

Introduction aux analyses de survie

Yohann.Foucher@univ-nantes.fr

Master 2 - Modélisation en Pharmacologie Clinique et Epidémiologie



UNIVERSITÉ DE NANTES



CENTRE HOSPITALIER
UNIVERSITAIRE DE NANTES

itun

institut
transplantation
urologie
néphrologie
INSERM - UMRI 643

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

1. Introduction

2. Définitions

3. Kaplan-Meier

Estimation

Variance

4. LogRank

5. Distributions paramétriques

Les principales lois

L'estimation des paramètres

6. Modèle de Cox

Définitions

Inférence

Hypothèses

Risques Proportionnels

Log linéarité

7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

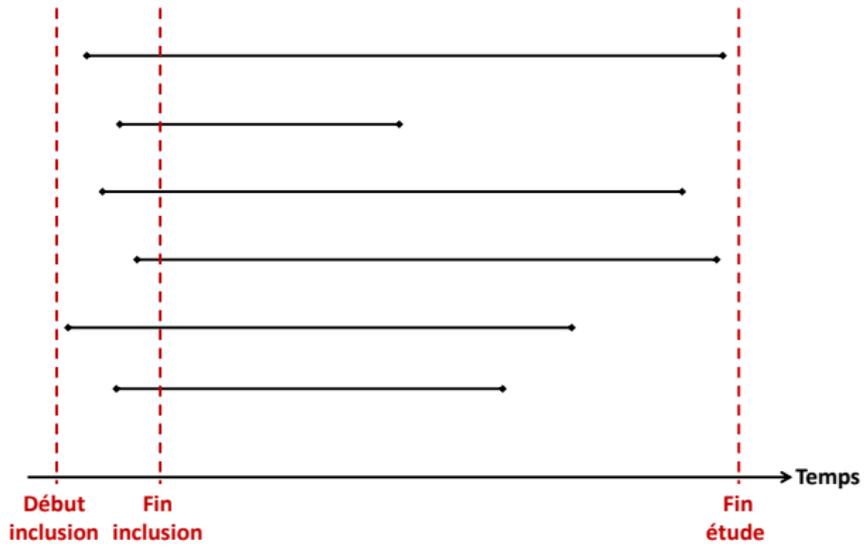
Hypothèses

Perspectives

- Etude des facteurs influençant l'apparition d'un événement.
- Variable à expliquer : Temps d'apparition d'un événement
- Soit T cette variable aléatoire (v.a.)
- Exemples :
 - Est ce que le tabagisme réduit le temps d'apparition d'un décès ?
↔ Est ce que le tabagisme réduit la **survie** ?
- Le décès a souvent été l'événement étudié en médecine, d'où le terme survie.
- D'autres temps peuvent être étudié (*time-to-event analysis*).

Illustration

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives



$$E[T|x_1, x_2, \dots] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots$$

- T : v.a représentant le temps de l'événement (ex : mois).
- x_1, x_2, \dots les variables explicatives d'intérêt.
- β_1, β_2, \dots les coefficients de régression.

→ β_1 représente le nombre moyen de mois supplémentaires avant l'évènement dans le groupe $x_1 = 1$ par rapport au groupe $x_1 = 0$.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

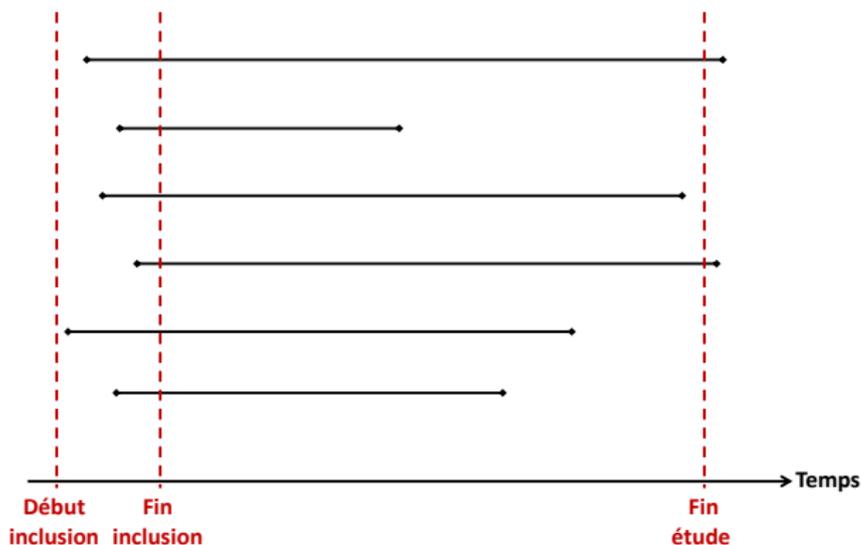
Inférence

Hypothèses

Perspectives

Problème de la censure à droite

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives



On ne connaît pas les temps d'apparition des événements pour les patients 1 et 4 → Régression linéaire impossible (valeurs manquantes informatives).

- Rappel : T est la v.a du temps d'apparition de l'événement.
 - Soit t_i le temps observé d'apparition de l'événement pour le sujet i ($i = 1, \dots, N$).
- Le temps de censure à droite, C , est une autre v.a. représentant le temps entre l'inclusion (origine, J_0 , *baseline*) et la fin du suivi qui aurait lieu indépendamment de l'événement.
 - Ex : Fin de l'étude, déménagement, perdu de vue, etc.
 - Soit c_i le temps de censure observé pour le sujet i ($i = 1, \dots, N$).
- Si y_i est le temps de suivi du sujet i , deux situations peuvent être distinguées :
 - Si $t_i \leq c_i$: on observe exactement le temps d'événement.
→ $y_i = t_i$ et $\delta_i = 1$.
 - Si $t_i > c_i$: le temps d'événement est inconnu, mais on sait qu'il est supérieur à c_i .
→ $y_i = c_i$ et $\delta_i = 0$.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Sujet (i)	Sexe (x_{1i})	Age (x_{2i})	Temps (y_i)	Evt (δ_i)
1	1	15	32	0
2	0	25	13	1
3	1	74	25	1
4	0	63	26	0
.
.
N

Comment modéliser T si ces observations sont incomplètes ?

- Régression linéaire impossible car données manquantes informatives (on observe Y mais pas T).
- Quid d'une régression logistique pour expliquer la variable binaire δ ?

$$\text{logit}\left(\text{Pr}(\delta = 1|x_1, x_2, \dots)\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots$$

- δ : v.a. à expliquer binaire
- x_1, x_2, \dots les variables explicatives d'intérêt.
- β_1, β_2, \dots les coefficients de régression.

→ $\exp(\beta_1)$ représente l'odds ration du groupe $x_1 = 1$ par rapport au groupe $x_1 = 0$.

Problème

- Un patient avec un long suivi a plus de chance d'être $\delta = 1$.
- Biais majeur dans l'estimation des effets des variables explicatives qui seront aussi explicatives du temps de suivi...

⇒ Nécessité de modèles spécifiques ⇐

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

- N : la taille de l'échantillon ($i = 1, \dots, N$).
- T : la v.a. représentant le temps d'apparition de l'événement.
- C : la v.a. représentant le temps de censure à droite.
- On ne peut observer qu'une seule résultante des deux v.a. :

$$Y = \min(T, C)$$

- y_i : l'observation pour le sujet i de Y .
- δ : l'indicatrice de l'événement avec :
 - $\delta_i = 1$ si y_i correspond à un temps d'événement.
 - $\delta_i = 0$ si y_i correspond à un temps de censure.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

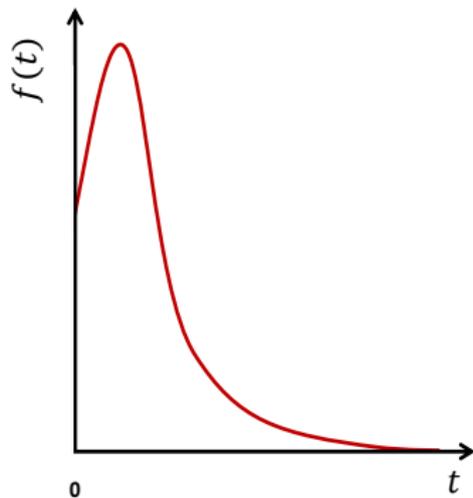
Perspectives

La fonction de densité de probabilité $f(t)$ représente la limite de probabilité que l'événement se produise au temps t .

$$f(t) = \lim_{\Delta t \rightarrow 0} Pr(t \leq T < t + \Delta t) / \Delta t$$

Même si il s'agit d'une limite, il est plus simple d'intuiter cette fonction comme la probabilité que l'événement se produise à peu près au temps t .

La fonction de densité $f(t)$



Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

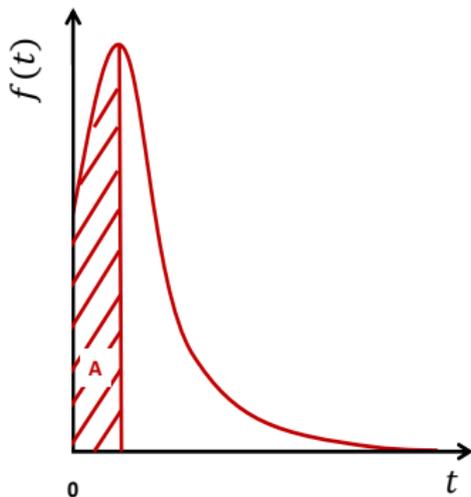
Perspectives

La fonction de répartition $F(t)$ est la probabilité que l'événement se produise avant t .

$$F(t) = Pr(T \leq t) = 1 - S(t) = \int_0^t f(u) du$$

$F(t) \in [0, 1]$, c'est une probabilité. Elle est croissante de 0 en 1. La probabilité d'avoir eu l'événement avant l'origine est égale à nulle : $F(0) = 0$. La probabilité d'avoir eu l'événement avant en temps de suivi très long est certaine : $F(\infty) = 1$.

