

Cours 2 : notes

Slide 16.

2 individus X_{i1} et X_{i2}

$$\frac{\lambda(t|X_{i1})}{\lambda(t|X_{i2})} = \frac{\cancel{\lambda_0^*(t)} e^{X_{i1}\beta^*}}{\cancel{\lambda_0^*(t)} e^{X_{i2}\beta^*}} = \exp((X_{i1} - X_{i2})\beta^*)$$

Ça ne dépend pas du temps.

$t \mapsto \lambda(t|X_{i1})$ et $t \mapsto \lambda(t|X_{i2})$

elles sont proportionnelles en tant que fonctions du temps.

\Rightarrow Proportional hazards model.

Slide 17.

Hazards ratio. Je suppose $X_{i1}^k = X_{i2}^k \forall k \neq j$
et $X_{i1}^j = X_{i2}^j + 1$.

$$\begin{aligned} \frac{\lambda(t|X_{i1})}{\lambda(t|X_{i2})} &= \exp\left(\sum_{k=1}^p (X_{i1}^k - X_{i2}^k) \beta_k^*\right) \\ &= \exp\left(\sum_{k=1}^p (X_{i1}^k - X_{i2}^k) \beta_k^*\right) \\ &= \exp\left((X_{i1}^j - X_{i2}^j) \beta_j^*\right) = \exp(\beta_j^*) \end{aligned}$$

$\exp(\beta_j^*)$ = valeur par laquelle est hazard ratio.
multiplié le hazard quand la cov.
 j° augmente, toutes choses égales
par ailleurs.

Slide 21.

$$\begin{aligned}
 L &\propto \prod_{i=1}^n f(T_i^c/x_i)^{\delta_i} \bar{F}(T_i^c/x_i)^{1-\delta_i} \\
 \text{prop à} &= \prod_{i=1}^n \left(\frac{f(T_i^c/x_i)}{\bar{F}(T_i^c/x_i)} \right)^{\delta_i} \bar{F}(T_i^c/x_i) \\
 &= \prod_{i=1}^n \lambda(T_i^c/x_i)^{\delta_i} \exp(-\Lambda(T_i^c/x_i))
 \end{aligned}$$

Rappel
 $F(t) = \exp(-\Lambda(t))$

dans le modèle de Cox.

$$\begin{aligned}
 &= \prod_{i=1}^n \lambda_0(T_i^c)^{\delta_i} \exp(X_i\beta)^{\delta_i} \exp\left(-\int_0^{T_i^c} \lambda_0(t) \exp(X_i\beta) dt\right) \\
 &= \prod_{i=1}^n \lambda_0(T_i^c)^{\delta_i} \exp(X_i\beta)^{\delta_i} \exp\left(-\exp(X_i\beta) \Lambda_0(T_i^c)\right)
 \end{aligned}$$

où $\Lambda_0(t) = \int_0^t \lambda_0(s) ds$.

$$\begin{aligned}
 \log L &= \sum_{i=1}^n \delta_i \log \lambda_0(T_i^c) + \delta_i \log \exp(X_i\beta) \\
 &\quad - \exp(X_i\beta) \Lambda_0(T_i^c).
 \end{aligned}$$

On remarque que

voir page suivante

$$\sum_{i=1}^n \lambda_0(T_i^c) \exp(X_i\beta) = \sum_{i=1}^n \lambda_0(T_i^c) \sum_{j: T_j^c > T_i^c} \exp(X_j\beta)$$

$$\begin{aligned}
 \Leftrightarrow & \begin{pmatrix} d_0^1 \\ \vdots \\ d_0^n \end{pmatrix} \\
 & \sum_{i=1}^n \delta_i \log d_0^i + \delta_i \log \exp(X_i\beta) \\
 & - \exp(X_i\beta) \sum_{j: T_j^c > T_i^c} d_0^j
 \end{aligned}$$

On dérive w.r.t. to d_0^i

$$\frac{\delta_i}{d_0^i} - \sum_{j: T_j^c > T_i^c} \exp(X_j\beta) = 0$$

$$\textcircled{*} \sum_{i=1}^n \lambda_0(T_i^c) \exp(X_i \beta)$$

$$= \sum_{i=1}^n \sum_{j: T_j^c \leq T_i^c} \lambda_0(T_j^c) \exp(X_i \beta)$$

$$= \sum_{j=1}^n \left(\sum_{i: T_i^c \geq T_j^c} \exp(X_i \beta) \right) \lambda_0(T_j^c)$$

en
échangeant
les 2
sommées.

$$\hat{\lambda}_0^j = \frac{\delta_i}{\sum_{j: T_j^c > T_i^c} \exp(X_j \beta)}$$

ce n'est pas un estimateur car il dépend de β inconnue.

Pour une valeur β fixée c'est le mieux qu'on puisse faire.

$$\sum_{i=1}^n \delta_i \log \frac{\delta_i}{\sum_{j: T_j^c > T_i^c} \exp(X_j \beta)} + \delta_i X_i \beta - \exp(X_i \beta) \frac{\sum_{k: T_k^c \leq T_i^c} \delta_k}{\sum_{j: T_j^c > T_i^c} \exp(X_j \beta)}$$

on n'a plus de dépendance de nouvelle log-vraisemblance qui ne dépend plus du paramètre λ_0 . \rightarrow log-vraisemblance partielle de Cox.

On la maximise $\hat{\beta}$ puis on injecte $\hat{\beta}$ dans " $\hat{\lambda}_0^j$ " ($\hat{\beta}$) = $\frac{\delta_i}{\sum_{j: T_j^c > T_i^c} \exp(X_j \hat{\beta})}$

Slide 30.

le risque de l'individu i $\lambda_0^*(t) \exp(X_i \beta^*)$
 j $\lambda_0^*(t) \exp(X_j \beta^*)$

$$M_i = X_i \hat{\beta}^* \text{ et } M_j = X_j \hat{\beta}^*$$

Si $M_i = X_i \hat{\beta}^* > X_j \hat{\beta}^* = M_j$ alors le risque de $i >$ risque de j en tout temps.

$$D_i^*(t) \exp(X_i \beta^*) > D_j^*(t) \exp(X_j \beta^*)$$

\Rightarrow on s'attend à ce que i meurt avant j
 $T_i < T_j$.

On dit qu'il y a concordance quand une paire i, j telle $T_i < T_j$ on a $X_i \beta^* > X_j \beta^*$.

on ne l'observe pas toujours à cause des censure.

\rightarrow C-index = proportion d'observations concordantes dans l'échantillon.

⚠ est seulement une mesure de discrimination.

Prediction dans un modèle de Cox.
 coxph $\rightarrow \hat{\beta}$ pour un nouvel ind X_+ .

predict (coxph, X_+) $\rightarrow X_+ \hat{\beta}$.

surfit (coxph) $\rightarrow \hat{\lambda}_0$

$$\rightarrow \exp \left(- \underbrace{\hat{\lambda}_0(t)}_{\text{Breslow}} e^{X_+ \hat{\beta}} \right) = \hat{F}(t | X_+)$$

Breslow