

# Biostatistique : Analyse de Survie

A. Latouche

# Données Censurées

- Régression logistique : Variable réponse binaire

- Statut vital : codé en 0 ou 1

- Présence d'une pathologie

- Si 2 patients décèdent : un à 1 mois et l'autre à 12 mois

- Ils auront le même Statut vital pour une régression logistique

⇒ Perte d'information majeure

# Délais d'événement

## Ojectifs


- Estimer les fonctions de survie de ses délais
  - Tester l'égalité de fonctions de survie entre 2 groupes de patients
  - Modèles de régression pour étudier l'effet de facteurs sur le délai de survie
- 
- Délai : **durée** entre survenue de 2 événements (identique ou pas)
  - Terminologie *End-Point*, Critère de jugement censuré

# Exemples de délais jusqu'à un événement

- Première chute
- Apparition de la démence
- Première naissance


Modèle à 2 états : Origine et Survenu de l'événement d'intérêt

## Time to fall




<http://www.ncbi.nlm.nih.gov/pubmed/12020141>

# Time to dementia



<http://www.ncbi.nlm.nih.gov/pubmed/16418406>



- Que représente la flèche  $\rightarrow$  ?
- Quelle est l'échelle de temps à utiliser (origine) ?
  - Délai depuis l'entrée dans un étude/ délai depuis la naissance
  - Fiabilité d'un voiture : Age ou Kilométrage ?


## Formalisme : Données censurées à droite

- Délai : modélisé par une variable aléatoire **positive**  $T$
- Pas toujours observé sur la durée de l'étude : censure  $C$


Pour chaque patient on observe un délai et un statut (0 si pas d'événement, 1 si événement)

- Si  $T < C$  : on observe l'élément et le statut est 1 (l'evt n'est pas censuré)
- Si  $T > C$  : on n'observe pas l'événement et le statut est 0 (evt censuré)

## Données de greffes de moëlle : Délai jusqu'au décès



# Données simulées



# Modélisation paramétrique pour $T$

- Loi exponentielle
- Loi de Weibull
- ...

Ces lois continues sont caractérisées par leur densité de probabilité  
Rappel pour une v.a. continue

$$\int_{\mathcal{D}_f} f(t)dt = 1$$

et

$$f(t) = \frac{P(t \leq T < t + dt)}{dt}$$

# Fonction de répartition et de Survie

Soit  $T$  une v.a. positive

- $F(t) = \int_0^t f(u)du = P(T \leq t)$
- $F$  représente la fraction des individus ayant présenté l'événement d'intérêt avant l'instant  $t$
  
- $S(t) = \int_t^\infty f(u)du = P(T > t)$
- $S$  représente la fraction des individus sans l'événement à l'instant  $t$

$$S(t) = 1 - F(t)$$

## Risque instantané (hazard rate)

Le risque instantané

$$\lambda(t) \approx \frac{P(t \leq T < t + dt | T > t)}{dt}$$

où  $dt$  est un petit intervalle de temps

d'où

$$\lambda(t) = \frac{P(t \leq T < t + dt)}{dt P(T > t)}$$

soit

$$\lambda(t) = f(t)/S(t)$$

**Pour décrire  $T$  on peut utiliser soit  $\lambda$  soit  $S$**

## Risque cumulé et Survie

$$\Lambda(t) = \int_0^t \lambda(u) du$$

Comme


$$\lambda(t) = \frac{f(t)}{S(t)} = \frac{d(\log(F(t)))}{dt}$$

$$\lambda(t) = -\frac{d(\log(S(t)))}{dt}$$

$$S(t) = \exp -\Lambda(t)$$

Graphique du risque cumulé : informe sur la variation du risque instantané

## Risque cumulé de décès



<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3285233/figure/F1/>

## Choix d'un modèle paramétrique

La loi de  $T$  est décrite par  $\lambda$

- Si on choisit un risque constant ( $= L$ )
- Que valent  $f$ ,  $F$  et  $S$  ?

## Choix d'un modèle paramétrique


La loi de  $T$  est décrite par  $\lambda$

- Si on choisit un risque constant ( $= L$ )
- Que valent  $f$ ,  $F$  et  $S$  ?


On dit que  $T \sim \text{Exp}(L)$ , Loi exponentielle de paramètre  $L$

- $f(t) = L \exp(-L t)$  pour  $t \geq 0$
- $S(t) = \exp(-L t)$
- $F(t) = 1 - \exp(-L t)$


# Densité de probabilité Loi Exp(1)



## Risque instantané : Loi Exp(1)




## Risque Cumulé : : Loi Exp(1)




# Loi de Weibull

- La fonction de risque est plus *flexible*
- 2 paramètres *shape* ( $\beta$ ) et *scale* (L)
- Risque :  $\lambda(t) = L\beta(Lt)^{\beta-1}$
- Survie :  $S(t) = \exp(-(Lt)^\beta)$
  
- Si  $\beta = 1$  :  $Exp(L)$  et risque constant
- Si  $\beta < 1$  risque décroissant
- Si  $\beta > 1$  risque croissant


## Densité de la loi Weibull(0.5,1)




## Densité de la loi Weibull(1,1)




## Densité de la loi Weibull(2,1)




## Densité de la loi Weibull(4,1)



# Risque Cumulé $\beta > 1$



# Risque Cumulé $\beta < 1$



# Estimateur de Kaplan-Meier

## Objectif

Estimer la fonction de survie quand les données sont censurées à droite

Sans censure on estime la fonction de répartition par

$$\hat{F}(t) = \frac{1}{n} \sum_{i=1}^n \mathbf{I}(T_i \leq t)$$

La méthode de Kaplan-Meier découle du raisonnement simple suivant :

Ne pas encore avoir subi l'évènement à l'instant  $t$  c'est :

- ne pas l'avoir subi juste avant  $t$
- et ne pas le subir en  $t$ .

