

Examen final

Durée 2h - Sans document - 2 novembre 2020

Exercice 1 (5 pts)

Nous considérons un n -échantillon $(Y_1, x_1), \dots, (Y_n, x_n)$ du couple (Y, x) où Y est une variable aléatoire à valeurs dans $\{0, 1\}$ et x est une variable réelle fixée.

Nous supposons qu'il existe une variable latente Y_i^* telle que $Y_i^* | x_i \sim \mathcal{L}(a + bx_i, 1)$ où $\mathcal{L}(\mu, s)$ est une loi de probabilité à valeurs réelles de densité

$$f_{\mathcal{L}(\mu, s)}(y) = \frac{\exp(-(y - \mu)/s)}{s(1 + \exp(-(y - \mu)/s))^2}.$$

Nous supposons enfin que

$$Y_i = \begin{cases} 1 & \text{si } Y_i^* \geq 0 \\ 0 & \text{si } Y_i^* < 0 \end{cases}.$$

1 (2 pts) Calculer $\mathbb{P}(Y_i = 1 | X = x_i)$.

Indication : la primitive de $\frac{\exp(-(y - \mu))}{(1 + \exp(-(y - \mu)))^2}$ est $\frac{1}{1 + \exp(-(y - \mu))}$.

2 (2 pts) Montrer qu'il s'agit d'un modèle linéaire généralisée. En suivant les notations du cours quant aux familles exponentielles à un paramètre de nuisance, on explicitera les paramètres ϕ , θ , les fonctions r et b ainsi que les régresseurs à considérer.

3 (1 pt) Est-ce le lien canonique qui a été choisi ?

Exercice 2 (4 pts)

Nous considérons la loi $\Gamma(6, 1)$ tronquée en $a > 0$, de densité

$$f(x) \propto x^5 \exp(-x) \mathbb{I}_{[a, \infty[}(x).$$

1 (2 pts) Proposer une méthode pour générer des réalisations suivant cette loi et donner le code R associé.

2 (2 pts) Proposer une méthode pour approcher

$$\int_a^\infty x^5 \exp(-x) dx.$$

Exercice 3 (6 pts)

Nous souhaitons estimer

$$\theta = \int_0^{2\pi} \exp(-x/10) \sin(x) dx .$$

1 (2 pts) Proposer deux méthodes de Monte Carlo pour estimer θ .

2 (2 pts) Comparer ces deux stratégies.

3 (2 pts) Déterminer le nombre de simulation nécessaire pour que l'erreur absolue relative de l'une des deux méthodes soit inférieure à 1% avec une probabilité supérieure ou égale à 99%.

Exercice 4 (5 pts)

Décrire et commenter les résultats obtenus à l'aide du code R ci-dessous.

```
> library(gRim)
> data(reinis)
> summary(reinis)
Number of cases in table: 1841
Number of factors: 6
Test for independence of all factors:
Chisq = 809.5, df = 57, p-value = 1.564e-133
Chi-squared approximation may be incorrect
> model1 <- dmod(~ .^., reinis)
> model2 <- backward(model1, k=log(1841))
change.AIC -108.0635 Edge deleted: mental,systol
change.AIC -52.9956 Edge deleted: phys,systol
change.AIC -48.7808 Edge deleted: mental,protein
change.AIC -23.7047 Edge deleted: systol,family
change.AIC -25.4955 Edge deleted: family,protein
change.AIC -23.0541 Edge deleted: phys,family
change.AIC -12.3780 Edge deleted: smoke,family
change.AIC -9.0485 Edge deleted: smoke,mental
change.AIC -2.7865 Edge deleted: mental,family
```

Description du jeu de données

reinis gRbase R Documentation Risk factors for coronary heart disease

Data collected at the beginning of a 15 year follow-up study of probable risk factors for coronary thrombosis. Data are from all men employed in a car factory.

A table with 6 discrete variables

- A smoking,
- B strenuous mental work,
- D strenuous physical work,
- E systolic blood pressure,
- F ratio of lipoproteins,
- G Family anamnesis of coronary heart disease.

②

Correction exam
final HPNA 304
2 novembre 2020

Exercice 1

$$1) P(Y_i = 1 | X = x_i)$$

$$= \int_0^{+\infty} \frac{e^{-(y - \alpha - \beta x_i)}}{(1 + e^{-(y - \alpha - \beta x_i)})^2} dy$$

$$= \left[\frac{1}{1 + \exp[-(y - \alpha - \beta x_i)]} \right]_0^{+\infty}$$

$$= 1 - \frac{1}{1 + e^{(\alpha + \beta x_i)}} = \left[\frac{e^{\alpha + \beta x_i}}{1 + e^{\alpha + \beta x_i}} \right]$$

On reconnaît le modèle ②
de régression logistique
questions 2) & 3) Triviales.

