

---

---

---

---

---



## Rough Paths:

- Motivación original ← estudiar "ecuaciones diferenciales" que incluyen perturbaciones aleatorias.
- Motivación reciente ← Realizar aprendizaje de máquina interpretando datos como trayectorias de funciones continuas.

## Motivación clásica:

$Y_t = f(t)$  ← función del tiempo.

$$\frac{dY_t}{dt} = v(Y_t) \quad \text{con} \quad Y_0 = y_0 \quad v: \mathbb{R} \rightarrow \mathbb{R}.$$

$$dY_t = v(Y_t) dt \quad \text{con} \quad Y_0 = y_0$$

$$\Updownarrow$$
$$Y_t - Y_s = \int_s^t v(Y_r) dr$$

Siguiente paso de generalidad:

$$dY_t = V(Y_t) dX_t$$



$$Y_t - Y_s = \int_s^t V(Y_r) dX_r$$

$X_t \leftarrow$  otra función del tiempo que satisface ciertas condiciones.

$$dY_t = V(Y_t) dX_t$$


↑  
Output

↑  
input.

¿Aplicación?  $X_t =$  precio en pesos del dolar.  
 $Y_t =$  Cartera de inversión de divisas.

Lado negativo:

Si vemos el mercado en tiempo real:



$\leftarrow$  Podría ser un problema.

Análisis detallado del problema:

$$dY_r = v(Y_r) dX_r \Leftrightarrow Y_{r+\varepsilon} - Y_r \approx v(Y_r) (X_{r+\varepsilon} - X_r).$$

Samplear  $X$  en  $[0,1]$  en tiempos

$$t_1 = \frac{1}{n}, \quad t_2 = \frac{2}{n}, \dots, \quad t_n = 1 = \frac{n}{n}.$$

$$\text{Si } X_i = X_{t_i} \quad Y_i = Y_{t_i}$$

$$Y_{i+1} = Y_i + v(Y_i) \Delta_i X$$

$$\Delta X_t \approx \Delta t + \text{error}$$

$$Y_{i+1} = Y_i + v(Y_i) \left( \frac{1}{n} + \frac{1}{\sqrt{n}} \xi_i \right).$$

modelo

$$\{\xi_i\} \leftarrow \text{v.a.i.i.d.} \quad \xi_i \sim \mathcal{N}(0,1).$$

Cuando tomamos límite obtenemos

$$dY_t = v(Y_t) (dt + dB_t).$$

$$Y_t - Y_s = \int_s^t v(Y_r) dr + \underbrace{\int_s^t v(Y_r) dB_r}_{\text{es "salt" de definir.}}$$

es "salt" de definir.

Esto motiva a formular ecuaciones del tipo


$$dY_t = V(Y_t) dX_t.$$

$X_t$  ← potencialmente tiene trayectorias muy erráticas.

¿Cómo depende el output en función del input?

↕  
¿Continuamente?

X


$$dY_t = V(Y_t) dX_t.$$

Proposición (Lyons et al).

No existe un espacio de Banach  $\mathcal{B}$

f.g. las trayectorias de un mov. Browniano

pertenezcan a  $\mathcal{B}$  casi seguramente y f.g.

el mapeo

$$(f, g) \mapsto \int_0^{(\cdot)} f(t)g(t)dt, \text{ definido primero}$$

sobre  $f, g$  diferenciables  $f, g: \mathbb{R} \rightarrow \mathbb{R}$

se extiende a  $\mathcal{B} \times \mathcal{B}$  de manera

continua.

Como esquivar esquivar esta restricción?

$$Y_t - Y_s = \int_s^t v(Y_r) dX_r \quad *$$

Framework general:

$$Y_t = (Y_t^1, \dots, Y_t^e) \quad e \in \mathbb{N}$$

$$X_s = (Y_s^1, \dots, Y_s^d) \quad d \in \mathbb{N}$$

$$V \in \mathbb{R}^{e \times d} \quad V = (V_{i,k}; \quad 1 \leq i \leq e, \quad 1 \leq k \leq d)$$

$$Y_t^i - Y_s^i = \sum_{k=1}^d \int_s^t V_{i,k}(Y_r) dX_r^k \quad \leftarrow \text{nuestra ecuación}$$

$\leftarrow$  suponer que tengo acceso a  $Y_s, X_s$ .

$$\hookrightarrow Y_t^i - Y_s^i = \sum_{k=1}^d \int_s^t \left( V_{i,k}(Y_s) + (V_{i,k}(Y_r) - V_{i,k}(Y_s)) \right) dX_r^k$$

$$= \sum_{k=1}^d \underbrace{V_{i,k}(Y_s)}_{\text{importante}} \underbrace{\int_s^t dX_r^k}$$

$$+ \sum_{k=1}^d \int_s^t \sum_{i=1}^e \int_s^r \frac{\partial V_{i,k}}{\partial Y_{r_2}^{i_2}}(Y_{r_2}) dY_{r_2}^{i_2} dX_r^k$$

$$\begin{aligned}
& \int_s^t \int_s^r \frac{\partial V_{i,r}(Y_{r_2})}{\partial y_{i_2}} dY_{r_2}^i dX_r^K \\
&= \int_s^t \int_s^r \frac{\partial V_{i,r}(Y_{r_2})}{\partial y_{i_2}} \sum_{k_2=1}^d \frac{\partial V_{i,r_2}(Y_{r_2})}{\partial y_{i_2}} dX_{r_2}^{k_2} dX_r^K \\
&= \int_s^t \int_s^r \frac{\partial V_{i,r}(Y_s)}{\partial y_{i_2}} \sum_{k_2=1}^d \frac{\partial V_{i,r_2}(Y_s)}{\partial y_{i_2}} dX_{r_2}^{k_2} dX_r^K
\end{aligned}$$

+ Terminos similares.


$$= \sum \text{Coeficientes}(s) \int_s^t \int_s^r \dots \int_s^{r_1} dX_{r_{t+1}}^{k_{t+1}} \dots dX_r^{k_t}$$

Definimos

$$\int_{s,t}^{k_1, \dots, k_t} [X] := \int_s^t \dots \int_s^{r_{t-1}} dX_{r_t}^{k_t} \dots dX_r^{k_1}$$

Ahora, en lugar de tomar el mapeo:

$$\{X_t\}_{t \geq 0} \xrightarrow{\text{No es continuo}} \{Y_t\}_{t \geq 0}$$



Aplicaciones en machine learning:

Objeto de interés:

Signaturas  $\rightarrow \left\{ S_{s,t}^{K_1, \dots, K_q} [X] \right\}$ .
 
 Suponer  $s=0, t=1$

Remark: Signaturas son "características" especiales de  $\{X_t\}_{t \geq 0}$ .

## Problema práctico:

$$- Y_t^1 = \alpha + \beta_1 Y_{t-1}^1 + \beta_2 Y_{t-2}^2 + \varepsilon_t^1 \leftarrow \text{clasif. 1.}$$

$$- Y_t^2 = \alpha + \beta_1 Y_{t-1}^1 + \beta_2 Y_{t-2}^2 + \varepsilon_t^2 \leftarrow \text{clasif. 2.}$$