^3 \approx 0,000026$
- $\Rightarrow \theta_1$  plus vraisemblable que  $\theta_2$  ou  $\theta_3$

## Estimateur du maximum de vraisemblance

### Estimateur du maximum de vraisemblance

- $X$  : variable aléatoire sur la population
- $X$  suit une loi de proba de paramètre  $\theta$  inconnu
- $\Theta$  : ensemble des valeurs possibles pour  $\theta$
- $\mathbf{x}$  : échantillon i.i.d.
- $T = f(X) =$  *estimateur du maximum de vraisemblance*  
défini par  $\mathbf{x} \mapsto t = f(\mathbf{x}) = \underset{\theta \in \Theta}{\text{Argmax}} L(\mathbf{x}, \theta)$

$\Rightarrow t =$  valeur  $\theta$  de  $\Theta$  pour laquelle la proba d'observer  $\mathbf{x}$  était la plus grande

## Calcul du maximum de vraisemblance

**Problème :** comment calculer le maximum de vraisemblance ?

- $\underset{\theta \in \Theta}{\text{Argmax}} L(\mathbf{x}, \theta) = \underset{\theta \in \Theta}{\text{Argmax}} P(x_1, \dots, x_n | \theta) = \underset{\theta \in \Theta}{\text{Argmax}} \prod_{i=1}^n P(x_i | \theta)$
- Certaines conditions de concavité et de dérivabilité  
 $\Rightarrow \underset{\theta \in \Theta}{\text{Argmax}} L(\mathbf{x}, \theta)$  obtenu lorsque  $\frac{\partial L(\mathbf{x}, \theta)}{\partial \theta} = 0$
- $\underset{\theta \in \Theta}{\text{Argmax}} L(\mathbf{x}, \theta) = \underset{\theta \in \Theta}{\text{Argmax}} \ln L(\mathbf{x}, \theta) = \underset{\theta \in \Theta}{\text{Argmax}} \sum_{i=1}^n \ln P(x_i | \theta)$

$$\underset{\theta \in \Theta}{\text{Argmax}} \ln L(\mathbf{x}, \theta) = \log \text{vraisemblance}$$

$$\Rightarrow \underset{\theta \in \Theta}{\text{Argmax}} L(\mathbf{x}, \theta) \text{ obtenu lorsque } \sum_{i=1}^n \frac{\partial \ln P(x_i | \theta)}{\partial \theta} = 0$$

## Max de vraisemblance et loi normale (1/2)

- $X \sim \mathcal{N}(\mu, \sigma^2)$ ; on suppose  $\sigma = 1$
- paramètre  $\theta =$  espérance  $\mu$
- loi normale  $\implies$  vraisemblance :

$$L(\mathbf{x}, \theta) = \prod_{i=1}^n p(x_i|\theta) = \prod_{i=1}^n \left[ \frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{1}{2}(x_i - \theta)^2 \right\} \right]$$

- $\frac{\partial L(\mathbf{x}, \theta)}{\partial \theta} = 0 \iff \frac{\partial \ln L(\mathbf{x}, \theta)}{\partial \theta} = 0$
- $\ln L(\mathbf{x}, \theta) = -\frac{n}{2} \ln 2\pi - \frac{1}{2} \sum_{i=1}^n (x_i - \theta)^2$
- $\frac{\partial L(\mathbf{x}, \theta)}{\partial \theta} = 0 \iff \sum_{i=1}^n (x_i - \theta) = 0 \iff \theta = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$

Estimateur du maximum de vraisemblance :  $\bar{X}$

## Max de vraisemblance et loi normale (2/2)

- $X \sim \mathcal{N}(\mu, \sigma^2)$
- paramètre  $\theta = (\mu, \sigma^2)$
- Log vraisemblance :

$$\ln L(\mathbf{x}, \theta) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

- Maximum de vraisemblance  $\implies \frac{\partial L(\mathbf{x}, \theta)}{\partial \mu} = 0$  et  $\frac{\partial L(\mathbf{x}, \theta)}{\partial \sigma^2} = 0$


$$\bullet \begin{cases} \frac{\partial L(\mathbf{x}, \theta)}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 & \implies \mu = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \\ \frac{\partial L(\mathbf{x}, \theta)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0 & \implies \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = s_n^2 \end{cases}$$

