

Modèles de durée

Théorie et applications

Etienne Dagorn

Université de Lille - LEM

Objectifs de la séance

À l'issue de cette séance, vous serez capables de :

- ⇒ caractériser et interpréter les principales lois paramétriques en analyse de durée (exponentielle, Weibull, log-logistique) ;
- ⇒ distinguer clairement les modèles *proportionnalité des hasards* et *temps accéléré*, et comprendre dans quels contextes chacun est pertinent ;
- ⇒ sélectionner une loi paramétrique plausible à partir de la forme observée de la fonction de hasard ;
- ⇒ situer les modèles paramétriques dans l'ensemble des outils d'analyse de durée, notamment par rapport à l'estimateur de Kaplan-Meier et au modèle semi-paramétrique de Cox.

Exemple fil rouge : durée de chômage

Contexte empirique :

- ⇒ Population : jeunes sortant d'études en 2020.
- ⇒ Variable d'intérêt : durée (en mois) avant l'accès au premier emploi stable.
- ⇒ Censure :
 - fin d'observation à 24 mois ;
 - certains individus sont encore au chômage à 24 mois.
- ⇒ Covariables :
 - diplôme, spécialité, sexe ;
 - participation à une formation, logement parental, etc.

Tout au long de la séance, imaginez que l'on cherche à modéliser **cette durée de chômage** avec différentes lois (Expo/Weibull/log-logistique) et différents cadres (PH/AFT).

Rappels

Motivation

Lois de base

Extensions

Panorama & extensions

Rappels :
Analyse non-paramétrique des durées

Cas pratique : comprendre les durées

Individu	Temps t_i	Événement ? (δ_i)
1	3	1
2	5	0 (censuré)
3	6	1
4	6	1
5	9	0 (censuré)
6	10	1

- ① Quels sont les **temps de défaillance uniques** $t_{(j)}$?
 - ② Quel est le **risk set** n_j juste avant chaque défaillance ?
 - ③ Quelle est la contribution de chaque individu à :
 - la **Kaplan–Meier** : $\hat{S}(t)$?
 - la **Nelson–Aalen** : $\hat{H}(t)$?
 - ④ Quelle serait l'**estimation du hasard instantané** entre 3 et 6 ?
 - ⑤ deux groupes (hommes/femmes) : que testerait le **log-rank** ?

Cas pratique : corrigé (1/2)

1. Temps de défaillance uniques :

$$t_{(1)} = 3, \quad t_{(2)} = 6, \quad t_{(3)} = 10.$$

2. Risk sets juste avant chaque événement :

$$n_1 = 6, \quad n_2 = 4 (\{3, 4, 5, 6\}), \quad n_3 = 1 (\{6\}).$$

3. Contributions KM et Nelson–Aalen

$t_{(j)}$	KM :	NA : $\Delta \hat{H}_j$
3	$1 - \frac{1}{6} = \frac{5}{6}$	$\frac{1}{6}$
6	$1 - \frac{2}{4} = \frac{1}{2}$	$\frac{2}{4} = \frac{1}{2}$
10	$1 - \frac{1}{1} = 0$	1

Cas pratique : corrigé (2/2)

4. Estimation du hasard instantané entre 3 et 6 :


$$\hat{h}(6) \approx \frac{d_2}{n_2} = \frac{2}{4} = 0.5.$$

5. Pour deux groupes (H/F), le test du log-rank évalue :

$$H_0 : S_H(t) = S_F(t) \quad \forall t \quad \Leftrightarrow \quad h_H(t) = h_F(t) \quad (\text{ratio de hasards} = 1).$$

Le test du log-rank compare, à chaque temps d'événement, les **défaillances observées** à celles **attendues sous H_0** .

Cas pratique : visualiser les durées et censures



Construction des **risk sets** et donc de $\hat{S}_{\text{KM}}(t)$ et $\hat{H}_{\text{NA}}(t)$.

Quiz : objets fondamentaux (1/6)

Question 1. Quelle(s) relation(s) est/sont toujours vraie(s) ?

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

b) $h(t) = \frac{f(t)}{S(t)}$

c) $S(t) = e^{-H(t)}$

d) $H(t) = \int_0^t f(u) du$

Quiz : objets fondamentaux (1/6)

Question 1. Quelle(s) relation(s) est/sont toujours vraie(s) ?

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

- Vrai pour toute variable de durée : définition générale de la fonction de survie.

b) $h(t) = \frac{f(t)}{S(t)}$

c) $S(t) = e^{-H(t)}$

d) $H(t) = \int_0^t f(u) du$

Quiz : objets fondamentaux (1/6)

Question 1. Quelle(s) relation(s) est/sont toujours vraie(s) ?

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

b) $h(t) = \frac{f(t)}{S(t)}$

- Vrai en temps continu : la densité $f(t)$ doit exister.
- Pour des durées discrètes, la définition du hazard est différente.

c) $S(t) = e^{-H(t)}$

d) $H(t) = \int_0^t f(u) du$

Quiz : objets fondamentaux (1/6)

Question 1. Quelle(s) relation(s) est/sont toujours vraie(s) ?

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

b) $h(t) = \frac{f(t)}{S(t)}$

c) $S(t) = e^{-H(t)}$

- Exact pour un hazard **continu** :

$$H(t) = \int_0^t h(u) du \Rightarrow S(t) = e^{-H(t)}.$$

- En temps discret (ou en présence de ties), c'est une approximation.

d) $H(t) = \int_0^t f(u) du$

Quiz : objets fondamentaux (1/6)

Question 1. Quelle(s) relation(s) est/sont toujours vraie(s) ?

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

b) $h(t) = \frac{f(t)}{S(t)}$

c) $S(t) = e^{-H(t)}$

d) $H(t) = \int_0^t f(u) du$

- Faux : le hasard cumulé est

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

avec $h(u) = f(u)/S(u)$ en continu.

Quiz : censure à droite (2/6)

Question 2. Laquelle de ces affirmations est correcte ?

- a) La censure réduit la taille de l'échantillon.
- b) Un individu censuré apporte l'information : $T > t$.
- c) La censure informative ne pose pas de problème pour KM.
- d) La censure doit être indépendante du temps propre.

Quiz : censure à droite (2/6)

Question 2. Laquelle de ces affirmations est correcte ?

- a) La censure réduit la taille de l'échantillon.
 - Faux : un individu censuré est **conservé** dans l'analyse ; il quitte seulement le risk set après son temps de censure.
- b) Un individu censuré apporte l'information : $T > t$.
- c) La censure informative ne pose pas de problème pour KM.
- d) La censure doit être indépendante du temps propre.

Quiz : censure à droite (2/6)

Question 2. Laquelle de ces affirmations est correcte ?

- a) La censure réduit la taille de l'échantillon.
- b) Un individu censuré apporte l'information : $T > t$.
 - Vrai : la censure fournit une **borne inférieure** sur la durée réelle.
- c) La censure informative ne pose pas de problème pour KM.
- d) La censure doit être indépendante du temps propre.

Quiz : censure à droite (2/6)

Question 2. Laquelle de ces affirmations est correcte ?

- a) La censure réduit la taille de l'échantillon.
- b) Un individu censuré apporte l'information : $T > t$.
- c) La censure informative ne pose pas de problème pour KM.
 - Faux : la censure **informative** viole l'hypothèse clé de KM/NA et entraîne un **biais systématique**.
- d) La censure doit être indépendante du temps propre.

Quiz : censure à droite (2/6)

Question 2. Laquelle de ces affirmations est correcte ?

- a) La censure réduit la taille de l'échantillon.
- b) Un individu censuré apporte l'information : $T > t$.
- c) La censure informative ne pose pas de problème pour KM.
- d) La censure doit être indépendante du temps propre.
 - Correct, mais incomplet : la condition générale est

$$T \perp C \mid X,$$

c'est-à-dire indépendance conditionnelle vis-à-vis des covariables.

Condition indispensable : censure **non-informative**, sinon les estimateurs KM/NA sont biaisés.

