

# Biostatistique

## Analyse de la survie

Pr Pascal ROY

Remerciements : Pr Jacques ESTEVE

1. Introduction - Analyse de la survie
2. Méthode de Kaplan et Meier - Test du Log-Rank
3. Taux de Mortalité
4. Survie paramétrique / Survie exponentielle par intervalle
5. Modèle à Taux proportionnel

Dans ces diapos, « log » est le logarithme népérien.

# 1. Introduction

- Contexte Médical
  - Quantifier la *probabilité de décès*, rechute...
  - Evaluer les *facteurs pronostiques*
  - Comparer des *traitements*

•••••

Le risque (ou probabilité) de décès d'un individu est de toute façon égal à un !!!

La probabilité de décéder estimée sur une cohorte d'individus n'a de sens qu'à délai fixé.

La variable d'intérêt est la variable aléatoire  $T$ , que constitue la durée qui sépare le diagnostic de la mort (ou de la rechute), variable dont on étudie la distribution.

# Contexte

- Statistique
  - mesure du *temps* écoulé entre deux *événements*
  - distribution *non gaussienne*
  - utilisation de méthodes *non-paramétriques*
  - Prise en compte de données incomplètes: données *censurées* et *tronquées*

# Temps entre événements

## Origine

Naissance

Infection HIV

*Diagnostic*, rando-  
misation, traitement

Entrée à l'hôpital

Rémission

Mise en service

## Événement

Maladie, décès

SIDA

*Décès* (ou décès *de la  
maladie*)

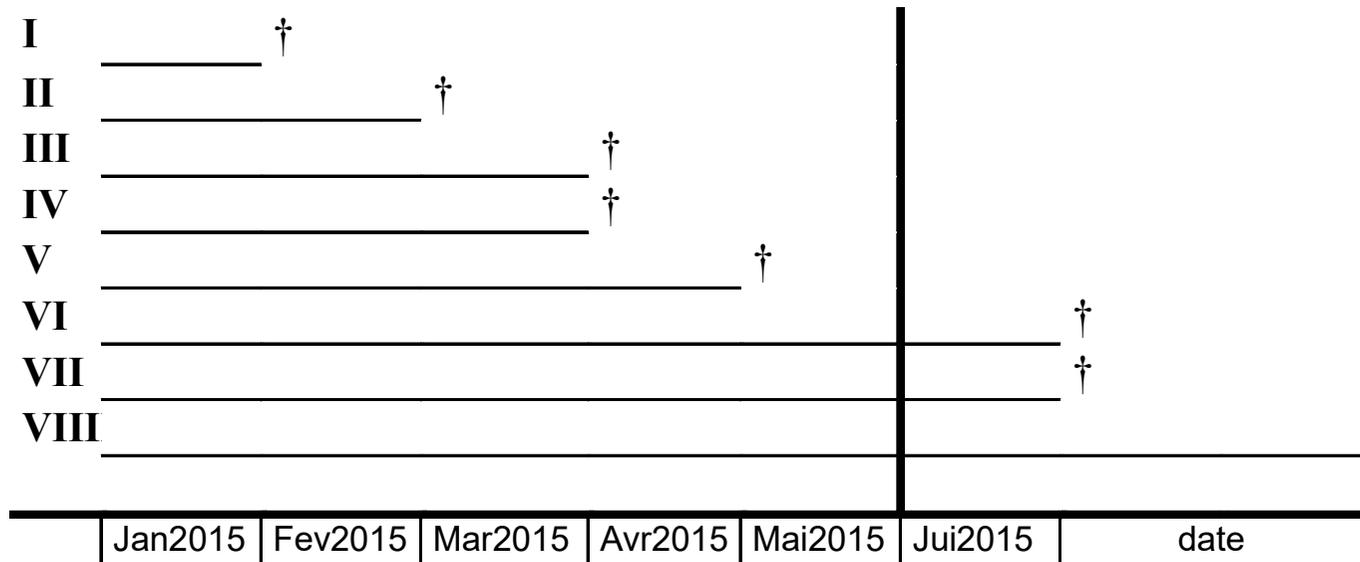
Infection nosocomiale

Rechute

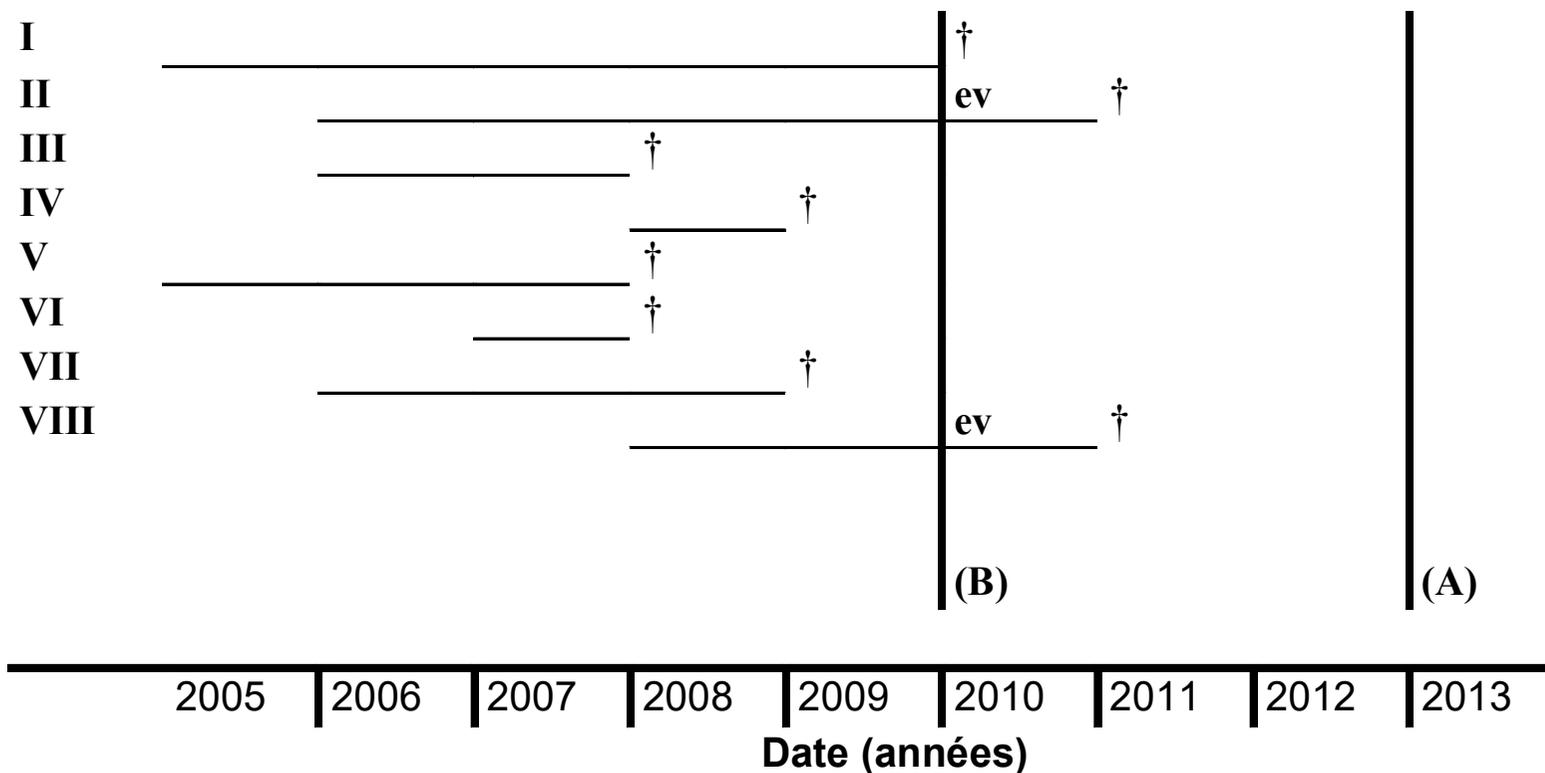
Panne

# Censure

- L'observation est censurée (à droite) si on sait seulement que  $T > t$ , *date* à laquelle l'observation s'est achevée.
  - l'évènement est le *décès* et le sujet est en vie à la fin de l'étude
  - l'évènement est le *décès par cancer* et l'observation s'achève par un *accident*

