

Econométrie des modèles de durée

Guillaume Horny*

*Banque de France and UCLouvain

Master 2 MOSEF

Chapitre 3: Modèles paramétriques

Plan

- 1 Modèles exponentiel et de Weibull
- 2 Modèles log-linéaire et log-logistique
- 3 Modèles AFT

Modèles exponentiel et de Weibull

Chapitre 3

- 1 Modèles exponentiel et de Weibull
- 2 Modèles log-linéaire et log-logistique
- 3 Modèles AFT

Deux distributions de référence

- **Loi exponentielle:** première loi “naturelle” pour des durées, reliée à la loi de Poisson
- **Loi de Weibull:** une extension de la loi exponentielle, flexible et facile à estimer

Loi de Poisson

Utilisée pour modéliser le **nombre d'événements** par intervalle de temps (nombre d'appels reçus en 1 heure par un standard, nombre de visite chez le docteur par an...)

Inventée par **Siméon Denis Poisson** (1781-1840), publiée en 1838 dans *Recherches sur la probabilité des jugements en matière criminelle et en matière civile*



Notations

Utilise des **processus de Poisson** lorsqu'on s'intéresse à la distribution intertemporelle des événements.

On suppose le temps continu, et on note $N(t)$ le nombre total d'événements qui se sont produit avant t . La suite de VA $\{N(t) | t \geq 0\}$ est un **processus de comptage**. On note également $N(t, t + \Delta)$, $\Delta > 0$ le nombre d'événements se produisant dans l'intervalle $]t, t + \Delta]$.

Définition d'un processus de Poisson

Un processus de Poisson suppose que l'occurrence d'un événement en t est définie par :

$$\begin{aligned}\Pr [N(t, t + \Delta) = 1] &= \lambda\Delta + o(\Delta), \\ \Pr [N(t, t + \Delta) = 0] &= 1 - \lambda\Delta + o(\Delta),\end{aligned}$$

où $[o(\Delta)/\Delta] \rightarrow 0$ lorsque $\Delta \rightarrow 0$.

Conséquences:

- la probabilité d'occurrence est proportionnelle à longueur de l'intervalle de temps, et le coefficient de proportionnalité est constant (ne varie pas dans le temps)
- l'occurrence est indépendante du nombre d'événements qui se sont déjà produits, et indépendante de t .

De Poisson à l'exponentielle

On peut montrer qu'un processus de Poisson de paramètre λ implique des durées séparant la réalisations de deux événements distribuées selon une loi exponentielle de paramètre λ .

Intuition:

Comme les événements sont indépendants:

$$\Pr[N(t, t + \Delta) = 1] = \Pr [N(t, t + \Delta) = 1 | N(0, t)]. \quad (1)$$

D'où le hasard:

$$\lim_{\Delta \rightarrow 0} \Pr [N(t, t + \Delta) = 1 | N(0, t) = 0] = \lambda \quad (2)$$

Loi exponentielle

T suit une loi exponentielle de paramètre λ si:

- hasard: $\lambda(t) = \lambda$
- hasard intégré : $\Lambda(t) = \lambda t$
- survie: $S(t) = \exp(-\lambda t)$
- densité: $f(t) = \lambda \exp(-\lambda t), \forall t > 0$

Loi exponentielle (suite)

Propriétés:

- $E(T) = 1/\lambda$ et $V(T) = 1/\lambda^2$
- le hasard intégré est une droite

Introduction de variables explicatives

on écrit: $\lambda_i(t|X_i) = \lambda_i = \exp(X_i\beta)$.

Exemple: code R de MV avec données simulées

```
rm(list=ls())
library(survival)

# simulations des variables explicatives
x1 <- rnorm(1000)
x2 <- rnorm(1000)

# simulation durées exponentielles ( $S(t) = \exp(- \lambda t)$ ,
# où  $\lambda = \exp(X' \beta)$ )
lambda0 <- exp(x1 - x2)
t <- (- log(runif(1000))) / lambda0
```

Exemple: code R de MV avec données simulées (suite)

```
# vraisemblance d'un modèle exponentiel
loglikeli <- function(theta){ -1 * sum((theta[1] * x1 \\
+ theta[2] * x2) - t * exp(theta[1] * x1 + theta[2] * x2))}

# maximisation vraisemblance
inits <- c(0,0)

est <- optim(inits, loglikeli, method = "BFGS")
est
```

Exemple: estimation avec STATA

```
streg X, dist(exponential)
```

Loi de Weibull

Inventé par **Waloddi Weibull** (1887-1979), ingénieur et mathématicien suédois. Publia de nombreux travaux sur la résistance des matériaux.