Quiz : risk sets (3/6)

Question 3. Le risk set n_j à l'instant $t_{(j)}$ contient :

- a) seulement les individus défaillants à $t_{(j)}$;
 - b) les individus “en vie” juste avant $t_{(j)}$;
 - c) les individus censurés **après** $t_{(j)}$;
 - d) les individus censurés **avant** $t_{(j)}$;

Quiz : risk sets (3/6)

Question 3. Le risk set n_j à l'instant $t_{(j)}$ contient :

- a) seulement les individus défaillants à $t_{(j)}$;
 - Faux : le risk set contient **tous les individus encore à risque juste avant** $t_{(j)}$, pas seulement ceux qui vont défaillir.
- b) les individus “en vie” juste avant $t_{(j)}$;
- c) les individus censurés **après** $t_{(j)}$;
- d) les individus censurés **avant** $t_{(j)}$;

Quiz : risk sets (3/6)

Question 3. Le risk set n_j à l'instant $t_{(j)}$ contient :

- a) seulement les individus défaillants à $t_{(j)}$;
 - b) les individus “en vie” juste avant $t_{(j)}$;
 - Vrai : un individu est dans n_j s'il n'a ni été censuré ni eu d'événement avant $t_{(j)}$.
 - c) les individus censurés **après** $t_{(j)}$;
 - d) les individus censurés **avant** $t_{(j)}$;

Quiz : risk sets (3/6)

Question 3. Le risk set n_j à l'instant $t_{(j)}$ contient :

- a) seulement les individus défaillants à $t_{(j)}$;
- b) les individus “en vie” juste avant $t_{(j)}$;
- c) les individus censurés **après** $t_{(j)}$;
 - Vrai : un individu censuré plus tard est encore à risque à $t_{(j)}$, donc bien dans le risk set.
- d) les individus censurés **avant** $t_{(j)}$;

Quiz : risk sets (3/6)

Question 3. Le risk set n_j à l'instant $t_{(j)}$ contient :

- a) seulement les individus défaillants à $t_{(j)}$;
 - b) les individus “en vie” juste avant $t_{(j)}$;
 - c) les individus censurés **après** $t_{(j)}$;
 - d) les individus censurés **avant** $t_{(j)}$;
 - Faux : s’ils ont été censurés avant, ils ont quitté le risk set et ne contribuent plus à n_j .

Quiz : Kaplan–Meier (4/6)

Que représente $\hat{S}(t)$ (estimateur de Kaplan–Meier) ?

- a) $\Pr(T > t \mid T > 0)$
 - b) $\Pr(T > t)$
 - c) La proportion d'individus encore suivis en fin de période.
 - d) Une probabilité ajustée des covariables.

Quiz : Kaplan–Meier (4/6)

Que représente $\hat{S}(t)$ (estimateur de Kaplan–Meier) ?

a) $\Pr(T > t \mid T > 0)$

- Vrai : c'est l'interprétation correcte.
- $T > 0$ est une condition triviale (aucun individu n'a encore échoué à $t = 0$).

b) $\Pr(T > t)$

c) La proportion d'individus encore suivis en fin de période.

d) Une probabilité ajustée des covariables.

Quiz : Kaplan–Meier (4/6)

Que représente $\hat{S}(t)$ (estimateur de Kaplan–Meier) ?

- a) $\Pr(T > t \mid T > 0)$
 - b) $\Pr(T > t)$
 - Presque vrai : équivalent car $\Pr(T > 0) = 1$.
 - Mais l'écriture conditionnelle est la forme rigoureuse.
 - c) La proportion d'individus encore suivis en fin de période.
 - d) Une probabilité ajustée des covariables.

Quiz : Kaplan–Meier (4/6)

Que représente $\hat{S}(t)$ (estimateur de Kaplan–Meier) ?

- a) $\Pr(T > t \mid T > 0)$
 - b) $\Pr(T > t)$
 - c) La proportion d'individus encore suivis en fin de période.
 - Faux : ce serait un simple ratio $\frac{\text{non-événements}}{\text{effectif}}$.
 - Kaplan-Meier **pondère** chaque intervalle par les tailles de risk sets et **corrige des censures** - ce n'est pas un comptage brut.
 - d) Une probabilité ajustée des covariables.

Quiz : Kaplan–Meier (4/6)

Que représente $\hat{S}(t)$ (estimateur de Kaplan–Meier) ?

- a) $\Pr(T > t \mid T > 0)$
 - b) $\Pr(T > t)$
 - c) La proportion d'individus encore suivis en fin de période.
 - d) Une probabilité ajustée des covariables.
 - Faux : KM est un estimateur **non-paramétrique sans covariable**.
 - Les covariables n'apparaissent que dans les modèles de Cox, AFT, etc.

Quiz : KM vs Nelson–Aalen (5/6)

Quel est le lien entre Nelson–Aalen et Kaplan–Meier ?

- a) NA estime la fonction de survie.
- b) NA estime le hazard cumulé.
- c) $\hat{S}(t) \approx e^{-\hat{H}(t)}$.
- d) NA = KM exactement.

Quiz : KM vs Nelson–Aalen (5/6)

Quel est le lien entre Nelson–Aalen et Kaplan–Meier ?

a) NA estime la fonction de survie.

- Faux : l'estimateur de Nelson–Aalen calcule le **hasard cumulé** :
$$\hat{H}(t) = \sum_{t_j \leq t} d_j / n_j.$$
- La survie n'est obtenue qu'indirectement, via une transformation.

b) NA estime le hazard cumulé.

c) $\hat{S}(t) \approx e^{-\hat{H}(t)}$.

d) NA = KM exactement.

Quiz : KM vs Nelson–Aalen (5/6)

Quel est le lien entre Nelson–Aalen et Kaplan–Meier ?

- a) NA estime la fonction de survie.
- b) NA estime le hazard cumulé.
 - Vrai : c'est précisément sa définition.
 - La survie correspond ensuite à l'idée : "ne pas avoir subi d'événement jusqu'à t " $\Rightarrow S(t) \approx e^{-\hat{H}(t)}$.
- c) $\hat{S}(t) \approx e^{-\hat{H}(t)}$.
- d) NA = KM exactement.

Quiz : KM vs Nelson–Aalen (5/6)

Quel est le lien entre Nelson–Aalen et Kaplan–Meier ?

a) NA estime la fonction de survie.

b) NA estime le hazard cumulé.

c) $\hat{S}(t) \approx e^{-\hat{H}(t)}$.

- Vrai : en **temps continu**, la relation $S(t) = e^{-H(t)}$ est exacte.
- En temps discret, \hat{S}_{KM} et $e^{-\hat{H}}$ diffèrent légèrement car KM applique une **multiplication de risques conditionnels**.

d) NA = KM exactement.

Quiz : KM vs Nelson–Aalen (5/6)

Quel est le lien entre Nelson–Aalen et Kaplan–Meier ?

- a) NA estime la fonction de survie.
- b) NA estime le hazard cumulé.
- c) $\hat{S}(t) \approx e^{-\hat{H}(t)}$.
- d) NA = KM exactement.
 - Faux : KM utilise les probabilités conditionnelles $(1 - d_j/n_j)$, alors que NA additionne les taux d_j/n_j .
 - Les deux estimateurs sont proches aux temps précoce mais peuvent diverger en **queue de distribution**.

Quiz : log-rank (6/6)

Le test du log-rank est le plus puissant lorsque :

- a) les risques sont proportionnels ;
- b) les courbes s'entrecroisent ;
- c) il y a beaucoup de censures ;
- d) le hasard dépend fortement du temps.

Quiz : log-rank (6/6)

Le test du log-rank est le plus puissant lorsque :

a) les risques sont proportionnels ;

- Vrai : le log-rank est optimal lorsque

$$h_1(t) = c h_2(t), \quad c > 0 \text{ constant (hazards proportionnels, } c = 1 \text{ sous } H_0\text{)}$$

Il détecte surtout un **décalage global** entre les deux hazards.

b) les courbes s'entrecroisent ;

c) il y a beaucoup de censures ;

d) le hasard dépend fortement du temps.

Quiz : log-rank (6/6)

Le test du log-rank est le plus puissant lorsque :

a) les risques sont proportionnels ;

- Vrai : le log-rank est optimal lorsque

$$h_1(t) = c h_2(t), \quad c > 0 \text{ constant (hazards proportionnels, } c = 1 \text{ sous } H_0\text{)}$$

Il détecte surtout un **décalage global** entre les deux hazards.

b) les courbes s'entrecroisent ;

- Faux : les croisements violent la proportionnalité → le test perd **fortement** en puissance.

c) il y a beaucoup de censures ;

d) le hasard dépend fortement du temps.

Quiz : log-rank (6/6)

Le test du log-rank est le plus puissant lorsque :

a) les risques sont proportionnels ;

- Vrai : le log-rank est optimal lorsque

$$h_1(t) = c h_2(t), \quad c > 0 \text{ constant (hazards proportionnels, } c = 1 \text{ sous } H_0\text{)}$$

Il détecte surtout un **décalage global** entre les deux hazards.

b) les courbes s'entrecroisent ;

- Faux : les croisements violent la proportionnalité → le test perd **fortement** en puissance.

c) il y a beaucoup de censures ;

- Faux : un volume important de censures réduit l'information et dégrade la puissance de tout test de survie, log-rank inclus.

d) le hasard dépend fortement du temps.

