

Analyse fonctionnelle de données

Jour 2 : ACP lissée

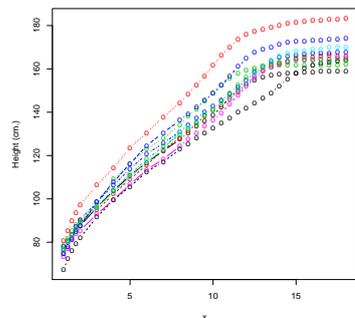
Jean-Marc Lasgouttes, Inria Paris

jean-marc.lasgouttes@inria.fr

Partie I. Données fonctionnelles croissantes

Courbes de croissance

Données une liste contenant la taille de 39 garçons et 54 filles et l'âge auquel elle a été mesurée

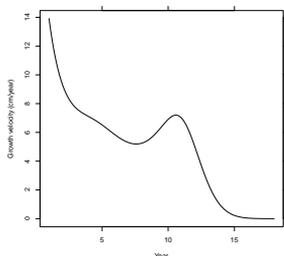


Données mesurées (31 points) pour 10 filles.

Courbes de croissance : transformation

Calcul de la vitesse on lisse la courbe de taille $H(t)$ et on la dérive pour obtenir la vitesse $V(t)$

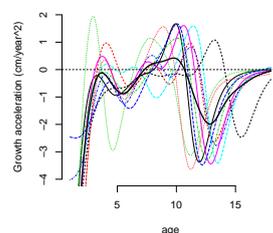
- on parle de courbe de croissance, mais on a en fait la taille $H(t)$
- l'expression $V(t_i) = [H(t_{i+1}) - H(t_i)]/[t_{i+1} - t_i]$ est très bruitée



Courbe de vitesse de croissance pour une fille.

Propriétés

- courbes croissantes
- méthodes paramétriques difficiles d'usage (jusqu'à 8 paramètres)
- croissance rapide au début, puis à l'adolescence
- certains peuvent avoir de l'avance ou du retard
- données très difficiles à collecter



Courbe d'accélération de croissance pour 10 filles (avec la moyenne).

Un modèle de croissance

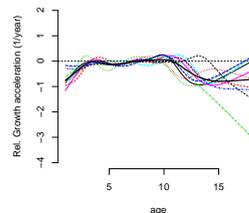
Écriture du modèle Pour mettre en évidence que l'accélération dépend de la vitesse, on écrit

$$V(t_{i+1}) - V(t_i) = w_i V(t_i) (t_{i+1} - t_i)$$

et en passant à la limite $A(t) = w(t)V(t)$

Modèle de taille on a en intégrant

$$H(t) = C_2 + C_1 \int_0^t \exp \left[\int_0^u w(s) ds \right] du$$



Courbe d'accélération relative pour 10 filles.

Évaluation on minimise

$$\sum_{j=1}^n [y_j - H(t_j)]^2 + \lambda \int w'''(t)^2 dt$$

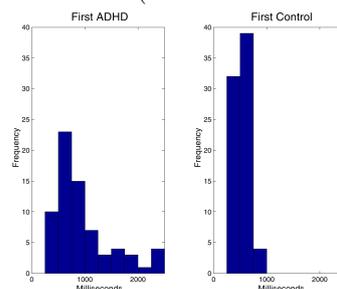
Dépendance non linéaire il faut une optimisation itérative plus lente

Partie II. Cas d'une courbe de densité

Trouble du déficit de l'attention avec hyperactivité

Données

- on affiche un signal à un enfant après un délai d'une dizaine de secondes et il doit appuyer sur un bouton
- 17 enfants souffrant de TDAH et 16 enfants de référence (≈ 70 essais chacun).



Histogrammes pour environ 70 temps de réaction à un signal. Gauche : enfant TDAH; droite : enfant de référence.

