

Classification supervisée et données fonctionnelles

Gilbert Saporta
Chaire de Statistique Appliquée & CEDRIC
Conservatoire National des Arts et Métiers
292 rue Saint Martin
F 75141 Paris Cedex 03
saporta@cnam.fr
<http://cedric.cnam.fr/~saporta>

Plan



- 1. Introduction**
- 2. Régression MCO sur données fonctionnelles**
- 3. Régression PLS fonctionnelle**
- 4. Méthodes linéaires de discrimination**
- 5. Prédiction anticipée**
- 6. Conclusion et perspectives**

Travaux réalisés en collaboration avec C.Preda(Univ. Lille2) et D.Costanzo (Univ.Calabria)

1. Introduction



- Données fonctionnelles: courbes ou trajectoires d'un processus stochastique X_t
- Réponse Y
 - Y numérique: régression
 - Y catégorielle: classification supervisée, discrimination
- Intervalle de temps commun $[0; T]$, variables centrées

■ Précurseurs:

- R.A. Fisher – 1924
- J. C. Deville – 1974
- P. Besse – 1979
- G. Saporta – 1981

■ Plus récemment:

- Aguilera, Valderrama – 1993, 1995, 1998
- Ramsay, Silverman – 1995, 1997
- Van der Heijden – 1997
- Preda, Cohen – 1999
- Cardot, Ferraty, Vieu - 1999, 2005

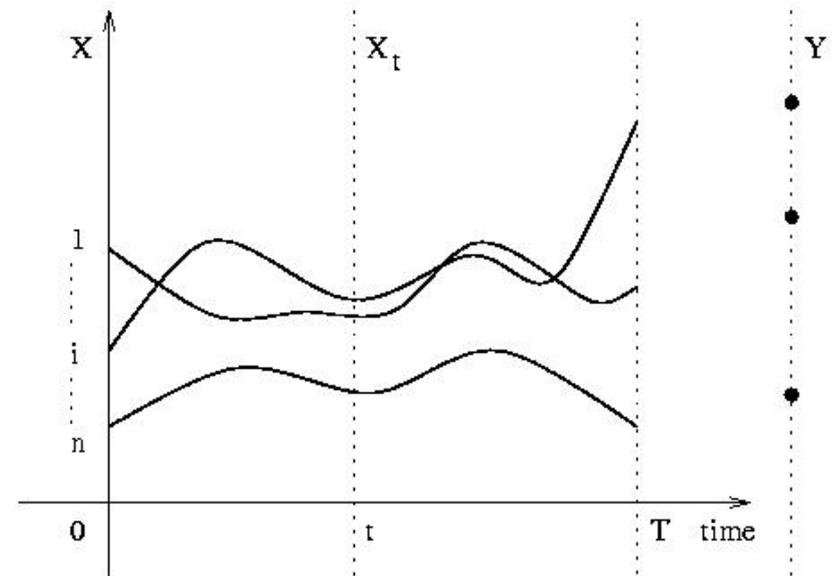
■ Régression sur données fonctionnelles

■ Exemple 1: $Y =$ récolte

$X_t =$ température

$p = \infty$

R.A.Fisher (1924)



- Données de très grande dimension: infinité non dénombrable (en principe..) de prédicteurs
- Combinaison linéaire
 - « Integral regression »

