

# Comment passer des anciennetés aux durées ? Illustration à partir de l'Enquête Famille et Logement.

Vianney Costemalle

Unité des études démographiques et sociales, Insee.

1 avril 2015

- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais ?
- 4 Estimations du modèle sur des simulations
- 5 Resultats avec l'Enquête Famille et Logement
- 6 Conclusion

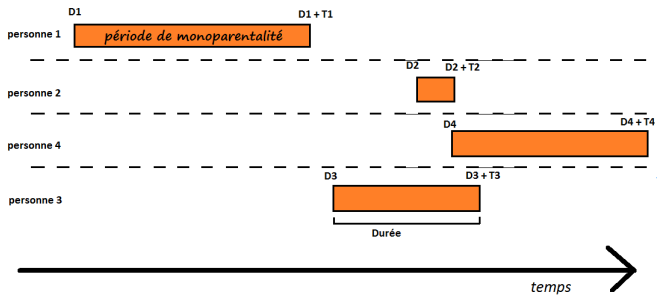
- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais?
- 4 Estimations du modèle sur des simulations
- 5 Resultats avec l'Enquête Famille et Logement
- 6 Conclusion

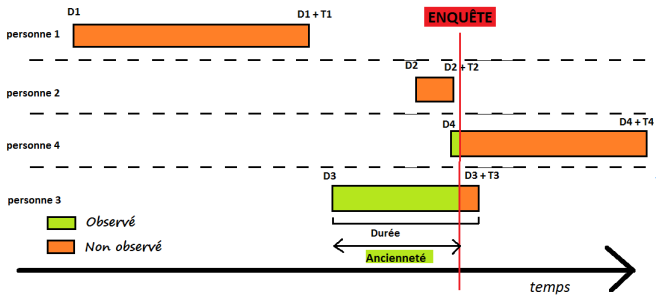
- L'Enquête Famille et Logement (EFL) a été réalisé en 2011 conjointement au recensement de la population, sur 360000 personnes âgées de 18 ans ou plus.
- Elle permet en particulier de connaître le stock de **familles monoparentales** en janvier 2011.

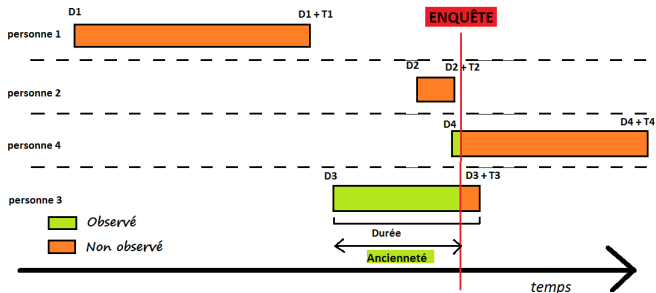
### Définition de la famille monoparentale :

Une famille monoparentale est composé d'un parent **sans conjoint cohabitant** ayant des **enfants mineurs** vivant dans le même logement.

- Grâce à une question sur leur dernier couple, on sait **depuis combien de temps** les adultes concernés sont en famille monoparentale. Mais on ne sais pas **combien de temps ils vont rester** en famille monoparentale.
- **Ancienneté** : "Depuis combien de temps est-on dans cette situation ?"
- **Durée** : "Combien de temps dure réellement cette situation ?"

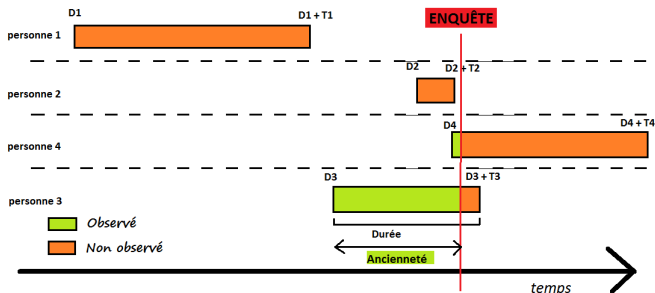






- **Effet de censure** : les anciennetés sont plus courtes que les durées, par définition.





- **Effet de censure** : les anciennetés sont plus courtes que les durées, par définition.
- **Effet de sélection** : les personnes restant longtemps dans la situation ont plus de chance d'être dans cette situation au moment de l'enquête.

## Questions :

- Quels sont les liens entre anciennetés et durées ?

Questions :

- Quels sont les liens entre anciennetés et durées ?
- Si les anciennetés du *groupe 1* sont en moyenne plus petites que les anciennetés du *groupe 2*, cela implique-t-il que les durées du *groupe 1* sont aussi en moyenne plus petites que celles du *groupe 2* ?