Propriétés

- formes très différentes dans les deux cas
- délai initial fixe de 120ms
- valeurs positives
- somme des valeurs fixée

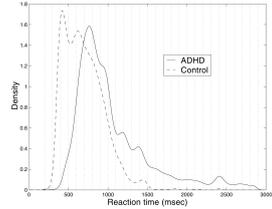
Transformation d'une densité

Problème une densité est contrainte par $\int p(x) dx = 1$, on ne peut pas l'approximer.

Réécriture on définit p en fonction d'une nouvelle fonction W sur laquelle il n'y a pas de contrainte

$$p(t) = C \exp W(t), \quad \text{avec } C^{-1} = \int \exp W(x) dx$$

Densité lissée



Densité lissée des temps de réaction pour 17 enfants ADHD (ligne pleine) et 16 enfants de contrôle (pointillé).

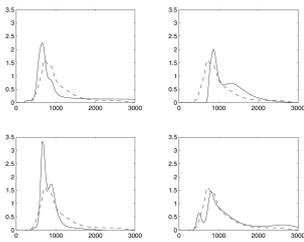
Méthode maximum de vraisemblance pénalisée par une dérivée 3^e

$$\sum_{i=1}^n \log_{10} p(t_i) + \lambda \int [W'''(x)]^2 dx$$

Pourquoi W''' ?

- on va s'intéresser à W'
- si $W''' = 0$, alors la distribution est une loi Gaussienne

Modélisation des individus



4 densités de temps de réaction d'enfants TDAH

Action on transforme les temps de réaction

$$z = \log_{10}(t - 120)$$

Pourquoi ?

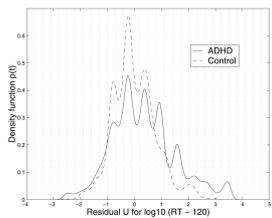
- 120 ms est le temps de réaction minimal observé
- l'impact du TDAH est plutôt multiplicatif qu'additif

Modèle individuel (ANOVA) pour l'essai j de l'enfant i du groupe G_k

$$z_{ijk} = \mu_k + \alpha_{i|k} + U_{ijk}, \quad \sum_{i \in G_k} \alpha_{i|k} = 0$$

μ_k : performance typique de G_k / $\alpha_{i|k}$: performance typique de l'enfant i de G_k

Les résidus



distribution des résidus

Observations

- $\mu_{TDAH} = 2.92 > \mu_{ctrl} = 2.72$ (écart ≈ 300 ms)
- le temps de réaction de l'enfant i est

$$\tau_i = 120 + 10^{\mu_k + \alpha_{i|k} + U_{ijk}}$$

Forme du résidu

- ce n'est pas une loi normale, il y a plusieurs modes
- on pourrait penser que c'est lié au fonctionnement du cerveau
- en fait c'est seulement lié à la technique de mesure!

Partie III. ACP fonctionnelle

Première approche

Données à chaque individu i est associée une fonction $y_i(t)$ et pour toute fonction $\xi(t)$ telle que $\int \xi(t)^2 dt = 1$, on pose

$$z_i = \int \xi(t) y_i(t) dt$$

1^{re} composante principale on cherche la fonction ξ_1 qui maximise la variance empirique de $\mathbf{z} = (z_1, \dots, z_n)$

$$(\xi_1, \mathbf{z}_1) = \arg \max_{\xi} \text{var } \mathbf{z}, \quad \text{avec } \int \xi_1(t)^2 dt = 1$$

- $\mathbf{z}_1 = (z_{i1})_{1 \leq i \leq n}$ est la première composante principale (score en anglais)
- $\xi_1(t)$ est le premier facteur principal (weight ou loading function en anglais)

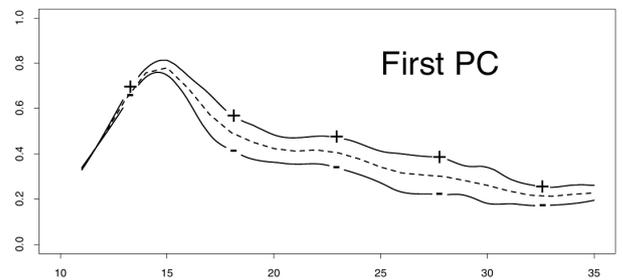
Autres composantes pour la j^e composante principale, on ajoute les conditions

$$\int \xi_1(t) \xi_j(t) dt = \int \xi_2(t) \xi_j(t) dt = \dots = \int \xi_{j-1}(t) \xi_j(t) dt = 0$$