Loi de Weibull

T suit une loi de Weibull de paramètre α et θ si:

- hasard: $\lambda(t) = \alpha\theta t^{\theta-1}$
- hasard intégré : $\Lambda(t) = \alpha t^\theta$
- survie: $S(t) = \exp(-\alpha t^\theta)$
- densité: $f(t) = \alpha\theta t^{\theta-1} \exp(-\alpha t^\theta)$

Loi de Weibull (suite)


Propriétés:

- pour $\theta = 1$, on retrouve la loi exponentielle
- $d\lambda/dt = \alpha\theta(\theta - 1)t^{\theta-2}$. Le hasard est donc monotone croissant pour $\theta > 1$ et monotone décroissant pour $\theta < 1$
- $\ln \Lambda(t) = \ln \alpha + \ln \theta t$. La courbe $\{\ln t, \ln \Lambda(t)\}$ est une droite

Introduction de variables explicatives

on écrit: $\alpha_j = \exp(X_j\beta)$.

Graphiques de hasards de Weibull

Fonctions de hasard de Weibull ($\alpha = 1$)

Code R des graphiques

Programme:

```
library(survival)
hasard <- fonction(x){alpha * theta * x^(theta - 1)}
alpha <- 1
theta <- 1
plot(hasard)
theta <- 2
curve(hasard, add=TRUE)
...
```

Exemple: estimation avec STATA

```
streg X, dist(weibull)
```


Modèles log-linéaire et log-logistique

Chapitre 3

- 1 Modèles exponentiel et de Weibull
- 2 Modèles log-linéaire et log-logistique
- 3 Modèles AFT

Loi log-normale (loi de Galton)

Francis Galton (1822-1911). Cousin de Charles Darwin et explorateur, géographe, météorologue, statisticien, anthropologue, psychométricien, ... Ses travaux statistiques visent à quantifier les caractéristiques (physiques, psychiques) de l'homme et leur évolution. Auteur de plusieurs contributions à la statistique, dont le modèle linéaire de "régression".
Côté obscur: eugéniste, défendit la "science de l'amélioration des lignées"



Loi log-normale

T suit une loi log-normale de paramètres (μ, σ) si:

- $\ln T \sim \mathcal{N}(\mu, \sigma)$
- densité : $f(t) = \frac{1}{t\sigma} \phi\left(\frac{\ln t - \mu}{\sigma}\right)$
- répartition : $F(t) = \Phi\left(\frac{\ln t - \mu}{\sigma}\right)$
- survie: $S(t) = 1 - \Phi\left(\frac{\ln t - \mu}{\sigma}\right)$
- hasard: $\lambda(t) = \frac{1}{t\sigma} \frac{\phi\left(\frac{\ln t - \mu}{\sigma}\right)}{1 - \Phi\left(\frac{\ln t - \mu}{\sigma}\right)}$

Rappel: changement de variable

Soit $X = g(Z)$, où Z est une variable aléatoire de densité f_Z et g est une application différentiable bijective, alors la densité f_X de X a pour expression:

$$f_X(x) = \frac{f_Z(g^{-1}(x))}{|g'[g^{-1}(x)]|}. \quad (3)$$

Loi log-normale (suite)

Propriétés:


- $E(T) = \exp(\mu + \sigma^2/2)$ et $\text{Var}(T) = [\exp(\sigma^2) - 1] \exp(2\mu + \sigma^2)$.
- $\lim_{t \rightarrow 0} \lambda(t) = 0$ et $\lim_{t \rightarrow \infty} \lambda(t) = 0$
- la fonction de hasard est croissante puis décroissante, donc unimodale.

Introduction de variables explicatives

on écrit: $\mu_i = X_i \beta$.