Quiz : log-rank (6/6)

Le test du log-rank est le plus puissant lorsque :

- a) les risques sont proportionnels;

- Vrai : le log-rank est optimal lorsque

$h_1(t) = c h_2(t)$, $c > 0$ constant (hazards proportionnels, $c = 1$ sous H_0)

Il détecte surtout un **décalage global** entre les deux hazards.

- b) les courbes s'entrecroisent ;

- Faux : les croisements violent la proportionnalité → le test perd **fortement** en puissance.

- c) il y a beaucoup de censures;

- Faux : un volume important de censures réduit l'information et dégrade la puissance de tout test de survie, log-rank inclus.

- d) le hasard dépend fortement du temps.

- Faux : le log-rank ne cible pas la forme de $h(t)$, mais les **différences persistantes** entre deux hazards.

Rappels : objets de base & censure

⇒ Durée étudiée : temps jusqu'à un événement

$$T = t_{\text{fin}} - t_0, \quad \delta = \mathbb{1}\{\text{événement observé}\}.$$

- ⇒ **Censure à droite** : on sait seulement que $T > t$ (événement non observé pendant la fenêtre).
 - ⇒ **Troncature / entrée retardée** : inclusion conditionnelle (« on n'entre dans l'échantillon que si $T > t_{\text{entrée}}$ »).
 - ⇒ **Hypothèse clé** : censure **non-informative** (conditionnellement aux covariables).

5 objets fondamentaux : $F(t)$, $S(t)$, $f(t)$, $h(t)$, $H(t)$ avec les ponts

$$S(t) = 1 - F(t), \quad H(t) = \int_0^t h(u) du, \quad S(t) = e^{-H(t)}.$$

Rappels : Kaplan–Meier & Nelson–Aalen

- $\Rightarrow t_{(1)} < \dots < t_{(J)}$: instants où au moins une défaillance survient.
 - $\Rightarrow d_j$: nb de défaillances à $t_{(j)}$; n_j : nb à risque juste avant $t_{(j)}$.

Kaplan–Meier (survie)

$$\hat{S}(t) = \prod_{t_{(j)} \leq t} \left(1 - \frac{d_j}{n_j}\right)$$

- ⇒ Fonction en **marches** : chute seulement aux **événements**.
 - ⇒ Censures : pas de chute mais réduisent les risk sets.

Nelson–Aalen (hasard cumulé)

$$\hat{H}(t) = \sum_{t_{(j)} \leq t} \frac{d_j}{n_j}, \quad \hat{S}(t) \approx e^{-\hat{H}(t)}.$$

KM : « combien restent ? » / NA : « à quelle vitesse sortent-ils ? »

Rappels : variance (Greenwood) & Breslow

Kaplan–Meier : produit de facteurs $1 - \frac{d_j}{n_j} \Rightarrow$ variance plus complexe.

Variance de Greenwood

$$\widehat{\text{Var}}(\hat{S}(t)) = \hat{S}^2(t) \sum_{t_{(j)} \leq t} \frac{d_j}{n_j(n_j - d_j)}$$

- ⇒ Chaque défaillance ajoute de l'incertitude (terme en d_j).
 - ⇒ Quand n_j diminue ⇒ la variance augmente fortement en fin de suivi.

Estimateur de Breslow pour le risque cumulé

$$\hat{\Lambda}(t) = \sum_{t(j) \leq t} \frac{d_j}{n_j}, \quad \widehat{\text{Var}}(\hat{\Lambda}(t)) = \sum_{t(j) \leq t} \frac{d_j}{n_j^2}.$$

Travailler sur $\hat{\Lambda}(t)$ (Breslow) est plus simple analytiquement, mais $\hat{S}(t)$ est plus intuitif à commenter.

Rappels : comparaison de courbes (log-rank)

Objectif : tester l'égalité de deux fonctions de survie

$$H_0 : S_1(t) = S_2(t) \quad \forall t.$$

Principe du log-rank

- ⇒ À chaque temps de défaillance t_j :
 - on observe d_{1j}, d_{2j} dans chaque groupe,
 - on compare à ce qu'on attendrait si les risques étaient identiques.
- ⇒ On cumule ces écarts dans une statistique χ^2 globale (approx. loi $\chi^2(1)$).

À retenir : test **global**, le plus puissant sous risques proportionnels, à compléter par la **visualisation** des courbes de Kaplan–Meier.

Rappels

Motivation

Lois de base

Extensions

Panorama & extensions

Rappel : ce que nous savons déjà

Objectifs de la séance précédente : KM, NA, censure, risk set, log-rank, hasard instantané.

5 objets fondamentaux :

$$F(t), \quad S(t) = \Pr(T > t), \quad f(t), \quad h(t) = \frac{f(t)}{S(t)}, \quad H(t) = \int_0^t h(u) du$$

$$S(t) = e^{-H(t)} \quad (\text{relation clé des modèles paramétriques})$$

- ⇒ Méthodes **non-paramétriques** : ne supposent rien sur la forme de la loi (KM/NA).
- ⇒ Limites : pas d'extrapolation, pas d'interprétation paramétrique, efficacité moindre.

Motivation : besoin d'un modèle structurel

Motivation : besoin d'un modèle structurel

En pratique, les décideurs veulent :

- ⇒ des **prédictions** : durée attendue au chômage, temps médian avant défaut ;
- ⇒ des **effets de politiques** : impact d'un traitement/formation/contrat ;
- ⇒ des **comparaisons robustes** entre groupes ;
- ⇒ une **interprétation économique** (vieillissement, sélection, décrochage, épuisement des opportunités...).

Modèles paramétriques = formaliser une hypothèse sur le cycle du risque :

$h(t)$ croît ? décroît ? reste constant ? change de signe ?

Approche : on encode des mécanismes plausibles dans la forme de $h(t)$, puis on l'estime statistiquement.

Conséquence : un modèle paramétrique est une *théorie* sur la dynamique des durées.

Pourquoi des modèles paramétriques ?

Idée clé

Imposer une loi sur les durées permet d'obtenir des estimateurs plus efficaces et interprétables.

Avantages :

- ⇒ Estimation directe de la **moyenne**, de la **médiane**, des **quantiles**.
- ⇒ Possibilité de **prédirer** au-delà de la fenêtre d'observation (*extrapolation*).
- ⇒ Effets des covariables via modèles **PH** ou **AFT**.
- ⇒ Lien clair entre forme du hasard et structure du modèle.

Inconvénients :

- ⇒ Risque de **mauvaise spécification** (shape du hasard incorrecte).
- ⇒ Diagnostics cruciaux : comparaison à KM, log(-log), résidus.

Limites pratiques des méthodes non-paramétriques

1. Impossibilité de synthétiser la durée par un paramètre simple

- ⇒ KM donne une **courbe**, pas une moyenne ni un modèle.
- ⇒ Impossible d'écrire des quantités comme sans lois :

$$\mathbb{E}[T], \quad \text{Var}(T), \quad m_{0.5}, \quad \Pr(T > t^*)$$

2. Comparaison de groupes limitée


- ⇒ Log-rank = test global mais **pas d'effet marginal interprétable**.
- ⇒ Pas de mesure du traitement : pas de **hazard ratio**, pas de **time ratio**.

3. Pas d'extrapolation

- ⇒ KM s'arrête au dernier événement observé.
- ⇒ impossible d'évaluer : $S(60 \text{ mois})$ si la fenêtre s'arrête à 36 mois.

Conclusion : KM/NA décrivent bien les données, mais n'expliquent ni ne prédisent.

Trois histoires différentes pour une même KM



Une même KM, trois histoires différentes

⇒ La **même** courbe de Kaplan–Meier peut être très bien ajustée par :

- une **exponentielle** ⇒ hasard **constant** (arrivées purement aléatoires, pas de durée-dépendance) ;
- une **Weibull croissante** ⇒ hasard **croissant** (vieillissement, usure, découragement progressif) ;
- une **log-logistique** ⇒ hasard **en cloche** (phase d'entrée, puis accélération des sorties, puis saturation).

⇒ Même qualité d'ajustement sur $S(t)$, mais :

- formes de $h(t)$ **radicalement différentes** ;
- donc **histoires économiques différentes** derrière les données.

Moralité : une bonne KM ne suffit pas. Il faut regarder la forme de $h(t)$ et choisir un modèle cohérent avec le mécanisme.

Le rôle central du *hasard* dans la modélisation

Dans un modèle paramétrique, tout part de $h(t)$:

$$h(t) \xrightarrow{\text{ intégration }} H(t) \xrightarrow{S(t)=e^{-H(t)}} S(t) \xrightarrow{f(t)=h(t)S(t)} f(t)$$

Pourquoi choisir $h(t)$?

- ⇒ C'est le **rythme instantané du phénomène**.
- ⇒ Il révèle la mécanique du système :
 - **Croissant** : usure, apprentissage, accumulation de risques.
 - **Décroissant** : sélection des robustes.
 - **En cloche** : phases d'entrée puis de sortie accélérée.

