

# Regresión lineal funcional.

Alejandro Cholaquidis

CMAT-Facultad de Ciencias, UdelaR  
Montevideo Uruguay

*Trabajo en conjunto con: A. Cuevas and J.R. Berrendero*

Seminario de Probabilidad y Estadística - Julio 2021

## 1 Regresión lineal

## 2 RKHS

## 3 Estimación de $\beta$

- Un estimador consistente en  $L^2$ , basado en regularización
- Un estimador consistente en el RKHS basado en discretización.

## 1 Regresión lineal

## 2 RKHS

## 3 Estimación de $\beta$

- Un estimador consistente en  $L^2$ , basado en regularización
- Un estimador consistente en el RKHS basado en discretización.

# El modelo lineal clásico

Supongamos que  $Y$  es una v.a. real,  $X$  un elemento aleatorio a valores en un Hilbert  $H$ , y

$$Y = \alpha_0 + \Gamma(X) + \epsilon$$

donde  $\alpha_0 \in \mathbb{R}$ ,  $\Gamma$  es un funcional lineal acotado en  $H$ ,  $\epsilon$  un ruido aleatorio, que se asume independiente de  $X$ .

# El modelo lineal clásico

Supongamos que  $Y$  es una v.a. real,  $X$  un elemento aleatorio a valores en un Hilbert  $H$ , y

$$Y = \alpha_0 + \Gamma(X) + \epsilon$$

donde  $\alpha_0 \in \mathbb{R}$ ,  $\Gamma$  es un funcional lineal acotado en  $H$ ,  $\epsilon$  un ruido aleatorio, que se asume independiente de  $X$ .

Usualmente  $H = L^2[0, 1]$ ,  $\Gamma(X) = \langle X, \beta \rangle$  con  $\beta \in H$ ,  $X(t) \in L^2(\Omega)$ ,  $\mathbb{E}(\epsilon) = 0$ ,  $\mathbb{E}(\epsilon^2) = \sigma^2 < \infty$ , entonces

$$Y = \beta_0 + \int_0^1 \beta(s)X(s)ds + \epsilon. \quad (1)$$

# El modelo lineal clásico

Supongamos que  $Y$  es una v.a. real,  $X$  un elemento aleatorio a valores en un Hilbert  $H$ , y

$$Y = \alpha_0 + \Gamma(X) + \epsilon$$

donde  $\alpha_0 \in \mathbb{R}$ ,  $\Gamma$  es un funcional lineal acotado en  $H$ ,  $\epsilon$  un ruido aleatorio, que se asume independiente de  $X$ .

Usualmente  $H = L^2[0, 1]$ ,  $\Gamma(X) = \langle X, \beta \rangle$  con  $\beta \in H$ ,  $X(t) \in L^2(\Omega)$ ,  $\mathbb{E}(\epsilon) = 0$ ,  $\mathbb{E}(\epsilon^2) = \sigma^2 < \infty$ , entonces

$$Y = \beta_0 + \int_0^1 \beta(s)X(s)ds + \epsilon. \quad (1)$$

Si tenemos  $(X_i, Y_i)$  iid, para  $i = 1, \dots, n$ , con

$$Y_i = \beta_0 + \int_0^1 \beta(s)X_i(s)ds + \epsilon_i,$$

queremos estimar  $\beta$ .

# El modelo lineal clásico

Escribimos

$$Y - \mathbb{E}(Y) = \int_0^1 \beta(t)(X(t) - \mathbb{E}(X(t)))dt + \epsilon \quad (2)$$

# El modelo lineal clásico

Escribimos

$$Y - \mathbb{E}(Y) = \int_0^1 \beta(t)(X(t) - \mathbb{E}(X(t)))dt + \epsilon \quad (2)$$

Si multiplicamos (2) por  $X - \mathbb{E}(X)$ , y tomamos esperanza

$$\mathbb{E}\left[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))\right] = \mathbb{E}\left[(X - \mathbb{E}(X)) \underbrace{\int_0^1 \beta(t)(X(s) - \mathbb{E}(X(s)))ds}_{\langle X - \mathbb{E}(X), \beta \rangle}\right] =: K(\beta)$$

donde  $K : L^2[0, 1] \rightarrow L^2[0, 1]$ , es

$$(K(u))(t) = \mathbb{E}\left[\langle X - \mathbb{E}(X), u \rangle (X(t) - \mathbb{E}(X(t)))\right] = \int_0^1 \text{Cov}(X(s), X(t))u(s)ds$$



# El modelo lineal clásico

Escribimos

$$Y - \mathbb{E}(Y) = \int_0^1 \beta(t)(X(t) - \mathbb{E}(X(t)))dt + \epsilon \quad (2)$$

Si multiplicamos (2) por  $X - \mathbb{E}(X)$ , y tomamos esperanza

$$\mathbb{E}\left[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))\right] = \mathbb{E}\left[(X - \mathbb{E}(X)) \underbrace{\int_0^1 \beta(t)(X(s) - \mathbb{E}(X(s)))ds}_{\langle X - \mathbb{E}(X), \beta \rangle}\right] =: K(\beta)$$

donde  $K : L^2[0, 1] \rightarrow L^2[0, 1]$ , es

$$(K(u))(t) = \mathbb{E}\left[\langle X - \mathbb{E}(X), u \rangle (X(t) - \mathbb{E}(X(t)))\right] = \int_0^1 \text{Cov}(X(s), X(t))u(s)ds$$

Se puede probar

- $K$  es autoadjunto:  $\langle K(u), v \rangle = \langle u, K(v) \rangle$

# El modelo lineal clásico

Escribimos

$$Y - \mathbb{E}(Y) = \int_0^1 \beta(t)(X(t) - \mathbb{E}(X(t)))dt + \epsilon \quad (2)$$

Si multiplicamos (2) por  $X - \mathbb{E}(X)$ , y tomamos esperanza

$$\mathbb{E}\left[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))\right] = \mathbb{E}\left[(X - \mathbb{E}(X)) \underbrace{\int_0^1 \beta(t)(X(s) - \mathbb{E}(X(s)))ds}_{\langle X - \mathbb{E}(X), \beta \rangle}\right] =: K(\beta)$$

donde  $K : L^2[0, 1] \rightarrow L^2[0, 1]$ , es

$$(K(u))(t) = \mathbb{E}\left[\langle X - \mathbb{E}(X), u \rangle (X(t) - \mathbb{E}(X(t)))\right] = \int_0^1 \text{Cov}(X(s), X(t))u(s)ds$$

Se puede probar

- $K$  es autoadjunto:  $\langle K(u), v \rangle = \langle u, K(v) \rangle$
- no negativo:  $\langle K(u), u \rangle \geq 0$

# El modelo lineal clásico

Escribimos

$$Y - \mathbb{E}(Y) = \int_0^1 \beta(t)(X(t) - \mathbb{E}(X(t)))dt + \epsilon \quad (2)$$

Si multiplicamos (2) por  $X - \mathbb{E}(X)$ , y tomamos esperanza

$$\mathbb{E}\left[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))\right] = \mathbb{E}\left[(X - \mathbb{E}(X)) \underbrace{\int_0^1 \beta(t)(X(s) - \mathbb{E}(X(s)))ds}_{\langle X - \mathbb{E}(X), \beta \rangle}\right] =: K(\beta)$$

donde  $K : L^2[0, 1] \rightarrow L^2[0, 1]$ , es

$$(K(u))(t) = \mathbb{E}\left[\langle X - \mathbb{E}(X), u \rangle (X(t) - \mathbb{E}(X(t)))\right] = \int_0^1 \text{Cov}(X(s), X(t))u(s)ds$$

Se puede probar

- $K$  es autoadjunto:  $\langle K(u), v \rangle = \langle u, K(v) \rangle$
- no negativo:  $\langle K(u), u \rangle \geq 0$
- Hilbert-Schmidt:  $\sum_i \|K(e_i)\| < \infty$ ,  $e_i$  b.o.n.