Estimateurs du maximum de vraisemblance :  $\bar{X}$  et  $S_n^2$



estimateur de la variance biaisé : variance non corrigée

## Retour sur le problème d'ajustement du cours 1 (1/6)



Observations

$(x_1, t_1)$

$\vdots$

$(x_{10}, t_{10})$

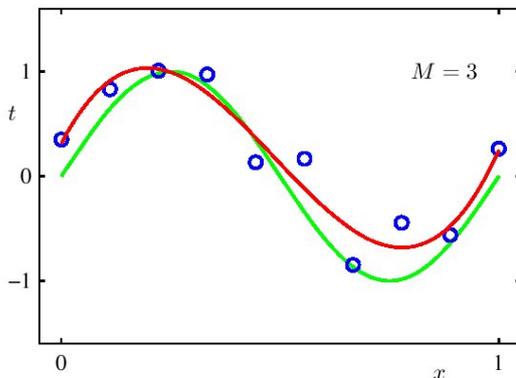
$\implies$  courbe  $\sin(2\pi x) \implies$  estimation de  $t_{11}$

$\implies$  reconnaissance de la courbe verte

## Retour sur le problème d'ajustement du cours 1 (2/6)


**Idée :** estimer la courbe verte par un polynôme :

$$y(x, \mathbf{w}) = w_0 + w_1 x + w_2 x^2 + \dots + w_M x^M = \sum_{j=0}^M w_j x^j$$



## Retour sur le problème d'ajustement du cours 1 (3/6)

**Idée :** les ordonnées des points bleus sont distribuées selon une loi normale autour de  $y(x, \mathbf{w})$  :



$$\Rightarrow P(t|x, \mathbf{w}, \sigma^2) = \mathcal{N}(t|y(x, \mathbf{w}), \sigma^2)$$

**Problème :** comment trouver  $\mathbf{w}$  et  $\sigma^2$  ?

$\Rightarrow$  par maximum de vraisemblance

## Retour sur le problème d'ajustement du cours 1 (4/6)

$$P(t|x, \mathbf{w}, \sigma^2) = \mathcal{N}(t|y(x, \mathbf{w}), \sigma^2)$$

- observations  $\{(x_i, t_i), i = 1, \dots, n\}$
- $\mathbf{t} = \{t_1, \dots, t_n\}$ ;  $\mathbf{x} = \{x_1, \dots, x_n\}$
- observations  $\Rightarrow$  échantillon i.i.d

$$\begin{aligned} \Rightarrow P(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2) &= \prod_{i=1}^n P(t_i|x_i, \mathbf{w}, \sigma^2) \\ &= \prod_{i=1}^n \mathcal{N}(t_i|y(x_i, \mathbf{w}), \sigma^2) \end{aligned}$$


- Max de vraisemblance  $\Rightarrow$  calculer la log-vraisemblance :

$$\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{i=1}^n [y(x_i, \mathbf{w}) - t_i]^2 + \frac{n}{2} \ln \frac{1}{\sigma^2} - \frac{n}{2} \ln(2\pi)$$

## Retour sur le problème d'ajustement du cours 1 (5/6)

$$\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{i=1}^n [y(x_i, \mathbf{w}) - t_i]^2 + \frac{n}{2} \ln \frac{1}{\sigma^2} - \frac{n}{2} \ln(2\pi)$$

- Maximum de log-vraisemblance  $\implies$  trouver  $\mathbf{w}_{ML}$  et  $\sigma_{ML}^2$  qui maximisent  $\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2)$
- maximiser par rapport à  $\mathbf{w}_{ML} \iff$  minimiser  $\sum_{i=1}^n [y(x_i, \mathbf{w}) - t_i]^2$



$\implies$  critère du cours 1.1

## Retour sur le problème d'ajustement du cours 1 (6/6)


$$\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{i=1}^n [y(x_i, \mathbf{w}) - t_i]^2 + \frac{n}{2} \ln \frac{1}{\sigma^2} - \frac{n}{2} \ln(2\pi)$$