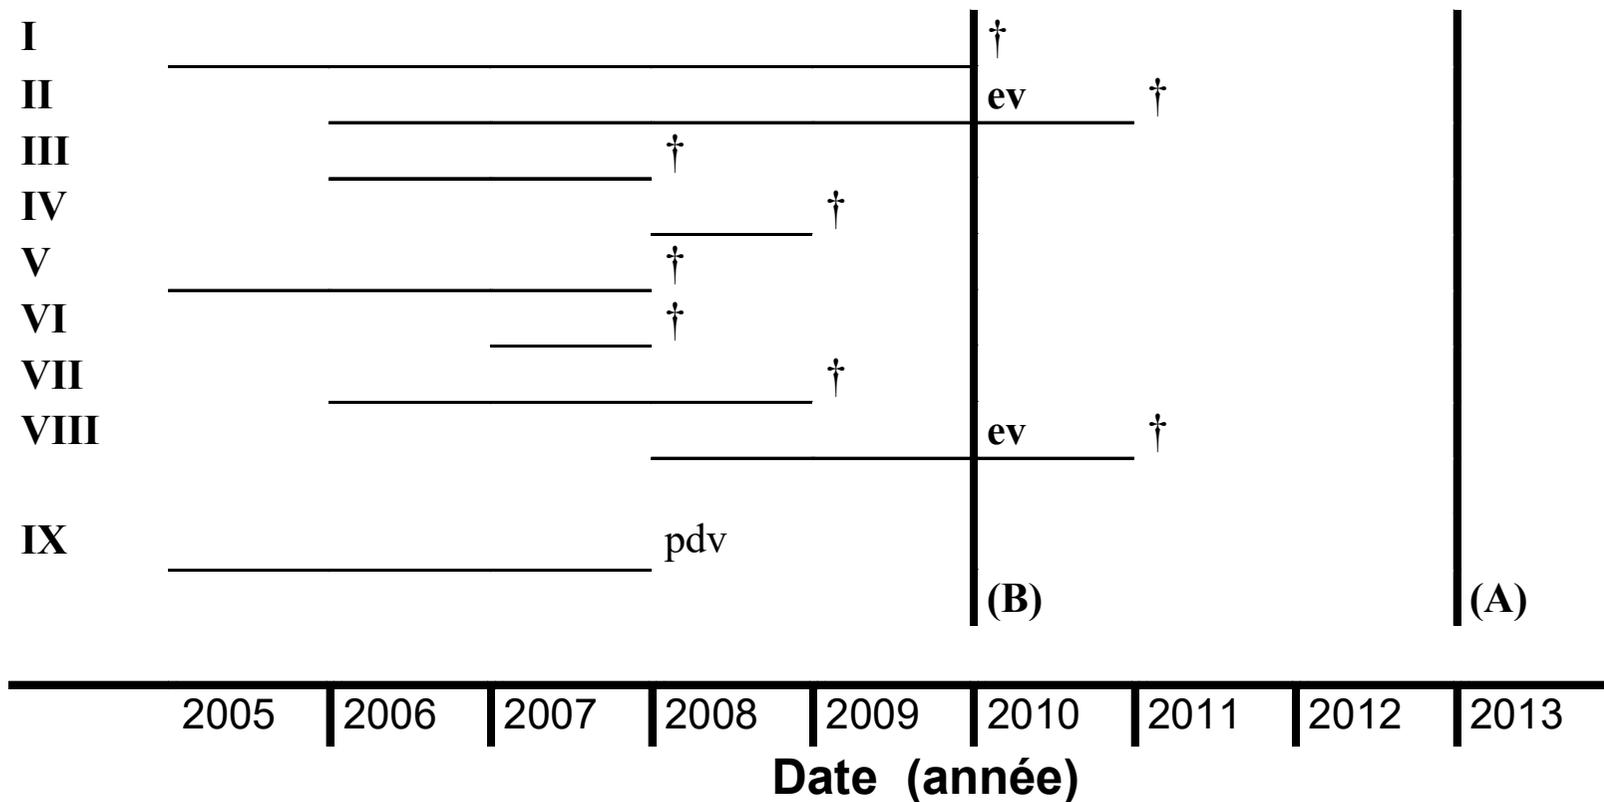


*Données fictives*  
*Date d'origine commune à tous les sujets*



### *Données fictives*

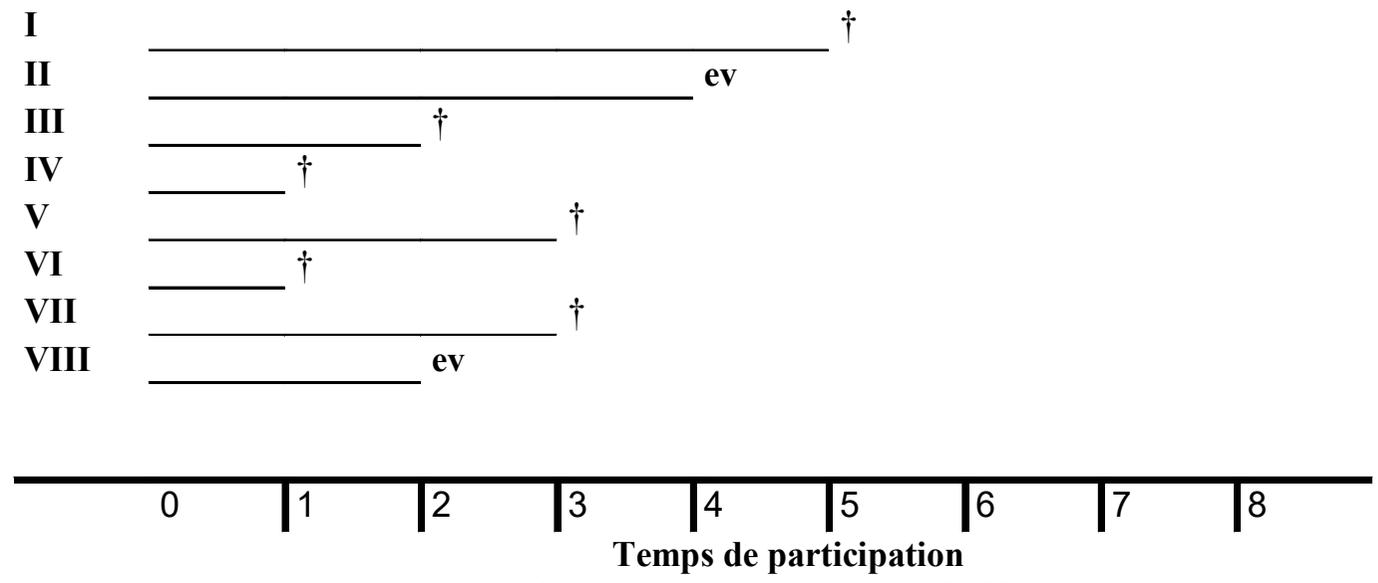
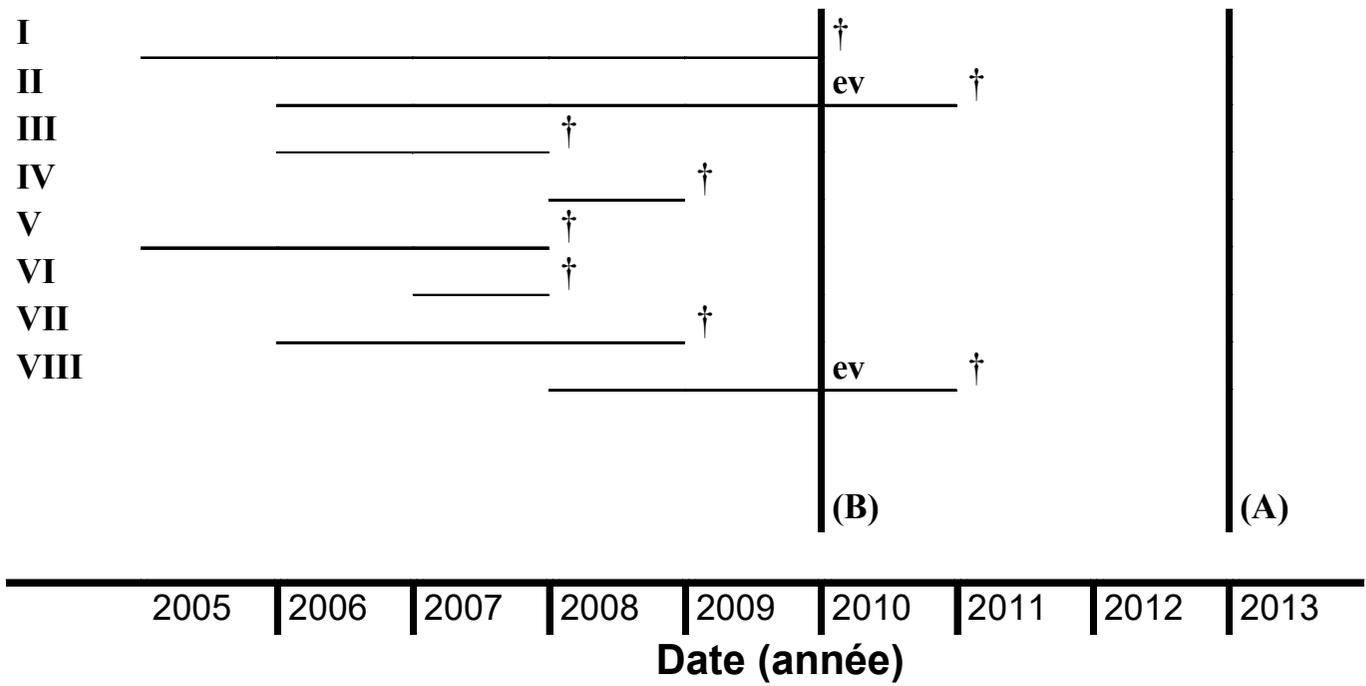
*Dates d'origine échelonnées au cours du temps.  
(A) et (B) sont deux dates possibles de fin de suivi*



**ev** : exclu vivant

### *Données fictives*

*Dates d'origine échelonnées au cours du temps.  
(A) et (B) sont deux dates possibles de fin de suivi*



En résumé, certains sujets ne sont pas suivis jusqu'à ce que l'événement se produise, pour eux on sait seulement que  $T > t_j$ . L'observation correspondante est une observation *censurée*. Les données de survie sont donc constituées de deux informations, la durée du suivi  $T$ , et l'indicateur d'événement  $\delta$  ;  $\delta = 1$  si l'observation se termine par un *décès*,  $\delta = 0$  si le sujet est *vivant* à la fin des dernières nouvelles.

# Définitions

- **Risque de décès** = *probabilité* d'être décédé à la date  $t$  = *fonction de répartition* de la variable  $T = R(t) = Pr(T \leq t)$
- **Survie** = *probabilité* d'être en vie à la date  $t = S(t) = Pr(T > t) = 1 - R(t)$ \*

\* pour une distribution continue

# Rappel

## Distribution cumulée

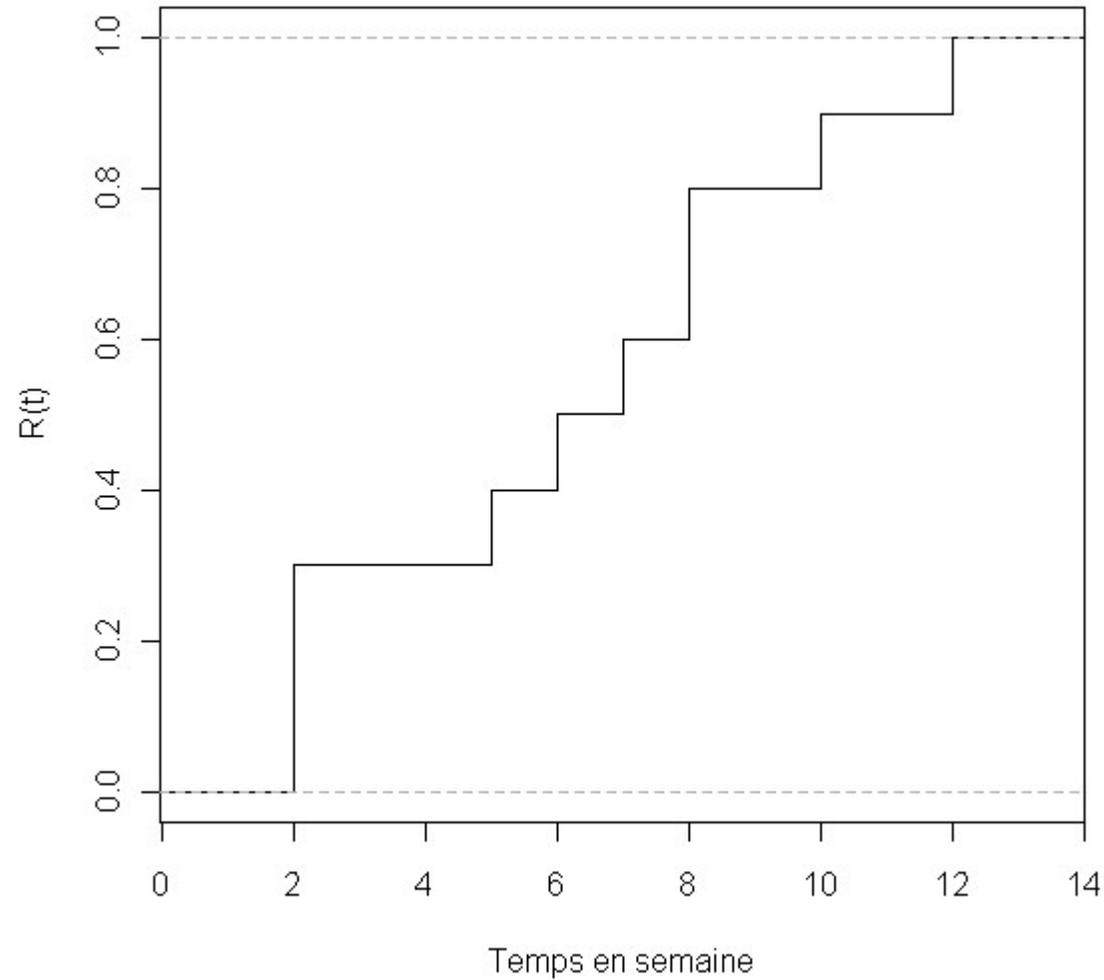
# Durées de survie

obs:  $t_1$   $t_2$   $t_3$   $t_4$   $t_5$   $t_6$   $t_7$   $t_8$   $t_9$   $t_{10}$   
 2 2 8 2 6 8 5 10 12 7

ord:  $t_{(1)}$   $t_{(2)}$   $t_{(3)}$   $t_{(4)}$   $t_{(5)}$   $t_{(6)}$   $t_{(7)}$   $t_{(8)}$   $t_{(9)}$   $t_{(10)}$   
 2 2 2 5 6 7 8 8 10 12

événmt:  $\leq 2$   $\leq 5$   $\leq 6$   $\leq 7$   $\leq 8$   $\leq 10$   $\leq 12$   
 freq. 0.3 0.4 0.5 0.6 0.8 0.9 1

# Fonction de répartition empirique



# Données complètes\*

- Si  $t_{(i)}$  est le  $i$ ème temps de survie de l'échantillon
- Le **Risque** est estimé par:
  - $t_{(i)} \longrightarrow i/n_0$
- La **Survie** est estimée par:
  - $t_{(i)} \longrightarrow (n_0 - i)/n_0 = n_i/n_0 = 1 - i / n_0$

