

# ¿Qué es Machine Learning?

Sesgo, varianza, overfitting y underfitting

German Rosati  
[german.rosati@gmail.com](mailto:german.rosati@gmail.com)

UNSAM - CONICET

22 de octubre de 2020

## ¿Cómo evaluar un modelo?

- Métricas de error - Loss Functions
- Train y Test Data
- Overfitting - Underfitting
- Balance Sesgo-Varianza
- Estimando el error de generalización

# Ahora sí... ¿Como evaluar un modelo?

## Criterios I

- Ahora bien, ¿qué es un buen modelo?
- Desde la cultura del **modelado estadístico** (Breiman, 2001 [1]) un buen modelo es un modelo que ajusta bien a los datos y cuyos parámetros cumplen algunas propiedades “deseables”
  - 1 Ser insesgado
  - 2 Ser robusto
  - 3 Tener varianza mínima...
  - 4 Etc...

# ¿Como evaluar un modelo?

## Criterios II

- El **modelado algorítmico** (Breiman, 2001 [1]) piensa sobre todo en la capacidad predictiva
- Pero... ¿sobre cuáles datos?
- Queremos modelos que funcionen bien -tengan bajo error- en datos que NO vimos, es decir, en datos “futuros”, datos de test, *out of sample*
- Pero muchas veces esos datos no existen o tardan en aparecer
- $\implies$  Separación en *Training Data* y *Test Data*
- Entreno-estimo-construyo el modelo sobre *Training Data* y evalúo sobre *Test Data*

# ¿Como evaluar un modelo?

## Métricas de error - Loss Functions - Funciones de pérdida

**Requisito:** alguna medida que permita evaluar cómo funciona mi modelo

- Grande cuándo el modelo funciona "mal" pequeña cuando funciona "bien"
- Sirve para "tunear", calibrar los parámetros del modelo
- Muchas métricas: por ahora nombramos dos
  - Mean Squared Error para variables cuantitativas

$$err = MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (1)$$

- Error de clasificación para variables categóricas

$$err = Class = \frac{1}{N} \sum_{i=1}^N I(y_i \neq \hat{y}_i) \quad (2)$$

# ¿Como evaluar un modelo?

## Train y Test Data

- Que un modelo funcione bien en datos de entrenamiento no quiere decir que funcione bien en datos nuevos...
- En general, el error en datos de entrenamiento es más bajo que el error en datos de test

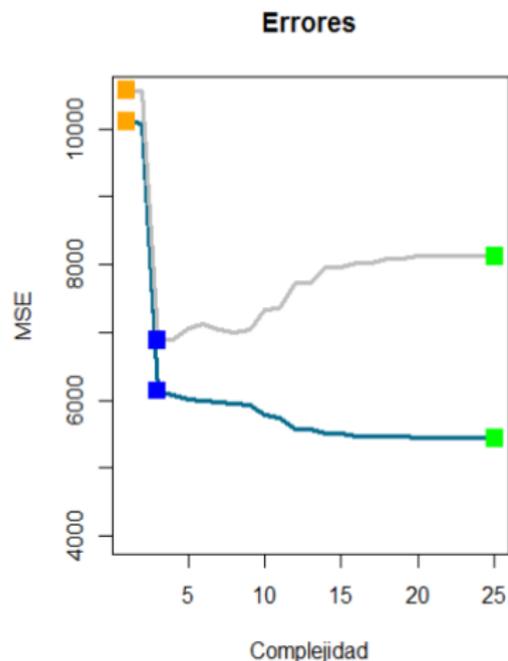
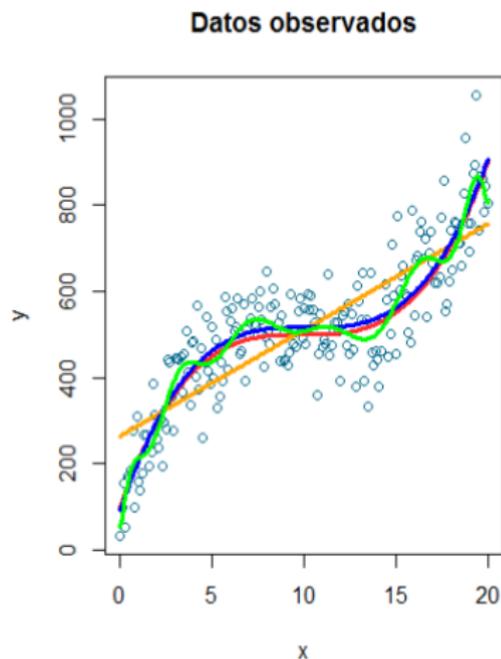
# ¿Como evaluar un modelo?