Questions :

- Quels sont les liens entre anciennetés et durées ?
- Si les anciennetés du *groupe 1* sont en moyenne plus petites que les anciennetés du *groupe 2*, cela implique-t-il que les durées du *groupe 1* sont aussi en moyenne plus petites que celles du *groupe 2* ?
- Peut-on inférer les durées à partir des anciennetés ? Quelles informations supplémentaires sont nécessaires à cette inférence ?


## Notations :

- $T$  : **Durée** de la situation étudiée.
- $D$  : Date de **début** de la situation.
- $E$  : Date de l'**enquête**.
- $A$  : **Ancienneté** de la situation au moment de l'enquête ( $A = E - D$ ).

- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais?
- 4 Estimations du modèle sur des simulations
- 5 Resultats avec l'Enquête Famille et Logement
- 6 Conclusion


# Variable de durée

- On simulera les durées à l'aide de la loi Gamma :  $T \sim \text{Gamma}(k, \lambda)$ .
- $k$  est le paramètre de *forme* et  $\lambda$  le paramètre d'*échelle*.



# Variable de durée


- On simulera les durées à l'aide de la loi Gamma :  $T \sim \text{Gamma}(k, \lambda)$ .
- $k$  est le paramètre de *forme* et  $\lambda$  le paramètre d'*échelle*.






# Variable de durée

- On simulera les durées à l'aide de la loi Gamma :  $T \sim \text{Gamma}(k, \lambda)$ .
- $k$  est le paramètre de *forme* et  $\lambda$  le paramètre d'*échelle*.






Effet **censure** plus fort ( $k > 1$ ) :


Temps moyen en années	
Ancienneté	4.4
FMP enquête	8.6
Réel	8

7.8% sont en FMP au moment de l'enquête.

Effet **censure** plus fort ( $k > 1$ ) :

Temps moyen en années	
Ancienneté	4.4
FMP enquête	8.6
Réel	8


7.8% sont en FMP au moment de l'enquête.

Effet **sélection** plus fort ( $k < 1$ ) :

Temps moyen en années	
Ancienneté	11.6
FMP enquête	23.5
Réel	8

7.7% sont en FMP au moment de l'enquête.

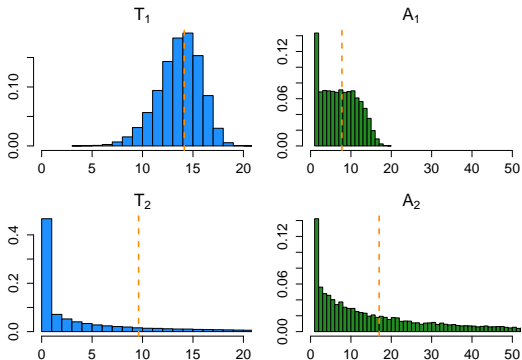
Ces deux effets s'annulent exactement si  $k = 1$  ( $T \sim \text{exponentielle}$ ) :







Temps moyen en années	
Ancienneté	7.9
FMP enquête	15.9
Réel	8

7.9% sont en FMP au moment de l'enquête.

- 2 groupes :  $T_i$  la durée *groupe i* et  $A_i$  son ancienneté.
- On peut avoir  $\mathbb{E}[A_1] < \mathbb{E}[A_2]$  MAIS  $\mathbb{E}[T_1] > \mathbb{E}[T_1]$ .



- Si les deux groupes ont les mêmes durées ( $T_1 = T_2$ ) ...
- ... on peut avoir  $\mathbb{E}[A_1] < \mathbb{E}[A_2]$ .



L'effet censure et l'effet sélection sont déterminés par :

- La forme de la densité de la variable de durée  $T$ .
- Le flux d'entrée en famille monoparentale.



- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais?**
- 4 Estimations du modèle sur des simulations
- 5 Resultats avec l'Enquête Famille et Logement
- 6 Conclusion

# Probabilité d'une observation

- $e$  : date de l'enquête (janvier 2011).
- Les **observations** sont les dates de début de monoparentalité  $d_1, \dots, d_n$  pour **ceux qui sont en famille monoparentale au moment de l'enquête**.
- Données discrètes : on n'observe que l'année de début de monoparentalité (ex : 1995, 2007, ...).
- $X$  : covariable représentant des caractéristiques individuelles (ex : sexe, catégorie sociale, ...)