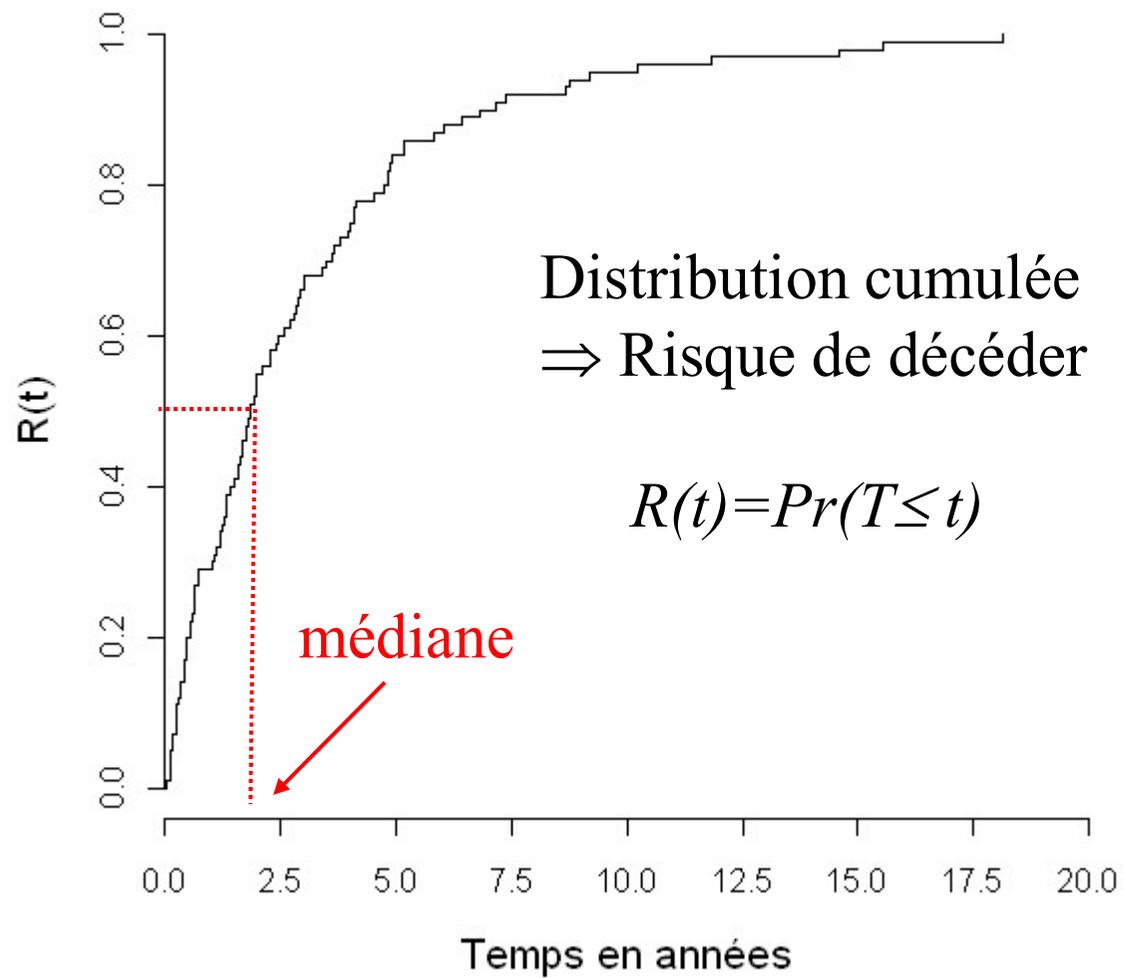
\*et sans ex-aequo

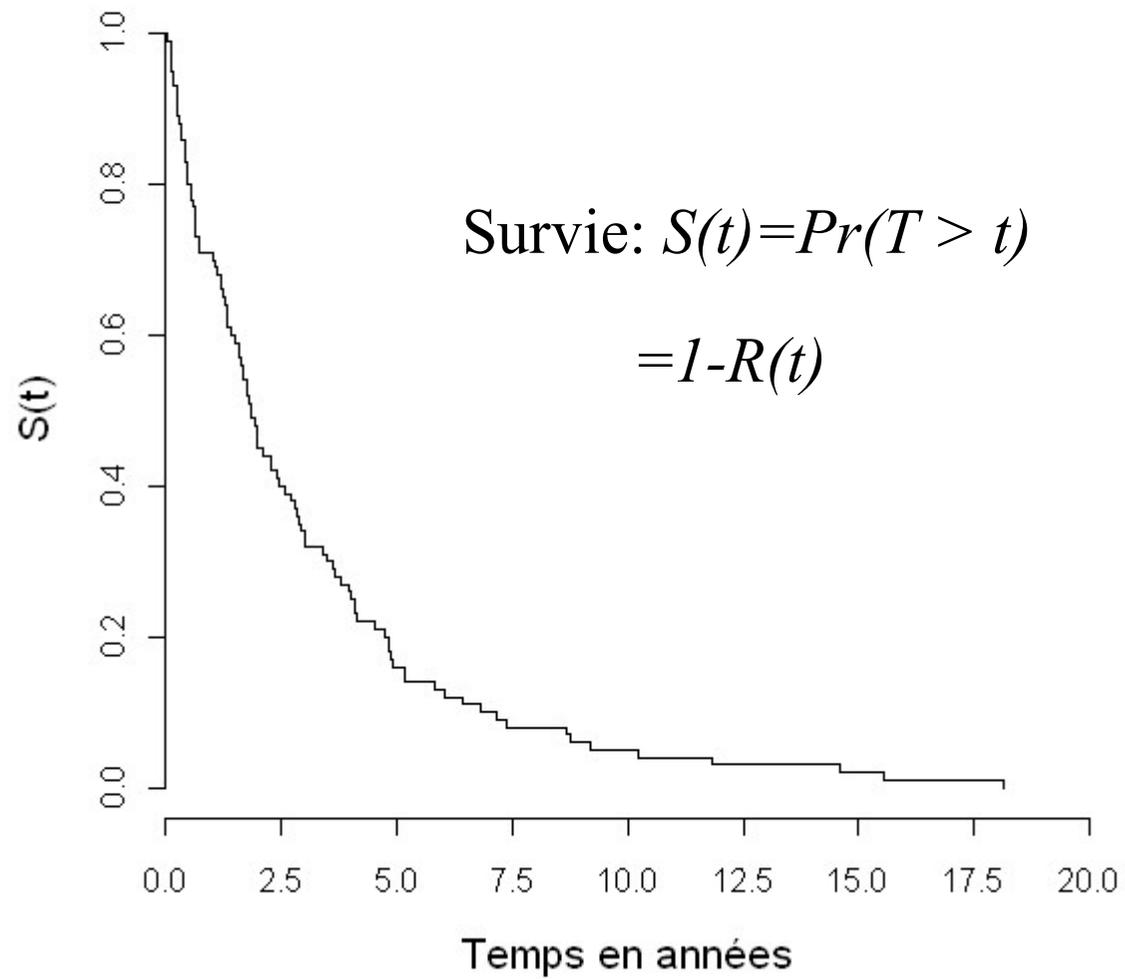
# Exemple 1: temps de survie en années (données complètes)

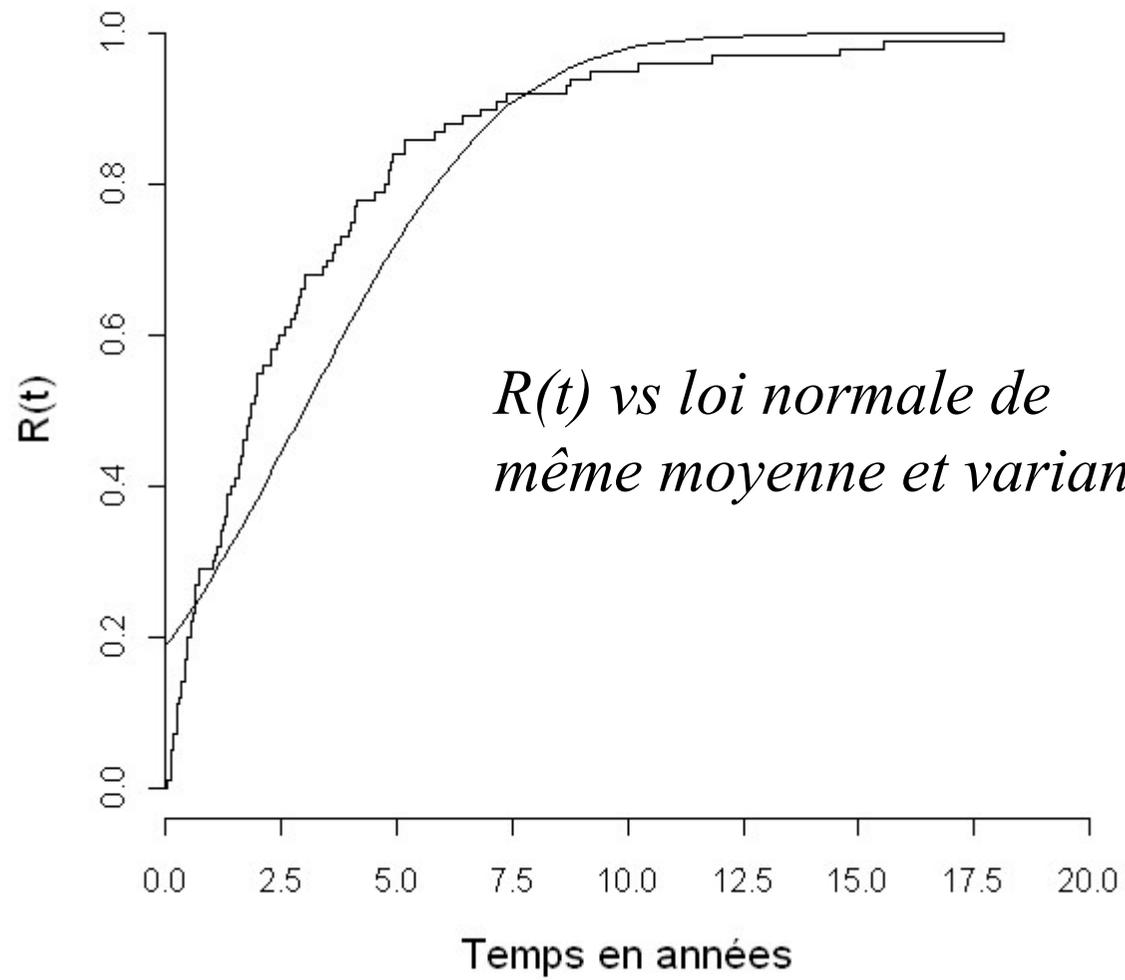
1.22	1.86	1.35	3.81	0.47	1.63	2.47	0.42	0.24	0.45
2.83	5.17	18.14	4.92	0.30	2.87	9.21	1.32	2.09	3.48
1.58	5.16	2.43	0.05	3.00	0.24	4.01	0.34	1.59	7.39
0.42	1.08	0.63	0.56	1.79	0.63	2.60	0.11	1.43	3.97
1.22	7.18	3.66	0.10	2.29	3.40	4.13	2.78	4.82	4.87
5.81	1.25	4.08	6.81	6.02	0.15	1.66	3.60	0.18	0.12
2.72	15.56	0.72	1.35	0.72	8.68	1.96	1.97	4.75	0.62
2.94	2.27	4.53	10.22	1.03	1.84	4.81	1.66	0.34	1.78
0.55	0.25	3.00	0.25	0.48	8.74	0.64	6.41	14.59	1.93
0.10	4.08	11.82	1.78	1.51	1.96	0.41	1.12	1.28	0.60

moyenne: 2.994 ans

déviatiion standard: 3.363 ans







# Données incomplètes

- Certains sujets ne sont pas suivis jusqu'à ce que l'événement se produise
  - pour eux on sait seulement que  $T > t_i$
  - $t_i$  est une observation *censurée*
- Les données censurées sont résumées par
  - $T$  durée du suivi,  $\delta$  indicateur de l'événement
    - $\delta = 1$  si l'observation se termine par un *décès*
    - $\delta = 0$  si le sujet est *vivant* à la fin du suivi

