

---



# Clase 8:

# Reconstrucción de ODEs




# Reconstrucción de ODEs

- Motivación en el marco de la materia
- Regresión + Regularización
- Reconstrucción de ODEs
  - Regresión LASSO
  - SINDy
- Vamos a hacer en el Colab
- Bibliografía

# Motivación en el marco de la materia


---

- Sistemas dinámicos = ODEs



# Regresión + Regularización

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot x$$



Error cuadrático medio

$$J(\hat{\beta}) = \underbrace{\frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2}_{\text{Función costo}} + \lambda \underbrace{\sum_{j=1}^M \|\hat{\beta}_j\|_p}_{\text{Penalización}}$$




Agrego a la **función costo** un **termino de penalización**. Si un parámetro toma un valor muy alto, este término también. Minimizar la función costo penalizando ese parámetro es restringir para que no sea alto

Estoy incorporando un **hiperparámetro (lambda)** que regula la **magnitud de penalización**, asignando más importancia a ciertos parámetros por sobre otros

Permitirá regular la **flexibilidad del modelo**, haciendo que sea **menos sensible al ruido** y, por lo tanto, **reduciendo su varianza** (aunque no necesariamente siempre reduciendo la complejidad del modelo)

# Regresión + Regularización


---




# Regresión + Regularización

Regularización LASSO (p=1)

$$J(\hat{\beta}) = \frac{1}{n} \sum_{i=1}^n \underbrace{(y^{(i)} - \hat{y}^{(i)})^2}_{\text{error}} + \lambda \sum_{j=1}^M \|\hat{\beta}_j\|_p$$



Agregamos un término de **penalización** en la función costo




Cuando penalizo, es posible que parámetros se hagan cero (se cancelan términos)

# Regresión + Regularización

---

La función costo en la mayoría de los casos **puede no ser convexa**



- El **descenso por el gradiente** puede **no encontrar el mínimo global**
- Pero la función costo se calcula de los **datos de entrenamiento**
- Entonces, el **mínimo global** puede dar un modelo con **sobreajuste**
- Notar que **regularizar** es buscar el mínimo de una **nueva función costo**, que incluye un **término de penalización**, por lo que **me aleja del mínimo global original**

# SINDy

---

Sparse Identification of Nonlinear Dynamical systems

Sistema dinámico  $\longrightarrow \frac{d\mathbf{x}}{dt} = \mathbf{f}(\mathbf{x}, t; \mu)$

Puedo plantear el campo vector como un desarrollo de variables en una base de transformaciones

$$\dot{\mathbf{X}} = \Theta(\mathbf{X}) \Xi$$

Derivadas  Parámetros (coeficientes)   
Variables transformadas (por ejemplo  $x^2.z$ ) 

Si tengo las variables y sus derivadas, puedo hacer una regresión lineal


En particular, regresión de tipo LASSO, agrego penalización que selecciona parámetros y los hace 0

Puedo obtener una representación esparsa de las relaciones y reconstruir las ecuaciones del sistema


## SINDy

## I. True Lorenz System

$$\begin{aligned}\dot{x} &= \sigma(y - x) \\ \dot{y} &= x(\rho - z) - y \\ \dot{z} &= xy - \beta z.\end{aligned}$$





Data In




## III. Identified System

$$\begin{aligned}\dot{x} &= \Theta(x^T)\xi_1 \\ \dot{y} &= \Theta(x^T)\xi_2 \\ \dot{z} &= \Theta(x^T)\xi_3\end{aligned}$$



Brunton, Proctor, & Kutz (2016). *Discovering governing equations from data by sparse identification of nonlinear dynamical systems*. PNAS, 113(15), 3932-3937.

# SINDy



Funciona también

- para datos ruidosos
- cuando no tengo la derivada pero la puedo calcular numéricamente con cierta confianza

Qué limitaciones tiene esto?

Brunton, Proctor, & Kutz (2016). *Discovering governing equations from data by sparse identification of nonlinear dynamical systems*. PNAS, 113(15), 3932-3937.


# Vamos a hacer en el Colab

---


- Reconstrucción de ODEs
  - Atractor de Lorenz
    - LASSO
    - SINDy
  - Oscilador amortiguado (video)
  - Oscilador de relajación de Van der Pol
    - Dificultades del método?

## Bibliografía recomendada


---



Kutz 2013



Brunton & Kutz 2019



James et al 2017

