

Enfoque Estadístico del Aprendizaje y el Descubrimiento 2019

Diego Kozlowski - diegokoz92@gmail.com

Juan Barriola - jmbarriola@gmail.com

María Eugenia Szretter - meszre@dm.uba.a

Andrés Farall - afarall@hotmail.com

Programa de la Materia

- Regresión lineal simple y múltiple.
 - Estimación por Cuadrados Mínimos.
 - Multicolinealidad.
 - Transformaciones.
 - Variables dummy. Interacción
 - Métodos de ajuste paso a paso
 - Alternativas Robustas
- Modelos Lineales Generalizados (GLM)
- Regresión logística.
- Regresión de Cuantiles (QR)
- Introducción a los Modelos Lineales Mixtos (LMM)

Maru

- Enfoques de la inferencia estadística
 - Modelado Estadístico
 - Significatividad Estadística (p-valor)
 - Máxima Verosimilitud e Inferencia Bayesiana.
- El problema de predicción.
 - Aprendizaje Supervisado
 - Medidas de Bondad de Ajuste
 - Trade-off sesgo-varianza
 - Sobreajuste

Andrés

- Regresión Lasso y Ridge
- Regresión No Paramétrica
 - Técnicas de suavizado
 - Modelos Aditivos
 - Projection Pursuit Regression
- Redes Neuronales Artificiales Multicapa (ANN - MLP). Regresión, Clasificación y Reducción de Dimensión (Autoencoders).
- Regresión/Clasificación con SVM y Gradient Boosting (Xgboost).
- Benchmarking, Comparación y selección de modelos: AIC, BIC, Enfoque Multimodel, Model Tuning(Caret).

Andrés

Objetivos Principales del Curso

- Ofrecer un enfoque **Estadístico** de las técnicas de Regresión
- Brindar **herramientas aplicadas**
- Posicionarse en un contexto **científico e interdisciplinario**
- Enseñar una amplia variedad de técnicas implementadas en **R**
- Utilizar conjuntos de **datos reales**
- **No profundizar en la matemática** sobre la cual se basan los métodos

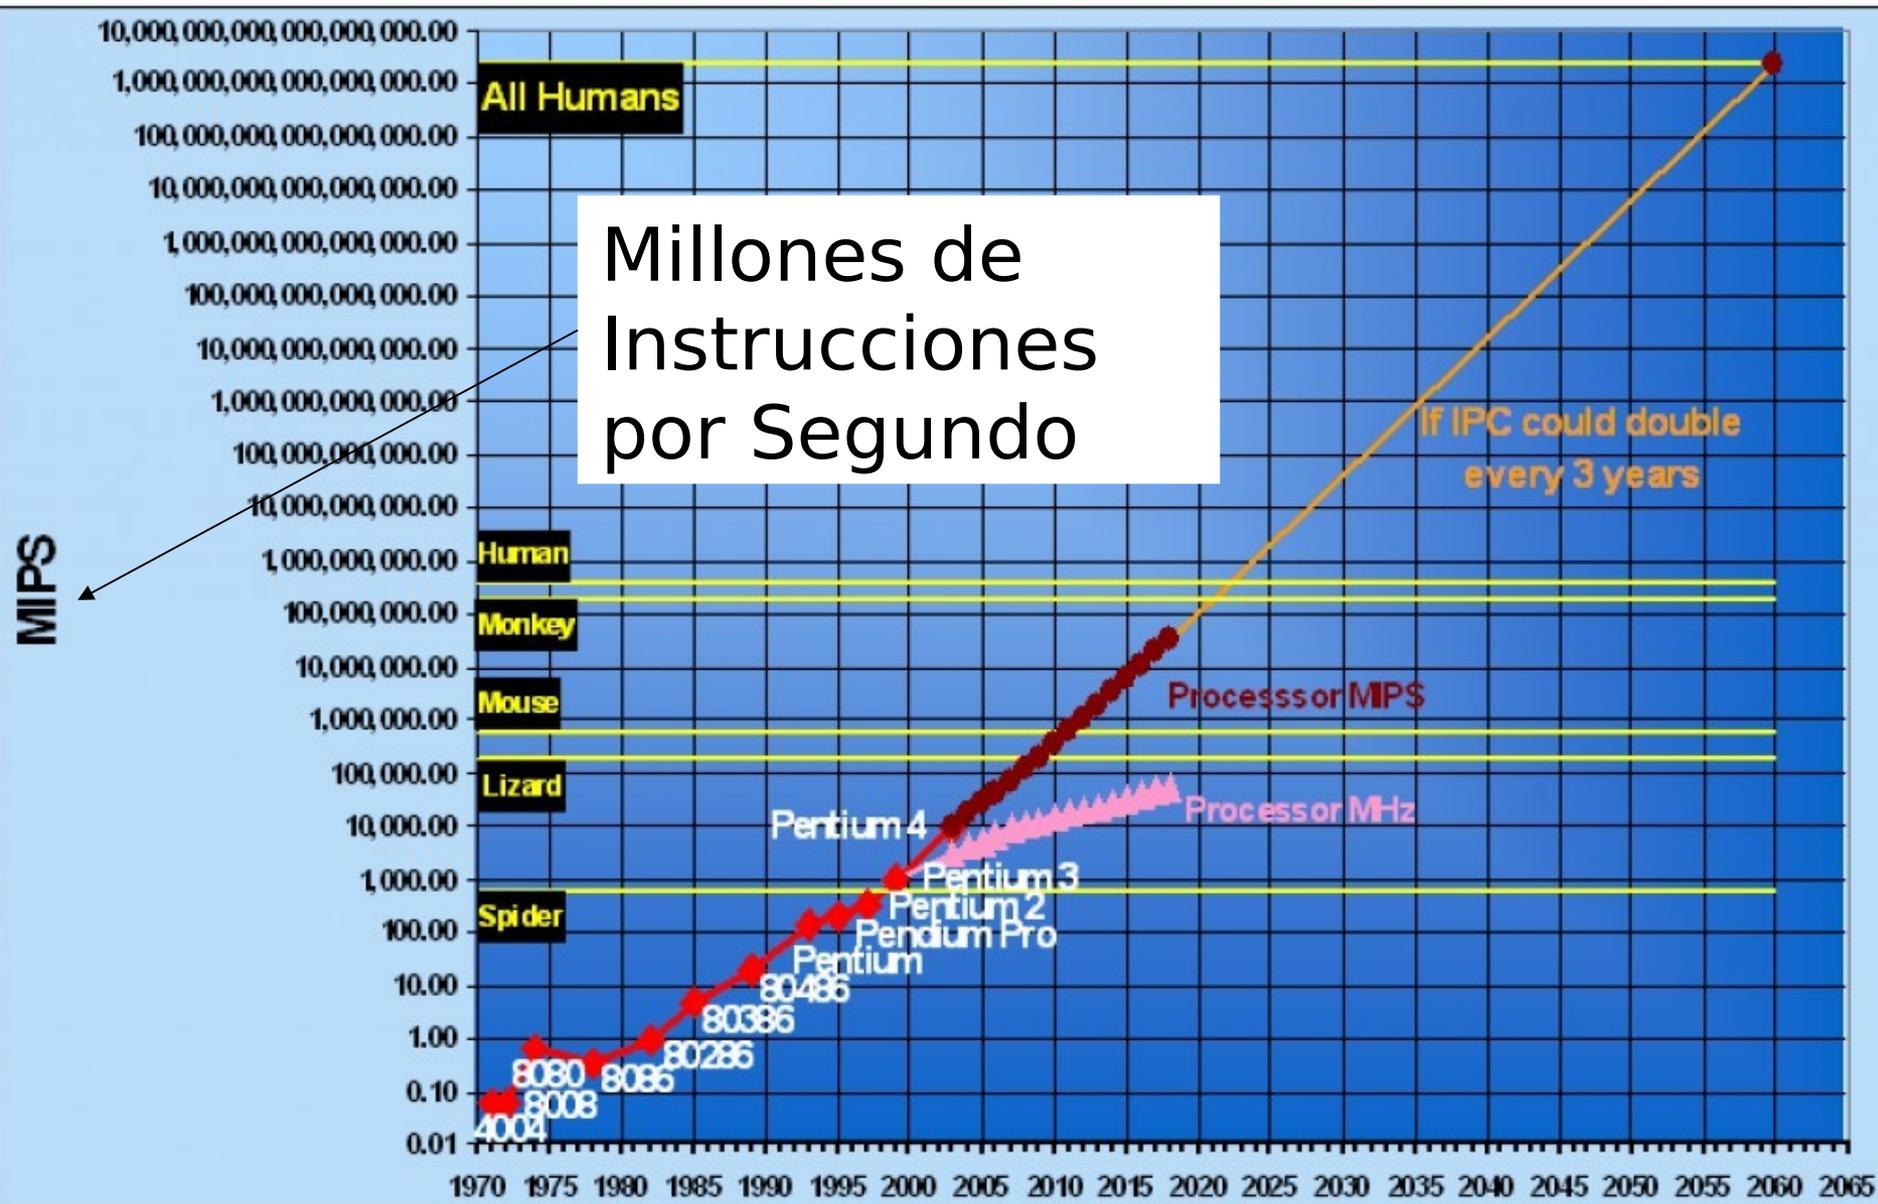
“Un Modelo Lineal No Se Le Niega a Nadie”

- Avanzamos de lo **simple** a lo complejo.
- Un modelo simple sirve como “**benchmark**” contra el que comparar el resultado de modelos más complejos.
- Un modelo simple permite **interpretar** la mecánica de las relaciones entre variables.

El Contexto Tecnológico

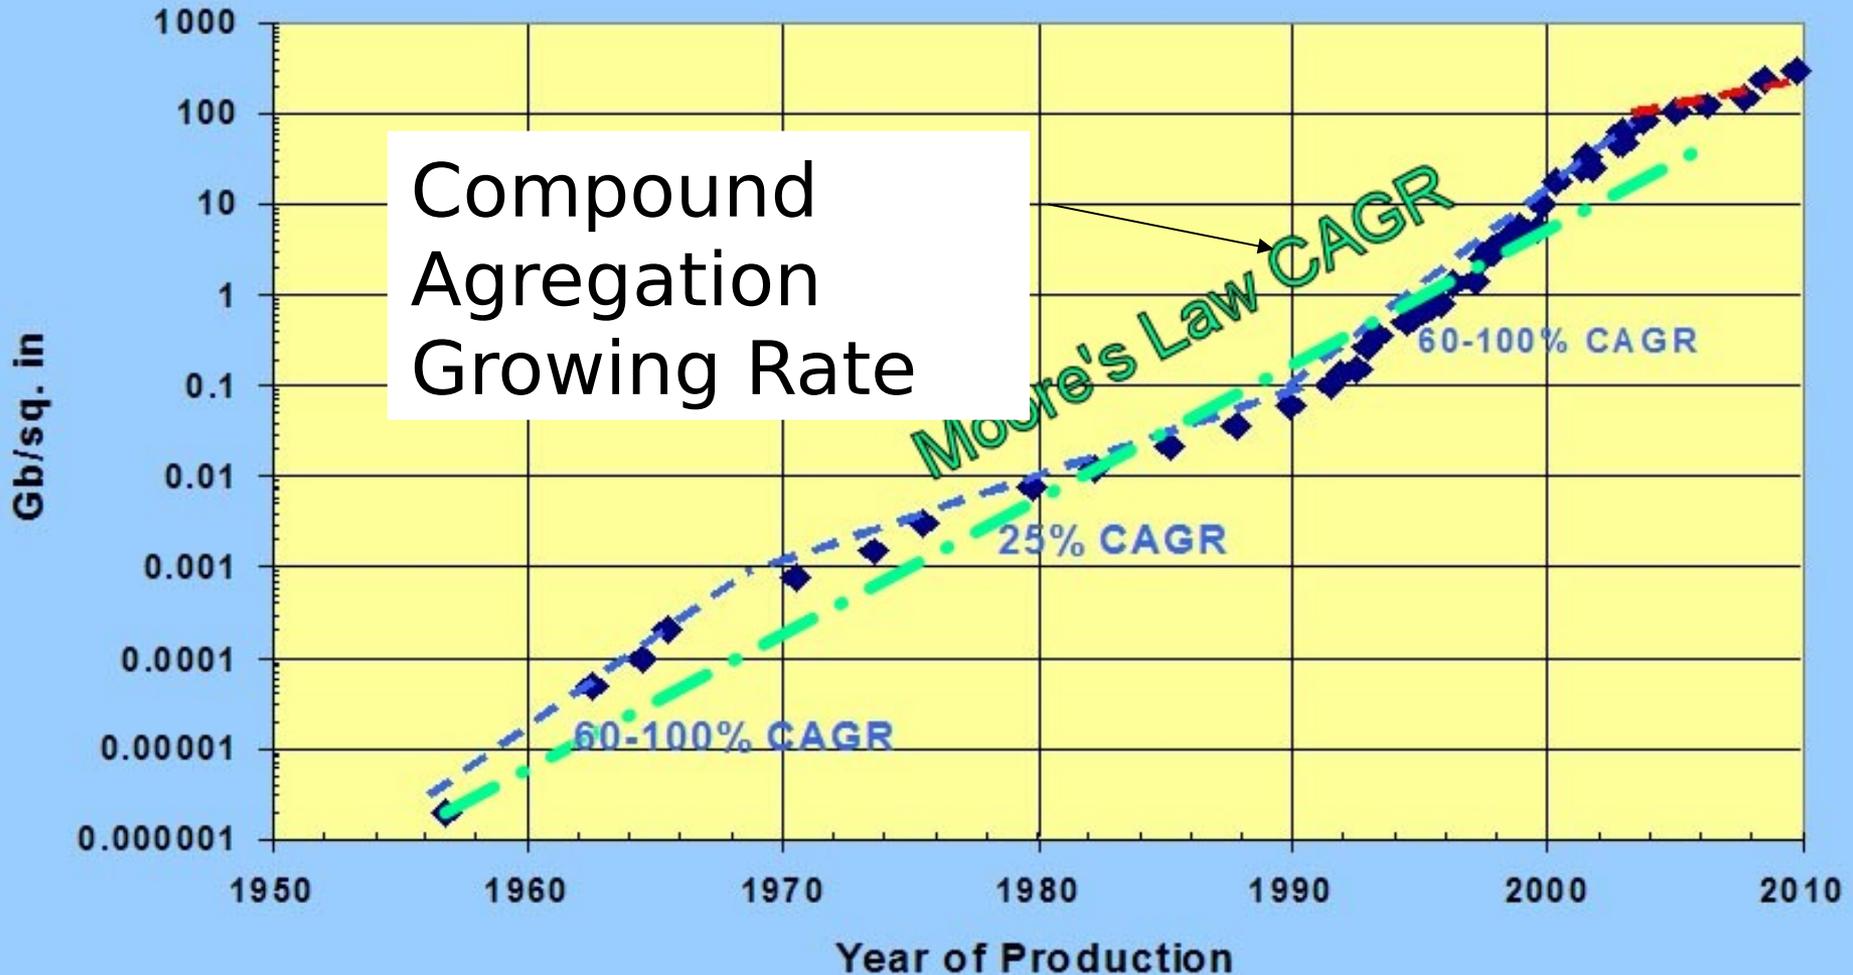
- Capacidad de **Cálculo**
- Capacidad de **Almacenamiento**
- Velocidad en la **Transmisión** de Datos
- Ciencia de Datos
- Machine Learning
- Data Mining
- Big Data
- Optimización

Que pasó con la Capacidad de Cálculo ?



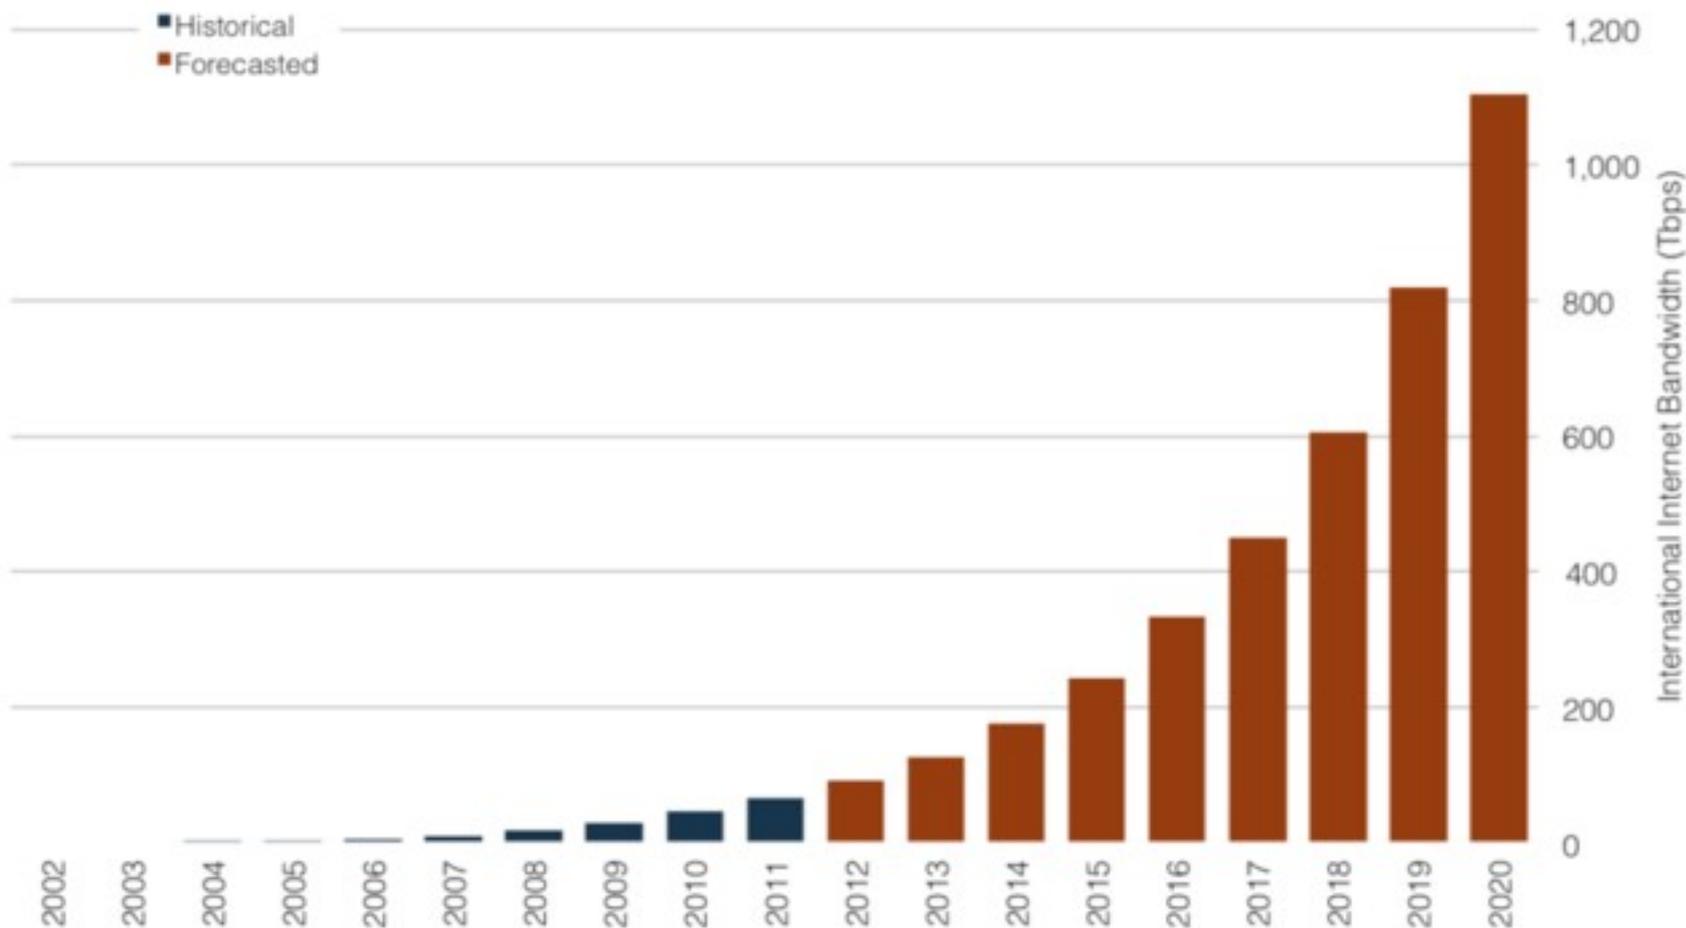
Que pasó con la Capacidad de Almacenamiento ?

Full History Disk Areal Density Trend

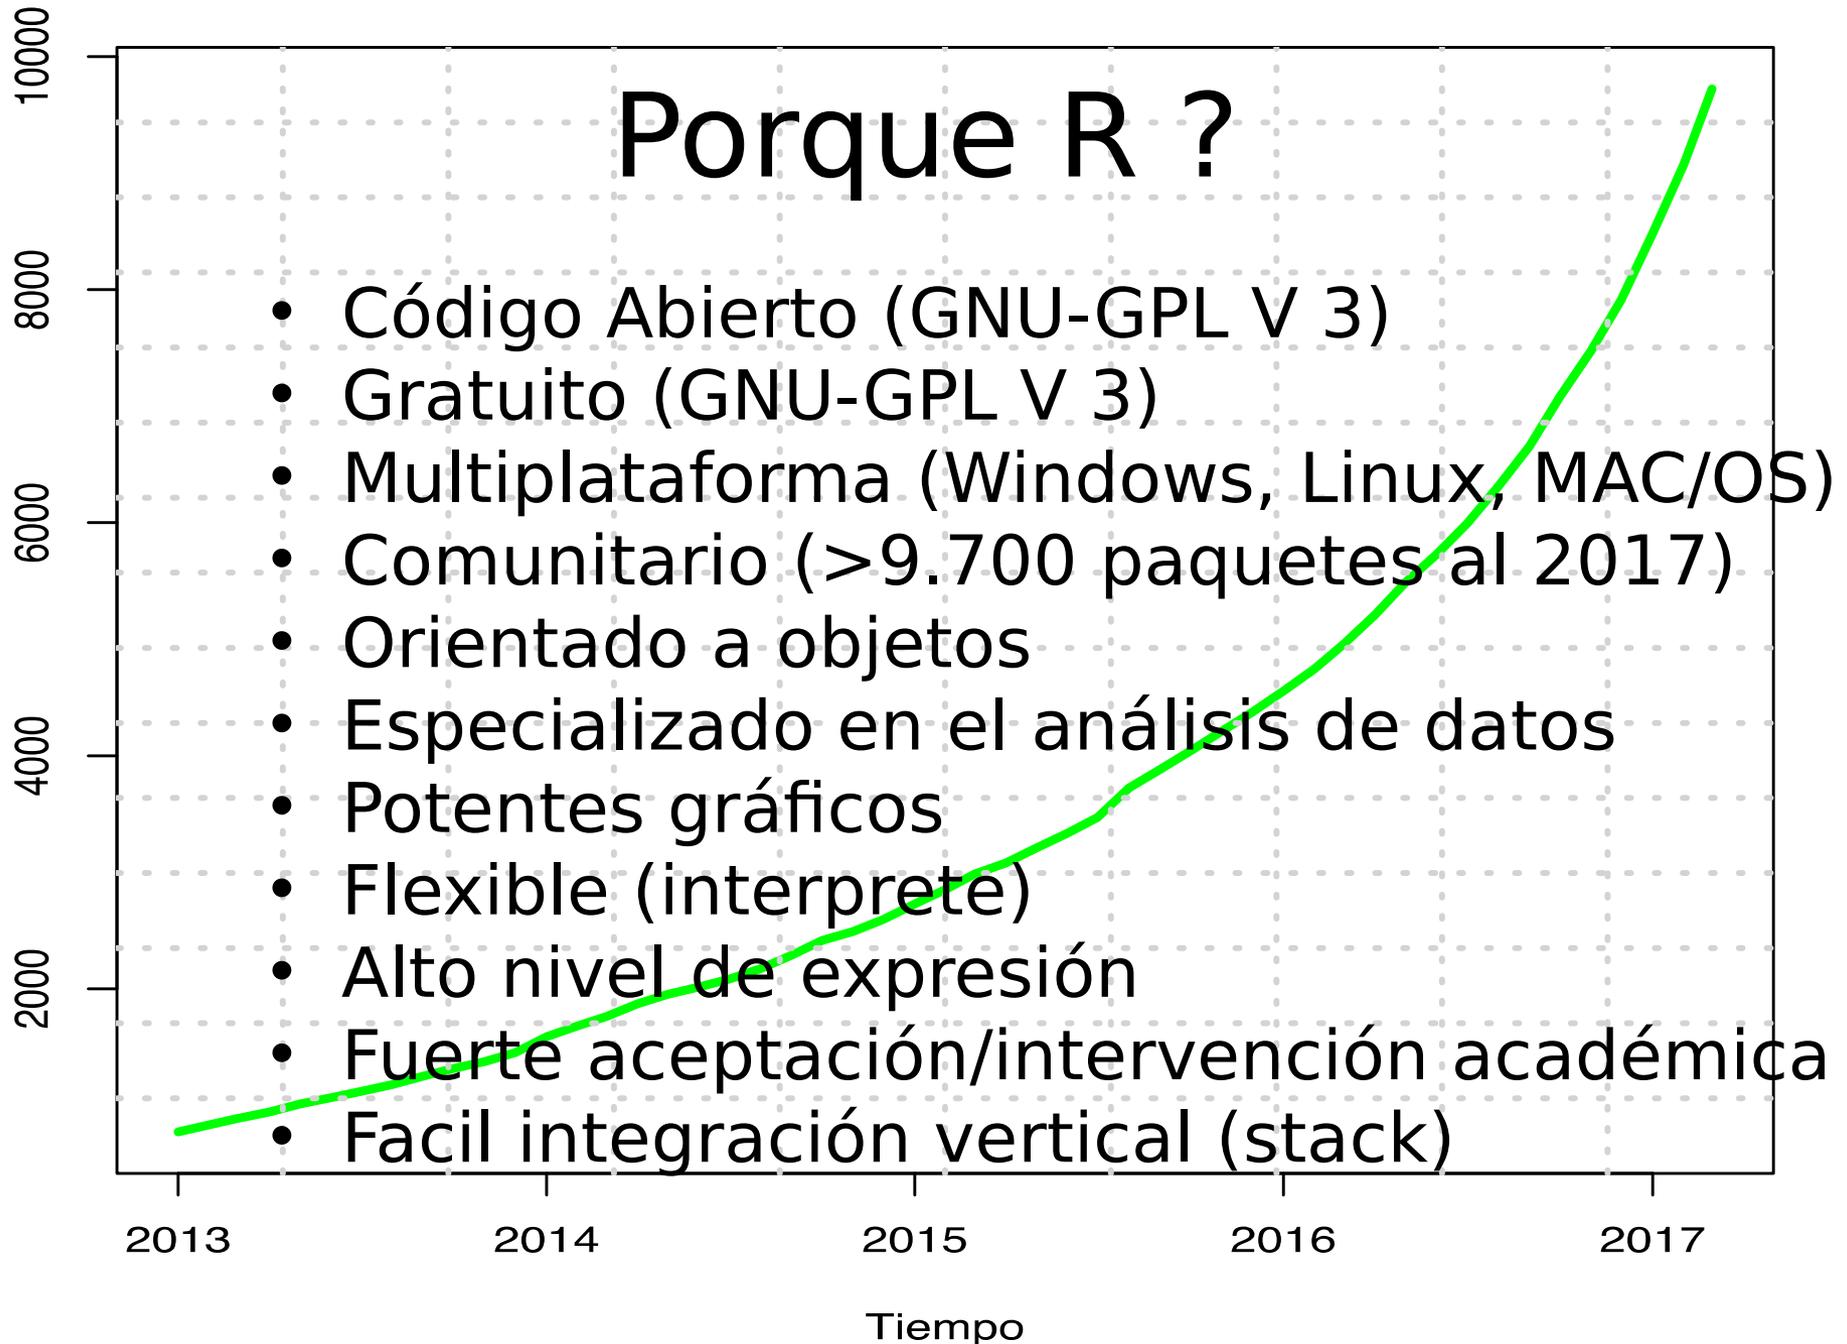


Que pasó con la Capacidad de Transmisión de Datos (Ancho de Banda) ?

Used International Bandwidth, 2002-2020



Evolucion de la cantidad de paquetes en CRAN

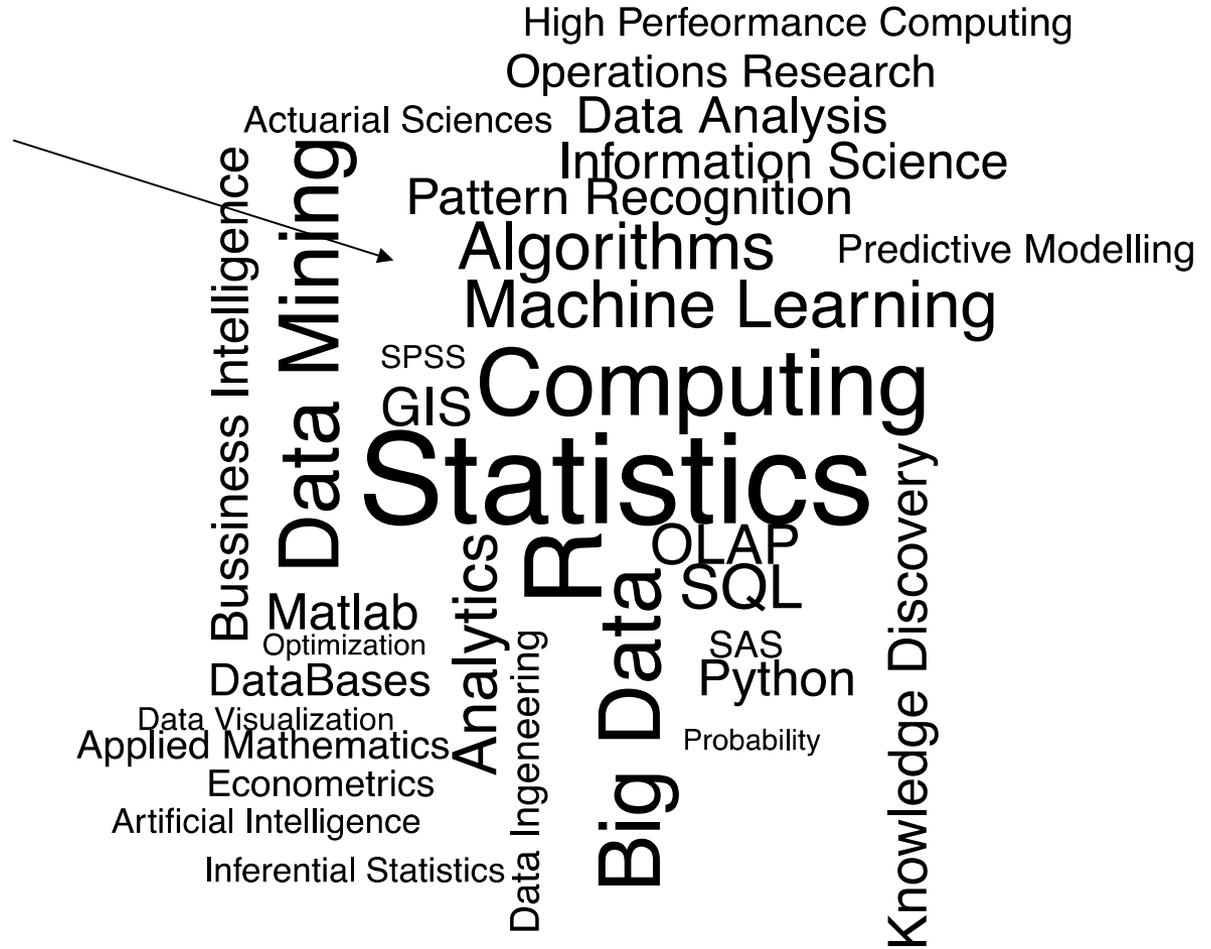


Porque R ?

- Código Abierto (GNU-GPL V 3)
- Gratuito (GNU-GPL V 3)
- Multiplataforma (Windows, Linux, MAC/OS)
- Comunitario (>9.700 paquetes al 2017)
- Orientado a objetos
- Especializado en el análisis de datos
- Potentes gráficos
- Flexible (interprete)
- Alto nivel de expresión
- Fuerte aceptación/intervención académica
- Facil integración vertical (stack)

Que es Ciencia de Datos ?

WordCloud de los Componentes de la Ciencia de Datos



Estadística

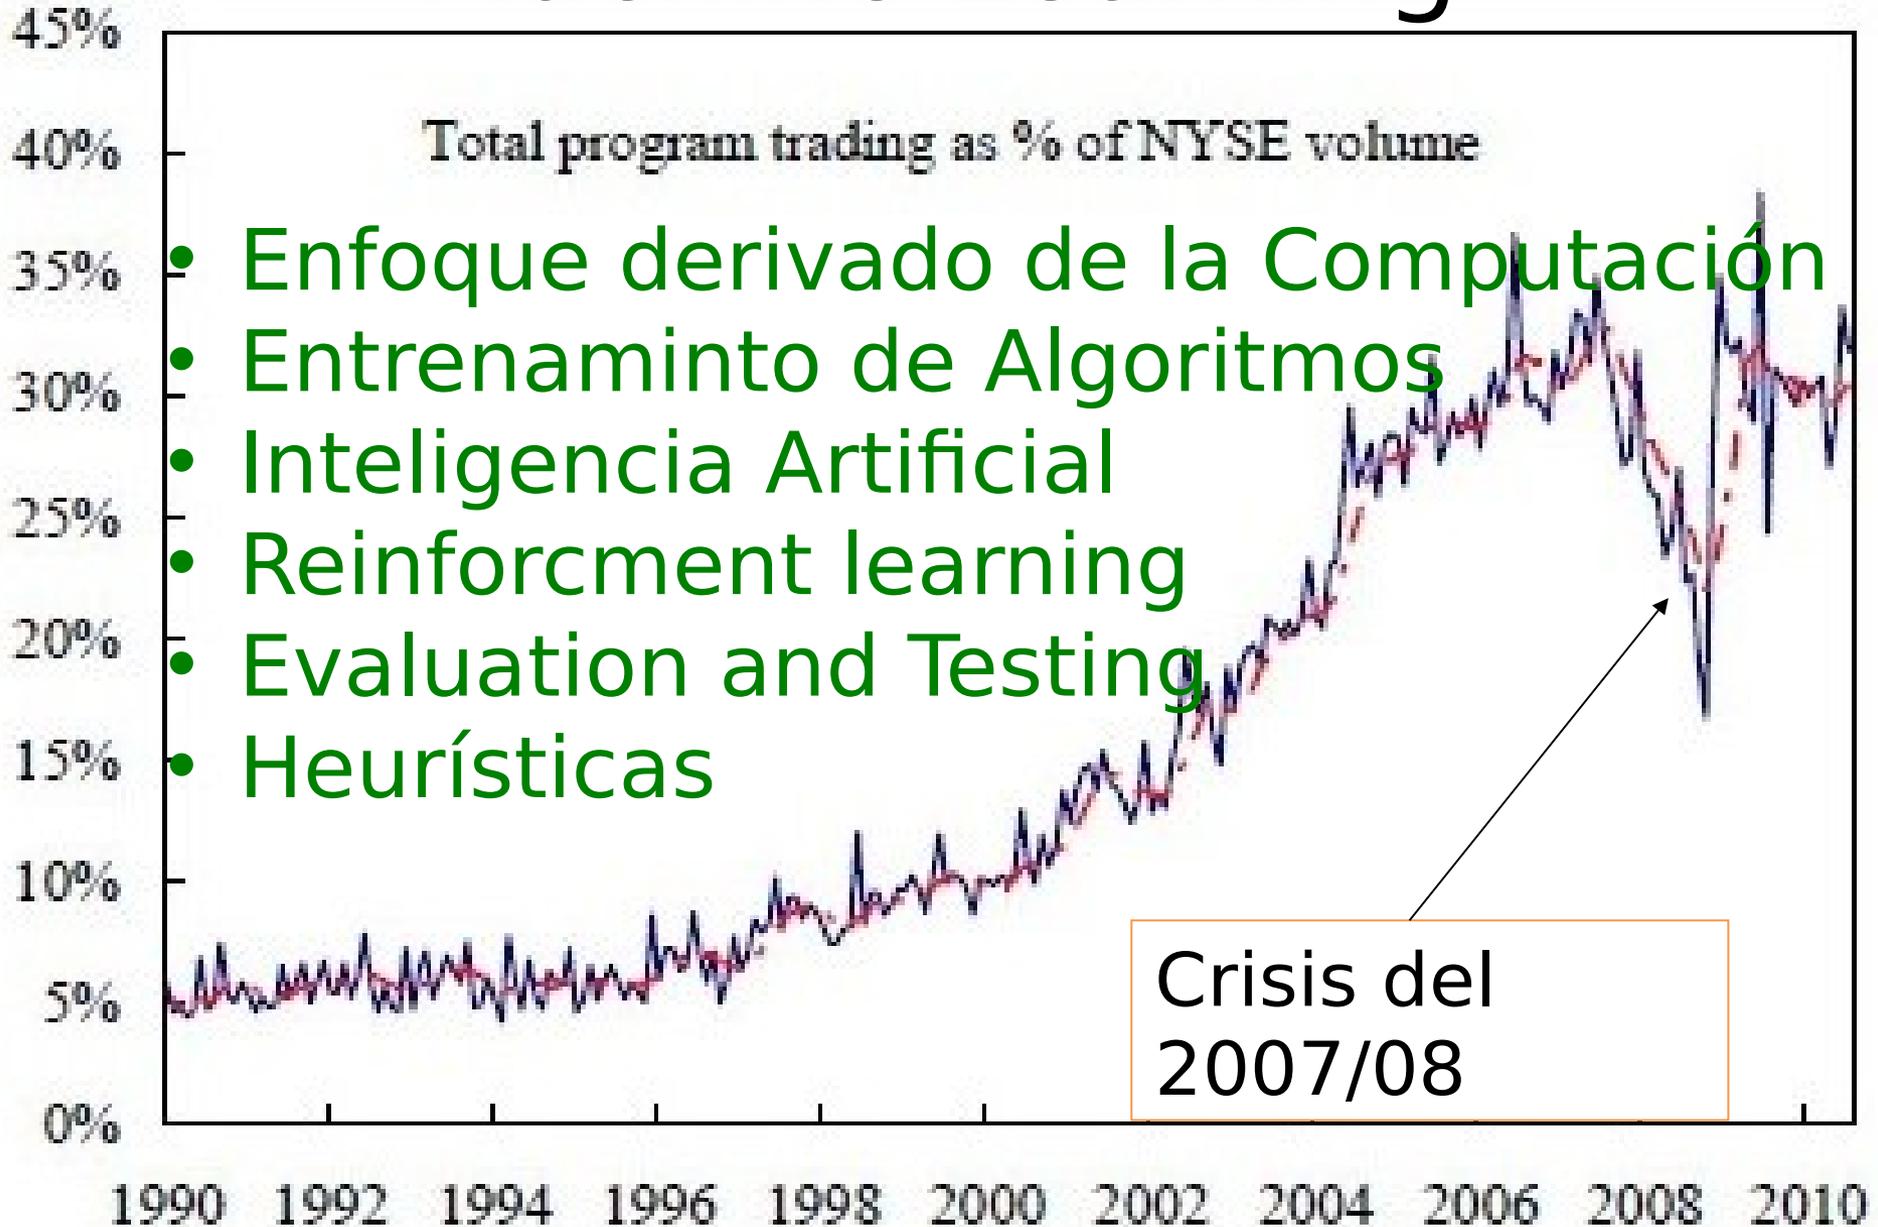
- Basada en la Teoría de Probabilidades.
- Formalizó el concepto de incertidumbre en las mediciones/estimaciones.
- Condicionada por la escasez de datos ($N > 30$?)
- Herramientas/conceptos básicos utilizados:
 - Modelo probabilístico
 - Población / Muestra
 - Variable Aleatoria
 - Verosimilitud
 - Inferencia
 - Significancia / P-valor
 - Intervalos de Confianza
 - Test de Hipótesis
 - Interpretabilidad

$$X = \mu + \epsilon$$

Componente
Determinístico

Componente
Aleatorio

Machine Learning



Big Data

Figure 1

Data is growing at a 40 percent compound annual rate, reaching nearly 45 ZB by 2020