Modéliser un phénomène de durée = modéliser son risque.

Pourquoi plusieurs lois ?



Chaque loi impose une géométrie spécifique au risque :

Loi	Forme de $h(t)$	Interprétation
Exponentielle	constante	Poisson/arrivées indépendantes
Weibull ($k > 1$)	croissant	vieillissement / usure
Weibull ($k < 1$)	décroissant	sélection des survivants
Log-logistique	en cloche	diffusion / contagion / cycles
Log-normale	en cloche	forte hétérogénéité
Gompertz	expo. croissant	mortalité / risques accumulés


Choisir un modèle paramétrique = choisir un mécanisme économique ou biologique.

Forme du hasard

Expo

Weibull $k > 1$ 

Log-logistique



Expo : risque constant. **Weibull** : risque monotone (croissant ou décroissant). **Log-logistique** : risque en cloche (entrée, pic, saturation).

Rappels

Motivation

Lois de base

Extensions

Panorama & extensions

Exponentielle : hasard constant (1/2)

Hypothèse structurelle (définition) :

$$h(t) = \lambda \quad (\lambda > 0)$$

- ⇒ Le risque instantané est **constant dans le temps**.
 - ⇒ Aucune durée-dépendance : ni usure, ni apprentissage, ni sélection.

Objets associés :

$$H(t) = \lambda t, \quad S(t) = e^{-\lambda t}, \quad f(t) = \lambda e^{-\lambda t}.$$

Propriété fondamentale : absence de mémoire

$$\Pr(T > t + s \mid T > s) = \Pr(T > t)$$

Le fait d'avoir “déjà attendu” ne change rien : le processus “redémarre” à chaque instant.

Conséquence intuitive : le passé n'influence jamais le risque futur (défaillance, sortie, embauche...).

Exponentielle : usages et limites (2/2)

Quantités fermées :

$$\mathbb{E}[T] = \frac{1}{\lambda}, \quad m_{0.5} = \frac{\ln 2}{\lambda}$$

Applications typiques :


- ⇒ files d'attente (M/M/1),
- ⇒ pannes simples / fiabilité,
- ⇒ arrivées indépendantes (Poisson).

Limites :

- ⇒ très peu réaliste pour les comportements humains ;
- ⇒ ne capture ni apprentissage, ni usure, ni sélection ;
- ⇒ risque constant = hypothèse très forte.

Exponentielle : densité, survie, hasard

Loi exponentielle : densité, survie et hasard



Weibull : hasard monotone (1/4)

Hasard :

$$h(t) = \lambda k t^{k-1}$$

Objets associés :

$$H(t) = \lambda t^k, \quad S(t) = e^{-\lambda t^k}.$$


Interprétation du paramètre de forme k

- ⇒ $k < 1$: hasard **décroissant** → sélection des robustes, apprentissage.
- ⇒ $k = 1$: hasard **constant** → cas particulier **exponentiel**.
- ⇒ $k > 1$: hasard **croissant** → usure, vieillissement, découragement.

Atout majeur : première loi simple offrant une **durée-dépendance flexible** (décroissante, constante, ou croissante).

Weibull : intuition sur la forme du hasard (2/4)


$k < 1$



$k = 1$



$k > 1$



Weibull = la loi qui permet de passer d'un risque décroissant → constant → croissant.

Weibull : comment sont estimés λ et k ? (3/4)

Objectif : trouver les valeurs de (λ, k) où le modèle est *compatible* avec les observations.

Principe : maximum de vraisemblance

- ⇒ chaque individu contribue par : – la **densité** s'il a eu l'événement ;
– la **survie** s'il est censuré ;
- ⇒ on choisit (λ, k) qui maximisent la vraisemblance globale.

Aspects pratiques :

- ⇒ pas de formule explicite : estimation par **optimisation numérique** ;

Interprétation :

- ⇒ \hat{k} décrit la **forme du risque** (croissant, constant, décroissant) ;
- ⇒ $\hat{\lambda}$ fixe l'**échelle temporelle**.

Weibull : usages et propriétés (4/4)

Applications :

- ⇒ durée de chômage (découragement/usure) ;
- ⇒ fiabilité matériel ;
- ⇒ survie médicale ;

Atouts :


- ⇒ très souple, estimation simple sous censure ;
- ⇒ compatible **PH** ou **AFT**.

Limites :

- ⇒ ne capture pas les hasards en cloche ;
- ⇒ pas adapté aux phénomènes en cycles.

Weibull : densité, survie, hasard

Loi de Weibull : densité, survie et hasard



Log-logistique : hasard en cloche (1/2)

Formes associées (idée générale) :

$$S(t) = \frac{1}{1 + (t/\lambda)^k}, \quad h(t) = \frac{k}{\lambda} \frac{(t/\lambda)^{k-1}}{1 + (t/\lambda)^k}.$$

Propriété fondamentale : hasard non monotone

augmente \rightarrow atteint un pic \rightarrow diminue.

Le risque est faible au début, croît fortement, puis ralentit.

Interprétations typiques :

- ⇒ phénomènes avec phases successives : entrée \rightarrow diffusion \rightarrow saturation ;
- ⇒ processus sociaux avec “effet de mode” ou contagion ;
- ⇒ hétérogénéité forte dans la population.

Log-logistique : propriétés et usages (2/2)

Caractéristiques simples :

- ⇒ Médiane : $m_{0.5} = \lambda$ (interprétation directe) ;
- ⇒ Espérance finie uniquement si $k > 1$.


Signature du modèle :

- ⇒ capture très bien les **hasards en cloche** ;
- ⇒ structure **AFT naturelle** (pas de modèle PH possible) ;
- ⇒ queues lourdes : attention aux moments (moyenne parfois infinie).

Applications classiques :

- ⇒ diffusion d'innovations ou d'idées ;
- ⇒ processus sociaux avec phases d'adoption puis stabilisation ;
- ⇒ dynamiques où l'hétérogénéité joue un rôle majeur.


Log-logistique : forme du hasard



Lecture : au début, peu de sorties (risque faible) → le risque augmente jusqu'à un **pic** → puis diminue (saturation, épuisement du potentiel).

log-logistic : densité, survie, hasard


Loi log-logistique : densité, survie et hasard



Risques proportionnels : intuition

Idée intuitive : Dans certains contextes, deux groupes peuvent avoir des profils de risque qui gardent **la même forme au cours du temps**. Seul le "niveau" du risque change.

Exemple visuel : deux courbes en parallèle



Même forme → une simple différence de niveau.

Signification : - le groupe A a toujours un risque plus élevé que B ; - **mais la différence reste stable dans le temps** ; - les deux groupes évoluent de manière "parallèle".

Cette situation apparaît dans certains modèles, mais pas tous.

Log-logistique : pourquoi les risques ne restent jamais parallèles ?

Rappel : la loi log-logistique produit un **hasard en cloche** :

faible au début → augmente → puis diminue.

Conséquence immédiate : Deux groupes log-logistiques ne peuvent pas avoir des courbes de risque gardant la **même forme** dans le temps.

Même si les groupes diffèrent seulement par un changement d'échelle (λ_1 vs λ_2) :

- ⇒ leurs courbes montent,
- ⇒ atteignent leur pic à des moments différents,
- ⇒ puis redescendent à des vitesses différentes.

Conclusion intuitive : Avec une loi log-logistique, les **formes de risque changent dans le temps**. Deux groupes ne peuvent donc **jamais évoluer en parallèle**. Le rapport de leurs risques **ne reste pas constant**.

Applications typiques des lois paramétriques

Quel modèle pour quel phénomène ?

Chaque loi encode une **géométrie du hasard** → **mécanismes** différents

⇒ Exponentielle (hasard constant)

- pannes électroniques sans usure (“memoryless failures”);
- phénomènes sans durée-dépendance : *risque constant dans le temps.*

⇒ Weibull (hasard croissant ou décroissant)

- $k > 1$ (croissant) : mortalité adulte, fatigue de matériaux, usure, découragement en chômage ;
- $k < 1$ (décroissant) : sélection des robustes, guérison progressive, apprentissage ;

⇒ Log-logistique (hasard en cloche)

- diffusion d'innovations (phases d'adoption puis saturation) ;
- délais de décision avec forte hétérogénéité.

Exemples : quelle loi pour quel phénomène ?

Exemple 1 : durée de chômage des jeunes diplômés

- ⇒ Forte sortie au début (les plus employables), puis ralentissement.
- ⇒ **Hypothèse plausible :** Weibull avec $k < 1$ (sélection des plus robustes)

Exemple 2 : adoption d'une nouvelle technologie

- ⇒ Début lent, puis accélération, puis saturation.
- ⇒ **Hypothèse plausible :** log-logistique (hasard en cloche).