# Probabilité d'une observation

On note  $S_T$  la **survie** de la variable de durée  $T$  :

$$S_T(t, x) = \mathbb{P}(T \geq t | X = x)$$

# Probabilité d'une observation

On note  $S_T$  la **survie** de la variable de durée  $T$  :

$$S_T(t, x) = \mathbb{P}(T \geq t | X = x)$$

$$\mathbb{P}(D_i = d_i | \text{FMP lors de l'enquête et } X = x_i)$$

# Probabilité d'une observation

On note  $S_T$  la **survie** de la variable de durée  $T$  :

$$S_T(t, x) = \mathbb{P}(T \geq t | X = x)$$

$$\begin{aligned} & \mathbb{P}(D_i = d_i | \text{FMP lors de l'enquête et } X = x_i) \\ = & \mathbb{P}(D_i = d_i | D_i \leq e < D_i + T_i \text{ et } X = x_i) \end{aligned}$$

# Probabilité d'une observation

On note  $S_T$  la **survie** de la variable de durée  $T$  :

$$S_T(t, x) = \mathbb{P}(T \geq t | X = x)$$

$$\begin{aligned} & \mathbb{P}(D_i = d_i | \text{FMP lors de l'enquête et } X = x_i) \\ = & \mathbb{P}(D_i = d_i | D_i \leq e < D_i + T_i \text{ et } X = x_i) \\ = & \frac{S_T(e - d_i, x_i) \mathbb{P}(D_i = d_i | X = x_i)}{\int_u S_T(e - u, x_i) \mathbb{P}(D = u | X = x_i) du} \end{aligned}$$

# Probabilité d'une observation

On note  $S_T$  la **survie** de la variable de durée  $T$  :

$$S_T(t, x) = \mathbb{P}(T \geq t | X = x)$$

$$\begin{aligned} & \mathbb{P}(D_i = d_i | \text{FMP lors de l'enquête et } X = x_i) \\ = & \mathbb{P}(D_i = d_i | D_i \leq e < D_i + T_i \text{ et } X = x_i) \\ = & \frac{S_T(e - d_i, x_i) \mathbb{P}(D_i = d_i | X = x_i)}{\int_u S_T(e - u, x_i) \mathbb{P}(D = u | X = x_i) du} \end{aligned}$$

**Hypothèse 1 :**

$T$  et  $D$  sont indépendantes

# Si $D$ est uniforme

Si  $D \sim \text{uniforme}$ , alors la densité de l'ancienneté peut s'écrire :

$$f_A(x) = \frac{S_T(x)}{\mathbb{E}[T]}$$

- si  $T \sim \text{exponentielle}$ ,  $f_A(x) = f_T(x) \rightarrow A$  et  $T$  ont la même densité !



Si  $D$  est uniforme

Si  $D \sim \text{uniforme}$ , alors la densité de l'ancienneté peut s'écrire :

$$f_A(x) = \frac{S_T(x)}{\mathbb{E}[T]}$$

- si  $T \sim \text{exponentielle}$ ,  $f_A(x) = f_T(x) \rightarrow A$  et  $T$  ont la **même densité** !

## Modélisation à partir du risque instantané

On note  $h$  le **risque instantané** associé à la variable  $T$  :

$$h(t, x) = \mathbb{P}(T = t | T \geq t \text{ et } X = x)$$

## Modélisation à partir du risque instantané

On note  $h$  le **risque instantané** associé à la variable  $T$  :

$$h(t, x) = \mathbb{P}(T = t | T \geq t \text{ et } X = x)$$

On a alors :

$$S_T(t, x) = \prod_{\tau=0}^{t-1} (1 - h(\tau, x))$$

## Modélisation à partir du risque instantané

On note  $h$  le **risque instantané** associé à la variable  $T$  :

$$h(t, x) = \mathbb{P}(T = t | T \geq t \text{ et } X = x)$$

On a alors :

$$S_T(t, x) = \prod_{\tau=0}^{t-1} (1 - h(\tau, x))$$

Approche de S.Nickell dans "*Estimating the probability of leaving unemployment*" (1979) :

$$h(t, x) = \frac{1}{1 + \exp(\beta x + \alpha_1 t + \alpha_2 t^2)}$$

## Modélisation à partir du risque instantané

On note  $h$  le **risque instantané** associé à la variable  $T$  :

$$h(t, x) = \mathbb{P}(T = t | T \geq t \text{ et } X = x)$$

On a alors :

$$S_T(t, x) = \prod_{\tau=0}^{t-1} (1 - h(\tau, x))$$

Approche de S.Nickell dans "*Estimating the probability of leaving unemployment*" (1979) :

$h(t, x) = \frac{1}{1 + \exp(\beta x + \alpha_1 t + \alpha_2 t^2)}$  → ça ne convient pas ici. Ce n'est pas assez flexible .

