

# TP2 : Modèles paramétriques pour les durées de vie avec ou sans covariables

Vous rédigerez un compte-rendu de ce TP dans son intégralité.

## 1 Modèle exponentiel

Soit  $X$  une variable aléatoire représentant une durée de vie (durée s'écoulant jusqu'à la survenue d'un événement d'intérêt), de loi exponentielle de paramètre  $\lambda = 1$ .

### 1.1 Simulation d'un échantillon avec contrôle du taux d'observations censurées

- ▶ Simuler à l'aide de la fonction `rexp()` un échantillon de taille  $n = 50$  de couples  $(X_i, C_i)$ ,  $i = 1, \dots, n$ , avec  $X_i$  indépendant de  $C_i$ , de lois exponentielles de paramètres respectifs  $\lambda = 1$  et  $\mu = 0.5$ .
- ▶ Définir un vecteur  $T = \min(X, C)$  et un vecteur  $\delta = \mathbb{1}(X \leq C)$ . On pourra utiliser `as.numeric(X==T)`.
- ▶ Déterminer  $\mathbb{P}(X > C)$  par un calcul exact.
- ▶ Calculer la proportion observée de censure sur l'échantillon simulé c'est-à-dire

$$1 - \frac{1}{n} \sum_{i=1}^n \delta_i.$$

Répéter plusieurs fois ce calcul pour plusieurs réalisations de l'échantillon et observer la fluctuation de la proportion de censure.

### 1.2 Estimation du paramètre $\lambda$

- ▶ Calculer une estimation ponctuelle du paramètre  $\lambda$  pour l'échantillon simulé.
- ▶ Reprendre la simulation de l'échantillon censuré de la question 1) et faire varier la taille  $n$  de l'échantillon.

Pour  $n$  allant de 10 à 5000, calculer les estimateurs  $\hat{\lambda}_n$  et les représenter graphiquement en fonction de  $n$ . On représentera aussi sur le même graphique la vraie valeur du paramètre  $\lambda = 1$ . Observer la convergence de  $\hat{\lambda}_n$ .

- ▶ Démontrer que :

$$\sqrt{n}(\hat{\lambda}_n - \lambda) \xrightarrow{\mathcal{L}} \mathcal{N}\left(0, \frac{\lambda^2}{\mathbb{P}(\delta_1 = 1)}\right)$$

En déduire un intervalle de confiance pour le paramètre  $\lambda$ .

- ▶ Pour  $n$  allant de 10 à 5000, calculer les bornes de l'intervalle de confiance, pour chaque valeur de  $n$  et les ajouter au graphique.
- ▶ Recommencer avec un échantillon simulé dont le taux de censure est de 50 %.

### 1.3 Estimation paramétrique de la fonction de survie

On construit un estimateur paramétrique  $\hat{S}_n(t) = \exp(-\hat{\lambda}_n t)$  de la fonction de survie  $S(t)$  dans le modèle exponentiel.

► Pour un échantillon de taille  $n = 30, 50, 100, 500$ , et un taux de censure correspondant à la simulation de 1.1, calculer les valeurs de l'estimateur  $\hat{S}_n(t) = \exp(-\hat{\lambda}_n t)$  pour  $t$  un vecteur de pas 0.01 allant de 0 à 3.

► Tracer la courbe représentative de  $\hat{S}_n(t)$  et superposer la courbe théorique  $S(t)$  pour les différentes tailles d'échantillons.

► On admet que

$$\sup_{t \geq 0} |\hat{S}_n(t) - S(t)| \leq \frac{|\hat{\lambda}_n - \lambda|}{\max(\lambda; \hat{\lambda}_n)}$$

en déduire une bande de confiance pour  $S(t)$  (uniforme en  $t$ ).

► Comparer graphiquement l'estimateur de Kaplan-Meier de la fonction de survie et l'estimateur  $\hat{S}_n(t)$  pour  $n = 30, 50, 100, 500$ .

## 2 Modèle Weibull

On s'intéresse maintenant à une variable aléatoire positive qui suit la loi de Weibull  $\mathcal{W}(a, b)$  de densité :

$$f(x) = (a/b)(x/b)^{a-1} \exp(-(x/b)^a), x > 0$$

où  $a, b > 0$  paramètres de forme et d'échelle (paramétrage de R)

### 2.1 Estimation des paramètres avec la fonction "survreg"

► Simuler à l'aide de la fonction `rweibull()` un échantillon de  $X_i, i = 1, \dots, n$ , de loi de Weibull  $\mathcal{W}(a, b)$  de paramètres  $a = 2$  et  $b = 5$  et  $n = 50$ .

► On pose  $Y = \log(X) = \mu + \sigma W$  où  $W$  admet pour fonction de répartition  $F_W(x) = 1 - e^{-e^x}$ ,  $x \in \mathbb{R}$ . Exprimer les paramètres  $a$  et  $b$  de la loi de  $X$  en fonction de  $\mu$  et  $\sigma$ .

► Utiliser la fonction de R `survreg` du package `survival` pour estimer  $\mu$  et  $\sigma$ . Si  $X$  est le vecteur qui contient l'échantillon de loi de  $\mathcal{W}(a, b)$  :

```
model<-survreg(Surv(X)~1, dist="weibull")
summary(model)
```

Observez ce que contiennent :

- `model$coefficients`

- `model$scale`

- `model$var`

Donner des intervalles de confiance asymptotiques de  $\mu$  et  $\sigma$  pour un niveau de confiance de 95%.

► Déduire une estimation ponctuelle de  $a$  et  $b$  de la loi  $\mathcal{W}(a, b)$ .