Exemple 3 : panne d'un composant électronique simple

- ⇒ Pannes indépendantes du temps d'utilisation.
- ⇒ **Hypothèse plausible :** exponentielle (hasard constant).

Réflexe à développer : partir du *mécanisme* imaginé dans la vraie vie, puis choisir la loi dont la forme de $h(t)$ lui ressemble.

Synthèse : trois lois paramétriques de base

Réflexe : choisir la loi dont la forme de $h(t)$ colle le mieux au mécanisme économique.

Loi	Survie $S(t)$	Hasard $h(t)$	PH / AFT ?	Interprétation / usages
Exponentielle	$S(t) = e^{-\lambda t}$	$h(t) = \lambda$ (constant)	PH & AFT possibles	phénomènes sans durée-dépendance.
Weibull	$S(t) = e^{-\lambda t^k}$	$h(t) = \lambda k t^{k-1},$ $k < 1$: décroissant, $k = 1$: constant, $k > 1$: croissant	PH ou AFT	usure ou sélection des robustes.
Log-logistique	$S(t) = \frac{1}{1 + (t/\lambda)^k}$	$h(t) = \frac{k}{\lambda} \frac{(t/\lambda)^{k-1}}{1 + (t/\lambda)^k}$ (hasard en cloche)	AFT seulement	phases d'adoption puis saturation.

Motivation : au-delà d'une loi commune pour tous

Jusqu'ici : une seule loi pour toutes les durées. En réalité : la durée dépend d'individus, de contextes, de choix.

Exemples de facteurs :

- ⇒ âge, genre, éducation ;
- ⇒ traitement / contrôle ;
- ⇒ santé, expérience, capital humain ;
- ⇒ exposition au risque, secteur, localisation.

Question centrale : *comment une covariable déforme-t-elle la distribution des durées ?*

Deux visions dominantes :

- ⇒ **PH** : changer l'**intensité** du risque ;
- ⇒ **AFT** : changer l'**vitesse** du temps.

→s concurrentes : PH vs AFT

Vision 1 : Proportional Hazards (PH)

$$h(t \mid X) = h_0(t) \exp(X\beta)$$

- ⇒ les covariables **modifient le niveau du risque** ;
- ⇒ la **forme temporelle reste identique** pour tous les groupes.

Vision 2 : Accelerated Failure Time (AFT)


$$T = T_0 \cdot \exp(-X\gamma)$$

- ⇒ les covariables **accélèrent ou ralentissent le temps** ;
- ⇒ l'événement survient **plus tôt ou plus tard**.

Métaphores : PH = déplacer la courbe **verticalement**. AFT = étirer/-compresser la courbe **horizontalement**.


PH vs AFT : comparaison visuelle simplifiée

À gauche : vision PH (risques proportionnels)




même forme, seulement un décalage vertical

À droite : vision AFT (temps accéléré)




même forme, mais "temps étiré"

Illustration : effet d'une variable en modèle PH



Signature des PH :

- ⇒ Les courbes de risque sont **proportionnelles** : ratio constant.
 - ⇒ Les courbes de survie sur échelle log(-log) sont **parallèles**.
 - ⇒ Interprétation directe : **hazard ratio** = e^β .



Signature des AFT :

- ⇒ Les courbes de survie sont “étirées” ou “compressées”.
 - ⇒ Pas de proportionnalité des hasards.
 - ⇒ Interprétation directe : **time ratio** = $e^{-\gamma}$.

Modèle AFT : comprendre le *time ratio*

Équation clé du modèle AFT :

$$T = T_0 \exp(-X\gamma)$$

$$\text{time ratio} = \exp(-\gamma)$$

- ⇒ > 1 : **durée étirée** → événement plus tard ;
- ⇒ < 1 : **durée compressée** → événement plus tôt.

Intuition :

- ⇒ PH = agit sur le **risque** (décalage vertical) ;
- ⇒ AFT = agit sur le **temps** (étirement horizontal).

Lecture : Le time ratio indique “de combien” la vidéo du temps est accélérée ou ralentie.

Une même loi peut être PH, AFT... ou aucun des deux

Idée générale : Selon la forme du hasard, une loi paramétrique peut s'écrire :

- ⇒ comme un **modèle PH** (effet vertical sur le risque),
- ⇒ ou comme un **modèle AFT** (effet horizontal sur le temps),
- ⇒ ou comme **ni l'un ni l'autre**.

Exponentielle : PH & AFT Hasard constant → les deux représentations coïncident.

Weibull : PH et AFT Hasard monotone (constant).

Log-normal : AFT seulement Survie en “S” asymétrique → impossible d'obtenir deux courbes proportionnelles.

Log-logistique : AFT seulement Hasard en cloche → les courbes ne peuvent jamais évoluer ”en parallèle”.

Message clé : la forme du hasard détermine si PH, AFT, ou les deux sont possibles.

PH ou AFT ? Résumé visuel

Loi	Forme du hasard	PH / AFT ?
Exponentielle	constant	PH & AFT
Weibull	monotone	PH & AFT
Log-normal	non monotone	AFT seulement
Log-logistique	en cloche	AFT seulement

PH = courbes "en parallèle". AFT = même forme, mais étirées/compressées dans le temps.

Quand utiliser PH ? Quand utiliser AFT ?

Choisir PH si :

- ⇒ l'effet des covariables déplace **verticalement le hasard** ;
- ⇒ la courbe $\log(-\log S(t))$ est **parallèle entre groupes** ;
- ⇒ interprétation en **hazard ratio** = centrale.

Choisir AFT si :

- ⇒ les groupes semblent “aller plus vite / lentement” ;
- ⇒ les courbes de survie semblent “étirées” ;
- ⇒ interprétation en **time ratio** plus intuitive.

En pratique : Tester PH → si non respecté → préférer AFT (log-normal, log-logistique, Weibull).

Quiz : PH ou AFT ?

Situation 1. On estime un modèle et on trouve :

$$\hat{\beta} = 0,5, \quad e^{\hat{\beta}} \approx 1,65.$$

On dit : « le traitement multiplie le **risque instantané** par 1,65 à tout instant ».

Situation 2. On estime un modèle et on trouve :

$$\hat{\gamma} = -0,3, \quad e^{-\hat{\gamma}} \approx 1,35.$$

On dit : « la durée médiane avant l'événement est **35 % plus longue** pour les traités ».

Question 1. Associez chaque situation au bon cadre :

- ① PH (hazards proportionnels)
 - ② AFT (Accelerated Failure Time)

Question 2. Dans quel cadre (PH ou AFT) l'interprétation suivante est-elle naturelle ? « Le traitement ralentit le temps jusqu'à l'événement ».

Correction du quiz : PH ou AFT ?

Situation 1.

$$e^{\hat{\beta}} \approx 1,65 \Rightarrow \text{hazard ratio}$$

- ⇒ Cadre : **PH**.
- ⇒ Interprétation : à tout instant t , le traitement augmente le **risque instantané** d'un facteur 1,65.

Situation 2.

$$e^{-\hat{\gamma}} \approx 1,35 \Rightarrow \text{time ratio}$$

- ⇒ Cadre : **AFT**.
- ⇒ Durée médiane est 35 % plus longue → le temps est **ralenti**.

Question 2 : « Le traitement ralentit le temps jusqu'à l'événement » ⇒ **AFT**.

À retenir : PH ⇒ hazard ratio ; AFT ⇒ time ratio (accélération / ralentissement du temps).

Feuille de route : modèles paramétriques avec covariables

Maintenant que nous avons :

- ⇒ les lois de base (exponentielle, Weibull, log-logistique),
- ⇒ la philosophie des modèles PH et AFT,
- ⇒ les signatures visuelles pour diagnostiquer l'un ou l'autre,

Nous allons estimer :

- ① le modèle exponentiel PH / AFT,
- ② le modèle Weibull PH,
- ③ le modèle Weibull AFT,
- ④ le modèle log-logistique AFT,
- ⑤ comparaison des ajustements.

Objectif final : savoir choisir, estimer et interpréter un modèle de durée paramétrique.

Rappels

Motivation

Lois de base

Extensions

Panorama & extensions

Vraisemblance sous censure : comprendre ce que l'on observe (1/2)

Pour chaque individu i , on observe :

$$t_i = \min(T_i, C_i) \quad \delta_i = \mathbf{1}\{T_i \leq C_i\}$$

- ⇒ **Cas 1 : événement observé** ($\delta_i = 1$) On connaît exactement la durée :
 $T_i = t_i$.
- ⇒ **Cas 2 : censure** ($\delta_i = 0$) On sait seulement que l'événement **n'est pas encore arrivé** :

$$T_i > t_i$$

Idée simple : Pour un censuré, on n'a pas la durée exacte... mais on a une **information partielle précieuse** : "il a survécu jusqu'à t_i ".