**1. Introduction - Analyse de la survie**

**2. Méthode de Kaplan et Meier - Test du Log-Rank**

**3. Taux de Mortalité**

**4. Survie paramétrique / Survie exponentielle par intervalle**

**5. Modèle à Taux proportionnel**

## 2. Méthode de Kaplan-Meier

- Données complètes (*observation de i décès*)

$$- S(t_i) = (1 - i/n_0) =$$

$$\left(1 - \frac{1}{n_0}\right) \times \left(1 - \frac{1}{n_0 - 1}\right) \times \left(1 - \frac{1}{n_0 - 2}\right) \times \dots \times \left(1 - \frac{1}{n_0 - i + 1}\right)$$

$$- S_1 \quad S_2 \quad S_3 \dots \dots \quad S_i$$

- Données incomplètes ( $\sum \delta_i$  décès)

$$\left(1 - \frac{\delta_1}{n_0}\right) \times \left(1 - \frac{\delta_2}{n_0 - 1}\right) \times \left(1 - \frac{\delta_3}{n_0 - 2}\right) \times \dots \times \left(1 - \frac{\delta_i}{n_0 - i + 1}\right)$$

# Kaplan-Meier (exemple)

- **Données complètes (*observation de 50 décès*)**

$$- S(t_{20}) = (1 - 20 / 50) = 30 / 50$$

$$\left(\frac{49}{50}\right) \times \left(\frac{48}{49}\right) \times \left(\frac{47}{48}\right) \times \dots \times \left(\frac{30}{31}\right)$$

- **Données incomplètes ( $\sum \delta_i$  décès)**

$$\left(\frac{49}{50}\right) \times (1) \times \left(\frac{47}{48}\right) \times \dots \times \left(\frac{30}{31}\right)$$

# Kaplan-Meier (exemple)

- **Données complètes (*observation de 50 décès*)**

$$- S(t_{20}) = (1 - 20 / 50) = 30 / 50$$

$$\left(\frac{\cancel{49}}{50}\right) \times \left(\frac{48}{\cancel{49}}\right) \times \left(\frac{47}{48}\right) \times \dots \times \left(\frac{30}{31}\right)$$

- **Données incomplètes ( $\sum \delta_i$  décès)**

$$\left(\frac{49}{50}\right) \times (1) \times \left(\frac{47}{48}\right) \times \dots \times \left(\frac{30}{31}\right)$$

# Kaplan-Meier (exemple)

- **Données complètes (*observation de 50 décès*)**

$$- S(t_{20}) = (1 - 20 / 50) = 30 / 50$$

$$\left(\frac{\cancel{49}}{50}\right) \times \left(\frac{\cancel{48}}{\cancel{49}}\right) \times \left(\frac{47}{\cancel{48}}\right) \times \dots \left(\frac{30}{31}\right)$$

- **Données incomplètes ( $\sum \delta_i$  décès)**

$$\left(\frac{49}{50}\right) \times (1) \times \left(\frac{47}{48}\right) \times \dots \left(\frac{30}{31}\right)$$

# Kaplan-Meier (exemple)

- **Données complètes (*observation de 50 décès*)**

$$- S(t_{20}) = (1 - 20 / 50) = 30 / 50$$

$$\left(\frac{\cancel{49}}{50}\right) \times \left(\frac{\cancel{48}}{\cancel{49}}\right) \times \left(\frac{\cancel{47}}{\cancel{48}}\right) \times \dots \left(\frac{30}{31}\right)$$

- **Données incomplètes ( $\sum \delta_i$  décès)**

$$\left(\frac{49}{50}\right) \times (1) \times \left(\frac{47}{48}\right) \times \dots \left(\frac{30}{31}\right)$$

# Kaplan-Meier (exemple)

- **Données complètes (*observation de 50 décès*)**

–  $S(t_{20}) = (1 - 20 / 50) = 30 / 50$

$$\left(\frac{\cancel{49}}{50}\right) \times \left(\frac{\cancel{48}}{\cancel{49}}\right) \times \left(\frac{\cancel{47}}{\cancel{48}}\right) \times \dots \times \left(\frac{30}{\cancel{31}}\right)$$

- **Données incomplètes ( $\sum \delta_i$  décès)**

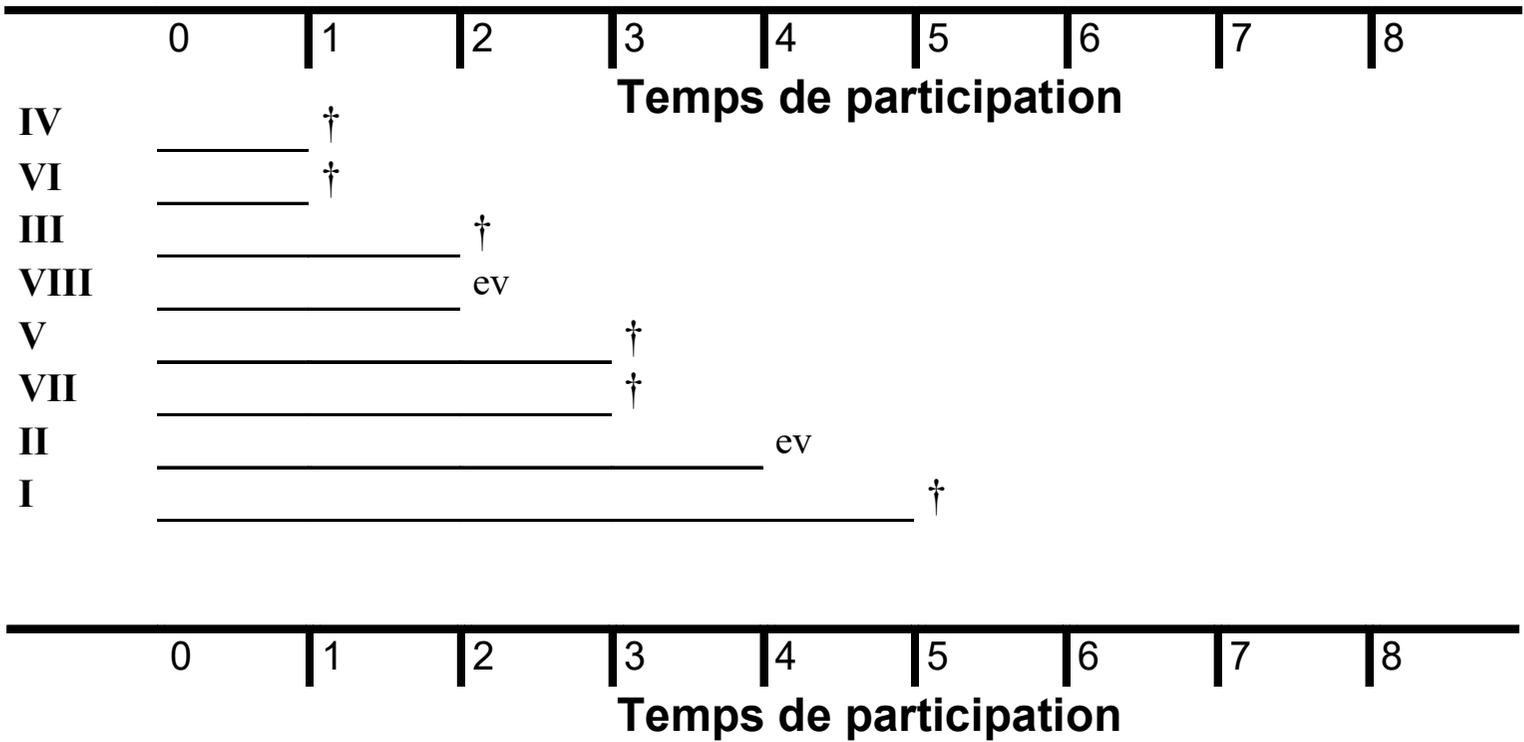
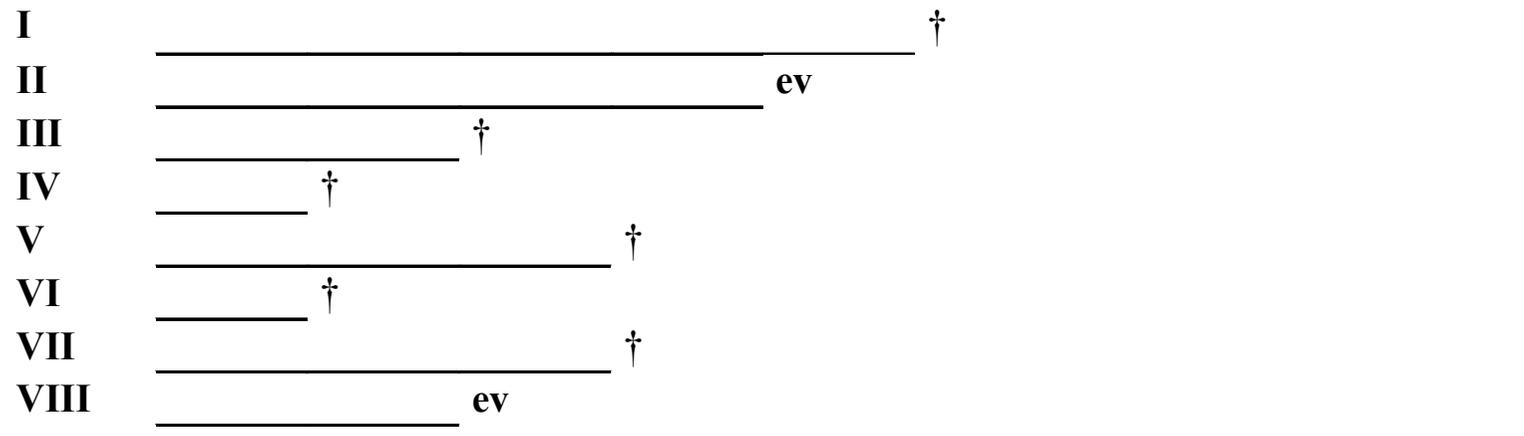
$$\left(\frac{49}{50}\right) \times (1) \times \left(\frac{47}{48}\right) \times \dots \times \left(\frac{30}{31}\right)$$

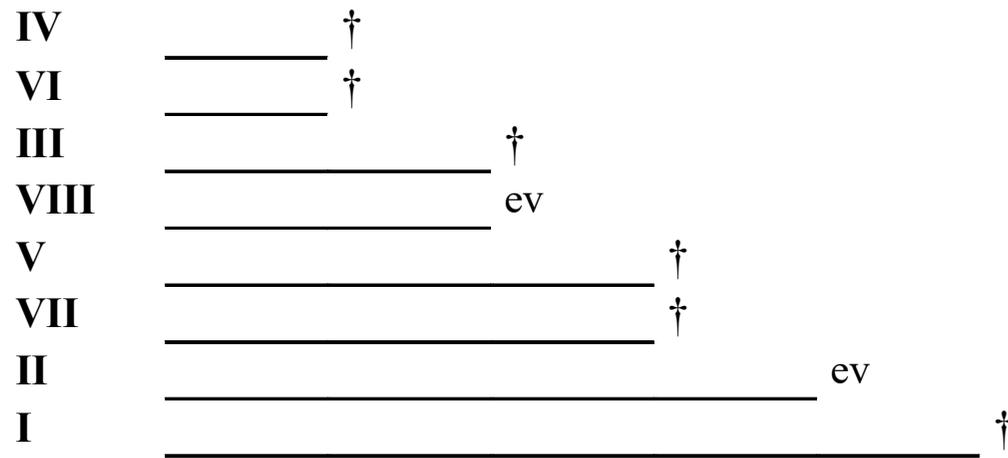
# Erreur type de la survie en $t_i$

- Si les données sont complètes (pas de censure) l'erreur type est celle d'une proportion

$$\hat{S}_i = n_i / n_0 \quad SE[\hat{S}_i] = \sqrt{\frac{\hat{S}_i (1 - \hat{S}_i)}{n_0}}$$