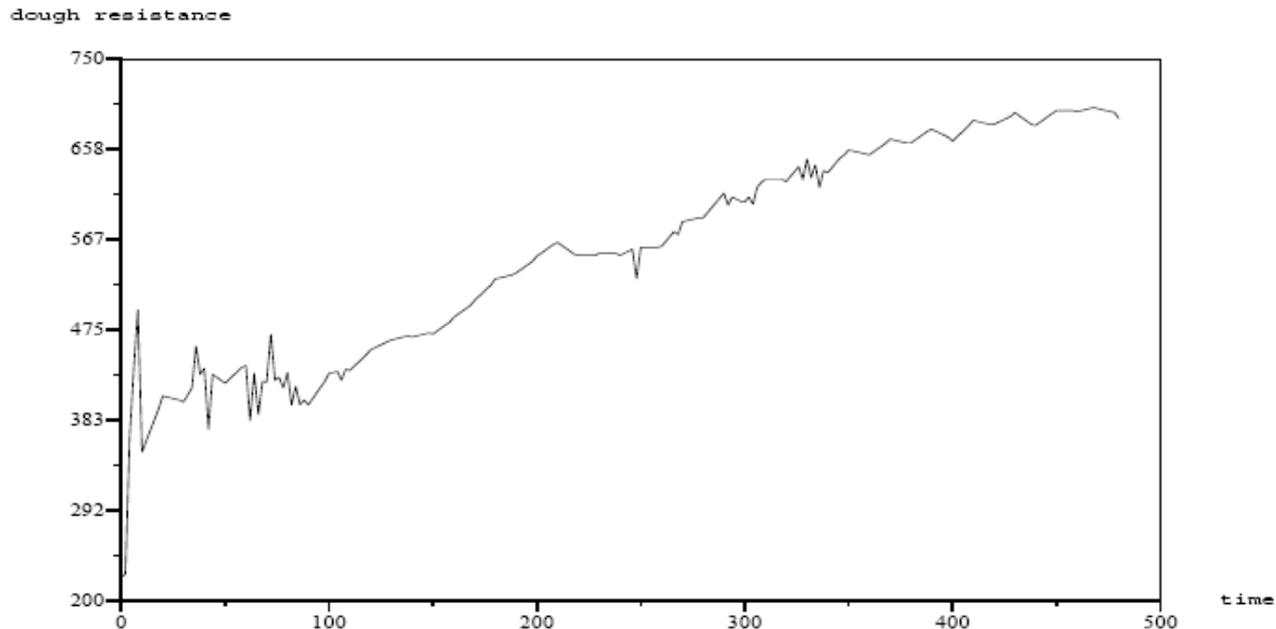
$$\hat{Y} = \int_0^T \beta(t) X_t dt$$

- Au lieu d'une somme finie

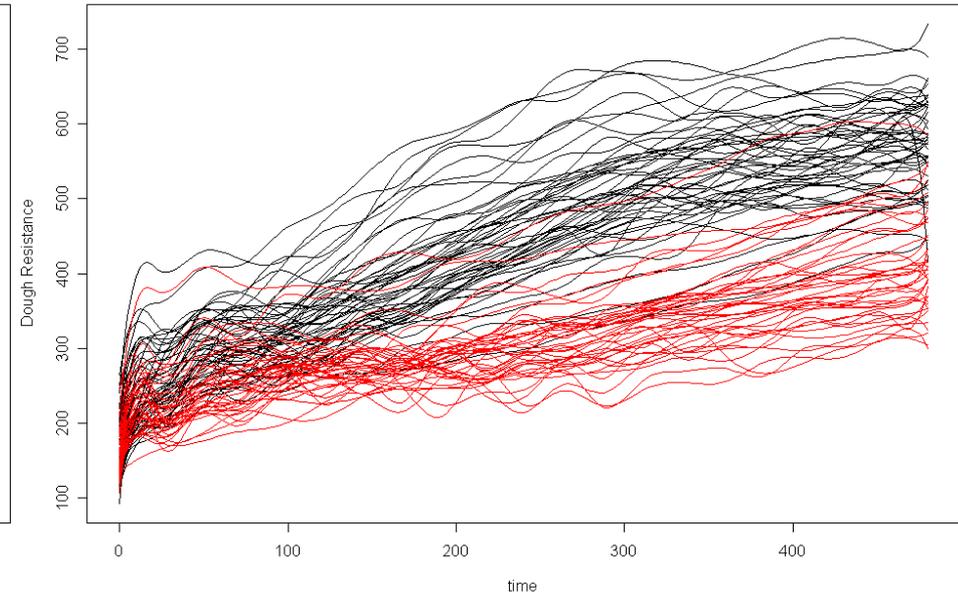
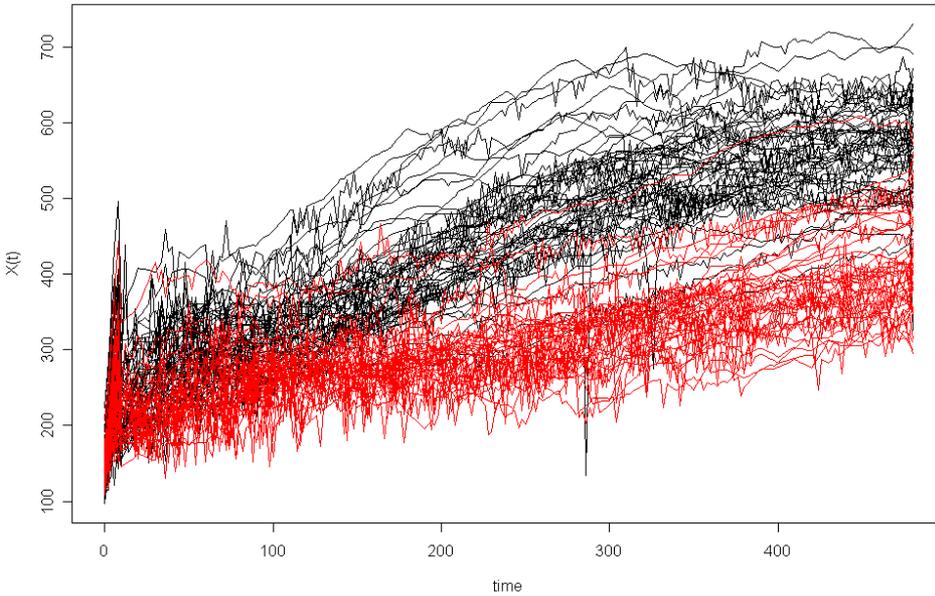
$$\hat{Y} = \sum_{j=1}^p \beta_j X_j$$

• Discrimination sur données fonctionnelles

- Exemple 2: courbes de pétrissage pour biscuits (Danone Vitapole)



bonne (black), mauvaise (red)



- Après lissage par B-splines cubiques (Lévédér & al, 2004)

Comment prédire la qualité des biscuits?

- Discrimination sur données fonctionnelles
 - Cas particulier de la régression sur données fonctionnelles pour deux classes
- Anticipation
 - déterminer $t^* < T$ tel que l'analyse sur $[0; t^*]$ donne des prédictions semblables à l'analyse sur $[0; T]$

2. Régression MCO sur données fonctionnelles

$$Y ; X_t \quad (E(Y)=E(X_t)=0)$$

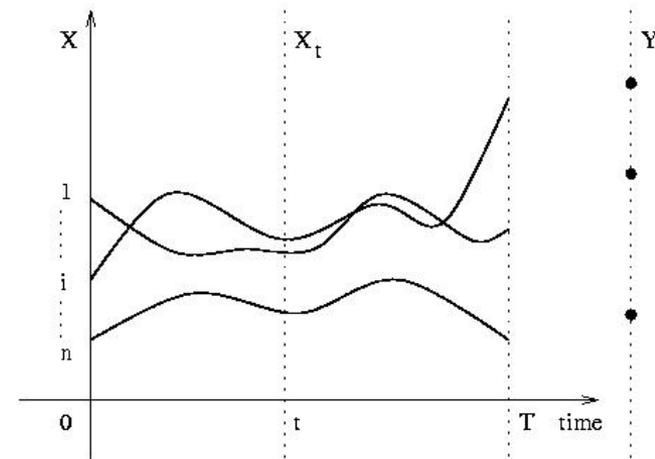
■ 2.1 Les mco

- Equations normales ou de Wiener-Hopf:

$$\hat{Y} = \int_0^T \beta(t) X_t dt$$

$$\text{cov}(X_t, Y) = \int_0^T C(t, s) \beta(s) ds$$

- $C(t, s) = \text{cov}(X_t, X_s) = E(X_t X_s)$



2.2 décomposition de Karhunen-Loeve

$$X_t = \sum_{i=1}^{\infty} f_i(t) \xi_i$$

- facteurs: $\int_0^T C(t, s) f_i(s) ds = \lambda_i f_i(t)$
- Composantes principales: $\xi_i = \int_0^T f_i(t) X_t dt$
- Covariance avec une composante principale:

$$c_i = \text{cov}(Y, \xi_i) = \text{cov}(Y, \int_0^T f_i(t) X_t dt) = \int_0^T E(X_t Y) f_i(t) dt$$

Résolution numérique:

- Equations intégrales non explicites dans le cas général: $C(t,s)$ connu point par point
- Fonctions en escalier: nombre fini de variables et d'individus: opérateurs matriciels mais de grande taille
- Approximations par discrétisation du temps

Une solution exacte:

- **W** matrice des produits scalaires entre trajectoires $w_{uv} = \int_0^T x_u(t) x_v(t) dt \quad u, v = 1, 2, \dots, n$

- Composantes principales: vecteur propres de **W**
- Facteurs principaux

$$f(t) = \frac{1}{n} \frac{1}{\lambda} \sum_{u=1}^n \xi_u X_u(t)$$

- Théorème de Picard: β unique si et seulement si:

$$\sum_{i=1}^{\infty} \frac{c_i^2}{\lambda_i^2} < \infty$$

- Généralement faux ... Surtout quand n est fini car $p > n$. Ajustement parfait en minimisant:

$$\frac{1}{n} \sum_{i=1}^n \left(y_i - \int_0^T \beta(t) x_i(t) dt \right)^2$$

- Même quand β est unique, « L'équation de Wiener-Hopf n'est pas une équation intégrale ordinaire mais un accouplement entre fonction et distribution dont la solution est plus souvent une distribution qu'une fonction » Paul Kree, 1972
- Nécessité de contraintes. (cf Green & Silverman 1994, Ramsay & Silverman 1997).

2.3 Régression sur composantes principales

$$\hat{Y} = \sum_{i=1}^{\infty} \frac{\text{cov}(Y, \xi_i)}{\lambda_i} \xi_i = \sum_{i=1}^{\infty} \frac{c_i}{\lambda_i} \xi_i$$

$$R^2(Y, \hat{Y}) = \sum_{i=1}^{\infty} r^2(Y, \xi_i) = \sum_{i=1}^{\infty} \frac{c_i^2}{\lambda_i}$$

- Approximation de rang q:

$$\hat{Y}^{(q)} = \sum_{i=1}^q \frac{\text{cov}(Y; \xi_i)}{\lambda_i} \xi_i \quad \hat{\beta}^{(q)}(t) = \sum_{i=1}^q \frac{\text{cov}(Y; \xi_i)}{\lambda_i} f_i(t)$$

- 
- Quelles composantes?
 - Les q premières?
 - Les q plus corrélées?
 - Les composantes principales sont calculées sans tenir compte de la réponse Y

3. Régression PLS fonctionnelle

- Utiliser les composantes PLS au lieu des composantes principales
- Première composante PLS :

$$\max_w \operatorname{cov}^2\left(Y, \int_0^T w(t) X_t dt\right) \quad \|w\|^2 = 1$$

$$w(t) = \frac{\operatorname{cov}(X_t, Y)}{\sqrt{\int_0^T \operatorname{cov}^2(X_t, Y) dt}} \quad t_1 = \int_0^T w(t) X_t dt$$

- Puis itération sur les résidus

- Approximation de Y par X_t d'ordre q :

$$\hat{Y}_{PLS(q)} = c_1 t_1 + \dots + c_q t_q = \int_0^T \hat{\beta}_{PLS(q)}(t) X_t dt$$

- Convergence :

$$\lim_{q \rightarrow \infty} E(\|\hat{Y}_{PLS(q)} - \hat{Y}\|^2) = 0$$

- Mais q doit être fini pour avoir une formule!
- q déterminé par validation croisée
(Preda & Saporta, 2005)

- Première composante PLS facilement interprétable: coefficients du même signe que $r(y; x_t)$
- Pas d'équation intégrale
- Meilleur ajustement par PLS que par ACP:

$$R^2(Y; \hat{Y}_{PLS(q)}) \geq R^2(Y; \hat{Y}_{PCR(q)})$$

(De Jong 1993)

4. Discrimination linéaire

4.1 ADL fonctionnelle

- ADL : combinaison linéaire $\int_0^T \beta(t) X_t dt$
maximisant le rapport

variance inter/variance intra

- Pour 2 groupes la FLD de Fisher s'obtient
en régressant Y codé sur X_t

eg $\sqrt{\frac{p_1}{p_0}}$ and $-\sqrt{\frac{p_0}{p_1}}$

(Preda & Saporta, 2005a)

- 
- La régression PLS avec q composantes donne une approximation de $\beta(t)$ et du score:

$$d_T = \Phi_{PLS}(X) = \int_0^T \hat{\beta}_{PLS}(t) X_t dt$$

- Pour plus de 2 groupes: régression PLS2 entre k-1 indicatrices de Y et X_t

Régression PLS2

- Y multiple: (Y_1, Y_2, \dots, Y_p)
- Critère de Tucker:

$$\max \text{cov}^2 \left(\int_0^{\infty} w(t) X_t dt; \sum_{i=1}^p c_i Y_i \right)$$