Comment construire la vraisemblance avec censure ?

Étape 1 : Identifier ce qu'on observe pour chaque individu

- ⇒ Si l'événement est observé ($\delta_i = 1$) : on connaît la **durée exacte** : $T_i = t_i$.
- ⇒ S'il est censuré ($\delta_i = 0$) : seulement une **borne inférieure** : $T_i > t_i$.

Étape 2 : Traduire cette information en probabilité

- ⇒ **Événement** : probabilité d'observer exactement $t_i \Rightarrow f(t_i)$ (densité)
- ⇒ **Censure** : probabilité d'être encore en vie à $t_i \Rightarrow S(t_i)$ (survie)

Étape 3 : Une formule unique pour les deux cas

$$L_i(\theta) = [f(t_i \mid \theta)]^{\delta_i} [S(t_i \mid \theta)]^{1-\delta_i}$$

- ⇒ si $\delta_i = 1 : f^1 S^0 = f(t_i)$
- ⇒ si $\delta_i = 0 : f^0 S^1 = S(t_i)$

Idée clé : La censure ne retire pas d'individus : elle change seulement la façon dont ils contribuent à la vraisemblance.

Vraisemblance sous censure : contributions individuelles (2/2)

Chaque individu contribue selon ce que l'on observe :

- ⇒ Événement observé ($\delta_i = 1$) → contribution par la **densité** : $f(t_i)$.
- ⇒ Censuré ($\delta_i = 0$) → contribution par la **survie** : $S(t_i)$.

On regroupe les deux cas :

$$L_i(\theta) = [f(t_i \mid \theta)]^{\delta_i} [S(t_i \mid \theta)]^{1-\delta_i}$$

Et la log-vraisemblance totale :

$$\ell(\theta) = \sum_{i=1}^n [\delta_i \log f(t_i \mid \theta) + (1 - \delta_i) \log S(t_i \mid \theta)].$$

Message clé : La censure **modifie la contribution** dans la vraisemblance, mais **aucune observation n'est supprimée**.

Exemple simple : contribution à la vraisemblance

individu jusqu'à $t_i = 5$. Que peut-on dire sur sa durée réelle T_i ?

Cas 1 : événement observé ($\delta_i = 1$)

- ⇒ On connaît la **valeur exacte** : $T_i = 5$.
- ⇒ La contribution est donc la **densité** au point 5 :

$$L_i = f(5 \mid \theta)$$

Cas 2 : censure ($\delta_i = 0$)

- ⇒ On sait seulement que l'événement n'est pas encore arrivé :

$$T_i > 5$$

- ⇒ Contribution = **probabilité de survivre au-delà de 5** :

$$L_i = S(5 \mid \theta)$$

Événement = durée exacte → *densité*. **Censure** = durée minimale
→ *survie*.

Exponentielle : intuition de la log-vraisemblance (1/2)

Rappel : modèle exponentiel Hasard constant $\lambda \Rightarrow$ durée moyenne $= 1/\lambda$.

Contribution d'un individu

- ⇒ **Événement** ($\delta_i = 1$) : $f(t_i) = \lambda e^{-\lambda t_i}$ (on connaît la durée exacte).
- ⇒ **Censure** ($\delta_i = 0$) : $S(t_i) = e^{-\lambda t_i}$ (on sait seulement $T_i > t_i$).

Idée clé :

- ⇒ tous les individus apportent un facteur $e^{-\lambda t_i}$;
- ⇒ seuls les événements apportent un facteur supplémentaire λ .

Ce qui compte au final : nombre d'événements D et temps total observé $T = \sum t_i$.

Exponentielle : log-vraisemblance et estimateur (2/2)

Log-vraisemblance individuelle

$$\ell_i = \delta_i(\log \lambda - \lambda t_i) + (1 - \delta_i)(-\lambda t_i).$$

Lecture : $-\lambda t_i$ apparaît pour tout le monde ; $\log \lambda$ seulement pour les événements.

En sommant :

$$\ell(\lambda) = D \log \lambda - \lambda T \quad \text{avec } D = \sum_i \delta_i, \quad T = \sum_i t_i.$$

MLE :

$$\hat{\lambda} = \frac{D}{T}.$$

$\hat{\lambda} = \frac{\text{événements}}{\text{temps exposé}} = \text{un taux d'incidence.}$

Weibull : comprendre la vraisemblance (1/2)

Rappel : Weibull (λ, k)

$$f(t) = \lambda k t^{k-1} e^{-\lambda t^k}, \quad S(t) = e^{-\lambda t^k}.$$

Rôle des paramètres :

- ⇒ λ : **niveau** du risque (scale) ;
- ⇒ k : **forme** du risque (croissant, constant, décroissant).

Contributions à la vraisemblance :

- ⇒ **Événement** : probabilité d'observer $t_i \Rightarrow f(t_i)$;
- ⇒ **Censure** : probabilité que $T_i > t_i \Rightarrow S(t_i)$.

Weibull = exponentielle "généralisée" : λ contrôle le niveau, k contrôle la forme du hasard.

Weibull : log-vraisemblance (structure) (2/2)

Log-vraisemblance individuelle

$$\ell_i = \delta_i \log f(t_i) + (1 - \delta_i) \log S(t_i).$$

En remplaçant f et S du Weibull :

$$\ell(\lambda, k) = \sum_i \left[\delta_i (\log(\lambda k) + (k-1) \log t_i) - \lambda t_i^k \right].$$

Interprétation des termes :

- ⇒ $\log(\lambda k)$: contribution des événements au niveau du risque ;
- ⇒ $(k-1) \log t_i$: effet de la **forme du hasard** (croissant/décroissant) ;
- ⇒ $-\lambda t_i^k$: **terme de survie**, présent pour tous (événements + censures).

Estimation :

- ⇒ Pas de solution analytique pour $(\hat{\lambda}, \hat{k}) \rightarrow$ Maximisation de $\ell(\lambda, k)$

densité pour les événements, survie pour les censures.

Sélection de modèle : expo vs Weibull (1/2)

Lien fondamental : L'exponentielle est un **cas particulier** du Weibull :

$$\text{Weibull}(\lambda, k) \quad \text{et} \quad \text{Expo}(\lambda) = \text{Weibull}(\lambda, 1).$$

Que signifie le paramètre k ?

- ⇒ $k < 1$: le risque **diminue** avec le temps (apprentissage, sélection) ;
- ⇒ $k = 1$: **risque constant** (processus "sans mémoire") ;
- ⇒ $k > 1$: le risque **augmente** (vieillissement, usure).

Interprétation du test :

- ⇒ si les données sont compatibles avec $k = 1 \Rightarrow$ modèle exponentiel suffisant ;
- ⇒ si $k \neq 1 \Rightarrow$ il existe une **forme du hasard non constante** ⇒ Weibull nécessaire.

Question pratique : Vos données suggèrent-elles que le **risque change au fil du temps** (croît-il ? décroît-il ?) ou restent-elles compatibles avec un risque constant ?

Sélection de modèle : expo vs Weibull (2/2)

Hypothèses :

$$H_0 : k = 1 \quad (\text{hasard constant})$$

$$H_1 : k \neq 1 \quad (\text{hasard non constant})$$

Statistique du rapport de vraisemblance :

$$LR = 2(\ell_{\text{Weibull}} - \ell_{\text{Expo}}), \quad LR \stackrel{H_0}{\sim} \chi^2(1).$$

Interprétation :

- ⇒ **LR petit** (p-value grande) ⇒ les données ne suggèrent pas de changement du risque. ⇒ **exponentielle acceptable**.
- ⇒ **LR grand** (p-value faible) ⇒ le risque évolue avec le temps. ⇒ **préférer Weibull**.

En clair : Ce test vérifie si le **hasard est constant** ou non.

Exemple numérique : test expo vs Weibull

Supposons :

$$\ell_{\text{Expo}} = -520.3, \quad \ell_{\text{Weibull}} = -510.1$$

$$LR = 2(\ell_W - \ell_E) = 20.4$$

$p\text{-value} \approx 0.00001 \Rightarrow$ on **rejette l'exponentielle**. Le hasard n'est **pas constant**.

Pourquoi AIC et BIC ? (Sélection de modèle 1/2)

Problème : Le test du rapport de vraisemblance (LR) ne compare que des **modèles imbriqués** (ex : exponential \subset Weibull).

Mais en pratique, on veut souvent comparer :

- ⇒ Weibull vs log-normal ;
- ⇒ log-logistique vs exponentielle ;
- ⇒ plusieurs modèles AFT ou PH entre eux ;
- ⇒ modèles avec covariables vs modèles sans covariables.