- maximiser  $\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2)$  par rapport à  $\sigma^2 \implies \frac{\partial \ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2)}{\partial \sigma^2} = 0$
- $\frac{\partial \ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \sigma^2)}{\partial \sigma^2} = \frac{1}{2\sigma^4} \sum_{i=1}^n [y(x_i, \mathbf{w}) - t_i]^2 - \frac{n}{2\sigma^4} \sigma^2 = 0$   
 $\implies \sigma^2 = \frac{1}{n} \sum_{i=1}^n [y(x_i, \mathbf{w}) - t_i]^2$

$$\sigma_{ML}^2 = \frac{1}{n} \sum_{i=1}^n [y(x_i, \mathbf{w}_{ML}) - t_i]^2$$

## Prévention des risques d'inondation (1/4)

- Plan de prévention des risques d'inondations (PPR-I) :  
photos satellite SPOT5  $\implies$  zones susceptibles d'être inondées



- 3 catégories de parcelles :
  - 1 inondables (PI)
  - 2 partiellement inondables (PPI)
  - 3 non inondables (NI)

## Prévention des risques d'inondation (2/4)

- images en teintes de gris
- proba d'obtenir un niveau de gris  $n$  dépend du type de zone :

$$P(n|PI) = \mathcal{N}(\mu_1, \sigma_1^2) \quad P(n|PPI) = \mathcal{N}(\mu_2, \sigma_2^2)$$
$$\mu_1 = 100 \quad \sigma_1 = 20 \quad \mu_2 = 85 \quad \sigma_2 = 5$$

- nouvelle image envoyée par SPOT5 :



- zone  $Z$  : niveau de gris =  $n = 80$

Problème : zone  $Z = PI$  ou  $PPI$  ?

## Prévention des risques d'inondation (3/4)

Problème : zone  $Z = PI$  ou  $PPI$  ?

- 2 hypothèses :
  - 1  $\theta_1 = \ll Z \text{ est de type } PI \gg$
  - 2  $\theta_2 = \ll Z \text{ est de type } PPI \gg$
- **Idée** : calcul du max de vraisemblance d'obtenir la zone  $Z$  sous  $\theta_1$  ou sous  $\theta_2$
- $L(\mathbf{x}, \theta_1) = p(80|PI)$ , avec  $p$  fct de densité de  $P(n|PI) = \mathcal{N}(\mu_1, \sigma_1^2)$

**Rappel** : la fonction de densité de  $\mathcal{N}(\mu, \sigma^2)$  est :

$$p(x) = \frac{1}{\sqrt{2\pi} \cdot \sigma} \exp \left\{ -\frac{1}{2} \left( \frac{x - \mu}{\sigma} \right)^2 \right\}$$

## Prévention des risques d'inondation (4/4)

Problème : zone  $Z = PI$  ou  $PPI$  ?

- $P(n|PI) = \mathcal{N}(\mu_1, \sigma_1^2) = \mathcal{N}(100, 20^2)$
- $L(\mathbf{x}, \theta_1) = p(80|PI)$ 
$$= \frac{1}{\sqrt{2\pi} \times 20} \exp \left\{ -\frac{1}{2} \left( \frac{80-100}{20} \right)^2 \right\}$$
$$= \frac{1}{20\sqrt{2\pi}} \exp \left\{ -\frac{1}{2} \right\}$$
$$\approx 0,0121$$
- $P(n|PPI) = \mathcal{N}(\mu_2, \sigma_2^2) = \mathcal{N}(85, 5^2)$
- $L(\mathbf{x}, \theta_2) = p(80|PPI) = \frac{1}{\sqrt{2\pi} \times 5} \exp \left\{ -\frac{1}{2} \left( \frac{80-85}{5} \right)^2 \right\} \approx 0,0484$

Max de vraisemblance  $\implies PPI$  plus probable

# RFIDEC — cours 5: MAP et apprentissage non paramétrique

Christophe Gonzales

LIP6 – Université Paris 6, France

## Plan du cours n°5

- 1 Maximum a posteriori
- 2 Estimation de densité

## Max de vraisemblance et loi binomiale (1/2)

- pièce de monnaie
- $X \in \{0, 1\}$ ,  $0 \iff$  Face,  $1 \iff$  Pile
- $X \sim \mathcal{B}(1, p) \implies P(X = x|p) = p^x(1-p)^{1-x}$
- $n$  lancers de la pièce  $\implies$  observations  $\mathbf{x} = \{x_1, \dots, x_n\}$

$$\bullet P(\mathbf{x}|p) = \prod_{i=1}^n P(x_i|p) = \prod_{i=1}^n p^{x_i}(1-p)^{1-x_i}$$