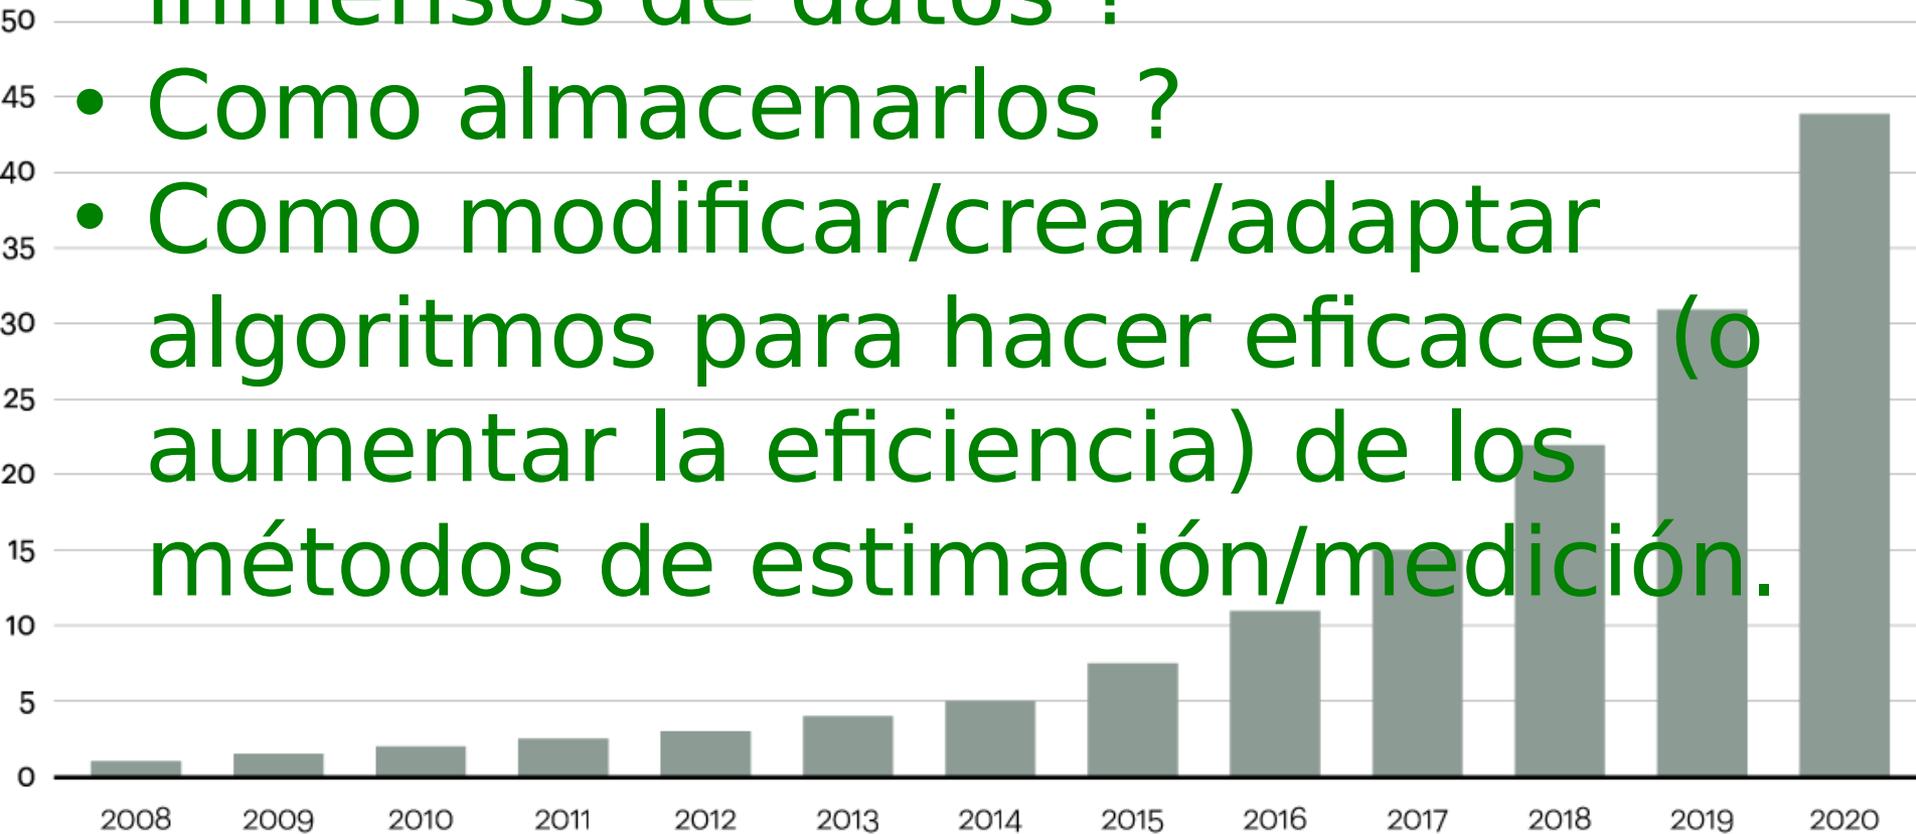
- Que hacer con volúmenes

Data in zettabytes (ZB)

inmensos de datos ?

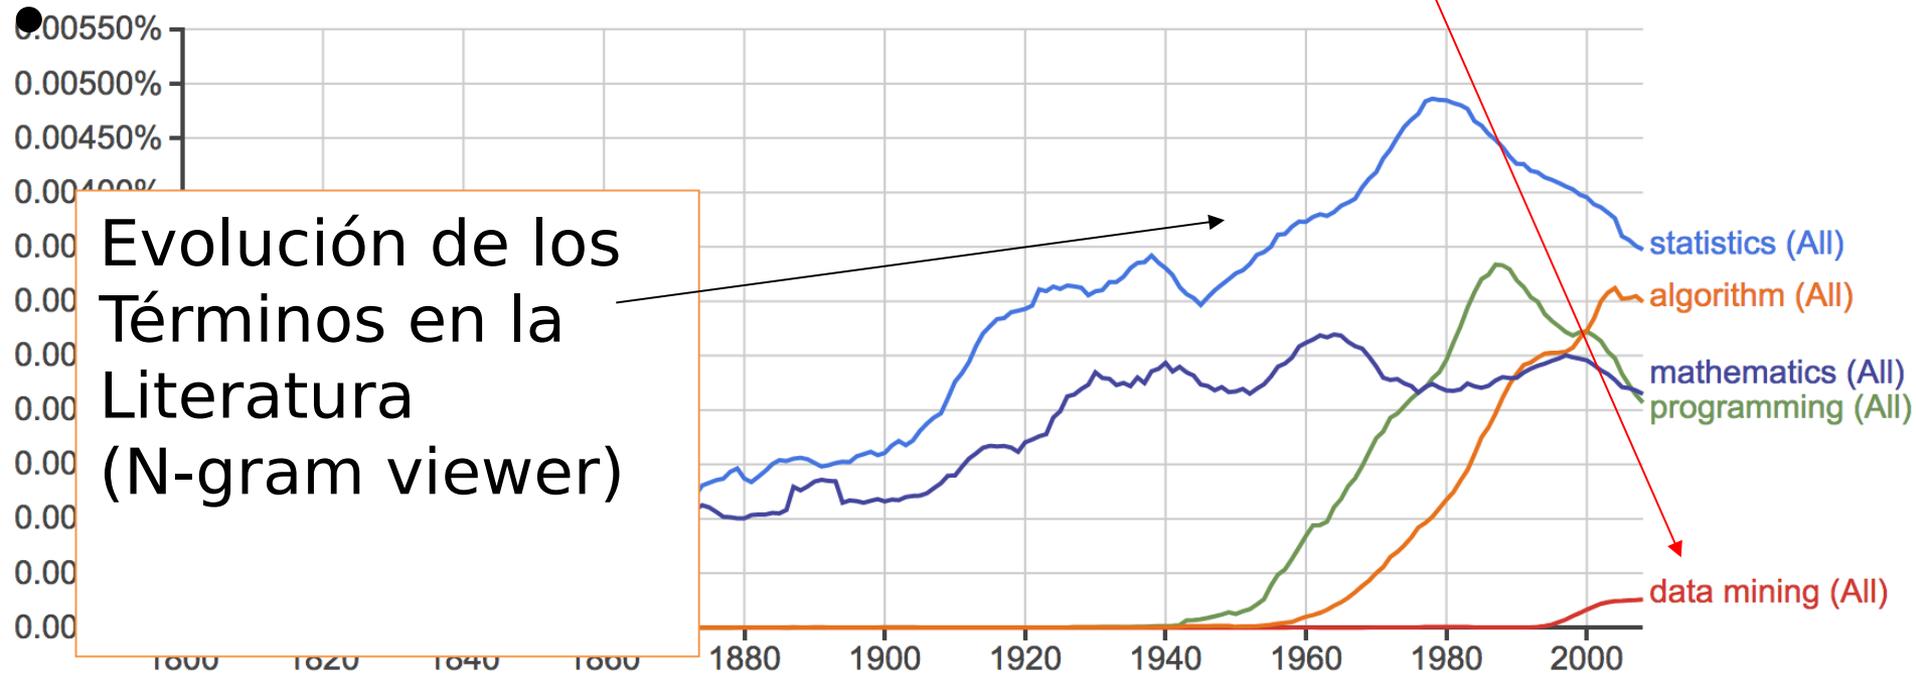
- Como almacenarlos ?

- Como modificar/crear/adaptar algoritmos para hacer eficaces (o aumentar la eficiencia) de los métodos de estimación/medición.



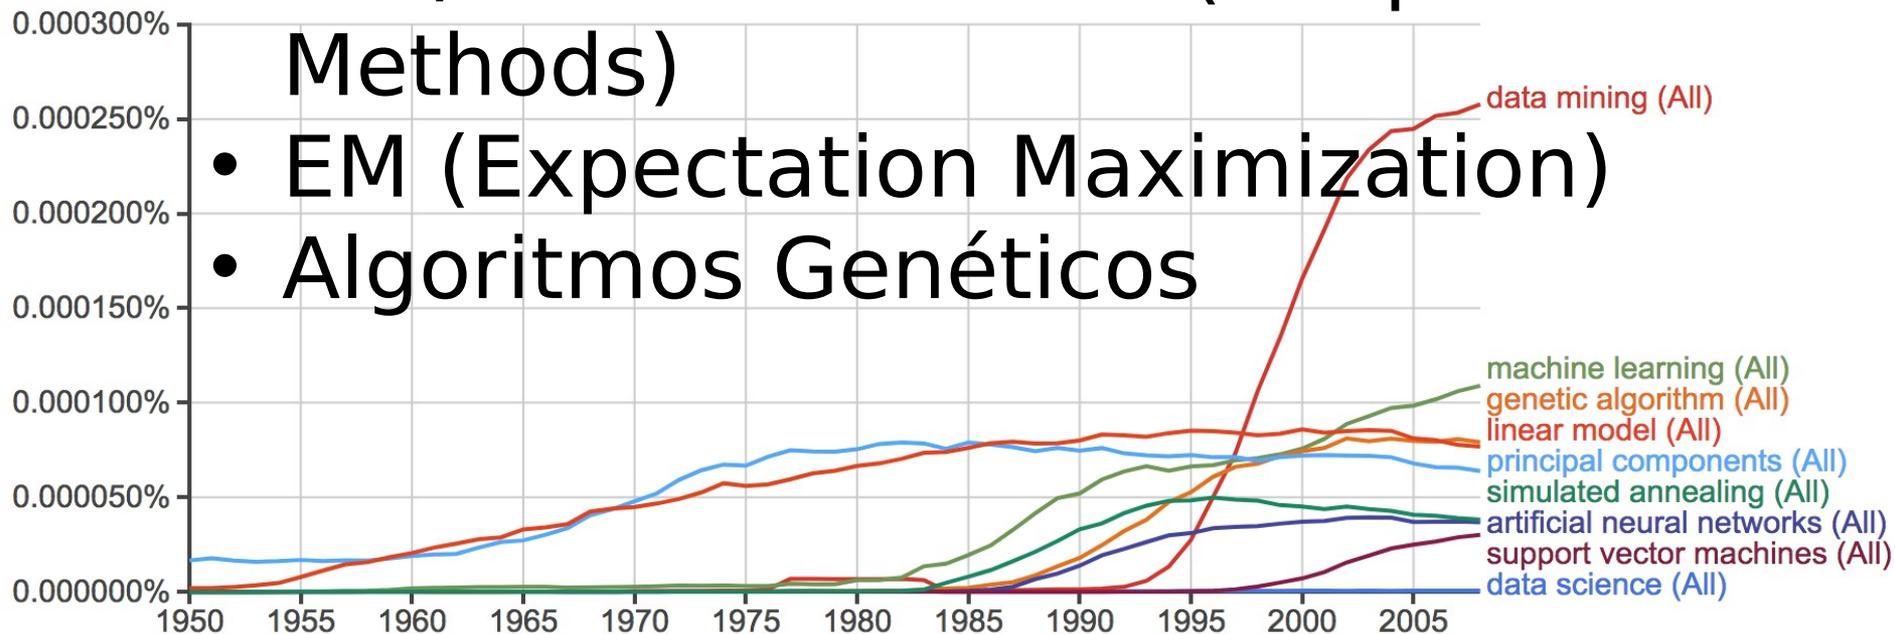
Data Mining

- Que patrones pueden extraerse de los datos ?
- Data Analysis y Analytics en gran escala
- Versión antigua del Data Science



Optimización

- Fuerza Bruta
- Random Optimization (Luus-Jaakola)
- Gradient Descent
- Newton-Rapson (Quasi)
- Simulated Annealing
- Optimización Lineal/Cuadrática con/sin restricciones (Simplex Like Methods)
- EM (Expectation Maximization)
- Algoritmos Genéticos



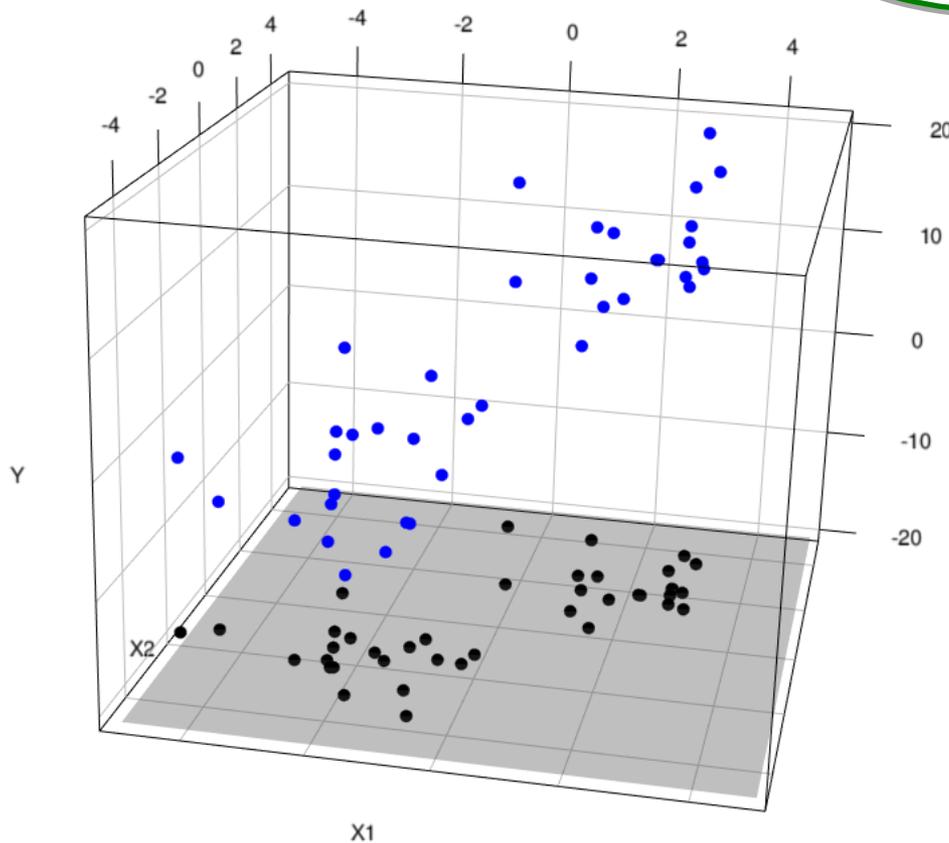
Taxonomía Basica de los Métodos en la Ciencia de Datos

- Métodos **Supervisados**
 - Clasificación
 - CART
 - Support Vector Machines
 - Regresión
 - Modelos Lineales
 - Redes Neuronales
- Métodos **No Supervisados**
 - Análisis Factorial
 - Componentes Principales
 - Análisis de Correspondencia
 - Segmentación
 - K-medias
 - Clusterización Jerárquica
 - GMM

Supervisado Vs. No Supervisado

Espacio de probabilidad conjunto

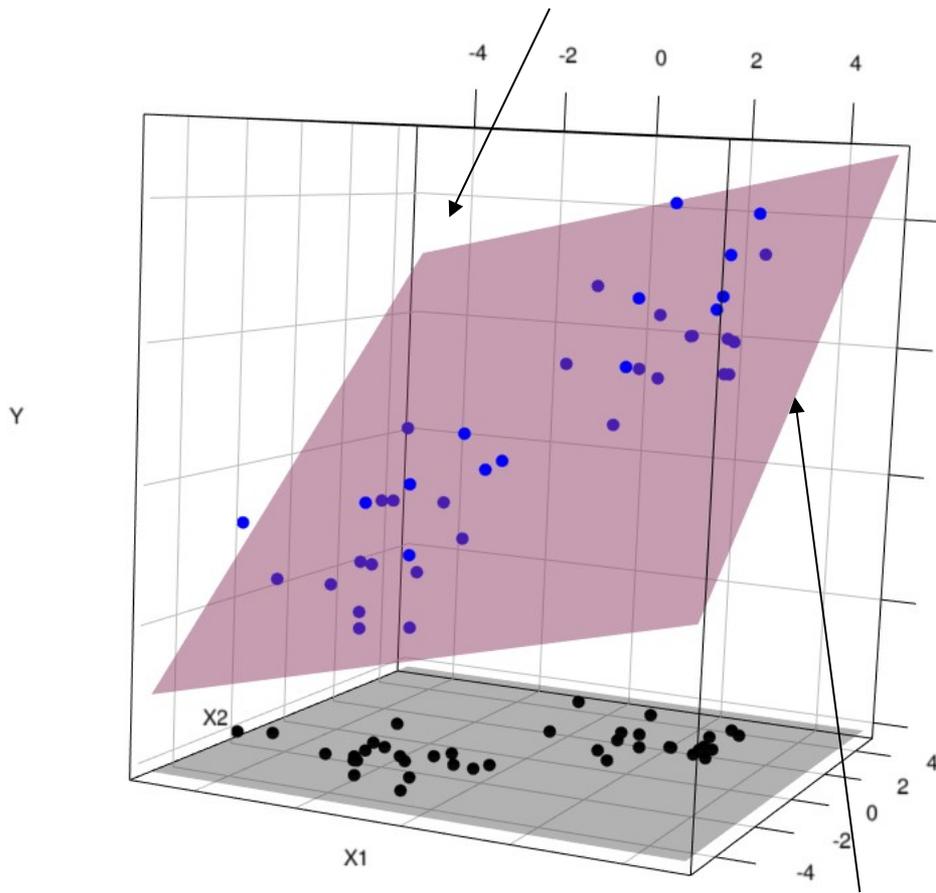
$$\Pr(X, Y) = \Pr(Y|X) \cdot \Pr(X)$$



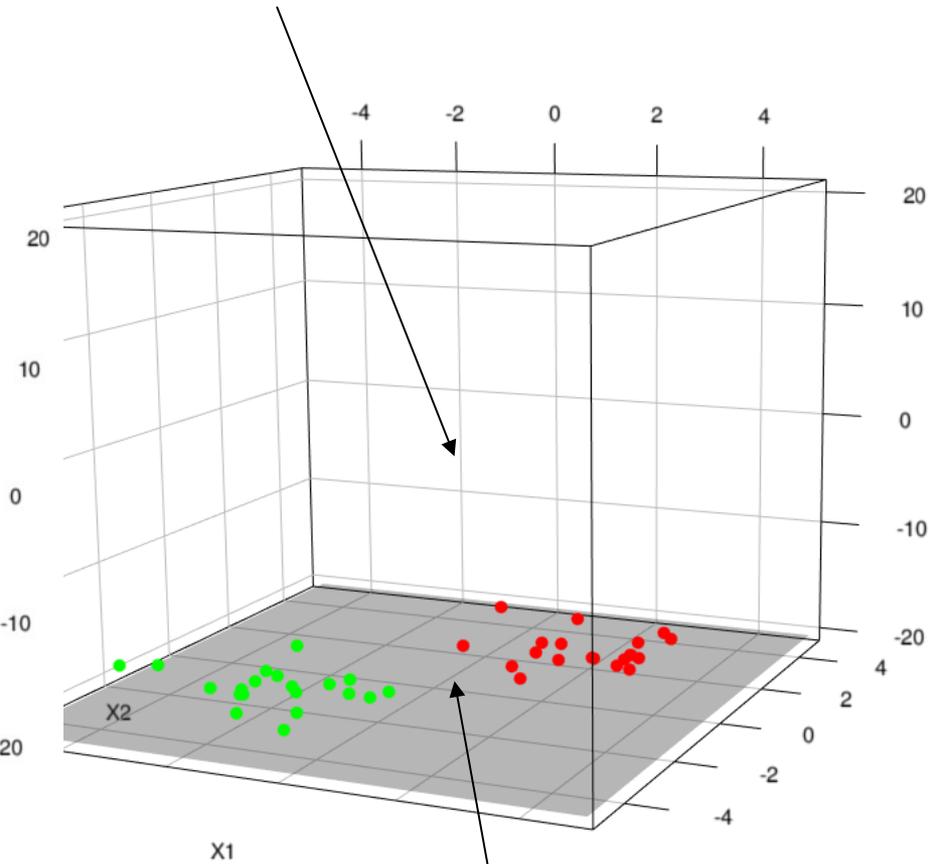
Variables Explicativas o Features

Variables Respuesta o Target

Regresión Vs. Clasificación



Relación
entre
Target y
Features



Sólo
Features

Sistema de Recomendaciones

<u>Indiv.</u>	Item 1	Item 2		Item j					Item p
1		3		9				2	
2	7	2			4				10
3			5						
4					8				3
5		1				7			
i			3	9					
N					7			4	

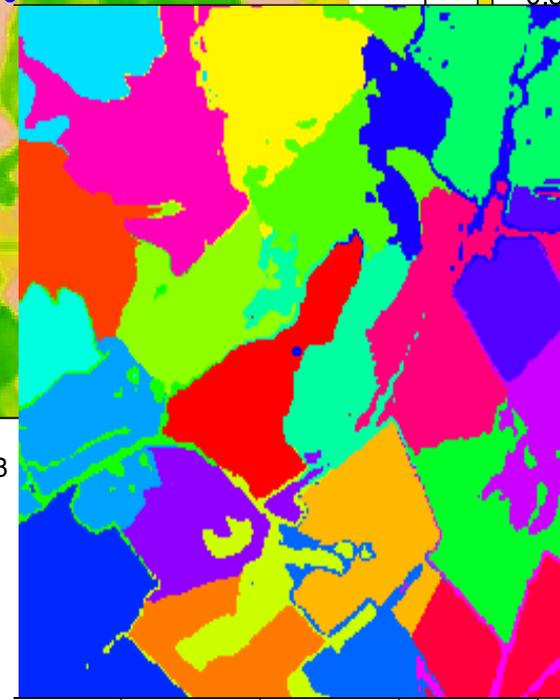
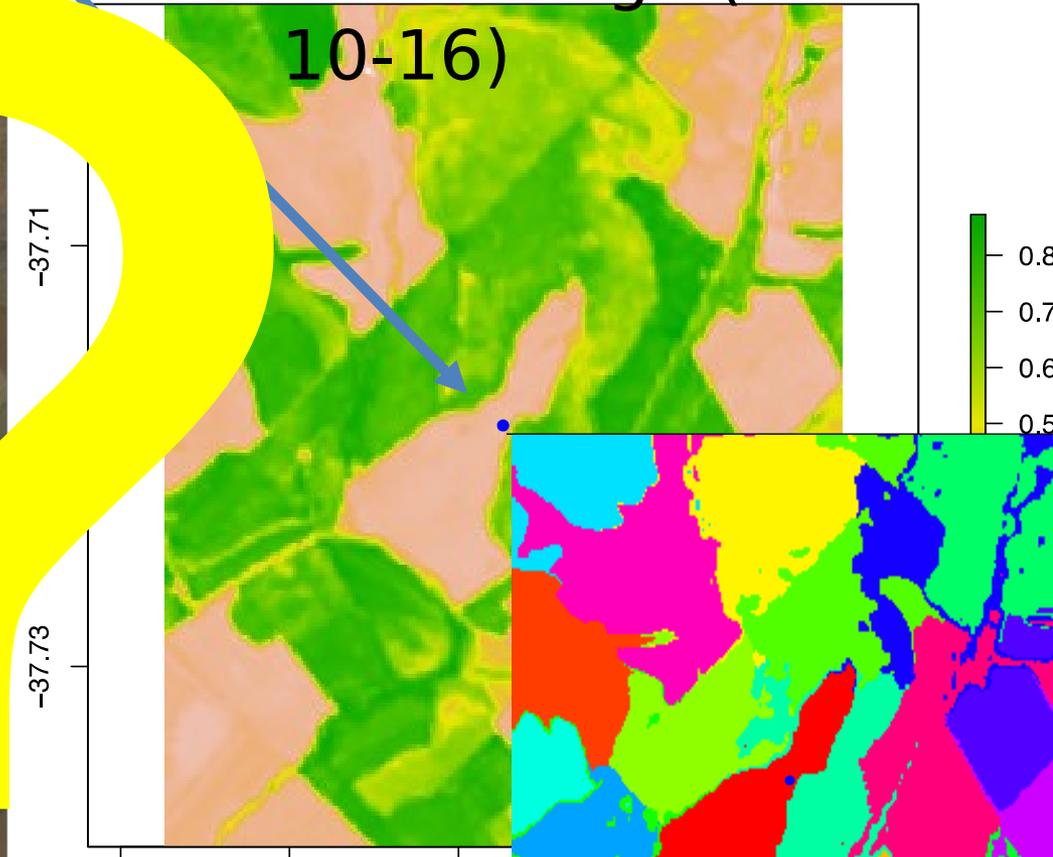
<u>Indiv.</u>	Item 1	Item 2		Item j					Item p
i*	?	6	?	?	?	8	?	3	?

GeoReferenciación Automática

Visible image
from Open Street
Map

Point of interest

NDVI image (2014-
10-16)



Symbolic Data Analysis (Estadística de Objetos?)



Repaso

Basado en el curso de Ciencia de Datos con
R Fundamentos Estadísticos

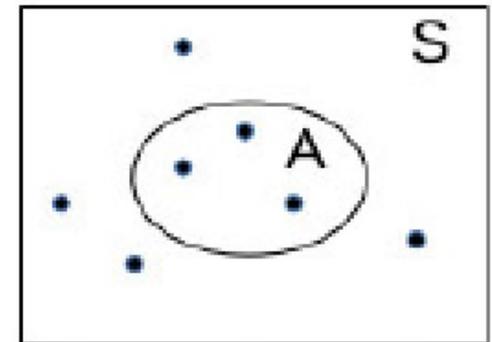
por

M. Sued, A. Bianco y M. Valdora

Teoría de Probabilidades

1. S espacio muestral: conjunto con los posibles resultados del experimento.
2. A, B, C : eventos a los cuales vamos a asignarles probabilidad.
3. \mathbb{P} : función de probabilidad.

$$\frac{m_A}{m} \rightarrow \mathbb{P}(A)$$



$$m = 7$$
$$m_A = 3$$

$\mathbb{P}(A)$ representa el porcentaje de veces que esperamos que A ocurra en **infinitas** repeticiones

Función de Probabilidad

$$0 \leq \mathbb{P}(A) \leq 1$$

La probabilidad del espacio muestral es uno: $\mathbb{P}(\mathcal{S}) = 1$.

Si A_1 y A_2 son eventos disjuntos ($A_1 \cap A_2 = \emptyset$), entonces

$$\mathbb{P}(A_1 \cup A_2) = \mathbb{P}(A_1) + \mathbb{P}(A_2) .$$

$$\mathbb{P}(A^c) = 1 - \mathbb{P}(A).$$

Dados dos eventos A y B , tenemos que

$$\mathbb{P}(A \cup B) = \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B)$$

Concepto de Independencia

Dado un evento B con $\mathbb{P}(B) > 0$, definimos la probabilidad del evento A dado que B aconteció mediante la formula:

Probabilidad
Condicional

$$\mathbb{P}(A | B) := \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}$$

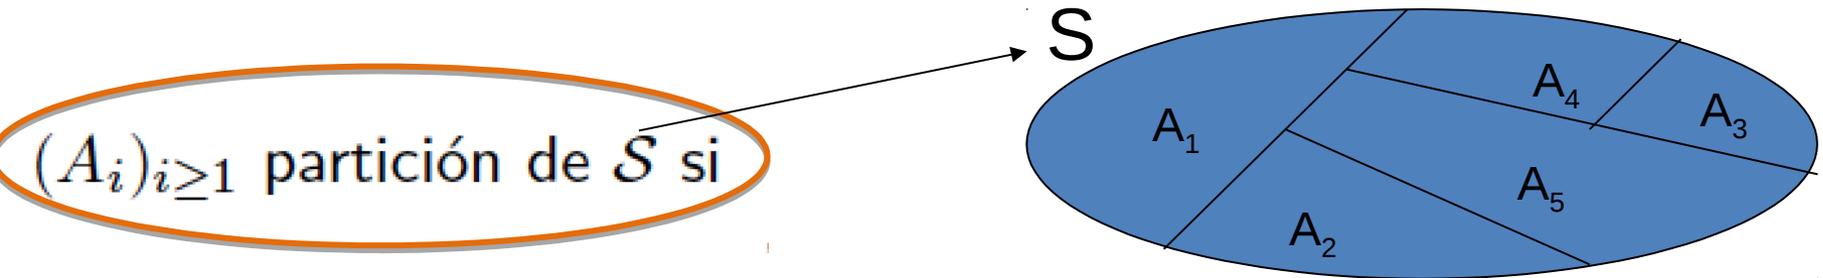
A y B se dicen independientes si

$$\mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B)$$

Lema: Si A y B son independientes y $\mathbb{P}(B) > 0$, entonces

$$\mathbb{P}(A | B) = \mathbb{P}(A)$$

Teorema de Bayes



1. Los eventos son disjuntos dos a dos: $A_i \cap A_j = \emptyset$, para $i \neq j$.
2. Los eventos cubren el espacio muestral: $\bigcup_{i \geq 1} A_i = \mathcal{S}$.

Inversión del
Condiciona

$$\mathbb{P}(C) = \sum_i \mathbb{P}(C | A_i) \mathbb{P}(A_i) .$$

$$\mathbb{P}(A_i | B) = \frac{\mathbb{P}(B | A_i) \mathbb{P}(A_i)}{\sum_{j \geq 1} \mathbb{P}(B | A_j) \mathbb{P}(A_j)} , \text{ para } i \geq 1 .$$

Variables Aleatorias

Una Variable Aleatoria X es una función definida sobre el espacio muestral que toma valores en los reales:

$$X : \mathcal{S} \rightarrow \mathbb{R}$$

Conjunto de valores de la Variable Aleatoria

Evento de Interes

Elementos del Espacio Muestral

$$X \in A = X^{-1}(A) = \{s \in \mathcal{S} : X(s) \in A\}$$

$$\mathbb{P}(X \in A) = \mathbb{P}(X^{-1}(A)) = \mathbb{P}(\{\omega \in \mathcal{S} : X(\omega) \in A\})$$

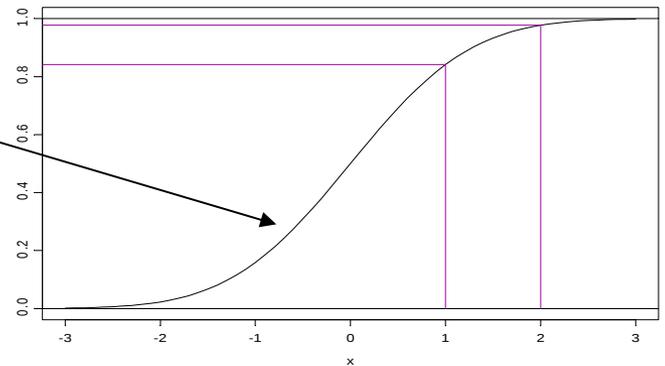
$$\mathbb{P}(X = t) = \mathbb{P}(X^{-1}(t)) = \mathbb{P}(\{\omega \in \mathcal{S} : X(\omega) = t\})$$

Valor puntual

La Función de Distribución

La función de distribución acumulada F_X de la variable (aleatoria) X está definida por:

$$F_X : \mathbb{R} \rightarrow [0, 1] \quad F_X(t) = \mathbb{P}(X \leq t) = F(t)$$



1. $0 \leq F_X(t) \leq 1$ para todo $t \in \mathbb{R}$.

2. F_X creciente: si $s \leq t$, entonces $F_X(s) \leq F_X(t)$.

3. $\lim_{t \rightarrow -\infty} F_X(t) = 0$ y $\lim_{t \rightarrow +\infty} F_X(t) = 1$.

4. F_X es continua a derecha con límite a izquierda:

5. $\mathbb{P}(X = a)$ es el salto en a de F_X

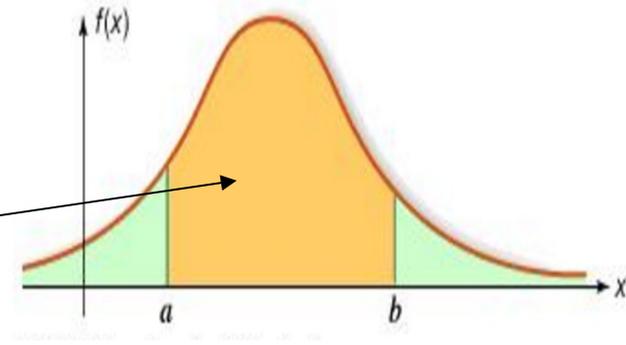
La Función de Densidad

Una variable aleatoria X se dice ^(*) absolutamente) continua si existe una densidad

$$f_X : \mathbb{R} \rightarrow \mathbb{R}_{\geq 0}$$

tal que

$$\mathbb{P}(X \in A) = \int_A f_X(u) du.$$



En particular,

$$F_X(t) = \mathbb{P}(X \leq t) = \int_{-\infty}^t f_X(u) du .$$

En tal caso, diremos que f_X es la función de densidad de la variable aleatoria X .

$f : \mathbb{R} \rightarrow \mathbb{R}$ se dice densidad si

- $f(u) \geq 0$ para todo $u \in \mathbb{R}$
- $\int_{-\infty}^{+\infty} f(u) du = 1$

La Normal Univariada

- Z normal estandar si

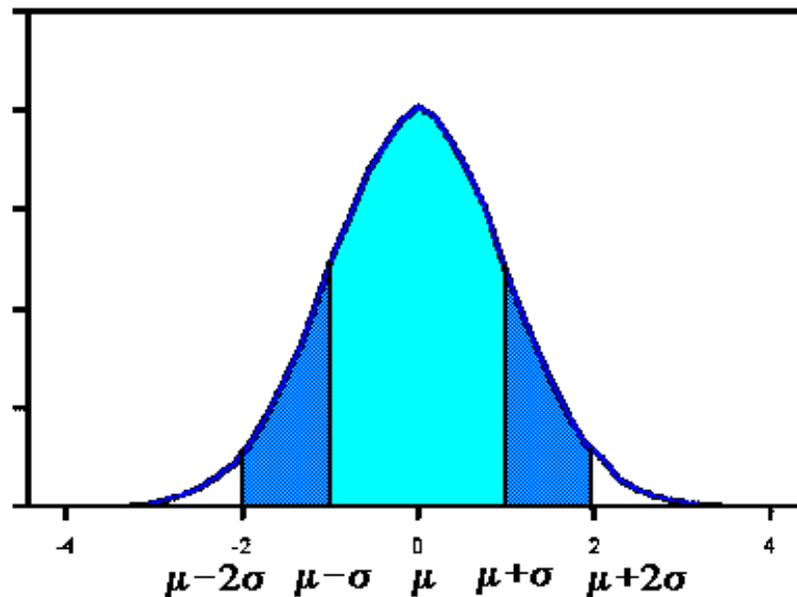
$$f_Z(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2}$$

- f_Z simétrica en el origen: $f_Z(z) = f_Z(-z)$
- Siendo f_Z simétrica, tenemos que $F_Z(-u) = 1 - F_Z(u)$
- $F_Z(z) = \int_{-\infty}^z f_Z(u) du$ no se puede calcular.
- Hay tabla con valores de $F_Z(u)$ para $u > 0$.
- $\phi(z) = F_Z(z)$ se llama función phi.

