



Splines multidimensionnelles pénalisées dans les modèles de survie : applications en épidémiologie des cancers

Mathieu FAUVERNIER, Laurent ROCHE, Zoé UHRY, Laure TRON,
Nadine BOSSARD, Laurent REMONTET

EPICLIN 2019, TOULOUSE

Vendredi 17 Mai 2019

Contexte épidémiologique

Le **cancer** est la **première cause de mortalité** en France (30% des décès)

Pour un cancer donné, connaître les **facteurs pronostiques** de la **survie** est un enjeu majeur

Facteurs pronostiques = caractéristiques

- du patient
- de la maladie
- de la prise en charge
- de l'**environnement social et économique**

Contexte méthodologique

Survie nette : survie que l'on observerait si la seule cause de décès était le cancer étudié.

Au temps t , le taux de mortalité toutes causes $h_{ttc}(t)$ est décomposé ainsi :

$$h_{ttc}(t|\mathbf{X}, \mathbf{Z}) = h_{attendu}(t|\mathbf{Z}) + h_{excès}(t|\mathbf{X})$$

Avec \mathbf{X} les covariables d'intérêt et \mathbf{Z} les covariables démographiques.

Modélisation du taux en excès

$$\text{Log}[h_{excès}(t|\mathbf{X})] = f(t, \mathbf{X})$$

\mathbf{X} peut contenir : âge au diagnostic, année de diagnostic, indice de défavorisation socio-économique, stade, ...

Contexte méthodologique

Effet non linéaire : effet d'un an d'âge supplémentaire dépend de l'âge considéré

Effet non proportionnel : effet de l'âge dépend du temps de suivi considéré

Interaction : effet de l'année dépend de l'âge considéré

Modélisation complexe

Pour représenter f , il faut tenir compte simultanément des effets potentiellement non linéaires et non proportionnels des effets propres de chaque covariable, mais également des interactions !

Objectif

Proposer un modèle du taux de mortalité (en excès) à partir de splines multidimensionnelles pénalisées

Splines = polynômes par morceaux utilisés pour représenter des effets non linéaires

Cadre théorique développé par Wood et al. (2016) mais adaptation nécessaire aux modèles de taux en excès

Méthode - spline multidimensionnelle par produit tensoriel

Considérons un effet linéaire de l'âge (pour simplifier) :

$$f(a) = \alpha_0 + \alpha_1 \times a$$

Faisons varier l'intercept et la pente selon un effet quadratique g du temps : $g(t) = \gamma_0 + \gamma_1 \times t + \gamma_2 \times t^2$.

Méthode - spline multidimensionnelle par produit tensoriel

Considérons un effet linéaire de l'âge (pour simplifier) :

$$f(a) = \alpha_0 + \alpha_1 \times a$$

Faisons varier l'intercept et la pente selon un effet quadratique g du temps : $g(t) = \gamma_0 + \gamma_1 \times t + \gamma_2 \times t^2$.

L'effet bidimensionnel est alors donné par :

$$\text{tensor}(t, \text{age}) = \beta_0 + \beta_1 \times t + \beta_2 \times t^2 \quad (1)$$

$$+ (\beta_3 + \beta_4 \times t + \beta_5 \times t^2) \times a \quad (2)$$

Méthode - spline multidimensionnelle par produit tensoriel

Considérons un effet linéaire de l'âge (pour simplifier) :

$$f(a) = \alpha_0 + \alpha_1 \times a$$

Faisons varier l'intercept et la pente selon un effet quadratique g du temps : $g(t) = \gamma_0 + \gamma_1 \times t + \gamma_2 \times t^2$.

L'effet bidimensionnel est alors donné par :

$$\text{tensor}(t, \text{age}) = \beta_0 + \beta_1 \times t + \beta_2 \times t^2 \quad (1)$$

$$+ (\beta_3 + \beta_4 \times t + \beta_5 \times t^2) \times a \quad (2)$$

⇒ **Prise en compte de l'interaction temps*âge**

Méthode - spline multidimensionnelle par produit tensoriel

Considérons un effet linéaire de l'âge (pour simplifier) :

$$f(a) = \alpha_0 + \alpha_1 \times a$$

Faisons varier l'intercept et la pente selon un effet quadratique g du temps : $g(t) = \gamma_0 + \gamma_1 \times t + \gamma_2 \times t^2$.

