

Examen

Exercice 1 Soit (Y_1, \dots, Y_n) un échantillon de v.a. de loi géométrique de paramètre $\theta \in]0, 1[$, où θ est un paramètre inconnu. On a donc $P(Y_1 = k) = (1 - \theta)^k$ pour $k \geq 0$.

1. Exprimer la vraisemblance de ce modèle.
2. Donner l'estimateur du maximum de vraisemblance de θ .
3. Montrer que cet estimateur est fortement consistant.
4. On suppose désormais que l'on observe Y_i seulement si $Y_i < C$ où $C > 0$ est un entier fixé connu. Dans ce modèle, les observations sont les variables aléatoires $L_i := \min(Y_i, C)$.
 - (a) Que peut-on dire de Y_i si $L_i = C$?
 - (b) Calculer la probabilité $P(L_i = \ell)$ pour ℓ un entier entre 0 et C . (On discutera selon que $\ell < C$ ou $\ell = C$).
 - (c) Calculer la vraisemblance du modèle $P(L_i = \ell_i, i \in \llbracket 1, n \rrbracket)$. On exprimera cette vraisemblance en fonction de $L := \sum_{i=1}^n \ell_i$ et de $D := \sum_{i=1}^n \mathbf{1}_{\{\ell_i < C\}}$.
 - (d) En déduire l'estimateur du maximum de vraisemblance de θ dans ce modèle.

Exercice 2 1. On teste l'efficacité d'un régime en relevant le poids de n personnes avant et après le régime, notés respectivement $(X_i)_{i=1\dots n}$ et $(Y_i)_{i=1\dots n}$. En supposant que les variables suivent une loi Gaussienne, construire un test statistique pour savoir si le régime est efficace.

2. On appelle loi de Bendford la loi sur l'ensemble $\{1, 2, \dots, 9\}$ définie par $p_k = \log_{10} \left(1 + \frac{1}{k}\right)$. La loi de Bendford est connue pour apparaître naturellement dans certaines séries statistiques: en considérant le premier chiffre des données de telles séries, on observe que celui-ci suit à peu près la loi de Bendford. On vous donne une série statistique X_1, \dots, X_n . Construire un test statistique permettant de savoir si cette série vérifie bien cette propriété.

Exercice 3 Soit la régression linéaire simple $y_i = ax_i + b + \varepsilon_i$, $i = 1 \dots n$. On suppose que les (ε_i) sont i.i.d. de loi $\mathcal{N}(0, \sigma^2)$. (les x_i sont supposés non aléatoires). On introduit un paramètre $\lambda > 0$. Pour éviter d'avoir une grande variance de l'estimateur de a , on choisit des estimateurs \tilde{a} , \tilde{b} de a et b qui minimisent la fonction

$$(a, b) \rightarrow \sum_{i=1}^n (y_i - (ax_i + b))^2 + \lambda a^2.$$

1. Trouver l'expression de \tilde{a} et \tilde{b} . On pourra introduire $S_{xy} := \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$ et $S_{xx} := \sum_{i=1}^n (x_i - \bar{x})^2$.
2. Calculer le biais de \tilde{a} .
3. Vérifier que $S_{xy} = \sum_{i=1}^n (x_i - \bar{x})y_i$. Calculer la variance de \tilde{a} .
4. Quelle est la loi de \tilde{a} ?
5. Construire un test statistique de $a = 0$ contre $a \neq 0$ reposant sur l'estimateur \tilde{a} .

Exercice 4 On veut comparer l'effet de régimes alimentaires sur le poids de poulets. On dispose de deux groupes de poulets: l'un nourri au régime 1 (variable $w1$) et l'autre au régime 2 (variable $w2$). On répondra aux questions en s'aidant des sorties R ci-dessous.

1. Dire ce que représentent les graphiques sur la dernière page.
2. Peut-on supposer que les observations suivent une loi Gaussienne?
3. Peut-on supposer que les deux groupes possèdent la même variance? Quelle loi suit la statistique F dans var.test?
4. Quelle est le nombre de poulets dans les groupes 1 et 2?
5. Donner l'expression de la statistique utilisée dans t.test (on notera (X_i) et (Y_i) les poids des poulets dans les deux groupes).
6. Y a-t-il une différence entre les deux régimes (prendre un risque à 5%)?

> summary(w1)

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
91	125	160	174	205	305

> summary(w2)

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
74.0	166.2	202.0	210.2	260.5	331.0

```
> ks.test(w1,'pnorm',mean(w1),sd(w1))
```

One-sample Kolmogorov-Smirnov test

data: w1

D = 0.11319, p-value = 0.7916

alternative hypothesis: two-sided

```
> ks.test(w2,'pnorm',mean(w2),sd(w2))
```

One-sample Kolmogorov-Smirnov test

data: w2

D = 0.10327, p-value = 0.9684

alternative hypothesis: two-sided

```
> var.test(w1,w2)
```

F test to compare two variances

data: w1 and w2

F = 0.6028, num df = 32, denom df = 19, p-value = 0.201

alternative hypothesis: true ratio of variances is not equal to 1

95 percent confidence interval:

0.2534088 1.3148254

sample estimates:

ratio of variances

0.6027972

```
> t.test(w1,w2,var.equal=T)
```

Two Sample t-test

data: w1 and w2

t = -2.0333, df = 51, p-value = 0.04724

alternative hypothesis: true difference in means is not equal to 0

95 percent confidence interval:


-71.9030588 -0.4575473

sample estimates:


mean of x mean of y

173.9697 210.1500


Regime 1




Regime 2



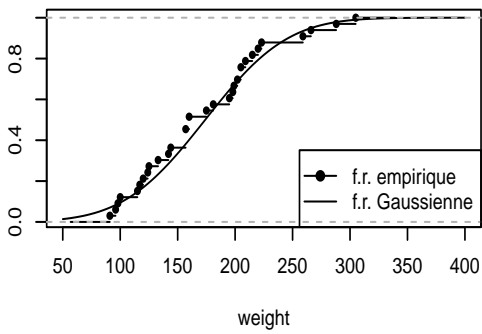
qqnorm: Regime 1



qqnorm: Regime 2



Régime 1



Régime 2