- Z normal estandar, Sea $X := \sigma Z + \mu$

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

- $F_X(x) = \phi((x - \mu)/\sigma)$
- $X \sim \mathcal{N}(\mu, \sigma^2)$



Esperanza y Varianza

Dada una variable aleatoria discreta X con $\mathbb{R}g(X) = \{x_1, x_2, \dots\}$ y función de probabilidad puntual $p_X(x_i)$, definimos la esperanza de X mediante la fórmula,

$$\mathbb{E}[X] = \sum_{i=1}^{\infty} x_i p_X(x_i),$$

Dada una variable aleatoria continua X con función de densidad f_X , definimos la esperanza de X como

$$\mathbb{E}[X] = \int_{-\infty}^{\infty} u f_X(u) du.$$

X v.a. discreta con $\mathbb{E}[X] = \mu$. La varianza de X , está definida mediante la fórmula

$$\mathbb{V}(X) = \mathbb{E}\left[(X - \mu)^2\right].$$

Covarianza y Correlación

- Medidas de asociación lineal entre variables (x e y)

Covarianza Empírica

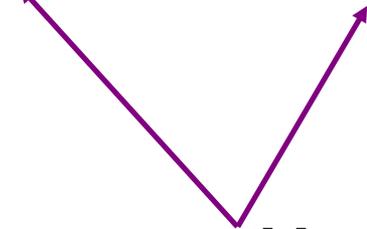

$$cov(x, y) = \sum_{i=1}^n \frac{1}{n} (x_i - \bar{x})(y_i - \bar{y})$$

Correlación


$$\rho(x, y) = cor(x, y) = \frac{cov(x, y)}{\sigma(x)\sigma(y)}$$

$$-1 \leq \rho(x, y) \leq 1$$

Medias

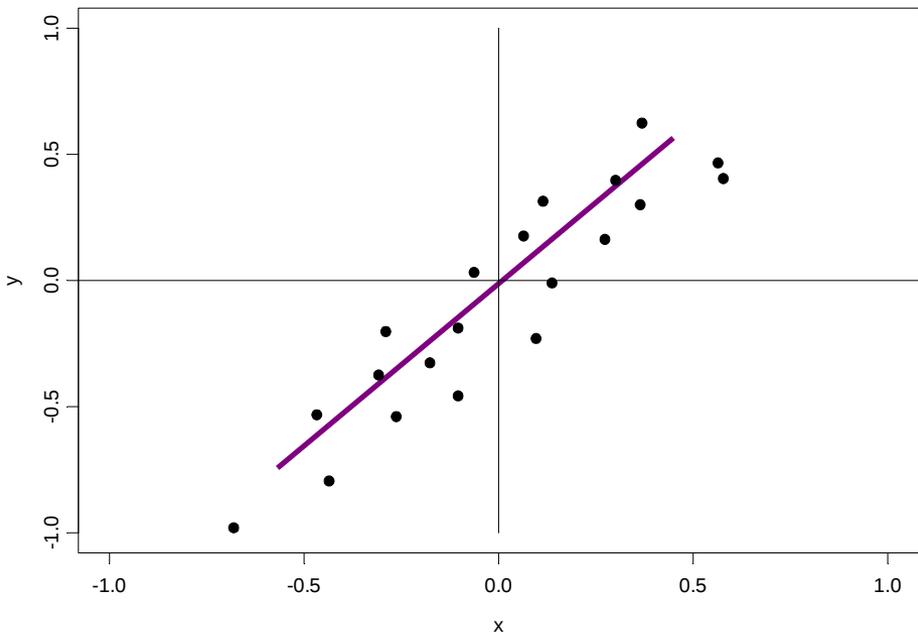


Desvios

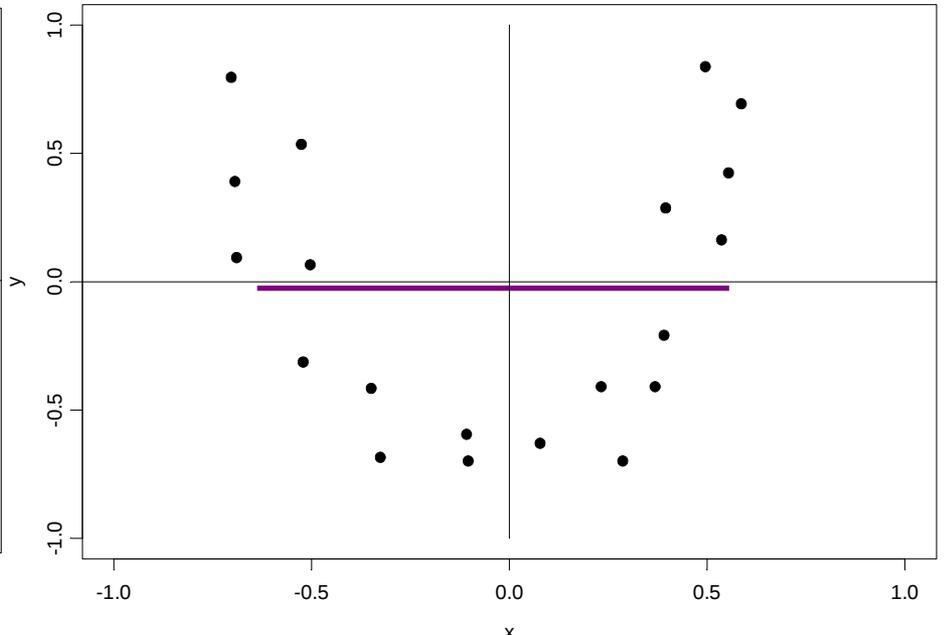


Asociación Vs. Correlación

$\text{Cor}(x,y) = 0.9$



$\text{Cor}(x,y) = 0.05$



Tchevichev

Sea W una v.a. con media μ_W y $V[W] = \sigma_W^2$. Luego, $\epsilon > 0$

$$\mathbb{P}(|W - \mu_W| \geq \epsilon) \leq \frac{\sigma_W^2}{\epsilon^2}$$

Ley de los Grandes Números

Sean $(X_i)_{i \geq 1}$ i.i.d., con $E[X_i] = \mu$ y $V[X_i] = \sigma^2$, para todo i .
Entonces, el promedio converge a μ en probabilidad:

$$\lim_{n \rightarrow \infty} \mathbb{P}(|\bar{X}_n - \mu| > \epsilon) = 0$$

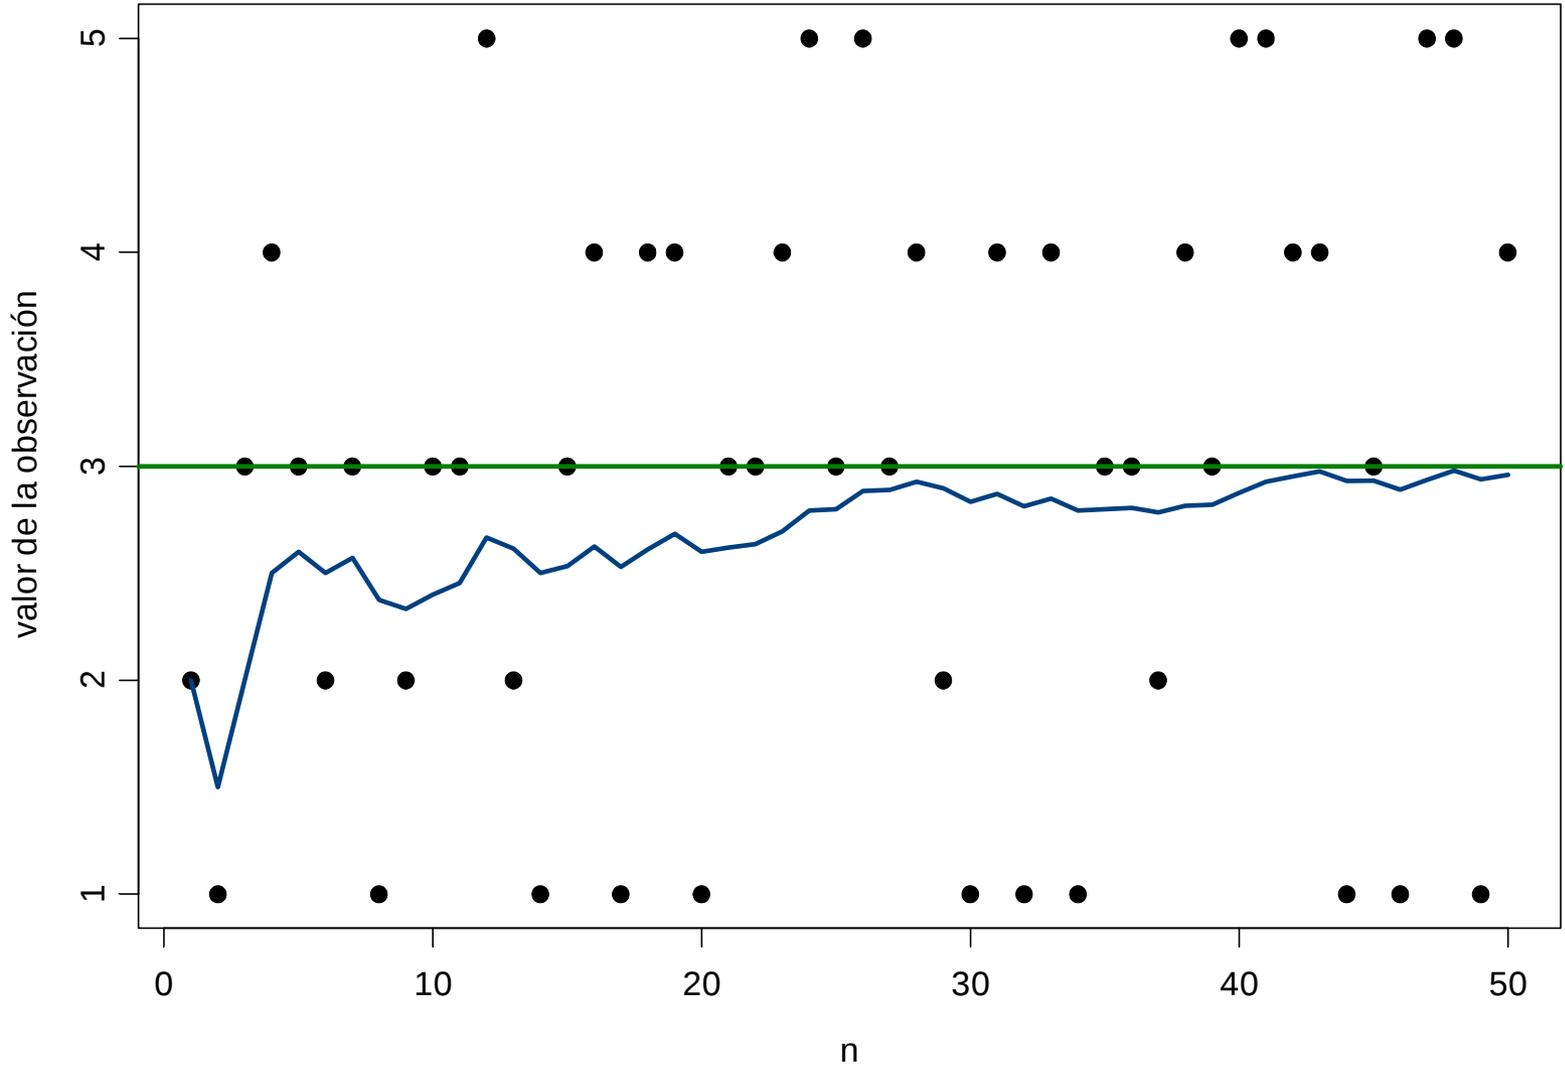
Promedio

Es decir, para todo $\epsilon > 0$, vale que

$$\bar{X}_n \rightarrow \mu \text{ en probabilidad}$$

Valores de la Variable

Ejemplo de Ley de los Grandes Números



Val	Prob
1	0.2
2	0.2
3	0.2
4	0.2
5	0.2

Teorema Central del Límite

Variables
Independientes e
Identicamente
Distribuidas

Sean $(X_i)_{i \geq 1}$ v.a. i.i.d. con $E[X] = \mu$ y $V[X] = \sigma^2$, entonces tenemos que

$$\mathbb{P}\left(\frac{\bar{X}_n - E(X_1)}{\sqrt{\text{Var}(\bar{X}_n)}} \leq x\right) \xrightarrow{n \rightarrow \infty} \phi(x) \quad \forall x \in \mathbb{R},$$

Promedio de
Variables
Aleatorias

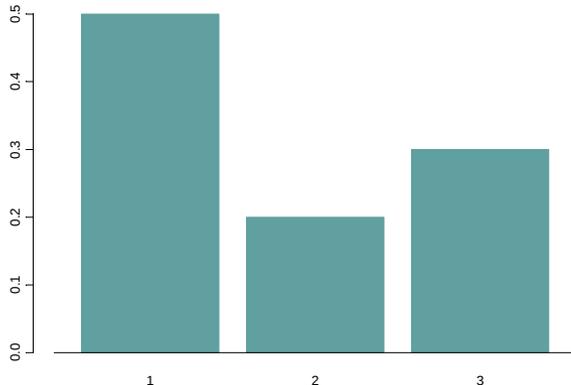
Función de
Distribución
Normal

Ejemplo del Teorema Central

X_i	$P(x_i)$
1	0.5
2	0.2
3	0.3

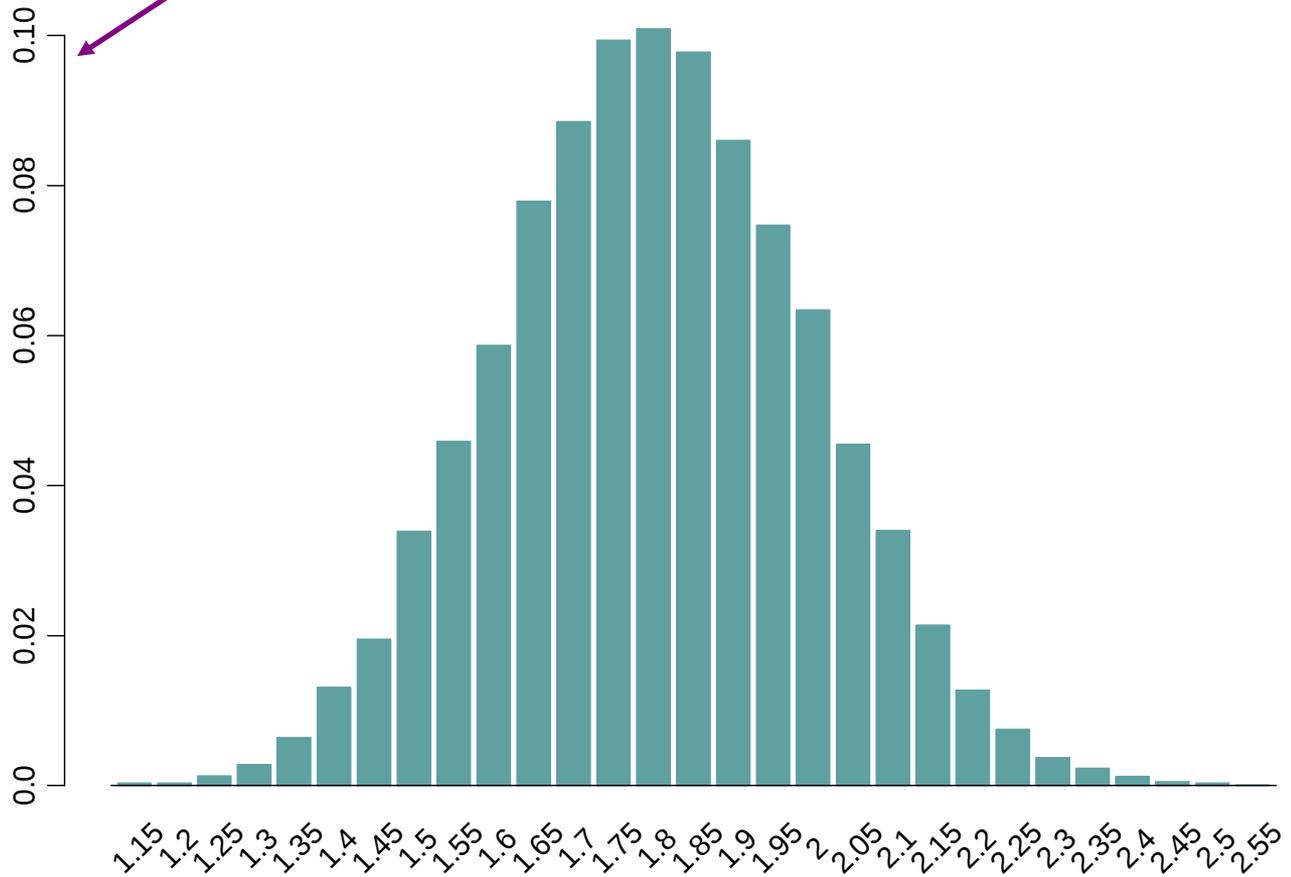


$(X_1+x_2)/2$	$P((X_1+x_2)/2)$
2/2	$0.5*0.5$
3/2	$0.5*0.2 + 0.2*0.5$
4/2	$0.5*0.3 + 0.2*0.2 + 0.3*0.5$
5/2	$0.2*0.3 + 0.3*0.2$
6/2	$0.3*0.3$



Distribución de $(x_1+x_2+\dots+x_{20})/20$

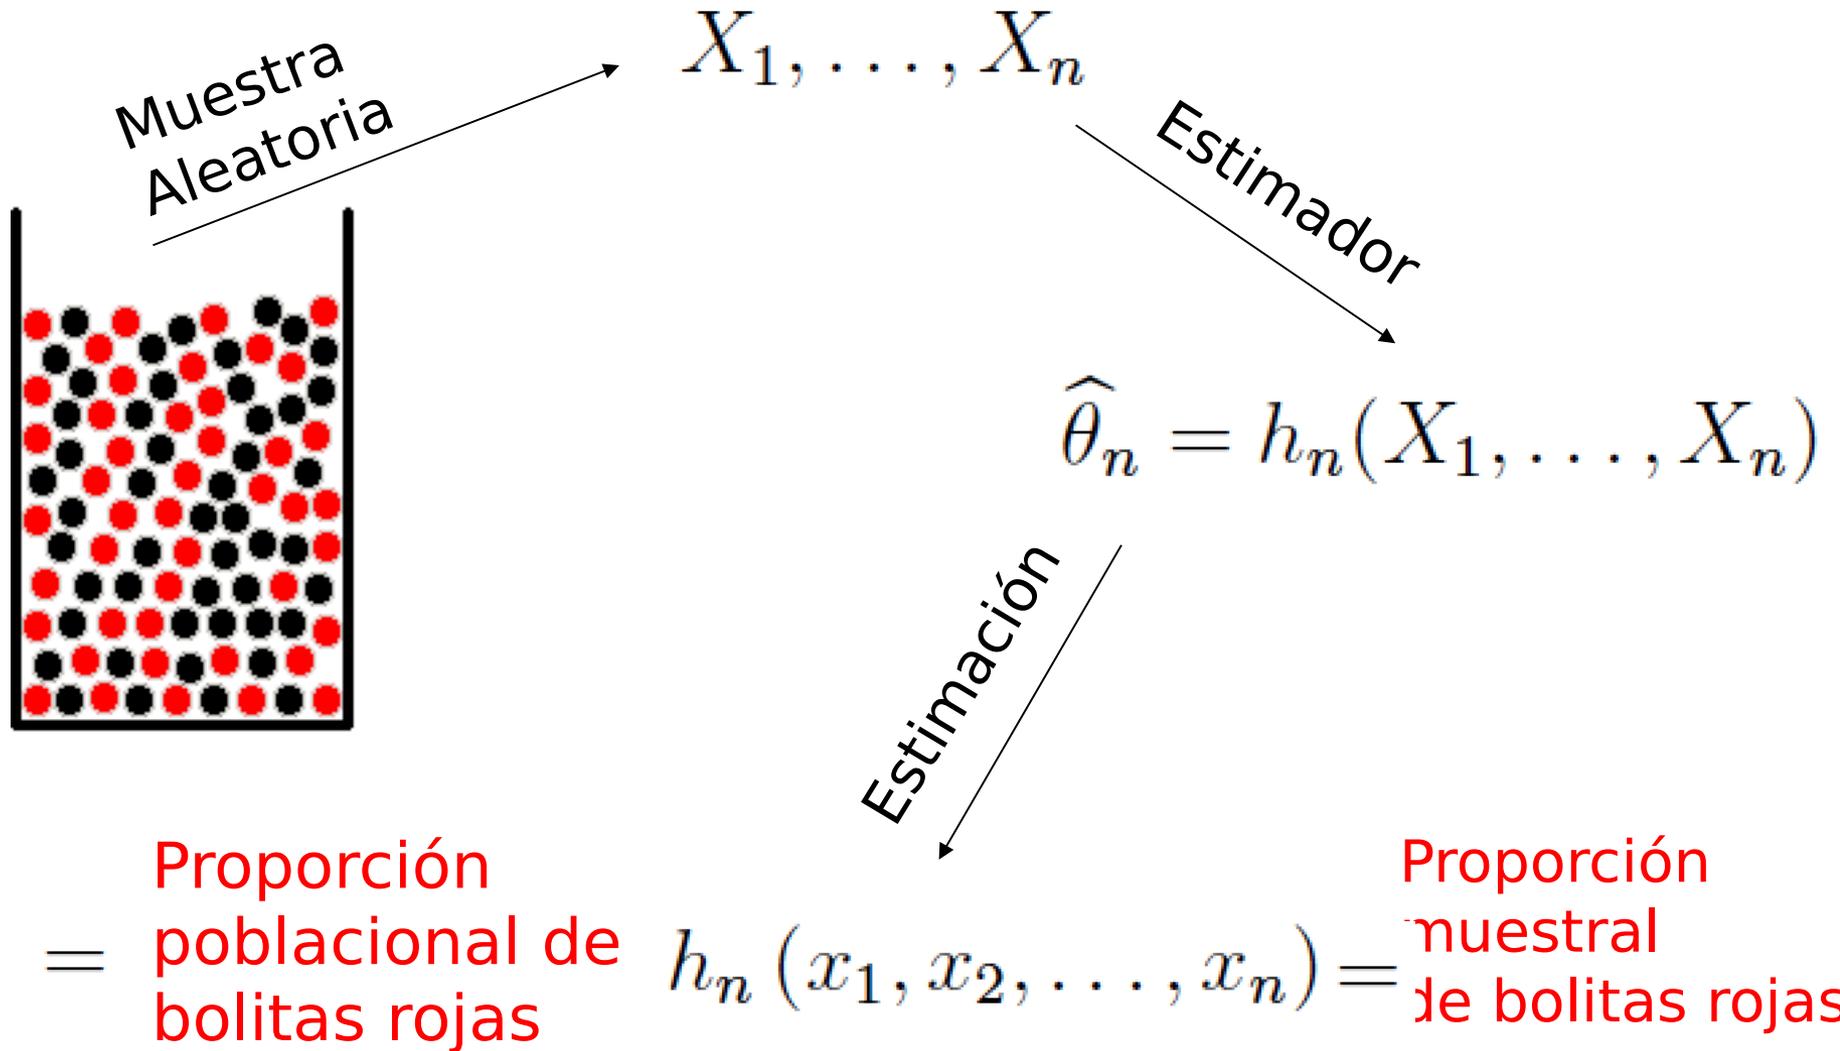
Probabilidad



Inferencia estadística

Trata de estimar o inferir mediante una muestra (aleatoria) el valor (desconocido) de un parámetro poblacional

Probabilidad e Inferencia, el problema de la “Inversión”



