

MODÈLES MULTI-ÉTATS MARKOVIENS ET SEMI-MARKOVIENS

PHILIPPE SAINT PIERRE

IMT, Equipe de Statistique et Probabilités

Université Paul Sabatier - Toulouse III

ECOLE CIMPA, LOMÉ, SEPTEMBRE 2018

ANALYSE DE SURVIE MULTIVARIÉE

PLUSIEURS DURÉES DÉPENDANTES

- **Plusieurs durées** pour un individu
 - Durée sans trouble oculaire avec un traitement différent dans chaque oeil
 - Fiabilité de deux composants d'une machine
 - Événements récurrents : crise d'asthme
 - Événements concurrents : sortie d'une période sans emploi
- **Une durée** pour **plusieurs individus** d'un même groupe
 - Durées de vie jumeaux ou d'un couple

CONTEXTE

- Données **censurées à droite**
- **Pas d'indépendance** : $\mathbb{P}(T > t, U > u) \neq \mathbb{P}(T > t) \times \mathbb{P}(U > u)$
- On ne peut pas analyser ces données avec les modèles de survie classiques

ANALYSE DE SURVIE MULTIVARIÉE

- Hougaard (2000).

ESTIMATION NON-PARAMÉTRIQUE

- Estimation de la fonction de survie multivariée

$$S(t, u) = \mathbb{P}(T > t, U > u)$$

- Aucune hypothèse sur la forme de la fonction de survie
- Dabrowska (1988), Prentice, Moodie et Wu (2004), Lopez et Saint-Pierre (2012), ...
- Méthodologie, implémentation et interprétation compliquées

COPULE DE SURVIE

- Estimation de la fonction de survie multivariée

$$S(t, u) = \mathbb{P}(T > t, U > u)$$

- On montre que

$$\begin{aligned} S(t, u) &= S_1(t) + S_2(u) - 1 + F(t, u) \\ &= S_1(t) + S_2(u) - 1 + C(1 - S_1(t), 1 - S_2(u)) \\ &= \mathcal{C}(S_1(t), S_2(u)) \end{aligned}$$

où C est une copule et \mathcal{C} est une **copule de survie**

- Estimation survie marginales avec l'estimateur de Kaplan-Meier
- Estimation du paramètres de copule par maximum de vraisemblance ou méthodes bayésiennes

MODÈLES DE FRAGILITÉ

- Introduction d'un terme de **fragilité** dans le modèle de Cox

$$\alpha(t|Z_{ij}, \omega_i) = \alpha_0(t) \omega_i \exp(\beta Z_{ij})$$

Z_{ij} covariable de l'individu j du **groupe i**


ω_i variable aléatoire *i.i.d.*

- L'**effet aléatoire** est commun aux individus d'un même groupe et différent d'un groupe à l'autre
- Permet de prendre en compte la **dépendance** entre les temps d'événement des individus d'un même groupe
- Ajustement sur les variables qui ne sont pas incluses dans le modèle (non mesurées ou non observées)
- Cas **bivariée** correspond à des groupes de deux individus


MODÈLES MULTI-ÉTATS

Survie multivariée : durées de vie de deux jumeaux


Modèle 1




Modèle 2



Modèle 3



Modèle 4




Analyse de survie




Événements répétés




Événements concurrents



Épidémiologie : représenter l'évolution d'un patient à travers les différents stades d'une maladie




Science sociale : représenter l'évolution de la situation professionnelle ou familiale



TYPE DE DONNÉES

- Données de **cohorte**, données **longitudinales**
- **Mesures répétées** dans le temps : la même variable est mesurée plusieurs fois pour un même individu
- Mesures effectuées à des moments quelconques (spécifiques à chaque individu)



MODÈLES MULTI-ÉTATS

- Les **modèles multi-états** permettent de modéliser ce type de données
- Notions d'état et de processus pour représenter l'évolution d'un phénomène
- L'analyse consiste à estimer les **intensités de transition** entre les états

- **Propriété de Markov** : l'information sur les états précédents est résumée par l'état présent
- Les intensités de transition α peuvent dépendre de deux échelles de temps :
 - la durée du suivi t (ou le temps calendaire, l'âge),
 - le temps de séjour d

| | | |
|-------------------------------|---|---|
| $\alpha(t, d) = \alpha$ | → | Modèle de Markov homogène |
| $\alpha(t, d) = \alpha(t)$ | → | Modèle de Markov non-homogène |
| $\alpha(t, d) = \alpha(d)$ | → | Modèle semi-Markovien homogène |
| $\alpha(t, d) = \alpha(t, d)$ | → | Modèle semi-Markovien non-homogène |