# El modelo lineal clásico

Escribimos

$$Y - \mathbb{E}(Y) = \int_0^1 \beta(t)(X(t) - \mathbb{E}(X(t)))dt + \epsilon \quad (2)$$

Si multiplicamos (2) por  $X - \mathbb{E}(X)$ , y tomamos esperanza

$$\mathbb{E}\left[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))\right] = \mathbb{E}\left[(X - \mathbb{E}(X)) \underbrace{\int_0^1 \beta(t)(X(s) - \mathbb{E}(X(s)))ds}_{\langle X - \mathbb{E}(X), \beta \rangle}\right] =: K(\beta)$$

donde  $K : L^2[0, 1] \rightarrow L^2[0, 1]$ , es

$$(K(u))(t) = \mathbb{E}\left[\langle X - \mathbb{E}(X), u \rangle (X(t) - \mathbb{E}(X(t)))\right] = \int_0^1 \text{Cov}(X(s), X(t))u(s)ds$$

Se puede probar

- $K$  es autoadjunto:  $\langle K(u), v \rangle = \langle u, K(v) \rangle$
- no negativo:  $\langle K(u), u \rangle \geq 0$
- Hilbert-Schmidt:  $\sum_i \|K(e_i)\| < \infty$ ,  $e_i$  b.o.n.

Por lo tanto  $\overline{K(B_H(0, 1))}$  es compacto, y por lo tanto **no es invertible**.

# El modelo lineal clásico

Para resolver este problema, sea  $\lambda_i$  los autovalores de  $K$ , asociados a autovectores  $v_i$ . Se puede probar que

$$X(t) - \mathbb{E}(X(t)) = \sum_{i=1}^{\infty} \xi_i v_i(t) \quad \text{en } L^2(\Omega), \text{ uniforme en } t \quad (3)$$

donde  $\xi_i$  v.a. tal que  $\mathbb{E}(\xi_i) = 0$ ,  $\mathbb{E}(\xi_j^2) = \lambda_j$ ,  $\mathbb{E}(\xi_i, \xi_j) = 0$  si  $i \neq j$ .

# El modelo lineal clásico

Para resolver este problema, sea  $\lambda_i$  los autovalores de  $K$ , asociados a autovectores  $v_i$ . Se puede probar que

$$X(t) - \mathbb{E}(X(t)) = \sum_{i=1}^{\infty} \xi_i v_i(t) \quad \text{en } L^2(\Omega), \text{ uniforme en } t \quad (3)$$

donde  $\xi_i$  v.a. tal que  $\mathbb{E}(\xi_i) = 0$ ,  $\mathbb{E}(\xi_j^2) = \lambda_j$ ,  $\mathbb{E}(\xi_i, \xi_j) = 0$  si  $i \neq j$ .

Si  $\{v_i\}_i$  es bon,  $\beta = \sum \langle \beta, v_i \rangle v_i$ ,

$$\langle \mathbb{E}[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))], v_j \rangle = \langle K(\beta), v_j \rangle = \langle \beta, K(v_j) \rangle = \lambda_j \langle \beta, v_j \rangle \quad j = 1, 2, \dots$$

# El modelo lineal clásico

Para resolver este problema, sea  $\lambda_i$  los autovalores de  $K$ , asociados a autovectores  $v_i$ . Se puede probar que

$$X(t) - \mathbb{E}(X(t)) = \sum_{i=1}^{\infty} \xi_i v_i(t) \quad \text{en } L^2(\Omega), \text{ uniforme en } t \quad (3)$$

donde  $\xi_i$  v.a. tal que  $\mathbb{E}(\xi_i) = 0$ ,  $\mathbb{E}(\xi_j^2) = \lambda_j$ ,  $\mathbb{E}(\xi_i, \xi_j) = 0$  si  $i \neq j$ .

Si  $\{v_i\}_i$  es bon,  $\beta = \sum \langle \beta, v_i \rangle v_i$ ,

$$\langle \mathbb{E}[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))], v_j \rangle = \langle K(\beta), v_j \rangle = \langle \beta, K(v_j) \rangle = \lambda_j \langle \beta, v_j \rangle \quad j = 1, 2, \dots$$

De (3):

$$\beta = \sum_{j=1}^{\infty} \frac{\langle \mathbb{E}[(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))], v_j \rangle}{\lambda_j} v_j = \sum_{j=1}^{\infty} \frac{\mathbb{E}[\xi_j(Y - \mathbb{E}(Y))]}{\lambda_j} v_j.$$

Por lo tanto  $\beta \in L^2[0, 1]$  si y sólo si  $\sum_j (\mathbb{E}[\xi_j(Y - \mathbb{E}(Y))])^2 / \lambda_j^2 < \infty$ .

# El modelo lineal clásico

Algunas desventajas de este modelo

- $L^2[0, 1]$  es “demasiado grande” para  $\beta$ : se usan métodos de regularización (penalización, suavizado, etc...) para excluir funciones muy irregulares.



# El modelo lineal clásico

## Algunas desventajas de este modelo

- $L^2[0, 1]$  es “demasiado grande” para  $\beta$ : se usan métodos de regularización (penalización, suavizado, etc...) para excluir funciones muy irregulares.
- La función  $\{X(t) : t \in [0, 1]\} \rightarrow X(t_0)$  no es un operador lineal y continuo en  $L^2[0, 1] \rightarrow \mathbb{R}$ . Esto importa si se quiere hacer reducción de dimensión vía selección de variables:

$$\{X(t) : t \in [0, 1]\} \rightarrow (X(t_1), \dots, X(t_p))$$

# El modelo lineal clásico

## Algunas desventajas de este modelo

- $L^2[0, 1]$  es “demasiado grande” para  $\beta$ : se usan métodos de regularización (penalización, suavizado, etc...) para excluir funciones muy irregulares.
- La función  $\{X(t) : t \in [0, 1]\} \rightarrow X(t_0)$  no es un operador lineal y continuo en  $L^2[0, 1] \rightarrow \mathbb{R}$ . Esto importa si se quiere hacer reducción de dimensión vía selección de variables:

$$\{X(t) : t \in [0, 1]\} \rightarrow (X(t_1), \dots, X(t_p))$$

- El modelo finito  $Y_i = \alpha_0 + \sum_{j=1}^p \beta_j X_i(t_j) + \epsilon_i$   $i = 1, \dots, n$  no es un caso particular del  $L^2$ , ya que  $\{X(t) : t \in [0, 1]\} \rightarrow \sum_j \beta_j X(t_j)$  no es un funcional continuo en  $L^2$ .