ACP classique sur les données de criminologie

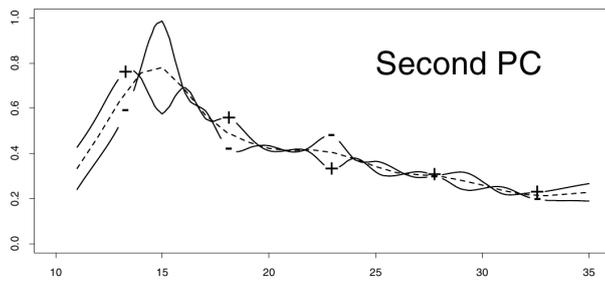
Méthode on applique l'ACP sur les données brutes et on interpole le résultat.

Composante 1 met en évidence les personnes âgées de plus de 15 ans

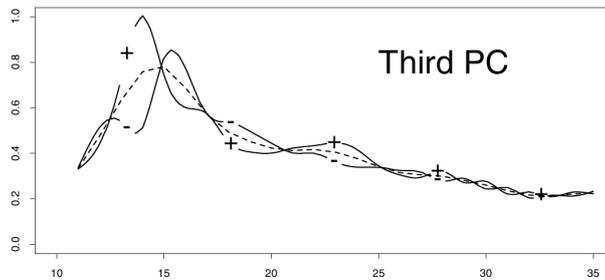


On représente la moyenne et l'effet de l'axe principal multiplié par un coefficient « adapté »

Composante 2 très difficile à interpréter.



Composante 3 très difficile à interpréter.



ACP fonctionnelle lissée

Idée pour éviter les problèmes, on ajoute une facteur de lissage dans l'ACP

1^{re} composante principale on veut contrôler la rugosité de ξ : on modifie donc la contrainte pour arriver au problème

$$(\xi_1, \mathbf{z}_1) = \arg \max_{\xi} \text{var } \mathbf{z}, \text{ avec } \int \xi_1(t)^2 dt + \lambda \int \xi_1''(t)^2 dt = 1$$

- $\mathbf{z}_1 = (z_{i1})_{1 \leq i \leq n}$ est la première composante principale (*score* en anglais)
- $\xi_1(t)$ est le premier facteur principal (*weight* ou *loading function* en anglais)
- λ est la pénalité de rugosité

Autres composantes pour la k^e composante principale, on a les conditions

$$\int \xi_k(t)^2 dt + \lambda \int \xi_k''(t)^2 dt = 1$$

$$\int \xi_k(t) \xi_\ell(t) dt + \lambda \int \xi_k''(t) \xi_\ell''(t) dt = 0, \text{ si } k \neq \ell$$

L'ACP fonctionnelle en pratique

Les parts de variation ce sont les variances des composantes principales \mathbf{z}_k , en ordre décroissant

$$\text{var } \mathbf{z}_1 \geq \text{var } \mathbf{z}_2 \geq \dots \geq \text{var } \mathbf{z}_p \geq 0$$

Les facteurs principaux on peut les représenter comme pour les données de criminologie, comme un effet sur la moyenne.

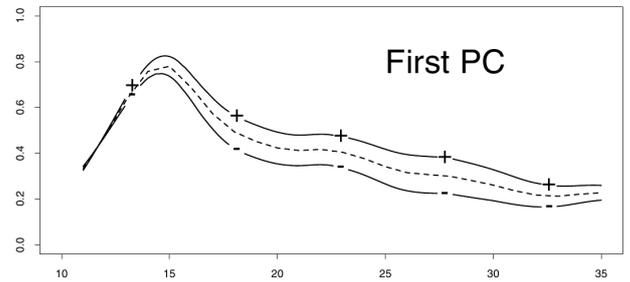
Sélection de variables

- on garde les variables de 1 à q , pas des variables arbitraires
- on peut se servir de la courbe des valeurs propres (coude)
- de toute façon, seuls les axes interprétables sont intéressants.