Inferencia Estadística

$$f \in \mathcal{M} = \{f(\cdot, \theta), \theta \in \Theta\}.$$

Familias
No/Semi
Paramétricas

Datos

Estimación
Modelo
Paramétrico

$$(X_i)_{i \geq 1} \text{ i.i.d. } X_i \sim F, F \in \mathcal{F}$$

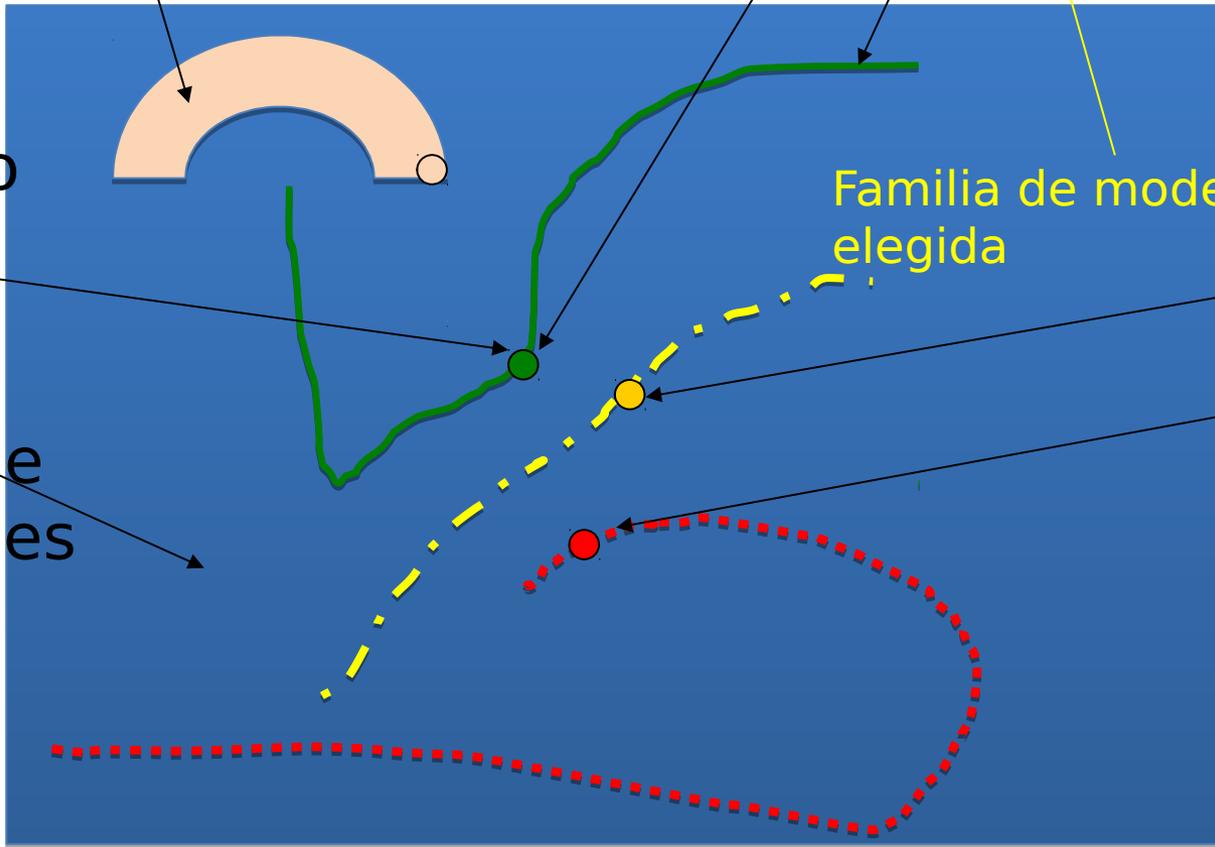
Verdadero
DGP

Familia de modelos
elegida

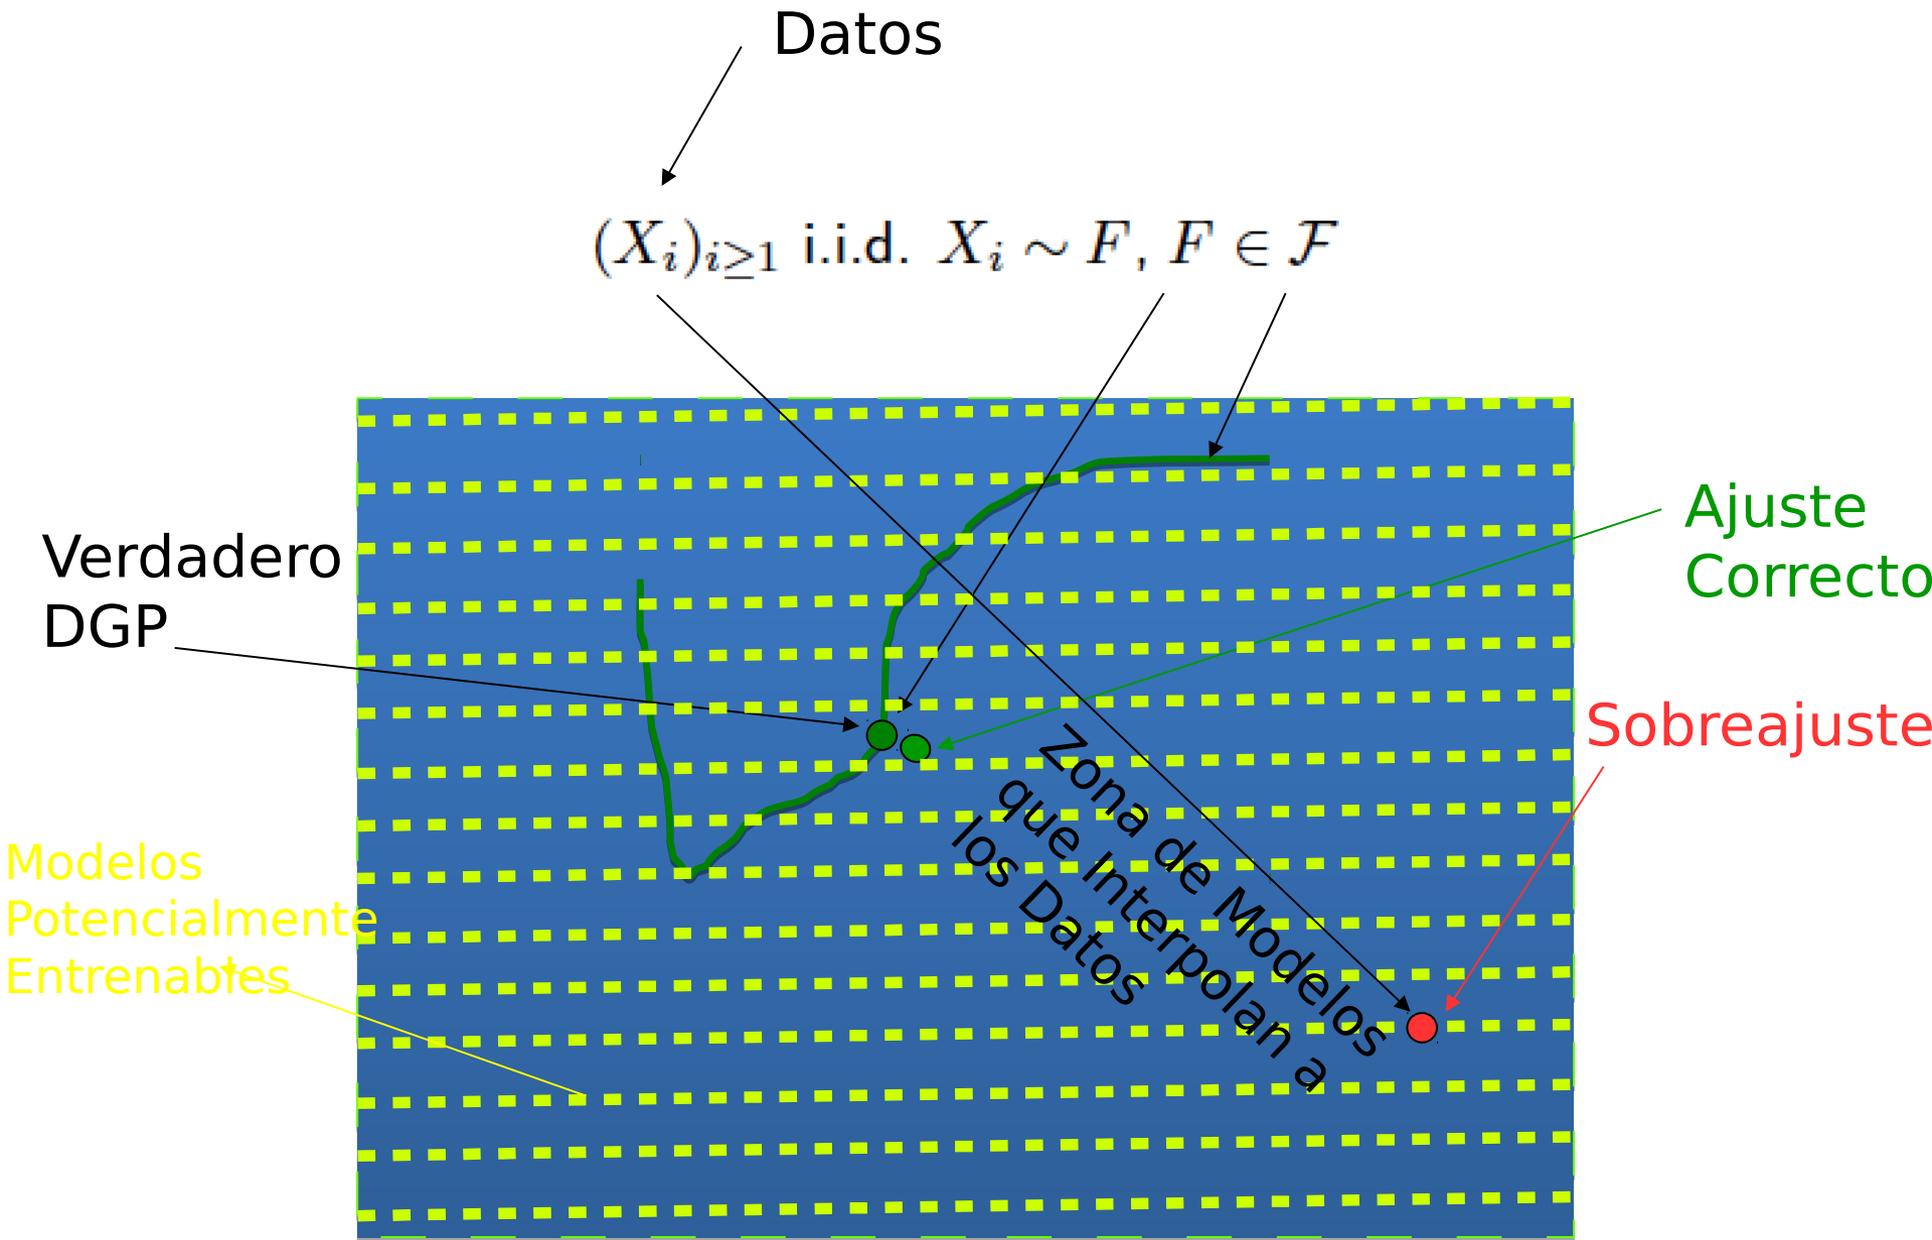
$$\hat{f} = f_{\hat{\theta}}(x)$$

Universo de
Posibilidades
DGP's

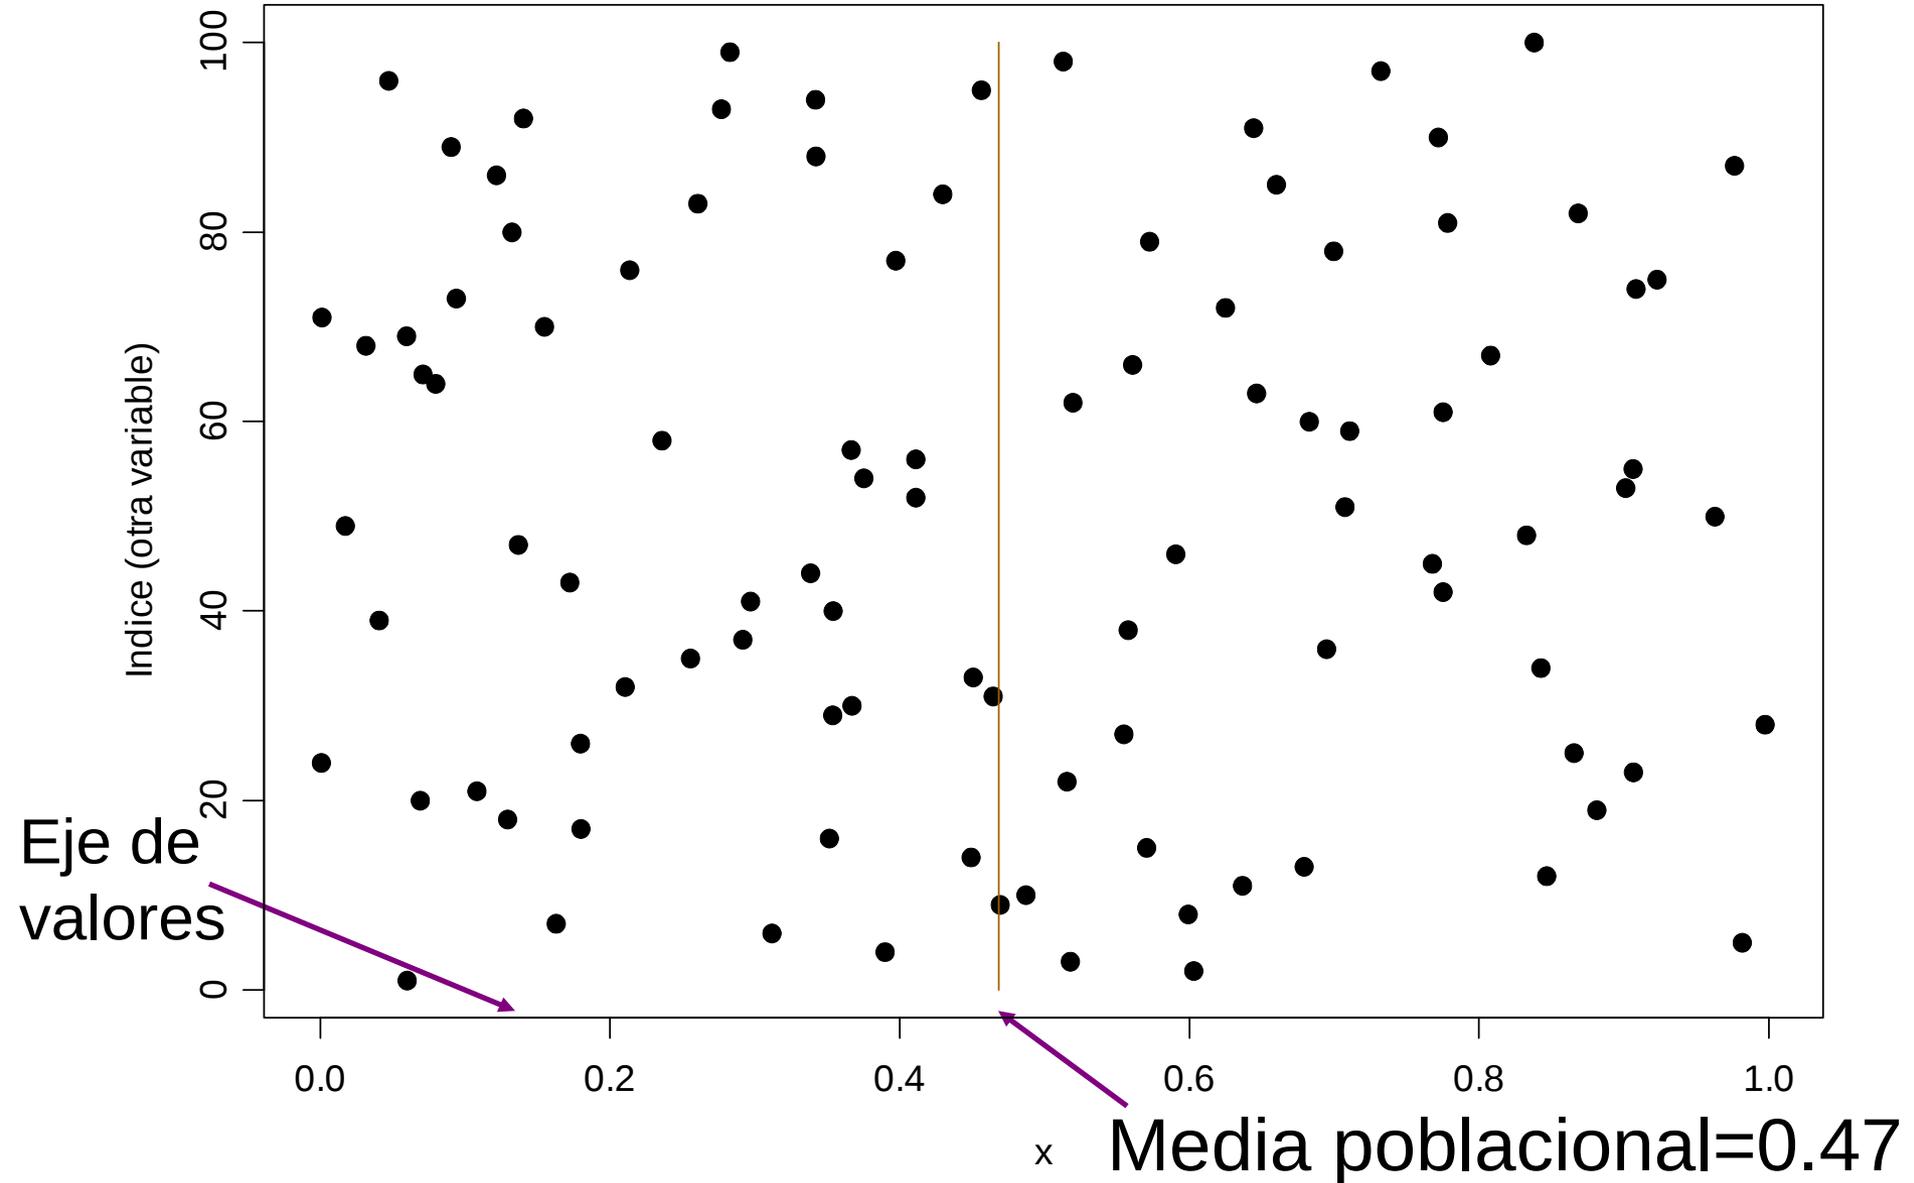
$$F_2 \in \mathcal{F}_2$$



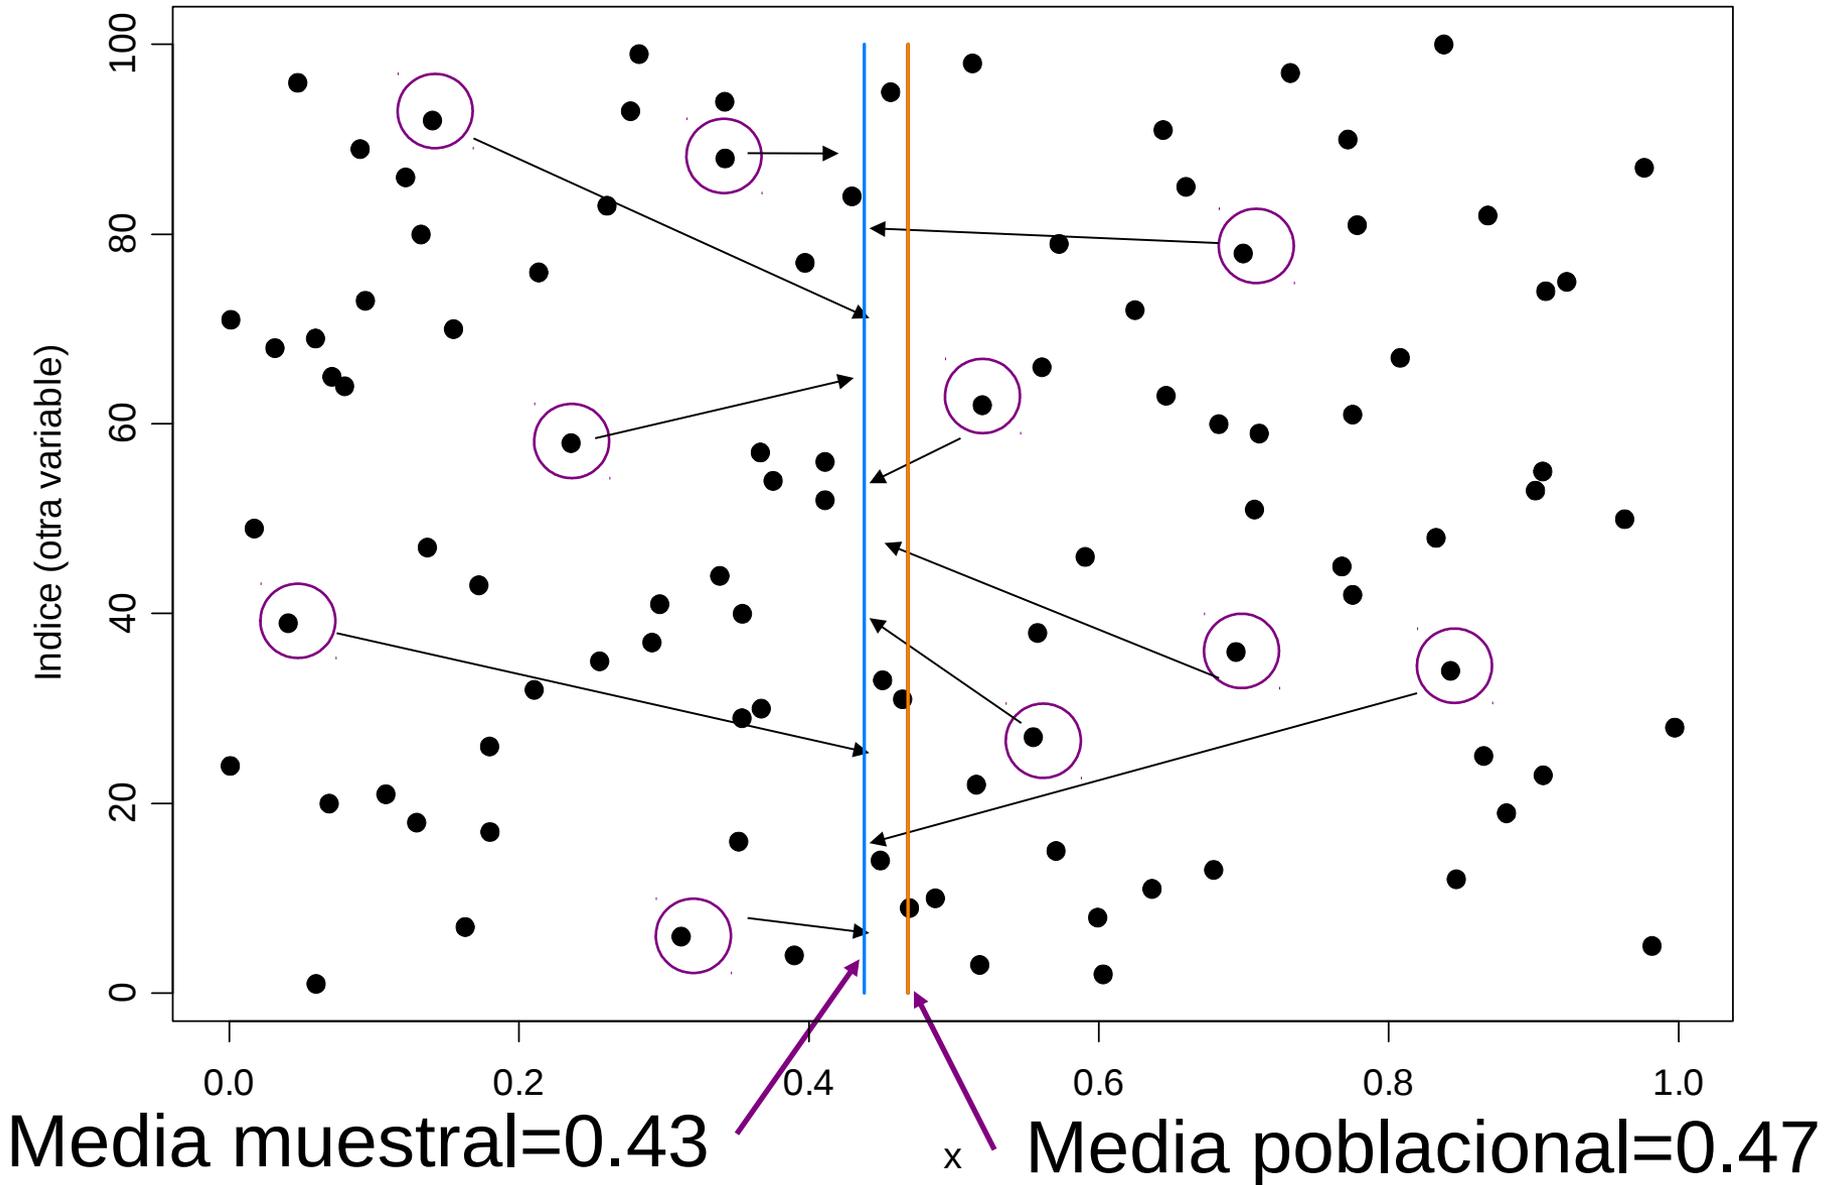
Aproximadores Universales (ANN - MLP)



La población (N=100)



La muestra (n=10)



El estimador y la estimación

Dados los datos: $x_1, x_2 \dots x_{10}$

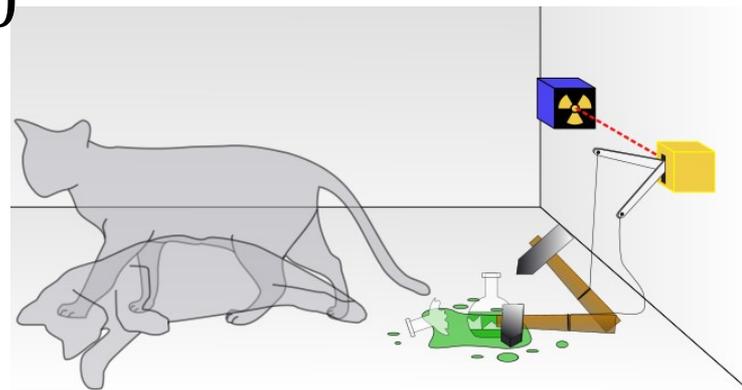
$$\bar{x} = \frac{\sum_{i=1}^{10} x_i}{10} = \frac{x_1}{10} + \frac{x_2}{10} + \dots + \frac{x_{10}}{10} = 0.43$$

Dados las variables aleatorias: $x_1, x_2 \dots x_{10}$

$$\bar{x} = \frac{\sum_{i=1}^{10} x_i}{10} = \frac{x_1}{10} + \frac{x_2}{10} + \dots + \frac{x_{10}}{10}$$

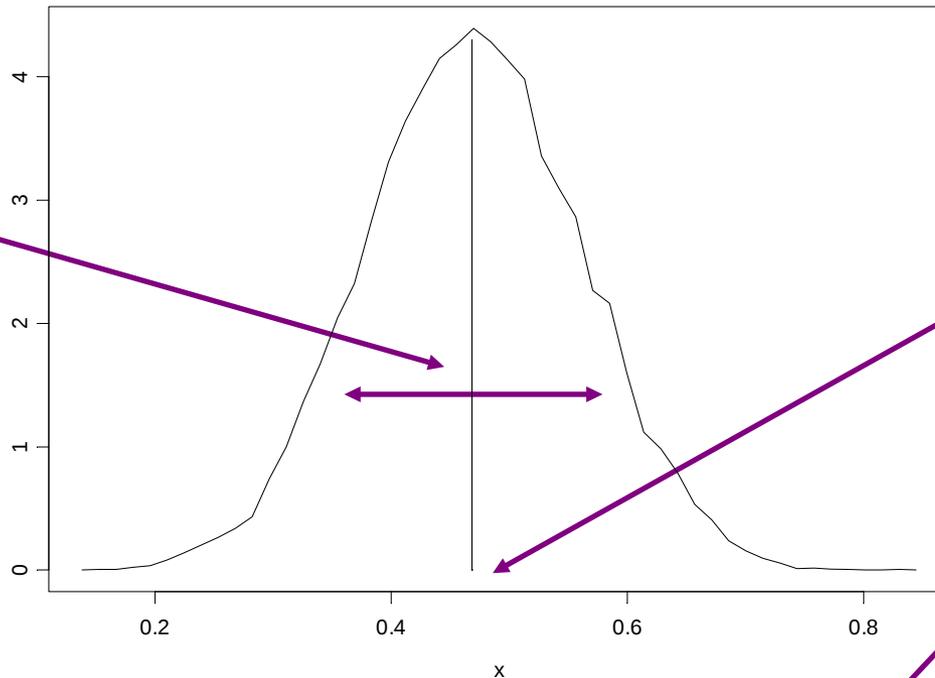
Schrödinger's cat

¿ Que tan bueno es ?
¿ Cuales son sus propiedades?



Repito el experimento 10000 veces

Desvío
= 0.09



Media
poblacional
= 0.468

Insesgado

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.15705	0.40697	0.46900	0.46879	0.53011	0.82568

Propiedades de los Estimadores

- Consistencia

$$\hat{\theta}_n \rightarrow \theta$$

Parámetro

- Insesgadez

$$\mathbb{E}(\hat{\theta}_n) = \theta$$

Estimador

- Error Cuadrático Medio

$$\text{ECM}(\hat{\theta}_n) = \mathbb{V}(\hat{\theta}_n) + \left\{ \mathbb{E}(\hat{\theta}_n) - \theta \right\}^2$$

$$\mathbb{E}(\hat{\theta}_n - \theta)^2$$

Varianza

Sesgo²

Verosimilitud

Parámetros

Variables
Aleatorias

- Modelo: $\mathcal{M} = \{p(\cdot, \theta), \theta \in \Theta\}$.
- $\mathbf{x} = x_1, \dots, x_n$ realización de X_1, \dots, X_n i.i.d.
- Función de verosimilitud asociada a $\mathbf{x} = x_1, \dots, x_n$:

Los
Parámetros
varían !!!

$$L(\cdot; \mathbf{x}) : \Theta \rightarrow \mathbb{R}$$

$$L(\theta; \mathbf{x}) = \mathbb{P}(X_1 = x_1, \dots, X_n = x_n), X_i \sim p(\cdot, \theta).$$

$$L(\theta; \mathbf{x}) = \prod_{i=1}^n p(x_i, \theta),$$

Observaciones están fijas !!!

Estimador de Máxima-Verosimilitud

- Función de verosimilitud: $L(\cdot ; \mathbf{x}) : \Theta \rightarrow \mathbb{R}$

$$L(\theta ; \mathbf{x}) = f_{X_1, \dots, X_n}(x_1, \dots, x_n), X_i \sim f(\cdot, \theta).$$

$$L(\theta ; \mathbf{x}) = \prod_{i=1}^n f(x_i, \theta),$$

- Propuesta de Máxima Verosimilitud:

$$h_n(\mathbf{x}) = \operatorname{argmax}_{\theta \in \Theta} L(\theta ; \mathbf{x}).$$

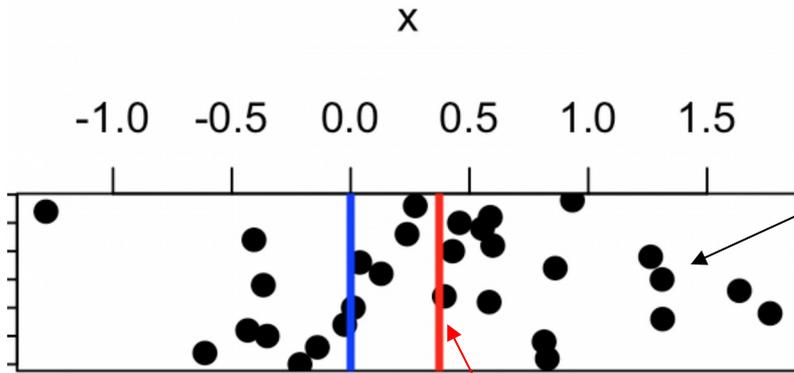
o sea

$$L(h_n(\mathbf{x}), \mathbf{x}) \geq L(\theta, \mathbf{x})$$

- Definimos el EMV siendo $\hat{\theta}_n = h_n(X_1, \dots, X_n)$.

Ejemplo de Verosimilitud

30 realizaciones
 $X \sim N(0, 1)$

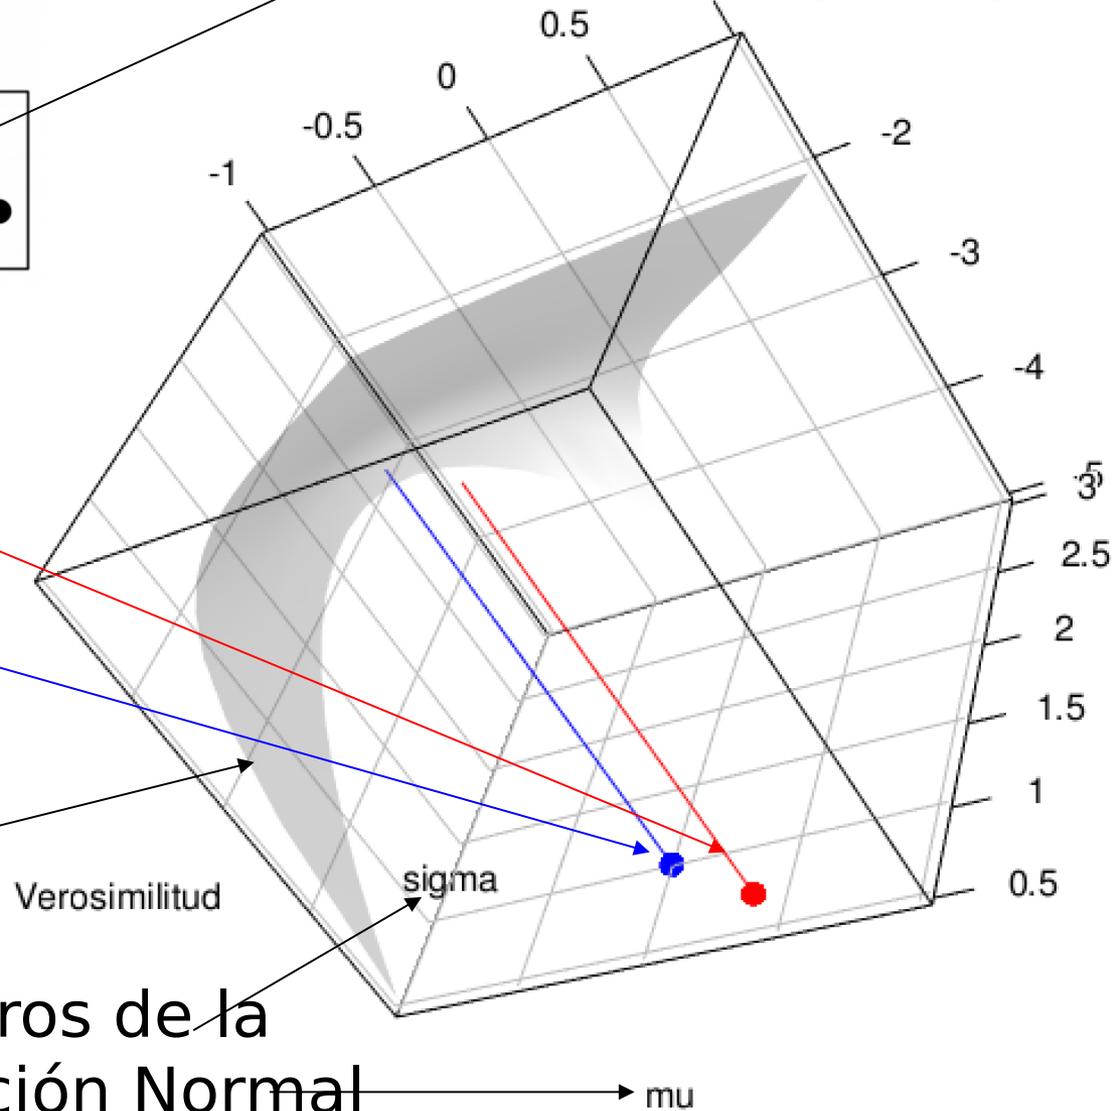


Media verdadera = 0

Media estimada MV = 0.37

Función de Verosimilitud (Normal) basada en los 30 x's fijos

Parámetros de la Distribución Normal



Selección de Modelos

- Modelo: $\mathcal{M} = \{f(\cdot, \theta), \theta \in \Theta\}$

- Verosimilitud (likelihood): $L(\theta, \mathbf{x}) = \prod_{i=1}^n f(x_i, \theta)$

$$\hat{\theta}(\mathbf{x}) = \operatorname{argmax}_{\theta \in \Theta} L(\theta; \mathbf{x}), \quad \text{o sea } L(\hat{\theta}(\mathbf{x}), \mathbf{x}) \geq L(\theta, \mathbf{x}).$$

- log-vero (log-likelihood): $\ell(\theta, \mathbf{x}) = \sum_{i=1}^n \log(f(x_i, \theta))$
- Bondad del Modelo:

$$\text{Bondad}(\mathcal{M}, \mathbf{x}) := \ell(\hat{\theta}(\mathbf{x}), \mathbf{x}) = \sum_{i=1}^n \log(f(x_i, \hat{\theta}(\mathbf{x})))$$

$$\text{AIC} = \text{AIC}(\mathcal{M}, \mathbf{x}) := -2 \left(\ell(\hat{\theta}(\mathbf{x}), \mathbf{x}) - \#\text{parámetros} \right)$$

Intervalos de confianza

Dado un parámetro poblacional desconocido, buscamos un intervalo (dependiente de la muestra) que con alta probabilidad contenga al verdadero valor del parámetro.

Intervalos de confianza

Dados $x_1 \dots x_n$ muestra aleatoria proveniente de una población con parámetro θ

Límite inferior Límite superior

$[I(x_1 \dots x_n), D(x_1 \dots x_n)]$ es un intervalo de confianza 0.95 si

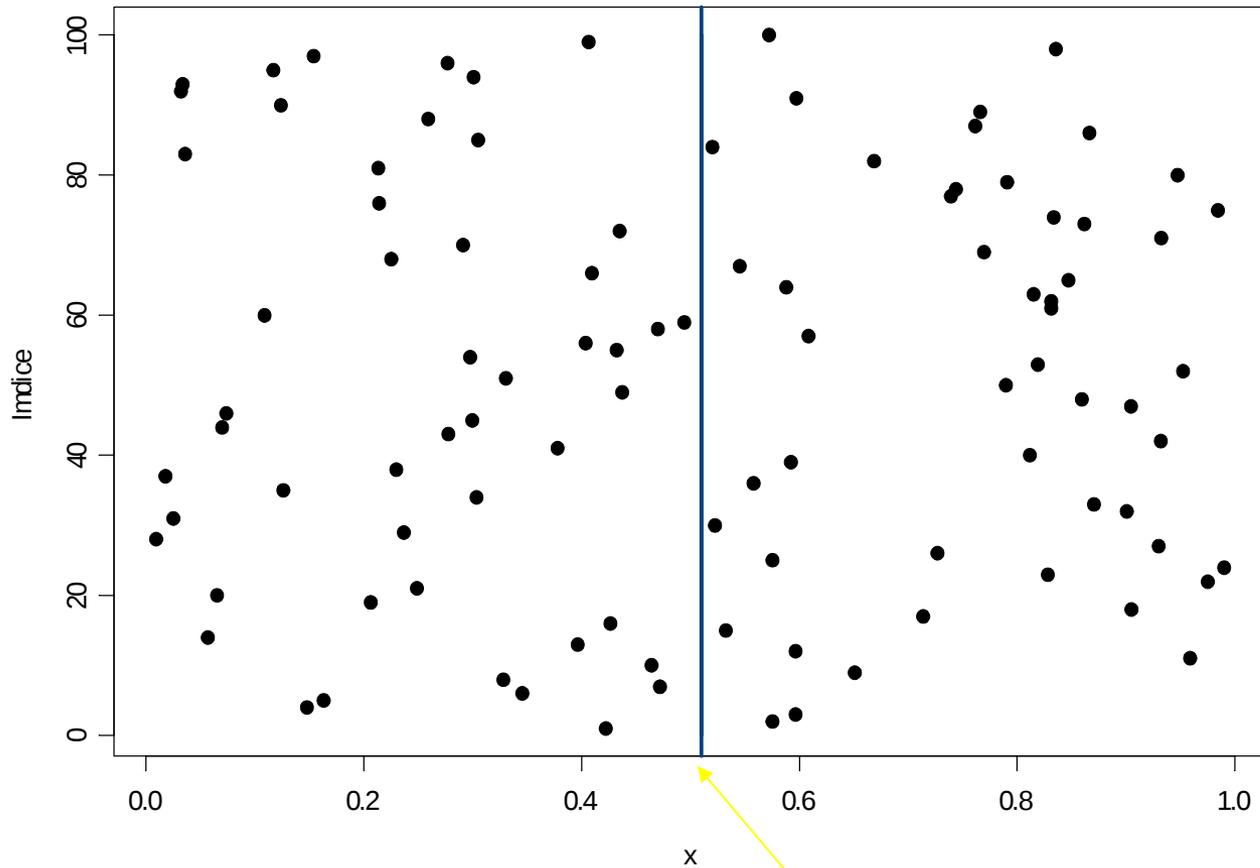
$$P(I(x_1 \dots x_n) \leq \theta \leq D(x_1 \dots x_n)) = 0.95$$

Fijo

Aleatorio

Intervalos de confianza: Ejemplo

La población



Media poblacional = 0.47

Propongo un intervalo de confianza (cualquiera)

Dada una muestra aleatoria de dos elementos x_1 y x_2

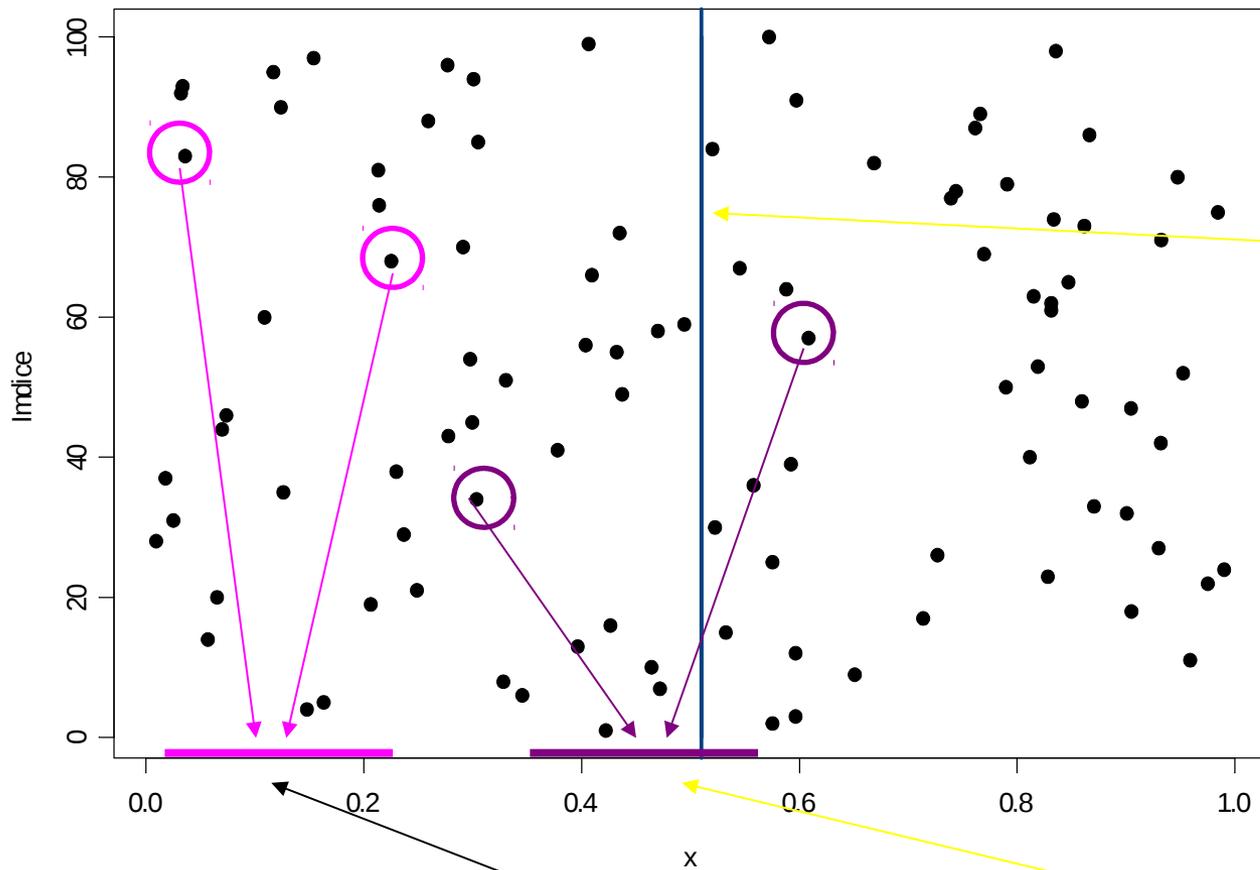
$$\left[I(x_1 \dots x_n), D(x_1 \dots x_n) \right]$$

=

$$\left[\left(\frac{x_1 + x_2}{2} \right) - 0.1, \left(\frac{x_1 + x_2}{2} \right) + 0.1 \right]$$

¿ Con que probabilidad cubre a la verdadera media poblacional (0.47)?

Dos realizaciones del intervalo de confianza (cualquiera)



Media poblacional = 0.47

No cubre

Si cubre

Repito el experimento 10000 veces

Repetición	Cubre ?
1	NO
2	NO
3	SI
4	NO
...	...
10000	NO

Proporción de intervalos que cubren = 0.3503

¿ Que pasa si tomo tamaño de muestra = 4 ?

Proporción de intervalos que cubren = 0.4871

¿ Que pasa si tomo tamaño de muestra = 8 ?

Proporción de intervalos que cubren = 0.6543

¿ Que pasa si tomo tamaño de muestra = 8 y longitud de intervalo = 0.4 ?

Proporción de intervalos que cubren = 0.8558

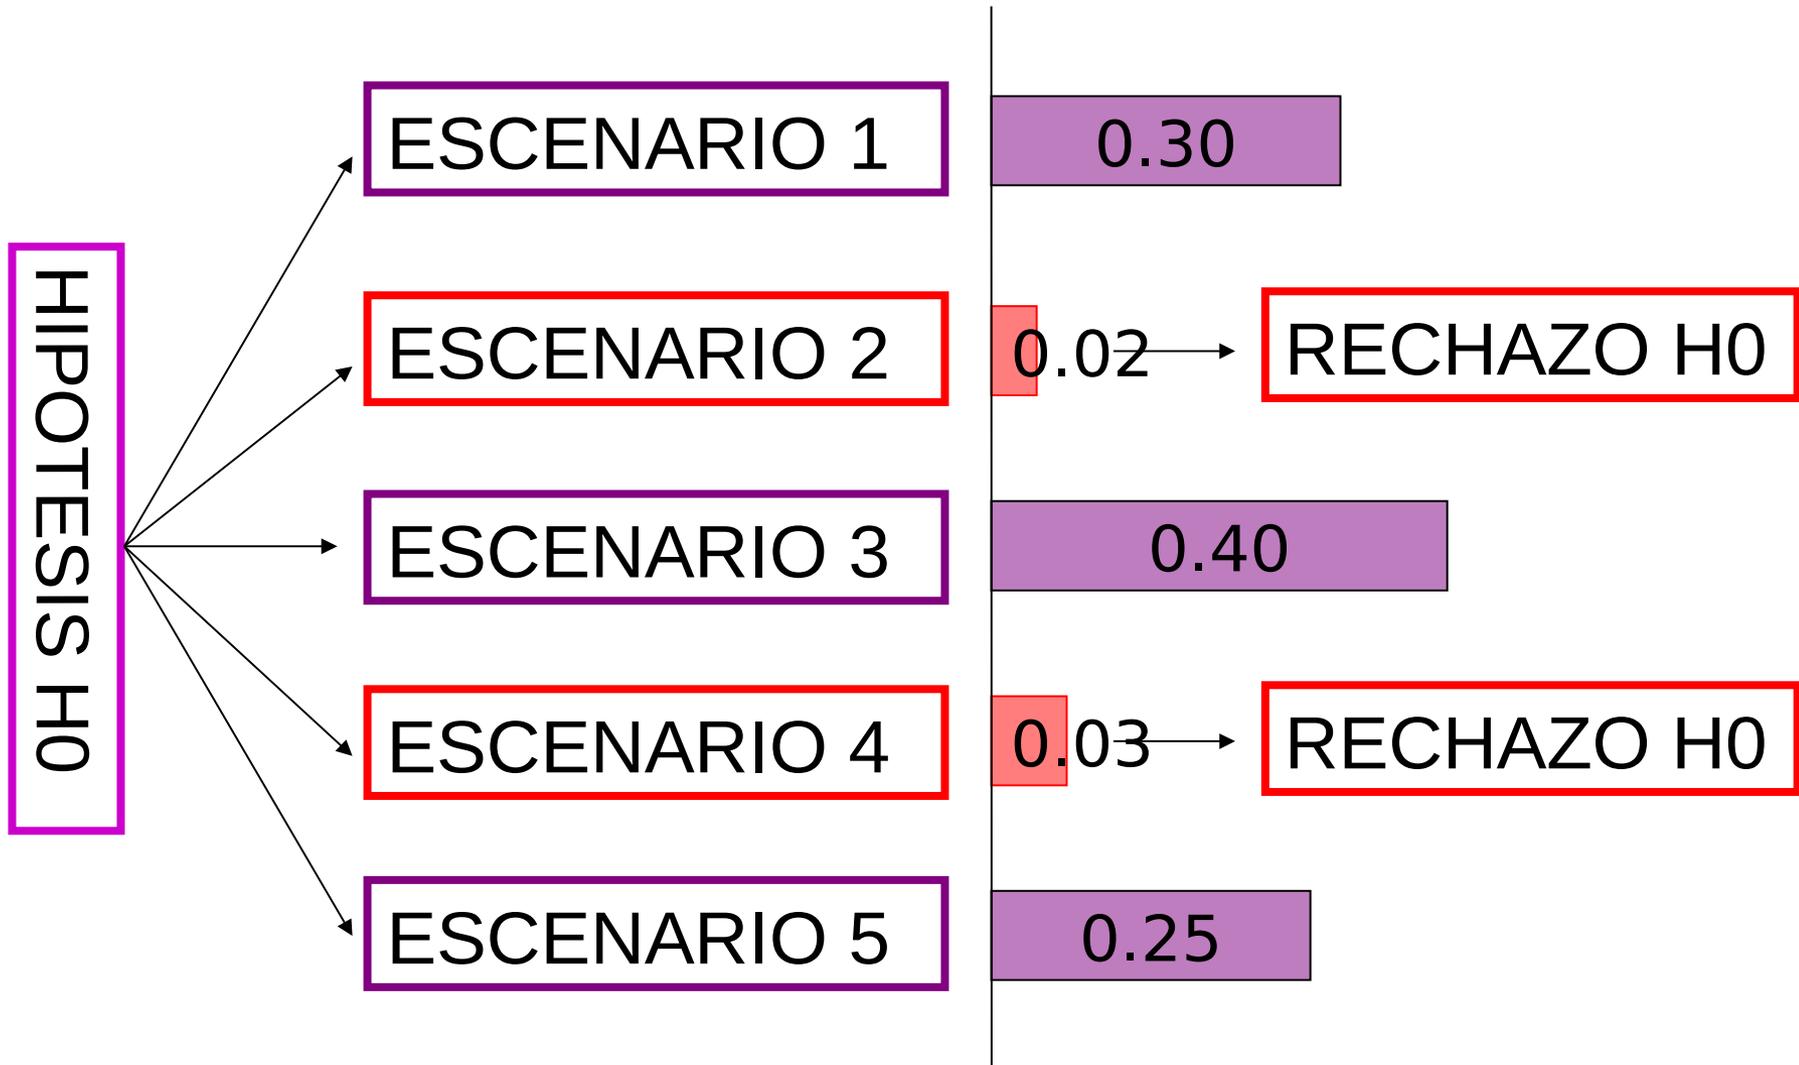
Test de Hipótesis

Es un mecanismo para decidir acerca de la validez de una hipótesis, controlando la probabilidad de rechazar la misma siendo que esta es verdadera.