**Problème** : à partir de  $\mathbf{x}$ , peut-on raisonnablement déduire  $p$  ?

- maximum de vraisemblance :

$$\ln P(\mathbf{x}|p) = \sum_{i=1}^n [x_i \ln p + (1 - x_i) \ln(1 - p)]$$


$$\frac{\partial \ln P(\mathbf{x}|p)}{\partial p} = \frac{1}{p} \sum_{i=1}^n x_i - \frac{n - \sum_{i=1}^n x_i}{1 - p} = 0 \implies p_{ML} = \frac{1}{n} \sum_{i=1}^n x_i$$

## Max de vraisemblance et loi binomiale (2/2)

$$p_{ML} = \frac{1}{n} \sum_{i=1}^n x_i$$

- 3 lancers  $\implies$  observations : {Pile,Pile,Pile} 
- Maximum de vraisemblance  $\implies p_{ML} = 1$ 
  - $\implies$  on considère que tout lancer de la pièce devrait tomber sur Pile
  - $\implies$  résultat à l'encontre du bon sens
  - $\implies$  autre estimateur : maximum a posteriori

## En route vers le maximum a posteriori



## Le modèle bayésien (1/4)

Maximum a posteriori  $\implies$  modèle bayésien

### Modèle bayésien

événements : parties de  $\mathcal{X} \times \Theta$ , où :

- $\mathcal{X}$  = l'espace des observations (échantillons)  $\mathbf{x}$  de taille  $n$
  - $\Theta$  = espace des paramètres  $\theta$
  - famille des événements dotée d'une loi de proba  $\Pi$
  - **cas discret** :  $\Pi$  déterminée par les probas des événements élémentaires  $\pi(\mathbf{x}, \theta)$
  - **cas continu** :  $\Pi$  déterminée par la densité jointe  $\pi(\mathbf{x}, \theta)$
-  Max de vraisemblance :  $\pi(\mathbf{x}|\theta)$  au lieu de  $\pi(\mathbf{x}, \theta) = \pi(\mathbf{x}|\theta)\pi(\theta)$

## Le modèle bayésien (2/4)

### Le cas discret :

- $\pi(\mathbf{x}, \theta) = \Pi(X = \mathbf{x}, \Theta = \theta)$ , où  $X, \Theta$  variables aléatoires
- $\pi(\mathbf{x}) = \Pi(X = \mathbf{x}) = \sum_{\theta \in \Theta} \Pi(X = \mathbf{x}, \Theta = \theta) = \sum_{\theta \in \Theta} \pi(\mathbf{x}, \theta)$
- $\pi(\theta) = \Pi(\Theta = \theta) = \sum_{\mathbf{x} \in \mathcal{X}} \Pi(X = \mathbf{x}, \Theta = \theta) = \sum_{\mathbf{x} \in \mathcal{X}} \pi(\mathbf{x}, \theta)$
- $\pi(\mathbf{x}|\theta) = \Pi(X = \mathbf{x}|\Theta = \theta) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\theta)}$
- $\pi(\theta|\mathbf{x}) = \Pi(\Theta = \theta|X = \mathbf{x}) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\mathbf{x})}$

### Probabilités a priori et a posteriori

- $\pi(\theta)$  = probabilité a priori de  $\theta$
- $\pi(\theta|\mathbf{x})$  = probabilité a posteriori de  $\theta$

## Le modèle bayésien (3/4)

### Le cas continu :

- $\pi(\mathbf{x}) = \Pi(X = \mathbf{x}) = \int_{\theta \in \Theta} \Pi(X = \mathbf{x}, \Theta = \theta) d\theta = \int_{\theta \in \Theta} \pi(\mathbf{x}, \theta) d\theta$
- $\pi(\theta) = \Pi(\Theta = \theta) = \int_{\mathbf{x} \in \mathcal{X}} \Pi(X = \mathbf{x}, \Theta = \theta) d\mathbf{x} = \int_{\mathbf{x} \in \mathcal{X}} \pi(\mathbf{x}, \theta) d\mathbf{x}$
- $\pi(\mathbf{x}|\theta) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\theta)}$
- $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\mathbf{x})}$