# Estimateur de Kaplan-Meier

Soient  $t_1 < \dots < t_k$  les différents temps d'évènements observés, alors on peut définir :

- $d_j$  : nombre de sujets subissant l'évènement au temps  $t_j$
- $c_j$  : nombre de sujets *censurés* dans l'intervalle  $[t_j, t_{j+1}[$
- $n_j$ : nombre de sujets à risque au temps  $t_j$  (effectif à risque)

Calcul des individus à risque

$$n_j = n_{j-1} - c_{j-1} - d_{j-1}$$

## Estimateur de Kaplan-Meier

ne pas encore avoir subi l'évènement en  $t_j$  c'est

- ne pas encore avoir subi l'évènement en  $t_{j-1}$
- et ne pas le subir en  $t_j$ ,

En utilisant les probabilités conditionnelles on obtient

$$\begin{aligned}\hat{S}(t_j) &= \hat{P}(X > t_j) \\ &= \hat{P}(X > t_j | X > t_{j-1}) \times \hat{P}(X > t_{j-1}) \\ &= \hat{P}(X > t_j | X > t_{j-1}) \times \hat{P}(X > t_{j-1} | X > t_{j-2}) \\ &\quad \times \hat{P}(X > t_{j-2}) \\ &\quad \dots \hat{P}(X > t_2 | X > t_1)\end{aligned}$$

Chaque probabilité  $P(X > t_j | X > t_{j-1})$  est estimée par  $(n_j - d_j)/n_j$

$$\hat{S}(t) = \prod_{t_j < t} \frac{n_j - d_j}{n_j}$$

## Présentation des données censurées (kidney package KMsurv)


time : delay d'infection en mois

type : intervention pour la pause du catheter

	time	delta	type
1	1.50	1	1
2	3.50	1	1
3	4.50	1	1
4	4.50	1	1
5	5.50	1	1
6	8.50	1	1

`table(kidney$delta)` nous fournit les effectifs en fonction du status  
soit 93 patients avec `status=0` et 26 patients avec `status=1`  
Soit 78% de données censurées

## Estimation de la fonction de survie



package : KMsurv, data(kidney)

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
---------	-------------	--------------------	-------	------

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
$[0; 2[$	0	5	0/5	1

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
$[0; 2[$	0	5	$0/5$	1
$[2; 3[$	1	5	$1/5$	$1-1/5=0.8$

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
$[0; 2[$	0	5	$0/5$	1
$[2; 3[$	1	5	$1/5$	$1-1/5=0.8$
$[3; 4[$	2	4	$2/4$	$(1-1/5)(1-1/2)$

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
$[0; 2[$	0	5	$0/5$	1
$[2; 3[$	1	5	$1/5$	$1-1/5=0.8$
$[3; 4[$	2	4	$2/4$	$(1-1/5)(1-1/2)$
$[4; 6[$	1	2	$1/2$	$0.4*1/2$

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
[0; 2[	0	5	0/5	1
[2; 3[	1	5	1/5	$1 - 1/5 = 0.8$
[3; 4[	2	4	2/4	$(1 - 1/5)(1 - 1/2)$
[4; 6[	1	2	1/2	$0.4 * 1/2$
[6; [	1	1	1/1	0

## Données Censurées : Estimation de la fonction de survie

$$S(t) = P(T > t)$$

Sujet	Delai	Status
1	2	1
2	3	1
3	3	1
4	4	1
5	6	1

Compléter le tableau suivant

Période	Nb de décès	Individus à risque	Proba	Taux
[0; 2[	0	5	0/5	1
[2; 3[	1	5	1/5	$1 - 1/5 = 0.8$
[3; 4[	2	4	2/4	$(1 - 1/5)(1 - 1/2)$
[4; 6[	1	2	1/2	$0.4 * 1/2$
[6; [	1	1	1/1	0

## Exercice

La médiane de survie est de 12 mois chez un groupe de souris. On suppose que l'on peut modéliser le délai de survie par une loi exponentielle.

- Quelle est la probabilité qu'une souris encore en vie au bout d'un an, décède dans la 2eme année ?
- $P(X < 24|X > 12) = P(12 < X < 24)/P(X > 12) = (P(X < 24) - P(X < 12))/0.5$
- Propriété la loi exponentielle est sans mémoire. En effet  $P(X > b|X > a) = P(X > b)/P(X > a)$  or  $P(X > a) = \exp(-\lambda a)$  donc  $P(X > b)/P(X > a) = \exp(-\lambda b)/\exp(-\lambda a)$

$$P(X > b|X > a) = P(X > b - a)$$