ACP lissée sur les données de criminologie

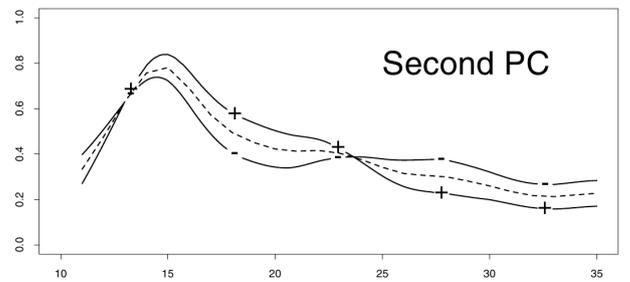
Méthode on applique l'ACP lissée sur les données.

Composante 1 met en évidence les délinquants qui commencent à la fin de l'adolescence

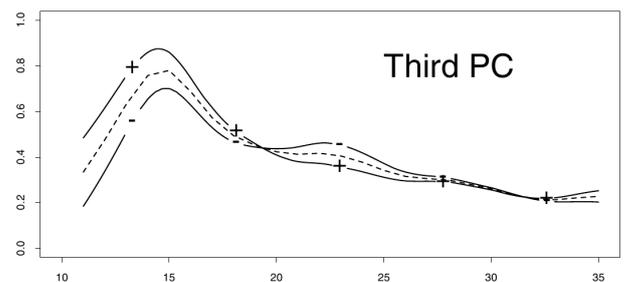


On représente la moyenne et l'effet de l'axe principal multiplié par un coefficient « adapté »

Composante 2 représente la désistance à long terme : la délinquance s'arrête avant 25 ans et le comportement devient meilleur que la moyenne



Composante 3 représente la délinquance juvénile : commence très jeune, s'améliore vers 20 ans, puis revient au niveau normal



Partie IV. Méthodes mathématiques

Approche matricielle

Données elles sont décrites avec les coefficients $\mathbf{Y} = (y_{ij})$ et une base de fonctions $\delta_j(t)$,

$$y_i(t) = \sum_{j=1}^m y_{ij} \delta_j(t), \quad \text{et } \bar{y}_j = \frac{1}{n} \sum_{i=1}^n y_{ij}$$

La matrice \mathbf{V} de variance-covariance de \mathbf{Y} s'écrit

$$V_{j\ell} = \frac{1}{n-1} \sum_{i=1}^n (y_{ij} - \bar{y}_j)(y_{i\ell} - \bar{y}_\ell)$$

Calcul des composantes on pose

$$\xi(t) = \sum_{k=1}^p \xi_k \beta_k(t), \quad L_{jk} = \int \delta_j(t) \beta_k(t) dt$$

et on peut alors écrire

$$\mathbf{z} = \int \xi(t) \mathbf{y}(t) dt = \mathbf{Y} \mathbf{L}' \boldsymbol{\xi}, \quad \text{var } \mathbf{z} = \boldsymbol{\xi}' \mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi}$$

Maximisation sous contrainte

Contrainte la contrainte sur ξ_1 s'écrit

$$\boldsymbol{\xi}' (\mathbf{J} + \lambda \mathbf{K}) \boldsymbol{\xi} = 1$$

$$J_{jk} = \int \beta_j(t) \beta_k(t) dt \quad K_{jk} = \int \beta_j''(t) \beta_k''(t) dt$$

Lagrangien on définit la *métrique* $\mathbf{M} = \mathbf{J} + \lambda \mathbf{K}$ et on maximise la grandeur

$$\mathcal{L}(\boldsymbol{\xi}, \theta) = \boldsymbol{\xi}' \mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi} - \theta [\boldsymbol{\xi}' \mathbf{M} \boldsymbol{\xi} - 1]$$