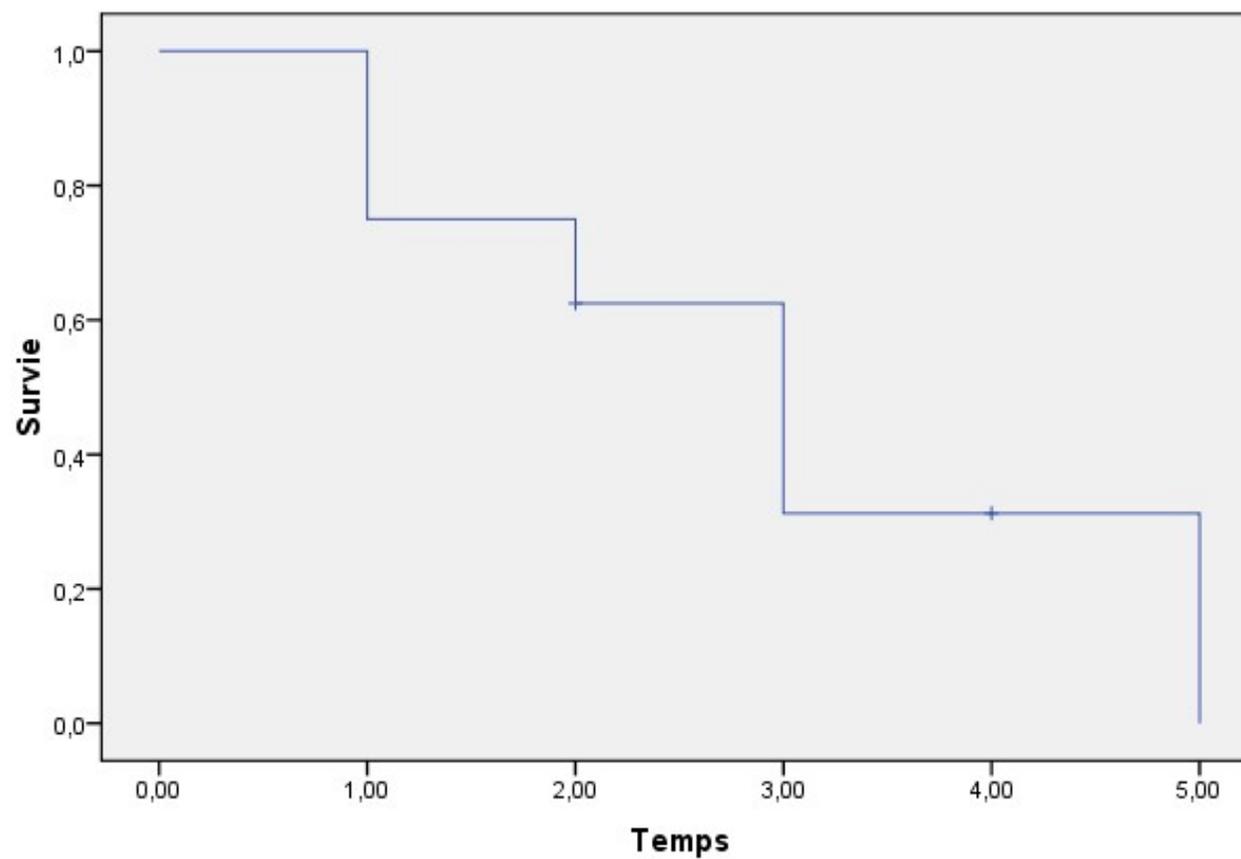
- En cas de censure l'erreur type est
  - plus élevée que celle-ci
    - Variance de Greenwood





Temps de participation						
$t_j$	$N_j$	ev	$d_j$	$s_j$	$S_j$	
0	8				1	
1	8	0	2	6/8	6/8	
2	6	0	1	5/6	5/8	
2	5	1	0	1	5/8	
3	4	0	2	2/4	5/16	
4	2	1	0	1	5/16	
5	1	0	1	0	0	

$t_j$	$N_j$	$ev$	$d_j$	$s_j$	$S_j$
0	8				1
1	8	0	2	6/8	6/8
2	6	0	1	5/6	5/8
2	5	1	0	1	5/8
3	4	0	2	2/4	5/16
4	2	1	0	1	5/16
5	1	0	1	0	0



# Comparaison de la survie dans deux groupes

- Comparer quoi?
  - la survie moyenne
  - la survie médiane
  - la probabilité de survie à un “délai” donné
- La troisième option est banale: utiliser le test classique:

$$\chi = \frac{\hat{S}_{1i} - \hat{S}_{2i}}{\sqrt{Var(\hat{S}_{1i}) + Var(\hat{S}_{2i})}}$$

# Comparaison de la survie dans deux groupes

- L'option précédente ne compare que la situation dans les deux groupes *à un délai donné*
- On souhaite comparer les **distributions** des durées de survie
- La spécificité des données de survie suggère l'utilisation de *méthodes non-paramétriques*

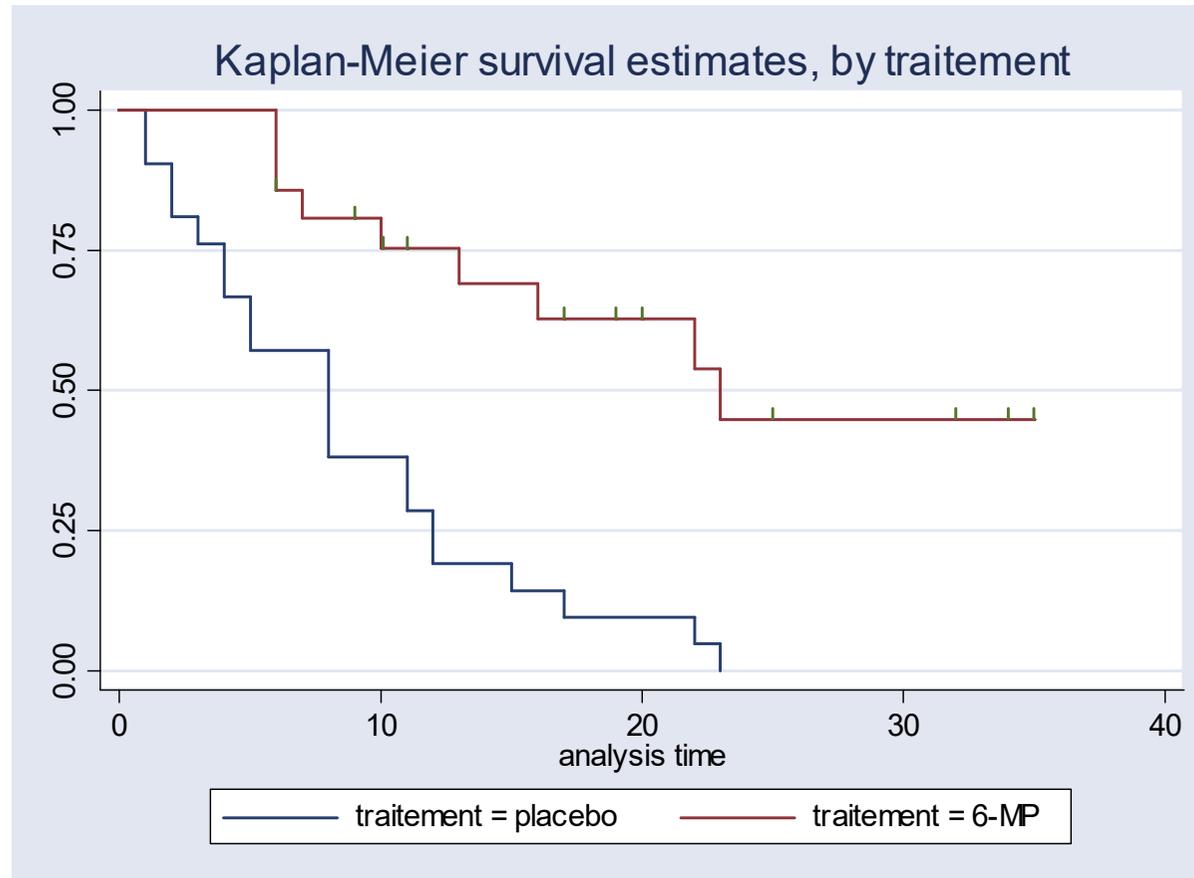
# Exemple 2, Anderson data

Une première illustration de ce qui précède est basé sur des données historiques très utilisées pour illustrer la méthodologie.

Elle concerne la durée de rémission de la leucémie aigue obtenue par traitement stéroïde si on traite en outre avec la 6-mercaptopurine

Ref:Freireich *et al. Blood* 1963;**21**:699-716

# Rechute 6-MP vs Placebo



# Comparaison des distributions de survie

- Généralisation des test de *rang* aux données censurées: les *rangs* des observations *triées globalement* se distribuent ils au hasard entre les deux groupes?
  - *le test du “log-rank”* est le test efficace contre l’alternative de taux proportionnels dans les deux groupes
  - C’est formellement le principe du test de *Mantel-Haenszel-Cochran*

# Test du “Log-rank”

- Calcul pratique
  - Calculer pour chaque date de décès le **nombre attendu** de décès qui serait observé si les taux de décès étaient les mêmes dans les (deux) groupes
  - Cumuler les différences entre **observés** et **attendus** jusqu’à la date du dernier décès observé
  - Evaluer la **signification** de la différence cumulée en la comparant à son erreur type
- Noter que ce test ne prend en compte que les rangs d’apparition des décès non les dates

# Test du Log-rank (technique)

- Pour chaque date de décès construire la table:

	<i>Groupe 1</i>	<i>Groupe 2</i>	<i>Total</i>
<i>décès</i>	$d_{1i}$	$d_{2i}$	$d_{+i}$
<i>effectifs</i>	$n_{1i}$	$n_{2i}$	$n_{+i}$

- Sous l'hypothèse nulle  $H_0$ , les  $d_{+i}$  décès se distribuent proportionnellement aux effectifs
  - Le nombre attendu dans le groupe 2 est donc

$$e_{2i} = d_{+i} \times n_{2i}/n_{+i}$$

- $d_{+i}$  étant fixé, la variance de  $\Delta_i = d_{2i} - e_{2i}$  est:

$$Var(\Delta_i) = \frac{n_{1i}n_{2i}d_{+i}(n_{+i} - d_{+i})}{n_{+i}^2(n_{+i} - 1)}$$

- test =  $(\sum_i \Delta_i)^2 / \sum_i Var(\Delta_i)$

**Si k est grand, ou si les marges de chaque tableau sont grandes,**

$$U = \sum_{i=1}^k w_i (d_{2i} - e_{2i}) = \sum_{i=1}^k w_i \left( d_{2i} - d_{+i} \frac{n_{2i}}{n_{+i}} \right)$$

**Suit une loi asymptotiquement normale. Sous  $H_0$ , le test s'écrit**

$$\chi^2 = \frac{\left[ \sum_{i=1}^k w_i \left( d_{2i} - d_{+i} \frac{n_{2i}}{n_{+i}} \right) \right]^2}{\sum_{i=1}^k w_i^2 d_{+i} \frac{(n_{+i} - d_{+i}) n_{1i} n_{2i}}{(n_{+i} - 1) n_{+i}^2}} \quad \chi^2 \text{ à } 1 \text{ ddl}$$

$$\chi^2 = \frac{\left[ \sum_{i=1}^k w_i \left( d_{2i} - d_{+i} \frac{n_{2i}}{n_{+i}} \right) \right]^2}{\sum_{i=1}^k w_i^2 d_{+i} \frac{(n_{+i} - d_{+i}) n_{1i} n_{2i}}{(n_{+i} - 1) n_{+i}^2}}$$

Si  $w_i = 1$ , test de Mantel-Haenszel, de Cox, ou du Logrank

comparant

$$O_2 = \sum_{i=1}^k d_{2i} \quad \text{et} \quad E_2 = \sum_{i=1}^k e_{2i}$$

$$\chi^2 = \frac{(O_2 - E_2)^2}{\sum_{i=1}^k v_i}$$

$$\chi^2 = \frac{(O_2 - E_2)^2}{\sum_{i=1}^k v_i}$$

**La formule approchée du logrank**

$$\chi_a^2 = \frac{(O_2 - E_2)^2}{E_2} + \frac{(O_1 - E_1)^2}{E_1}$$

**est conservative !**

## Exemple 2:6-MP vs Placebo

T	n1	d1	n2	d2	n+	d+	e2	var	e1
1	21	0	21	2	42	2	1.000	0.488	1.000
2	21	0	19	2	40	2	0.950	0.486	1.050
3	21	0	17	1	38	1	0.447	0.247	0.553
4	21	0	16	2					
5	21	0	14	2					
6	21	3	12	0					
7	17	1	12	0					
8	16	0	12	4					
10	15	1	8	0					
11	13	0	8	2					
12	12	0	6	2					
13	12	1	4	0					
15	11	0	4	1					
16	11	1	3	0					
17	10	0	3	1					
22	7	1	2	1					
23	6	1	1	1					
<b>Total</b>		<b>9</b>		<b>21</b>			<b>10.749</b>	<b>6.257</b>	<b>19.251</b>

**Log-rank test  $\chi^2 = (21 - 10.749)^2 / 6.257 = 16.794$**

# Log rank test, extension

- Le test s'étend simplement dans deux directions:
  - **Comparaison de plus de deux groupes:** la table 2x2 est remplacée par une table 2xk. La variance par une matrice de covariance. Le test est à k-1 ddl.
  - **Contrôle pour des facteurs de confusion:** on stratifie les données selon les valeurs des variables à contrôler. On calcule les observés, les attendus et les variances dans chaque strate. On cumule les résultats pour construire le test. *(les attendus sont calculés à "facteur de confusion constants")*

# Conclusion

- On dispose de nombreux outils pour estimer la *distribution de durée de survie* éventuellement censurée
- Des *tests de comparaison* de distributions existent
- On aimerait avoir des *modèles de régression* pour gérer simultanément plusieurs co-variables.

