


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

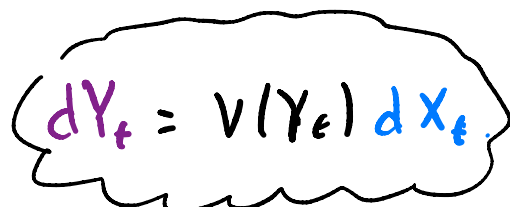
$$dY_t = V(Y_t) dX_t.$$

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 .

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

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

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

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

+ 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:

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

Problemas de clasificación que se pueden resolver con técnicas de rough path.

Analogía con regresión:

$Y \leftarrow$ respuesta (score crediticio).

$$Y = \beta_0 + \sum_{j=1}^d \beta_j X_j$$

$X_j \leftarrow$ características,
 $X_j \in \mathbb{R}$.

$\left. \begin{array}{l} Y^1, \dots, Y^n \\ (X_{1,1}, \dots, X_{d,1}), \dots, (X_{1,n}, \dots, X_{d,n}) \end{array} \right\} \leftarrow \text{observaciones}$


$\beta_0, \dots, \beta_d \leftarrow$ tienen una fórmula para calcularse.

Pasamos ahora de regresión a clasificación

Me gustaría:

$$Y = \phi \left(\beta_0 + \sum_{j=1}^d \beta_j X_j \right)$$


$$\phi(x) = \mathbb{1}_{\{x \geq 0\}}$$



$$Y = \varphi \left(\beta_0 + \sum_{j=1}^d \beta_j X_j \right)$$

$\phi(x)$ = sigmoide como en

Nos da un aprox. de la clasificación.



Nota:

Si queremos reducir

$$\sum_{l=1}^n \mathcal{E}(Y^l - \varphi(\beta_0 + \sum_{j=1}^d \beta_j X_j^l)) + \sum_{j=1}^d w_j \tilde{\mathcal{E}}(\beta_j)$$

$\mathcal{E} \leftarrow$ cuantificación del error

$\tilde{\mathcal{E}} \leftarrow$ penaliz.

De vuelta al problema de clasificación de series de tiempo:

- $X_t^1 = \alpha + \beta_1 X_{t-1}^1 + \beta_2 X_{t-2}^1 + \varepsilon_t^1 \leftarrow \text{clasif. 1. } \textcircled{\#}$

- $X_t^2 = \alpha + \beta_1 X_{t-1}^2 + \beta_2 X_{t-2}^2 + \varepsilon_t^2 \leftarrow \text{clasif. 2. } \textcircled{\#\#}$

Queremos:

- $Y \leftarrow \text{respuesta: eres } \textcircled{\#} \text{ o } \textcircled{\#\#} \checkmark$

Valores de $Y \leftarrow \{0, 1\} \checkmark$

Ahora vamos a observar:

Voy a ver algo como:




Input \leftarrow la trayectoria de la serie

Problema: como aplico lo que tengo en slides anteriores ?

↓ traducción.

Obtener "características" extraídas de la trayectoria de la serie de tiempo?

$$X \xrightarrow{\tilde{S}} (\tilde{S}_1(x), \dots, \tilde{S}_{40}(x)).$$



características.

Ahora: puedo proponer números β_0, \dots, β_4 t.g.

$$Y = \varphi \left(\beta_0 + \sum_{i=1}^{40} \beta_i \tilde{S}_i(x) \right) + \text{error de medición.}$$

Ésta es "toda" la metodología, siempre y cuando \tilde{S}_i ya estén elegidas,

Conexión con Rough paths:

Comentario:

Hay info. que me gustaría que no influyera en la variable de respuesta.

- Reconocimiento de acciones \leftarrow Marcos de referencia no importan
- Reconocimiento de caracteres chinos. \leftarrow invarianza bajo "dibujar más rápido".

Características: $X \in \mathbb{R}^d$

$$(\tilde{S}_1(x), \dots, \tilde{S}_{40}(x))$$

$$= (S_{i_1, \dots, i_q}(x); 1 \leq q \leq Q \quad i_j \in \{1, \dots, d\})$$

Justificación de que S_{i_j} son "buenos candidatos" \leftarrow depende.