► La fonction `deltamethod` du package `msm` permet d'estimer la matrice de variance-covariance d'un vecteur  $g(U_n)$  à partir de celle de  $U_n$  pour  $g$  une fonction convenablement choisie. La syntaxe est la suivante si  $g : (x_1, x_2) \mapsto g(x_1, x_2) = (g_1(x_1, x_2), g_2(x_1, x_2))$  :

```
deltamethod(list(~g1(x1, x2), ~g2(x1, x2)), Un, Var(Un), ses=FALSE)
```

où  $\text{Var}(U_n)$  est la matrice de variance-covariance estimée du vecteur  $U_n$ . L'option `ses=FALSE` renvoie la matrice de variance-covariance, si `ses=TRUE` les écarts-types estimés.

► Donner des intervalles de confiance asymptotiques de  $a$  et  $b$  pour un niveau de confiance de 95% obtenus par la  $\delta$ -méthode.

## 2.2 Estimation des paramètres avec la fonction "flexsurvreg"

On reprend la même simulation (fixer la graine!) et on utilise une autre fonction `flexreg` du package `flexsurv` qui est un peu plus facile d'utilisation, mais davantage "boîte noire". De plus, elle permet de faire des graphiques facilement. La syntaxe est la suivante :

```
model2 <- flexsurvreg(Surv(X)~1, dist="weibull")
model2
plot(model2, type="survival", est=TRUE, ci=TRUE)
```

► Comparer les résultats obtenus avec `model2` et ceux précédemment obtenus. Expliquer l'utilité pratique de superposer l'estimateur de Kaplan-Meier sur la fonction de survie estimée dans le modèle de Weibull.

► Reprendre la simulation avec un échantillon censuré. On pourra conserver la même loi  $\mathcal{W}(a, b)$  pour l'échantillon  $(X_i)_{i=1, \dots, n}$  et simuler l'échantillon  $(C_i)_{i=1, \dots, n}$  selon une loi exponentielle de paramètre  $\mu$  calibré de façon à obtenir environ 25% de censure pour  $n = 50$ , puis pour  $n = 100$ .

## 3 Autres modèles paramétriques

Reprendre rapidement le paragraphe précédent pour une autre loi de  $X$  de votre choix (log-logistique, log-normale, gamma, etc).

## 4 Ajout d'une covariable

On s'intéresse maintenant à un modèle de régression avec une covariable  $Z$ .

$$Y = \log(X) = \mu + \gamma Z + \sigma W$$

### 4.1 Simulation et estimation des paramètres

► Simulation.

- Générer des variables  $(W_i)_{i=1, \dots, n}$  de fonction de répartition  $F_W(x) = 1 - \exp(-\exp(x))$ ,  $x \in \mathbb{R}$ , pour  $n=100$ .
- Puis générer les  $(X_i)_{i=1, \dots, n}$  selon le modèle de régression log-linéaire  $\ln(X_i) = \mu + \gamma Z_i + W_i$  avec  $\mu = 2$ ,  $\gamma = 3$  et  $\sigma = 0.5$  et pour une covariable binaire  $Z$  telle que  $Z_i = 0$  pour  $i = 1, \dots, n/2$  et  $Z_i = 1$  pour  $i = n/2 + 1, \dots, n$  (prendre  $n$  pair).

► Générer un échantillon censuré avec l'échantillon  $(C_i)_{i=1, \dots, n}$  selon une loi exponentielle de paramètre  $\mu = 0.01$ .

- ▶ Utiliser la fonction `survreg` pour donner une estimation de  $\mu$ ,  $\gamma$  et  $\sigma$ .
- ▶ Modifier la valeur de  $n = 100, 200, 500$  et le taux de censure (avec  $\mu = 0.01, 0.003$ ) et faire une étude de la sensibilité (en examinant par exemple les écarts-types des estimateurs).

#### 4.2 Examen des résidus de Cox-Snell

- ▶ Déterminer les résidus de Cox-Snell  $(R_i)_{i=1, \dots, n}$  associés à l'hypothèse du modèle de Weibull où  $R_i = \hat{\Lambda}_{\hat{\mu}, \hat{\gamma}, \hat{\sigma}}(T_i)$ .
- ▶ A l'aide de la fonction `survfit`, représenter graphiquement l'estimateur de Nelson-Aalen de la fonction de risque cumulé de l'échantillon censuré  $(R_i, \delta_i)$  et superposer la droite d'équation  $y = x$  correspondant à la fonction de risque cumulé d'une loi exponentielle de paramètre 1.
- ▶ Examiner l'adéquation du modèle de Weibull à l'aide de ce graphique.

### 5 Application au jeu de données réelles "pharmacoSmoking".

- ▶ Proposer une analyse statistique de ces données en ajustant plusieurs modèles de régression (avec hypothèse de loi Weibull, log-logistique et log-normale) pour une ou plusieurs covariables de votre choix. En particulier :
  - ▶ Examiner les valeurs des AIC pour le choix de modèle
  - ▶ Superposer les courbes de survie ajustées avec les trois modèles paramétriques et avec l'estimateur de Kaplan-Meier (on pourra aussi choisir de comparer les courbes de risques cumulés). Utiliser `flexsurvreg` pour les graphiques et convertir la covariable en facteur afin de pouvoir superposer les courbes des deux groupes avec la fonction `plot`.
  - ▶ Examiner les résidus de Cox-Snell pour les trois modèles paramétriques.
  - ▶ Examiner éventuellement d'autres modèles de lois disponibles dans `flexsurvreg` (visualisation graphique seulement ...).
- ▶ Conclure en faisant le lien avec le TP1.