# El modelo lineal clásico

## Algunas desventajas de este modelo

- $L^2[0, 1]$  es “demasiado grande” para  $\beta$ : se usan métodos de regularización (penalización, suavizado, etc...) para excluir funciones muy irregulares.
- La función  $\{X(t) : t \in [0, 1]\} \rightarrow X(t_0)$  no es un operador lineal y continuo en  $L^2[0, 1] \rightarrow \mathbb{R}$ . Esto importa si se quiere hacer reducción de dimensión vía selección de variables:

$$\{X(t) : t \in [0, 1]\} \rightarrow (X(t_1), \dots, X(t_p))$$

- El modelo finito  $Y_i = \alpha_0 + \sum_{j=1}^p \beta_j X_i(t_j) + \epsilon_i$   $i = 1, \dots, n$  no es un caso particular del  $L^2$ , ya que  $\{X(t) : t \in [0, 1]\} \rightarrow \sum_j \beta_j X(t_j)$  no es un funcional continuo en  $L^2$ .

## RKHS

En el enfoque RKHS  $\beta \in H(K) \subset L^2[0, 1]$  donde  $H(K)$  es el RKHS del operador  $K$ .

## 1 Regresión lineal

## 2 RKHS

## 3 Estimación de $\beta$

- Un estimador consistente en  $L^2$ , basado en regularización
- Un estimador consistente en el RKHS basado en discretización.

## RKHS I

Sea  $k(s, t)$  un núcleo continuo, simétrico, semidefinido positivo. Definimos

$$H_0(k) = \left\{ f : f(s) = \sum_{i=1}^n a_i k(s, t_i), a_i \in \mathbb{R}, t_i \in [0, 1], n \in \mathbb{N} \right\},$$

## RKHS I

Sea  $k(s, t)$  un núcleo continuo, simétrico, semidefinido positivo. Definimos

$$H_0(k) = \left\{ f : f(s) = \sum_{i=1}^n a_i k(s, t_i), a_i \in \mathbb{R}, t_i \in [0, 1], n \in \mathbb{N} \right\},$$

en este espacio definimos el producto interno  $\langle \cdot, \cdot \rangle_k$ , dado por

$$\langle f, g \rangle_k = \sum_{i,j} a_i b_j k(s_i, t_j)$$

## RKHS I

Sea  $k(s, t)$  un núcleo continuo, simétrico, semidefinido positivo. Definimos

$$H_0(k) = \left\{ f : f(s) = \sum_{i=1}^n a_i k(s, t_i), a_i \in \mathbb{R}, t_i \in [0, 1], n \in \mathbb{N} \right\},$$

en este espacio definimos el producto interno  $\langle \cdot, \cdot \rangle_k$ , dado por

$$\langle f, g \rangle_k = \sum_{i,j} a_i b_j k(s_i, t_j)$$

El RKHS asociado a  $k$  es  $H(k)$ , el límite puntual de sucesiones de Cauchy en  $H_0(k)$ .

## RKHS I

Sea  $k(s, t)$  un núcleo continuo, simétrico, semidefinido positivo. Definimos

$$H_0(k) = \left\{ f : f(s) = \sum_{i=1}^n a_i k(s, t_i), a_i \in \mathbb{R}, t_i \in [0, 1], n \in \mathbb{N} \right\},$$

en este espacio definimos el producto interno  $\langle \cdot, \cdot \rangle_k$ , dado por

$$\langle f, g \rangle_k = \sum_{i,j} a_i b_j k(s_i, t_j)$$

El RKHS asociado a  $k$  es  $H(k)$ , el límite puntual de sucesiones de Cauchy en  $H_0(k)$ .

Propiedad de reproducción:

$$f(t) = \langle f, k(\cdot, t) \rangle_k \quad \forall f \in H(k)$$



## RKHS I

Sea  $k(s, t)$  un núcleo continuo, simétrico, semidefinido positivo. Definimos

$$H_0(k) = \left\{ f : f(s) = \sum_{i=1}^n a_i k(s, t_i), a_i \in \mathbb{R}, t_i \in [0, 1], n \in \mathbb{N} \right\},$$

en este espacio definimos el producto interno  $\langle \cdot, \cdot \rangle_k$ , dado por

$$\langle f, g \rangle_k = \sum_{i,j} a_i b_j k(s_i, t_j)$$

El RKHS asociado a  $k$  es  $H(k)$ , el límite puntual de sucesiones de Cauchy en  $H_0(k)$ .

Propiedad de reproducción:

$$f(t) = \langle f, k(\cdot, t) \rangle_k \quad \forall f \in H(k)$$

El operador evaluación es continuo:

$$|f_n(s) - f(s)| \leq |\langle k(s, \cdot), f_n - f \rangle_k| \leq \|k(s, \cdot)\|_k \|f_n - f\|_k = k(s, s)^{1/2} \|f_n - f\|_k.$$

## RKHS I

Sea  $k(s, t)$  un núcleo continuo, simétrico, semidefinido positivo. Definimos

$$H_0(k) = \left\{ f : f(s) = \sum_{i=1}^n a_i k(s, t_i), a_i \in \mathbb{R}, t_i \in [0, 1], n \in \mathbb{N} \right\},$$

en este espacio definimos el producto interno  $\langle \cdot, \cdot \rangle_k$ , dado por

$$\langle f, g \rangle_k = \sum_{i,j} a_i b_j k(s_i, t_j)$$

El RKHS asociado a  $k$  es  $H(k)$ , el límite puntual de sucesiones de Cauchy en  $H_0(k)$ .

Propiedad de reproducción:

$$f(t) = \langle f, k(\cdot, t) \rangle_k \quad \forall f \in H(k)$$

El operador evaluación es continuo:

$$|f_n(s) - f(s)| \leq |\langle k(s, \cdot), f_n - f \rangle_k| \leq \|k(s, \cdot)\|_k \|f_n - f\|_k = k(s, s)^{1/2} \|f_n - f\|_k.$$

Como  $k$  es continuo, la convergencia en el RKHS implica la convergencia uniforme y por lo tanto las funciones en  $H(k)$  son continuas.

## RKHS II, otra construcción posible

Supongamos  $X(t) \in L^2(\Omega)$ ,  $X \in L^2[0, 1]$  c.s, con función de covarianza  $k$  y función de media  $m$ . Sea

$$L_0(X) = \left\{ \sum_{i=1}^p a_i (X(t_i) - m(t_i)), p \in \mathbb{N}, t_i \in [0, 1], a_1, \dots, a_p \in \mathbb{R} \right\}$$

y  $L(X)$  la **completación**  $L^2(\Omega)$  de  $L_0(X)$ .