La fonction de répartition $F(t)$



Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

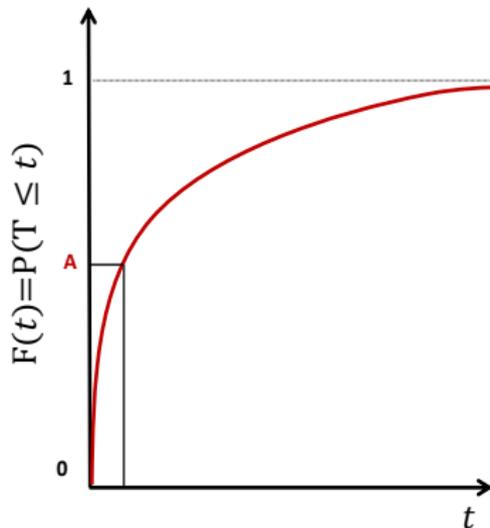
Définitions

Inférence

Hypothèses

Perspectives

La fonction de répartition $F(t)$



Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

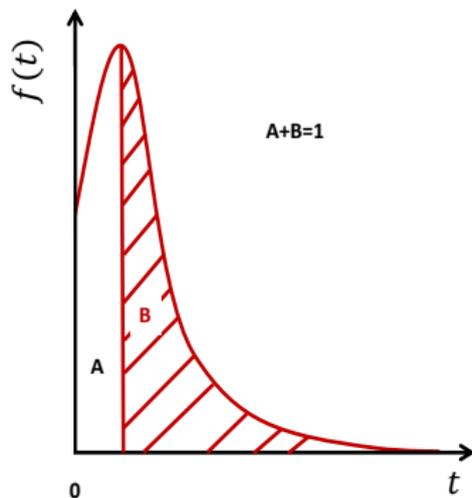
La fonction de survie $S(t)$ est la probabilité que l'événement se produise après t .

$$S(t) = Pr(T > t) = \int_t^{\infty} f(u)du$$

$S(t) \in [0, 1]$, c'est une probabilité. Elle est décroissante de 1 en 0. La probabilité d'être en vie à l'origine est égale à 1 : $S(0) = 1$. La probabilité d'être en vie après en temps infini est nulle : $S(\infty) = 0$.

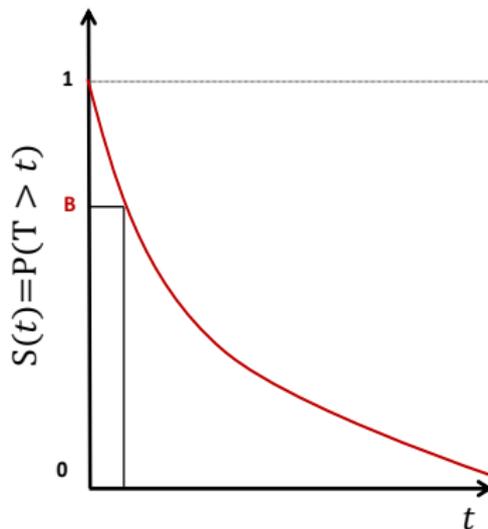
La fonction de survie $S(t)$

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
- Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
- Perspectives



La fonction de survie $S(t)$

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
- Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
- Perspectives



Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

La fonction de risque instantanée $h(t)$ représente la limite de probabilité que l'événement se produise au temps t sachant qu'il ne s'est pas produit avant.

$$h(t) = \lim_{\Delta t \rightarrow 0} Pr(t \leq T < t + \Delta t | T \geq t) / \Delta t$$

Elle peut être vue comme une vitesse. $h(t) > 0$, l'événement est unique et sans retour : on ne ressuscite pas. Tout processus vivant est vieillissant.

La fonction de risque cumulé $H(t)$ est la somme des risques instantanés jusqu'en t .

$$H(t) = \int_0^t h(u) du$$

Toutes ces fonctions sont équivalentes. Il suffit d'en définir une pour retrouver les autres. Liens importants :

$$S(t) = \exp(-H(t)) = \exp\left(-\int_0^t h(u) du\right) = f(t)/h(t)$$

⇒ Comment estimer $S(t)$? ⇐

1. Introduction
2. Définitions
- 3. Kaplan-Meier**
Estimation
Variance
4. LogRank
5. Distributions paramétriques
Les principales lois
L'estimation des paramètres
6. Modèle de Cox
Définitions
Inférence
Hypothèses
Risques Proportionnels
Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

1. Introduction

2. Définitions

3. Kaplan-Meier

Estimation

Variance

4. LogRank

5. Distributions paramétriques

Les principales lois

L'estimation des paramètres

6. Modèle de Cox

Définitions

Inférence

Hypothèses

Risques Proportionnels

Log linéarité

7. Perspectives

Etre en vie à deux ans après l'inclusion, c'était être en vie à un an **et** ne pas être décédé dans la seconde année. On écrit cette propriété pour tout temps t_1 et t_2 tels que $t_2 > t_1$:

$$S(t_2) = Pr(T > t_2)$$

$$\Downarrow$$

$$S(t_2) = Pr(T > t_2, T > t_1)$$

$$\Downarrow$$

$$S(t_2) = Pr(T > t_2 | T > t_1) Pr(T > t_1)$$

On observe tous les couples (y_i, δ_i) avec $i = 1, \dots, N$. On peut ainsi généraliser la propriété précédente en ordonnant tous les sujets par y_i :

$$S(y_N) = Pr(T > y_N | T > y_{N-1}) \times \dots \times Pr(T > y_1)$$

↓

$$S(y_N) = Pr(T > y_N | T > y_{N-1}) \times \dots \times Pr(T > y_1 | T > t_0)$$

↓

$$S(y_N) = \prod_{i=1}^N Pr(T > y_i | T > y_{i-1})$$

avec $t_0 = 0$

Si on souhaite la survie à n'importe quel temps t tel que $t < y_N$, il suffit d'arrêter le produit précédent au dernier individu suivi juste avant t :

$$S(t) = \prod_{i: y_i < t} Pr(T > y_i | T > y_{i-1})$$

La question est maintenant de savoir comment estimer ces probabilités conditionnelles. La probabilité de connaître l'événement au temps y_i sachant qu'on ne l'a pas subi avant y_{i-1} est estimée par le nombre d'événements entre y_{i-1} et y_i parmi tous les sujets à risque au temps y_i :

$$Pr(T \leq y_i | T > y_{i-1}) = \frac{\sum_j I(\delta_j = 1, y_{i-1} < y_j \leq y_i)}{\sum_j I(y_j > y_{i-1})} = \frac{d_i}{n_i}$$

On en déduit les probabilités de survie conditionnelles :

$$Pr(T > y_i | T > y_{i-1}) = 1 - Pr(T \leq y_i | T > y_{i-1}) = 1 - \frac{d_i}{n_i}$$

Remarquons que si le temps y_i correspond à une censure ($\delta_i = 0$), il n'y a aucun événement dans l'intervalle de y_{i-1} à y_i , alors cette probabilité vaut 1. La probabilité de survie $S(t)$ ne change que si y_i correspond à l'observation d'un événement dans l'échantillon ($\delta_i = 1$). Cette propriété simplifie les calculs.

On démontre ainsi que l'estimateur de Kaplan-Meier * de la survie est obtenu comme suit :

$$\hat{S}(t) = \prod_{i: y_i < t} \left(1 - \frac{d_i}{n_i}\right)$$

*. Kaplan E, Meier P. Non-parametric estimation from incomplete observations. Journal of the American Statistical Association 1958 ; 53 :457-481.

Soient deux groupes de patients atteints d'un cancer du poumon. On propose deux types de chimiothérapies (A/B) aléatoirement et on étudie le temps entre le traitement et le décès du patient. Voici les observations :

Chimio	Mois (t_i)	Evt (δ_i)
A	24	1
A	26	0
A	30	1
A	31	0
B	22	0
B	28	1
B	30	0
B	32	0

- Pour le groupe A.