Intuitivamente

- Nos paramos en la hipótesis que queremos validar y pensamos los diferentes escenarios posibles con sus probabilidades (según la hipótesis)
- Si la realidad se corresponde con un escenario que bajo la hipótesis es poco probable, rechazamos la hipótesis

Gráficamente




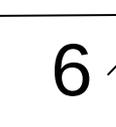
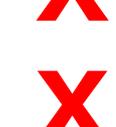
Receta para armar un Test de Hipótesis

- Definir la Hipótesis nula (H_0)
- Elegir un estadístico que mida o refleje el alejamiento de la evidencia de H_0
- Definir un valor de probabilidad (α) por debajo del cual creamos que los eventos son suficientemente “raros”
- Evaluar el estadístico en los datos y comparar la probabilidad de un resultado como ese o “mas extremo” con α

H0: Juan NO es adivino



$$P(Z \geq 10) = \\ = 1/1024 = 0.000977$$



$$P(Z \geq 6) = \\ = 0.377$$

Z = Cantidad de aciertos 10

6

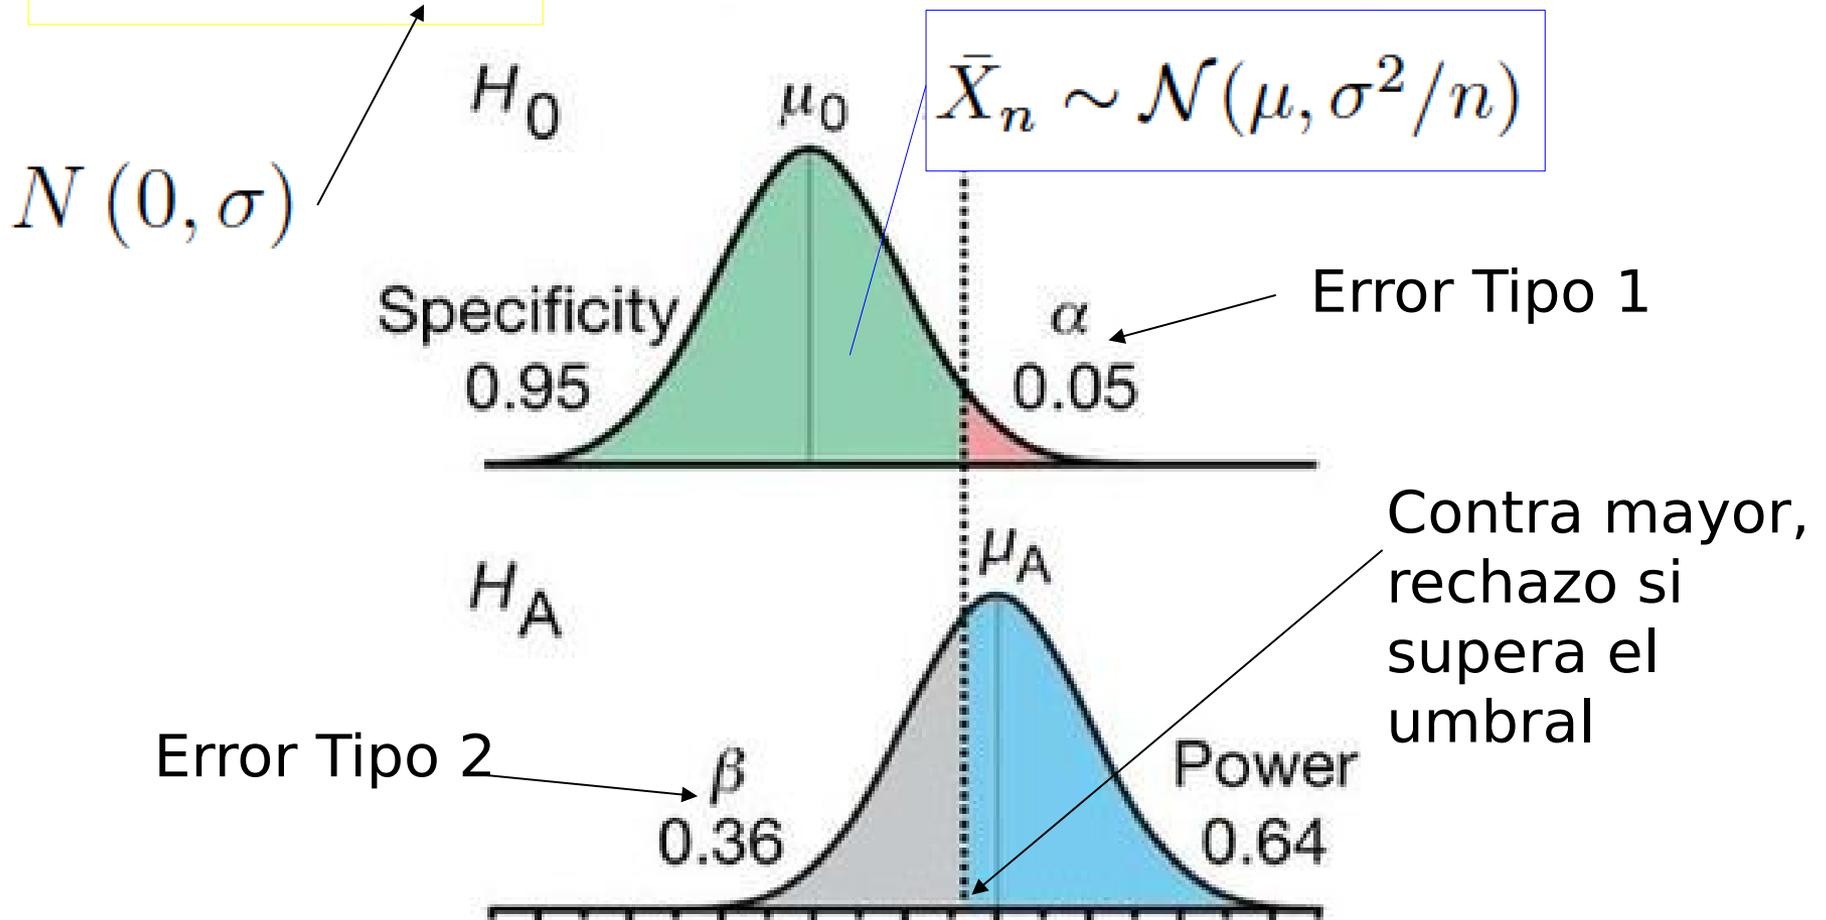
Potencia, Especificidad y Errores

Modelo

$$X = \mu + \epsilon$$

Estimador

$$\bar{X} = \bar{X}_n = \frac{\sum_{i=1}^n X_i}{n}$$

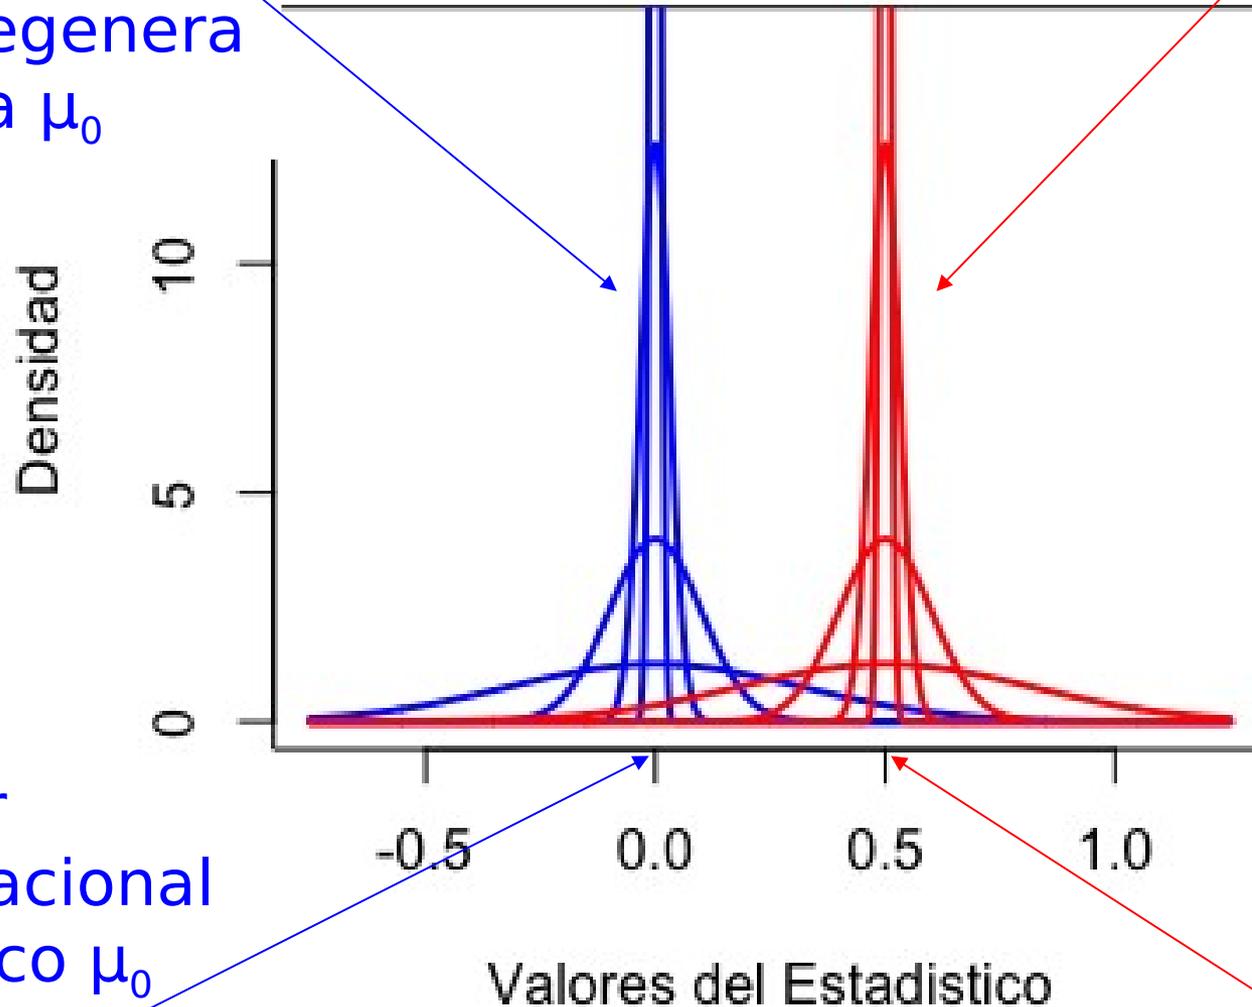


La Virtud y El Problema de la Consistencia

La distribución se degenera hacia μ_0

Convergencia del Estadístico

La distribución se degenera hacia μ_A



Valor poblacional teórico μ_0

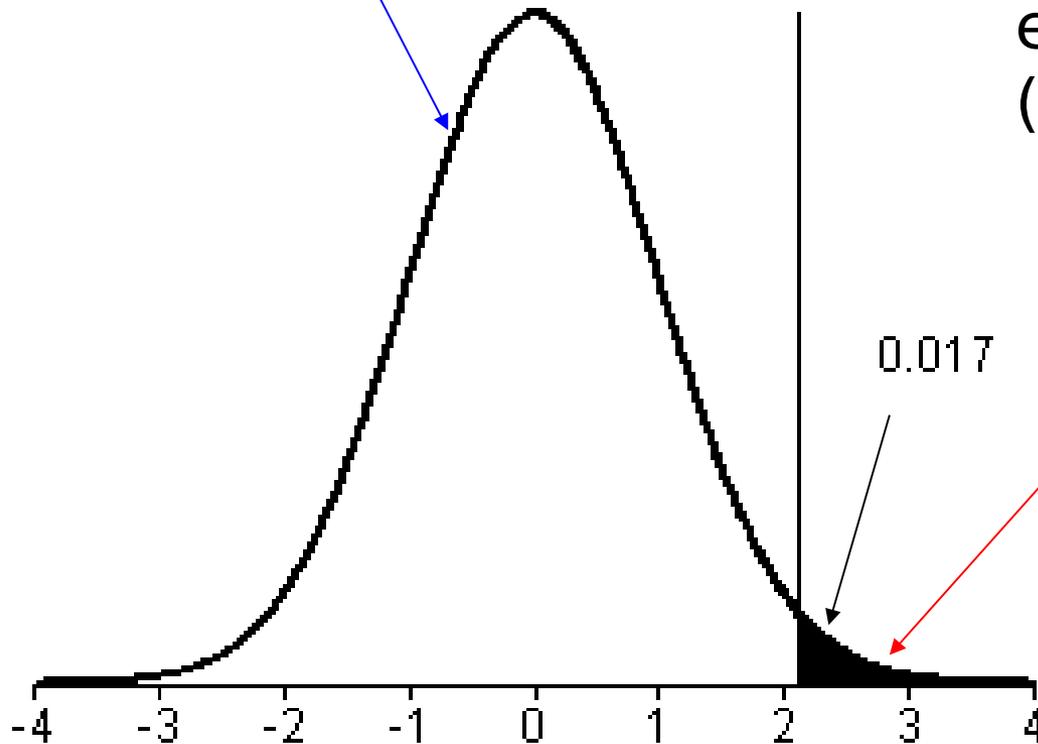
Valor poblacional real μ_A

El p-valor

- Concepto fundamental de la **Estadística** que cuantifica objetivamente la evidencia acerca de la validez de una hipótesis.
- Específicamente, mide en base a las observaciones el grado de “**compatibilidad**” de una hipótesis en términos del comportamiento distribucional de un estimador /estadístico.

Gráficamente

Distribución del Estadístico bajo la Hipótesis



Valor observado del estadístico (estimación)

Probabilidad de observar "algo tan o mas extremo" que lo observado basado en la muestra

0.017

Evidencia a favor H0

Evidencia contra H0



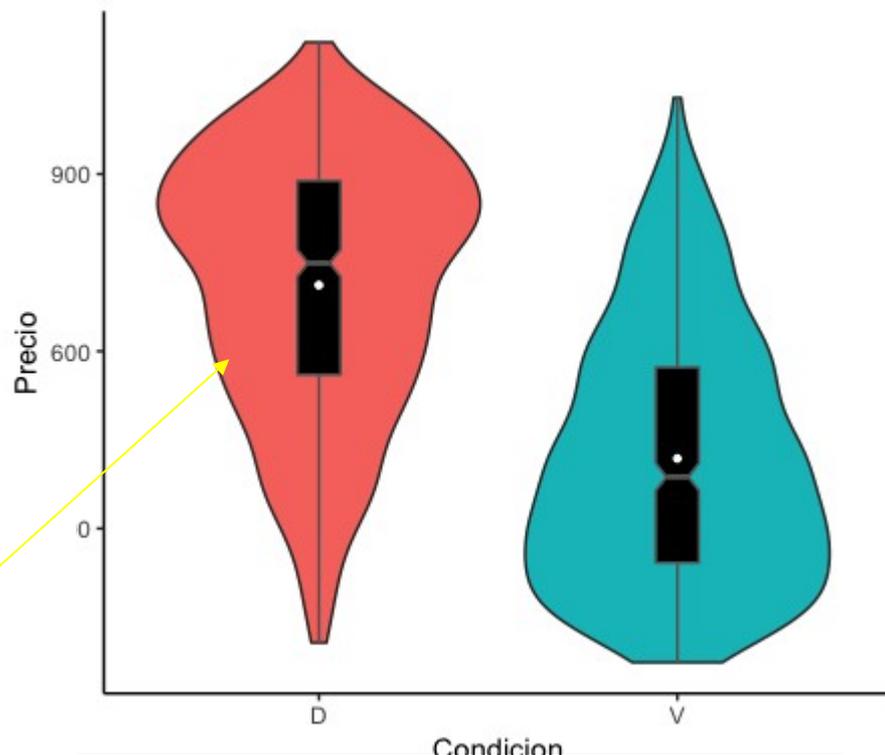
Para que sirve el Enfoque Estadístico ?

- **OVBIO**: Para cuantificar la incertidumbre de las estimaciones.
-
- **OVBIO**: Para completar la falta de información con “relaciones” matemáticas razonables/justificadas.
- **NO TAN OVBIO**: Para Modelar correctamente los fenómenos de interés, discriminando las relaciones “concomitantes” de aquellas que son “esenciales”

Los Agentes Inmobiliarios venden sus casas mas caras que las de sus clientes ?

pre	due
639.4115	V
218.7228	V
498.5153	D
307.9519	V
604.6274	D
452.0448	V

Precios en miles de u\$s



Claramente, venden SUS casas mas caras

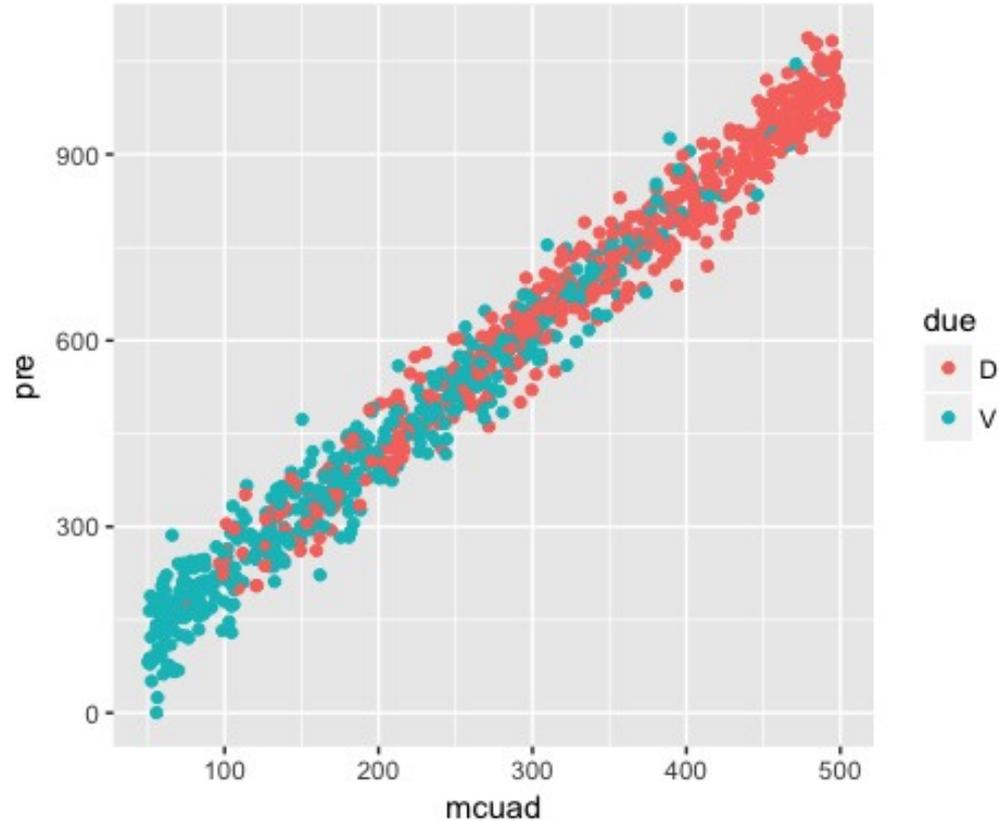
```
> table(due)
```

due	Co
D	503
V	497

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	710.391	9.633	73.75	<2e-16 ***
dueV	-284.165	13.555	-20.96	<2e-16 ***

Problema de Especificación

	pre	due	mcuad
1	421.2050	V	199.8858
2	335.3559	V	158.8452
3	852.9682	D	403.0014
4	601.3251	V	280.2027
5	674.4204	D	327.0117
6	710.6430	V	357.1478

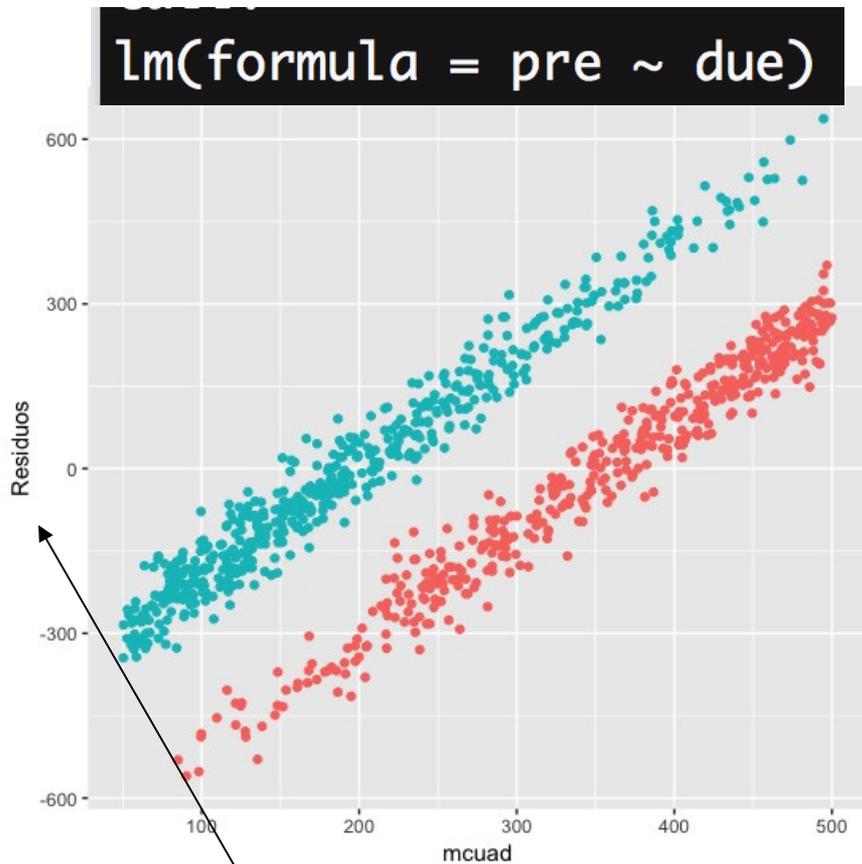


El factor (D/V) NO es significativo

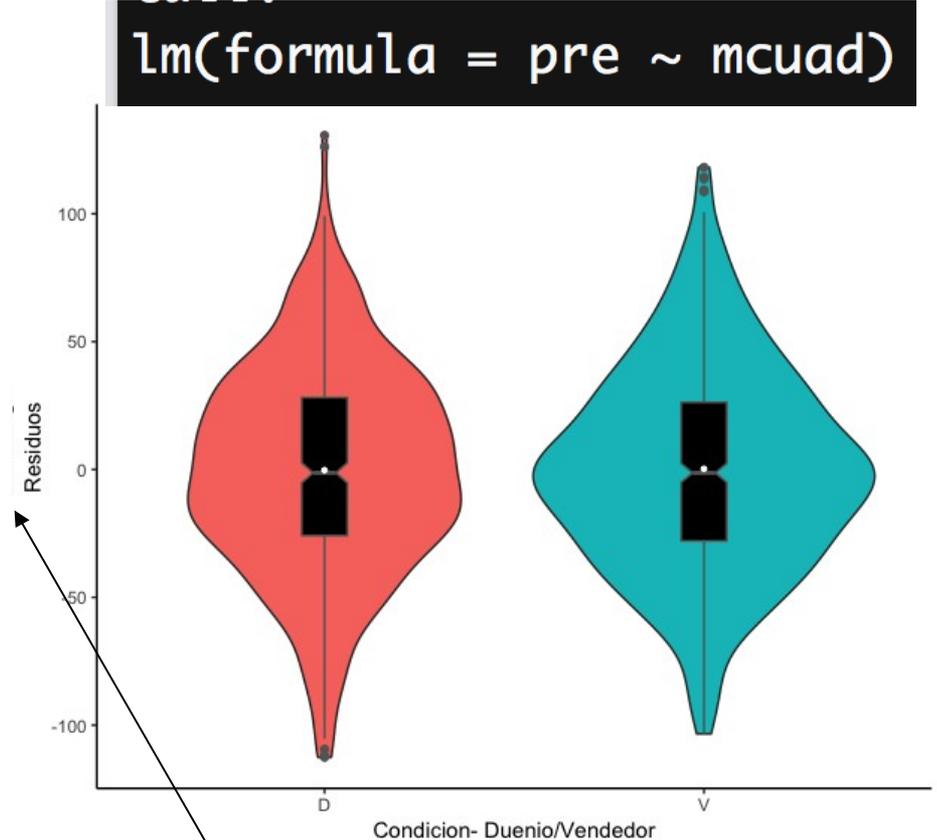
Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	23.49817	4.58556	5.124	3.58e-07	***
mcuad	1.99409	0.01221	163.352	< 2e-16	***
dueV	-1.84336	3.10025	-0.595	0.552	

Que Está Pasando ?



Despues del ajuste
queda mucha estructura
en los residuos



Nada por
explicar en los
residuos

Inferencia Bayesiana

Distribución Posterior de los Parámetros considerando : Prior + Datos

Likelihood de los Datos bajo el Modelo

Distribución Prior

$$p(\Theta|y) = \frac{p(y|\Theta)p(\Theta)}{p(y)}$$

Parámetros aleatorios

Observaciones

Distribución Marginal de las Observaciones

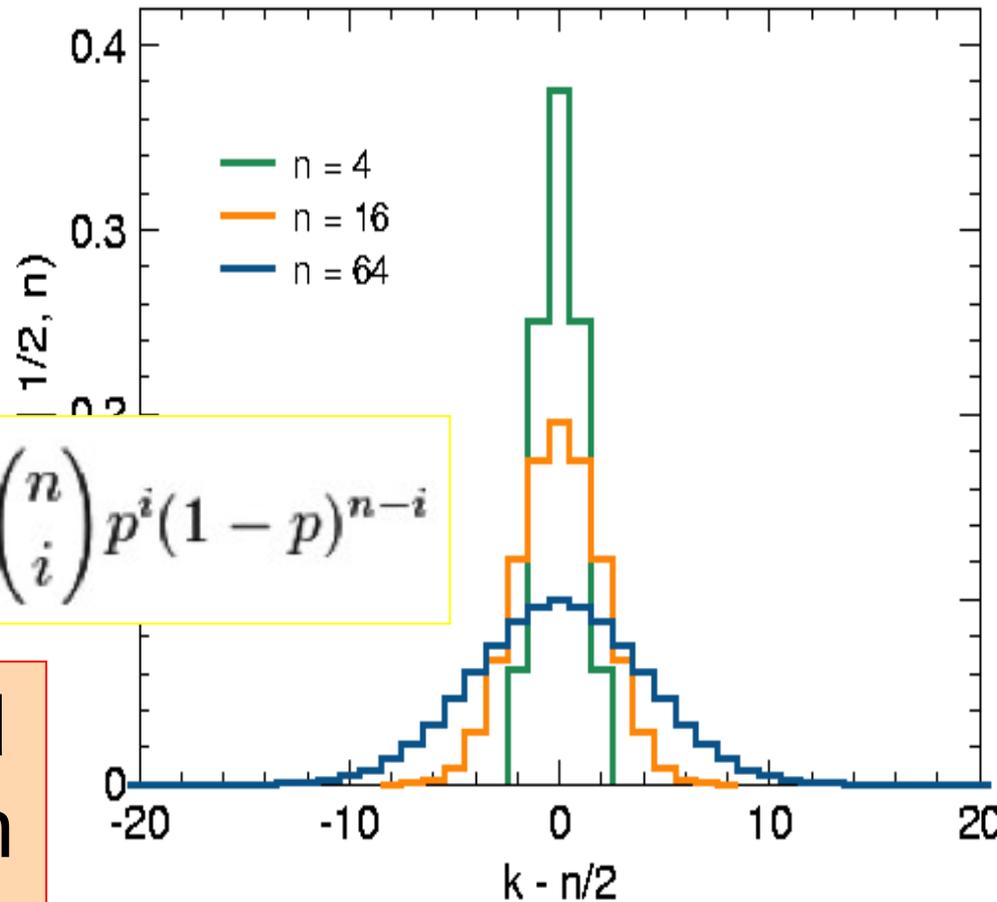
$$p(\Theta|y) \propto p(y|\Theta)p(\Theta)$$

$$p(y) = \int p(y|\Theta)p(\Theta)d\Theta$$

Mecanismo de Actualización de la Distr. de los Parámetros

Distribución Binomial

notation:	$B(n, p)$
parameters:	$n \in \mathbf{N}_0$ — number of trials $p \in [0, 1]$ — success probability in each trial
support:	$k \in \{0, \dots, n\}$
pmf:	$\binom{n}{k} p^k (1 - p)^{n-k}$
cdf:	$I_{1-p}(n - k, 1 + k)$
mean:	np

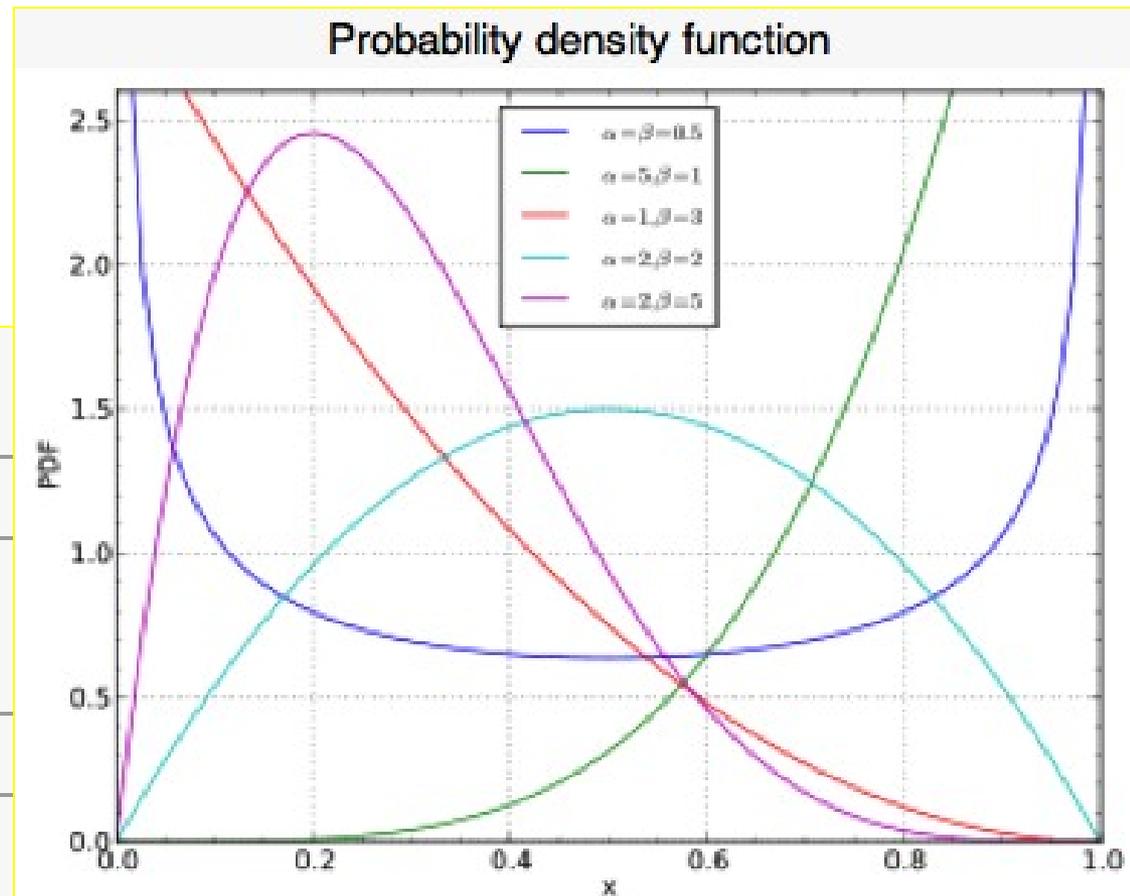


$$F(x; n, p) = \Pr(X \leq x) = \sum_{i=0}^{\lfloor x \rfloor} \binom{n}{i} p^i (1 - p)^{n-i}$$

Cual es la probabilidad de observar k éxitos en n intentos ?

Distribución Beta

parameters:	$\alpha > 0$ shape (real) $\beta > 0$ shape (real)
support:	$x \in (0; 1)$
pdf:	$\frac{x^{\alpha-1}(1-x)^{\beta-1}}{B(\alpha, \beta)}$
cdf:	$I_x(\alpha, \beta)$
mean:	$\frac{\alpha}{\alpha + \beta}$
median:	$I_{0.5}^{-1}(\alpha, \beta)$ no closed form
mode:	$\frac{\alpha - 1}{\alpha + \beta - 2}$ for $\alpha > 1, \beta > 1$
variance:	$\frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$



Cual es la probabilidad de una probabilidad ?

Ejemplo Sencillo: Binomial y Beta

Beta(α, β)

$$f(x|p) = \binom{n}{x} p^x (1-p)^{n-x}$$

$$\pi(p) = \frac{1}{B(\alpha, \beta)} p^{\alpha-1} (1-p)^{\beta-1}$$



Evento
dicotómico

$\left\{ \begin{array}{l} 1 \\ 0 \end{array} \right.$

p
 $1-p$

$$f(p|x) = \frac{f(x|p)}{f_X(x)} \pi(p)$$

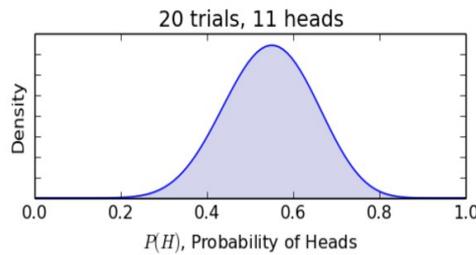
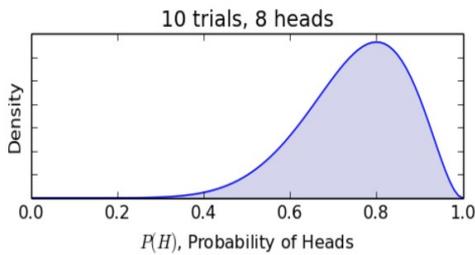
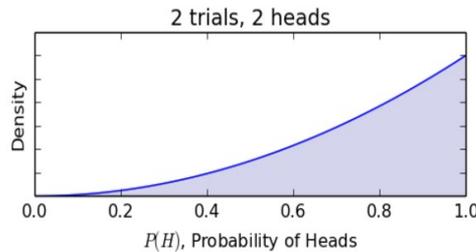
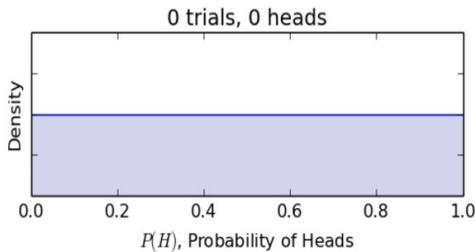
$$\propto p^x (1-p)^{n-x} p^{\alpha-1} (1-p)^{\beta-1}$$

$$\propto p^{x+\alpha-1} (1-p)^{n-x+\beta-1}$$

Beta($x + \alpha, n - x + \beta$)

de
éxitos

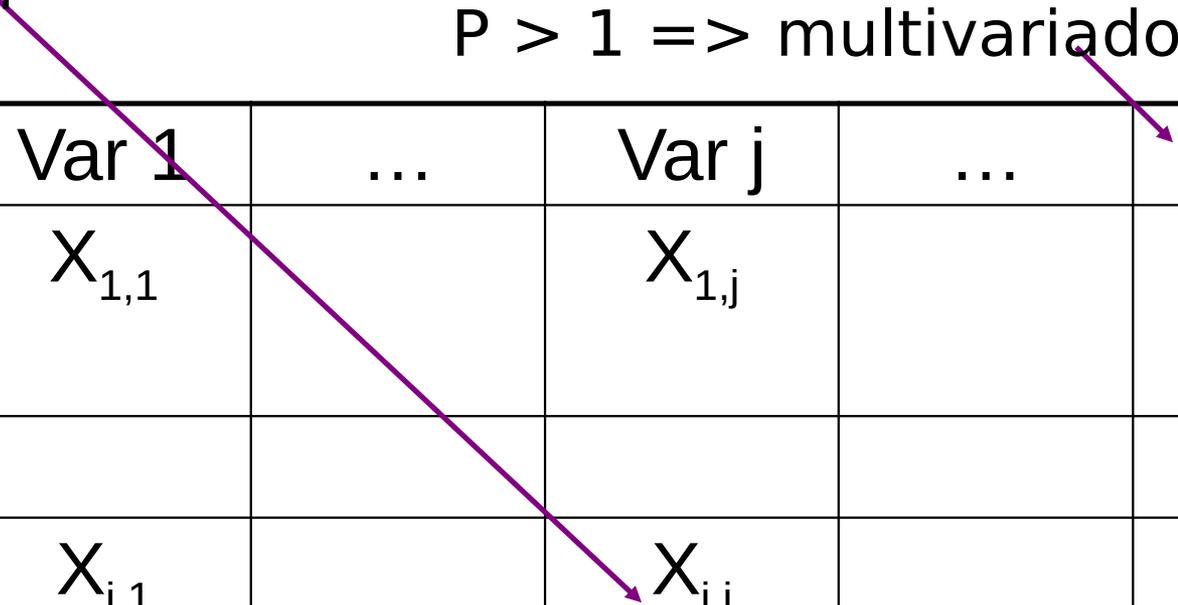
de
casos



La información

Medición

$P > 1 \Rightarrow$ multivariado



	Var 1	...	Var j	...	Var p
Ind 1	$X_{1,1}$		$X_{1,j}$		$X_{1,p}$
...					
Ind i	$X_{i,1}$		$X_{i,j}$		$X_{i,p}$
...					
Ind n	$X_{n,1}$		$X_{n,j}$		$X_{n,p}$

Las variables (columnas)

- Características o atributos cambiantes de los individuos que interesa analizar.

Los individuos (filas)

- Elementos sobre los cuales se miden los atributos.