Besoin : un outil qui compare **l'ajustement** du modèle et **la pénalité de complexité**, même pour des modèles totalement différents.

Solution : AIC et BIC Deux critères simples pour choisir le *meilleur modèle* parmi plusieurs, même s'ils ne sont pas imbriqués.

Sélection de modèle : AIC et BIC (2/2)

Définitions :

$$AIC = -2\ell + 2p, \quad BIC = -2\ell + p \log n.$$

- ⇒ ℓ : log-vraisemblance maximisée (qualité d'ajustement).
- ⇒ p : nombre de paramètres (complexité du modèle).
- ⇒ n : taille de l'échantillon.

Interprétation :

- ⇒ Le terme -2ℓ récompense **l'ajustement** (plus petit = meilleure fit).
- ⇒ Les termes $2p$ ou $p \log n$ pénalisent **la complexité**.
- ⇒ **Modèle préféré = celui avec le critère le plus petit.**

Sélection de modèle : AIC et BIC (2/2)

Définitions :

$$AIC = -2\ell + 2p, \quad BIC = -2\ell + p \log n.$$

- ⇒ ℓ : log-vraisemblance maximisée (qualité d'ajustement).
- ⇒ p : nombre de paramètres (complexité du modèle).
- ⇒ n : taille de l'échantillon.

AIC : favorise l'ajustement (moins sévère). **BIC** : pénalise davantage les modèles complexes (critère plus conservateur).

AIC/BIC permettent de comparer **des modèles non imbriqués**, sur les **mêmes données**, quel que soit le cadre (PH, AFT, paramétriques...).

Exemple numérique : comparaison AIC/BIC

Trois modèles ajustés sur les mêmes données :

Modèle	p (param.)	AIC	BIC
Exponentielle	1	1042	1046
Weibull	2	1026	1034
Log-logistique	2	1022	1030

Lecture du tableau :

- ⇒ L'exponentielle a l'AIC/BIC les plus **grands** → mauvais ajustement.
- ⇒ Weibull améliore nettement l'ajustement (AIC/BIC plus faibles).
- ⇒ Log-logistique est encore meilleur : **gains supplémentaires** malgré la même complexité que Weibull.

Plus petit = meilleur compromis ajustement / complexité. Ici :
log-logistique gagne selon *AIC* et *BIC*.

Diagnostics visuels pour choisir une loi

1. KM vs modèle théorique

- ⇒ Superposer la courbe de survie paramétrique à la KM.
- ⇒ Chercher des écarts systémiques (début / fin de support).

2. Graphique $\log(-\log \hat{S}(t))$

- ⇒ Linéaire en $t^\alpha \Rightarrow$ Weibull plausible.
- ⇒ Courbure marquée ⇒ loi plus flexible à envisager.

3. Nelson-Aalen vs $H(t)$ théorique

- ⇒ Vérifier la forme du **risque cumulé**.
- ⇒ Segments quasi-linéaires vs convexes/concaves.

Un bon fit visuel ne suffit pas : il faut aussi vérifier la **cohérence de $h(t)$** avec l'histoire économique.

Durée-dépendance ou hétérogénéité latente ? (1/2)

Observation courante en données de durée : **un hazard décroissant** (risque plus élevé au début, puis plus faible).

Deux interprétations possibles :

- ⇒ **Durée-dépendance réelle** Le risque change réellement avec le temps :
 - apprentissage (chômage) ;
 - découragement (prospection) ;
 - épuisement d'opportunités.
- ⇒ **Hétérogénéité non observée / sélection** Les individus sont différents :
 - ceux avec risque élevé sortent très tôt ;
 - ceux qui restent sont les "robustes".

Message clé : Un hazard décroissant observé *peut être dû à la composition du groupe*, pas à un changement du risque individuel.

Pourquoi un hazard peut *sembler* décroissant ? (2/2)

Exemple : deux types d'individus


- ⇒ 50% "fragiles" : hazard $h = 0.5$ (risque élevé)
- ⇒ 50% "robustes" : hazard $h = 0.1$ (risque faible)

Ce qui se passe dans le temps :

- ① Au début, beaucoup de "fragiles" sortent très vite.
- ② Après un moment, il ne reste principalement que les "robustes".
- ③ Le hazard **observé** dans l'échantillon diminue... même si le hazard **individuel** est constant !

Hazard moyen décroissant \neq hazard individuel décroissant. La baisse peut venir d'une **sélection progressive** des survivants.

Frailty : sélection des fragiles vs robustes



Même si chaque individu a un **hasard constant**, la **moyenne** peut être décroissante car les plus fragiles sortent plus tôt. C'est l'effet **frailty**.

Pourquoi un mélange d'individus crée un hazard décroissant ?

Idée centrale : Les individus n'ont pas tous le même risque **initial**. Certains sont fragiles (risque élevé), d'autres robustes (risque faible).

Ce qui se passe dans le temps :

- ① Les individus **fragiles** ont plus de chances de connaître l'événement tôt.
- ② Ils quittent donc l'échantillon rapidement.
- ③ Plus le temps passe, plus la population restante est composée de **survivants robustes**.
- ④ Le **risque moyen observé** baisse - même si le risque individuel ne change pas.

Un hazard décroissant peut venir d'une **sélection naturelle des survivants**, pas d'un changement du risque individuel.

Frailty Gamma : l'intuition avant les maths

Idée centrale : Les individus n'ont pas tous le même risque initial. Leur “ fragilité ” est un facteur multiplicatif noté v .

$$h(t \mid v) = v\lambda$$

Conditionnellement à v : chaque individu suit une loi exponentielle (hasard constant).

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

Mais l'échantillon contient un **mélange** d'individus :

- ⇒ les plus “ fragiles ” (v élevé) sortent vite ;
- ⇒ les plus “ robustes ” (v faible) restent plus longtemps.

Survie observée = **moyenne** des survies individuelles. C'est ce mélange qui modifie la forme de $S(t)$.

Frailty Gamma : l'essentiel mathématique

1. Survie conditionnelle :

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

2. Survie marginale = moyenne sur la distribution de v :

$$S(t) = \mathbb{E}_v[e^{-v\lambda t}]$$


3. Choix du Gamma : Si $v \sim \Gamma(\alpha, \alpha)$, alors

$$\mathbb{E}(e^{-vx}) = \left(1 + \frac{x}{\alpha}\right)^{-\alpha}.$$

En posant $x = \lambda t$:

$$S(t) = \left(1 + \frac{\lambda t}{\alpha}\right)^{-\alpha}.$$

Pourquoi le Gamma ? Parce qu'il donne une forme **fermée, simple et interprétable** pour $S(t)$.



- ⇒ Hasard individuel : constant.
 - ⇒ Hasard agrégé : décroissant.

La sélection suffit à créer une **fausse** durée-dépendance.

Pourquoi intégrer des covariables dépendantes du temps ?

Dans beaucoup de situations, ce qui influence la durée change lui-même avec le temps :

- ⇒ un traitement commence (ou s'arrête) en cours de suivi ;
- ⇒ l'état de santé évolue ;
- ⇒ un individu suit une formation pendant le chômage ;
- ⇒ un revenu, un statut familial, une exposition au risque se modifient.

Limite des modèles "simples" : Ils supposent que les covariables restent fixes pendant toute la durée.

Idée clé : représenter le parcours d'un individu comme une suite d'intervalle où les covariables sont **constants**. Chaque changement d'état → un **nouvel épisode**.

Idée intuitive : découper le temps en épisodes

Principe : À chaque fois qu'une covariable change, on coupe le suivi en un nouvel intervalle.

Exemple :

Début	Fin	Événement ?	Statut du traitement
0	6	0	0 (non traité)
6	10	1	1 (traité)

Lecture :

- ⇒ L'individu est "non traité" de 0 à 6.
- ⇒ À 6, il commence le traitement → nouveau segment.
- ⇒ L'événement arrive à 10 pendant le dernier segment.

Cette structure "(début, fin, événement)" permet d'utiliser Cox, Weibull, log-logistique, etc. Les logiciels se chargent du reste.

Idée clé : découper le temps en épisodes (“counting process”)

Principe : Chaque fois qu'une covariable change, on crée un **nouvel intervalle de temps**. L'individu est donc représenté par plusieurs “ épisodes ” successifs :

Début	Fin	Événement ?	Statut $X(t)$
0	6	0	0 (non traité)
6	10	1	1 (traité)

Lecture de l'exemple :

- ⇒ de 0 à 6 : l'individu n'est pas traité, pas d'événement ;
- ⇒ à 6 : le statut change → nouvel épisode ;
- ⇒ de 6 à 10 : traité, et l'événement survient à la fin.