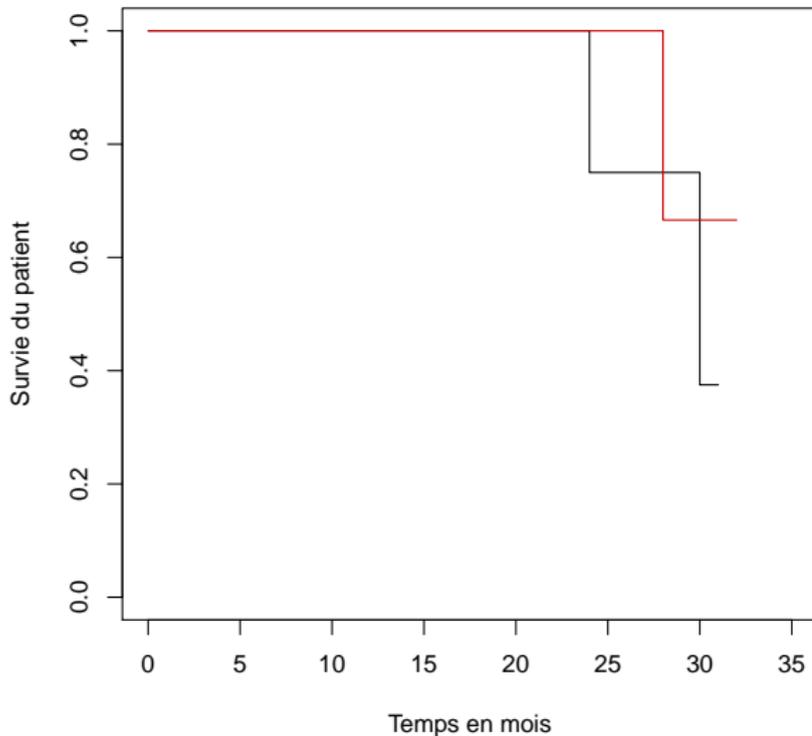
t_i	d_i	c_i	n_i	proba	$\hat{S}(t)$
0	0	0	4	1	1
24	1	0	4	$1-1/4 = 0.75$	$1 \times 0.75 = 0.75$
30	1	1	$4-1-1 = 2$	$1-1/2 = 0.50$	$0.75 \times 0.50 = 0.375$
31	0	0	$1-0 = 1$	$1-0/1=1$	$0.375 \times 1 = 0.375$

- Pour le groupe B.

t_i	d_i	c_i	n_i	proba	$\hat{S}(t)$
-------	-------	-------	-------	-------	--------------

```
> ta <- c(0, 24, 30, 31)
> sa <- c(1, 0.75, 0.375, 0.375)
> plot(ta, sa, type="s", ylab="Survie du patient",
+ xlab="Temps en mois", ylim=c(0,1), xlim=c(0, 35))
> tb <- c(0, 28, 32)
> sb <- c(1, 0.666, 0.666)
> lines(tb, sb, type="s", col="red3")
```

Un exemple simple



- Etude du cancer du poumon.
- Essai clinique sur 137 hommes (traitement par chimiothérapie vs. standard).
- Temps étudié = Délai entre le début du traitement et le décès du patient.
- 6 variables explicatives mesurées à l'inclusion :
 - Type de la cellule (squamous cell, large cell, small cell and adenocarcinoma)
 - Score de Karnofsky
 - Délai entre diagnostic et traitement (en mois)
 - Age (en années)
 - Thérapie antérieure (yes/no)
 - Traitement (chemotherapy vs. sandard)

Objectif : Evaluer l'effet du médicament

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives

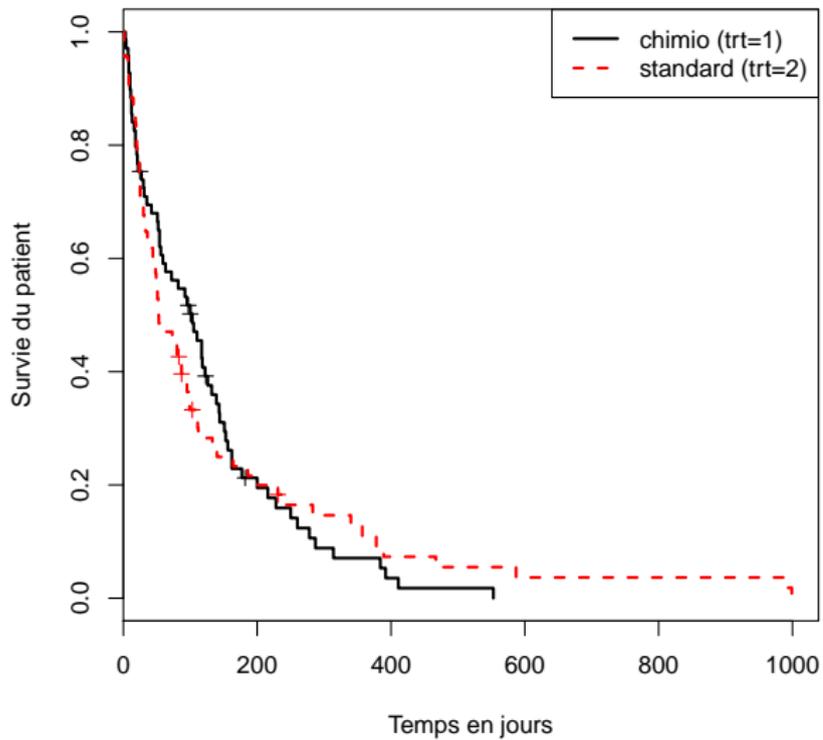
```
> library(survival)
> veteran[1:10,]
```

	trt	celltype	time	status	karno	diagtime	age	prior
1	1	squamous	72	1	60	7	69	0
2	1	squamous	411	1	70	5	64	10
3	1	squamous	228	1	60	3	38	0
4	1	squamous	126	1	60	9	63	10
5	1	squamous	118	1	70	11	65	10
6	1	squamous	10	1	20	5	49	0
7	1	squamous	82	1	40	10	69	10
8	1	squamous	110	1	80	29	68	0
9	1	squamous	314	1	50	18	43	0
10	1	squamous	100	0	70	6	70	0

```
> f <- survfit(Surv(time, status) ~ trt,  
+ data = veteran)  
> plot(f, ylab="Survie du patient",  
+ col=1:2, lwd=2, lty=1:2, xlab="Temps en jours")  
> legend("topright", c("chimio (trt=1)", "standard (trt=2)"),  
+ col=1:2, lty=1:2, lwd=2)
```

Un exemple plus complet

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives



- Légende.
- Libellé des axes.
- Unité du temps.
- Fonction en escalier.
- Axe des ordonnées entre 0 et 1, sinon symbole "//".
- Effectifs à risque au cours du temps.

†. Pocock SJ, Clayton TC, Altman DG. Survival plots of time-to-event outcomes in clinical trials : good practice and pitfalls. Lancet. 2002 ;359 :1686-9.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

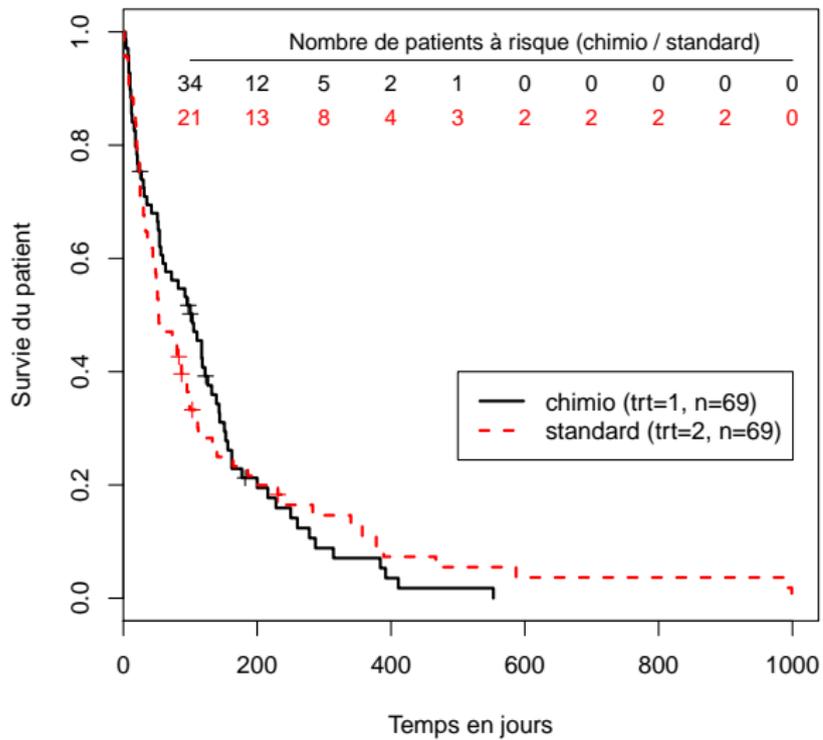
```

> plot(f, ylab="Survie du patient",
+ col=1:4, lwd=2, lty=1:2, xlab="Temps en jours")
> nb.risk1<-function(x) {
+ dim(veteran[veteran$trt==1,])[1]-sum(veteran$time[veteran$trt==1]<x) }
> nb.risk2<-function(x) {
+ dim(veteran[veteran$trt==2,])[1]-sum(veteran$time[veteran$trt==2]<x) }
> .time <- seq(100, 1000, by=100)
> text(x=500, y=0.98, "Nombre de patients à risque (chimio / standard)", cex=0.9)
> segments(x0=0, y0=0.95, x1=1000, y1=0.95)
> text(x=.time, y=rep(0.91, length(.time)),
+ as.character(sapply(.time, FUN="nb.risk1")), cex=0.9)
> text(x=.time, y=rep(0.85, length(.time)),
+ as.character(sapply(.time, FUN="nb.risk2")), col=2, cex=0.9)
> legend(600, 0.4, c("chimio (trt=1)", "standard (trt=2)"),
+ col=1:2, lty=1:2, lwd=2)

```

Bonnes pratiques de représentation

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
 - Variance
- LogRank
- Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
- Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
- Perspectives



L'hypothèse principale : censure non-informative

Cet estimateur est non-biaisé si les temps de censures à droite sont indépendants des temps d'événements.