## Le modèle bayésien (4/4)

### Probabilités a priori et a posteriori

- $\pi(\theta)$  = probabilité a priori de  $\theta$   
= idée que l'on se fait de  $\theta$  avant observation
- $\pi(\theta|\mathbf{x})$  = probabilité a posteriori de  $\theta$   
= idée que l'on se fait de  $\theta$  après observation

- Formule de Bayes :  $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\pi(\mathbf{x})}$

- $\begin{cases} \text{cas discret : } \pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\sum_{\theta \in \Theta} \pi(\mathbf{x}, \theta)} = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\sum_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta)} \\ \text{cas continu : } \pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\int_{\theta \in \Theta} \pi(\mathbf{x}, \theta) d\theta} = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\int_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta) d\theta} \end{cases}$

- **Rappel** :  $\pi(\mathbf{x}|\theta)$  = vraisemblance de l'échantillon =  $L(\mathbf{x}, \theta)$

## Maximum a posteriori

### Maximum a posteriori (MAP)

$T$  estimateur du maximum a posteriori de  $\theta$  :

défini par  $\mathbf{x} \mapsto t = \underset{\theta \in \Theta}{\text{Argmax}} \pi(\theta|\mathbf{x})$

- échantillon i.i.d de  $n$  observations
- $X = (X_1, \dots, X_n) \implies \mathbf{x} = (x_1, \dots, x_n)$  observation de  $X$
- $\begin{cases} \text{cas discret} : \pi(\theta|\mathbf{x}) = \frac{L(\mathbf{x}, \theta)\pi(\theta)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \\ \text{cas continu} : \pi(\theta|\mathbf{x}) = \frac{L(\mathbf{x}, \theta)\pi(\theta)}{\int_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)d\theta} \end{cases}$
- échantillon i.i.d  $\implies \pi(\mathbf{x}|\theta) = L(\mathbf{x}, \theta) = \begin{cases} \prod_{i=1}^n P(x_i|\theta) & (\text{discret}) \\ \prod_{i=1}^n p(x_i|\theta) & (\text{continu}) \end{cases}$

## MAP : retour sur la pièce de monnaie (1/2)

- pièce de monnaie  $\implies X \in \{0, 1\}$   
 $0 \iff \text{Face}$    $1 \iff \text{Pile}$  
  - $X \sim \mathcal{B}(1, \theta) \implies P(X = x|\theta) = \theta^x(1 - \theta)^{1-x}$
  - échantillon  $\mathbf{x}$  de 3 lancers  $\implies \{\text{Pile, Pile, Pile}\}$  
  - Max de vraisemblance  $\implies \theta_{ML} = 1$   
 $\implies$  tous les lancers devraient tomber sur Pile
- 
- Modèle bayésien :  $\Theta = \{\theta_1, \theta_2\}$   
 $\theta_1 = \ll \text{biais en faveur de Pile} \gg, \theta_2 = \ll \text{biais en faveur de Face} \gg$
  - Info a priori :  $\pi(\theta_1) = \frac{2}{3}, \pi(\theta_2) = \frac{1}{3}$

**Problème** : quelle est la valeur du maximum a posteriori ?

## MAP : retour sur la pièce de monnaie (2/2)

- Info a priori :  $\pi(\theta_1) = \frac{2}{3}, \pi(\theta_2) = \frac{1}{3}$
- $L(\mathbf{x}, \theta_1) = \pi(\mathbf{x}|\theta_1) = \prod_{i=1}^3 P(x_i|\theta_1) = \frac{2^3}{3^3} \times (1 - \frac{2}{3})^0 = \frac{2^3}{3^3} \approx 0,296$
- $L(\mathbf{x}, \theta_2) = \pi(\mathbf{x}|\theta_2) = \prod_{i=1}^3 P(x_i|\theta_2) = \frac{1^3}{3^3} \times (1 - \frac{1}{3})^0 = \frac{1^3}{3^3} \approx 0,037$
- $\pi(\theta_1|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_1)\pi(\theta_1)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} = \frac{\frac{2^3}{3^3} \times \frac{2}{3}}{\frac{2^3}{3^3} \times \frac{2}{3} + \frac{1^3}{3^3} \times \frac{1}{3}} \approx 0,941$
- $\pi(\theta_2|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_2)\pi(\theta_2)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \approx 0,059$