Estadísticos básicos

Matriz de varianzas y covarianza

	X_1	...	X_j	...	X_p
X_1	$\text{Var}(X_1)$...	$\text{Cov}(X_1, X_j)$...	$\text{Cov}(X_1, X_p)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
X_j	$\text{Cov}(X_j, X_1)$...	$\text{Var}(X_j)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
X_p	$\text{Cov}(X_p, X_1)$	$\text{Var}(X_p)$

Varianza

Covarianza

	Var 1	...	Var j	...	Var p
Ind 1	$X_{1,1}$		$X_{1,j}$		$X_{1,p}$
...					
Ind i	$X_{i,1}$		$X_{i,j}$		$X_{i,p}$
...					
Ind n	$X_{n,1}$		$X_{n,j}$		$X_{n,p}$

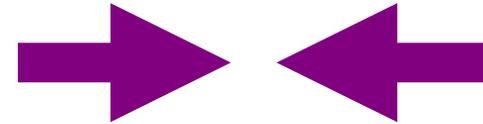
Vector de medias

	Var 1	...	Var j	...	Var p
Medias	\bar{X}_1		\bar{X}_j		\bar{X}_p

Resumen de Información

Técnicas Factoriales

Componentes Principales - Análisis Factorial
- Análisis de Correspondencia



Técnicas de Segmentación

Clusterización jerárquica
- Métodos de Partición (K-medias)



	Var 1	...	Var j	...	Var p
Ind 1	$X_{1,1}$		$X_{1,j}$		$X_{1,p}$
...					
Ind i	$X_{i,1}$		$X_{i,j}$		$X_{i,p}$
...					
Ind n	$X_{n,j}$		$X_{n,j}$		$X_{n,p}$

Analisis Factorial



No observable

Factores o variables
latentes

Observable

Variables o atributos



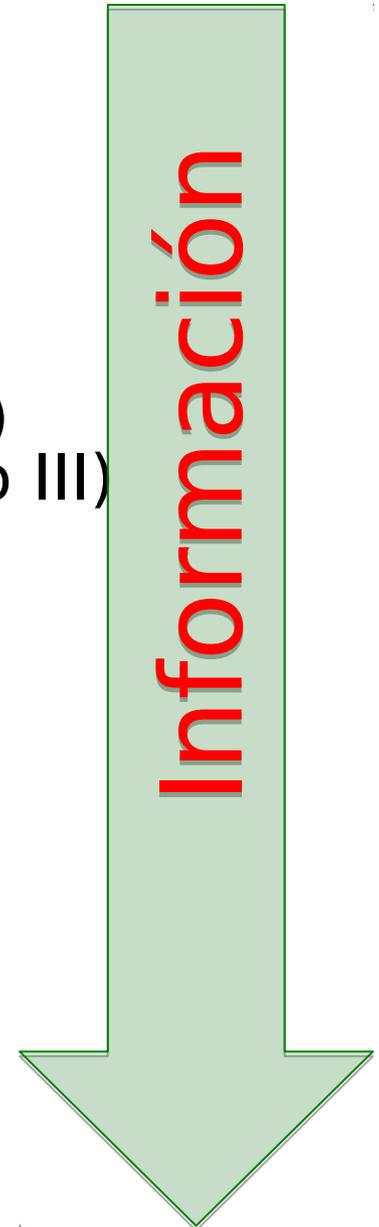
Estadística Descriptiva y Análisis Exploratorio de Datos

Objetivos:

- Conocer los datos
- Descubrir patrones
- Verificar la existencia de patrones
- Entender los patrones
- Resumir información
- Hallar asociaciones de variables
- Detectar anomalías

Las variables

- Categóricas o cualitativas
 - Color de pelo
 - Tipo de auto
 - Sexo
- Ordinales
 - Calificación de examen (A, B, C, D y E)
 - Etapa de una enfermedad (etapa I, II o III)
- Discretas
 - Cantidad de hijos
- Continuas
 - Salario
 - Peso
 - Edad
 - Tiempo



Descripciones multivariadas

- Tablas cruzadas
- Gráficos de dispersión (scatterplot)
- Hexbin
- Estimación de densidad por núcleo
- Gráficos de mosaico (mosaic plot)
- Gráficos de estrella (star plots)
- Caras

Tablas cruzadas (cross tabulation) o de Contingencia

Observaciones
conjuntas

Tuvo en cuenta el CONSUMO

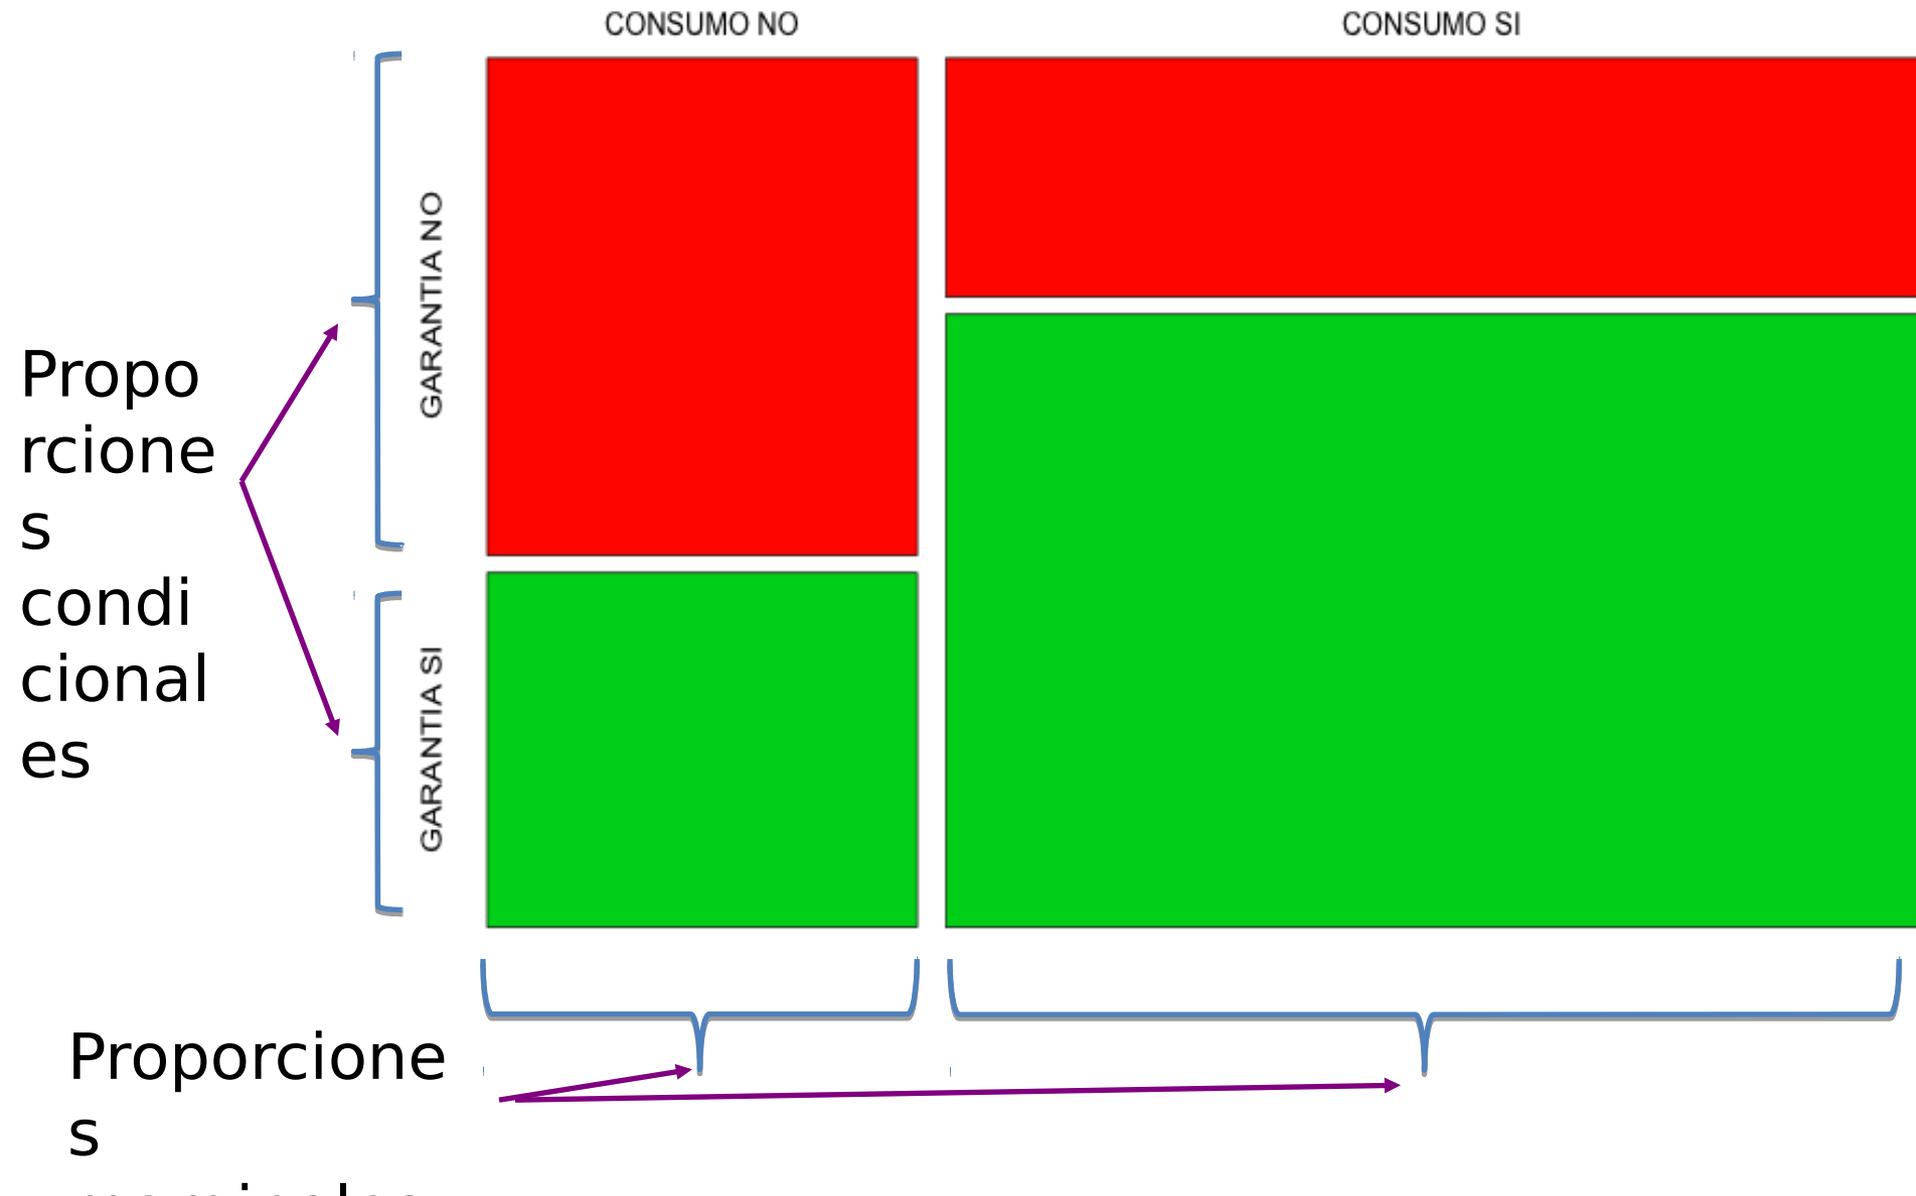
Tuvo
en cuenta
la GARANTIA

	NO	SI	Total
NO	258	280	538
SI	184	719	903
Total	442	999	1441

Totales
marginales

Total de
casos

Gráficos de mosaicos



Sobrevivientes del Titanic

, , Age = Child, Survived = No

Class	Sex	
	Male	Female
1st	0	0
2nd	0	0
3rd	35	17
Crew	0	0

, , Age = Child, Survived = Yes

Class	Sex	
	Male	Female
1st	5	1
2nd	11	13
3rd	13	14
Crew	0	0

, , Age = Adult, Survived = No

Class	Sex	
	Male	Female
1st	118	4
2nd	154	13
3rd	387	89
Crew	670	3

Total de
casos
= 2201

, , Age = Adult, Survived = Yes

Class	Sex	
	Male	Female
1st	57	140
2nd	14	80
3rd	75	76
Crew	192	20

Mosaico del Titanic

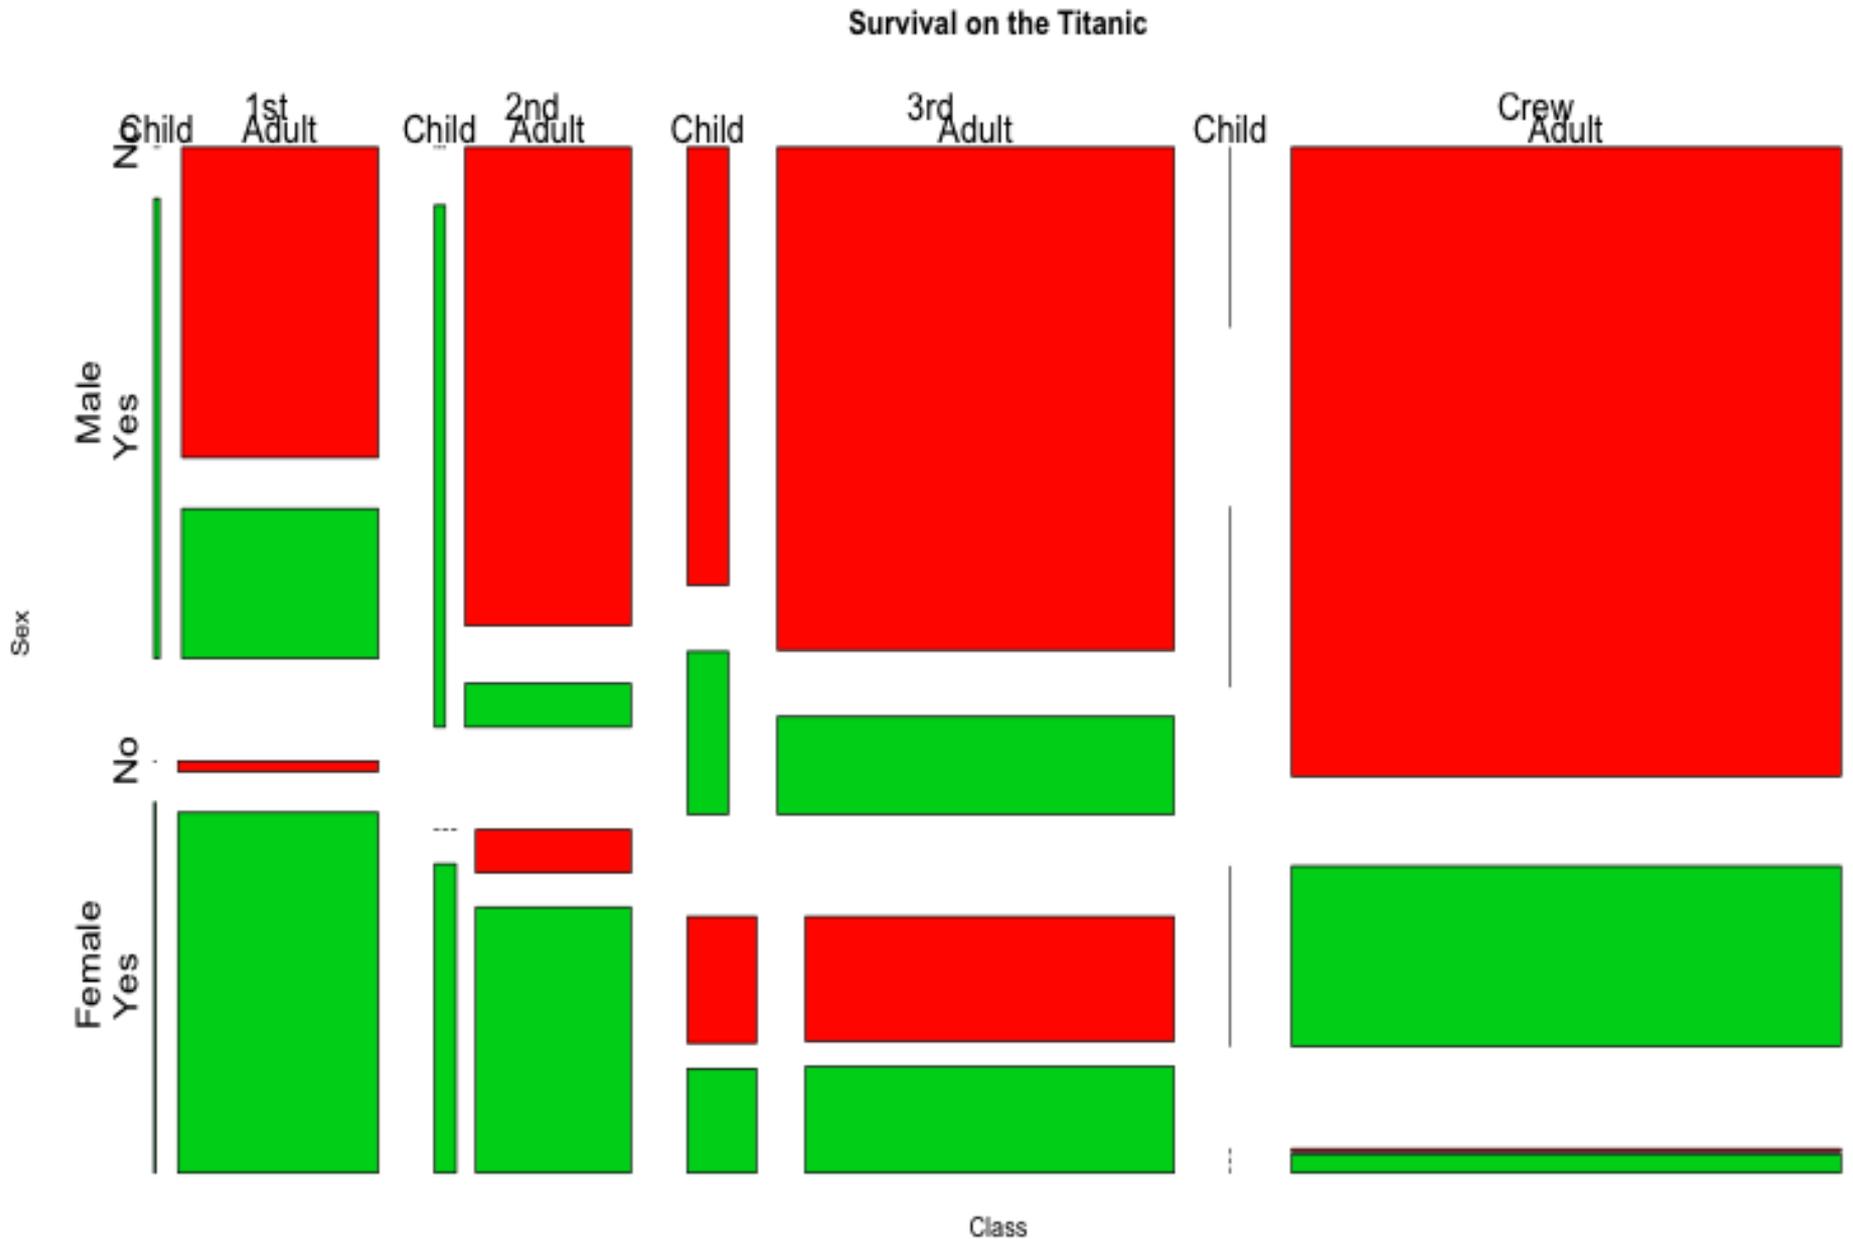


Gráfico de dispersión (X,Y)

Dos variables

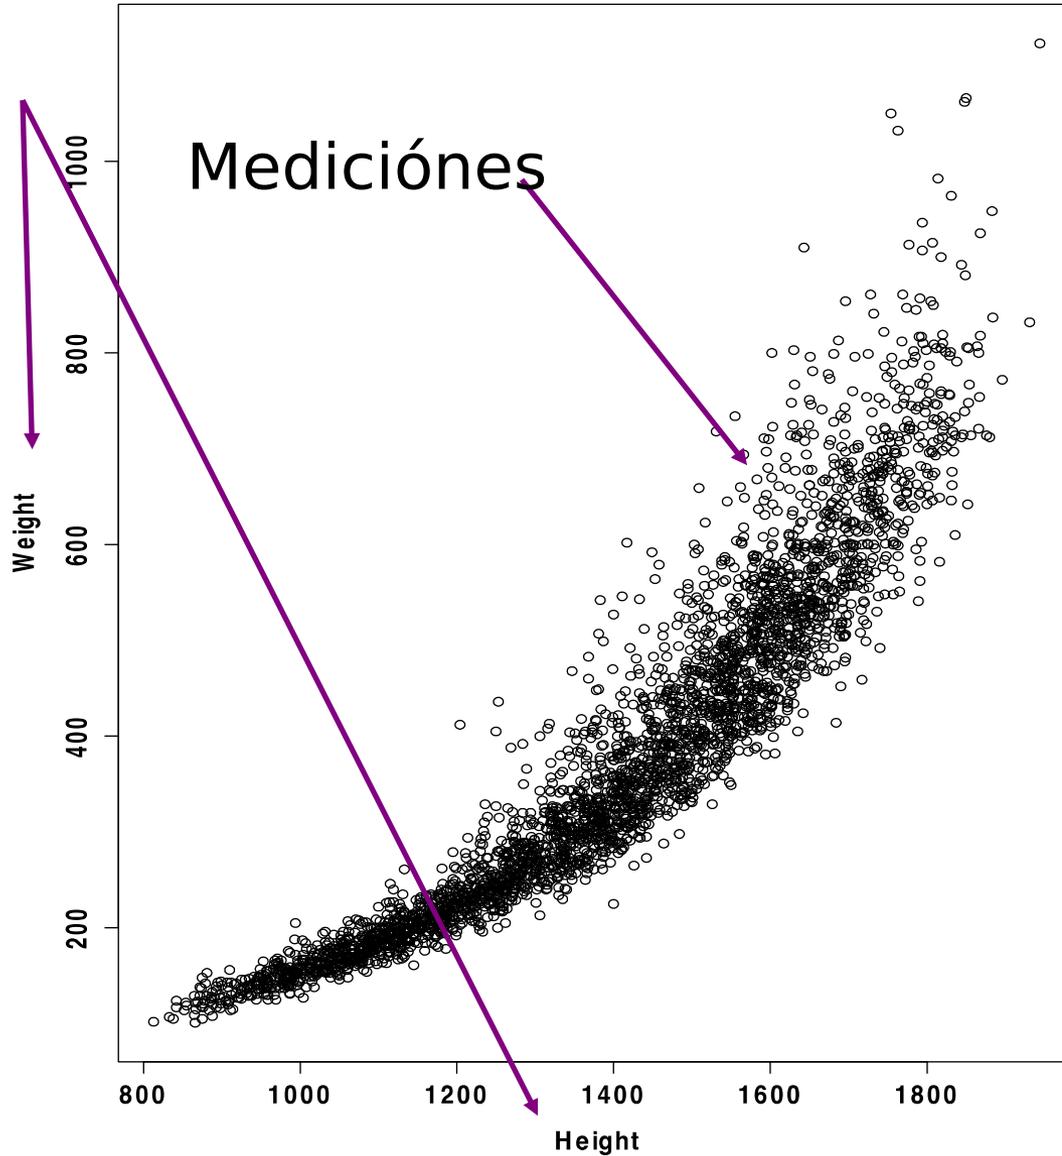


Grafico Contour

Contour plot for bivariate intensity

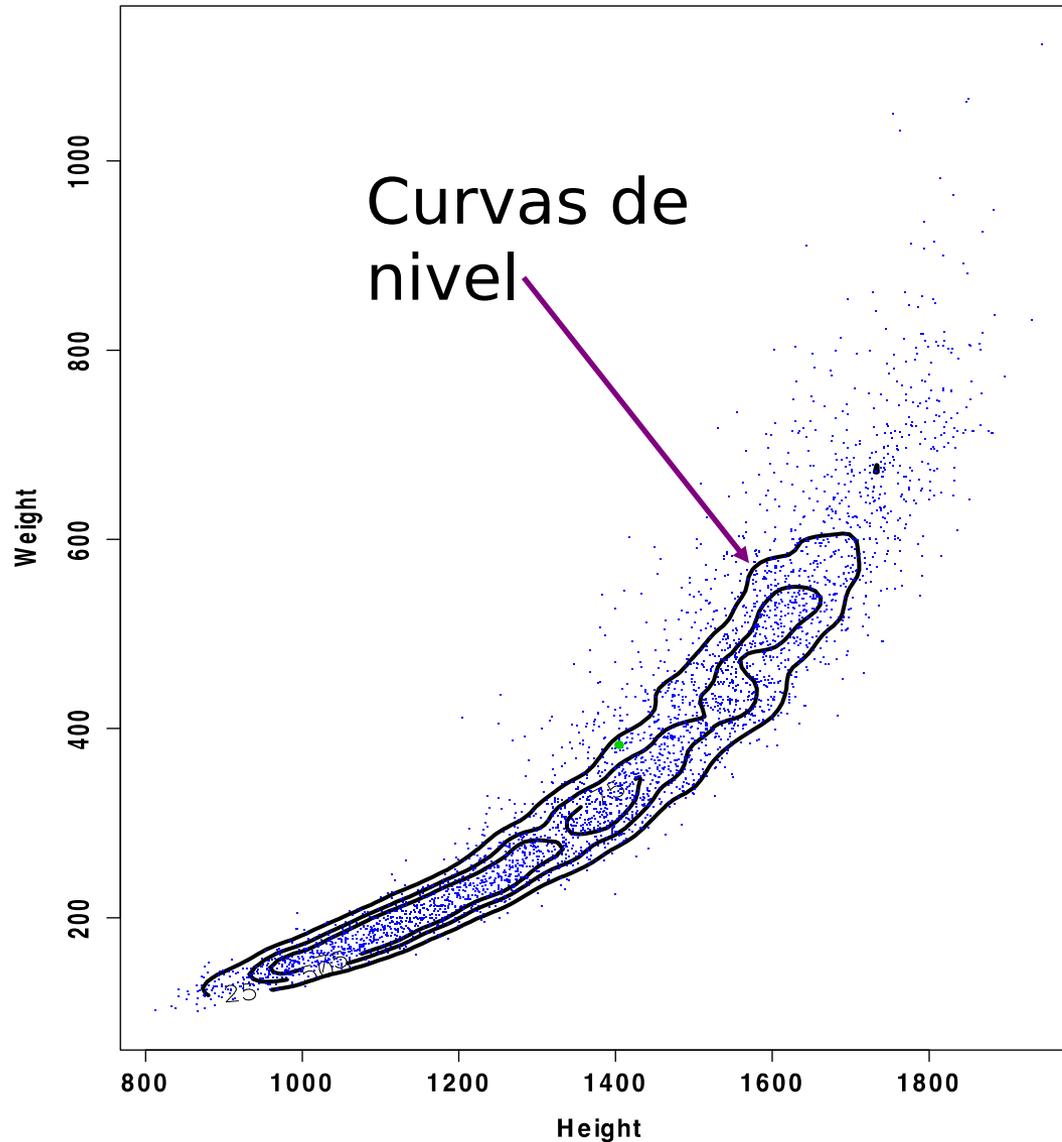
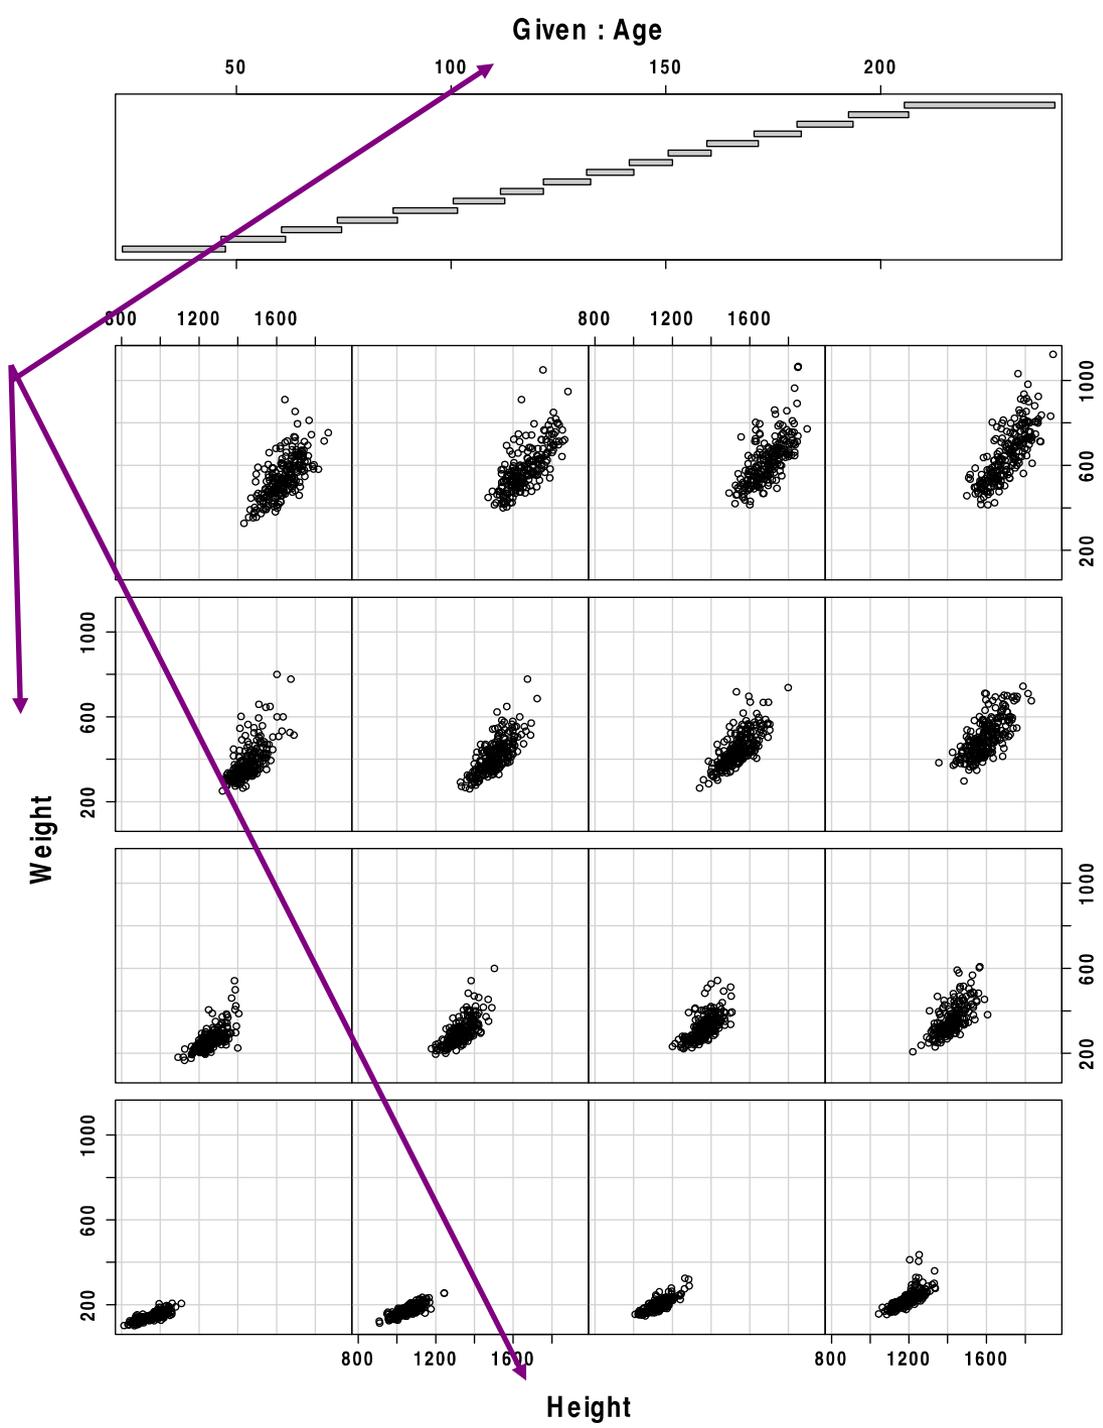
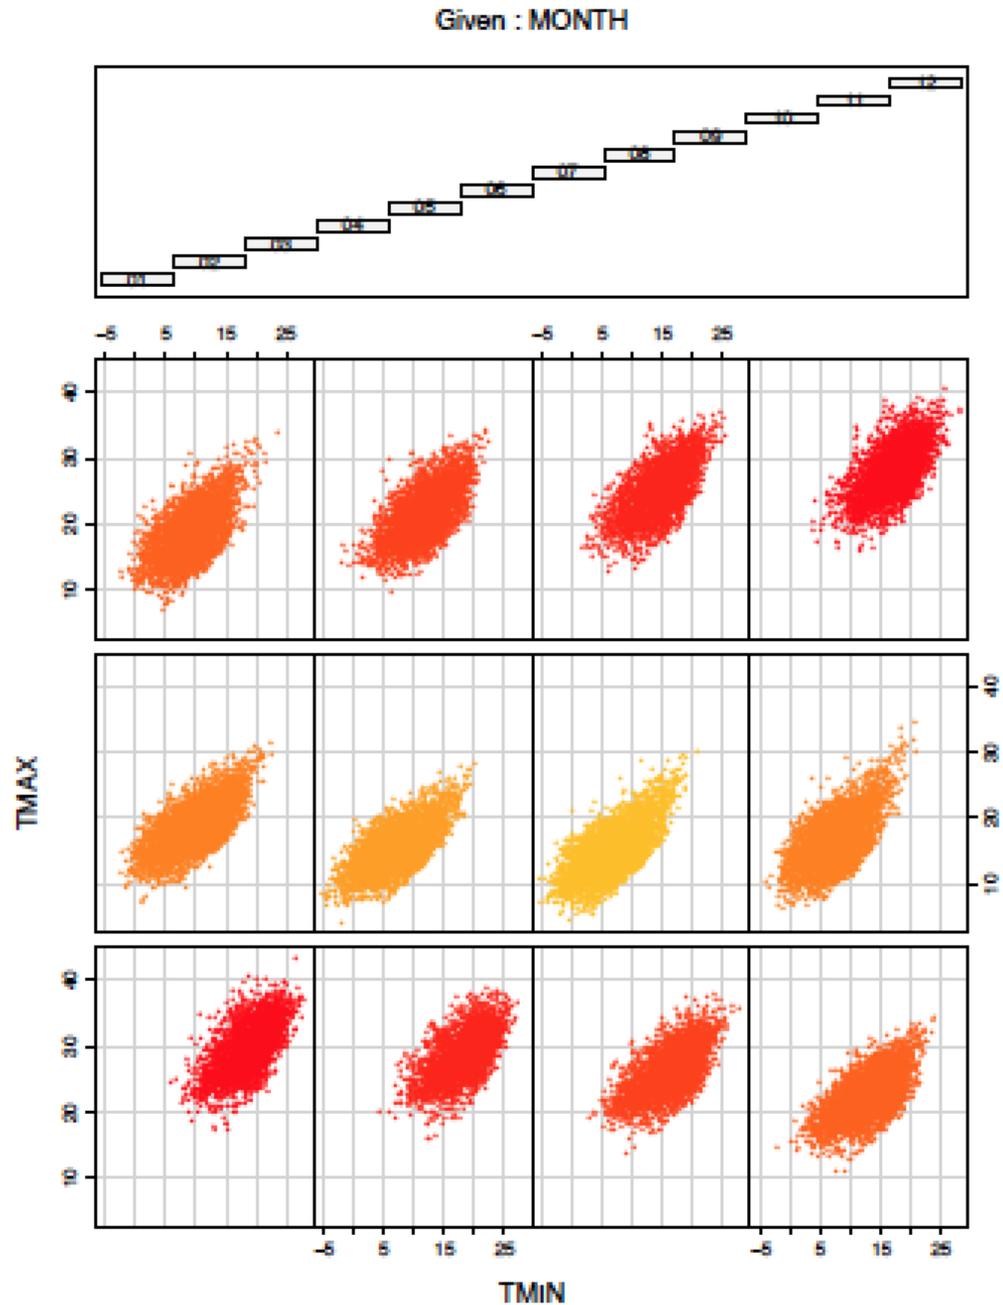


Gráfico "CoPlot"