- Ex1 :** Etude de la mortalité liée au VIH en Afrique. Si tous les patients quittent le centre de soins pour mourir dans leur village (sous-estimation de la mortalité).
- Ex2 :** Etude de la mortalité des patients sur liste de greffe : les patients greffés vont en moyenne mieux que les autres (sur estimation de la mortalité).

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Cet estimateur est assez facilement démontrable en remarquant que l'estimateur de Kaplan-Meier est un estimateur obtenu par maximisation et en utilisant la delta-méthode :

$$\text{Var}[\hat{S}(t)] = \hat{S}(t)^2 \times \sum_{i: y_i \leq t} \frac{d_i}{(n_i - d_i)n_i}$$

On peut en déduire l'intervalle de confiance à $(1-\alpha)\%$:

$$IC_{95\%}[\hat{S}(t)] = \hat{S}(t) \pm z_{\alpha/2} \sqrt{\text{Var}[\hat{S}(t)]}$$

Reprenons l'exemple du groupe A

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance**
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives

t_i	d_i	c_i	n_i	$\hat{S}(t)$	$g_i = d_i / ((n_i - d_i)n_i)$	$\sum_i g_i$	$\sqrt{\text{Var}[\hat{S}(t)]}$
0	0	0	4	1.000	0.000	0.000	0.000
24	1	0	4	0.750	$1 / (4(4-1)) = 0.083$	0.083	0.216
30	1	1	2	0.375	$1 / (2(2-1)) = 0.500$	0.583	0.286
31	0	0	1	0.375	0.000	0.583	0.286

Reprenons l'exemple du groupe A

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

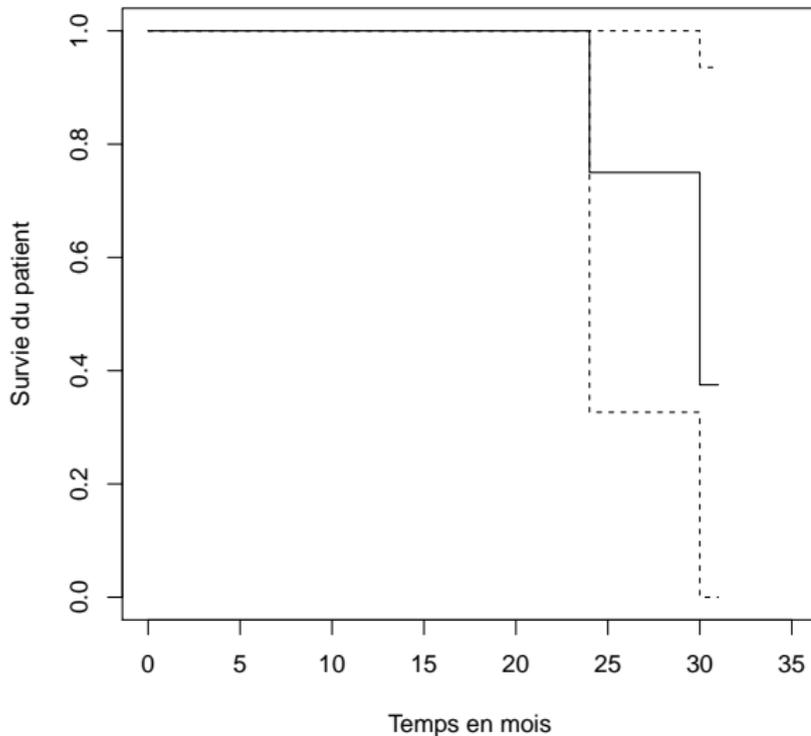
Inférence

Hypothèses

Perspectives

```
> ta <- c(0, 24, 30, 31)
> sa <- c(1, 0.75, 0.375, 0.375)
> sda <- c(0, 0.216, 0.286, 0.286)
> plot(ta, sa, type="s", ylab="Survie du patient",
+ xlab="Temps en mois", ylim=c(0,1), xlim=c(0, 35))
> lines(ta, pmax(sa-qnorm(0.975)*sda, 0), lty=2, type="s")
> lines(ta, pmin(sa+qnorm(0.975)*sda, 1), lty=2, type="s")
```

Reprenons l'exemple du groupe A



Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

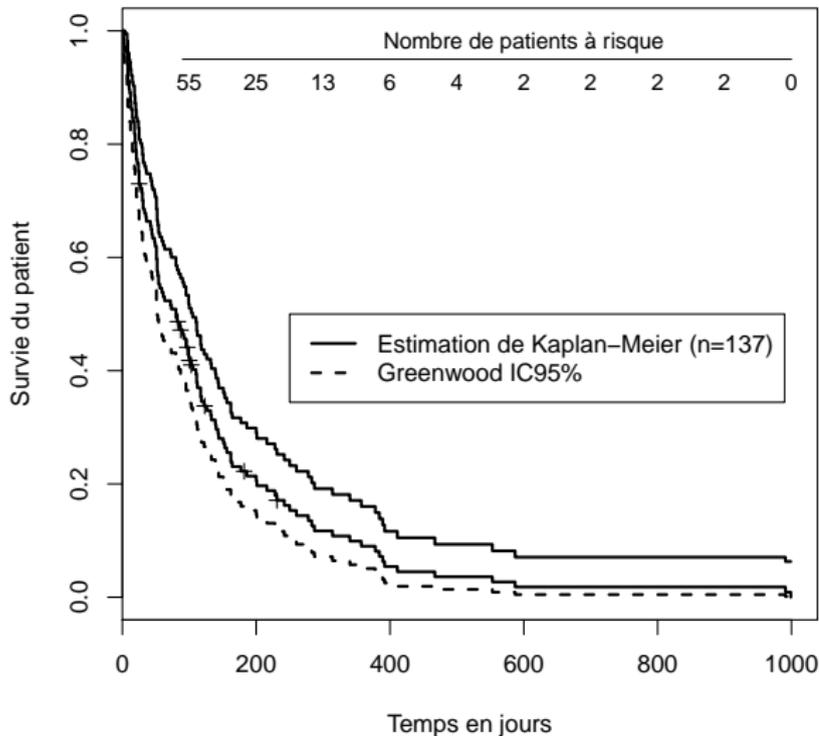
Définitions

Inférence

Hypothèses

Perspectives

```
> f <- survfit(Surv(time, status) ~ 1,  
+ error="greenwood", data = veteran)  
> plot(f, ylab="Survie du patient",  
+ col=1, lwd=2, lty=1:2, xlab="Temps en jours",  
+ conf.int=TRUE)  
> nb.risk<-function(x) {  
+ dim(veteran)[1]-sum(veteran$time<x) }  
> .time <- seq(100, 1000, by=100)  
> text(x=500, y=0.98, "Nombre de patients à risque", cex=0.9)  
> segments(x0=0, y0=0.95, x1=1000, y1=0.95)  
> text(x=.time, y=rep(0.91, length(.time)),  
+ as.character(sapply(.time, FUN="nb.risk")), cex=0.9)  
> legend(250, 0.5, c("Estimation de Kaplan-Meier (n=137)", "Greenwood IC95%"),  
+ col=1, lty=1:2, lwd=2)
```



Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Il y a-t-il une différence de survie selon le traitement ?

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

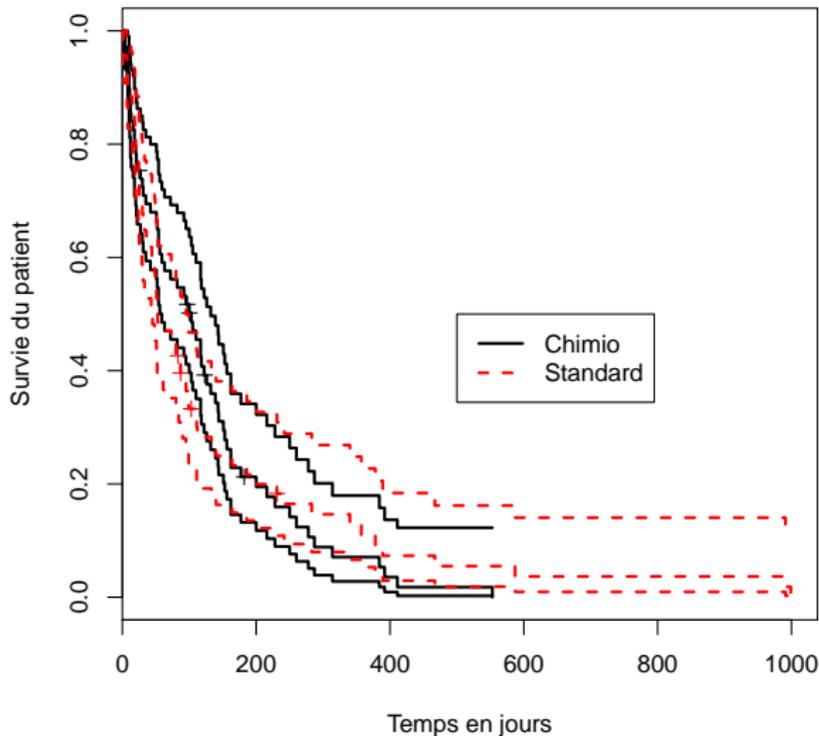
Inférence

Hypothèses

Perspectives

```
> f <- survfit(Surv(time, status) ~ trt,  
+ error="greenwood", data = veteran)  
> plot(f, ylab="Survie du patient",  
+ col=1:4, lwd=2, lty=1:2, xlab="Temps en jours",  
+ conf.int=TRUE)  
> legend(500, 0.5, c("Chimio", "Standard"),  
+ col=1:2, lty=1:2, lwd=2)
```

Comme d'habitude, un chevauchement d'IC95% ne prouve rien...