Exercice 2

1) On utilise l'algorithme
acceptation-rejet ; on simule une
réalisation suivant une
loi gamma $(6, 1)$; on
l'accepte si elle est plus grande
que α ; si on rejette on
recommence jusqu'à acceptation.

Code R pour générer une réalisation :

```
bad <- TRUE  
while (bad) {  
  y <- rgamma(1, 6, 1)  
  if (y >= alpha) { bad <- FALSE; x <- y } }
```

$$\Delta \int_a^\infty x^5 e^{-x} dx$$

(3)

$$= E_{\text{Exp}(1)}(x^5 \mathbb{1}_{\{x \geq a\}})$$

On peut mettre en œuvre la méthode de Monte Carlo explicite.

On simule $X_1, \dots, X_N \stackrel{\text{iid}}{\sim} \text{Exp}(1)$

On approxime $\int_a^\infty x^5 e^{-x} dx$

par

$$\frac{1}{N} \sum_{i=1}^N X_i^5 \mathbb{1}_{\{X_i \geq a\}}$$

Exercício 3

4

$$1] \hat{\theta}_1 = \left(\frac{1}{N}\right) (2\pi) \sum_{i=1}^N e^{-\frac{x_i}{10}} \sin(x_i)$$

$$\text{em } X_1, \dots, X_N \stackrel{iid}{\sim} \sqrt{[0, 2\pi]}$$

$$\hat{\theta}_2 = \left(\frac{1}{N}\right) 10 \sum_{i=1}^N \sin(x_i) \cos(x_i)$$

$$\text{em } X_1, \dots, X_N \stackrel{iid}{\sim} \text{Exp}\left(\frac{1}{10}\right)$$

$$2] E(\hat{\theta}_1) = 0$$

$$V(\hat{\theta}_1) = \frac{1}{N} \left[(2\pi)^2 E_{\sqrt{[0, 2\pi]}} \left(e^{-\frac{2x}{10}} \sin^2(x) \right) - 0^2 \right]$$

$$\text{Logo queremos, } E_{\sqrt{[0, 2\pi]}} \left(e^{-\frac{2x}{10}} \sin^2(x) \right)$$

$$= \int_0^{2\pi} \frac{e^{-\frac{2x}{10}} \sin^2(x)}{2\pi} dx$$

$$E(\hat{\theta}_2) = \theta$$

(5)

$$V(\hat{\theta}_2) = \frac{1}{N} \left[10^2 E_{\text{Exp}\left(\frac{1}{10}\right)} \left(\sin^2(x) \frac{\pi(x)}{[0, 2\pi]} \right)^2 \right]$$

on a alors,

$$E_{\text{Exp}\left(\frac{1}{10}\right)} \left(\sin^2(x) \frac{\pi(x)}{[0, 2\pi]} \right)$$

$$= \int_0^{2\pi} \frac{1}{10} e^{-\frac{x}{10}} \sin^2(x) dx$$

Il s'agit donc de calculer

$$10 \int_0^{2\pi} e^{-\frac{x}{10}} \sin^2(x) dx \text{ et}$$

$$(2\pi) \int_0^{2\pi} e^{-\frac{x}{5}} \sin^2(x) dx$$

(6)

$$\frac{\kappa}{10} < \frac{\kappa}{5}$$

$$\Rightarrow \frac{-\kappa}{10} > -\frac{\kappa}{5}$$

$$\Rightarrow e^{-\frac{\kappa}{10} \pi m^2 / \kappa} > e^{-\frac{\kappa}{5} \pi m^2 / \kappa}$$

$$\Rightarrow \int_0^{2\pi} e^{-\frac{\kappa}{10} \pi m^2 / \kappa} dm > \int_0^{2\pi} e^{-\frac{\kappa}{5} \pi m^2 / \kappa} dm$$

$$\Rightarrow 10 \int_0^{2\pi} e^{-\frac{\kappa}{10} \pi m^2 / \kappa} dm > (2\pi) \int_0^{2\pi} e^{-\frac{\kappa}{5} \pi m^2 / \kappa} dm$$

$$\Rightarrow V(\hat{\theta}_1) \leq V(\hat{\theta}_2)$$

31 Nous allons utiliser le meilleur estimateur à savoir $\hat{\theta}_1$.

Erreur absolue relative de $\hat{\theta}_1$ est $|\hat{\theta}_1 - \theta| / |\theta|$

Trouver (*) la plus petite valeur
de N telle que (*) cherchons

(7)

$$\mathbb{P}\left(\frac{|\hat{\theta}_1 - \theta_1|}{|\theta_1|} \leq 10^{-2}\right) \geq 1 - 10^{-2}$$

$\theta_1 > 0$ trivialement.