## RKHS II, otra construcción posible

Supongamos  $X(t) \in L^2(\Omega)$ ,  $X \in L^2[0, 1]$  c.s, con función de covarianza  $k$  y función de media  $m$ . Sea

$$L_0(X) = \left\{ \sum_{i=1}^p a_i (X(t_i) - m(t_i)), p \in \mathbb{N}, t_i \in [0, 1], a_1, \dots, a_p \in \mathbb{R} \right\}$$

y  $L(X)$  la **completación**  $L^2(\Omega)$  de  $L_0(X)$ . Definimos para  $U \in L(X)$ ,

$$\Psi_X(U)(s) = \langle U, X(s) - m(s) \rangle = \mathbb{E}(U(X(s) - m(s))).$$

Es un mapa inyectivo de  $L(X)$  a  $L^2[0, 1]$ .

## RKHS II, otra construcción posible

Supongamos  $X(t) \in L^2(\Omega)$ ,  $X \in L^2[0, 1]$  c.s, con función de covarianza  $k$  y función de media  $m$ . Sea

$$L_0(X) = \left\{ \sum_{i=1}^p a_i (X(t_i) - m(t_i)), p \in \mathbb{N}, t_i \in [0, 1], a_1, \dots, a_p \in \mathbb{R} \right\}$$

y  $L(X)$  la **completación**  $L^2(\Omega)$  de  $L_0(X)$ . Definimos para  $U \in L(X)$ ,

$$\Psi_X(U)(s) = \langle U, X(s) - m(s) \rangle = \mathbb{E}(U(X(s) - m(s))).$$

Es un mapa inyectivo de  $L(X)$  a  $L^2[0, 1]$ . Definimos

$$H(k) = \{\Psi_X(U) : U \in L(X)\}.$$

## RKHS II, otra construcción posible

Supongamos  $X(t) \in L^2(\Omega)$ ,  $X \in L^2[0, 1]$  c.s, con función de covarianza  $k$  y función de media  $m$ . Sea

$$L_0(X) = \left\{ \sum_{i=1}^p a_i (X(t_i) - m(t_i)), p \in \mathbb{N}, t_i \in [0, 1], a_1, \dots, a_p \in \mathbb{R} \right\}$$

y  $L(X)$  la **completación**  $L^2(\Omega)$  de  $L_0(X)$ . Definimos para  $U \in L(X)$ ,

$$\Psi_X(U)(s) = \langle U, X(s) - m(s) \rangle = \mathbb{E}(U(X(s) - m(s))).$$

Es un mapa inyectivo de  $L(X)$  a  $L^2[0, 1]$ . Definimos

$$H(k) = \{\Psi_X(U) : U \in L(X)\}.$$

Es un espacio de Hilbert con el producto interno heredado de  $L(X)$ :

$$\langle f, g \rangle_k := \langle \Psi_X^{-1}(f), \Psi_X^{-1}(g) \rangle.$$

## RKHS II, otra construcción posible

Supongamos  $X(t) \in L^2(\Omega)$ ,  $X \in L^2[0, 1]$  c.s, con función de covarianza  $k$  y función de media  $m$ . Sea

$$L_0(X) = \left\{ \sum_{i=1}^p a_i (X(t_i) - m(t_i)), p \in \mathbb{N}, t_i \in [0, 1], a_1, \dots, a_p \in \mathbb{R} \right\}$$

y  $L(X)$  la **completación**  $L^2(\Omega)$  de  $L_0(X)$ . Definimos para  $U \in L(X)$ ,

$$\Psi_X(U)(s) = \langle U, X(s) - m(s) \rangle = \mathbb{E}(U(X(s) - m(s))).$$

Es un mapa inyectivo de  $L(X)$  a  $L^2[0, 1]$ . Definimos

$$H(k) = \{\Psi_X(U) : U \in L(X)\}.$$

Es un espacio de Hilbert con el producto interno heredado de  $L(X)$ :

$$\langle f, g \rangle_k := \langle \Psi_X^{-1}(f), \Psi_X^{-1}(g) \rangle.$$

Por lo tanto  $\Psi_X$  es una isometría entre  $L(X)$  y  $H(k)$ . Observar que  $\Psi_X(X(t_i) - m(t_i))(s) = k(t_i, s) \in H(k)$ .

# RKHS vía el operador $K^{1/2}$

Dado  $k(s, t)$  continuo, simétrico, semidefinido positivo,  $K(f)(\cdot) = \int_0^1 k(s, \cdot) f(s) ds$  es compacto. Denotamos  $K^{1/2}$  el (único) operador tal que  $K^{1/2} K^{1/2} = K$ . Se define

$$\mathcal{H}(K) = \{K^{1/2}(f) : f \in L^2[0, 1]\}.$$



# RKHS vía el operador $K^{1/2}$

Dado  $k(s, t)$  continuo, simétrico, semidefinido positivo,  $K(f)(\cdot) = \int_0^1 k(s, \cdot) f(s) ds$  es compacto. Denotamos  $K^{1/2}$  el (único) operador tal que  $K^{1/2} K^{1/2} = K$ . Se define

$$\mathcal{H}(K) = \{K^{1/2}(f) : f \in L^2[0, 1]\}.$$

Si  $\{v_i\}_i$  es bon de  $L^2[0, 1]$ , de autofunciones de  $K$ , con autovalores  $\lambda_i > 0$ ,

$$\mathcal{H}(K) = \left\{ f \in L^2[0, 1] : f = \sum_i \langle f, v_i \rangle v_i \quad \text{y} \quad \left\{ \frac{\langle f, v_i \rangle}{\sqrt{\lambda_i}} \right\}_i \in \ell^2(\mathbb{N}) \right\}$$

# RKHS vía el operador $K^{1/2}$

Dado  $k(s, t)$  continuo, simétrico, semidefinido positivo,  $K(f)(\cdot) = \int_0^1 k(s, \cdot) f(s) ds$  es compacto. Denotamos  $K^{1/2}$  el (único) operador tal que  $K^{1/2} K^{1/2} = K$ . Se define

$$\mathcal{H}(K) = \{K^{1/2}(f) : f \in L^2[0, 1]\}.$$

Si  $\{v_i\}_i$  es bon de  $L^2[0, 1]$ , de autofunciones de  $K$ , con autovalores  $\lambda_i > 0$ ,

$$\mathcal{H}(K) = \left\{ f \in L^2[0, 1] : f = \sum_i \langle f, v_i \rangle v_i \quad \text{y} \quad \left\{ \frac{\langle f, v_i \rangle}{\sqrt{\lambda_i}} \right\}_i \in \ell^2(\mathbb{N}) \right\}$$

La condición  $\{\langle f, v_i \rangle / \sqrt{\lambda_i}\}_i \in \ell^2(\mathbb{N})$  impone regularidad en  $f$  ya que por el Teorema de Mercer,  $\sum_i \lambda_i = \int_0^1 k(s, s) ds < \infty$ .