1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

Il s'agit d'une statistique construite sous la forme d'une statistique du χ^2 . L'idée est donc de calculer des effectifs dits *attendus* d'événements (e) et de les comparer aux effectifs observés (o). Ces effectifs attendus sont calculés en considérant l'hypothèse nulle vraie :

H_0 : Les deux courbes de survie sont similaires : $S_A(t) = S_B(t)$.

H_1 : Les deux courbes de survie sont différentes : $S_A(t) \neq S_B(t)$.

Pour cela, il suffit de considérer qu'à chaque temps d'événement observé ($\delta_i = 1$), la probabilité d'apparition de l'événement est équivalente dans les deux groupes. Elle est simplement estimée par le nombre d'événement divisé par l'effectif à risque quel que soit le groupe (d_i/n_i).

Si n_{Ai} et n_{Bi} sont les effectifs à risque dans chacun des groupes (tels que $n_i = n_{Ai} + n_{Bi}$), alors le nombre de décès attendus est $e_{Ai} = \frac{d_i}{n_i} n_{Ai}$ dans le groupe A et $e_{Bi} = \frac{d_i}{n_i} n_{Bi} = d_i - e_{Ai}$ dans le groupe B.

t_i	d_{Ai}	n_{Ai}	d_{Bi}	n_{Bi}	d_i	n_i	e_{Ai}	e_{Bi}
24	1	4	0	3	1	7	$4 \cdot 1/7 = 0.57$	$3 \cdot 1/7 = 0.43$
28	0	2	1	3	1	5	$2 \cdot 1/5 = 0.40$	$3 \cdot 1/5 = 0.60$
30	1	2	0	2	1	4	$2 \cdot 1/4 = 0.50$	$2 \cdot 1/4 = 0.50$

$$\rightarrow o_A = 2, o_B = 1, e_A = 1.47, e_B = 1.53$$

$$\chi_{LR}^2 = \frac{(o_A - e_A)^2}{e_A} + \frac{(o_B - e_B)^2}{e_B} \sim \chi_{1\ ddf}^2$$

Pour notre exemple, on a :

```
> stat <- ((2-1.47)^2)/1.47 + ((1-1.53)^2)/1.53
> 1-pchisq(3.84, df = 1) # pour comprendre...
```

```
[1] 0.05004352
```

```
> 1-pchisq(stat, df = 1)
```

```
[1] 0.5404625
```

L'étude ne permet pas de montrer une relation significative entre le type de chimiothérapie et la survie des patients ($p > 0.05$).

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

```
> survdiff(Surv(time, status) ~ trt, data = veteran)
```

Call:

```
survdiff(formula = Surv(time, status) ~ trt, data = veteran)
```

	N	Observed	Expected	(O-E) ² /E	(O-E) ² /V
trt=1	69	64	64.5	0.00388	0.00823
trt=2	68	64	63.5	0.00394	0.00823

Chisq= 0 on 1 degrees of freedom, p= 0.928

L'étude ne permet pas de montrer une relation significative entre le traitement et la survie des patients atteints d'un cancer du poumon ($p > 0.05$).

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation
Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

- Hypothèse : la distribution des temps de survie répond à une loi paramétrique prédéfinie
- Le livre de Bagdonavicius et Nikulin[‡] détaille beaucoup de possibilités
- Les deux lois simples les plus utilisées :
 - Loi Exponentielle
 - Loi de Weibull

[‡]. Vilijandas Bagdonavicius et Mikhail Nikulin. Accelerated Life Models. Modeling and Statistical Analysis. 2002, Chapman and Hall/CRC : Boca Raton, London

- Hypothèse : la fonction de risque est constante au cours du temps

$$h(t) = \alpha \quad (1 \text{ paramètre})$$

d'où

$$H(t) = \int_0^t \alpha du = \alpha \int_0^t du = \alpha t,$$

$$S(t) = \exp(-\alpha t),$$

$$f(t) = \alpha \exp(-\alpha t).$$

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

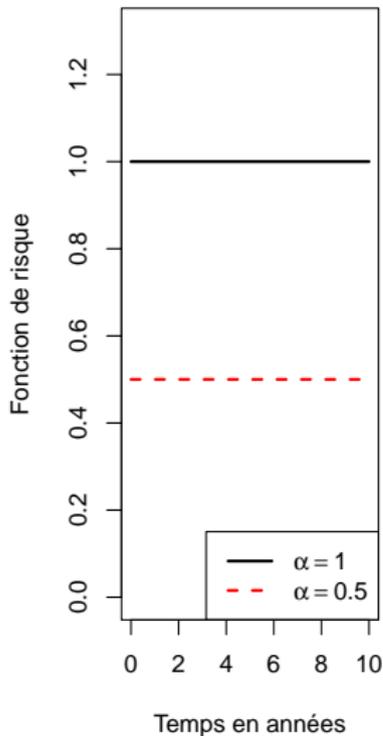
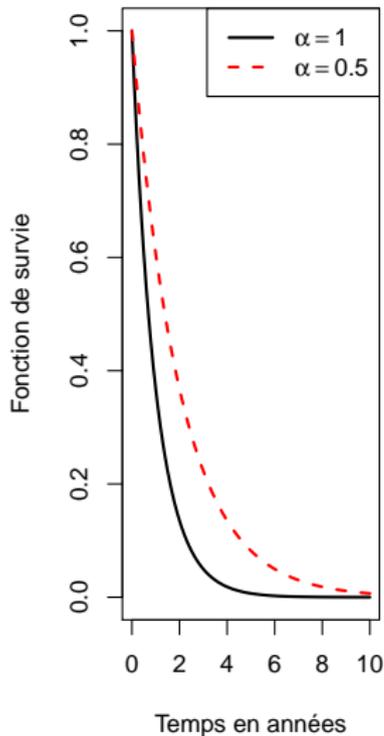
Inférence

Hypothèses

Perspectives

```
> h.exp <- function(a, t) { a * rep(1, length(tps)) }  
> s.exp <- function(a, t) { exp(-a*t) }  
> tps <- seq(0, 10, by=0.1)  
> par(mfrow=c(1,2))  
> plot(tps, h.exp(a=1, t=tps), ylab="Fonction de risque",  
+ xlab="Temps en années", ylim=c(0, 1.3), type="l", lwd=2)  
> lines(tps, h.exp(a=0.5, t=tps), col=2, type="l", lwd=2, lty=2)  
> legend("bottomright", c(expression(alpha==1.0),  
+ expression(alpha==0.5)), lwd=2, col=1:2, , lty=1:2)  
> plot(tps, s.exp(a=1, t=tps), ylab="Fonction de survie",  
+ xlab="Temps en années", ylim=c(0, 1), type="l", lwd=2)  
> lines(tps, s.exp(a=0.5, t=tps), col=2, type="l", lwd=2, lty=2)  
> legend("bottomright", c(expression(alpha==1.0),  
+ expression(alpha==0.5)), lwd=2, col=1:2, , lty=1:2)
```

La loi Exponentielle



- Hypothèse : la fonction de risque est monotone (croissante ou décroissante au cours du temps)

$$h(t) = \gamma \alpha^\gamma t^{\gamma-1} \quad (2 \text{ paramètres})$$

d'où

$$H(t) = (\alpha t)^\gamma \quad (\text{exo : calculer l'intégrale})$$

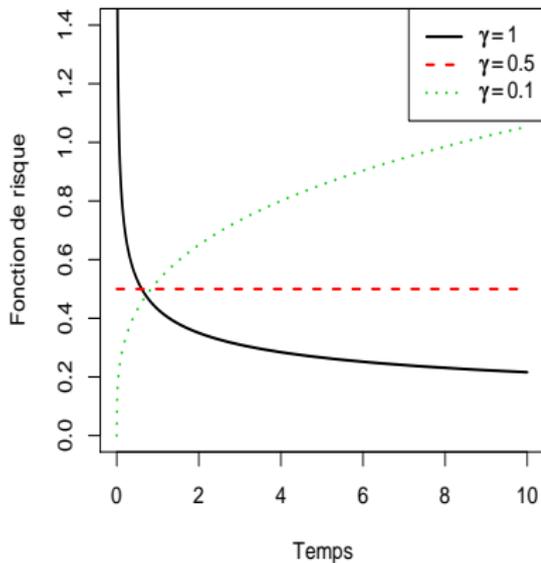
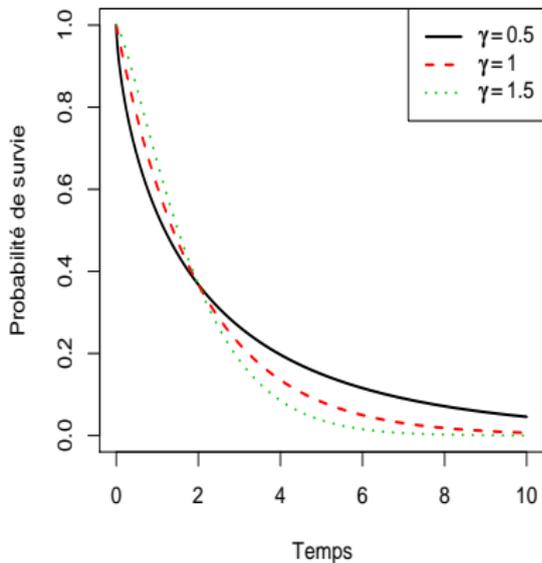
$$S(t) = \exp(-(\alpha t)^\gamma),$$

$$f(t) = \gamma \alpha^\gamma t^{\gamma-1} \exp(-\alpha t).$$

- Si $\gamma = 1 \Rightarrow$ Loi Exponentielle

La loi de Weibull (pour $\alpha = 0.5$ quelque soit la courbe)

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives



1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

L'estimateur du maximum de Vraisemblance (1)

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

La Vraisemblance, ℓ , représente la probabilité d'observer l'échantillon.
Rappels de notations :

- Soit N individus inclus dans l'étude ($i = 1, \dots, N$).
- Soit y_i le temps de suivi de l'individu i .
- Soit δ_i l'indicatrice de censure : $\delta_i = 1$ si y_i correspond à un événement et $\delta_i = 0$ si y_i correspond à une censure à droite.