Max a posteriori :  $\theta = \theta_1 \implies X \sim \mathcal{B}(1, \theta_1) = \mathcal{B}(1, 0.941)$

 probabilité que la pièce tombe sur Face  $\neq 0$

calcul de la distribution a posteriori :  $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\int_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta)d\theta}$

⇒ si  $\pi(\mathbf{x}|\theta)\pi(\theta)$  complexe analytiquement alors calcul de l'intégrale compliqué

### Lois conjuguées

- $\pi(\theta)$  : loi a priori
- $\pi(\mathbf{x}|\theta)$  : fonction de vraisemblance
- $\pi(\theta|\mathbf{x})$  : distribution a posteriori
- $\pi(\theta)$  et  $\pi(\mathbf{x}|\theta)$  sont conjuguées si  $\pi(\theta|\mathbf{x})$  appartient à la même famille de lois que  $\pi(\theta)$

## Lois conjuguées : exemple de la pièce de monnaie

● pièce de monnaie ⇒  $X \in \{0, 1\}$  : 0 ⇔  1 ⇔ 

●  $X \sim \mathcal{B}(1, \theta)$  ⇒ vraisemblance d'un échantillon :

$$\pi(\mathbf{x}|\theta) = \theta^x(1 - \theta)^{n-x}, \text{ avec } x = \#(x_i = 1)$$

⇒ loi binomiale

### Distribution de probabilité Beta

$$\text{Loi Beta : } \text{Beta}(\theta, a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \theta^{a-1}(1-\theta)^{b-1}$$

$$\text{avec } \Gamma(x) = \int_0^{+\infty} t^{x-1} e^{-t} dt$$

$$\text{Espérance} = \frac{a}{a+b} \quad \text{Variance} = \frac{ab}{(a+b)^2(a+b+1)}$$

⇒ loi Beta et loi binomiales conjuguées

## Lois conjuguées : loi binomiale et loi Beta

● loi a priori :  $\pi(\theta) = \text{Beta}(\theta, a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \theta^{a-1}(1-\theta)^{b-1}$

● fonction de vraisemblance :  $\pi(\mathbf{x}|\theta) = \theta^x(1-\theta)^{n-x}$ , avec  $x = \#(x_i = 1)$

● loi a posteriori :  $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\sum_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta)} \propto \pi(\mathbf{x}|\theta)\pi(\theta)$

● loi a posteriori :  $\pi(\theta|\mathbf{x}) \propto \theta^{x+a-1}(1-\theta)^{b+n-x-1}$

$$\Rightarrow \pi(\theta|\mathbf{x}) \sim \text{Beta}(\theta, x+a, b+n-x)$$

## Comparaison MAP – maximum de vraisemblance

● pièce de monnaie  $\implies X \in \{0, 1\}$  : 0  $\iff$   1  $\iff$  

● Max de vraisemblance :

$$\pi(\mathbf{x}|\theta) = \theta^x(1 - \theta)^{n-x} \implies \text{Beta}(\theta, x + 1, n - x + 1)$$

● Max a posteriori :

$$\pi(\theta|\mathbf{x}) \propto \theta^{x+a-1}(1 - \theta)^{b+n-x-1} \implies \text{Beta}(\theta, x + a, n - x + b)$$


$\implies$  Max de vraisemblance  $\iff$  Max a posteriori avec  $a = 1$  et  $b = 1$

Or  $\text{Beta}(\theta, 1, 1) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} = \text{constante}$

Max de vraisemblance  $\iff$  Max a posteriori avec a priori uniforme

**!**  $n \rightarrow +\infty \implies$  max de vraisemblance  $\approx$  max a posteriori  
 $\implies$  l'a priori devient négligeable