L'idée centrale : **actualiser $X(t)$ dans le temps** en découpant la trajectoire en épisodes successifs.

Pourquoi découper en épisodes (tstart-tstop) ?

Exemple concret : Un individu commence un traitement au temps $t = 6$.

$$\begin{array}{ccc} \underbrace{[0, 6]} & \Rightarrow & \underbrace{[6, 10]} \\ X(t)=0 : \text{non traité} & & X(t)=1 : \text{traité} \end{array}$$

Problème : Les modèles de durée (Cox, Weibull, etc.) supposent que les covariables **restent constantes** pendant l'intervalle analysé.

Solution : découper le suivi en épisodes

- ⇒ un épisode = une période où $X(t)$ ne change pas ;
- ⇒ chaque changement de statut crée un nouvel intervalle ;
- ⇒ l'événement appartient à l'épisode où il se produit.

Découper permet au modèle d'utiliser la **bonne valeur de la covariable au bon moment**.

Hazards cause-spécifiques : l'idée

Contexte : Plusieurs types possibles d'événement (ex. démission, licenciement).

Définition : pour une cause k

$$h_k(t) = \lim_{\Delta \rightarrow 0} \frac{\Pr(t \leq T < t + \Delta, \text{ cause} = k \mid T \geq t)}{\Delta}$$

Interprétation :

- ⇒ risque instantané de sortir **par la cause k** ;
- ⇒ en traitant les autres causes comme des **censures**.

On étudie l'évolution du **mécanisme k** en lui-même.

Comment utiliser les hazards cause-spécifiques ?

Estimation :

- ⇒ créer un jeu de données par cause ;
- ⇒ cause $k =$ événement ;
- ⇒ autres causes = censures ;
- ⇒ ajuster Cox ou un modèle paramétrique sur chaque cause.

Ce que cela dit :

- ⇒ comment les covariables influencent **chaque mécanisme** (ex. effets différents sur démission / licenciement).

Ne décrit pas la probabilité finale de sortir par $k \rightarrow$ il faut la **cumulative incidence** pour cela.

Modèle de Fine-Gray : l'idée

But : modéliser directement la **probabilité cumulée** d'un événement de cause k :

$$\text{CIF}_k(t) = \Pr(T \leq t, \text{ cause} = k).$$

Pourquoi ? Parce que la CIF répond à une question centrale :

⇒ “ Quelle est la **probabilité** que l'événement k se produise avant t ? ”

Idée Fine-Gray : modifier la définition du “ risque ” pour que la CIF soit directement reliée au modèle.

Au lieu de modéliser le **hazard** d'une cause, on modélise la **CIF** elle-même.

Fine-Gray : intuition du hazard subdistribution

Pour relier directement les covariables à la **CIF**, Fine-Gray définit un hazard modifié :

$$\tilde{h}_k(t) = \lim_{\Delta \rightarrow 0} \frac{\Pr(t \leq T < t + \Delta, \text{ cause} = k \mid \text{encore "à risque"})}{\Delta}$$

Différence clé : Les individus sortis par une autre cause **restent dans le dénominateur.**

ils ne disparaissent pas du “risk set”

- ⇒ Cela garde la probabilité cumulée dans la dynamique du modèle.
- ⇒ On obtient directement des effets sur la **CIF**, pas seulement sur les hazards.

À retenir : Cause-spécifique → effets sur les *hazards*. Fine-Gray → effets sur les *probabilités cumulées (CIF)*.

Cause-spécifique vs Fine–Gray : deux questions différentes

Modèle cause-spécifique (Cox appliqué à chaque cause)

- ⇒ On étudie le **mécanisme instantané** de la cause k .
- ⇒ Question :
“ Comment X modifie le **hazard de la cause k** ? ”

- ⇒ Les autres causes sont traitées comme des censures.

Modèle de Fine–Gray

- ⇒ On étudie directement la **probabilité cumulée** d'observer la cause k .
 - ⇒ Question :
“ Comment X modifie la **CIF** de la cause k ? ”
- ⇒ Les autres causes restent dans le risk set (subdistribution hazard).

Résumé intuitif : Cause-spécifique → comment ça se produit. Fine–Gray → avec quelle probabilité cela arrivera au final.

Risques concurrents : pièges et intuition

Situation typique : un individu peut connaître plusieurs issues mutuellement exclusives. Exemples :

- ⇒ chômage : emploi / inactivité / formation ;
- ⇒ entreprise : faillite / rachat / sortie du marché ;
- ⇒ étudiant : diplomation / abandon / changement d'établissement.

Piège majeur : Kaplan-Meier suppose que la censure est **non-informative**.


Mais ici :être “censuré” par une autre cause = événement informatif.

Conséquence :

- ⇒ KM **surestime** la survie spécifique à une cause.
- ⇒ KM répond à “probabilité de **n'avoir aucun événement**”, pas à “probabilité de **ne pas avoir l'événement k**”.

Message essentiel : Avec plusieurs causes, la survie et le risque doivent être définis **cause par cause**.

Exemple de risques concurrents : sortie du chômage



- ⇒ Trois **hazards cause-spécifiques** : emploi, formation, inactivité.
- ⇒ Un individu peut quitter l'état “chômeur” par **une seule** de ces issues.

Pour étudier l'effet d'une politique, on peut :

- ⇒ soit modéliser chaque hazard $h_k(t)$ séparément (cause-spécifique),
- ⇒ soit modéliser directement la **probabilité cumulée** d'accès à l'emploi (Fine–Gray).

Incidence cumulée (CIF) : interprétation économique

$$\text{CIF}_k(t) = \Pr(T \leq t, \text{ cause} = k)$$

Lecture : probabilité que l'individu ait connu l'issue k avant le temps t .

Distinction cruciale :

- ⇒ **CIF** = probabilités réelles observées dans une population.
 - ⇒ **Hazard cause-spécifique** = *mécanismes instantanés*.

En présence de concurrence :

$$\text{CIF}_k(t) = \int_0^t S(u^-) h_k(u) du.$$

- ⇒ h_k détermine la vitesse vers la cause k .
 - ⇒ $S(u)$ capture la compétition des autres causes.

Donc : Analyser h_k = comprendre les **forces** ; Analyser CIF = comprendre les **probabilités finales** observées.

Rappels

Motivation

Lois de base

Extensions

Panorama & extensions

Quel modèle retenir ?

Avant de choisir un modèle : regarder les données. La forme de $S(t)$, $h(t)$, et la présence de queues lourdes ou de durée-dépendance guident le choix.

Quelques repères pratiques :

⇒ Weibull

- flexible : hasard monotone (croissant ou décroissant) ;
- compatible **PH et AFT** ;
- très bon point de départ.

⇒ Log-logistique

- très utile si $S(t)$ a une **queue lourde** ;
- hazard en **cloche** (non monotone) ;
- souvent gagnant en **AIC/BIC**.

⇒ KM / NA

- indispensable pour **visualiser** la structure des données ;
- permet de repérer monotonie, points de rupture, hétérogénéité.

Extensions : les 5 idées à retenir

1. Vraisemblance sous censure

événement → $f(t)$ censure → $S(t)$

2. Choix de modèle

Imbriqués : LR-test Non imbriqués : AIC/BIC

3. Frailty

$h(t) \downarrow$ observé $\not\Rightarrow h(t) \downarrow$ individuel

4. Covariables dépendantes du temps

$(t_{\text{start}}, t_{\text{stop}}]$ pour rendre $X(t)$ constant par épisode

5. Risques concurrents

Cause-spécifique : hazard Fine–Gray : CIF

Trois cadres pour analyser les durées

1. Non-paramétrique (KM / NA)

Décrit les données, sans hypothèses.

2. Semi-paramétrique (Cox PH)


Effets de covariables ; forme de $h_0(t)$ libre.

3. Paramétrique (Expo, Weibull, Log-logistique)

Forme imposée \Rightarrow interprétation + prédiction.

Résumé : Souplesse (KM) \rightarrow équilibre (Cox) \rightarrow prédiction (paramétrique).

Choisir le bon cadre : arbre décisionnel enrichi



Règle d'or : commencer simple (KM), tester PH, puis affiner (Cox ou paramétrique).

Checklist pratique : analyser des durées

1. Explorer

- ⇒ Courbes KM par groupe.
- ⇒ NA pour la forme du risque.
- ⇒ Niveau de censure.

2. Tester

- ⇒ Diagnostics PH (log–log parallèle?)
- ⇒ Expo vs Weibull : LR-test.
- ⇒ Comparer les lois : AIC / BIC.

3. Choisir

- ⇒ **PH** si hazard ratio central.
- ⇒ **AFT** si time ratio plus parlant.
- ⇒ **Frailty** si hétérogénéité forte.
- ⇒ **Risques concurrents** si plusieurs issues.