Résolution les équations sont

$$\mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi} - \theta \mathbf{M} \boldsymbol{\xi} = 0 \quad \boldsymbol{\xi}' \mathbf{M} \boldsymbol{\xi} = 1$$

et finalement $\boldsymbol{\xi}$ est un vecteur propre de la matrice $\mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}'$

$$\mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi} = \theta \boldsymbol{\xi} \quad \boldsymbol{\xi}' \mathbf{M} \boldsymbol{\xi} = 1$$

Problème on ne sait rien du spectre de $\mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}'$

Diagonalisation

Propriété Soit \mathbf{M} une matrice réelle symétrique définie positive. une matrice \mathbf{S} est \mathbf{M} -symétrique si $\mathbf{S}' \mathbf{M} = \mathbf{M} \mathbf{S}$. Dans ce cas

- \mathbf{S} est une matrice diagonalisable et ses vecteurs/valeurs propres sont réels.
- Elle possède une base de vecteurs propres $\mathbf{v}_1, \dots, \mathbf{v}_p$ qui est \mathbf{M} -orthonormale

$$\mathbf{v}'_k \mathbf{M} \mathbf{v}_\ell = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{sinon} \end{cases}$$

Application la matrice $\mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}'$ est \mathbf{M} -symétrique :

$$[\mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}']' \mathbf{M} = \mathbf{L} \mathbf{V} \mathbf{L}' = \mathbf{M} [\mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}']$$

Elle possède donc une base de vecteurs propres $\boldsymbol{\xi}_1, \dots, \boldsymbol{\xi}_p$ tels que

$$\boldsymbol{\xi}'_k \mathbf{M} \boldsymbol{\xi}_\ell = \begin{cases} 1 & \text{si } k = \ell \\ 0 & \text{sinon} \end{cases}$$

Ces vecteurs vérifient donc les contraintes demandées dans la définition de l'ACP.

L'ACP fonctionnelle lissée

Facteur principal c'est le vecteur propre $\boldsymbol{\xi}_k$ associé à θ_k

Composantes principale c'est $\mathbf{z}_k = \mathbf{Y} \mathbf{L}' \boldsymbol{\xi}_k$, dont la variance est

$$\text{var } \mathbf{z}_k = \boldsymbol{\xi}'_k \mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi}_k = \boldsymbol{\xi}'_k \mathbf{M} \mathbf{M}^{-1} \mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi}_k = \theta_k \boldsymbol{\xi}'_k \mathbf{M} \boldsymbol{\xi}_k = \theta_k$$

Les composantes principales sont décorrélées

$$\text{cov}(\mathbf{z}_k, \mathbf{z}_\ell) = \boldsymbol{\xi}'_k \mathbf{L} \mathbf{V} \mathbf{L}' \boldsymbol{\xi}_\ell = \theta'_\ell \boldsymbol{\xi}'_k \mathbf{M} \boldsymbol{\xi}_\ell = 0 \quad \text{si } k \neq \ell$$

Valeurs propres on classe les valeurs propres par ordre décroissant

$$\theta_1 \geq \theta_2 \geq \dots \geq \theta_p \geq 0$$

Elles sont positives parce que ce sont des variances

Lien avec l'ACP classique L'ACP fonctionnelle est une sorte d'ACP centrée des coefficients \mathbf{Y} sous la métrique \mathbf{M}

Partie V. Utilisation du paquet « fda »

Lissage de densité

Fonction calcule une densité de la forme $C^{-1} \exp W(t)$

```
denslist <- density.fd(x, WfdParobj,  
  conv=0.0001, iterlim=20, dbglev=1...)
```

Paramètres utiles

- **x** : ensemble d'observations. Soit un vecteur de valeurs (avec un poids uniforme), soit une matrice à 2 colonnes (valeurs, poids)
- **WfdParObj** : un objet retourné par `fdPar()`

Paramètres peut-être utiles si la convergence est difficile

- **conv** : précision pour la convergence de l'algorithme
- **iterlim** : nombre max d'itérations
- **dbglev** : niveau d'information (0 : rien, 1 : normal, 2 : maximum)