# RKHS vía el operador $K^{1/2}$

Dado  $k(s, t)$  continuo, simétrico, semidefinido positivo,  $K(f)(\cdot) = \int_0^1 k(s, \cdot) f(s) ds$  es compacto. Denotamos  $K^{1/2}$  el (único) operador tal que  $K^{1/2} K^{1/2} = K$ . Se define

$$\mathcal{H}(K) = \{K^{1/2}(f) : f \in L^2[0, 1]\}.$$

Si  $\{v_i\}_i$  es bon de  $L^2[0, 1]$ , de autofunciones de  $K$ , con autovalores  $\lambda_i > 0$ ,

$$\mathcal{H}(K) = \left\{ f \in L^2[0, 1] : f = \sum_i \langle f, v_i \rangle v_i \quad \text{y} \quad \left\{ \frac{\langle f, v_i \rangle}{\sqrt{\lambda_i}} \right\}_i \in \ell^2(\mathbb{N}) \right\}$$

La condición  $\{\langle f, v_i \rangle / \sqrt{\lambda_i}\}_i \in \ell^2(\mathbb{N})$  impone regularidad en  $f$  ya que por el Teorema de Mercer,  $\sum_i \lambda_i = \int_0^1 k(s, s) ds < \infty$ . El producto interno en  $\mathcal{H}(K)$  es

$$\langle f, g \rangle_k = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle \langle g, v_i \rangle}{\lambda_i}.$$

# Los dos RKHS son el mismo, para eso

## Teorema de Mercer

Sea  $k : [0, 1]^2 \rightarrow \mathbb{R}$  continuo, simétrico, definido positivo. Definimos

$$K(f)(t) = \int_0^1 k(s, t)f(s)ds$$

el cual resulta compacto y autoadjunto. Sea  $\{v_i\}_i$  bon de  $L^2[0, 1]$ , de autofunciones de  $K$ , con autovalores  $\{\lambda_i\}_i$ . Entonces para todo  $t, s$ ,

$$k(t, s) = \sum_{i=1}^{\infty} \lambda_i v_i(s)v_i(t). \quad (4)$$

La convergencia es absoluta para todo  $s, t \in [0, 1]^2$ , y uniforme en  $[0, 1]^2$ .

El mapa  $\Phi : [0, 1] \rightarrow l^2(\mathbb{N})$  definido como

$$\Phi(t) = \{\sqrt{\lambda_i}v_i(t)\}_i$$

se denomina *feature map*.

## Propiedad reproductora

$$\langle f, k(s, \cdot) \rangle_k = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle \langle k(s, \cdot), v_i \rangle}{\lambda_i} = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle K(v_i)(s)}{\lambda_i} = f(s)$$

## Propiedad reproductora

$$\langle f, k(s, \cdot) \rangle_k = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle \langle k(s, \cdot), v_i \rangle}{\lambda_i} = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle K(v_i)(s)}{\lambda_i} = f(s)$$

Por el Teorema de Mercer:

- $\langle \Phi(s), \Phi(t) \rangle_{\rho} = k(s, t)$
- $\langle \Phi(s), \Phi(\cdot) \rangle_{\rho} = k(s, \cdot) \in \mathcal{H}(K)$ .

$\mathcal{H}(K)$  and  $H(k)$  son el mismo espacio de funciones con el mismo producto.

Dado un kernel de Mercer  $k$ , existe un único espacio de Hilbert  $H$ :

- 1  $k(s, \cdot) \in H$ .

## Propiedad reproductora

$$\langle f, k(s, \cdot) \rangle_k = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle \langle k(s, \cdot), v_i \rangle}{\lambda_i} = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle K(v_i)(s)}{\lambda_i} = f(s)$$

Por el Teorema de Mercer:

- $\langle \Phi(s), \Phi(t) \rangle_{\rho} = k(s, t)$
- $\langle \Phi(s), \Phi(\cdot) \rangle_{\rho} = k(s, \cdot) \in \mathcal{H}(K)$ .

$\mathcal{H}(K)$  and  $H(k)$  son el mismo espacio de funciones con el mismo producto.

Dado un kernel de Mercer  $k$ , existe un único espacio de Hilbert  $H$ :

- 1  $k(s, \cdot) \in H$ .
- 2 Para todo  $f \in H, f(s) = \langle f, k(s, \cdot) \rangle_H$ .

## Propiedad reproductora

$$\langle f, k(s, \cdot) \rangle_k = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle \langle k(s, \cdot), v_i \rangle}{\lambda_i} = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle K(v_i)(s)}{\lambda_i} = f(s)$$

Por el Teorema de Mercer:

- $\langle \Phi(s), \Phi(t) \rangle_{\rho} = k(s, t)$
- $\langle \Phi(s), \Phi(\cdot) \rangle_{\rho} = k(s, \cdot) \in \mathcal{H}(K)$ .

$\mathcal{H}(K)$  and  $H(k)$  son el mismo espacio de funciones con el mismo producto.

Dado un kernel de Mercer  $k$ , existe un único espacio de Hilbert  $H$ :

- 1  $k(s, \cdot) \in H$ .
- 2 Para todo  $f \in H, f(s) = \langle f, k(s, \cdot) \rangle_H$ .
- 3 El espacio generado por  $\{k(s, \cdot) : s \in [0, 1]\}$  es denso en  $H$ ,



## Propiedad reproductora

$$\langle f, k(s, \cdot) \rangle_k = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle \langle k(s, \cdot), v_i \rangle}{\lambda_i} = \sum_{i=1}^{\infty} \frac{\langle f, v_i \rangle K(v_i)(s)}{\lambda_i} = f(s)$$

Por el Teorema de Mercer:

- $\langle \Phi(s), \Phi(t) \rangle_{\rho} = k(s, t)$
- $\langle \Phi(s), \Phi(\cdot) \rangle_{\rho} = k(s, \cdot) \in \mathcal{H}(K)$ .

$\mathcal{H}(K)$  and  $H(k)$  son el mismo espacio de funciones con el mismo producto.

Dado un kernel de Mercer  $k$ , existe un único espacio de Hilbert  $H$ :

- 1  $k(s, \cdot) \in H$ .
- 2 Para todo  $f \in H, f(s) = \langle f, k(s, \cdot) \rangle_H$ .
- 3 El espacio generado por  $\{k(s, \cdot) : s \in [0, 1]\}$  es denso en  $H$ ,

Resta probar 3, que se sigue de: si  $f \in \mathcal{H}(K)$  tal que  $\langle f, k(s, \cdot) \rangle = 0$  para todo  $s$ , entonces  $f(s) = 0$  para todo  $s$ .

# La idea general

Reemplazar  $\langle X, \beta \rangle$  en  $Y = \langle X, \beta \rangle + \epsilon$  con  $\langle X, \beta \rangle_k$  donde  $\beta \in H(k)$ .