L'estimateur du maximum de Vraisemblance (2)

- Si tous les individus sont indépendants :

$$l = \prod_i^N \ell_i$$

- ℓ_i représente la probabilité d'observer l'individu i .
- Elle est aussi appelée contribution individuelle.

- $\ell_i = f(y_i)$ si l'événement est observé au temps y_i ($\delta_i = 1$)
- $\ell_i = S(y_i)$ si le temps de survie est censuré au temps y_i ($\delta_i = 0$)

$$l = \prod_i^N \ell_i = \prod_i^N f(y_i)^{\delta_i} S(y_i)^{1-\delta_i} = \prod_i^N h(y_i)^{\delta_i} S(y_i)$$

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

L'estimateur du maximum de Vraisemblance (3)

Il est plus simple de travailler à partir de la logVraisemblance :

$$\log(\ell) = \sum_i^N \delta_i \log(h(y_i)) + \log(S(y_i))$$

$$\log(\ell) = \sum_i^N \delta_i \log(h(y_i)) - H(y_i)$$

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

$$\log(\ell) = \sum_i^N \delta_i \log(h(y_i)) - H(y_i) \iff \log(\ell) = \sum_i^N \delta_i \log(\alpha) - \alpha y_i$$

$$\partial \log(\ell) / \partial \alpha = \sum_i^N \delta_i / \alpha - y_i$$

$$\hat{\alpha} \text{ satisfait } \partial \log(\ell) / \partial \alpha = 0 \iff \sum_i^N \delta_i / \hat{\alpha} - y_i = 0$$

$$\sum_i^N \delta_i / \hat{\alpha} = \sum_i^N y_i \iff \hat{\alpha} = \sum_i^N \delta_i / \sum_i^N y_i$$

$$\hat{\alpha} = \text{Nb Evt} / \text{Suivi cumulé total}$$

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

- Exo : Retrouver l'estimateur de la variance de $\hat{\alpha}$. Rappel : $\hat{V}(\hat{\alpha})$ est obtenue par :

$$\hat{V}(\hat{\alpha}) = \left[\frac{-\partial^2 \log(\ell)}{\partial^2 \alpha} \right]^{-1}$$

- En pratique, le modèle est souvent complexe et est basé sur de nombreux paramètres. Il n'est alors plus possible d'estimer à la main leur valeur. Les logiciels utilisent des algorithmes qui permettent d'obtenir numériquement ces résultats (estimations et variances).

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

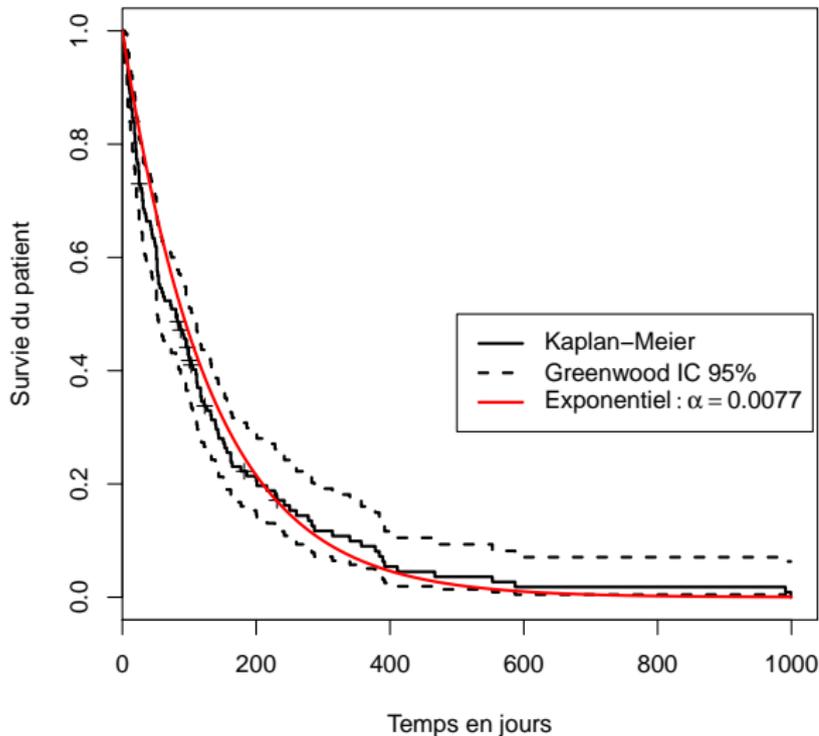
Hypothèses

Perspectives

```
> f <- survfit(Surv(time, status) ~ 1,  
+ error="greenwood", data = veteran)  
> plot(f, ylab="Survie du patient",  
+ col=1, lwd=2, xlab="Temps en jours",  
+ conf.int=TRUE)  
> alpha <- sum(veteran$status)/sum(veteran$time)  
> alpha
```

```
[1] 0.00768169
```

```
> tps <- 0:1000  
> lines(tps, s.exp(a=alpha, tps), col=2, lwd=2)  
> legend(500, 0.5, c("Kaplan-Meier", "Greenwood IC 95%", expression(Exponentiel:alp
```



1. Introduction

2. Définitions

3. Kaplan-Meier

Estimation

Variance

4. LogRank

5. Distributions paramétriques

Les principales lois

L'estimation des paramètres

6. Modèle de Cox

Définitions

Inférence

Hypothèses

Risques Proportionnels

Log linéarité

7. Perspectives

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. **Modèle de Cox**
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

$$h(t|X_1 = x_1, X_2 = x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

- $h_0(t)$ est la fonction de risque de base : fonction de risque dans la population de référence (toutes les variables explicatives sont nulles).
- $\beta = (\beta_1, \beta_2, \dots)$ sont les coefficients de régression.
- Principe fondamental : la fonction de risque n'est pas estimée :
Modèle semi-paramétrique.
 - Partie "non paramétrique" (pas d'estimation de $h_0(t)$)
 - Partie paramétrique (fonction exponentielle d'un régresseur linéaire)

§. Cox DR. Regression models and life-tables. Journal of the Royal Statistical Society : Series B, 34 :187-220, 1972.

$$h(t|X_1 = x_1, X_2 = x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

- Chez les hommes ($x_1 = 1$) et toutes les autres covariables fixées ($X_2 = x_2, \dots$) :

$$h(t|x_1 = 1, X_2 = x_2, \dots) = h_0(t) \exp(\beta_1) \exp(\beta_2 x_2 + \dots)$$

- Chez les femmes ($x_1 = 0$) et toutes les autres covariables fixées ($X_2 = x_2, \dots$) :

$$h(t|x_1 = 0, X_2 = x_2, \dots) = h_0(t) \exp(\beta_2 x_2 + \dots)$$

- $HR_{H/F} = \exp(\beta_1)$ représente le rapport des risques (hazard ratio : HR) entre hommes et femmes, toutes les autres variables étant constantes.

Généralisation

- Si $\beta_1 > 0$ alors $\exp(\beta_1) > 1$: x_1 est un facteur de risque.
- Si $\beta_1 < 0$ alors $\exp(\beta_1) < 1$: x_1 est un facteur protecteur.
- Si $\beta_1 = 0$ alors $\exp(\beta_1) = 1$: x_1 n'est pas un facteur influençant le temps d'événement.

$$h(t|X_1 = x_1, X_2 = x_2) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2 + \dots)$$

- Dans le groupe $\{X_1 = 0\}$, c'est à dire les femmes :
 - $h_0(t) \exp(\beta_2 X_2)$
 - $HR_{X_2=1/X_2=0} = \exp(\beta_2)$
- Dans le groupe $\{X_1 = 1\}$, c'est à dire les hommes :
 - $h_0(t) \exp(\beta_1 + \beta_2 X_2 + \beta_3 X_2) = h_0(t) \exp(\beta_1 + (\beta_2 + \beta_3) X_2)$
 - $HR_{X_2=1/X_2=0} = \exp(\beta_2 + \beta_3)$
- Le HR associé X_2 est différent selon les modalités de la variable X_1 (et inversement)
- $HR_{X_2} = \exp(\beta_2) \exp(\beta_3 X_1)$: $\exp(\beta_3)$ représente le facteur entre les HR des groupes $\{X_1 = 0\}$ et $\{X_1 = 1\}$.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

$$h(t|X_1 = x_1, X_2 = x_2) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2)$$

- Si $\beta_3 > 0$ alors $\exp(\beta_3) > 1$: le risque est supérieur dans le groupe $\{x_1 = 1\}$.
- Si $\beta_3 < 0$ alors $\exp(\beta_3) < 1$: le risque est inférieur dans le groupe $\{x_1 = 1\}$.
- Si $\beta_3 = 0$ alors $\exp(\beta_3) = 1$: le risque est inchangé entre les deux groupes.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. **Modèle de Cox**
 - Définitions
 - Inférence**
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

- Soit $y_1 < y_2 < \dots < y_N$ les différents temps observés pour les N individus.
- On démontre que la probabilité conditionnelle que le sujet i subisse l'événement en y_i sachant qu'il est à risque au temps y_i parmi tous les individus à risque au même temps est égale à :

$$\ell_i = \frac{h(y_i | x_{1i}, \dots)}{\sum_{j: y_j \geq y_i} h(y_i | x_{1j}, \dots)}$$

$$\ell_i = \frac{h_0(y_i) \exp(\beta_1 x_{1i} + \dots)}{\sum_{j: y_j \geq y_i} h_0(y_i) \exp(\beta_1 x_{1j} + \dots)}$$

$$\ell_i = \frac{\exp(\beta_1 x_{1i} + \dots)}{\sum_{j: y_j \geq y_i} \exp(\beta_1 x_{1j} + \dots)}$$

- Il s'agit de la contribution individuelle à la vraisemblance partielle. Elle ne dépend pas de $h_0(t)$.

