



Analyse des données fonctionnelles catégorielles. Le package R cfda

Cristian Preda, Quentin Grimonprez, Vincent Vandewalle

► To cite this version:

Cristian Preda, Quentin Grimonprez, Vincent Vandewalle. Analyse des données fonctionnelles catégorielles. Le package R cfda. JDS 2021 : 52èmes Journées de Statistique de la Société Française de Statistique (SFdS), Jun 2021, Nice, France. hal-03519016

HAL Id: hal-03519016

<https://inria.hal.science/hal-03519016>

Submitted on 10 Jan 2022

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Categorical functional data analysis. The *cfda* R package

Cristian Preda¹, Quentin Grimonprez², Vincent Vandewalle¹

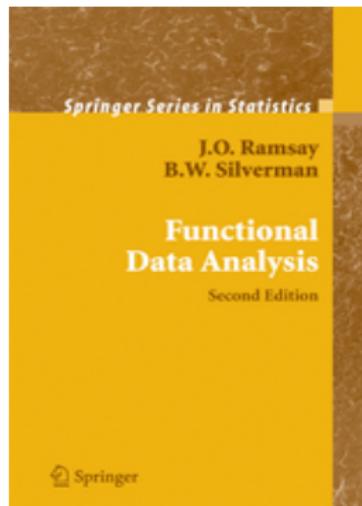
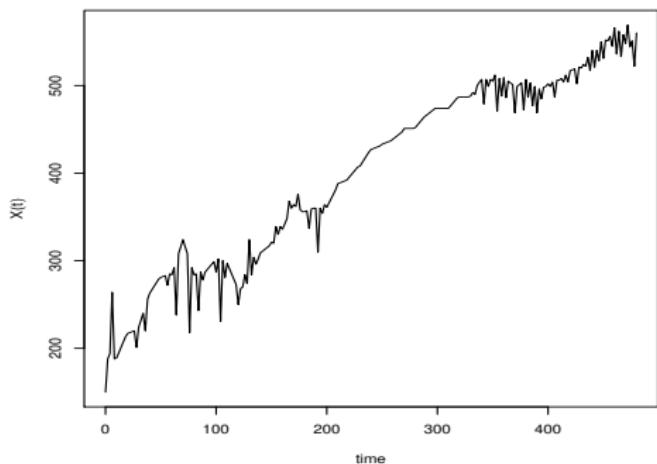
¹Université de Lille et MODAL/Inria Lille Nord-Europe

² DIAGRAMS Technologies

52^{èmes} Journées de Statistiques de la SFdS
Université Côte d'Azur, Nice
June 7-11, 2021

(Categorical) Functional Data

Most of considered functional data is **scalar** (univariate/multivariate) :



Model : Stochastic process, $X = \{X_t, t \in \mathcal{T}\}$,

$$X_t \in \mathbb{R}^p, p \geq 1,$$

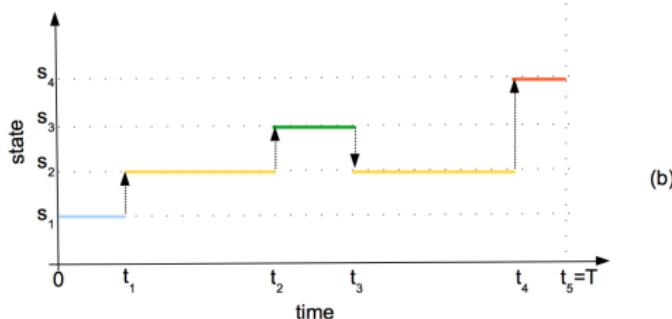
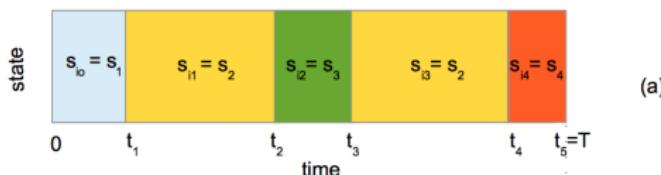
for some continuous index set \mathcal{T}

Categorical functional data

Set of states : $\mathcal{S} = \{s_1, s_2, \dots, s_K\}$, $K \geq 2$

$$X_t : \Omega \rightarrow \mathcal{S}.$$

A path of X on $[0, T]$ is a sequence of states s_{i_j} and times points t_j :
 $\{(0 = t_0, s_{i_0}), (t_1, s_{i_1}), (t_2, s_{i_2}), \dots, (t_p = T, s_{i_p})\}$,