# La idea general

Reemplazar  $\langle X, \beta \rangle$  en  $Y = \langle X, \beta \rangle + \epsilon$  con  $\langle X, \beta \rangle_k$  donde  $\beta \in H(k)$ . El problema es que en la mayoría de casos  $X(\omega)(\cdot) \notin H(k)$  c.s.. Por ejemplo si  $X$  es el Browniano

$$H(k) = \{f \in L^2[0, 1] : f \text{ abs. cont. y } f' \in L^2[0, 1]\}.$$

# La idea general

Reemplazar  $\langle X, \beta \rangle$  en  $Y = \langle X, \beta \rangle + \epsilon$  con  $\langle X, \beta \rangle_k$  donde  $\beta \in H(k)$ . El problema es que en la mayoría de casos  $X(\omega)(\cdot) \notin H(k)$  c.s.. Por ejemplo si  $X$  es el Browniano

$$H(k) = \{f \in L^2[0, 1] : f \text{ abs. cont. y } f' \in L^2[0, 1]\}.$$

Parzen define  $\langle X, \beta \rangle_k =: \Psi_X^{-1}(\beta)$ . Si asumimos

$$Y = U_X + \epsilon, \tag{5}$$

donde  $U_X \in L(X)$ , y  $\epsilon \in L(X)^\perp$ ,  $\mathbb{E}(\epsilon) = 0$ . El modelo (5) es

$$Y = \Psi_X^{-1}(\alpha) + \epsilon, \tag{6}$$

donde  $\alpha \in H(k)$  y  $\epsilon \in L(X)^\perp$ , además

# La idea general

Reemplazar  $\langle X, \beta \rangle$  en  $Y = \langle X, \beta \rangle + \epsilon$  con  $\langle X, \beta \rangle_k$  donde  $\beta \in H(k)$ . El problema es que en la mayoría de casos  $X(\omega)(\cdot) \notin H(k)$  c.s.. Por ejemplo si  $X$  es el Browniano

$$H(k) = \{f \in L^2[0, 1] : f \text{ abs. cont. y } f' \in L^2[0, 1]\}.$$

Parzen define  $\langle X, \beta \rangle_k =: \Psi_X^{-1}(\beta)$ . Si asumimos

$$Y = U_X + \epsilon, \tag{5}$$

donde  $U_X \in L(X)$ , y  $\epsilon \in L(X)^\perp$ ,  $\mathbb{E}(\epsilon) = 0$ . El modelo (5) es

$$Y = \Psi_X^{-1}(\alpha) + \epsilon, \tag{6}$$

donde  $\alpha \in H(k)$  y  $\epsilon \in L(X)^\perp$ , además

$$\alpha(t) = \langle \alpha, k(\cdot, t) \rangle_k = \mathbb{E}[\psi_X^{-1}(\alpha)X(t)] = \mathbb{E}((Y - \epsilon)X(t)) = \mathbb{E}(YX(t)).$$

# El modelo finito-dimensional y el $L^2$ son RKHS

## Finito dimensional

Si

$$Y = \Psi_X^{-1}(\alpha) + \varepsilon. \quad (7)$$

Entonces existen  $X(t_1^*), \dots, X(t_p^*)$  y  $\beta_1, \dots, \beta_p \in \mathbb{R}$  tal que

$$Y = \beta_1 X(t_1^*) + \dots + \beta_p X(t_p^*) + \varepsilon$$

**si y sólo si** para todo  $t \in T$ ,  $\alpha(t) = \beta_1 k(t, t_1^*) + \dots + \beta_p k(t, t_p^*)$ .

# El modelo finito-dimensional y el $L^2$ son RKHS

## Finito dimensional

Si

$$Y = \Psi_X^{-1}(\alpha) + \varepsilon. \quad (7)$$

Entonces existen  $X(t_1^*), \dots, X(t_p^*)$  y  $\beta_1, \dots, \beta_p \in \mathbb{R}$  tal que

$$Y = \beta_1 X(t_1^*) + \dots + \beta_p X(t_p^*) + \varepsilon$$

**si y sólo si** para todo  $t \in T$ ,  $\alpha(t) = \beta_1 k(t, t_1^*) + \dots + \beta_p k(t, t_p^*)$ .

## El modelo $L^2$ es un RKHS

Si

$$Y = \int_0^1 \beta(t) X(t) dt + \varepsilon := \langle \beta, X \rangle_2 + \varepsilon, \quad (8)$$

entonces vale el modelo (7), ya que  $\langle \beta, X \rangle_2 \in L(X)$ .

# El modelo finito-dimensional y el $L^2$ son RKHS

## Finito dimensional

Si

$$Y = \Psi_X^{-1}(\alpha) + \varepsilon. \quad (7)$$

Entonces existen  $X(t_1^*), \dots, X(t_p^*)$  y  $\beta_1, \dots, \beta_p \in \mathbb{R}$  tal que

$$Y = \beta_1 X(t_1^*) + \dots + \beta_p X(t_p^*) + \varepsilon$$

**si y sólo si** para todo  $t \in T$ ,  $\alpha(t) = \beta_1 k(t, t_1^*) + \dots + \beta_p k(t, t_p^*)$ .

## El modelo $L^2$ es un RKHS

Si

$$Y = \int_0^1 \beta(t) X(t) dt + \varepsilon := \langle \beta, X \rangle_2 + \varepsilon, \quad (8)$$

entonces vale el modelo (7), ya que  $\langle \beta, X \rangle_2 \in L(X)$ .

**Recíprocamente**, si vale (7), y existe  $\beta \in L^2[0, 1]$  tal que  $\alpha = K\beta$ , entonces el modelo (8) vale.



# Componentes principales

Para resolver el modelo  $L^2$ , usualmente  $\{X(t) : t \in [0, 1]\}$  se proyecta sobre  $u_1, \dots, u_p$  donde  $\{u_j : 1, \dots\}$  es una b.o.n. La trayectoria se reemplaza con

$$\langle X, u_1 \rangle_2 u_1 + \dots + \langle X, u_p \rangle_2 u_p$$

Intuitivamente, esto funciona si

$$\int_0^1 X(t)\beta(t)dt \approx \sum_{j=1}^p \beta_j \langle X, u_j \rangle_2 \quad \text{donde } \beta_j = \langle \beta, u_j \rangle_2.$$

# Componentes principales

Para resolver el modelo  $L^2$ , usualmente  $\{X(t) : t \in [0, 1]\}$  se proyecta sobre  $u_1, \dots, u_p$  donde  $\{u_j : 1, \dots\}$  es una b.o.n. La trayectoria se reemplaza con

$$\langle X, u_1 \rangle_2 u_1 + \dots + \langle X, u_p \rangle_2 u_p$$

Intuitivamente, esto funciona si

$$\int_0^1 X(t)\beta(t)dt \approx \sum_{j=1}^p \beta_j \langle X, u_j \rangle_2 \quad \text{donde } \beta_j = \langle \beta, u_j \rangle_2.$$

¿Cuándo no hay pérdida, y cómo tiene que ser  $\alpha$ ?