Tres
variables



CoPlot De Temperaturas



Muchos
puntos
superpuestos

Gráfico de dispersión

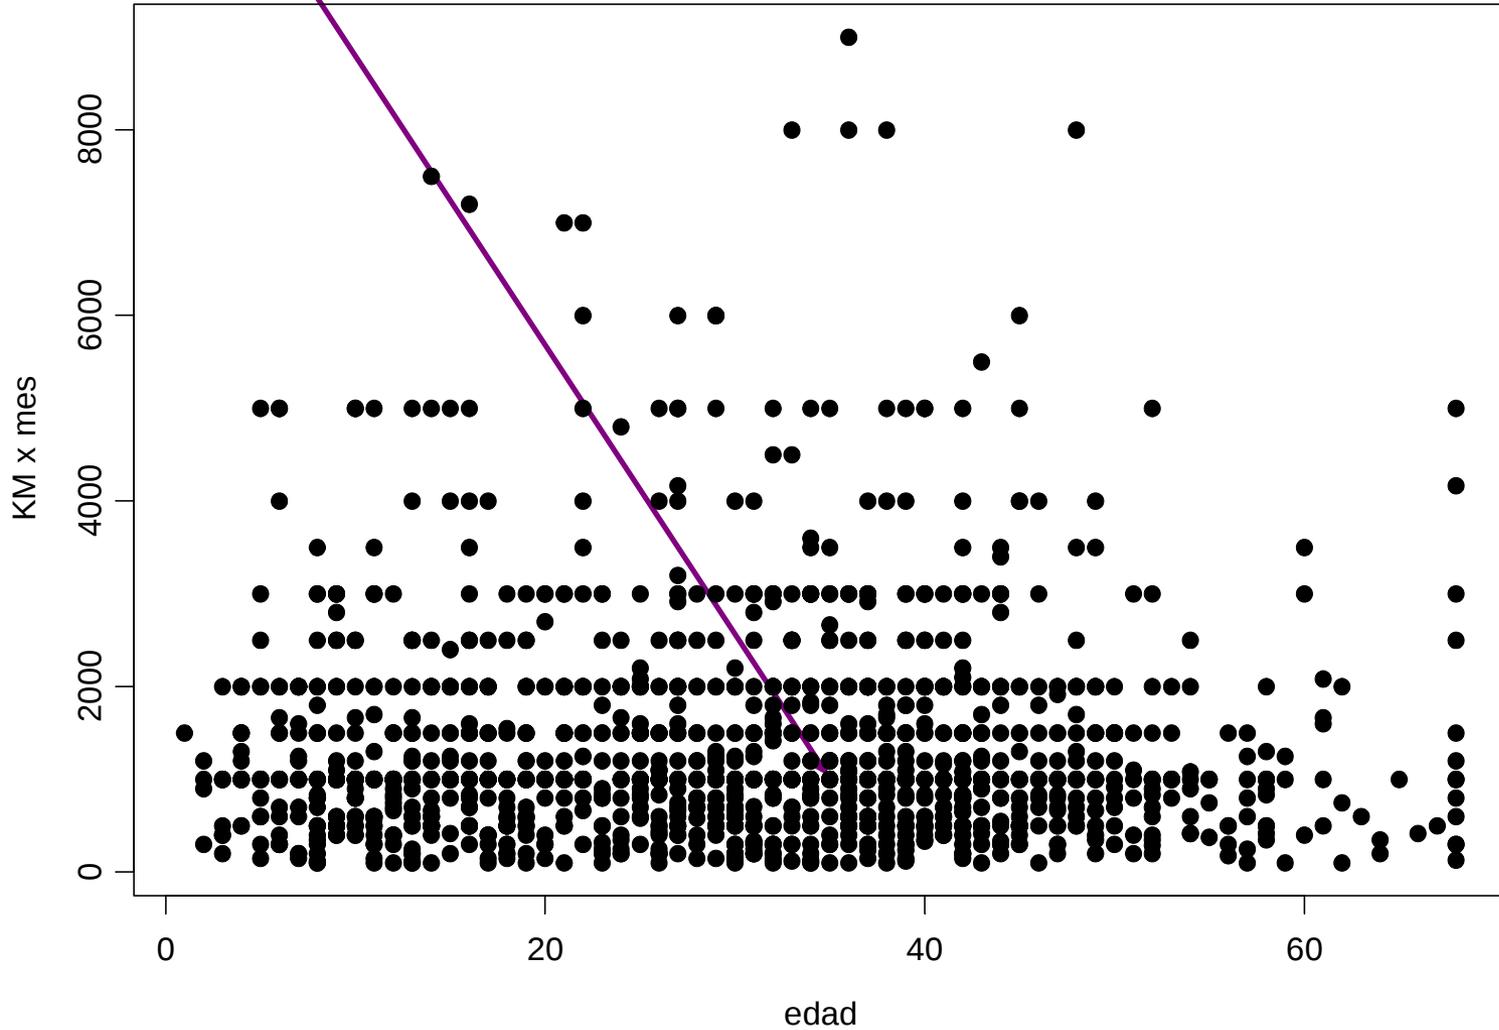


Gráfico hexbin

Mayor
concentración

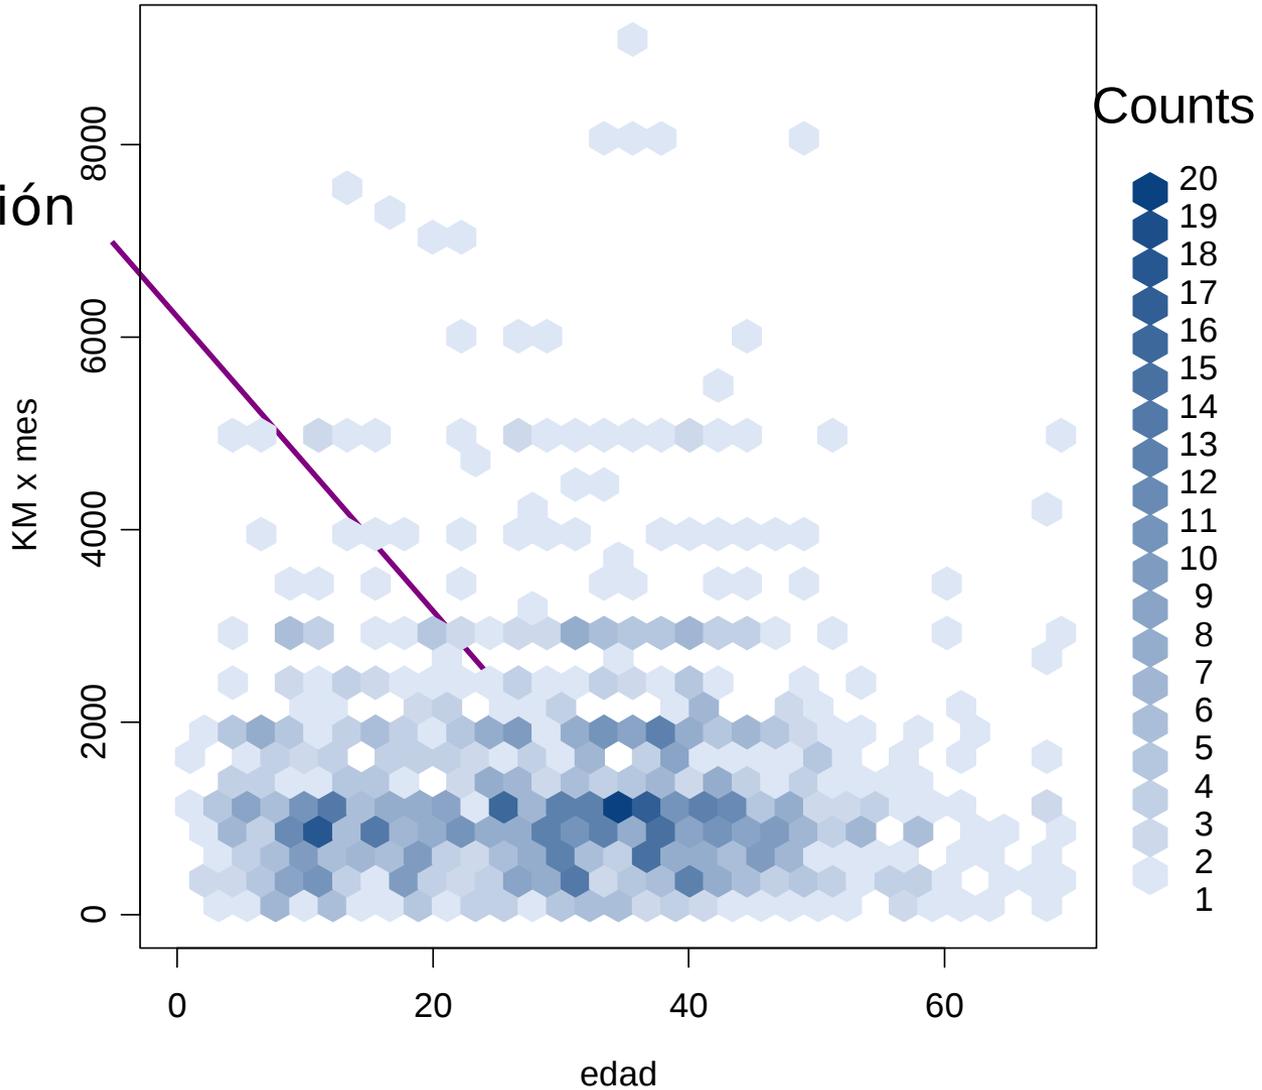


Gráfico hexbin

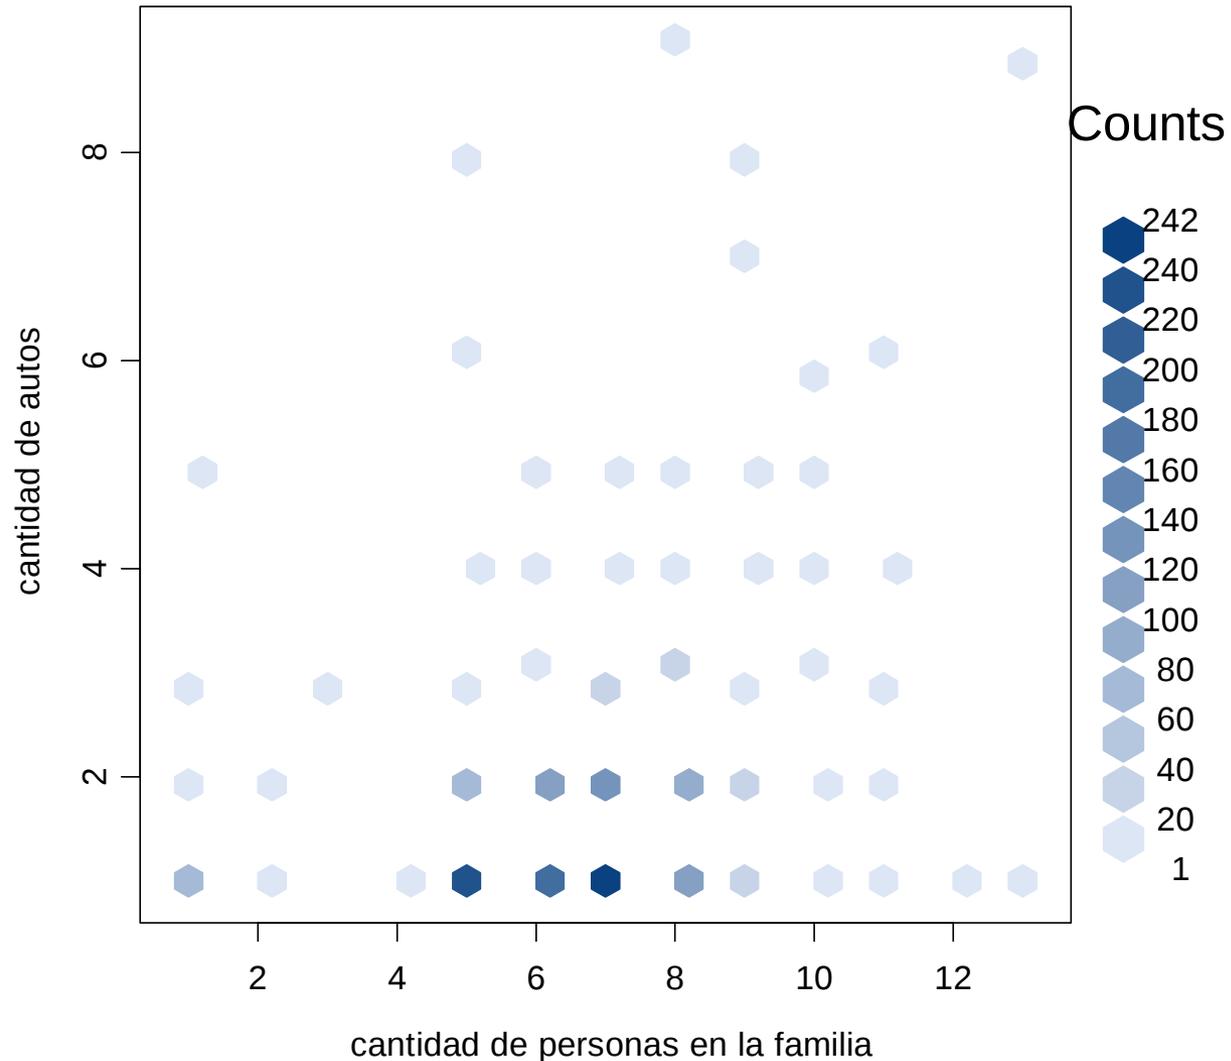
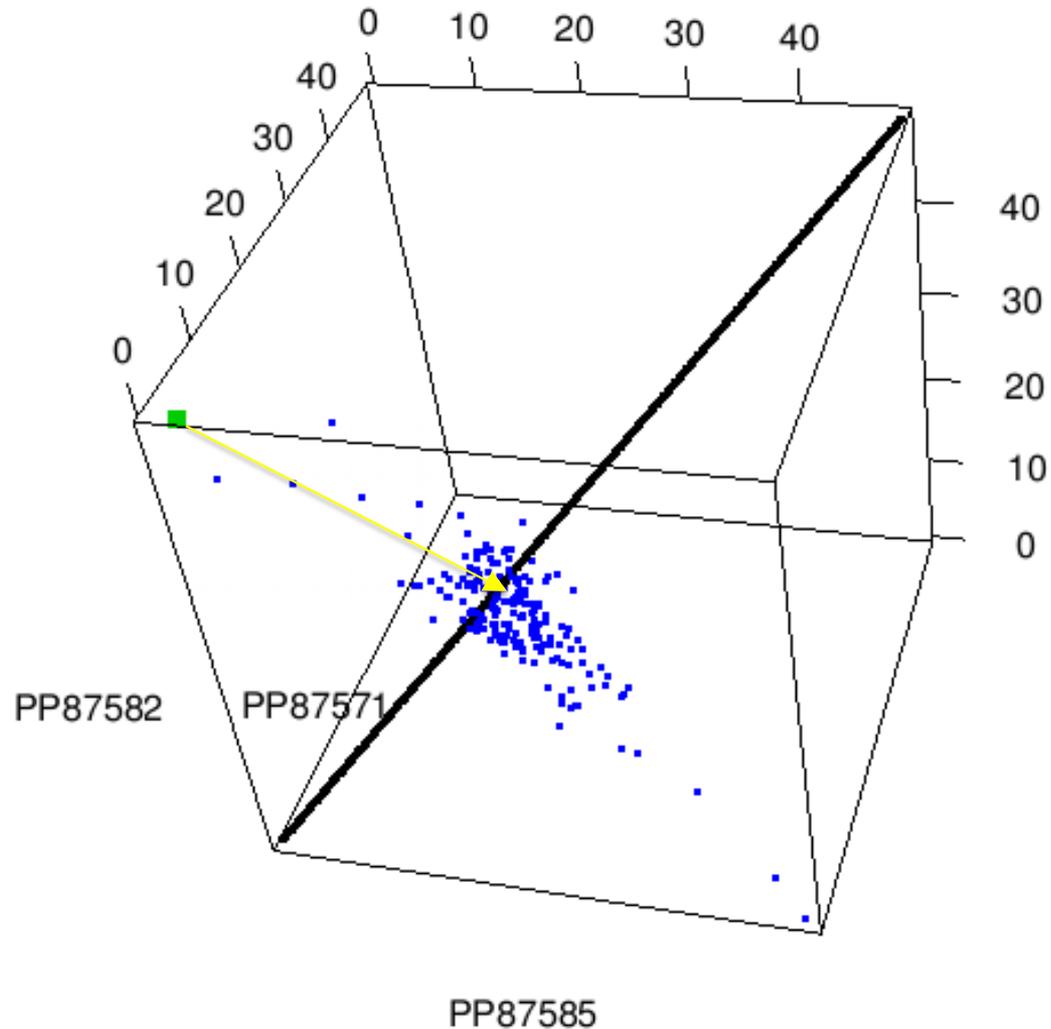
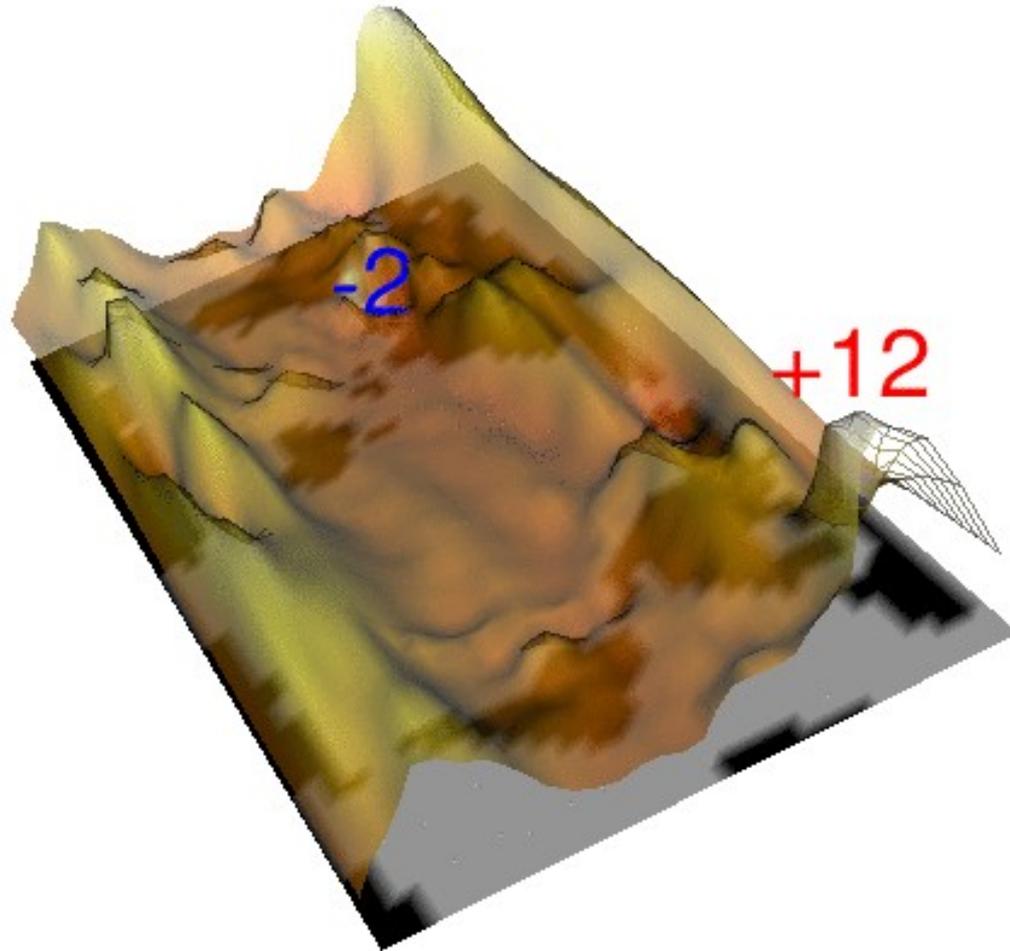


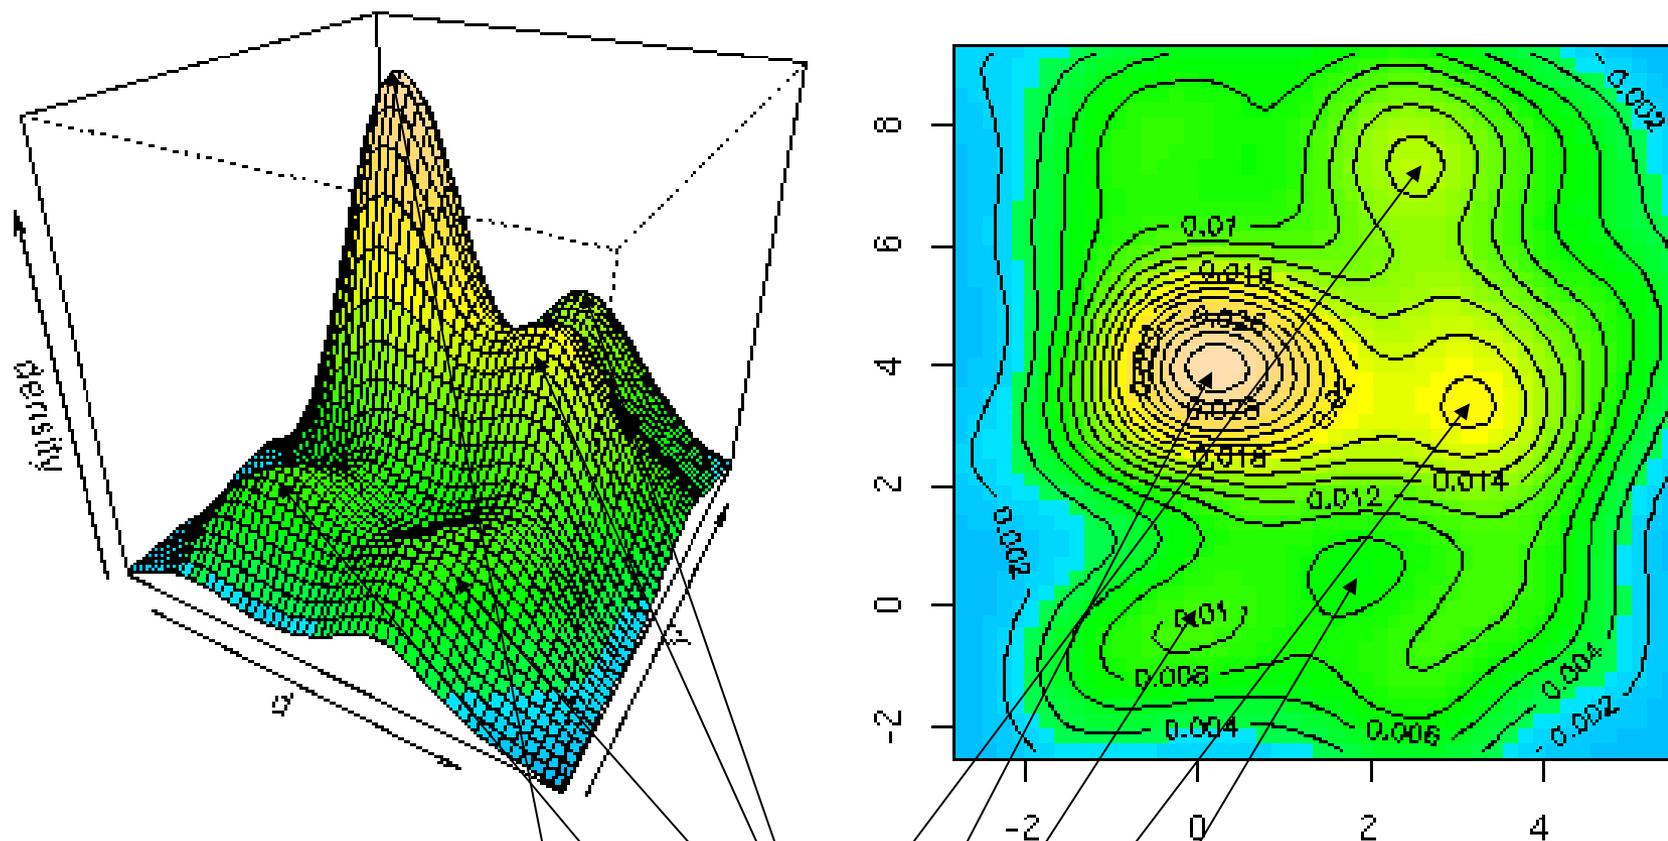
Gráfico de dispersión (X,Y,Z)



Campo medio de diferencias entre R4 y control para el periodo 2046-2050



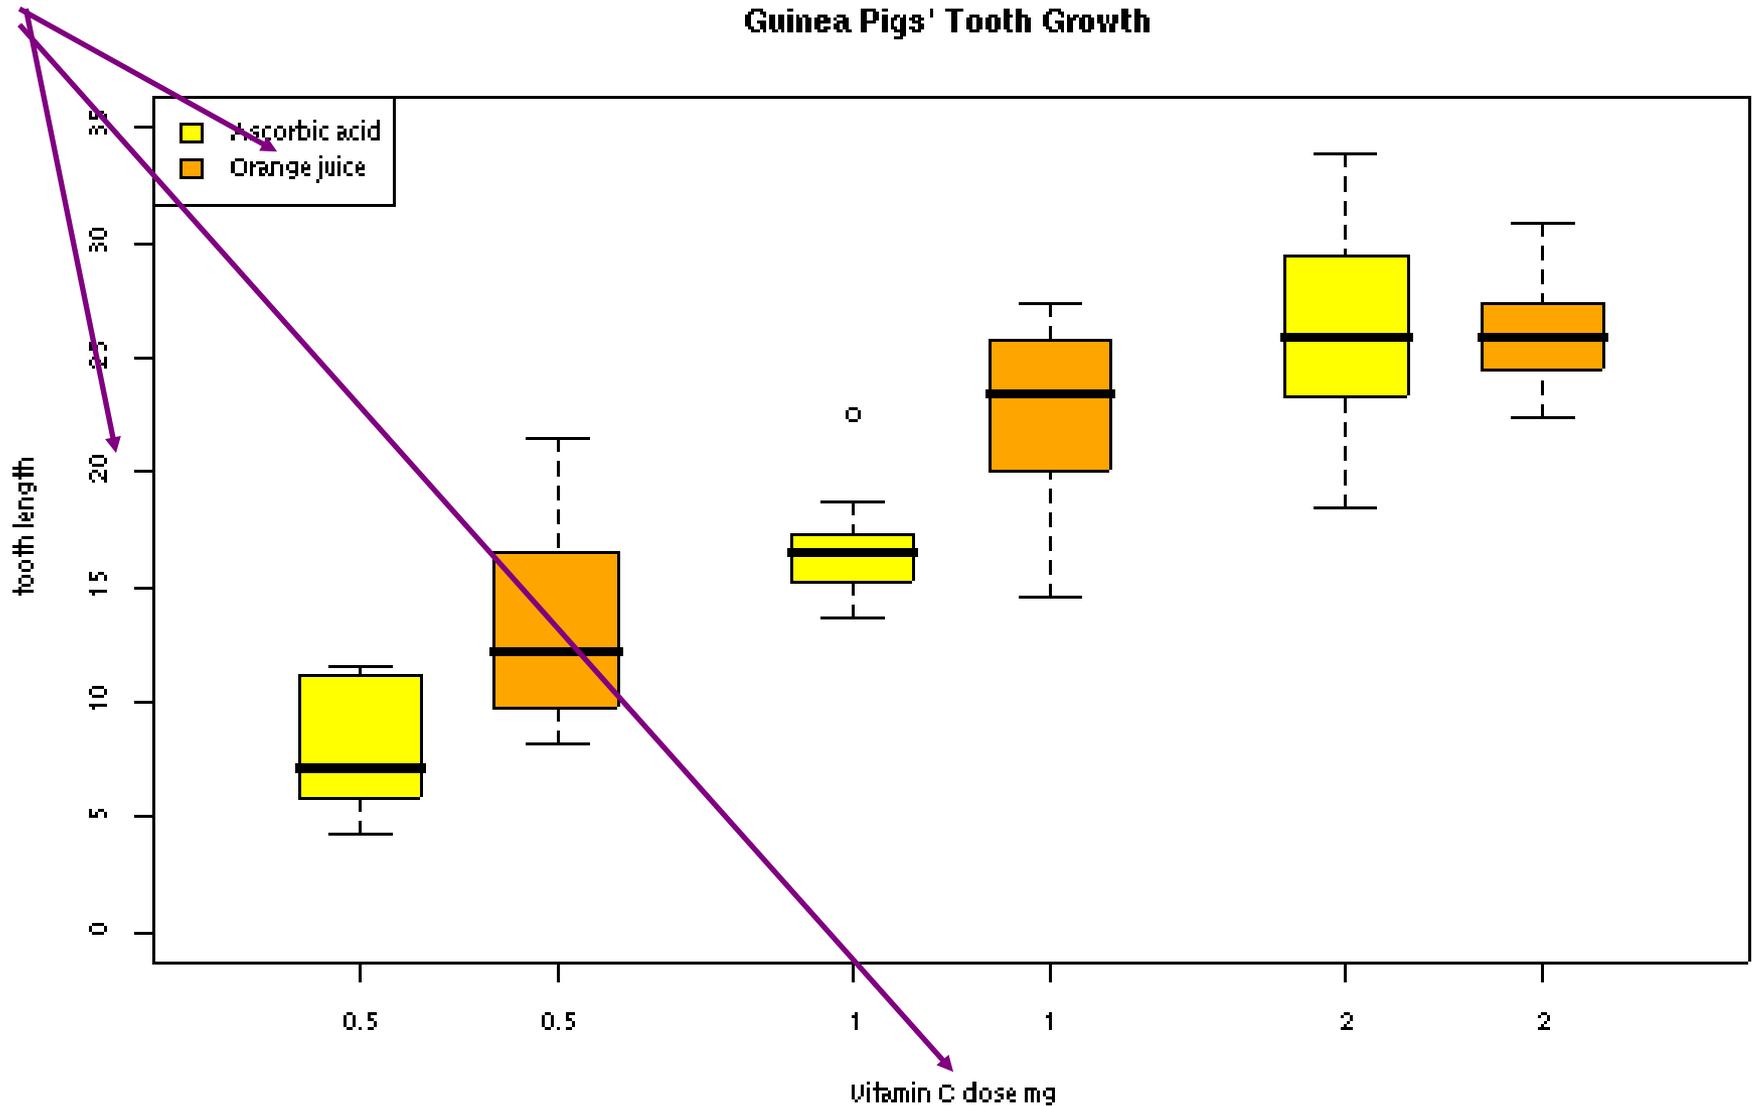
Estimación de densidad por núcleos (Bivariado)



Posibles clusters

Tres
variables

Múltiples Boxplots

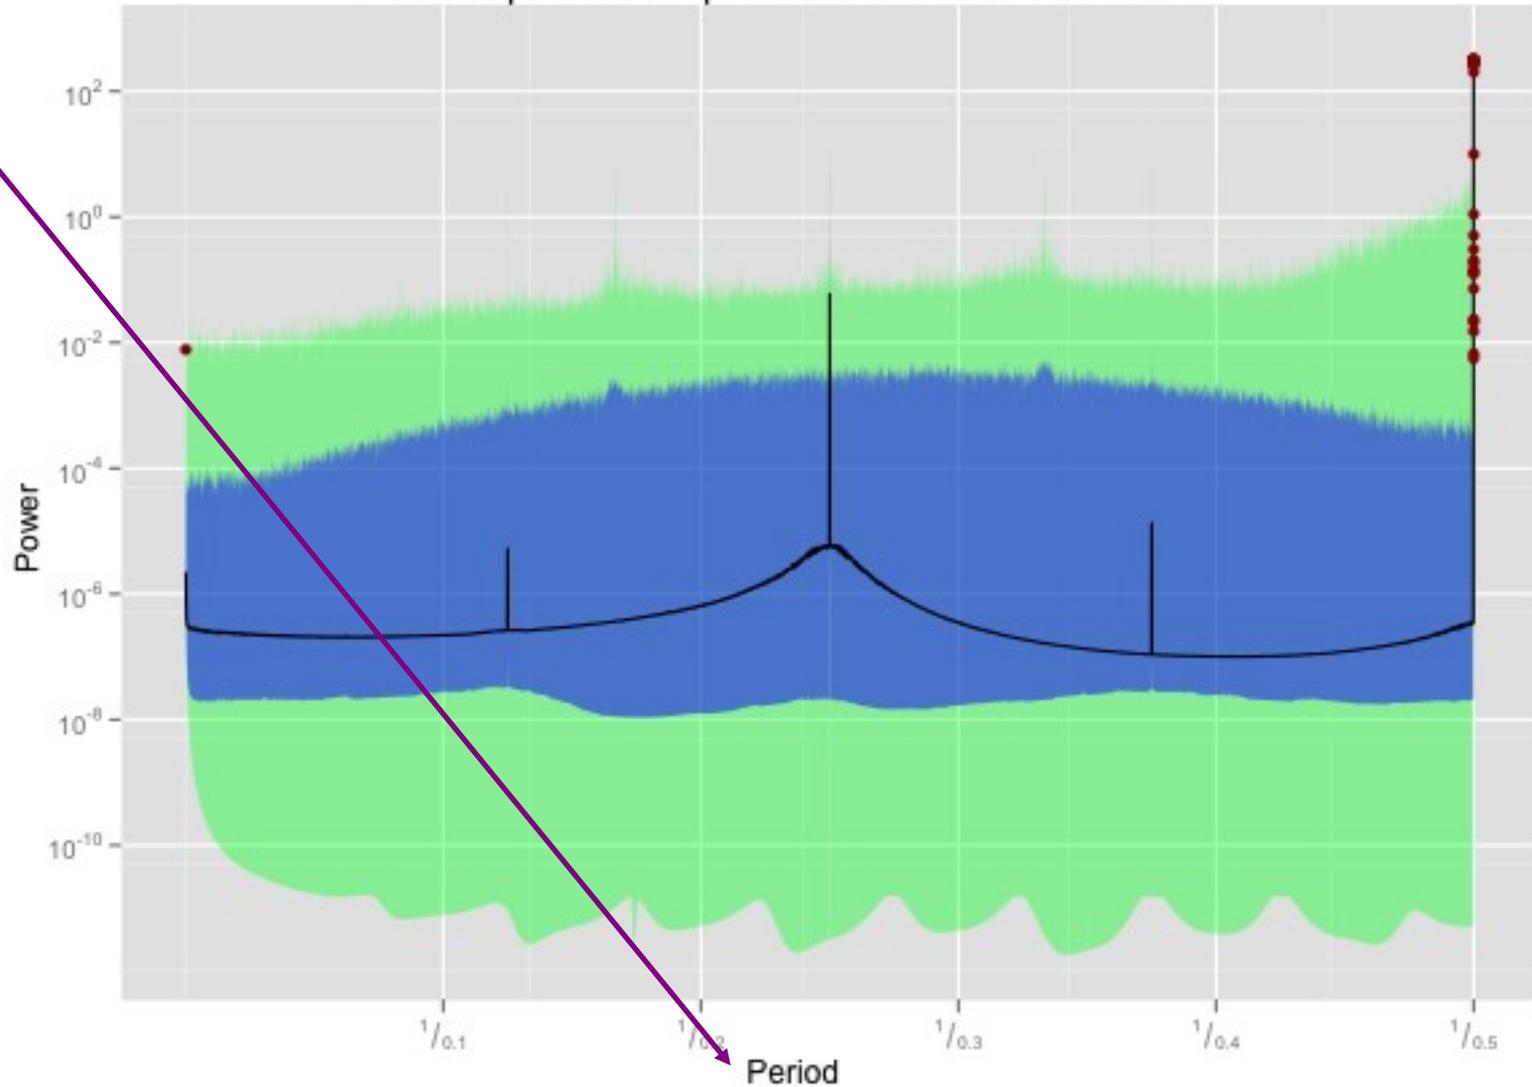


Boxplot condicionado a

Dos variables

una variable continua

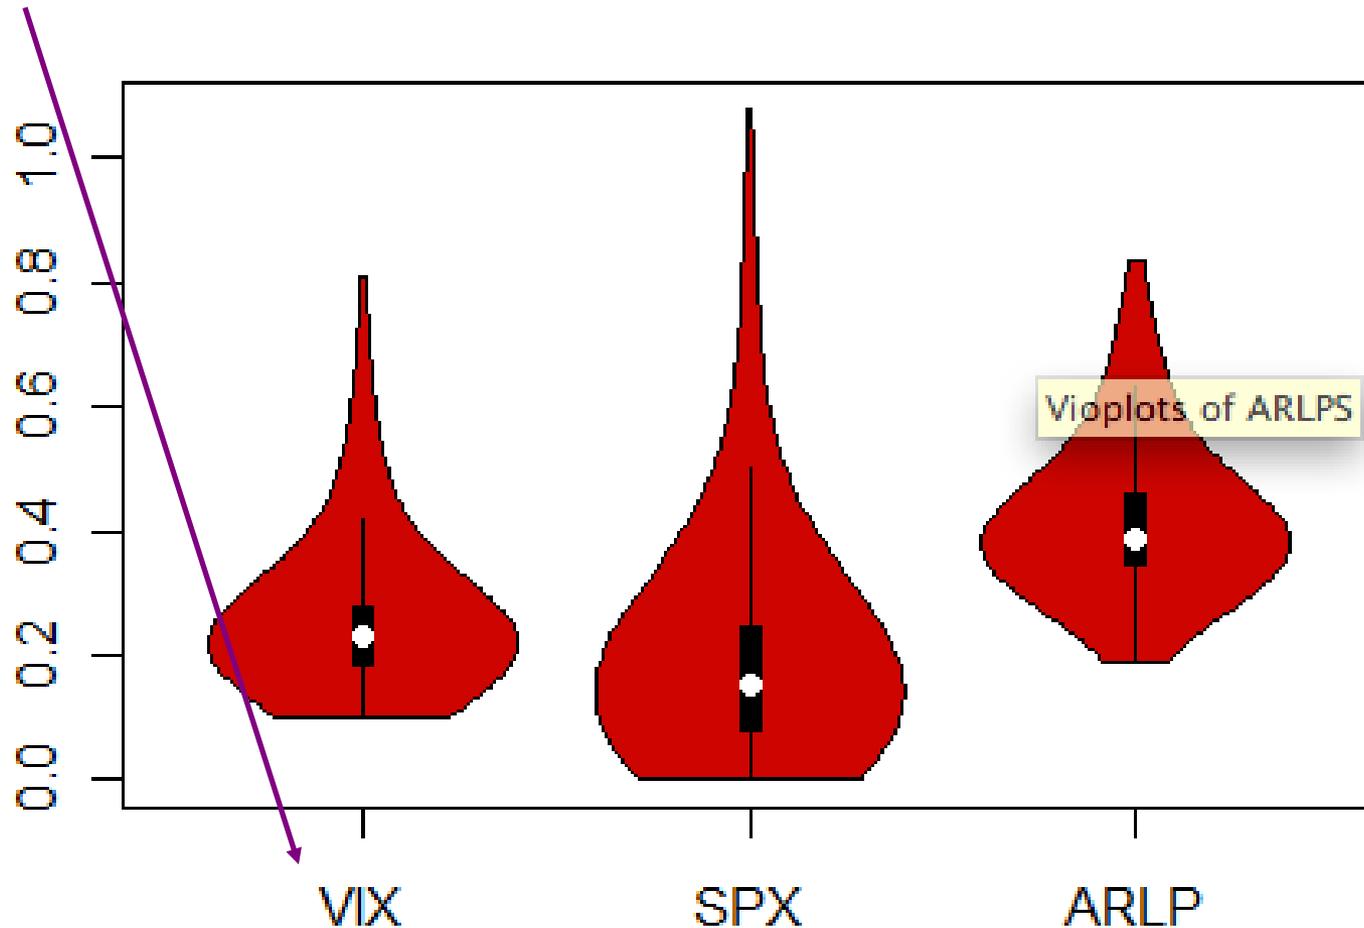
Power Spectra: Boxplot Distribution of Coefficients