## Ejemplo teórico

- Función original:  $f(x_i) = 500 + 0,4X_i^3 + \epsilon_i$
- Modelo Lineal:  $\hat{f}(x_i) = \hat{\beta}_0 + \hat{\beta}_1 X_i$
- Modelo Cuadrático:  $\hat{f}(x_i) = \hat{\beta}_0 + \hat{\beta}_1 X_i + \hat{\beta}_2 X_i^2$
- Modelo Polinómico de orden 25:  
 $\hat{f}(x_i) = \hat{\beta}_0 + \hat{\beta}_1 X_i + \hat{\beta}_2 X_i^2 + \dots + \hat{\beta}_{25} X_i^{25}$

# ¿Como evaluar un modelo?

## Ejemplo teórico



# ¿Como evaluar un modelo?

## Overfitting - Underfitting

- TrS-error decrece constantemente: siempre es posible generar un modelo muy “complejo” como para que ajuste bien a los datos (¿cuáles?)
- TeS-error decrece hasta un punto y luego comienza a crecer nuevamente. Se produce “overfitting” (sobreajuste).
- El modelo “trabaja” demasiado para encontrar patrones en el TrS y tiende a confundir el verdadero patrón ( $f(x)$  - el “proceso generador de los datos”) con ruido ( $\epsilon$ ) que no existe en el TeS.

# ¿Como evaluar un modelo?

## Balance Sesgo-Varianza

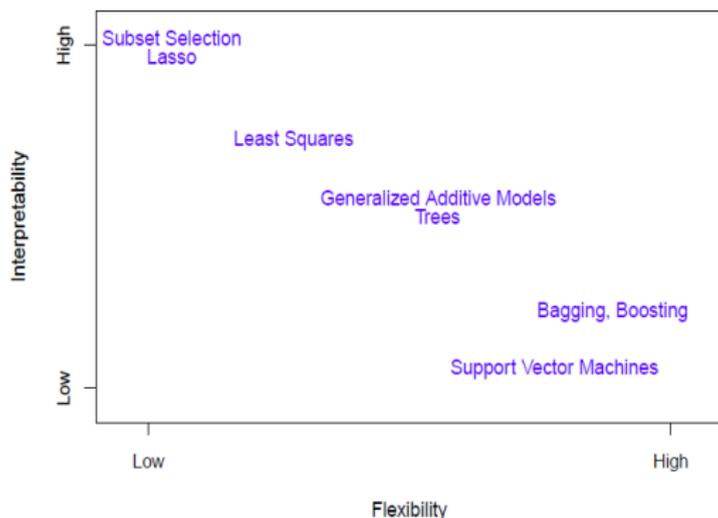
- El ECM puede descomponerse en tres partes

$$E[(y - \hat{f}(x))^2] = V(\hat{f}(x)) + bias^2 + \sigma^2 \quad (3)$$

- **Error debido al sesgo:** diferencia entre el valor esperado de nuestra predicción y el verdadero valor poblacional
- **Error debido a la varianza:** producido por la variabilidad de las predicciones del modelo en un punto determinado.
- El  $\sigma^2$  es la parte “irreducible” del error en el modelo