# Componentes principales

Para resolver el modelo  $L^2$ , usualmente  $\{X(t) : t \in [0, 1]\}$  se proyecta sobre  $u_1, \dots, u_p$  donde  $\{u_j : 1, \dots, p\}$  es una b.o.n. La trayectoria se reemplaza con

$$\langle X, u_1 \rangle_2 u_1 + \dots + \langle X, u_p \rangle_2 u_p$$

Intuitivamente, esto funciona si

$$\int_0^1 X(t)\beta(t)dt \approx \sum_{j=1}^p \beta_j \langle X, u_j \rangle_2 \quad \text{donde } \beta_j = \langle \beta, u_j \rangle_2.$$

¿Cuándo no hay pérdida, y cómo tiene que ser  $\alpha$ ? Consideremos el modelo

$$Y = \beta_1 \langle X, u_1 \rangle_2 + \dots + \beta_p \langle X, u_p \rangle_2 + \varepsilon, \quad (9)$$

donde  $\beta_1, \dots, \beta_p \in \mathbb{R}$  y  $\varepsilon \in L(X)^\perp$ .

## Proposición

Si vale (9) entonces  $Y = \Psi_X^{-1}(\alpha) + \varepsilon$ .

# Componentes principales

Para resolver el modelo  $L^2$ , usualmente  $\{X(t) : t \in [0, 1]\}$  se proyecta sobre  $u_1, \dots, u_p$  donde  $\{u_j : 1, \dots\}$  es una b.o.n. La trayectoria se reemplaza con

$$\langle X, u_1 \rangle_2 u_1 + \dots + \langle X, u_p \rangle_2 u_p$$

Intuitivamente, esto funciona si

$$\int_0^1 X(t)\beta(t)dt \approx \sum_{j=1}^p \beta_j \langle X, u_j \rangle_2 \quad \text{donde } \beta_j = \langle \beta, u_j \rangle_2.$$

¿Cuándo no hay pérdida, y cómo tiene que ser  $\alpha$ ?. Consideremos el modelo

$$Y = \beta_1 \langle X, u_1 \rangle_2 + \dots + \beta_p \langle X, u_p \rangle_2 + \varepsilon, \quad (9)$$

donde  $\beta_1, \dots, \beta_p \in \mathbb{R}$  y  $\varepsilon \in L(X)^\perp$ .

## Proposición

*Si vale (9) entonces  $Y = \Psi_X^{-1}(\alpha) + \varepsilon$ . Recíprocamente si  $Y = \Psi_X^{-1}(\alpha) + \varepsilon$  y  $\alpha$  pertenece al espacio generado por  $\{Ku_1, \dots, Ku_p\}$  entonces vale el modelo (9).*

## 1 Regresión lineal

## 2 RKHS

## 3 Estimación de $\beta$

- Un estimador consistente en  $L^2$ , basado en regularización
- Un estimador consistente en el RKHS basado en discretización.

# Regularización de Tichonov

$\alpha(t) = \mathbb{E}(YX(t))$  sugiere usar  $\tilde{\alpha}(t) = \frac{1}{n} \sum_{i=1}^n Y_i X_i(t)$ , pero  $\mathbb{P}(\tilde{\alpha} \in H(k)) = 0$ .

# Regularización de Tichonov

$\alpha(t) = \mathbb{E}(YX(t))$  sugiere usar  $\tilde{\alpha}(t) = \frac{1}{n} \sum_{i=1}^n Y_i X_i(t)$ , pero  $\mathbb{P}(\tilde{\alpha} \in H(k)) = 0$ .

Consideremos

$$\check{\alpha} = \arg \min_{f \in H_k} \|\tilde{\alpha} - f\|_2^2 + \gamma_n \|f\|_k^2 = (K + \gamma_n I)^{-1} K \tilde{\alpha}.$$

y

$$\hat{\alpha} := (\hat{K} + \gamma_n I)^{-1} \hat{K} \tilde{\alpha}, \tag{10}$$

donde  $\hat{K}$  es el operador integral definido por el kernel  $\hat{k}(s, t) = n^{-1} \sum_{i=1}^n X_i(s) X_i(t)$ .

# Regularización de Tichonov

$\alpha(t) = \mathbb{E}(YX(t))$  sugiere usar  $\tilde{\alpha}(t) = \frac{1}{n} \sum_{i=1}^n Y_i X_i(t)$ , pero  $\mathbb{P}(\tilde{\alpha} \in H(k)) = 0$ .

Consideremos

$$\check{\alpha} = \arg \min_{f \in H_k} \|\tilde{\alpha} - f\|_2^2 + \gamma_n \|f\|_k^2 = (K + \gamma_n I)^{-1} K \tilde{\alpha}.$$

y

$$\hat{\alpha} := (\hat{K} + \gamma_n I)^{-1} \hat{K} \tilde{\alpha}, \quad (10)$$

donde  $\hat{K}$  es el operador integral definido por el kernel  $\hat{k}(s, t) = n^{-1} \sum_{i=1}^n X_i(s) X_i(t)$ .

## Teorema

Sea  $\gamma_n \rightarrow 0$  tal que  $\gamma_n^2 \sqrt{n} \rightarrow \infty$ , supongamos que  $\mathbb{E}(\|X\|_2^4) < \infty$ . Entonces  $\|\hat{\alpha} - \alpha\|_2 \rightarrow 0$  en probabilidad, cuando  $n \rightarrow \infty$ .



# Regularización de Tichonov

$\alpha(t) = \mathbb{E}(YX(t))$  sugiere usar  $\tilde{\alpha}(t) = \frac{1}{n} \sum_{i=1}^n Y_i X_i(t)$ , pero  $\mathbb{P}(\tilde{\alpha} \in H(k)) = 0$ .

Consideremos

$$\check{\alpha} = \arg \min_{f \in H_k} \|\tilde{\alpha} - f\|_2^2 + \gamma_n \|f\|_k^2 = (K + \gamma_n I)^{-1} K \tilde{\alpha}.$$

y

$$\hat{\alpha} := (\hat{K} + \gamma_n I)^{-1} \hat{K} \tilde{\alpha}, \quad (10)$$

donde  $\hat{K}$  es el operador integral definido por el kernel  $\hat{k}(s, t) = n^{-1} \sum_{i=1}^n X_i(s) X_i(t)$ .

## Teorema

Sea  $\gamma_n \rightarrow 0$  tal que  $\gamma_n^2 \sqrt{n} \rightarrow \infty$ , supongamos que  $\mathbb{E}(\|X\|_2^4) < \infty$ . Entonces  $\|\hat{\alpha} - \alpha\|_2 \rightarrow 0$  en probabilidad, cuando  $n \rightarrow \infty$ .

## ¿y en norma RKHS?

$\hat{\alpha} \in H(\hat{k})$ , pero no necesariamente  $\hat{\alpha} \in H(k)$ .

# Regularización de Tichonov

$\alpha(t) = \mathbb{E}(YX(t))$  sugiere usar  $\tilde{\alpha}(t) = \frac{1}{n} \sum_{i=1}^n Y_i X_i(t)$ , pero  $\mathbb{P}(\tilde{\alpha} \in H(k)) = 0$ .