- 1. Introduction - Analyse de la survie**
- 2. Méthode de Kaplan et Meier - Test du Log-Rank**
- 3. Taux de Mortalité**
- 4. Survie paramétrique / Survie exponentielle par intervalle**
- 5. Modèle à Taux proportionnel**

# 3. Taux de mortalité

- Objectif: Quantifier le risque de décéder *maintenant* si on était en vie *jusqu'à maintenant*
  - Le taux de décès  $\lambda(t)$  mesure la « *force de mortalité* » appliquée à la population des patients *survivants* à la date  $t$  après le diagnostic

$$\lambda(t) = \lim_{dt \rightarrow 0} \frac{\Pr(t \leq T < t + dt | T > t)}{dt}$$

- Le *taux* de décès **n'est pas** une *probabilité* en particulier il est éventuellement  $>1$



# Relation entre $R$ , $S$ et $\lambda$

dérivée de  $R$  (densité)

$$\lambda(t) = \frac{R'(t)}{1 - R(t)}$$

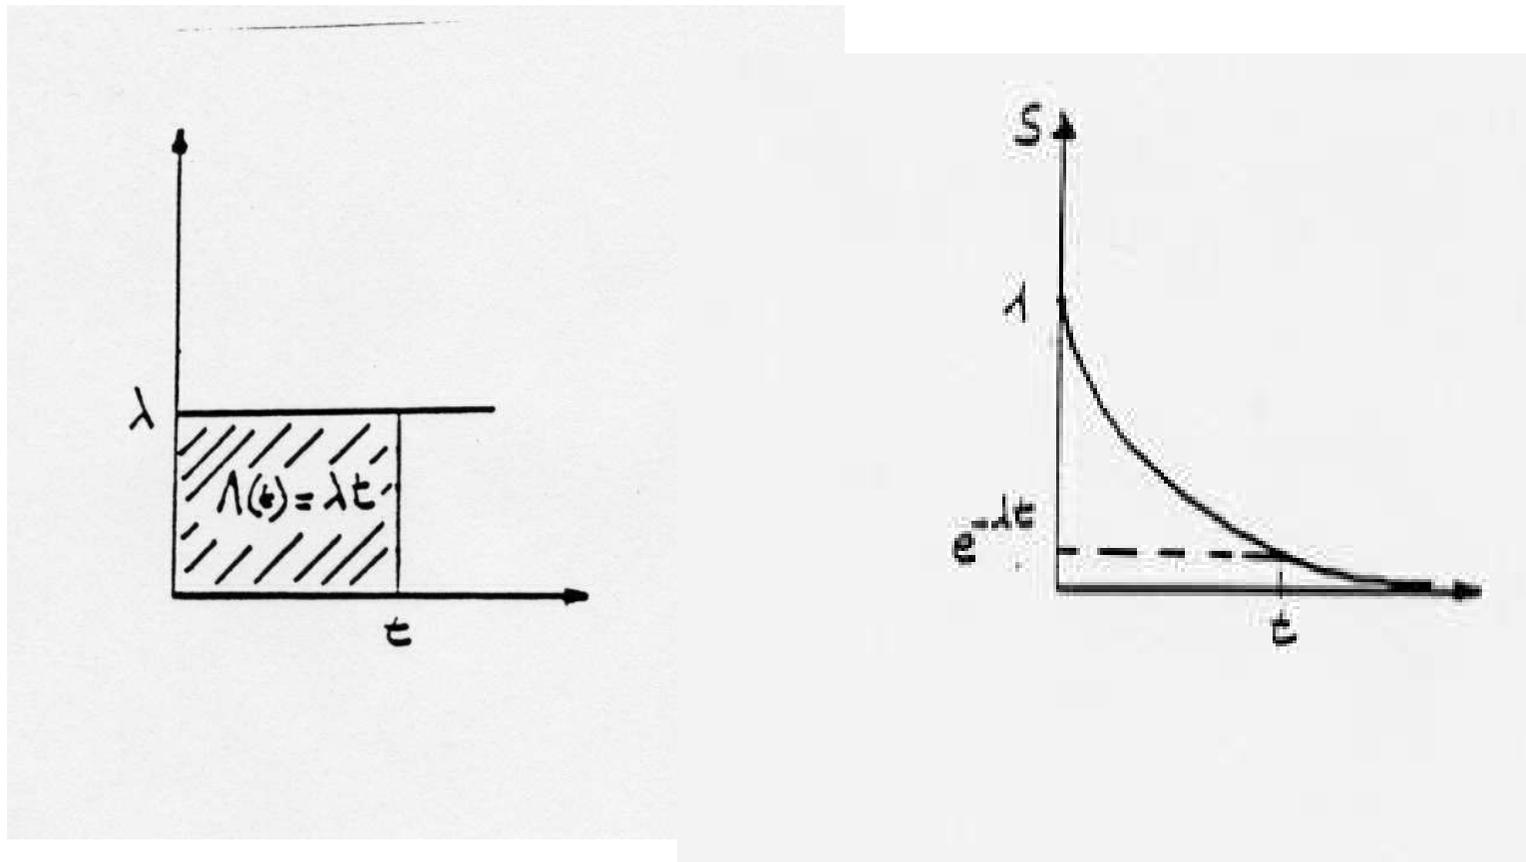
$$\text{Log}(1 - R(t)) = -\int_0^t \lambda(u) du = -\Lambda(t)$$

$$S(t) = e^{-\Lambda(t)}$$

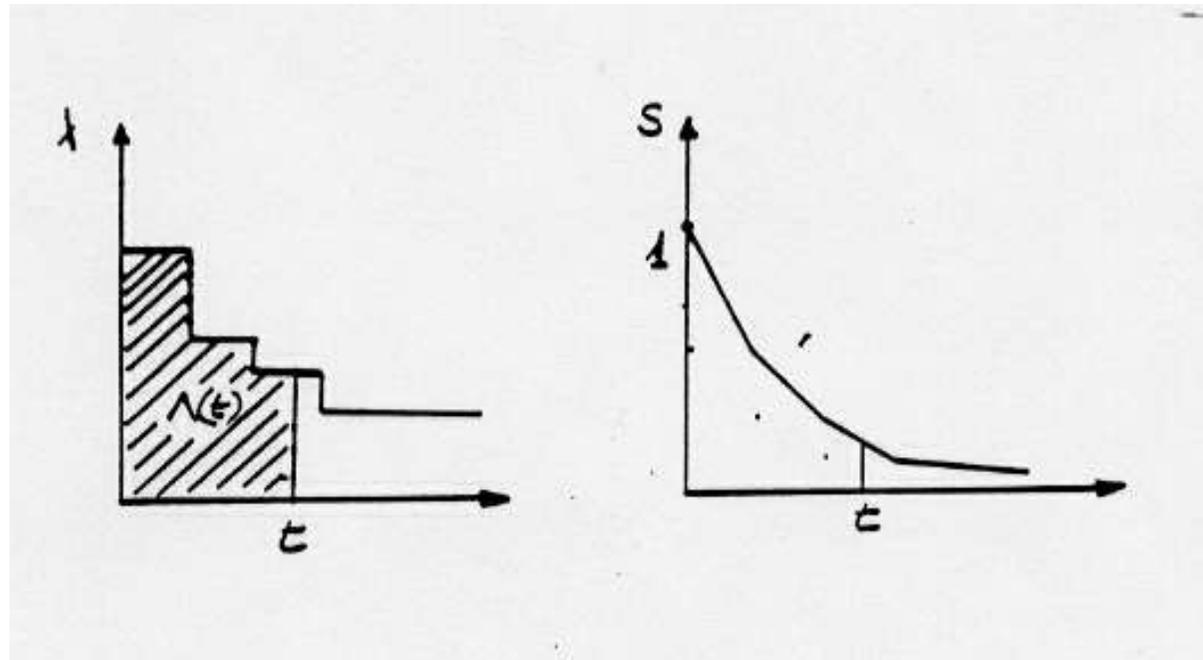
taux cumulé

lorsque  $\lambda(t)$  est constant ( $= \lambda$ ) la survie est dite  
**exponentielle:  $S(t) = e^{-\lambda t}$**

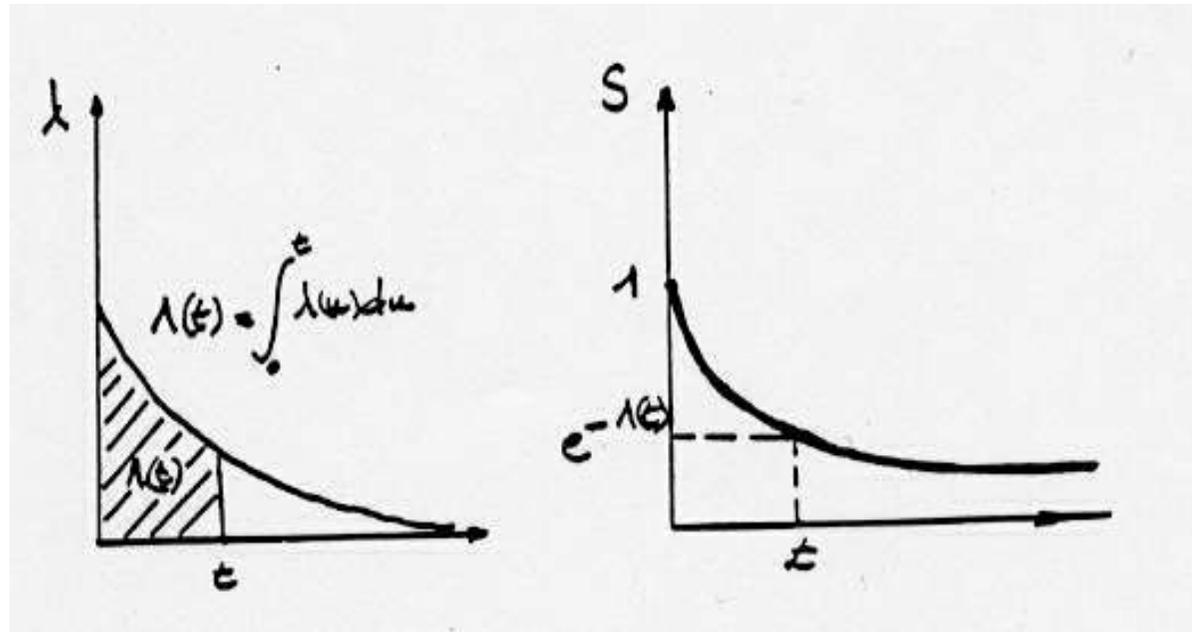
# 4. Survie exponentielle



# Survie exponentielle par intervalle



# Cas général



1. Introduction - Analyse de la survie
2. Méthode de Kaplan et Meier - Test du Log-Rank
3. Taux de Mortalité
4. Survie paramétrique / Survie exponentielle par intervalle
5. Modèle à Taux proportionnel