# ¿Como evaluar un modelo?

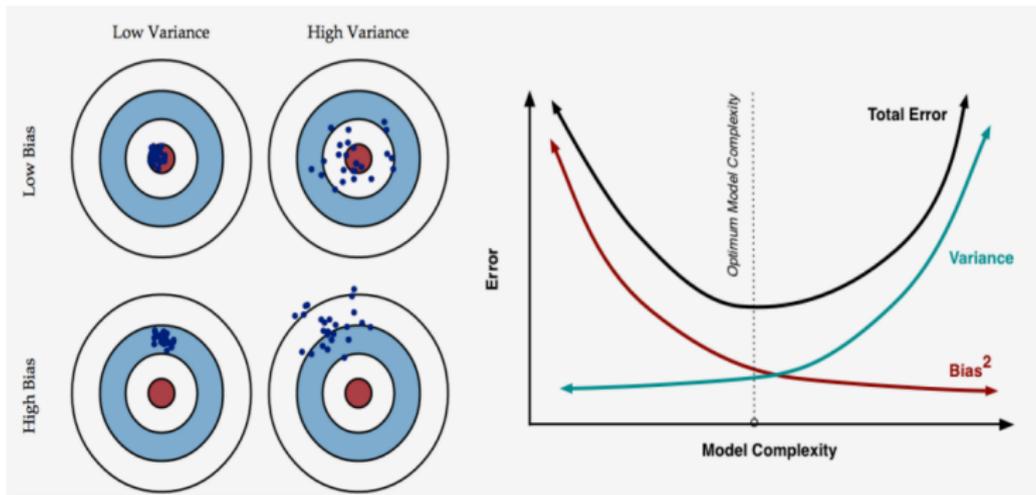
Algunos trade-offs



**Fuente:** (James, Witten, Hastie y Tibshirani, 2013 [2]) : 25

# ¿Cómo evaluar un modelo?

¿Cómo evaluar un modelo? - Balance Sesgo-Varianza



Fuente: [Scott Fortman's Blog](#)

# ¿Como evaluar un modelo?

Estimando el error de generalización

- Herramientas para estimar el error de generalización de un modelo -qué tan bien va a funcionar sobre datos “no vistos”
  - 1 *Validation Set Approach*
  - 2 *Cross Validation*
  - 3 *Bootsrap*
  - 4 *Etc.*

# ¿Como evaluar un modelo?

## Validation Set Approach

- Dividimos el **aleatoriamente** *dataset* en *Training Set - TrS* y *Test Set - TeS*
- El modelo se ajusta en el TrS y el modelo ajustado se usa para predecir las observaciones correspondientes al TeS

# ¿Como evaluar un modelo?

## Cross Validation

- 1 Dividimos el **aleatoriamente** *dataset* en  $K$  porciones de igual tamaño
- 2 Fiteamos el modelo dejando como TeS una de las  $K$  partes
- 3 Computamos el error en la parte dejada afuera previamente
- 4 Repetimos para  $k = 1, 2, 3, \dots, K$

La estimación del error será el promedio de las  $K$  estimaciones de error

$$CV(\hat{f}) = \sum_{k=1}^K \frac{n_k}{N} err_k \quad (4)$$

# ¿Como evaluar un modelo?

## Cross Validation

	Dataset Original				
Iteración 1	C1 (VaSet)	C2 (TrSet)	C3 (TrSet)	C4 (TrSet)	C5 (TrSet)
Iteración 2	C1 (TrSet)	C2 (VaSet)	C3 (TrSet)	C4 (TrSet)	C5 (TrSet)
Iteración 3	C1 (TrSet)	C2 (TrSet)	C3 (VaSet)	C4 (TrSet)	C5 (TrSet)
Iteración 4	C1 (TrSet)	C2 (TrSet)	C3 (TrSet)	C4 (VaSet)	C5 (TrSet)
Iteración 5	C1 (TrSet)	C2 (TrSet)	C3 (TrSet)	C4 (TrSet)	C5 (VaSet)

# ¿Como evaluar un modelo?

## Cross Validation

¿Cómo elegimos  $K$ ?

- $K$  pequeño maximiza datos para estimar, sensible a valores extremos
- $K$  grande maximza datos para evaluar, modelo estimado con menor precisión
- Regla del dígito pulgar oscilante: 5 o 10 (James, Witten, Hastie y Tibshirani, 2013 [2])

- La máxima de Box...
- Dado que todos los modelos son simplificaciones de la realidad, no podemos llegar a la “verdad” por complejidad creciente.
- Principio de Occam, caso contrario, *overfitting*
- ¿Modelado estadístico o algorítmico? Dependerá del problema en cuestión

# Referencias bibliográficas I



BREIMAN, L.

Statistical modeling: The two cultures (with comments and a rejoinder by the author).  
*Statistical Science* 16, 3 (08 2001), 199–231.



JAMES, G., WITTEN, D., HASTIE, T., AND TIBSHIRANI, R.

*An Introduction to Statistical Learning – with Applications in R*, vol. 103 of *Springer Texts in Statistics*.  
Springer, New York, 2013.