## Modélisation à partir du risque instantané

On note  $h$  le **risque instantané** associé à la variable  $T$  :

$$h(t, x) = \mathbb{P}(T = t | T \geq t \text{ et } X = x)$$

On a alors :

$$S_T(t, x) = \prod_{\tau=0}^{t-1} (1 - h(\tau, x))$$


Approche de S.Nickell dans "*Estimating the probability of leaving unemployment*" (1979) :

$h(t, x) = \frac{1}{1 + \exp(\beta x + \alpha_1 t + \alpha_2 t^2)}$  → ça ne convient pas ici. Ce n'est pas assez flexible .

**Hypothèse 2 : risques instantanés proportionnels**

$$h(t, x) = h_0(t) e^{\beta x}$$

On modélise le risque instantané de base,  $h_0$ , par une fonction **constante par morceaux**.




On peut choisir :

- la taille du pas élémentaire (5 ans sur la figure).
- le nombre de pas élémentaire (4 pas sur la figure).

# Estimation de $\mathbb{P}(D)$ .

La probabilité  $\mathbb{P}(D)$  est proportionnelle aux **flux d'entrée** en famille monoparentale. → on utilise ici une source annexe : l'Étude des Relations Familiales et Intergénérationnelles (ERFI).




**Figure:** Estimation de la probabilité d'entrer en famille monoparentale. Champ : personnes âgées de 18 à 73 ans en 2005, France métropolitaine. Source : ERFI, vagues 1-3.



# Estimation de $\mathbb{P}(D)$ .

La probabilité  $\mathbb{P}(D)$  est proportionnelle aux **flux d'entrée** en famille monoparentale. → on utilise ici une source annexe : l'Étude des Relations Familiales et Intergénérationnelles (ERFI).



**Figure:** Estimation de la probabilité d'entrer en famille monoparentale. Champ : personnes âgées de 18 à 73 ans en 2005, France métropolitaine. Source : ERFI, vagues 1-3.

## Vraisemblance

Vraisemblance des observations  $d_1, \dots, d_n$

$$\prod_{i=1}^n \left[ \frac{\hat{f}_D^{Erfi}(d_i, x_i) \prod_{\tau=0}^{2010-d_i} (1 - h_0(\tau)e^{\beta x_i})}{\sum_{u \leq 2010} \left[ \hat{f}_D^{Erfi}(u, x_i) \prod_{\tau=0}^{2010-u} (1 - h_0(\tau)e^{\beta x_i}) \right]} \right]$$

- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais?
- 4 Estimations du modèle sur des simulations**
- 5 Resultats avec l'Enquête Famille et Logement
- 6 Conclusion

Figure: Effet censure.

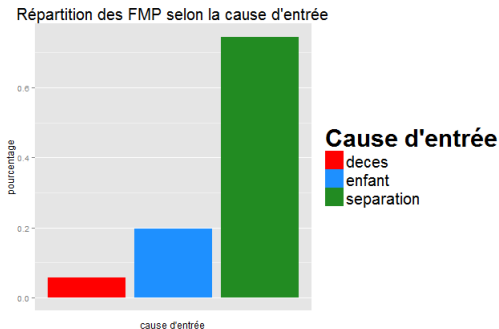
Figure: Effet sélection.

- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais?
- 4 Estimations du modèle sur des simulations
- 5 Resultats avec l'Enquête Famille et Logement**
- 6 Conclusion


- Sur 360000 adultes interrogés, 12519 sont déterminés comme étant en FMP.
- 1073 hommes et 11446 femmes.

- Sur 360000 adultes interrogés, 12519 sont déterminés comme étant en FMP.
- 1073 hommes et 11446 femmes.


Champ : personnes de 18 ou plus en 2011 étant en FMP lors de l'enquête, France métropolitaine.  
Source : EFL



# Population entière




**Figure:** Estimation du risque instantané de quitter la situation de monoparentalité (source : EFL) .




**Figure:** Estimation de la fonction de survie (source : EFL).



# Différence selon le sexe




**Figure:** Estimation du risque instantané de quitter la situation de monoparentalité selon le sexe (source : EFL) .




**Figure:** Estimation de la fonction de survie selon le sexe (source : EFL).

# Différence selon le sexe



**Figure:** Estimation du risque instantané de quitter la situation de monoparentalité selon le sexe (source : EFL) .

→ on ne retient pour la suite que l'analyse des **femmes** en famille monoparentale.