Valeur retournée une liste contenant

- **Wfdobj** : un objet de données fonctionnelles décrivant la fonction $W(x)$
- **C** : la constante de normalisation

Utilisation : `with(denslist, exp(eval.fd(evalarg, Wfdobj)) / C)`

Lissage de fonction monotone

Fonction calcule une fonction de la forme $\beta_0 + \beta_1 \int \exp W(u) du$

```
monfdobj <- smooth.monotone(argvals, y, WfdParobj,  
  conv=.0001, iterlim=50, ...)
```

Paramètres

- **argvals** : les abscisses t_j des points mesurés
- **y** : les données correspondantes (en colonnes si plusieurs individus)
- **WfdParobj** : un objet produit par `fdPar()`
- **conv, interlim** : voir `density.fd`

Valeur retournée un objet de classe `monfd`, qui contient

- **Wfdobj** : un objet de données fonctionnelles décrivant la fonction $W(x)$
- **beta** : les coefficients de régression b_0 et b_1 pour chaque courbe lissée
- **yhatfd** : donnée fonctionnelle pour la courbe monotone lissée
- **argvals, y** : les paramètres d'entrée

Utilisation la fonction suivante évalue une fonction à une série de points `newdata`

```
predict(object, newdata=NULL, ...)
```

On peut utiliser `eval.monfd`, mais il ne prend pas en compte `monfdobj$beta`

Lissage de fonction positive

Fonction calcule une fonction de la forme $\exp W(t)$

```
posfdobj <- smooth.pos(argvals, y, WfdParobj,  
  conv=.0001, iterlim=50, ...)
```

Paramètres

- **argvals** : les abscisses t_j des points mesurés
- **y** : les données correspondantes. Si on a plusieurs individus, alors ils sont en colonne (chaque ligne correspond à un t_j)
- **WfdParobj** : un objet produit par `fdPar()`
- **conv, interlim** : voir `density.fd`

Valeur retournée un objet de classe `posfd`, qui contient

- **Wfdobj** : un objet de données fonctionnelles décrivant la fonction $W(t)$
- **argvals, y** : les paramètres d'entrée

Utilisation Typiquement on utilise `eval.posfd` ou `predict`

```
with(posfdobj, eval.posfd(evalarg, Wfdobj))  
predict(posfdobj, newdata=evalarg)
```

ACP lissée

Fonction

```
pca.fd(fdobj, nharm = 2, harmfdPar=fdPar(fdobj),  
  centerfns = TRUE)
```

Paramètres

- **fdobj** : données fonctionnelles décrivant les individus
- **nharm** : le nombre d'axes principaux à calculer
- **harmfdPar** : un objet retourné par `fdPar()`
- **centerfns** : indique si les données doivent être centrées

Valeur un objet de classe `pca.fd` qui contient

- **harmonics** : données fonctionnelles représentant les fonctions propres
- **values** : toutes les valeurs propres
- **scores** : matrices des scores (\mathbf{z})
- **varprop** : proportion de variance expliquée par chaque valeur propre
- **meanfd** : données fonctionnelles représentant la moyenne

Représentation des fonctions propres

Fonction sert à représenter des fonction propres de l'ACP. Chacune est représentée en terme de variation autour de la moyenne.

```
plot(x, nx = 128, pointplot = TRUE, harm = 0,  
  expand = 0, cycle = FALSE, ...)
```

Paramètres voir la documentation de `plot` pour plus de détails (`titles`, `xlab`, `ylab`, ...)

- **x** : le résultat de `pca.fd`
- **nx** : nombre de points à tracer en abscisse
- **pointplot** : si TRUE, utiliser des $+/-$ pour dénoter les variations, sinon des courbes

- **harm** : les harmoniques à afficher (un plot par harmonique), toutes affichées par défaut
- **expand** : la distance entre les +/- et la moyenne (défaut : 2 écarts types)
- **cycle** : si `length(harm) == 2`, représente les harmoniques par un cycle