MODÈLE DE MARKOV

PROCESSUS DE MARKOV

- $\{X(t), t \in [0, +\infty[\}$ un **processus de Markov** à temps continu et à espace d'états fini $S = \{1, \dots, s\}$
- Probabilités de transition $\mathbf{P}(s, t) = \{p_{hj}(s, t)\}$

$$p_{hj}(s, t) = \mathbb{P}(X(t) = j \mid X(s) = h)$$

- Intensités de transition entre les états, $\mathbf{Q}(t) = \{\alpha_{hj}(t)\}$

$$\alpha_{hj}(t) = \lim_{\Delta t \rightarrow 0} \frac{p_{hj}(t, t + \Delta t)}{\Delta t}, \quad h \neq j$$

$$\alpha_{hh}(t) = - \sum_{j \neq h} \alpha_{hj}(t)$$

- Considérons $X_1(\cdot), \dots, X_n(\cdot)$, n copies indépendantes de $X(\cdot)$

MODÈLE DE MARKOV HOMOGENÈ

- La matrice des probabilités de transition

$$\mathbf{P}(s, s + \Delta t) = \mathbf{P}(0, \Delta t) = \exp(\mathbf{Q} \times \Delta t)$$

- Intensités de transition : $\alpha_{hj}(t) = \alpha_{hj}$
- Modèle à risques proportionnels

$$\alpha_{hj} = \alpha_{hj0} \exp(\beta_{hj}^T \mathbf{Z}), \quad h \neq j$$

α_{hj0} intensité de transition de base

$\mathbf{Z} = (Z_1, \dots, Z_k)^T$ vecteur de k covariables associé à l'individu

$\beta_{hj} = (\beta_{hj,1}, \dots, \beta_{hj,k})^T$ vecteur de coefficients de régression associé à la transition de l'état h vers l'état j

MODÈLE DE MARKOV HOMOGENÈNE PAR PÉRIODE

- Intensités de transition définies sur $r + 1$ intervalles $[t_{k-1}, t_k[$

$$\begin{aligned} \alpha_{hj}(t) &= \alpha_{hj0} && \text{si } t_0 \leq t < t_1 \\ \alpha_{hj}(t) &= \alpha_{hjk} = \alpha_{hj0} \exp\left(\sum_{v=1}^k \gamma_{hj,v}\right) && \text{si } t_k \leq t < t_{k+1} \end{aligned}$$

$\forall k = 1, \dots, r$ et $t_{r+1} = +\infty$

α_{hjk} intensités de base dans l'intervalle $[t_k, t_{k+1}[$

$\gamma_{hj} = (\gamma_{hj,1}, \dots, \gamma_{hj,k})$ vecteur de coefficients de régression

- Les intensités sont **constantes** sur chaque intervalle
- Estimation des paramètres par maximum de vraisemblance

MODÈLE DE MARKOV NON-HOMOGÈNE

- Intensités de transition $\alpha_{hj}(t)$ dépendent de la durée du suivi
- $\mathbf{N} = (N_{hj}; h \neq j, h, j = 1, \dots, s)$ un processus de comptage multivarié

$N_{hj}(t)$ compte le nombre de transitions (dans toute la population) observées de h vers j dans $[0, t]$

- $\lambda = (\lambda_{hj}; h \neq j)$, intensité du processus \mathbf{N}

$$\lambda_{hj}(t) = \alpha_{hj}(t)Y_h(t), \forall h \neq j$$

$Y_h(t) = \sum_{i=1}^n \mathbb{1}_{\{X_i(t^-)=h\}}$ est le nombre total d'individus observés dans h juste avant t (individus à risque)

MODÈLE DE MARKOV NON-HOMOGÈNE

- $\mathbf{A}(\mathbf{t}) = \{A_{hj}(t)\}$, la matrice des intensités cumulées

$$A_{hj}(t) = \int_0^t \alpha_{hj}(s) ds$$

- La matrice des probabilités de transition $\mathbf{P}(s, t) = \{p_{hj}(s, t)\}$ est définie par le produit intégral

$$\mathbf{P}(s, t) = \prod_{u \in]s, t]} (\mathbf{Id} + d\mathbf{A}(u))$$

Id matrice identité

ESTIMATION NON-PARAMETRIQUE

- Estimateur de **Nelson-Aalen** des intensités cumulées

$$\widehat{A}_{hj}(t) = \int_0^t \frac{J_h(u)}{Y_h(u)} dN_{hj}(u), \quad \forall h \neq j$$

$$J_h(t) = \mathbf{1}_{\{Y_h(t) > 0\}}$$

- Estimateur de **Aalen-Johansen** de la matrice des probabilités de transition

$$\widehat{\mathbf{P}}(s, t) = \prod_{u \in]s, t]} \left(\mathbf{Id} + d\widehat{\mathbf{A}}(u) \right), \quad 0 < s \leq t$$