## La loi Beta



## Loi normale et loi conjuguée

● fonction de vraisemblance = loi normale,  $\sigma^2$  connue  
 $\implies$  loi a priori conjuguée : loi  $\Gamma$

### La loi $\Gamma$

●  $X \sim \Gamma(x, k, \theta)$

● fonction de densité de la loi  $\Gamma$  :

$$f(x, k, \theta) = x^{k-1} \frac{e^{-x/\theta}}{\theta^k \Gamma(k)} \quad \forall x, k, \theta > 0$$

●  $\Gamma(k) = \int_0^{+\infty} t^{k-1} e^{-t} dt$


●  $E(X) = k\theta, \quad V(X) = k\theta^2$

**!** Lorsque  $k$  entier :  $\Gamma(x, k, \theta) =$  loi de  $k$  variables indépendantes suivant une loi exponentielle d'espérance  $\theta$

● Familles de lois conjuguées :

[http://en.wikipedia.org/wiki/Conjugate\\_prior](http://en.wikipedia.org/wiki/Conjugate_prior)

## Loi Gamma



## Prévention des risques d'inondation (1/3)

- Plan de prévention des risques d'inondations (PPR-I) :

photos satellite SPOT5  $\Rightarrow$  zones susceptibles d'être inondées



- 3 catégories de parcelles :

- 1 inondables ( $PI$ )
- 2 partiellement inondables ( $PPI$ )
- 3 non inondables ( $NI$ )

## Prévention des risques d'inondation (2/3)

- images en teintes de gris
- proba d'obtenir un niveau de gris  $n$  dépend du type de zone :  
$$P(n|PI) = \mathcal{N}(100, 20^2) \quad P(n|PPI) = \mathcal{N}(85, 5^2)$$
- nouvelle image envoyée par SPOT5 :



- zone  $Z$  : niveau de gris =  $n = 80$
- **Connaissance a priori** : 60% de  $PI$ , 10% de  $PPI$ , 30% de  $NI$

Problème : zone  $Z = PI$  ou  $PPI$  ?

## Prévention des risques d'inondation (3/3)

Problème : zone  $Z = PI$  ou  $PPI$  ?

- 2 hypothèses :

- $\theta_1 = \ll Z \text{ est de type } PI \gg$
- $\theta_2 = \ll Z \text{ est de type } PPI \gg$

- Idée** : calcul du MAP d'obtenir la zone  $Z$  sous  $\theta_1$  ou sous  $\theta_2$

$$\pi(\theta_1|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_1)\pi(\theta_1)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \quad \pi(\theta_2|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_2)\pi(\theta_2)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)}$$

- Rappel cours 4 :  $L(\mathbf{x}, \theta_1) \approx 0,0121$      $L(\mathbf{x}, \theta_2) \approx 0,0484$



- a priori :  $\pi(\theta_1) = 0,6$      $\pi(\theta_2) = 0,1$

$$\pi(\theta_1|\mathbf{x}) = \frac{0,0121 \times 0,6}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \quad \pi(\theta_2|\mathbf{x}) = \frac{0,0484 \times 0,1}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)}$$

MAP  $\Rightarrow$  parcelle inondable (PI)

## Analyse d'un trafic réseau (1/4)

- Réseau informatique : transfert de paquets



- Problème** : analyse des paquets perdus sur un sous-réseau
- $X$  : variable aléatoire « nombre de paquets envoyés jusqu'à bonne réception »
- $X$  loi géométrique :  $P(X = n) = (1 - p)^{n-1}p$   
 $p$  : probabilité qu'un paquet soit correctement transmis

## Analyse d'un trafic réseau (2/4)

- observation de 7 réalisations de  $X$  :

2	3	8	3	4	7	8
---	---	---	---	---	---	---

Estimation de  $p$  ?