La Vraisemblance partielle (2)

- En supposant les individus indépendants, le produit des contributions individuelles précédentes pour les sujets ayant subi l'événement permet d'obtenir la vraisemblance partielle :

$$p_{\partial l} = \prod_{i=1}^N \left\{ \frac{\exp(\beta_1 x_{1i} + \dots)}{\sum_{j: y_j \geq y_i} \exp(\beta_1 x_{1j} + \dots)} \right\}^{\delta_i}$$

- La maximisation de cette fonction permet d'estimer les coefficients de régression, $\hat{\beta} = (\hat{\beta}_1, \hat{\beta}_2, \dots)$, sans avoir à estimer la distribution de ce dernier.
- La matrice Hessienne correspondante permet d'obtenir la matrice de variance-covariance des coefficients de régression : $Var(\hat{\beta})$.
- On peut en déduire l'intervalle de confiance à $(1-\alpha)\%$ toujours grâce au théorème central limite, par exemple pour β_1 :

$$IC95\%[\hat{\beta}_1] = \hat{\beta}_1 \pm z_{\alpha/2} \sqrt{Var(\hat{\beta}_1)}$$

```
> dim(veteran)
```

```
[1] 137  8
```

```
> names(veteran)
```

```
[1] "trt"      "celltype" "time"      "status"    "karno"     "diagtime" "age"  

[8] "prior"
```

```
> fit.cox1<-coxph(Surv(time, status)~ trt,  

+ data = veteran)  

> fit.cox1
```

Call:

```
coxph(formula = Surv(time, status) ~ trt, data = veteran)
```

	coef	exp(coef)	se(coef)	z	p
trt	0.0177	1.02	0.181	0.0982	0.92

```
Likelihood ratio test=0.01 on 1 df, p=0.922 n= 137, number of events= 128
```

Les patients avec un traitement standard (trt=2) ont 1.02 fois plus de risque de décéder que les patients avec la nouvelle chimiothérapie (trt=1).

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives

```
> summary(fit.cox1)
```

Call:

```
coxph(formula = Surv(time, status) ~ trt, data = veteran)
```

```
n= 137, number of events= 128
```

	coef	exp(coef)	se(coef)	z	Pr(> z)
trt	0.01774	1.01790	0.18066	0.098	0.922

	exp(coef)	exp(-coef)	lower .95	upper .95
trt	1.018	0.9824	0.7144	1.45

```
Concordance= 0.525 (se = 0.026 )
Rsquare= 0 (max possible= 0.999 )
Likelihood ratio test= 0.01 on 1 df, p=0.9218
Wald test = 0.01 on 1 df, p=0.9218
Score (logrank) test = 0.01 on 1 df, p=0.9218
```

L'intervalle de confiance à 95% du HR estimé est compris entre 0,71 et 1,45.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

```
> names(fit.cox1)
```

```
[1] "coefficients"      "var"                "loglik"
[4] "score"            "iter"               "linear.predictors"
[7] "residuals"        "means"              "concordance"
[10] "method"           "n"                  "nevent"
[13] "terms"            "assign"              "wald.test"
[16] "y"                 "formula"             "call"
```

```
> fit.cox1$coefficients
```

```
      trt
0.01774257
```

```
> fit.cox1$loglik
```

```
[1] -505.4491 -505.4442
```

La logVraisemblance de ce modèle est de -505,444. Une belle jambe (pour l'instant...).

$$H_0 : HR_{x_1} = 1 \Leftrightarrow \beta_1 = 0$$

$$H_1 : HR_{x_1} \neq 1 \Leftrightarrow \beta_1 \neq 0$$

- Test de Wald (bilatéral ou unilatéral) :

$$T = \frac{\hat{\beta}_1}{\sqrt{\text{Var}(\hat{\beta}_1)}} \sim N(0, 1)$$

- Test du rapport des vraisemblances (bilatérale) :

$$\chi^2_{LRS} = -2 \times \{\log(\ell_0) - \log(\ell_1)\} \sim \chi^2_{ddl}$$

où ℓ_0 est la logVraisemblance sans β_1 (i.e. $\beta = 0$) et ℓ_1 celle du modèle complet.

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

Inférence

Hypothèses

Perspectives

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

H_1 : Au moins un coefficient différent de 0.

Test du rapport des vraisemblances :

$$\chi_{LRS}^2 = -2 \times \{\log(\ell_0) - \log(\ell_1)\} \sim \chi_{pddl}^2$$

où ℓ_0 est la logVraisemblance sans $\{x_1, \dots, x_p\}$ et ℓ_1 celle avec du modèle complet.

```
> dim(veteran)
```

```
[1] 137  8
```

```
> names(veteran)
```

```
[1] "trt"      "celltype" "time"      "status"    "karno"     "diagtime" "age"
[8] "prior"
```

```
> fit.cox2<-coxph(Surv(time, status)~ trt + age,
+ data = veteran)
> fit.cox2
```

Call:

```
coxph(formula = Surv(time, status) ~ trt + age, data = veteran)
```

	coef	exp(coef)	se(coef)	z	p
trt	-0.00365	0.996	0.18251	-0.020	0.98
age	0.00753	1.008	0.00966	0.779	0.44

Likelihood ratio test=0.63 on 2 df, p=0.731 n= 137, number of events= 128

Pour un âge fixé, les patients avec un traitement standard (trt=2) ont 1.00 fois plus de risque de décéder que les patients avec la nouvelle chimiothérapie (trt=1). On ne peut pas montrer que ce HR entre les deux groupe soit statistiquement significatif ($p > 0.05$).

```
> fit.cox1$loglik
[1] -505.4491 -505.4442
> fit.cox2$loglik
[1] -505.4491 -505.1361
> -2*(fit.cox1$loglik[2]-fit.cox2$loglik[2])
[1] 0.6161708
> 1-pchisq(-2*(fit.cox1$loglik[2]-fit.cox2$loglik[2]), df=1)
[1] 0.4324738
> summary(fit.cox2)$coefficients
              coef exp(coef)      se(coef)          z Pr(>|z|)
trt -0.003654234  0.9963524  0.182513535 -0.02002171  0.9840261
age  0.007527262  1.0075557  0.009661283  0.77911618  0.4359113
> summary(fit.cox2)$coefficients[2,5]
[1] 0.4359113
```

Les tests du rapport de vraisemblance et de Wald renvoient des probabilités critiques équivalentes.

```
> summary(veteran$age[veteran$strtr==1])
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
34.00	49.00	62.00	57.51	66.00	81.00

```
> summary(veteran$age[veteran$strtr==2])
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
35.00	52.00	62.00	59.12	66.00	81.00

```
> t.test(veteran$age[veteran$strtr==1], veteran$age[veteran$strtr==2])
```

Welch Two Sample t-test

```
data: veteran$age[veteran$strtr == 1] and veteran$age[veteran$strtr == 2]
t = -0.8937, df = 134.827, p-value = 0.3731
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -5.174206  1.953405
sample estimates:
mean of x mean of y
 57.50725  59.11765
```

Pas étonnant que les résultats liés au traitement soient inchangés, les moyennes d'âge semblent proches entre les deux groupes. On ne devrait pas faire un test de différence de moyennes d'âge entre les deux groupes car l'hypothèse nulle est vraie à coup sûr (tirage au sort).

```
> summary(coxph(Surv(time, status)~ trt * age,  
+ data = veteran))$coefficients
```

	coef	exp(coef)	se(coef)	z	Pr(> z)
trt	-0.3113942213	0.7324251	1.20722624	-0.25794189	0.7964518
age	0.0004951811	1.0004953	0.02884639	0.01716614	0.9863041
trt:age	0.0052054323	1.0052190	0.02016938	0.25808585	0.7963406

Nous ne pouvons pas mettre en évidence un effet différent du traitement selon l'âge ($p = 0.7960$).