Graphique de hasard log-normal

Fonctions de hasard log-normal ($\mu = 0, \sigma = 1$)



Code R du graphique

Programme:

```
library(survival)  
plot(dlnorm)
```

Loi log-logistique

T suit une loi log-logistique de paramètre α et θ si:

- $\ln T \sim \text{Logistique}(\alpha, \theta)$
- densité: $f(t) = \frac{\alpha\theta(\alpha t)^{\theta-1}}{[1+(\alpha t)^\theta]^2}$
- répartition: $F(t) = \frac{(\alpha t)^\theta}{1+(\alpha t)^\theta}$
- survie: $S(t) = \frac{1}{1+(\alpha t)^\theta}$
- hasard: $\lambda(t) = \frac{\alpha\theta(\alpha t)^{\theta-1}}{1+(\alpha t)^\theta}$


Loi log-logistique (suite)

- pour $\theta < 1$, le hasard est monotone décroissant avec $\lim_{t \rightarrow 0} \lambda(t) = \infty$
- pour $\theta = 1$, le hasard est monotone décroissant avec $\lim_{t \rightarrow 0} \lambda(t) = \alpha$
- pour $\theta > 1$, le hasard est croissant puis décroissant (donc unimodal), avec $\lim_{t \rightarrow 0} \lambda(t) = 0$ et $\lim_{t \rightarrow \infty} \lambda(t) = 0$. Le maximum est atteint pour $t = \frac{(\theta-1)^{1/\theta}}{\alpha}$.

Introduction de variables explicatives

on écrit: $\alpha_i = \exp(-X_i\beta)$.

Graphiques de hasards log-logistiques

Fonction de hasard log-logistique ($\alpha = 1$)

Code R du graphique

Même principe que pour la loi de Weibull (exercice!)

Exemple: estimation avec STATA

```
streg X, dist(loglogistic)
```

Autres lois

- loi Gamma généralisée
- loi de Gompertz
- loi de Gumbel
- hasards de Box-Cox
- modèle inverse-gaussien
- ...

Exemple: estimation avec STATA

```
foreach model in exponential weibull gompertz lognormal \<\  
loglogistic gamma {  
  quietly streg X, dist('model')  
  estimates store 'model'  
}  
estimates stats _all
```

Conclusion

- il existe un grand nombre de lois paramétriques
- sélection de modèles: par tests d'emboîtement, ou par comparaison de critères d'information (AIC,...)

Limitation: modèles peu flexibles (1 ou 2 paramètres, 3 pour la loi Gamma généralisée) pour la dépendance au temps!

Modèles AFT

Chapitre 3

- 1 Modèles exponentiel et de Weibull
- 2 Modèles log-linéaire et log-logistique
- 3 Modèles AFT

Modèles avec accélération du temps

Les modèles AFT viennent de la modélisation de $\ln T$ plutôt que de T .
D'où la régression:

$$\ln t = X'\beta + u, \quad (4)$$

où u a une distribution à support non-nécessairement positif.
⇒ le modèle AFT tire sa flexibilité de la loi de u .

Accélération du temps?

Partant de:

$$\exp(t) = \exp(X'\beta) \exp(u), \quad (5)$$

On peut montrer (exercice!):

$$\lambda(t|X) = \lambda_0[t \exp(-X'\beta)] \exp(X'\beta). \quad (6)$$

Interprétation:

Dans un modèle AFT, les X modifient le hasard via un coefficient de proportionnalité appliqué :

- au hasard de base (dilatation verticale),
- à t (dilatation de l'axe des temps, horizontale).

Origine du nom: applications industrielles

Modèles AFT usuels

Distribution de u	Distribution de T
valeur extrême	Weibull
gaussienne	log-normale
logistique	log-logistique

Exemple d'estimation sous R

Code:

```
library(survival)
# ln T ~ Weibull
survreg(Sur(duree, transition) ~ x1 + x2, dist='weibull')
# ln T ~ exponentielle
survreg(Sur(duree, transition) ~ x1 + x2, dist='exponential')
survreg(Sur(duree, transition) ~ x1 + x2, dist='weibull', \\
scale=1 )
# ln T ~ log-normale
survreg(Sur(duree, transition) ~ x1 + x2, dist='lognormal')
```

Exemple d'estimation sous STATA

```
streg X, dist( ) time
```

Interprétation des estimations

$$\ln t = X' \beta + u, \quad (7)$$

- si X_k est en log, β_k est l'élasticité de T par rapport à X_k ,
- si X_k est binaire, β_k est approximativement le taux de croissance de T lorsque X_k passe de 0 à 1.

Comparaison HP-AFT

- les coefficients affectent le hasard dans les modèles HP, la durée dans les modèles AFT
- le modèle de Weibull (et donc exponentiel) est à l'intersection des deux classes de modèles

Exercice: Vérifier en posant u comme distribué selon une loi de valeur extrême.

Remarque générale: vérifier toujours les paramétrisations avant de commenter les résultats!