$\widehat{\mathbf{A}}$ estimateur de Nelson-Aalen

- Comparaison des intensités obtenues dans différents groupes (test du Log-rank)

ESTIMATION SEMI-PARAMÉTRIQUE

- Les intensités de transition suivent un modèle à risques proportionnels

$$\alpha_{hji}(t | \mathbf{Z}_i) = \alpha_{hj0}(t) \exp(\beta_{hj}^T \mathbf{Z}_i) \quad , h \neq j$$

- Sachant β , l'estimateur de Breslow


$$\hat{A}_{hj0}(t) = \int_0^t \frac{J_h(u)}{\sum_{i=1}^n \exp(\beta_{hj}^T \mathbf{Z}_i) Y_{hi}(t)} dN_{hj}(u),$$

- β estimé par maximisation de la vraisemblance partielle de Cox

$$\mathcal{L}_{Cox}(\beta) = \prod_t \prod_{i=1} \prod_{h \neq j} \left[\frac{Y_{hi}(t) \exp(\beta_{hj}^T \mathbf{Z}_i)}{\sum_{i=1}^n \exp(\beta_{hj}^T \mathbf{Z}_i) Y_{hi}(t)} \right]^{\Delta N_{hji}(t)}$$

MODÈLE SEMI-MARKOVIEEN HOMOGÈNE

- Modèle Markovien inadapté \implies Approche semi-Markovienne
- Soit $(J_n, S_n)_{n \geq 0}$ un processus semi-Markovien



- $(J_n)_{n \geq 0}$ est une chaîne de Markov homogène
- $X_n = S_n - S_{n-1}$, le temps de séjour dans l'état J_{n-1}
- $J_n \neq J_{n+1}$

- Probabilités de transition de la chaîne de Markov $(J_n)_{n \geq 0}$

$$p_{hj} = \mathbb{P}(J_{n+1} = j \mid J_n = h)$$

- Distribution du temps de séjour (dans l'état h avant d'aller dans l'état j)

$$F_{hj}(d) = \mathbb{P}(X_{n+1} \leq d \mid J_n = h, J_{n+1} = j)$$

$\implies S_{hj}(x), f_{hj}(x), \alpha_{hj}(x)$ (fonctions de survie, de densité et d'intensité correspondantes)

- Intensités de transition du processus semi-Markovien

$$\lambda_{hj}(d) = \lim_{\Delta d \rightarrow 0} \frac{1}{\Delta d} \mathbb{P}(J_{n+1} = j, d < X_{n+1} \leq d + \Delta d \mid J_n = h, X_{n+1} > d)$$

$$= \begin{cases} \frac{p_{hj}f_{hj}(d)}{S_h(d)} & \text{si } S_h(d) = \sum_{j=1}^S p_{hj}S_{hj}(d) > 0 \\ 0 & \text{sinon} \end{cases}$$

VRAISEMBLANCE

- Contributions à la vraisemblance

- Transition de $h \rightarrow j$ observée : $S_h(d)\lambda_{hj}(d) = p_{hj}f_{hj}(d)$
- Censure à droite dans l'état h : $S_h(d)$

- Vraisemblance

$$L = \prod_{i=1}^n \left\{ \prod_{k=1}^{n_i} p_{J_{i,k-1}J_{i,k}} f_{J_{i,k-1}J_{i,k}}(X_{i,k}) \right\} \times \left[S_{J_{i,n_i}}(U_i) \right]^{\delta_i}$$

$\delta_i = 1$ si l'individu i est censuré et 0 sinon

U_i le temps de séjour censuré pour l'individu i si $\delta_i = 1$

n_i le nombre de transitions pour l'individu i

ESTIMATION PARAMÉTRIQUE

- Modélisation des distributions des **temps de séjour** par des **lois paramétriques**
- Modèle à risques proportionnels pour les intensités des temps de séjour

$$\alpha_{hj}(d | \mathbf{Z}) = \alpha_{hj0}(d) \exp(\beta_{hj}^T \mathbf{Z})$$

α_{hj0} risque d'une loi de Weibull, Weibull généralisée, ...

