

(1)

TD n°1 (Analyse de survie)

Des indications sur la résolution des exercices

Ex 1 1) Facile

2)  $Y_i(t) = \mathbb{1}_{(X_i > t)}$  (au lieu de  $Y_i(t) = \mathbb{1}_{(X_i \geq t)}$ ) pour  $t \geq 0$ .

$P(Y_i = 1) = P(X_i > t) = (1 - F(t))(1 - G(t))$  (cf 1<sup>ère</sup> question)

Donc  $Y_i \sim B((1 - F(t))(1 - G(t)))$ . (loi de Bernoulli de para.  $(1 - F(t))(1 - G(t))$ )

$Y_n(t) = \sum_{i=1}^n Y_i(t)$  où les  $Y_i$   $i=1, \dots, n$  sont indépendantes de la loi  $B(p)$   
où  $p = (1 - F(t))(1 - G(t))$ .

Ainsi  $Y_n(t)$  suit une loi Binomiale  $B(n, p)$ .

3) Soit  $J_n(t) = \mathbb{1}_{(Y_n(t) > 0)} = 1 - \mathbb{1}_{(Y_n(t) \leq 0)} = 1 - \mathbb{1}_{(Y_n(t) = 0)}$

Montrons que  $\mathbb{1}_{(Y_n(t) = 0)} \xrightarrow[n \rightarrow \infty]{P} 0$ ? et ainsi  $J_n(t) \xrightarrow{P} 1$ .

Soit  $\epsilon > 0$ . On a  $P(\mathbb{1}_{(Y_n(t) = 0)} > \epsilon) = \cancel{P(\mathbb{1}_{(Y_n(t) = 0)} = 1)} = P(Y_n(t) = 0)$

Or  $Y_n(t) \sim B(n, p)$  donc  $P(Y_n(t) = k) = \binom{n}{k} p^k (1-p)^{n-k}$ ,  $k=0, \dots, n$ .

et donc  $P(Y_n(t) = 0) = (1-p)^n = (1 - (1 - F(t))(1 - G(t)))^n$ .

Avec  $(1 - F(t))(1 - G(t)) < 1$  on a  $P(Y_n(t) = 0) \rightarrow 0$ .

Pour la v.a.  $Y_n(t)$  on a par la loi faible des Grands nombres :

$\frac{1}{n} Y_n(t) = \frac{1}{n} \sum_{i=1}^n Y_i(t) \xrightarrow{P} E(Y_n(t)) = (1 - F(t))(1 - G(t))$

On a d'après 3)  $\frac{J_n(t)}{\frac{Y_n(t)}{n}} = \frac{J_n(t)}{\frac{Y_n(t)}{n}} \xrightarrow{P} \frac{1}{(1 - F(t))(1 - G(t))}$  si  $(1 - F(t))(1 - G(t)) > 0$

Par suite  $\frac{J_n(t)}{Y_n(t)} \xrightarrow{P} \left(\frac{1}{n}\right) \cdot \left(\frac{n J_n(t)}{Y_n(t)}\right) \xrightarrow{P} 0 \cdot \frac{1}{(1 - F(t))(1 - G(t))} = 0$



5) De  $\tilde{H}_n(t) = \int_0^t J_n(s) h(s) ds$  pour  $t > 0$ , on a :

$$E(\tilde{H}_n(t)) = \int_0^t E(J_n(s)) h(s) ds \quad (\text{par Fubini})$$

$$\text{Or } E(J_n(s)) = E(\mathbb{1}_{(Y_n(s) > 0)}) = P(Y_n(s) > 0) \xrightarrow{n \rightarrow \infty} 1 \quad (\text{par 3}^\circ)$$

et  $|E(J_n(s)) h(s)| \leq h(s)$ . Or  $\int_0^t h(s) ds = H(t) < \infty$ , par suite Th. C.D

$$E(\tilde{H}_n(t)) \xrightarrow{n \rightarrow \infty} \int_0^t h(s) ds = H(t), \quad \text{et } E(\tilde{H}_n(t) - H(t)) \xrightarrow{n \rightarrow \infty} 0.$$

Ex 2. 1°) déjà vu en TD !

2°) voir cours !

3°) Dans le cas de v.a. censurées soit l'estimateur  $\tilde{S}_n(t)$  :

$$\tilde{S}_n(t) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{(T_i > t, D_i = 1)}$$

ici on introduit la v.e.  $D_i$  qui exprime l'existence de v. censurées

Rappelons que les  $(T_i)$  sont iid.  $(C_i)$  iid. et  $(T_i) \perp (C_i)$

On note  $f_T$  la densité de  $T$  et  $f_C$  celle de  $C$ .