**Figure:** Estimation de la fonction de survie selon le sexe (source : EFL).

## Niveau de diplôme atteint au moment de l'enquête


4 niveaux de diplôme (aucun diplôme, diplômes de niveau inférieur au bac, diplômes équivalents au bac, diplômes de niveau supérieur au bac) .

$$h(t, x) =$$

$$h_0(t) \exp(\beta_{bac-} \mathbb{1}(DIP=Bac-) + \beta_{bac} \mathbb{1}(DIP=Bac) + \beta_{bac+} \mathbb{1}(DIP=Bac+))$$

Coefficient	Valeur	IC à 95%
$\beta_{bac-}$	0.12	(0.061, 0.18)
$\beta_{bac}$	0.25	(0.18, 0.32)
$\beta_{bac+}$	-0.0005	(-0.07, 0.07)

Catégorie de référence : aucun diplôme




Champ : Femmes de plus de 18 ans en 2011,  
France métropolitaine. Source : EFL

## Catégorie sociale au moment de l'enquête

Coefficient	Valeur	IC à 95%
$\beta_{\text{agriculteur}}$	-0.35	(-0.93, 0.23)
$\beta_{\text{artisan}}$	-0.014	(-0.15, 0.12)
$\beta_{\text{cadre}}$	-0.11	(-0.23, 0.003)
$\beta_{\text{prof. inter.}}$	-0.14	(-0.23, -0.05)
$\beta_{\text{employé}}$	-0.03	(-0.11, 0.045)

Catégorie de référence : ouvrier

Champ : Femmes de plus de 18 ans en 2011,  
France métropolitaine. Source : EFL




## Cause d'entrée en famille monoparentale

Coefficient	Valeur	IC à 95%
$\beta_{\text{séparation}}$	0.64	(0.57, 0.7)
$\beta_{\text{décès}}$	0.54	(0.44, 0.63)

Catégorie de référence : enfant

Champ : Femmes de plus de 18 ans en 2011,  
France métropolitaine. Source : EFL



## Comparaison avec ERFI

- avantage : pas d'effet de sélection → modèles de durée classiques avec censure à droite.
- inconvénient : effectif plus restreint (1677 personnes ayant vécu une situation de monoparentalité)

Figure: Comparaison entre la survie estimée avec l'EFL et la survie estimée avec ERFI

- 1 Introduction
- 2 Relations entre anciennetés et durées
- 3 Comment rectifier les biais?
- 4 Estimations du modèle sur des simulations
- 5 Resultats avec l'Enquête Famille et Logement
- 6 Conclusion**

# Discussion des hypothèses

- ① T et D indépendants : les simulations montrent que
- $\text{corr}(T, D) < 0$ , on sous-estime la survie
  - $\text{corr}(T, D) > 0$ , on sur-estime la survie

On observe dans ERFI une **corrélation négative** entre  $T$  et  $D$ .



# Discussion des hypothèses

- 1 T et D indépendants : les simulations montrent que
  - $\text{corr}(T, D) < 0$ , on sous-estime la survie
  - $\text{corr}(T, D) > 0$ , on sur-estime la survie

On observe dans ERFI une **corrélation négative** entre  $T$  et  $D$ .

- 2 Risques instantanés proportionnels :

# Discussion des hypothèses

- 1 T et D indépendants : les simulations montrent que
  - $\text{corr}(T, D) < 0$ , on sous-estime la survie
  - $\text{corr}(T, D) > 0$ , on sur-estime la survie

On observe dans ERFI une **corrélation négative** entre  $T$  et  $D$ .

- 2 Risques instantanés proportionnels :
- 3 Covariables indépendantes du temps : la catégorie sociale, le diplôme peuvent changer au cours du temps.

# Discussion des hypothèses

- 1 T et D indépendants : les simulations montrent que
  - $\text{corr}(T, D) < 0$ , on sous-estime la survie
  - $\text{corr}(T, D) > 0$ , on sur-estime la survie

On observe dans ERFI une **corrélation négative** entre  $T$  et  $D$ .

- 2 Risques instantanés proportionnels :
- 3 Covariables indépendantes du temps : la catégorie sociale, le diplôme peuvent changer au cours du temps.
- 4 Possibilité d'estimer  $f_D$  : il faut une source annexe.

# Questions ?