- Composantes PLS :

$$t = \int_0^{\infty} w(t) X_t dt$$

$$s = \sum_{i=1}^p c_i Y_i$$

Première composante PLS: premier vecteur propre du produit des opérateurs d'Escoufier $\mathbf{W}^X \mathbf{W}^Y$

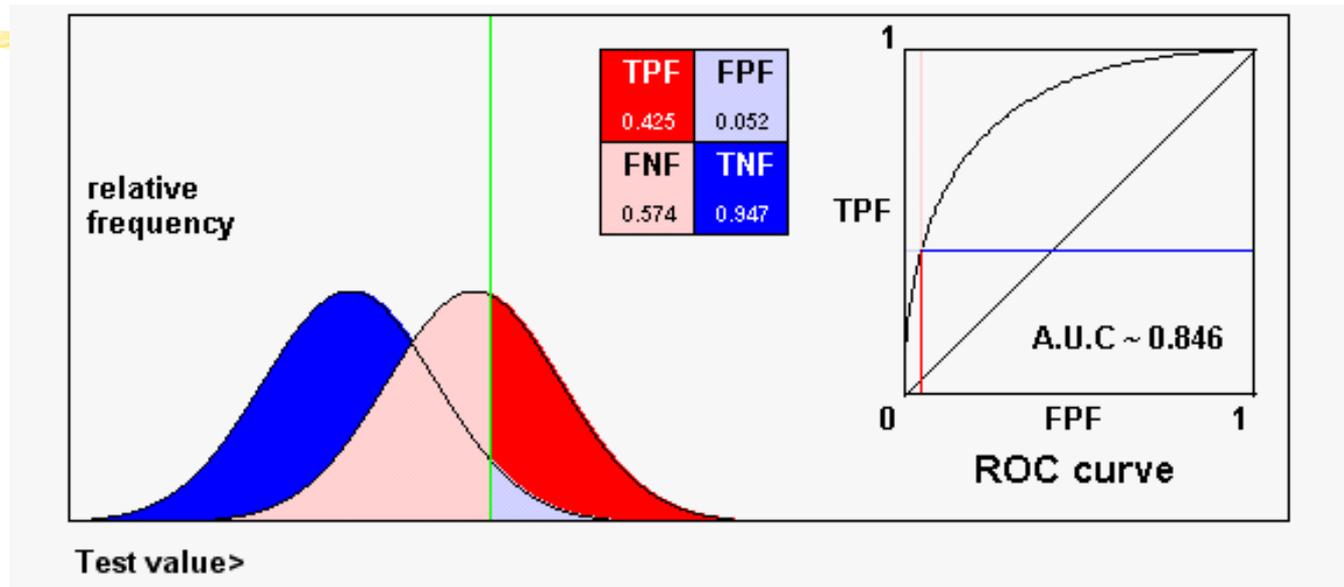
$$\mathbf{W}^X Z = \int_0^T E(X_t Z) X_t dt, \quad \mathbf{W}^Y Z = \sum_{i=1}^p E(Y_i Z) Y_i, \quad \forall Z \in L_2(\Omega).$$

Preda & Saporta, 2002 & 2005a ; Barker & Rayens , 2003

4.2 Mesures de qualité

- Pour $k=2$: courbe ROC et AUC
 - Pour un seuil s , x est classé en 1 si $d_T(x) > s$
 - Sensibilité ou taux de vrais positifs:
 $P(d_T(x) > s / Y=1) = 1 - \beta$
 - 1- Spécificité ou 1-taux de vrais négatifs:
 $P(d_T(x) > s / Y=0) = \alpha$

Courbe ROC



- En cas de discrimination parfaite :
courbe confondue avec les côtés du carré
- Si distribution conditionnelles identiques, courbe confondue avec la diagonale

- Courbe ROC invariante pour toute transformation monotone croissante
- Surface sous la courbe: mesure de performance permettant de comparer (partiellement) des modèles

- $$AUC = \int_{s=+\infty}^{s=-\infty} (1 - \beta(s)) d\alpha(s) = P(X_1 > X_2)$$

On tire une obs de G_1 et une de G_2

- AUC estimée par la proportion de paires concordantes

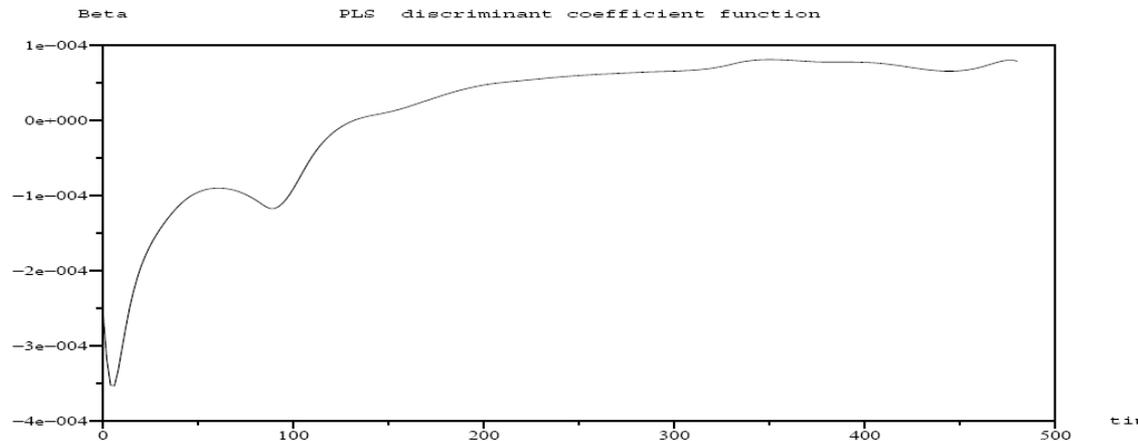
$$c = n_c / n_1 n_2$$

- n_c statistique de **Wilcoxon-Mann-Whitney**

$$U+W = n_1 n_2 + 0.5 n_1 (n_1 + 1) \quad AUC = U / n_1 n_2$$

courbes de pétrissage

- Après $T = 480s$ de pétrissage, on obtient des biscuits de qualités Y
- 115 observations: 50 « bon », 40 « mauvais » and 25 « indéterminés »
- 241 mesures à pas constant
- Lissage avec B-splines cubiques , 16 nœuds