\mathbf{Z} vecteur des covariables

β_{hj} vecteur des coefficients de régression

- Estimation des paramètres par maximisation de la vraisemblance

APPLICATION À L'ASTHME

PACKAGES DU LOGICIEL

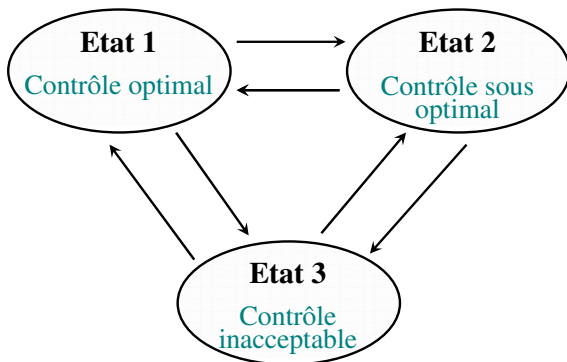
- CRAN Task View : *Survival Analysis*
- Modèle Markovien homogène : *msm*
- Modèle Markovien non homogène : *etm, mstate, msSurv*
- Modèle semi-Markovien homogène : *SemiMarkov*

BASE DE DONNÉES

- 406 patients asthmatiques
4.15 consultations par patient en moyenne
Reculs de 3 mois à quatre ans
- Notion de **contrôle** : jugement global du médecin sur l'activité de la maladie
- Etude de l'**Indice de Masse Corporelle (IMC)**
 - $IMC = poids / (taille)^2$
 - 2 modalités : $IMC < 25$ et $IMC \geq 25$ (surpoids)


MODÈLE

- Modèle à 3 états de contrôle
- Toutes les transitions entre les états sont possibles



Modèle homogène


- Probabilités de transition $3 \rightarrow 1$ pour la covariable IMC



- Modèle homogène par période (2 périodes)
 - ⇒ Meilleur ajustement aux données
 - ⇒ L'hypothèse d'homogénéité semble trop restrictive

Modèle non-homogène


- Probabilités de transition 3 \rightarrow 1 pour la covariable IMC




Modèle non-homogène

- Estimations dans un modèle **homogène** et **non-homogène**

Probabilités de transition 1 vers 3




Probabilités de transition 3 vers 1



Modèle semi-Markovien

- Estimations paramétriques des intensités $3 \rightarrow 1$ du processus semi-Markovien pour la covariable IMC



Coefficients de régression de l'IMC

- Coefficients de régression pour la covariable IMC

| Transition | Modèle MH | | | Modèle MNH | | |
|------------|---------------|--------------|-----------------|---------------|--------------|-----------------|
| | $\hat{\beta}$ | <i>E.T.</i> | <i>p</i> -value | $\hat{\beta}$ | <i>E.T.</i> | <i>p</i> -value |
| 1 → 2 | -0.409 | 0.383 | 0.02 | -0.248 | 0.236 | 0.28 |
| 1 → 3 | -0.122 | 0.269 | 0.71 | 0.655 | 0.303 | 0.03 |
| 2 → 1 | 0.542 | 0.364 | <0.01 | -0.030 | 0.203 | 0.88 |
| 2 → 3 | 0.041 | 0.378 | 0.87 | 0.204 | 0.249 | 0.42 |
| 3 → 1 | -1.170 | 0.370 | <0.01 | -0.595 | 0.220 | <0.01 |
| 3 → 2 | -0.561 | 0.293 | <0.01 | -0.234 | 0.191 | 0.21 |

- Effet de l'IMC également significatif pour la transition 3 → 1
 - par stratification
 - avec l'IMC dépendant du temps
 - avec le modèle semi-Markovien


Coefficients de régression de l'IMC

● Modèle Markov homogène avec 2 états de contrôle

| Transition | Covariables | Modèle univarié | | | Modèle multivarié | | |
|------------|-------------------------|-----------------|--------------|-----------------|-------------------|--------------|-----------------|
| | | $\hat{\beta}$ | E.T. | p-value | $\hat{\beta}$ | E.T. | p-value |
| 1 → 2 | IMC | -0.129 | 0.247 | 0.60 | -0.174 | 0.278 | 0.53 |
| | Sévérité | 0.665 | 0.272 | 0.04 | 0.820 | 0.305 | <0.01 |
| | Corticoïdes Oraux | 0.110 | 0.269 | 0.68 | -0.422 | 0.305 | 0.17 |
| | Antécédents Corticoïdes | 0.651 | 0.262 | 0.01 | 0.498 | 0.299 | 0.10 |
| 2 → 1 | IMC | -0.801 | 0.184 | <0.01 | -0.637 | 0.219 | <0.01 |
| | Sévérité | -0.726 | 0.203 | <0.01 | -0.062 | 0.255 | 0.81 |
| | Corticoïdes Oraux | -1.002 | 0.209 | <0.01 | -0.693 | 0.248 | <0.01 |
| | Antécédents Corticoïdes | -0.852 | 0.212 | <0.01 | -0.312 | 0.266 | 0.24 |

⇒ Résultats ajustés

DISCUSSION

- Méthodes adaptées pour modéliser des données de survie multivariée
 - Résultats facilement interprétables en pratique
 - Packages 
 - Hypothèses sous-jacentes (Markov, homogénéité, risques proportionnels, observation continue)
-
- Méthodes prenant en compte une censure par intervalles
 - Méthodes prenant en compte des effets aléatoires
 - Développer des méthodes adaptées à une censure informative