En utilisant, et après l'inégalité
de Bienaymé - Tchebychev
nous avons

$$\mathbb{P}\left(\frac{|\hat{\theta}_1 - \theta_1|}{|\theta_1|} \leq 10^{-2}\right) \geq 1 - \frac{\text{V}(\hat{\theta}_1)}{\theta_1^2 10^{-4}}$$

$$1 - \frac{\text{V}(\hat{\theta}_1)}{\theta_1^2 10^{-4}} \geq [1 - 10^{-2}]$$

$$\Leftrightarrow \frac{\text{V}(\hat{\theta}_1)}{\theta_1^2} \leq 10^{-6}$$

$$\Leftrightarrow N \geq 10^6 \left(\frac{(2\pi)^{1/2}}{\theta_1^2} e^{-\frac{1}{2}} \text{mm}^2 / (\mu / \mu) - 1 \right)$$

$$N \geq \alpha 10^6$$

Si $\alpha \leq \alpha$, alors

$$10^6 \alpha \geq 10^6 \alpha$$

Et si $N \geq 10^6 \alpha$ alors

$$N \geq 10^6 \alpha$$

$$\alpha = \left[\frac{2\pi}{\sigma^2} \int_0^{2\pi} e^{-\frac{\kappa}{5} \sin^2(\kappa)} d\kappa - 1 \right] \text{voir (*)}$$

$$\alpha \leq \left[8\pi e^{\frac{\pi}{5}} \int_0^{2\pi} e^{-\frac{\kappa}{5}} d\kappa - 1 \right]$$

$$\alpha \leq 8\pi e^{\frac{\pi}{5}} \left[-5e^{-\frac{\kappa}{5}} \right]_0^{2\pi} - 1$$

$$\alpha \leq 8\pi e^{\frac{\pi}{5}} \left(5 - 5e^{-\frac{2\pi}{5}} \right) - 1$$

$$\# 167,5$$

$$N \geq 167,5 \times 10^6$$

$$(*) \sigma = \int_0^{2\pi} e^{-\frac{\kappa}{10} \sin^2(\kappa)} d\kappa$$

[voir pu]
okes →

$$\Theta = \int_0^{2\pi} e^{-\frac{\kappa}{10} \sin(\pi)} \nu d\kappa$$

(8')

$$= \int_0^{\pi} e^{-\frac{\kappa}{10} \sin(\pi)} \nu d\kappa + \int_{\pi}^{2\pi} e^{-\frac{\kappa}{10} \sin(\pi)} \nu d\kappa$$

$$= \int_0^{\pi} e^{-\frac{\kappa}{10} \sin(\pi)} \nu d\kappa + \int_0^{\pi} e^{-\frac{\kappa+\pi}{10} \sin(\kappa+\pi)} \nu d\kappa$$

$$= \int_0^{\pi} \sin(\kappa) \left[e^{-\frac{\kappa}{10}} - e^{-\frac{\pi}{10}} e^{-\frac{\kappa}{10}} \right] \nu d\kappa$$

$$= \int_0^{\pi} \sin(\kappa) e^{-\frac{\kappa}{10}} (1 - e^{-\frac{\pi}{10}}) \nu d\kappa$$


$$\geq \int_0^{\pi} \sin(\pi) e^{-\frac{\kappa}{10}} \left(\frac{1}{4}\right) \nu d\kappa$$

$$\geq \frac{e^{-\frac{\pi}{10}}}{4} \int_0^{\pi} \sin(\pi) \nu d\kappa$$

$$\geq \frac{e^{-\frac{\pi}{10}}}{8} \Rightarrow \frac{1}{8} \leq 4e^{\frac{\pi}{5}}$$

Exercice 4

Mise en œuvre d'un modèle
 logy-linéaire graphique
 6 variables qualitatives
 1842 individus
 modèle 1 est le modèle
 saturé
 modèle 2 est le meilleur
 modèle par une méthode
 des critères basée sur la
 critère BIC



- G || A, B, D, E, F
- B || A, E, F, D