- **Performance pour $Y=\{\text{bon, mauvais}\}$**
 - On divise 100 fois les données en apprentissage et test (60, 30)
 - Taux d'erreur moyen
 - 0.142 avec 3 composantes principales
 - 0.112 avec 3 composantes PLS
 - AUC moyen= 0.746

4.3 Régression logistique fonctionnelle

$$\ln\left(\frac{\pi_i}{1-\pi_i}\right) = \alpha + \int_0^T x_i(t)\beta(t)dt; \quad i = 1, \dots, n$$

$$\pi_i = P(Y = 1 | X = x_i(t); t \in T)$$

Hypothèse: $\beta(t)$ et les trajectoires sont dans le même espace de dimension fini (Ramsay et al., 1997)

$$\beta(t) = \sum_{q=1}^p b_q \psi_q(t) = \mathbf{b}' \boldsymbol{\psi} \quad x_i(t) = \sum_{q=1}^p c_{iq} \psi_q(t) = \mathbf{c}'_i \boldsymbol{\psi}$$

D'où une régression logistique classique:

$$\ln\left(\frac{\pi}{1-\pi}\right) = \alpha\mathbf{1} + \mathbf{C}\Phi\mathbf{b}$$

avec $\mathbf{C} = (c_{iq})$ $\Phi = (\phi_{kq} = \int_T \psi_k(t)\psi_q(t)dt)$

Aguilera *et al.* (2006) utilisent les composantes principales de X_t comme base

5. Prédiction anticipée

- Chercher $t^* < T$ tel que l'analyse sur $[0; t^*]$ donne des prédictions semblables à l'analyse sur $[0; T]$
- Solution:
 - En augmentant s depuis 0 , chercher la première valeur telle que $AUC(s)$ ne diffère pas significativement de $AUC(T)$

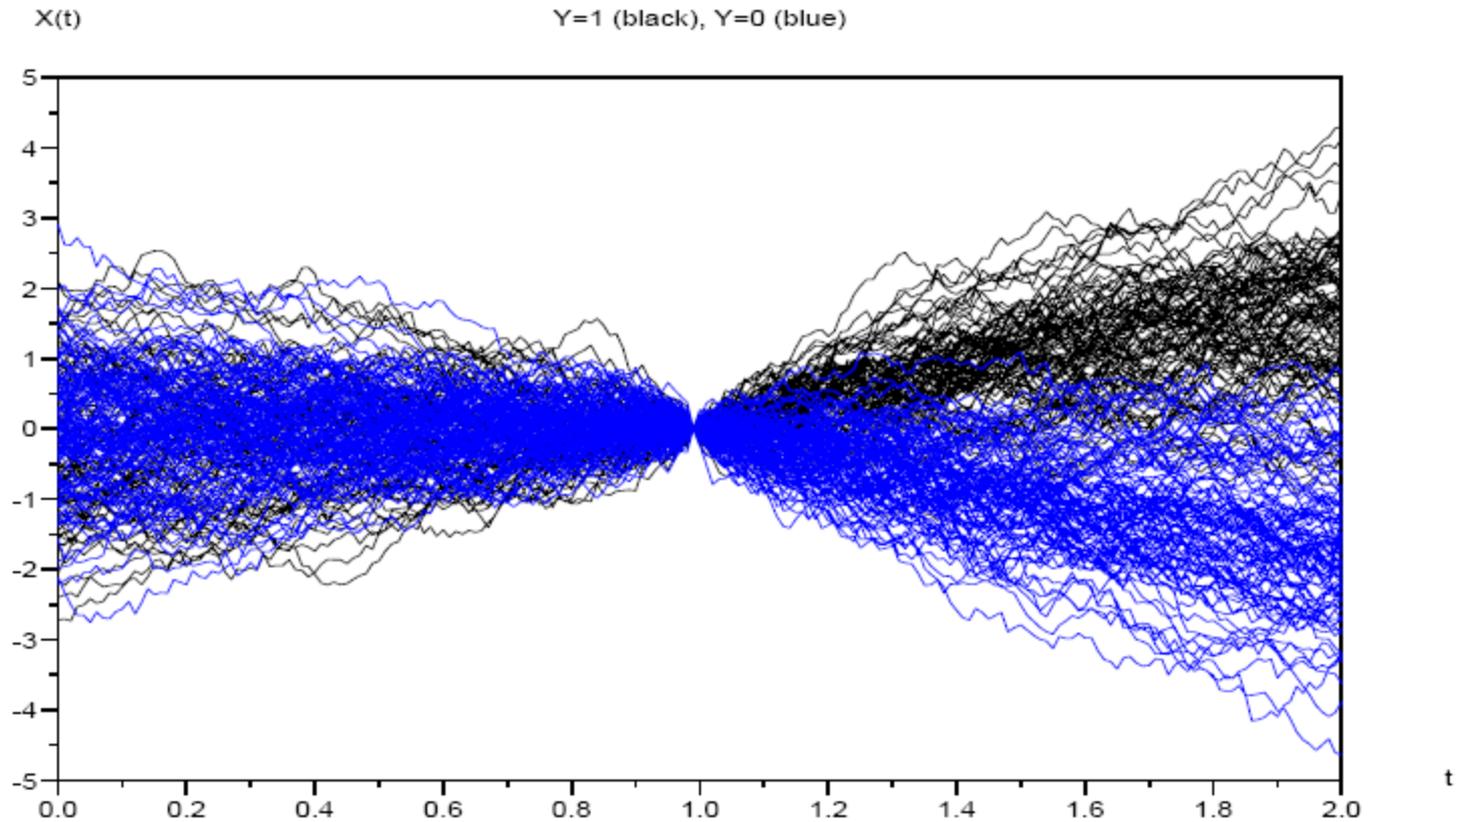
- Test d'égalité via une procédure bootstrap
 - Rééchantillonnage des données, stratifié pour conserver les proportions des classes
 - A chaque réplication b on calcule $AUC_b(s)$ et $AUC_b(T)$
 - Test basé sur les différences (Student ou Wilcoxon pour données appariées)
 $\delta_b = AUC_b(s) - AUC_b(T)$