Categorical functional data

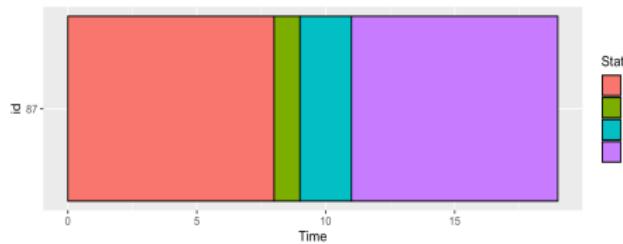
An example : Paths of infected patients.

$$\mathcal{S} = \{D, C, T, S\},$$

- D = patient has no follow-up
- C = patient has a follow-up but no treatment
- T = the patient has a medical follow-up with a treatment but the infection is not suppressed
- S = the patient has a medical follow-up with a treatment and the infection is suppressed.

A path on $[0, 19]$:

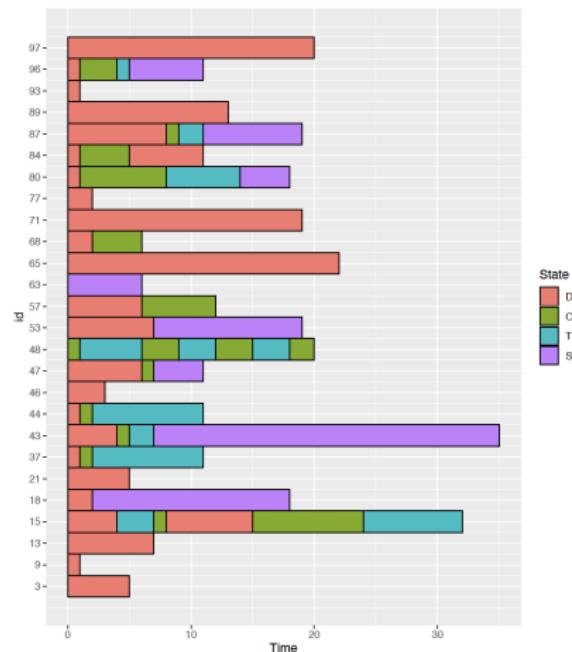
time	state
0	D
8	C
9	T
11	S
19	S



Categorical functional data

An example : Paths of infected patients.

Several paths :



Categorical functional data

The seminal work of Jean-Claude Deville (1982)

Analyse de données chronologiques qualitatives : comment analyser des calendriers ?, Annales de l'INSEE, No. 45, p. 45-104.

ANNALES DE L'INSEE — N° 45-1982

Analyses de données chronologiques qualitatives : comment analyser des calendriers?

par Jean-Claude DEVILLE*

* J. C. Deville, statisticien au sein de l'INSEE. Cet article est le résultat d'un travail collectif. La mise en pratique de la méthode qui est présentée ici s'est faite dans le cadre d'un groupe de travail de l'ENSAE au cours d'années universitaires 1979-1980. Sans Benoît Hézay, André Thévenin, et Olivier Savigny ce travail ne serait pas ce qu'il est. On doit aussi remercier Gilbert Flionne, qui nous a rejoint en cours d'étude dans le cadre de son DEE. Régis Bouvier a été pour nous un solide coup de main, démontre qu'il était de voir comment les idées développées dans cet article pouvaient se transformer en des réalisations concrètes. On doit aussi, naturellement, citer Gilbert Sauvageau, pour ses conseils et ces techniques ont été constamment discutées et pratiquées depuis un bon moment.

La statistique descriptive des processus aléatoires est un domaine à peu près vierge. Cet article montre comment décrire un ensemble d'individus caractérisés par une carrière, c'est-à-dire, par une évolution dans un ensemble d'états fini. En utilisant judicieusement des méthodes d'analyse factorielle, on aboutit à des représentations, optimales en un certain sens, des individus et des états du processus dans un espace euclidien de dimension finie arbitraire. L'exemple traité concerne l'évolution, entre 15 et 45 ans, de l'état matrimonial d'un groupe de femmes.

Categorical functional data

Other pioneer works

- ▶ Boumaza Rachid (1980). Contribution à l'Étude Descriptive d'une Fonction Aléatoire Qualitative. Ph.D. thesis, Université Paul Sabatier, Toulouse.

- ▶ Deville Jean-Claude, Saporta Gilbert (1983). Correspondence Analysis with an Extension towards Nominal Time Series. Journal of Econometrics, 22, pages 169–189.

Categorical functional data analysis

Dimension reduction by optimal encoding and principal components

Idea : find $z \in L_2(\Omega)$ that maximizes

$$\int_0^T \eta^2(z; X_t) dt,$$

with $\eta^2(z; X_t) = \frac{\text{var}(\mathbb{E}_t(z))}{\text{var}(z)}$ and $\mathbb{E}_t(z) = \mathbb{E}(z|X_t)$.