Consideremos

$$\tilde{\alpha} = \arg \min_{f \in H_k} \| \tilde{\alpha} - f \|_2^2 + \gamma_n \| f \|_k^2 = (K + \gamma_n I)^{-1} K \tilde{\alpha}.$$

y

$$\hat{\alpha} := (\hat{K} + \gamma_n I)^{-1} \hat{K} \tilde{\alpha}, \quad (10)$$

donde  $\hat{K}$  es el operador integral definido por el kernel  $\hat{k}(s, t) = n^{-1} \sum_{i=1}^n X_i(s) X_i(t)$ .

## Teorema

Sea  $\gamma_n \rightarrow 0$  tal que  $\gamma_n^2 \sqrt{n} \rightarrow \infty$ , supongamos que  $\mathbb{E}(\|X\|_2^4) < \infty$ . Entonces  $\|\hat{\alpha} - \alpha\|_2 \rightarrow 0$  en probabilidad, cuando  $n \rightarrow \infty$ .

## ¿y en norma RKHS?

$\hat{\alpha} \in H(\hat{k})$ , pero no necesariamente  $\hat{\alpha} \in H(k)$ .

**Teorema:** si  $n\gamma_n^2 \rightarrow \infty$ ,  $\gamma_n \rightarrow 0$ ,  $\|\tilde{\alpha} - \alpha\|_k \rightarrow 0$  en probabilidad.

## Lema de Parzen

## Lemma

Sean  $\alpha \in H(k)$ ,  $T_p = \{t_{j,p} : j = 1, \dots, p\}$  donde  $0 \leq t_{1,p} \leq \dots \leq t_{p,p} \leq 1$ , tal que  $T_p \subset T_{p+1} \subset [0, 1]$  y  $\overline{\cup_p T_p} = [0, 1]$ . Entonces existe  $\beta_{1,p} \dots, \beta_{p,p}$  tal que

$$\left\| \alpha(\cdot) - \sum_{j=1}^p \beta_{j,p} k(t_{j,p}, \cdot) \right\|_k^2 \rightarrow 0, \text{ cuando } p \rightarrow \infty.$$

## Lema de Parzen

## Lemma

Sean  $\alpha \in H(k)$ ,  $T_p = \{t_{j,p} : j = 1, \dots, p\}$  donde  $0 \leq t_{1,p} \leq \dots \leq t_{p,p} \leq 1$ , tal que  $T_p \subset T_{p+1} \subset [0, 1]$  y  $\bigcup_p T_p = [0, 1]$ . Entonces existe  $\beta_{1,p} \dots, \beta_{p,p}$  tal que

$$\left\| \alpha(\cdot) - \sum_{j=1}^p \beta_{j,p} k(t_{j,p}, \cdot) \right\|_k^2 \rightarrow 0, \text{ cuando } p \rightarrow \infty.$$

Esto sugiere usar

$$\alpha_p(\cdot) = \sum_{j=1}^p \beta_{j,p} k(t_{j,p}, \cdot) \quad \text{y} \quad \hat{\alpha}_p(\cdot) = \sum_{j=1}^p \hat{\beta}_{j,p} k(t_{j,p}, \cdot), \quad (11)$$

donde para  $j = 1, \dots, p$ ,  $\hat{\beta}_{j,p}$  son los estimadores por mínimos cuadrados del modelo lineal  $p$ -dimensional

$$Y_i = \sum_{j=1}^p \beta_{j,p} X(t_{j,p}) + e_{i,p} = \langle \alpha_p, X \rangle_k + e_{i,p}, \quad i = 1, \dots, n. \quad (12)$$

# Consistencia

## Theorem

Supongamos que  $Y_i = \langle X, \alpha \rangle_k + \epsilon_i$ , con  $i = 1, \dots, n$ . Consideramos

$$Y_i = \sum_{j=1}^p \beta_{j,p} X(t_{j,p}) + e_{i,p} = \langle \alpha_p, X \rangle_k + e_{i,p}, \quad i = 1, \dots, n. \quad (13)$$

donde  $p = p_n \rightarrow \infty$ . Supongamos que

- (i)  $e_{i,p} = e_i$  son iid sub-Gaussianos,  $SG(\sigma_p^2)$  con  $\sigma_p^2 \geq C_0 > 0$  para todo  $p$ .<sup>a</sup>
- (ii)  $\sup_{t \in [0,1]} X(t)$  es sub-Gaussiano.
- (iii)  $n(\gamma_{p,p})^2 / (p^2 \log^3 n) \rightarrow \infty$ , donde  $\gamma_{p,p}$  es el autovalor mas chico de  $K_{T_p}$ , la matriz de covarianzas de  $(X(t_{1,p}), \dots, X(t_{p,p}))$ .

Entonces

$$\nu_n \|\hat{\alpha}_p - \alpha_p\|_k^2 \rightarrow 0 \quad \text{c.s.} \quad \forall \nu_n \rightarrow \infty$$

tal que  $n\gamma_{p,p} / (p^2 \nu_n \log n) \rightarrow \infty$ . Como consecuencia del Lema de Parzen,

$$\|\alpha - \hat{\alpha}_p\|_k^2 = \max\{\nu_n^{-1}, \mathcal{O}(\|\alpha - \alpha_p\|_k^2)\} \quad \text{c.s.}$$

---

<sup>a</sup> $\mathbb{P}(|e_{i,p}| > t) \leq 2 \exp(-t^2 / (2\sigma_p^2))$

# El autovalor mas chico de $K_{T_p}$







## Proposición

Sea  $\{W(t)\}_{t \in [0,1]}$  con incrementos estacionarios e independientes, tal que  $\mathbb{E}(W^2(t)) < \infty$  y  $\mathbb{E}(W(t)) = 0$  para todo  $t \in [0, 1]$ , entonces para todo  $\delta > 0$ ,

$$p^{1+\delta} \gamma_{p,p} \rightarrow \infty,$$

donde  $\gamma_{p,p}$  es el autovalor mas chico de la matriz de covarianzas de  $(W(1/p), \dots, W(1))$ .

Para el fBM con Hurst  $H$ ,  $\gamma_{p,p} = \mathcal{O}(1/p^{2H})$ .

-  Berrendero, J.R., Bueno-Larraz, B. and Cuevas, A.(2018) An RKHS model for variable selection in functional linear regression. *Journal of Multivariate Analysis*
-  Berrendero, J.R., Bueno-Larraz, B. and Cuevas, A.(2019) On functional logistic regression via RKHS's. *To appear in...*
-  Berrendero, J.R., Cuevas, A. and Torrecilla, J.L.(2017) On the use of reproducing kernel Hilbert spaces in functional classification *JASA*
-  Cucker, F. and Smale J. (2002) On the mathematical foundations of learning. *Bulletin of the American mathematical society*, 39(1), 1-49.
-  Gupta, A. and Joshi, S. (2008) Some studies on the structure of covariance matrix of discrete-time fBm. *IEEE Transactions on Signal Processing* vol. 56, no 10, p. 4635-4650.
-  Parzen, E. (1959) Statistical inference on time series by Hilbert space methods, I. *Technical Report 23, Stanford University*.