■ 5.2 Données simulées

- Deux classes équiprobables
- $W(t)$ brownien standard

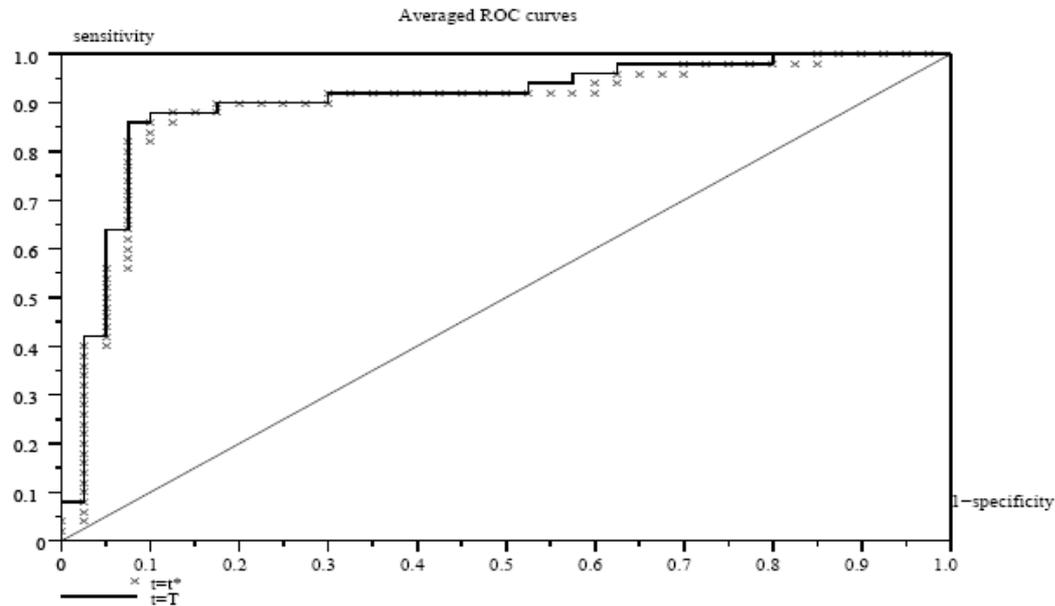
$$\text{Class } \{Y = 0\} : X_t = \begin{cases} W(1 - t), & 0 \leq t \leq 1 \\ -2 \sin(t - 1) + W(t - 1), & 1 < t \leq 2 \end{cases}$$

$$\text{Class } \{Y = 1\} : X_t = \begin{cases} W(1 - t), & 0 \leq t \leq 1 \\ 2 \sin(t - 1) + W(t - 1), & 1 < t \leq 2 \end{cases}$$



Sample of size $n = 100$ for each class of Y .

- Avec $B=50$

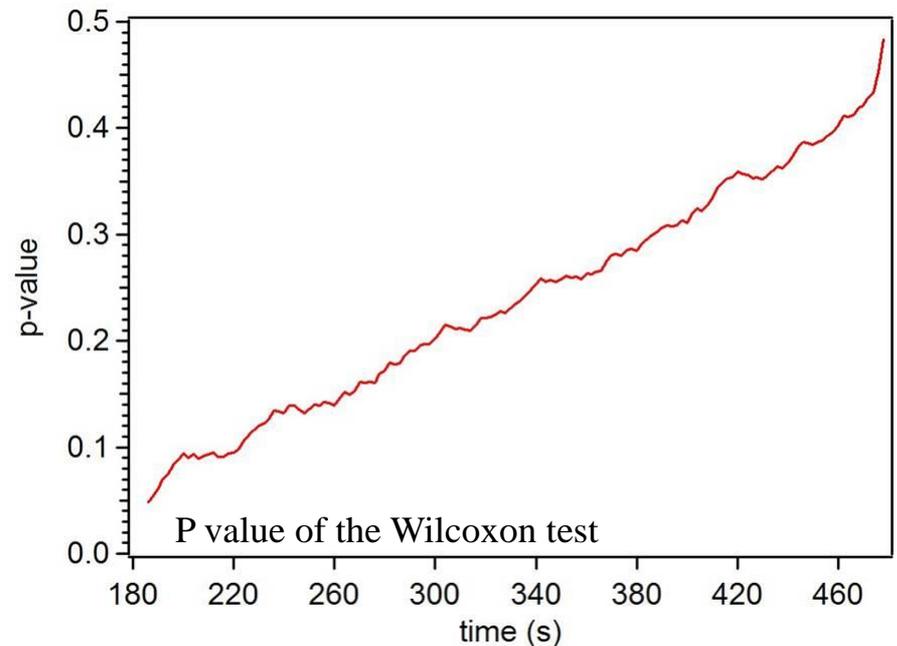


For the Wilcoxon test (one-tailed) with the first error type fixed to 0.05, the minimum t^* for which the test is not significant is $t^* = 1.46$. The Wilcoxon statistic is 1.582 and the two averaged AUC corresponding to $t^* = 1.46$ and $T = 2$ are $\overline{AUC}(t^*) = 0.866$ and $\overline{AUC}(T) = 0.872$.