Solution :

$$\int_0^T \mathbb{E}_t(z) dt = \lambda z.$$

$\{(\lambda_i, z_i)\}_{i \geq 1}$ such that $\lambda_1 \geq \lambda_2 \geq \dots \geq 0$ and

$$\int_0^T \mathbb{E}_t(z_i) dt = \lambda_i z_i.$$

Categorical functional data analysis

Dimension reduction by optimal encoding and principal components

Optimal encoding functions : a^x , $x \in \mathcal{S}$:

$$z = \int_0^T \sum_{x \in \mathcal{S}} a^x(t) \mathbf{1}_t^x dt,$$

with

$$\int_0^T \sum_{y \in \mathcal{S}} p^{x,y}(t, s) a^y(s) ds = \lambda a^x(t) p^x(t), \quad \forall t \in [0, T], \forall x \in \mathcal{S},$$

where $p^x(t) = \mathbb{P}(X_t = x)$ and $p^{x,y}(t, s) = \mathbb{P}(X_t = x, X_s = y)$.
under the constraint :

$$\int_0^T \sum_{x \in \mathcal{S}} [a^x(t)]^2 p^x(t) dt = 1.$$

Categorical functional data analysis

Two expansion formulas

$$\mathbf{1}_t^x = \sum_{i \geq 1} z_i a_i^x(t) \frac{1}{p^x(t)}, \quad \forall x \in \mathcal{S}.$$

and

$$p^{x,y}(t, s) = p^x(t)p^y(s) \sum_{i \geq 1} \lambda_i a_i^x(t) a_i^y(s),$$

$$\forall t, s \in [0, T], \forall x, y \in \mathcal{S}.$$

In particular, for $x = y$ and $s = t$ we obtain

$$p^x(t) = \left\{ \sum_{i \geq 1} \lambda_i [a_i^x(t)]^2 \right\}^{-1}, \quad \forall t \in [0, T], \forall x \in \mathcal{S}.$$

Categorical functional data analysis

Approximation

Let $\{\phi_1, \dots, \phi_m\}$, $\phi_i : [0, T] \rightarrow \mathbb{R}$, $i = 1, \dots, m$, be a basis of functions (Fourier, B-splines, monomial, etc.) and for each $x \in \mathcal{S}$ consider the approximation :

$$a^x(t) \approx \alpha_{(x,1)}\phi_1(t) + \alpha_{(x,2)}\phi_2(t) + \dots + \alpha_{(x,m)}\phi_m(t), \quad \forall t \in [0, T],$$

where $\alpha_x = (\alpha_{(x,1)}, \alpha_{(x,2)}, \dots, \alpha_{(x,m)})'$ $\in \mathbb{R}^m$.

Let $\alpha \in \mathbb{R}^{m \times K}$ be the column vector obtained by the concatenation of the vectors $\{\alpha_x\}_{x \in \mathcal{S}}$

Categorical functional data analysis

Approximation

Then,

$$G\alpha = \lambda F\alpha,$$

under the constraint

$$\alpha' F\alpha = 1,$$

where the matrix G is the covariance matrix of the random variables $\{V_{(x,i)}, x \in \mathcal{S}, i \in 1, \dots, m\}$, defined as

$$V_{(x,i)} = \int_0^T \phi_i(t) \mathbf{1}_t^x dt, \quad \forall x \in \mathcal{S},$$

$$G = \{ G_{(x,i),(y,j)} = \text{cov}(V_{(x,i)}, V_{(y,j)}) , \quad x, y \in \mathcal{S}, i, j = 1, \dots, m \},$$

Categorical functional data analysis

Approximation

The matrix F is defined by

$$F = \{F_{(x,i),(y,j)} = \mathbb{E}(U_{(x,i),(y,j)}) , \quad x, y \in \mathcal{S}, i, j = 1, \dots, m\} , \quad (1)$$

where $U_{(x,i),(y,j)}$ is the random variable

$$U_{(x,i),(y,j)} = \int_0^T \phi_i(t) \phi_j(t) \mathbf{1}_t^x \mathbf{1}_t^y dt = \begin{cases} \int_0^T \phi_i(t) \phi_j(t) \mathbf{1}_t^x dt & \text{if } x = y, \\ 0 & \text{otherwise.} \end{cases}$$

Thus, F is a block diagonal matrix, each block being a square matrix of size $m \times m$ corresponding to each x in \mathcal{S} ,
 $\{U_{(x,i),(x,j)}, i, j = 1, \dots, m\}$.