Rappel : si  $Z_i := \mathbb{1}_{(T_i \leq C_i)}$  alors  $Z_i \sim B(p)$  (sont iid).

$$\text{ou } p = \int_0^\infty S_C(t) f_T(t) dt \quad \text{ou } S_C(t) = P(C > t) = 1 - F_C(t)$$

$$\text{En effet : } P(Z_i = 1) = P(T_i \leq C_i) = P((T_i, C_i) \in I)$$

$$= \iint_I f_{(T,C)}(x,y) dx dy = \iint_I f_T(x) f_C(y) dx dy$$

$$= \int_0^\infty \left( \int_x^\infty f_C(y) dy \right) f_T(x) dx = \int_0^\infty \underbrace{P(C > x)}_{S_C(x)} \cdot f_T(x) dx = p$$





(3)

Pour l'estimation de  $\tilde{S}_n(t)$ :

De même on pose  $U_i := \mathbb{1}_{(T_i > t, D_i = 1)}$  (des var. de Bernoulli) iid!

$$\begin{aligned} \text{et on a: } P(U_i = 1) &= P(T_i > t, D_i = 1) = P(T_i > t, T_i \leq C_i) \\ &= P(t < T_i \leq C_i) = \int_t^{\infty} \left( \int_x^{\infty} f_C(y) dy \right) f_T(x) dx \\ &= \int_t^{\infty} S_C(x) \cdot f_T(x) dx \end{aligned}$$

Donc  $U_i \sim B(q)$  avec  $q = \int_t^{\infty} S_C(x) f_T(x) dx$ .

Par suite en appliquant la LFGN on arrive à:

$$\tilde{S}_n(t) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{(T_i > t, D_i = 1)} \stackrel{\text{P.P.S}}{\longrightarrow} \frac{1}{n} \sum_{i=1}^n U_i \longrightarrow E(U_i) = q.$$

$$\text{i.e. } \tilde{S}_n(t) \xrightarrow{\text{P.P.S.}} \int_t^{\infty} S_C(x) f_T(x) dx.$$

$$\begin{aligned} \text{Mais } \int_t^{\infty} S_C(x) f_T(x) dx &= \int_t^{\infty} (1 - F_C(x)) f_T(x) dx = \int_t^{\infty} f_T(x) dx - \int_t^{\infty} F_C(x) f_T(x) dx \\ &= S_T(t) - \int_t^{\infty} F_C(x) f_T(x) dx < S_T(t) \quad \left| \begin{array}{l} \text{si il y a censure} \\ \text{le } F_C(x) \neq 0 \end{array} \right. \end{aligned}$$

Donc  $\tilde{S}_n(t) \not\rightarrow S_T(t)$  dans le cas d'existence de censure

En fait  $\tilde{S}_n(t) \xrightarrow{\text{P.P.S.}} \ell$  avec  $\ell < S_T(t)$ .



TD n°2. Analyse de survie

Ex I et Ex II déjà faits !

Ex III Avec  $f_T(t) = \frac{\lambda \alpha t^{\alpha-1}}{(1 + \lambda t)^\alpha}$ ,  $t \geq 0, \lambda > 0, \alpha \geq 1$

On a  $S_T(t) = \int_t^\infty f_T(t) dt = \dots$

à calculer !

et  $h(t) = \frac{f_T(t)}{S_T(t)} = \dots$

Ex IV Ici  $T \sim \mathcal{E}(\theta)$  loi exponentielle de paramètre  $\theta > 0$   
 $C \sim \mathcal{E}(\beta)$  " " " "  $\beta > 0$

et refaire les calculs de l'Ex II cette fois avec ces deux lois exponentielles..

Ex V Avec la présence dans les données de l'événement de censure v. d'individus censurés ( $S^+$  etc...) on utilise l'estimateur  $\hat{S}_{KM}$

On calcule l'estimateur de Kaplan-Meier  $\hat{S}_{KM}(t)$  par :

(\*)  $\hat{S}_{KM}(t) = \prod_{\substack{t_{(j)} \leq t \\ t_{(j)} = t_{(j)}^*}} \left(1 - \frac{m_j}{n_j}\right)^{D_j}$  où  $t_{(1)} < t_{(2)} < \dots < t_{(n)}$

où  $m_j$  = nombre d'événements E (observés) avant à  $t_{(j)}$

$n_j$  = nombre "d'individus à risque" (en vie) à  $t_{(j-1)}$

$n_j = n - \sum_{s=1}^{j-1} m_s - \sum_{s=j}^{j-1} c_s$

avec  $c_j$  = nombre de censures dans l'intervalle  $[t_{(j-1)}, t_{(j)})$



(5)

ou encore 
$$m_i = n_{i-1} - m_{i-1} - c_{i-1}$$

et  $m_{i-1}$  = nombre d'événements (obs) à  $t_{(i-1)}$

$c_{i-1}$  = nombre de va censurées de  $[t_{(i-1)}, t_{(i)}[$ ,  $i > 1$

et on calcule  $\hat{S}_{KM}(t)$  dans chaque intervalle  $[t_{(i-1)}, t_{(i)}[$

et  $\hat{S}_{KM}(t)$  est constant dans  $t \in [t_{(i-1)}, t_{(i)}[$

(voir l'exemple du cours!)

Pour le taux de service  $h(t)$  (ou fonction de usque):

un estimateur est  $\hat{h}_n(t_{(i)}) = \frac{m_i}{n_i}$ ,  $i = 1, 2, \dots, n$

puis on fait une interpolation linéaire entre les points  $(t_{(i)}, \hat{h}_n(t_{(i)}))$ .

Traiter les graphes correspondants à  $\hat{S}_{KM}(t)$  et  $\hat{h}_n(t)$ .

Remarque: les instants  $t_{(i)}$  correspondent soit à l'observation de l'événement E, ou une censure.