5.3 Courbes de pétrissage

Prédiction anticipée

- $B=50$
- $t^*=186$
- Il est donc possible de réduire de plus de moitié la durée d'étude!



5.4 Prévision adaptative

- Au lieu d'un t^* commun, adapter t^* à chaque trajectoire nouvelle ω , connaissant le début de la trajectoire. Pour certaines trajectoires il pourra être nécessaire d'observer le processus plus longtemps que sur $[0, t^*]$, pour d'autres non.
- t^* devient une v.a. $t^*(\omega)$

- Procédure proche dans son esprit des tests séquentiels:
 - On discrétise $[0, T]$ avec un pas h
 - Si à t , on arrête d'observer $X(\omega)$ et que l'on prend une décision de classement alors $t^*=t$, sinon on continue jusqu'à $t+h$ etc.
- La décision dépend de la similarité de $X(\omega)$ avec des observations x_i en tenant compte de la prédiction que l'on peut faire de Y

« Taux de conservation »

- d_t score discriminant calculé sur $[0,t]$
- $\Omega_\omega(t)$ ensemble des observations prédites comme ω au temps t .
- $P_{0|\Omega_\omega(t)}$ proportion classée dans le groupe $Y=0$ au temps T . Idem pour

$$P_{1|\Omega_\omega(t)} \quad P_{0|\bar{\Omega}_\omega(t)} \quad P_{1|\bar{\Omega}_\omega(t)}$$

- On a $p_{0|\Omega_\omega(t)} + p_{1|\Omega_\omega(t)} = 1$ et $p_{0|\bar{\Omega}_\omega(t)} + p_{1|\bar{\Omega}_\omega(t)} = 1$

- Deux taux de conservation:

$$C_{\Omega_\omega(t)} = \max\{p_{0|\Omega_\omega(t)}, p_{1|\Omega_\omega(t)}\}$$

$$C_{\bar{\Omega}_\omega(t)} = \max\{p_{0|\bar{\Omega}_\omega(t)}, p_{1|\bar{\Omega}_\omega(t)}\}$$

- Taux global de conservation $\min(C_{\Omega_\omega(t)}; C_{\bar{\Omega}_\omega(t)})$

- Pour tout t $0.5 \leq C_\Omega(\omega, t) \leq 1$

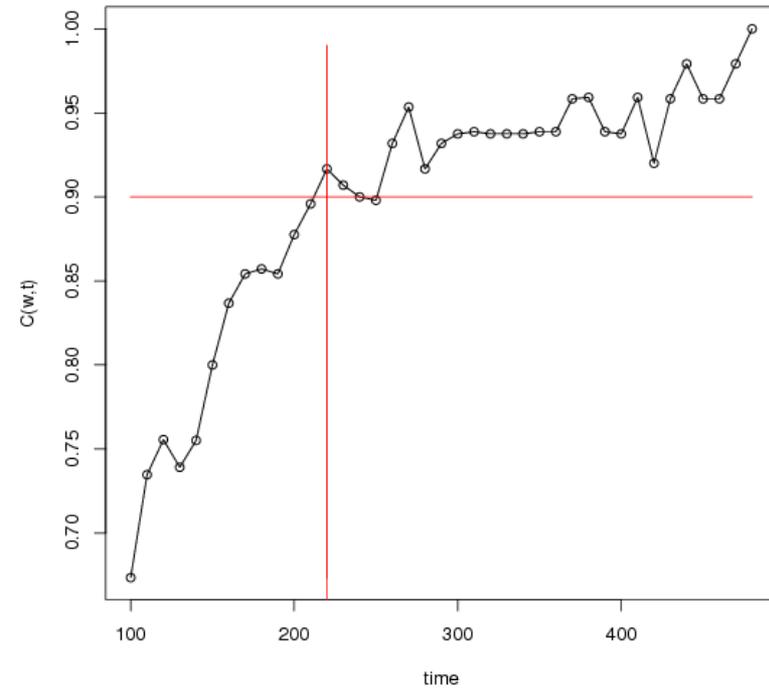
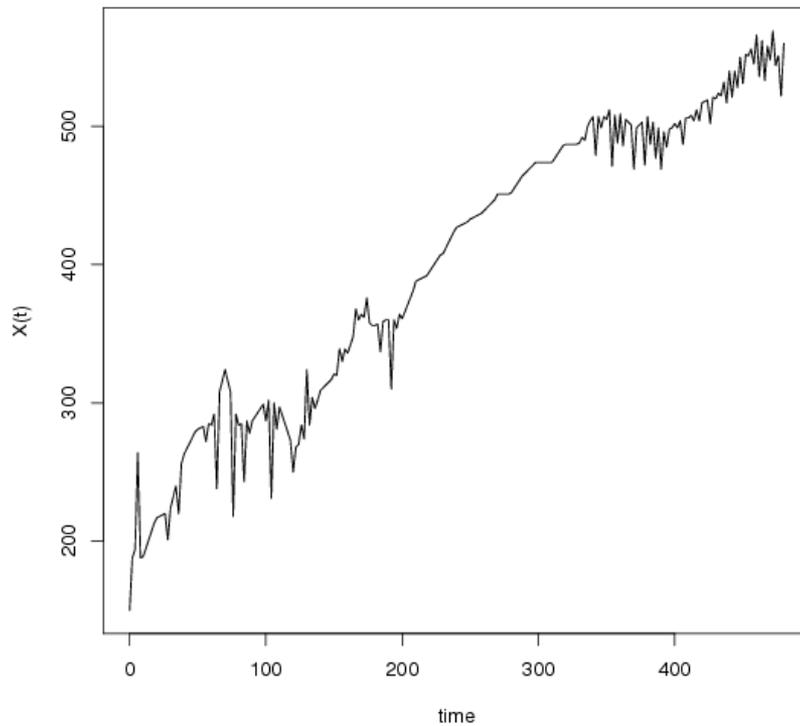
- $C_\Omega(\omega, T) = 1.$