Categorical functional data analysis

Estimation

Let $\{X_1, \dots, X_n\}$ be a sample of n paths of X corresponding to a random sample $(\omega_1, \dots, \omega_n) \in \Omega^n$. Then,

- ▶ the V data set with n rows and Km columns for the V 's random variables,

ω	$V_{(s_1, 1)}$	\dots	$V_{(s_1, m)}$	\dots	$V_{(x, i)}$	\dots	$V_{(s_K, m)}$
ω_1	$V_{(s_1, 1)}(\omega_1)$	\dots	$V_{(s_1, m)}(\omega_1)$	\dots	$V_{(x, i)}(\omega_1)$	\dots	$V_{(s_K, m)}(\omega_1)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
ω_n	$V_{(s_1, 1)}(\omega_n)$	\dots	$V_{(s_1, m)}(\omega_n)$	\dots	$V_{(x, i)}(\omega_n)$	\dots	$V_{(s_K, m)}(\omega_n)$

- ▶ and the U dataset with n rows and Km^2 columns for the U 's random variables, respectively :

ω	\dots	$U_{(x, i), (x, 1)}$	\dots	$U_{(x, i), (x, m)}$	\dots	$U_{(s_K, m), (s_K, m)}$
ω_1	\dots	$U_{(x, i), (x, 1)}(\omega_1)$	\dots	$U_{(x, i), (x, m)}(\omega_1)$	\dots	$U_{(s_K, m), (s_K, m)}(\omega_1)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
ω_n	\dots	$U_{(x, i), (x, 1)}(\omega_n)$	\dots	$U_{(x, i), (x, m)}(\omega_n)$	\dots	$U_{(s_K, m), (s_K, m)}(\omega_n)$

Categorical functional data analysis

Estimation

For each i and j in $\{1, \dots, m\}$ and x and y in \mathcal{S} one has :

$$\widehat{G}_{(x,i),(y,j)} = \widehat{\text{cov}}(V_{(x,i)}, V_{(y,j)}) = \frac{1}{n-1} \left(\sum_{h=1}^n V_{(x,i)}(\omega_h) V_{(y,j)}(\omega_h) - n \bar{V}_{(x,i)} \bar{V}_{(y,j)} \right)$$

and

$$\widehat{F}_{(x,i),(y,j)} = \begin{cases} \bar{U}_{(x,i),(y,j)} = \frac{1}{n} \sum_{h=1}^n U_{(x,i),(y,j)}(\omega_h) & \text{if } x = y, \\ 0 & \text{otherwise.} \end{cases}$$

An estimate of i -th eigenvector $\alpha^{(i)}$, $i \geq 1$, is the i -th eigenvector $\widehat{\alpha}_i$ of the eigen-equation,

$$\widehat{G}\widehat{\alpha} = \widehat{\lambda}\widehat{F}\widehat{\alpha},$$

under the constraint

$$\widehat{\alpha}' \widehat{F} \widehat{\alpha} = 1.$$

Categorical functional data analysis

Estimation

Then, for each $x \in \mathcal{S}$, the i -th encoding eigen-function a_i^x is estimated by

$$\hat{a}_i^x = \sum_{j=1}^m \hat{\alpha}_{i,(x,j)} \phi_j, \quad i \geq 1.$$

The estimates for the principal components :

$$\hat{z}_i(\omega) = \int_0^T \sum_{x \in \mathcal{S}} \hat{a}_i^x(t) \mathbf{1}_t^x(\omega) dt = \sum_{x \in \mathcal{S}} \sum_{j=1}^m \hat{\alpha}_{i,(x,j)} V_{(x,j)}(\omega), \quad i \geq 1.$$

Categorical functional data analysis

Estimation

Confidence bounds.

Bootstrapping from the V and U datasets,

$$\widehat{\text{var}}(\widehat{a_i^x}(t)) = \phi(t)' \widehat{\Sigma}_{(i,x)} \phi(t),$$

where $\phi(t)$ is the column vector $\phi(t) = (\phi_1(t), \dots, \phi_m(t))'$ and $\widehat{\Sigma}_{(i,x)}$ is the covariance matrix of $\widehat{\alpha}_{i,x} = (\widehat{\alpha}_{i,(x,1)}, \dots, \widehat{\alpha}_{i,(x,m)})$.

Then, for a confidence level $1 - u$, $u \in [0, 1]$, a confidence interval for $a_i^x(t)$ is obtained as

$$\text{CI}^{1-u}(a_i^x(t)) = \widehat{a_i^x(t)} \pm \zeta_{1-\frac{u}{2}} \sqrt{\widehat{\text{var}}(a_i^x(t))},$$

where $\zeta_{1-\frac{u}{2}}$ is the quantile of order $1 - \frac{u}{2}$ of the standard normal distribution.