- estimation par max de vraisemblance
- estimation par MAP

## ① estimation par max de vraisemblance

2	3	8	3	4	7	8
---	---	---	---	---	---	---

- vraisemblance :  $L(\mathbf{x}, \theta) = \prod_{i=1}^7 P(x_i|\theta)$

$\theta =$  estimation de  $p$

- observations  $\implies L(\mathbf{x}, \theta) = (1 - \theta)^{28}\theta^7$

$$\implies \ln L(\mathbf{x}, \theta) = 28 \ln(1 - \theta) + 7 \ln \theta$$

$$\implies \frac{\partial \ln L(\mathbf{x}, \theta)}{\partial \theta} = \frac{-28}{1 - \theta} + \frac{7}{\theta} = \frac{7 - 35\theta}{\theta(1 - \theta)}$$

$$\implies \text{maximum de vraisemblance} = \theta = 0,2$$

## ② estimation par max de vraisemblance

2	3	8	3	4	7	8
---	---	---	---	---	---	---

- A priori :  $\pi(\theta) = \text{Beta}(\theta, 2, 15) = \frac{\Gamma(17)}{\Gamma(2)\Gamma(15)} \theta^1 (1 - \theta)^{14}$

- $\text{Argmax}_{\theta} \pi(\theta|\mathbf{x}) = \text{Argmax}_{\theta} L(\mathbf{x}, \theta) \pi(\theta)$ 

$$= \text{Argmax}_{\theta} [(1 - \theta)^{28}\theta^7] \times [(1 - \theta)^{14}\theta]$$

$$= \text{Argmax}_{\theta} (1 - \theta)^{42}\theta^8$$

$$= \text{Argmax}_{\theta} 42 \ln(1 - \theta) + 8 \ln \theta$$


$$\implies \theta_{MAP} = 0,16$$

## ② Estimation de densité

## En route vers le non paramétrique

● jusqu'à maintenant : estimations des paramètres des densités :

- max de vraisemblance
- max a posteriori



⇒ *statistique paramétrique*

⇒ connaissance de la famille de lois a priori


Que faire si aucune loi a priori évidente ?

⇒ statistique non paramétrique

## Estimation de densité : idée naïve

- $X$  : variable aléatoire
- $\{x_1, \dots, x_n\}$  : les classes de  $X$
- échantillon de taille  $n \Rightarrow n_i$  individus dans la classe  $x_i$

Densité  $\approx$  histogramme des valeurs observées




*Problème* : fonction de densité très irrégulière

## Estimation de densité : la fenêtre mobile (1/2)

*Idée de la fenêtre mobile*

- $X$  : variable aléatoire
- $\forall x$  valeur de  $X$ ,  $I_x = [x - \frac{h}{2}, x + \frac{h}{2}[$  = classe de longueur  $h$
- densité estimée :  $\hat{f}(x) = \frac{1}{n} \#x_i : x - \frac{h}{2} \leq x_i < x + \frac{h}{2}$



*Problème* : fonction de densité encore trop irrégulière

## Estimation de densité : la fenêtre mobile (2/2)

densité estimée :  $\hat{f}(x) = \frac{1}{n} \#x_i : x - \frac{h}{2} \leq x_i < x + \frac{h}{2}$

$$\Rightarrow \hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

où  $K$  = fonction indicatrice de l'intervalle  $[-\frac{1}{2}, \frac{1}{2}[$  :

$$K(u) = \begin{cases} 0 & \text{si } u \geq \frac{1}{2} \text{ ou } u < -\frac{1}{2} \\ 1 & \text{si } -\frac{1}{2} \leq u < \frac{1}{2} \end{cases}$$

### Estimation de densité par la méthode du noyau

- $X$  : variable aléatoire
  - $\forall x$  valeur de  $X$ ,  $I_x = [x - \frac{h}{2}, x + \frac{h}{2}[$  = classe de longueur  $h$
  - densité estimée :  $\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$
- avec  $K$  = fonction continue = *noyau*

## Estimation de densité par la méthode du noyau

$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

- noyaux fréquemment utilisés :
  - noyau gaussien :  $K(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}}$
  - noyau d'Epanechnikov :  $K(u) = \frac{3}{4\sqrt{5}} \left(1 - \frac{u^2}{5}\right)$  pour  $|u| < \sqrt{5}$
- constante  $h$  = constante de lissage
  - $\left\{ \begin{array}{l} h \text{ petit} \implies \hat{f} \text{ très irrégulière} \\ h \text{ grand} \implies \hat{f} \text{ très (trop) lisse} \end{array} \right.$
- $h$  souvent défini empiriquement