L'effet bidimensionnel est alors donné par :

$$\text{tensor}(t, \text{age}) = \beta_0 + \beta_1 \times t + \beta_2 \times t^2 \quad (1)$$

$$+ (\beta_3 + \beta_4 \times t + \beta_5 \times t^2) \times a \quad (2)$$

⇒ **Prise en compte de l'interaction temps*âge**

Le principe est similaire avec plus de deux covariables.

Méthode - pénalisation

En règle générale, on n'utilise pas des polynômes linéaires ou quadratiques mais des splines cubiques.

Problèmes

- Le nombre de paramètres augmente fortement avec le nombre de facteurs pronostiques et la complexité des splines
- Les prédictions risquent d'être erratiques

Solution proposée

Pénalisation visant à lisser les prédictions

Méthode - vraisemblance pénalisée

On considère le temps comme seul prédicteur avec

$$\log[h_{\text{excès}}(t)] = f(t)$$

Si $l(\beta)$ est la log-vraisemblance du modèle et λ le paramètre de lissage, alors la log-vraisemblance pénalisée $l_p(\beta|\lambda)$ s'écrit :


$$l_p(\beta|\lambda) = l(\beta) - \lambda \text{pen} = l(\beta) - \lambda \int f''(t)^2 dt$$

Le critère objectif $l_p(\beta|\lambda)$ est un compromis entre la fidélité aux données $l(\beta)$ et la régularité de l'effet du temps $\int f''(t)^2 dt$.


λ est le paramètre qui contrôle ce compromis.

Pénalisation sur la dérivée seconde (pourquoi $\int f''(t)^2 dt$?)


intégrale = 18




intégrale = 89



intégrale = 249



intégrale = 873



Méthode - Estimation des paramètres de lissage

En pratique, **il y a autant de paramètres de lissage que de facteurs pronostiques** et il faut les estimer.

Deux approches sont possibles :

- **validation croisée** : cherche le modèle qui **minimise les erreurs de prédictions**
- **vraisemblance marginale** : approche bayésienne cherchant le modèle **le plus susceptible d'avoir généré les données**

Inégalités socio-économiques

Données: 1 865 patientes diagnostiquées d'un cancer du col de l'utérus entre 2006 et 2009 en France (données FRANCIM).

EDI = European Deprivation Index (variable continue, **valeur élevée = défavorisation élevée**)

Modèle:







$$\text{Log}[h_E(t, a, EDI)] = \text{tensor}(t, a, EDI)$$

- 5 nœuds par base marginale (temps, âge, EDI)
- Nombre de paramètres: $5*5*5 = 125$
- 3 paramètres de lissage

âge 35

âge 51

âge 80



Conclusion

Avantages

- Modélisation simultanée des effets non linéaires, non proportionnels et des interactions
- Restitution de formes très complexes en limitant : sélection de modèles, catégorisation de variables continues et sur-ajustement
- Sélection intégrée des paramètres de lissage stable et efficiente
- Forme entièrement paramétrique permettant la projection
- Cadre théorique commun (développé par Wood) pour les vraisemblances régulières
- **Nombreuses perspectives en recherche clinique**

Inconvénients

- Approche tensor limitée à 3 ou 4 covariables continues

La méthode est décrite par Fauvernier et al. (2019) et est implémentée dans le package R **survPen** disponible sur le CRAN et sur GitHub

Remerciements

Merci de votre attention

Nous tenons à remercier l'ANR (Agence Nationale de la Recherche) et l'Institut National du Cancer (INCa) pour avoir financé ce travail.
Nous remercions également Guy Launoy, Jacques Estève et le réseau FRANCIM.

Références

- Fauvernier, M., Roche, L., Uhry, Z., Tron, L., Bossard, N., Remontet, L., and the CENSUR working survival group (2019). Multidimensional penalized hazard model with continuous covariates: applications for studying trends and social inequalities in cancer survival. *in revision in the Journal of the Royal Statistical Society Series C Applied Statistics*.
- Wood, S. N., Pya, N., and Säfken, B. (2016). Smoothing parameter and model selection for general smooth models. *Journal of the American Statistical Association*, 111(516):1548–1563.