# Exemple 1: temps de survie en années

100 données complètes

1.22	1.86	1.35	3.81	0.47	1.63	2.47	0.42	0.24	0.45
2.83	5.17	18.14	4.92	0.30	2.87	9.21	1.32	2.09	3.48
1.58	5.16	2.43	0.05	3.00	0.24	4.01	0.34	1.59	7.39
0.42	1.08	0.63	0.56	1.79	0.63	2.60	0.11	1.43	3.97
1.22	7.18	3.66	0.10	2.29	3.40	4.13	2.78	4.82	4.87
5.81	1.25	4.08	6.81	6.02	0.15	1.66	3.60	0.18	0.12
2.72	15.56	0.72	1.35	0.72	8.68	1.96	1.97	4.75	0.62
2.94	2.27	4.53	10.22	1.03	1.84	4.81	1.66	0.34	1.78
0.55	0.25	3.00	0.25	0.48	8.74	0.64	6.41	14.59	1.93
0.10	4.08	11.82	1.78	1.51	1.96	0.41	1.12	1.28	0.60

moyenne: 2.994 ans      déviation standard: 3.363 ans

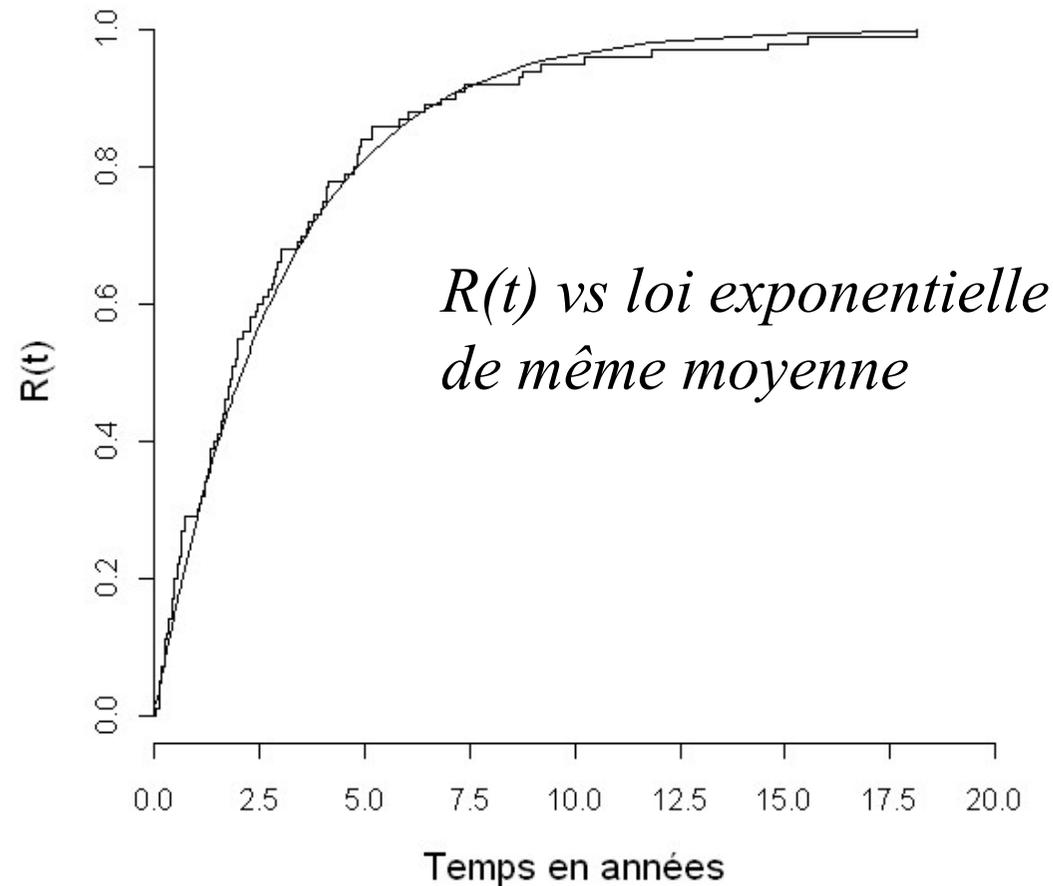
Les données sont ici parfaitement décrites par une distribution exponentielle ayant la même moyenne que les données du tableau 1. La distribution exponentielle de moyenne  $1/\lambda$  est le plus simple des modèles de survie paramétrique avec

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

$$R(t) = 1 - \exp(-\lambda t)$$

Le paramètre  $\lambda$  est le taux de mortalité, ou nombre de décès par unité de temps, estimé par  $n_0 / (\sum t_i)$ . Les données étant complètes, on a en effet observé  $n_0$  décès pour une durée totale d'observation de ces sujets égale à  $(\sum t_i)$ . Cette quantité s'exprime en personnes années d'observation : années d'observation accumulées par l'ensemble des personnes étudiées.

La fonction de répartition exponentielle qui s'ajuste le mieux aux données est la fonction  $1 - \exp(-1/2.994 \times t)$  où 2.994 est la moyenne des temps de survie des données.



# Modèles paramétriques I

- Définir  $\lambda(t)$  à l'aide d'une fonction connue aux paramètres près, par exemple:

Nom	Taux de mortalité	Survie
exponentielle	$\lambda$	$e^{-\lambda t}$
Weibull	$\gamma \lambda^\gamma t^{\gamma-1}$	$e^{-(\lambda t)^\gamma}$
Gompertz	...	....
Lognormal	...	....

# Modèle exponentiel

## Relation entre $R$ , $S$ et $\lambda$

$$S(t) = e^{-\lambda t}$$

$$R(t) = 1 - e^{-\lambda t}$$

$$R'(t) = \lambda e^{-\lambda t}$$

$$\lambda(t) = \frac{R'(t)}{1 - R(t)} = \lambda$$

$$\text{Log}(S(t)) = \text{Log}(1 - R(t)) = -\int_0^t \lambda \, du = -\lambda t = -\Lambda(t)$$

# Modèle de Weibull

## Relation entre $R$ , $S$ et $\lambda$

$$S(t) = e^{-(\lambda t)^\gamma}$$

$$R(t) = 1 - e^{-(\lambda t)^\gamma}$$

$$R'(t) = \gamma \lambda^\gamma t^{\gamma-1} e^{-(\lambda t)^\gamma}$$

$$\lambda(t) = \frac{R'(t)}{1 - R(t)} = \gamma \lambda^\gamma t^{\gamma-1}$$

$$\text{Log}(S(t)) = \text{Log}(1 - R(t)) = -\int_0^t \lambda(u) du = -(\lambda t)^\gamma = -\Lambda(t)$$

Modèle à 2 paramètres. Le modèle exponentiel correspond au cas où  $\gamma = 1$ . Si  $\gamma > 1$ , le taux est une fonction croissante du temps. Si  $\gamma < 1$ , le taux est une fonction décroissante du temps. Le taux instantané est une puissance du temps.

# Estimation par intervalle(I)

- On subdivise la durée de suivi en intervalles dans lesquels le taux de décès est supposé constant:

–  $t_0=0, t_1, t_2, \dots, t_I=fin\ du\ suivi$

- On compte le nombre de personnes  $n_{i-1}$  exposées au risque de décès en  $t_{i-1}$  pour chaque  $i$

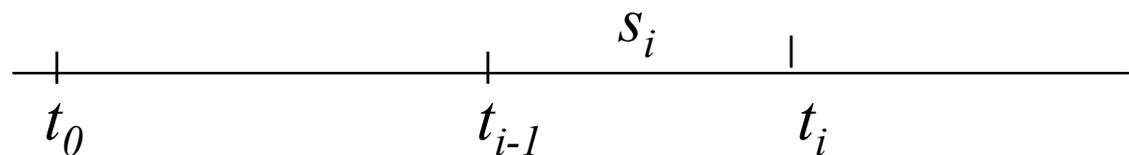
- .....

# Estimation par intervalle(II)

- On compte le nombre de *décès*  $d_i$  et de *sortis vivants*  $c_i$  dans l'intervalle  $[t_{i-1}, t_i[$
- On estime
  - *le taux de décès*  $\lambda_i$  dans chaque intervalle
  - la probabilité conditionnelle  $s_i = e^{-\lambda_i(t_i - t_{i-1})}$  de survivre en  $t_i$  si on était *vivant en*  $t_{i-1}$

# Estimation par intervalle(III)

$$S(t_{i-1}) \quad S(t_i) = S(t_{i-1}) * s_i$$



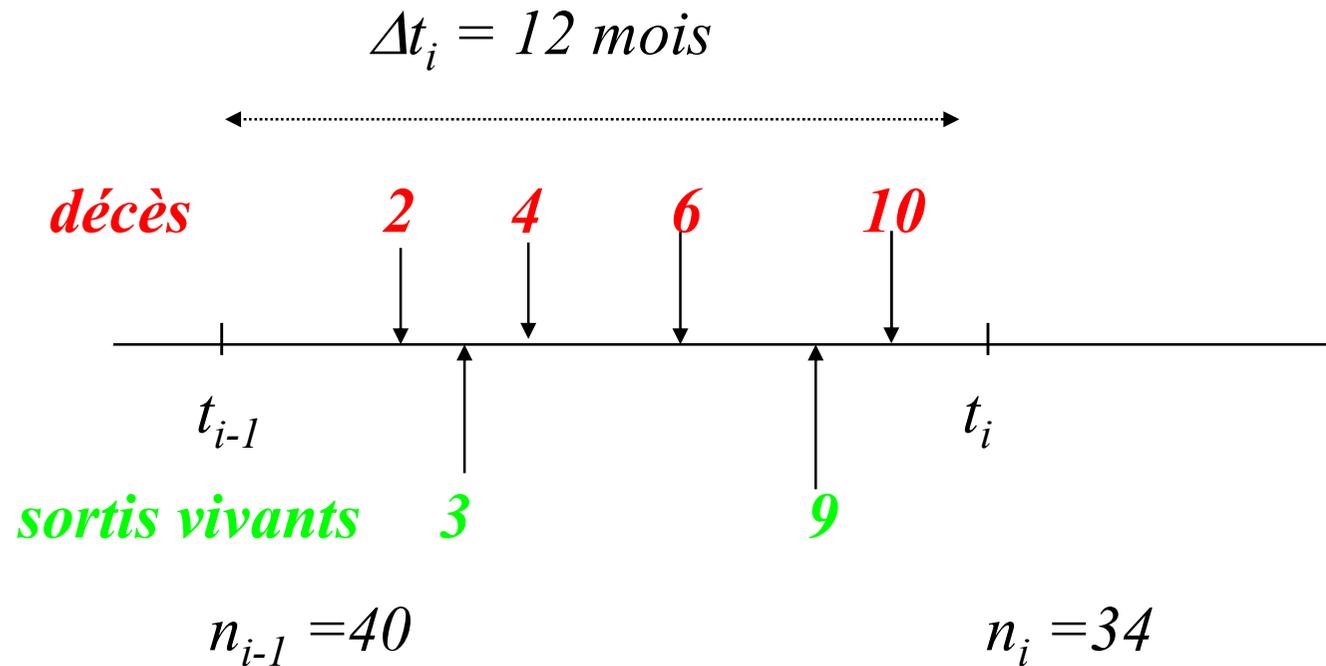
**Pour survivre en  $t_i$  ( $S(t_i)$ ) il faut**

- *survivre jusqu'en  $t_{i-1}$  ( $S(t_{i-1})$ )*
- *survivre dans l'intervalle  $[t_{i-1} t_i]$  ( $s_i$ )*

**La survie en  $t_i$  peut ainsi être calculée comme le produit de la survie dans des intervalles successifs....**

$$S(t_i) = s_1 * s_2 * \dots * s_i$$

# Estimation de $\lambda_i$ (Exemple)



$$\hat{\lambda}_i = \frac{4}{34 \times 12 + (2 + 3 + 4 + 6 + 9 + 10)} = \frac{4}{442} = 9.050 / 1000 \text{ p.m}$$

# 5. Modèles à taux proportionnels

- Dans le cas d'un facteur dichotomique le modèle s'écrit:
  - »  $\lambda_1(t) = \alpha \lambda_0(t)$  ;  $\alpha$  est appelé le **taux relatif** du groupe 1 par rapport au groupe 0
- L'idée du modèle à **taux de mortalité proportionnels** est implicite dans le test du « log-rank » qui évalue l'hypothèse “ $\alpha=1$  ?”
- Si on modélise linéairement le paramètre  $\lambda$  des distributions **exponentielles et de Weibull** on obtient des modèles à taux proportionnels
- Le **modèle de Cox** est un modèle à taux proportionnels dans lequel la forme analytique du taux n'est pas spécifiée.