- Ventaja: 1 $S_{i_1, \dots, i_q}(x)$ son invariantes
bajo reparametrizaciones.

- Ventaja 2:

$$(S_{i_1, \dots, i_q} ; q \in \mathbb{N} \setminus \{0\}, i_j \in \{1, \dots, d\}).$$

$$\downarrow$$

$$\tilde{\mathcal{F}} := \bigoplus_{q=1}^{\infty} (\mathbb{R}^d)^{\otimes q} \leftarrow = \left\{ \sum_{q=1}^{\infty} \sum_{i_1, \dots, i_q=1}^d a_{i_1, \dots, i_q} e_{i_1} \otimes \dots \otimes e_{i_q} \right\}$$

Para encajar a las S_{i_1, \dots, i_q} en $\tilde{\mathcal{F}}$

escogemos $a_{i_1, \dots, i_q} = S_{i_1, \dots, i_q}$.

Ventaja:

Si consideramos

$$\int_s^t \int_s^{t_1} \int_s^{t_2} \dots \int_s^{t_{q-1}} 1 dX_{t_q} \otimes dX_{t_{q-1}} \otimes \dots \otimes dX_s \in (\mathbb{R}^d)^{\otimes q}$$

$$\Downarrow$$

$$= \sum_{i_1, \dots, i_q} \left(\int_s^t \int_s^{t_1} \int_s^{t_2} \dots \int_s^{t_{q-1}} 1 dX_{t_q}^{i_q} dX_{t_{q-1}}^{i_{q-1}} \dots dX_s^{i_1} \right) e_{i_1} \otimes \dots \otimes e_{i_q}$$

Nota:

El "espacio de Fock" $\tilde{F} = \bigoplus_{q=0}^{\infty} (\mathbb{R}^d)^{\otimes q}$

tiene un producto que le llamamos " \otimes "

$$\begin{array}{ccc} (e_{i_1} \otimes e_{i_2}) \otimes (e_{i_3}) & = & e_{i_1} \otimes e_{i_2} \otimes e_{i_3} \\ \uparrow & & \uparrow \\ \tilde{F} & & \tilde{F} \end{array}$$

Ventaja 2:)

Por inv. bajo reparametrización:

puedo pensar que X_t solo se considera para $t \in [0, 1]$.

$Y_t \leftarrow$ otra "trayectoria" $t \in [1, 2]$ t.g. $Y_1 = X_1$

Tenemos un producto en las trayectorias.

$$(X \otimes Y)_t = \begin{cases} X_t & \text{si } t \in [0, 1] \\ Y_t & \text{si } t \in [1, 2] \end{cases} \quad t \in [0, 2]$$

↑
producto en
las trayectorias.

$$S(X \otimes Y) = S(X) \otimes S(Y). \leftarrow$$

Signaturas
pueden calcularse
en sub-intervalos
y luego "pegarse"


Ventaja 2.2.)

$$X_t = t v \quad v \in \mathbb{R}^d$$

Entonces

$$1 + \int_0^1 dX_v + \int_0^1 \int_0^{t_1} dX_{t_2} \otimes dX_{t_1} + \dots$$

$$= 1 + \sum_{k=1}^M \frac{v^{\otimes k}}{k!} = \exp\{v\}.$$



$X_t \leftarrow$ diferenciable.

$$\int_0^1 X_t dX_t$$

$$S_{i_1, \dots, i_q} S_{j_1, \dots, j_q} = \sum_{\substack{(u_1, \dots, u_q) \\ \in \mathcal{I}}} \square S_{u_1, \dots, u_q, i_1, \dots, i_q}$$

$$C_q = \underset{\text{coef}}{\text{q'ésimo}} \text{ de } \log(E[\exp\{\lambda X_t\}]).$$

$d=1$
candidate de en 10,7

$S_{i_1, \dots, i_g} =$ Casus de orden g . B.

$$e \quad \frac{-\lambda B_0}{2} - \frac{1}{2}$$