Règle de décision

- En prenant un niveau de confiance γ , ici 0.9, on définit la règle adaptative pour ω à l'instant t :
 - (1) Si $C_{\Omega}(\omega, t) > \gamma$ alors l'observation de ω sur $[0, t]$ suffit pour prédire $Y(\omega)$ car la prédiction à t est la même que la prédiction à T du sous-groupe $\Omega_{\omega}(t)$
 - (2) Si $C_{\Omega}(\omega, t) < \gamma$, on continue d'observer jusqu'à $t+h$ et on recommence jusqu'à satisfaction de (1)

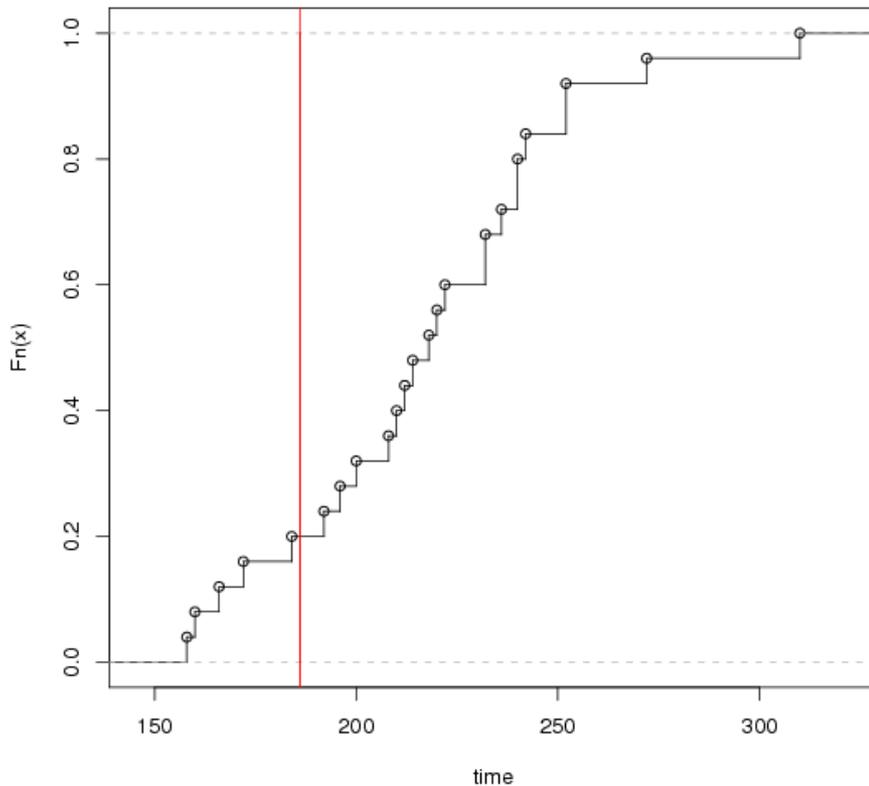
Application

une nouvelle farine



taux de conservation

25 « nouvelles » farines



- Distribution cumulée empirique de $t^*(\omega)$. 5 points plus en avance que $t = 186$, temps optimal pour la prédiction anticipée. 10 prédites comme «mauvaise».

6. Conclusions et perspectives

- La régression PLS permet d'effectuer une prédiction linéaire de manière simple et efficace
- Nécessité de prétraitements pour données bruitées
- Prédiction anticipée via une procédure bootstrap, possibilité de prédiction « on-line » : adapter t^* pour chaque nouvelle courbe
- En cours:
 - Comparaison avec régression logistique PLS fonctionnelle et autres approches

Références

- Aguilera A.M., Escabias, M. , Valderrama M.J. (2006) Using principal components for estimating logistic regression with high-dimensional multicollinear data, *Computational Statistics & Data Analysis*, 50, 1905-1924
- Barker M., Rayens W. (2003) Partial least squares for discrimination. *J. of Chemometrics* 17:166–173
- Dabo-Niang S., Ferraty F. (2008): *Functional and Operatorial Statistics*, Springer-Verlag
- Costanzo D., Preda C. , Saporta G. (2006) Anticipated prediction in discriminant analysis on functional data for binary response . In *COMPSTAT2006*, p. 821-828, Physica-Verlag
- Lévéder C., Abraham C., Cornillon P. A., Matzner-Lober E., Molinari N. (2004) Discrimination de courbes de pétrissage. *Chimiometrie 2004*, 37–43.
- Preda C. , Saporta G. (2005) PLS regression on a stochastic process, *Computational Statistics and Data Analysis*, 48, 149-158.
- Preda C., Saporta G., Lévéder C., (2007) PLS classification of functional data, *Computational Statistics*, 22(2), 223-235
- Ramsay J.O. , Silverman (2005) *Functional data analysis*, 2nd edition, Springer