1. Introduction

2. Définitions

3. Kaplan-Meier

Estimation

Variance

4. LogRank

5. Distributions paramétriques

Les principales lois

L'estimation des paramètres

6. Modèle de Cox

Définitions

Inférence

Hypothèses

Risques Proportionnels

Log linéarité

7. Perspectives

$$h(t|x_1, x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

- Fonction de risque dépendante du temps
- Facteurs de risque indépendants du temps

$$h(t|x_1, x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

- Fonction de risque dépendante du temps
- Facteurs de risque indépendants du temps

$$h(t|x_1, x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

- **Fonction de risque dépendante du temps.**
- Facteurs de risque indépendants du temps. Les HR sont constants au cours du temps.

Cette dernière hypothèse (*proportional hazard*, PH) est régulièrement non respectée.

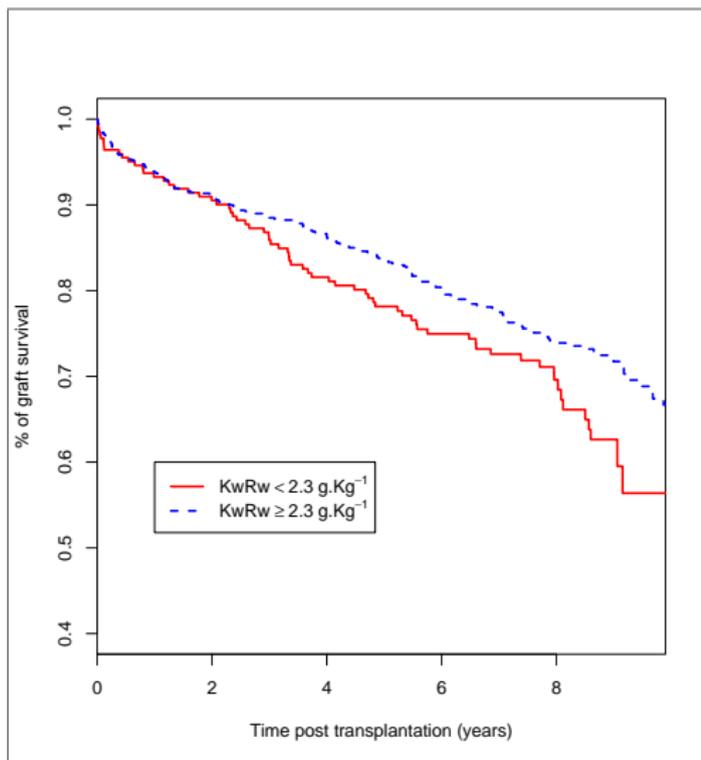
$$h(t|x_1, x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

- Fonction de risque dépendante du temps.
- Facteurs de risque indépendants du temps. Les HR sont constants au cours du temps.

Cette dernière hypothèse (*proportional hazard*, PH) est régulièrement non respectée.

$$KwRw = \frac{\text{Poids du rein}}{\text{Poids du receveur}}$$

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives



- Tracer les courbes $\log(-\log(S(t)))$ dans chacun des groupes en fonction du temps t .
- Si courbes parallèles : hypothèse respectée.
- Démonstration :

$$h(t|x_1) = h_0(t) \exp(\beta_1 x_1)$$

\iff

$$H(t|x_1) = \int_0^t h_0(u) \exp(\beta_1 x_1) du$$

\iff

$$H(t|x_1) = \exp(\beta_1 x_1) \int_0^t h_0(u) du = H_0(t) \exp(\beta_1 x_1)$$

\iff

$$S(t|x_1) = \exp(-H(t|x_1)) = \exp(-H_0(t) \exp(\beta_1 x_1)) = S_0(t)^{\exp(\beta_1 x_1)}$$

Donc si l'hypothèse PH est respectée :

$$\log(S(t|x_1)) = \exp(\beta_1 x_1) \log(S_0(t))$$

$$\iff$$

$$-\log(S(t|x_1)) = \exp(\beta_1 x_1) H_0(t)$$

$$\iff$$

$$\log(-\log(S(t|x_1))) = \beta_1 x_1 + \log(H_0(t))$$

Ex : si $x_1 = 1/0$:

$$\log(-\log(S(t|x_1 = 1))) - \log(-\log(S(t|x_1 = 0))) = \beta_1$$

Introduction

Définitions

Kaplan-Meier

Estimation

Variance

LogRank

Distributions
paramétriques

Les principales lois

L'estimation des
paramètres

Modèle de Cox

Définitions

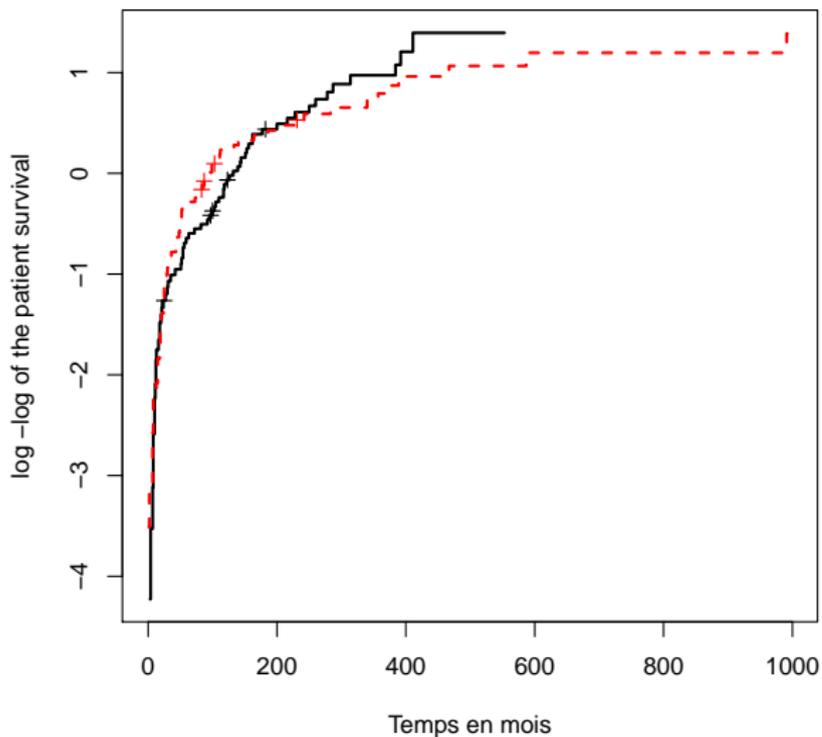
Inférence

Hypothèses

Perspectives

```
> f <- survfit(Surv(time, status) ~ trt, data = veteran)
> log.minus.log<-function(y) { log(-log(y)) }
> plot(f , fun=log.minus.log, ylab="log -log of the patient survival",
+ col=1:2, lwd=c(2,2), lty=1:2, xlab="Temps en mois")
```

- Introduction
- Définitions
- Kaplan-Meier
- Estimation
- Variance
- LogRank
- Distributions paramétriques
- Les principales lois
- L'estimation des paramètres
- Modèle de Cox
- Définitions
- Inférence
- Hypothèses
- Perspectives



$$h(t|x_1, x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

→ Si x_2 est une variable continue :

$$HR_{u+1/u} = \exp(\beta_2) \forall u$$

→ Cette relation dose-effet constante peut souvent être remise en question, en particulier quand il s'agit de la variable d'intérêt (et pas d'une "simple" variable d'ajustement).

→ Une solution simple et pragmatique :

- 1 catégoriser la variable en p classes équilibrées,
- 2 choisir la première classe comme référence ($p - 1$ variables indicatrices),
- 3 tracer le log des HR en fonction du centre de chaque classe,
- 4 vérifier la linéarité.

$$h(t|x_1, x_2, \dots) = h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \dots)$$

→ Si x_2 est une variable continue :

$$HR_{u+1/u} = \exp(\beta_2) \forall u$$

→ Cette relation dose-effet constante peut souvent être remise en question, en particulier quand il s'agit de la variable d'intérêt (et pas d'une "simple" variable d'ajustement).

→ Une solution simple et pragmatique :

- 1 catégoriser la variable en p classes équilibrées,
- 2 choisir la première classe comme référence ($p - 1$ variables indicatrices),
- 3 tracer le log des HR en fonction du centre de chaque classe,
- 4 vérifier la linéarité.

1. Introduction
2. Définitions
3. Kaplan-Meier
 - Estimation
 - Variance
4. LogRank
5. Distributions paramétriques
 - Les principales lois
 - L'estimation des paramètres
6. Modèle de Cox
 - Définitions
 - Inférence
 - Hypothèses
 - Risques Proportionnels
 - Log linéarité
7. Perspectives

- **Le modèle de Cox stratifié** : une fonction de risque base différente par modalité d'une variable (ajuster sur cette variable sans estimer les effets fixes).
- **Analyses des résidus.**
- **Le modèle de Cox étendu** aux variables dont l'effet ou la valeur dépendent du temps.
- **Les modèles à risques compétitifs** permettent de modéliser des événements en concurrence et de prendre en compte une éventuelle censure informative.
- **Les modèles de survie relative** permettent d'éliminer la mortalité attendue d'une population de référence.
- **Les modèles multi-états** permettent de modéliser l'évolution d'un patient à travers différents états santé.
- **Les modèles de fragilités** permettent d'inclure des effets aléatoires et donc une structure de dépendance des données.

- LogVraisemblance → LogLikelihood
- Hazard Ratio (HR)
- Modèle à Risque Proportionnel → Proportional Hazard (PH) model
- Test du rapport de Vraisemblances → Likelihood Ratio Statistic (LRS)
- Vraisemblance partielle → Partial Likelihood
- Fonction de répartition : Cumulative Incidence Function (CIF).