# Modèles à taux proportionnels II

- Le modèle s'écrit  $\lambda(t, \mathbf{z}) = \lambda(t, 0) \exp(\beta \mathbf{z})$ , la fonction  $\lambda(t, 0)$  est le *taux de base (inconnu)*,  $\mathbf{z}$  un *vecteur de covariable (mesurée)*,  $\beta$  un *vecteur de paramètre (à estimer)*
- Le *taux cumulé* et la *survie* sont donc:

$$\Lambda(t, \mathbf{z}) = \Lambda(t, 0) \times e^{\beta \mathbf{z}}$$

$$S(t, \mathbf{z}) = e^{-\Lambda(t, \mathbf{z})} = S(t, 0)^{\exp(\beta \mathbf{z})}$$

# Modèles à taux proportionnels III

$$\text{Log}\left(\frac{\lambda(t, \mathbf{z})}{\lambda(t, \mathbf{0})}\right) = \sum_{i=1}^m \beta_i z_i = \beta \mathbf{z}$$

*Le log du taux relatif est une fonction linéaire des covariables*

$$\text{Log}\left(\frac{\lambda(t, z_1, \dots, z_i, \dots, z_m)}{\lambda(t, z_1, \dots, 0, \dots, z_m)}\right) = \beta_i z_i$$

$\alpha_i = e^{\beta_i}$  est le taux relatif des sujets pour lesquels  $z_i=1$  par rapport à ceux pour lesquels  $z_i=0$ , ‘*toutes choses égales par ailleurs*’

## Exemple 2:analyse avec le modèle de Cox

- Etudier le temps de remission *avec le nouveau traitement 6-MP*; comparer la distribution du temps de remission dans les deux groupes *'traitement standard (corticoïdes+placebo)* et *'nouveau traitement (corticoïdes et 6-MP)*
- le modèle est
  - $\lambda(t,z)=\lambda(t,0)\exp(\beta z)$ ;  $z=1$  pour le nouveau traitement, et  $z=0$  pour le traitement standard
  - $\alpha=\exp(\beta)$  est le *taux relatif* de rechute *dans le groupe 6-MP* comparé au groupe placebo
  - le taux de rechute dans le groupe traitement est  $\lambda(t,0)$

# Ajustement pour une variable de confusion

- Bien que l'étude soit randomisée la valeur de logwbc est différente pour les traités et les non traités. Il convient donc de prendre en compte cette variable dans l'évaluation de la différence.

- La méthode de regression réalise cela avec le modèle:

$$\lambda(t, \text{traitement}, \text{logwbc}) = \lambda(t, 0, 0) \exp(\beta * \text{traitement} + \gamma * \text{logwbc})$$

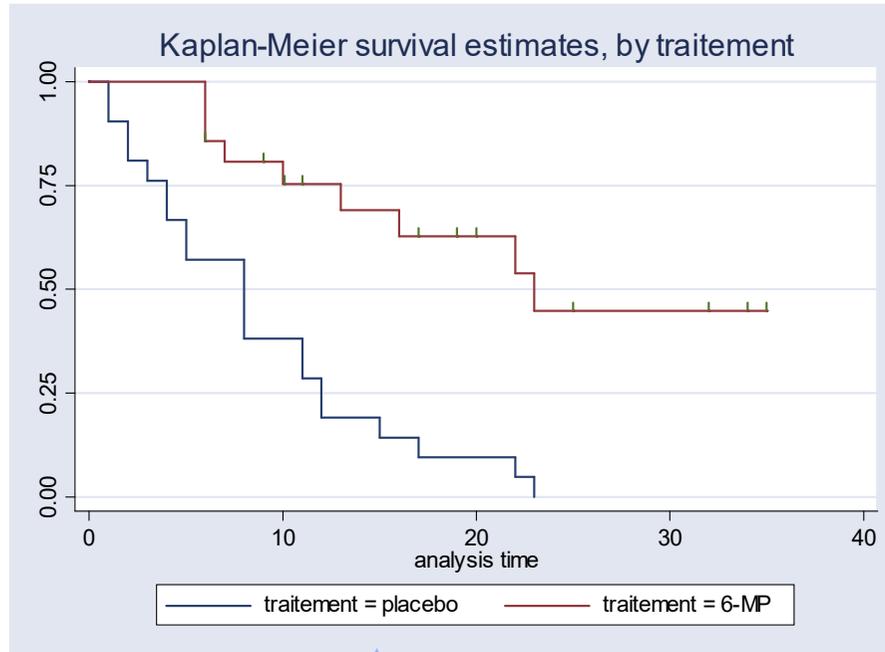
$\alpha = \exp(\beta)$  est alors le taux relatif des “traités” vs

“placebo” à wbc constant

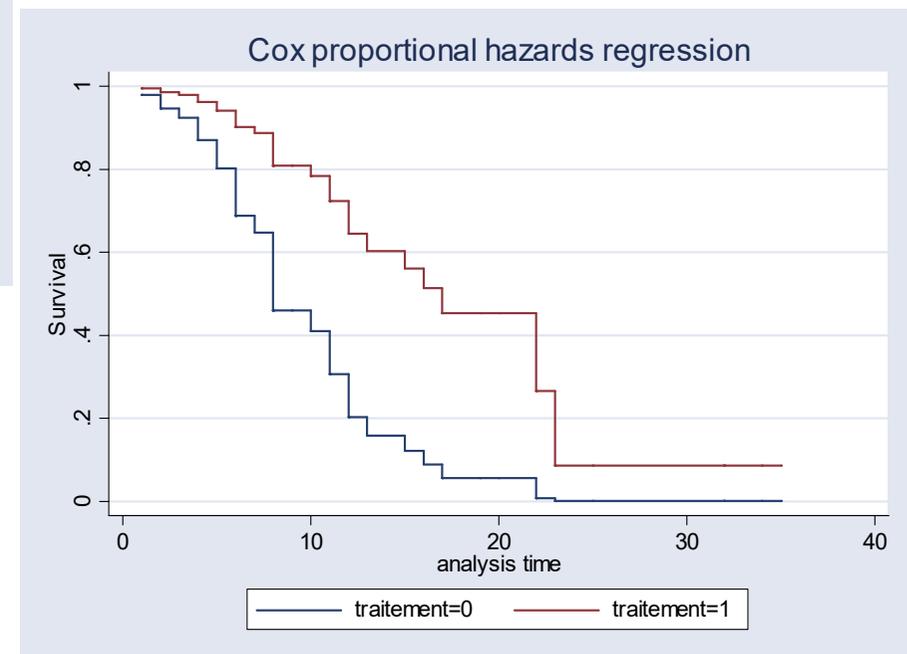
$$\beta = -1.2941$$

$$\exp(\beta) = 0.2742$$

# Survie ajustée



Comparaison ajustée  
Pour  $\text{Logwbc}=2.930$  (moyenne)



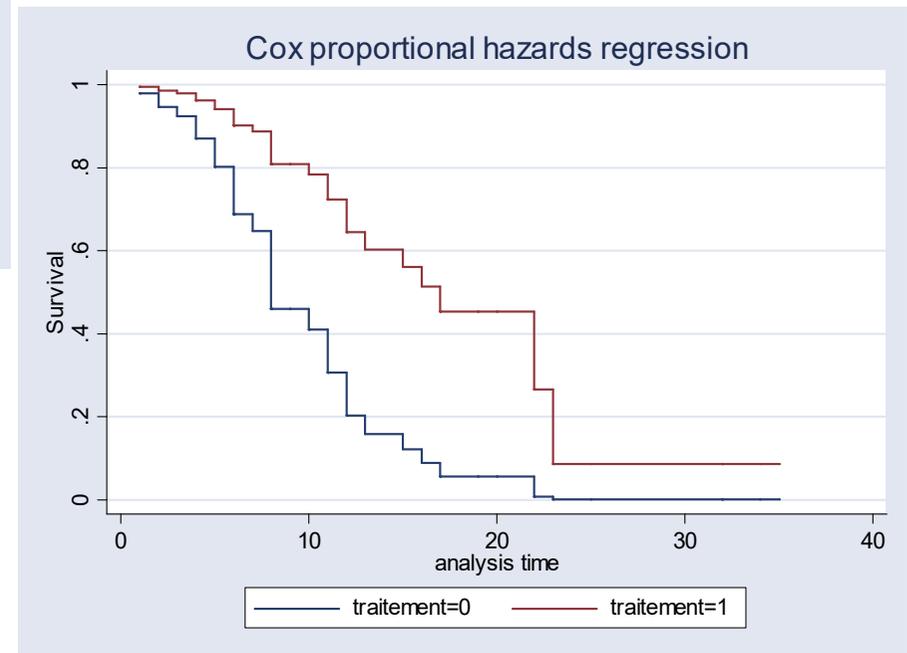
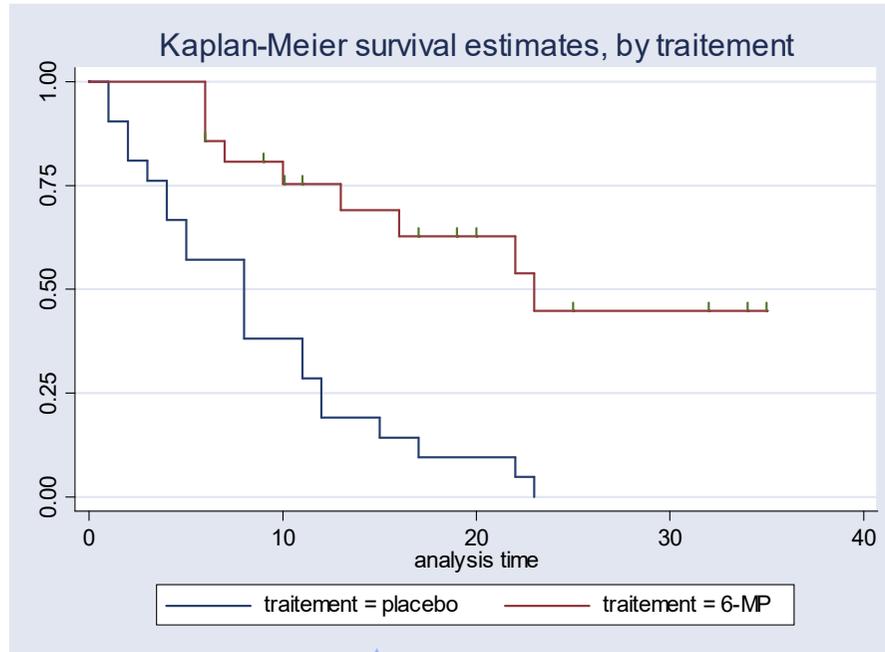
Comparaison KM, le groupe traité bénéficie de Wbc plus favorables

# Survie ajustée

$$0.80^{0.2742} = 0.94$$

$$0.40^{0.2742} = 0.78$$

$$0.20^{0.2742} = 0.64$$



Comparaison KM, le groupe traité bénéficie de Wbc plus favorables