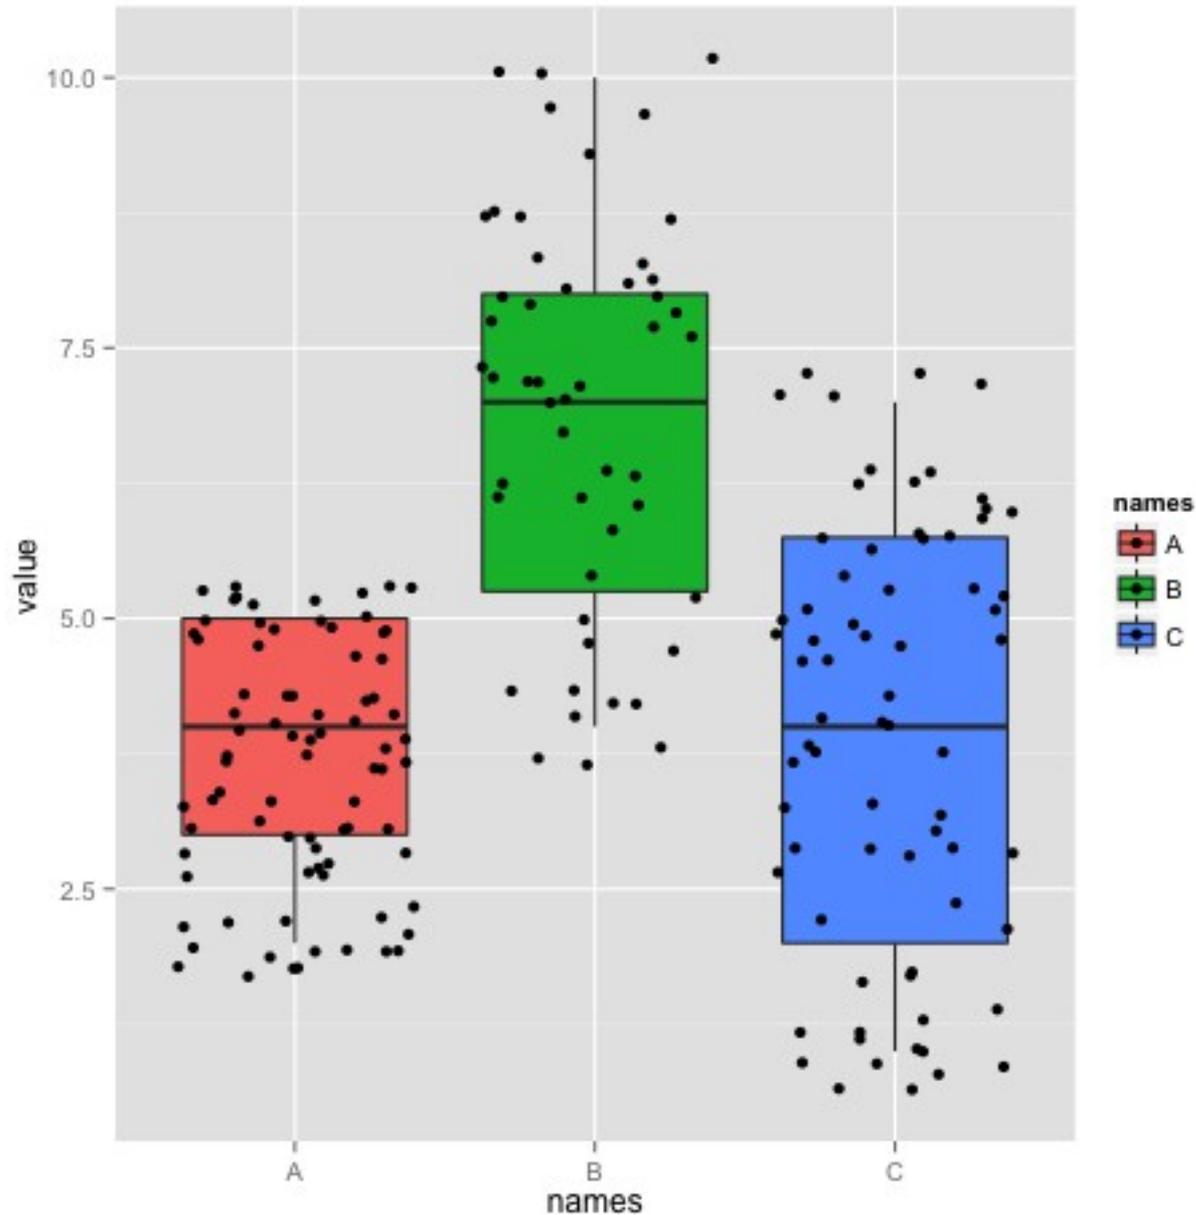
Gráficos de Violin

Stock index

Violins of Volatility



Boxplot + Scatterplot



Grafos

Nodos

Aristas

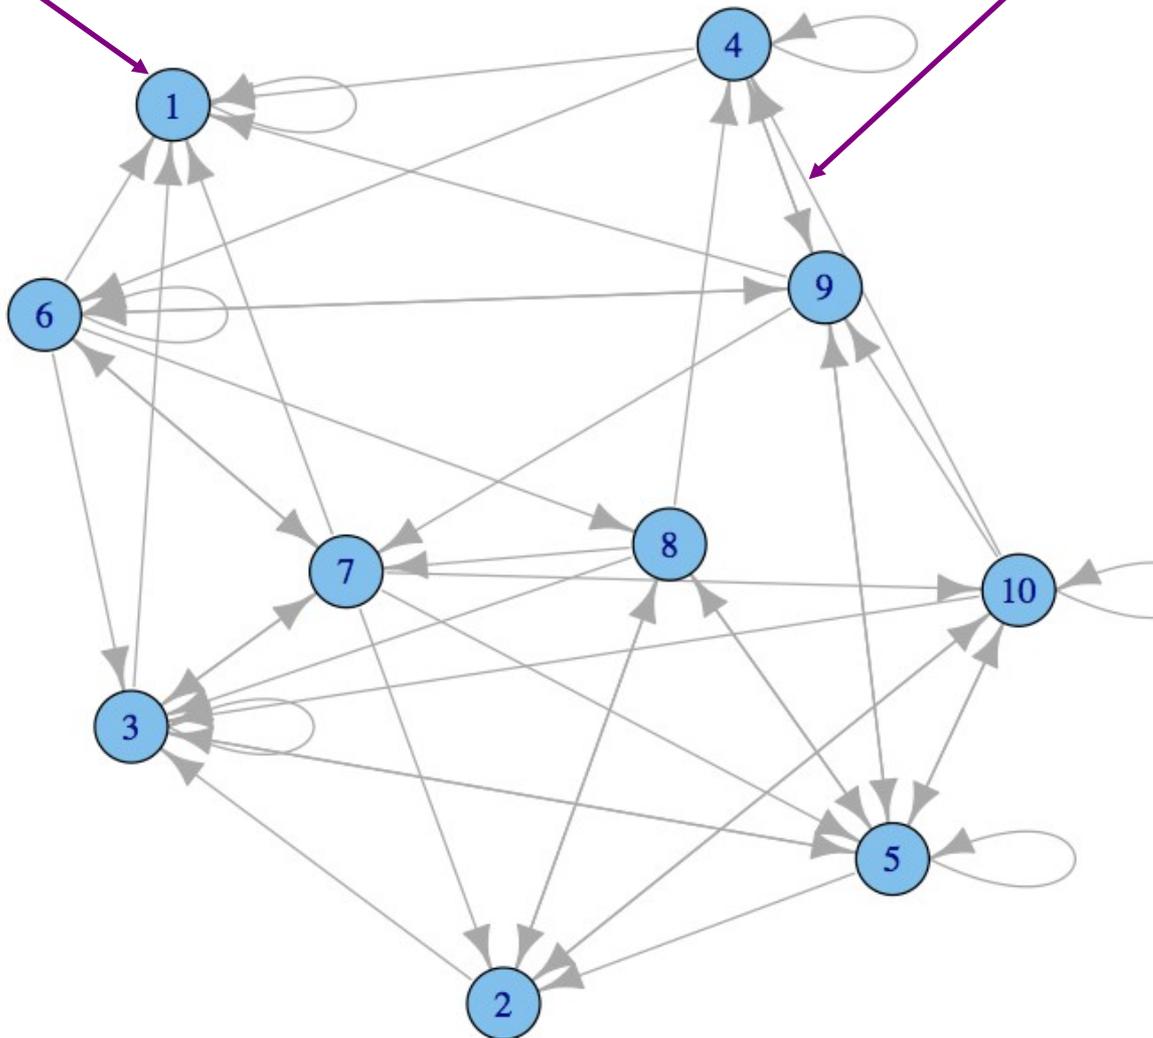
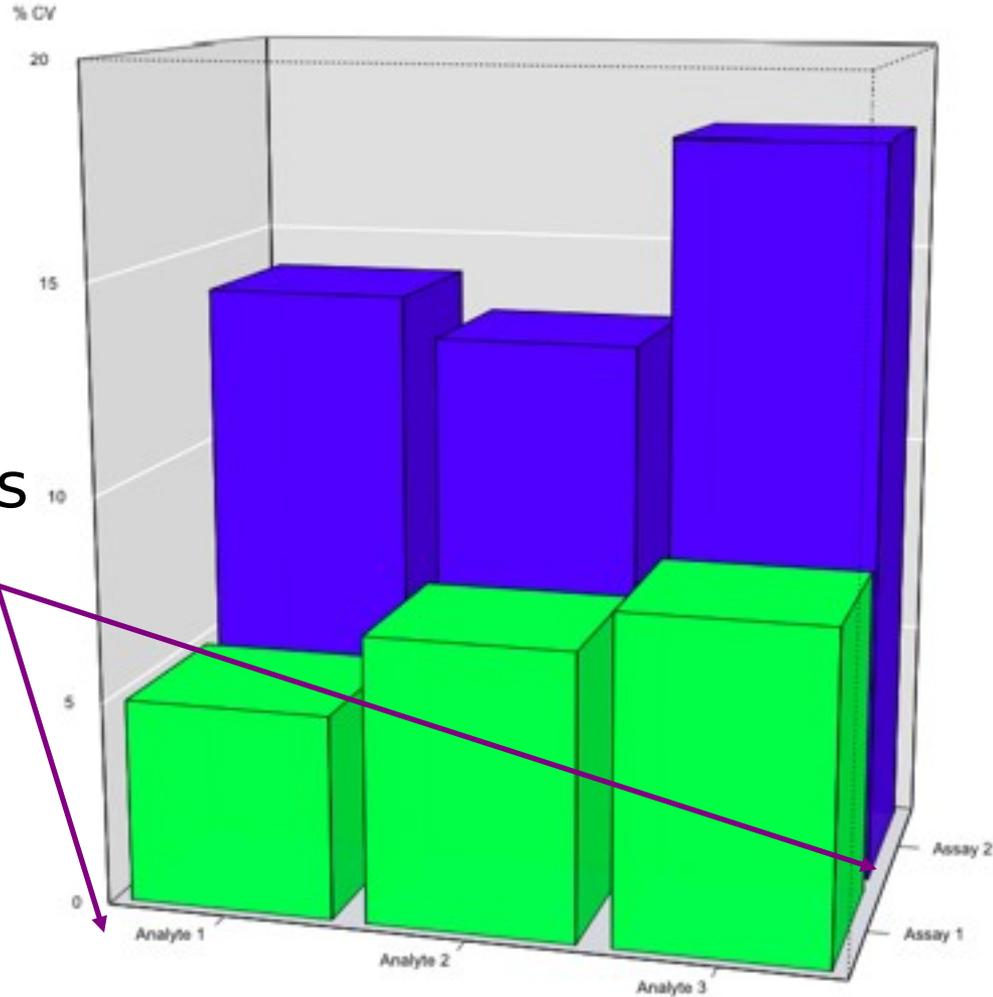


Gráfico de barras 3D



Dos variables categóricas

Gráficos de elipses

Correlaciones

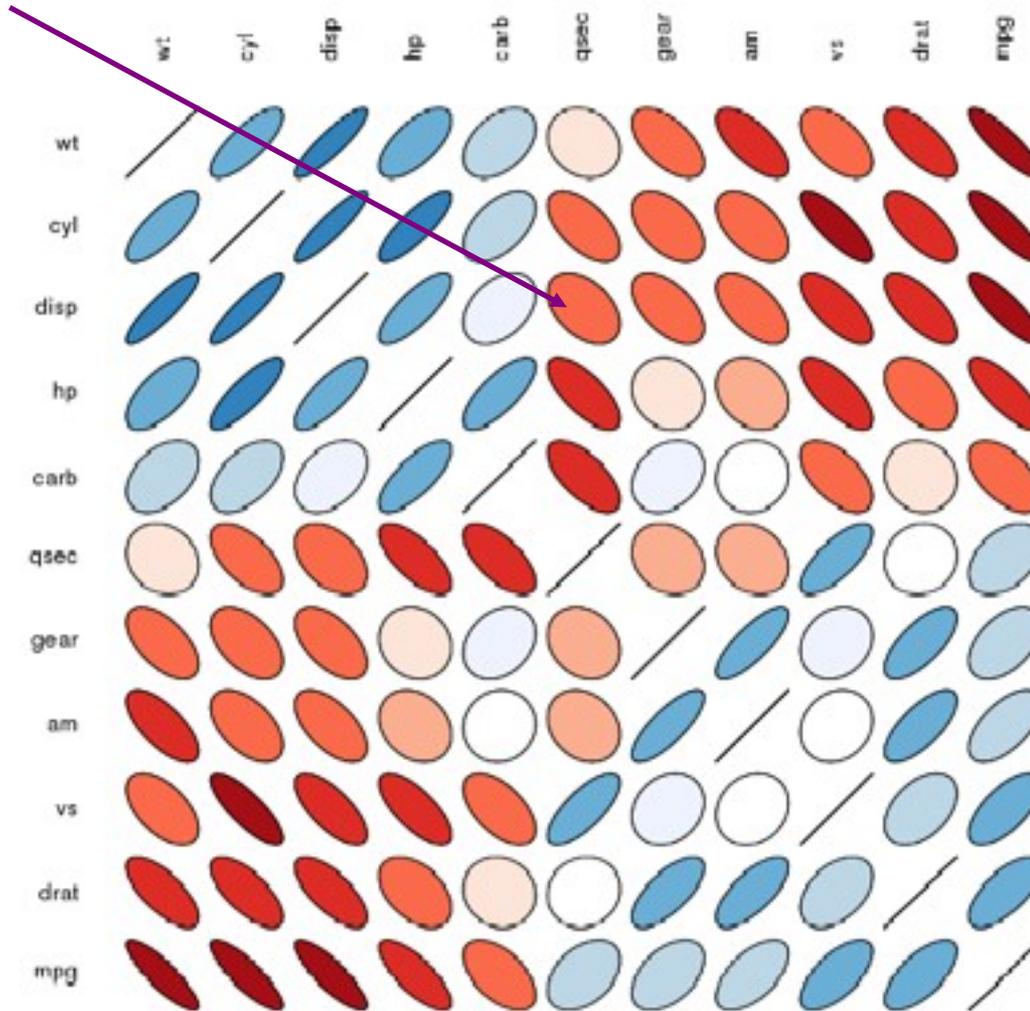
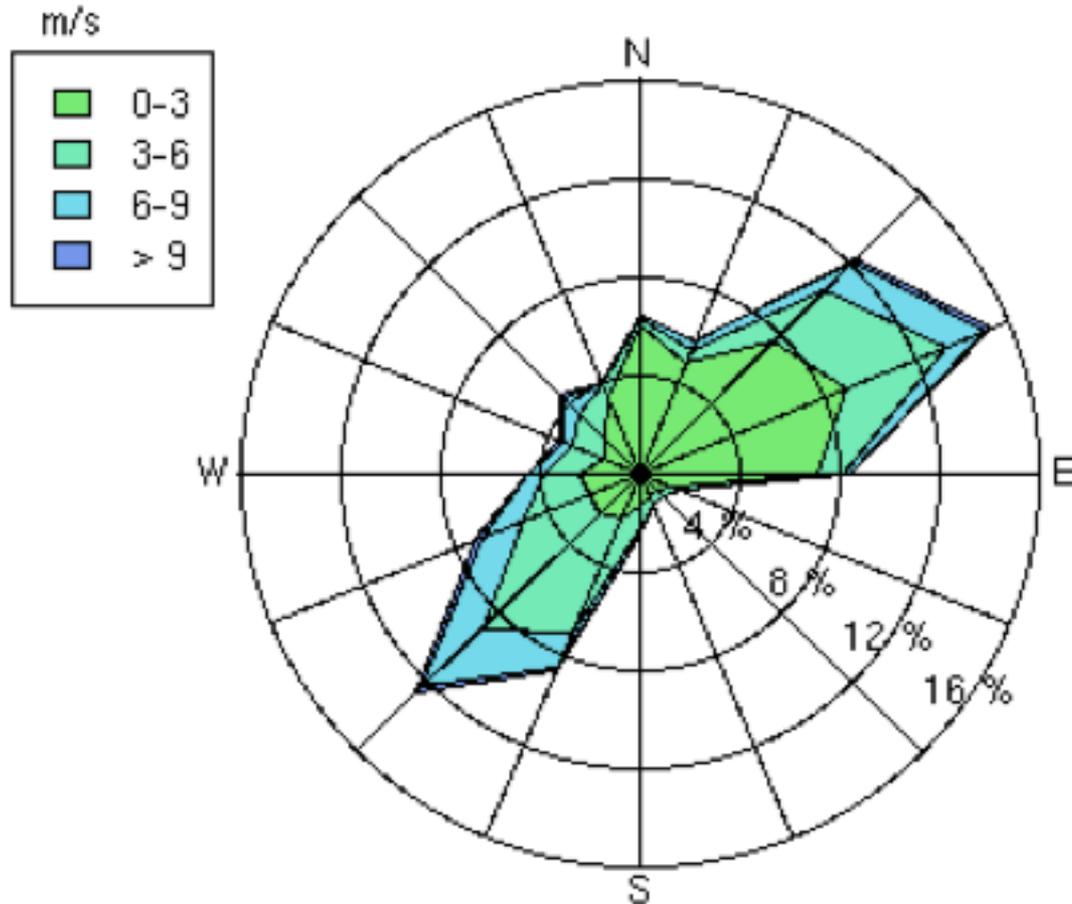
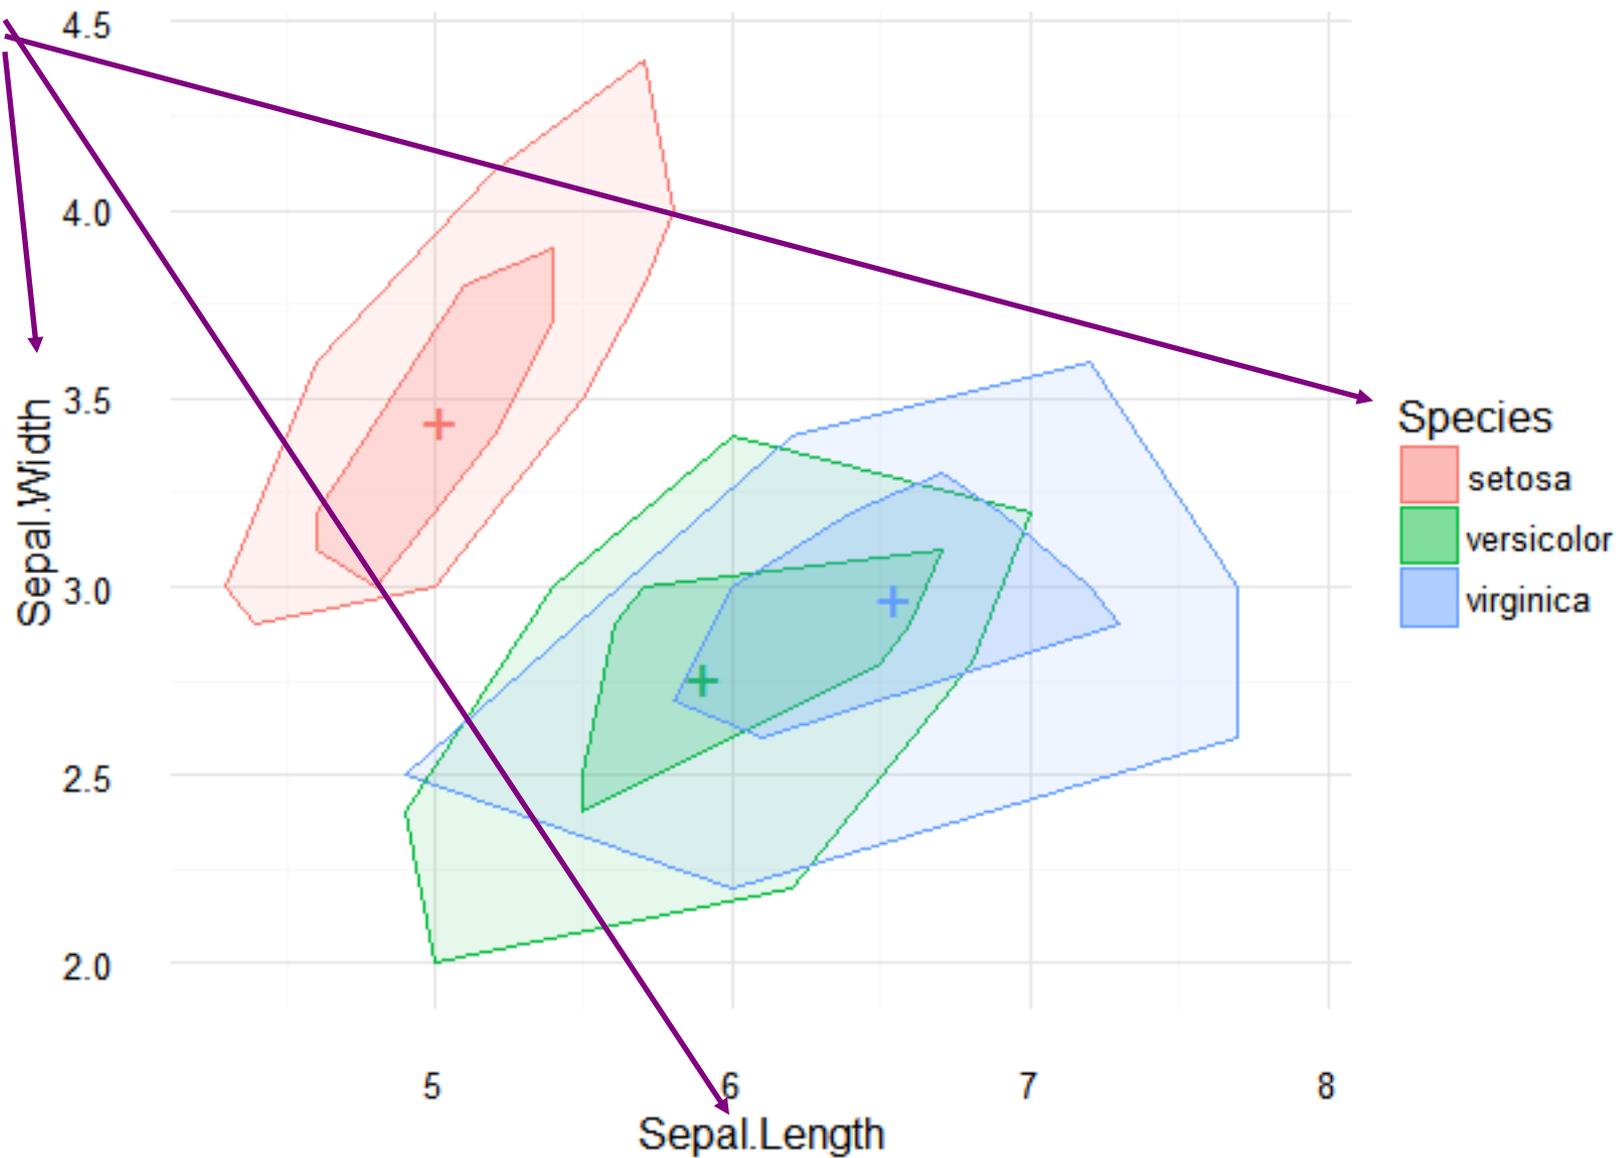


Gráfico de densidad para datos angulares (Viento)



Tres
variables

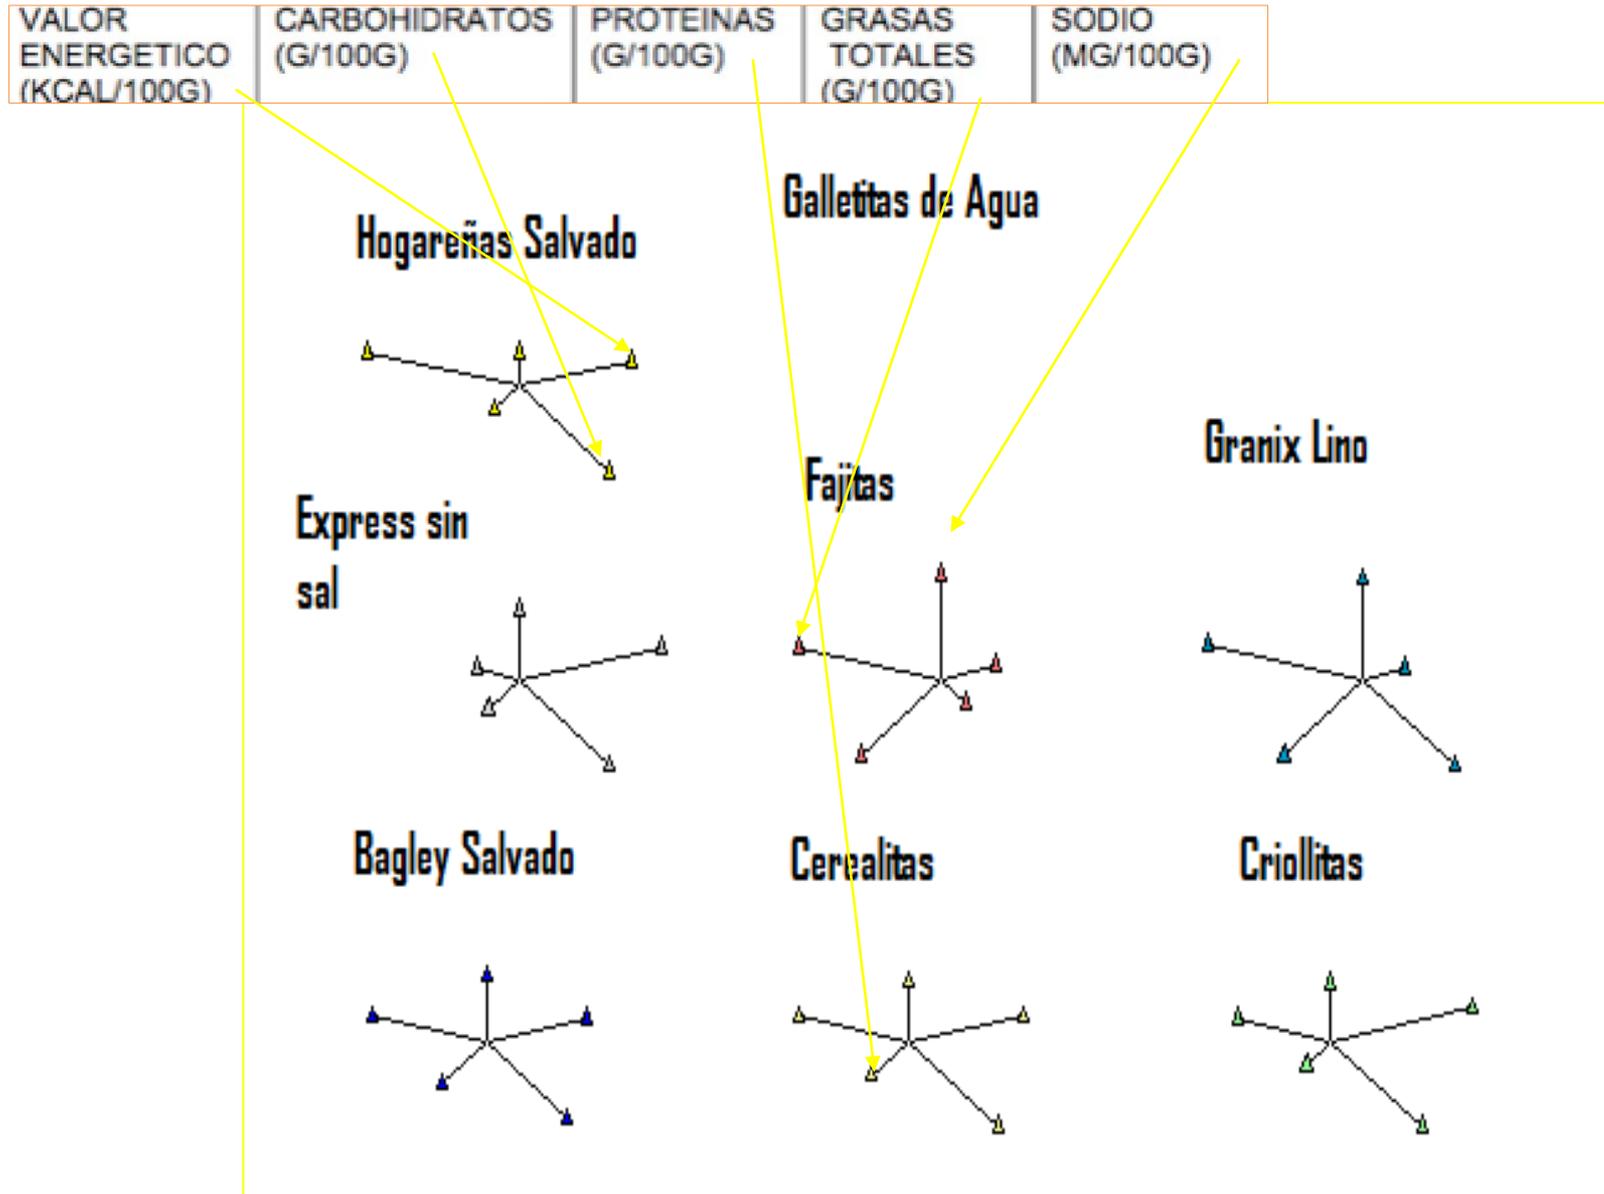
Bagplot (2D Boxplot)



Datos de galletitas

MARCA	VALOR ENERGETICO (KCAL/100G)	CARBOHIDRATOS (G/100G)	PROTEINAS (G/100G)	GRASAS TOTALES (G/100G)	SODIO (MG/100G)
cerealitas	439	65	11	15	574
fajitas	466	57	10	22	828
express s/sal	445	69	11	14	12
oreo	478	67	5,6	21	363
melba	464	70	6,3	18	263
pepitos	463	66	7,1	19	136
criollitas	438	69	11	13	431
merengadas	418	69	6,3	13	201
sonrisas	423	70	6,8	13	241
maná	444	73	9	13	375
guinditas	407	70	6	12	106,7
pepas	437	60	6,7	18	76,67
Polvorón	410	56,7	6,3	18	66,7
biscoch.grasa.azuc	493	60	7,6	24	1066
hogareñas.salvado	424	65	11	13	892
granix.con.lino	462	55	11	22	931
bagley salvado	421	63	11	14	624

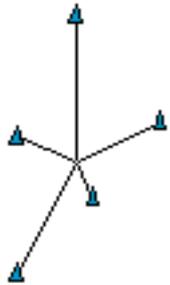
Gráficos de estrellas (1)



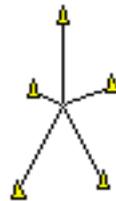
Gráficos de estrellas (2)

Galletitas Dulces

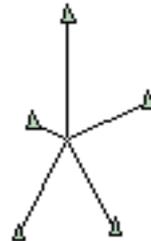
Oreo



Pepas



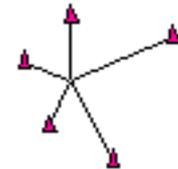
Pepitos



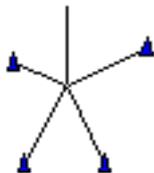
Polvorón



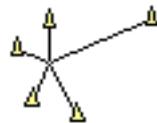
Sonrisas



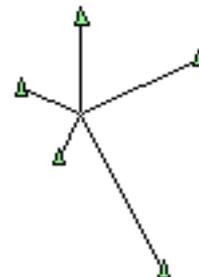
Bizcochos
azucarados



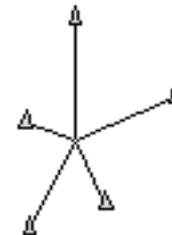
Guindas



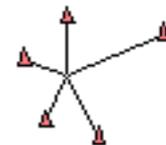
Maná



Melba



Merengadas




Gráficos de caras (1)

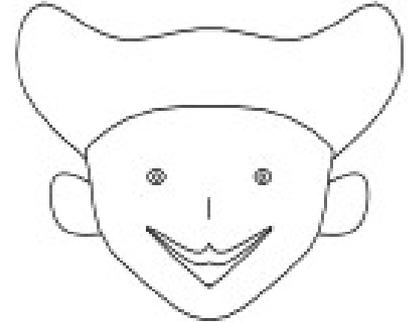
hogare.as.salvado



express sisal



fajitas



granix.con.lino



bagley salvado



cerealitas

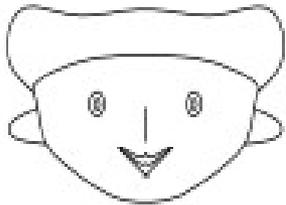


criollitas

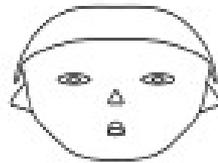


Gráficos de caras (2)

oreo



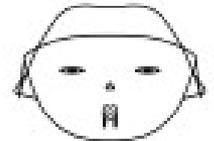
pepas



pepitos



polver.n



sonrisas



bizcoch.grasa.azuc



guinditas



man.



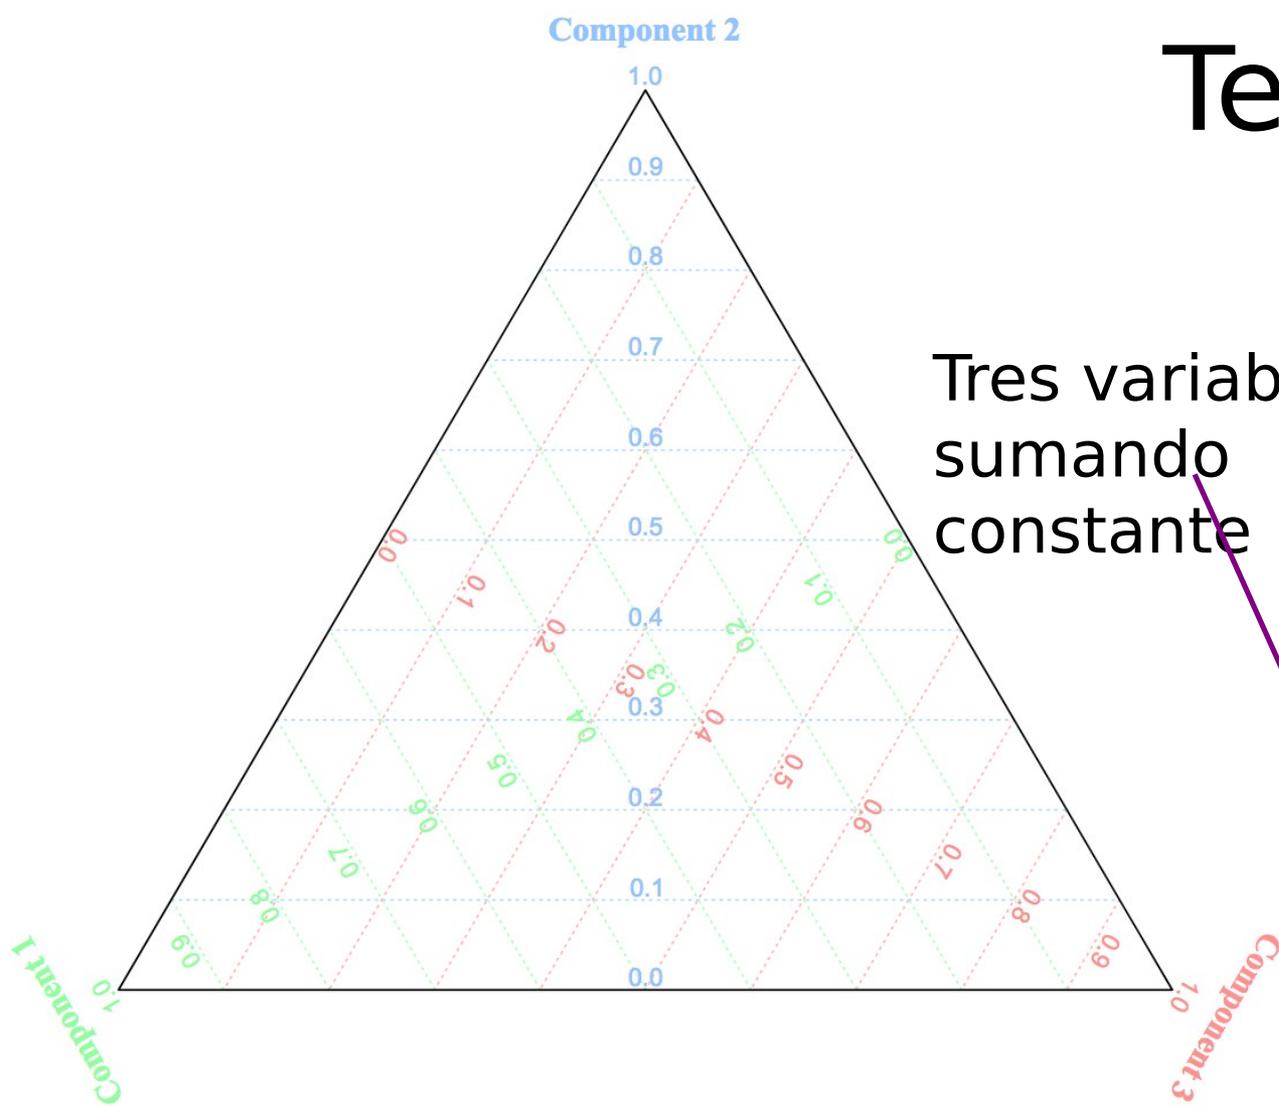
melba



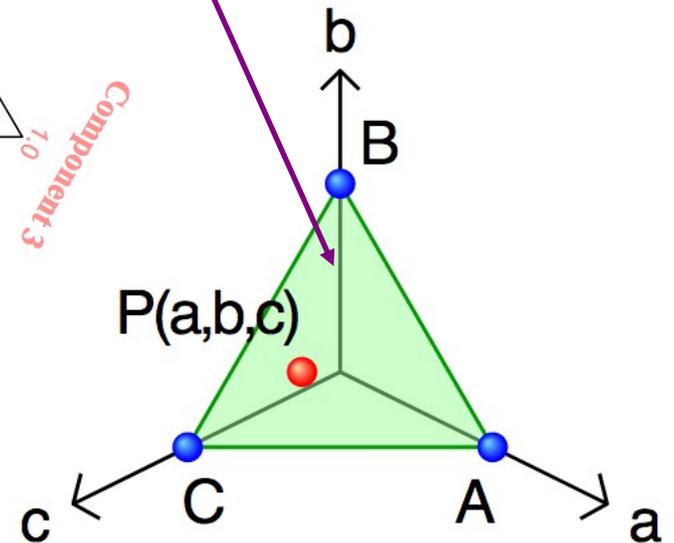
merengadas



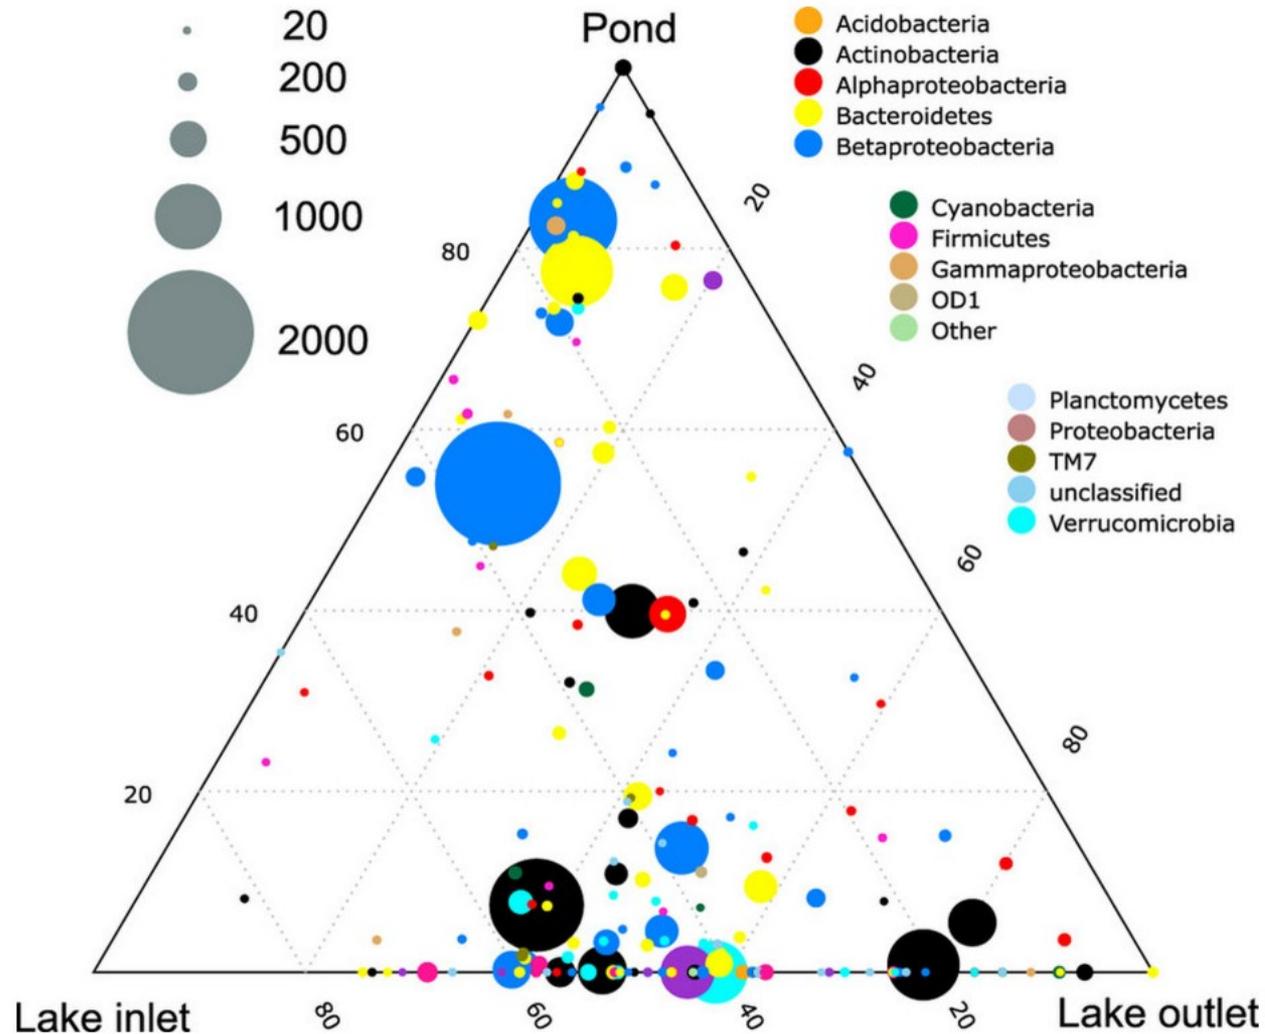
Ternary Plot



Tres variables
sumando
constante



Presencia de bacterias en 3 habitats



Axes represent the pond, inlet and outlet and the percentage of reads associated with each environment. The size of the symbol indicates number of reads associated with each OTU and taxonomic affiliations are indicated by colors. All OTUs with at least 20 reads were included into the plot.

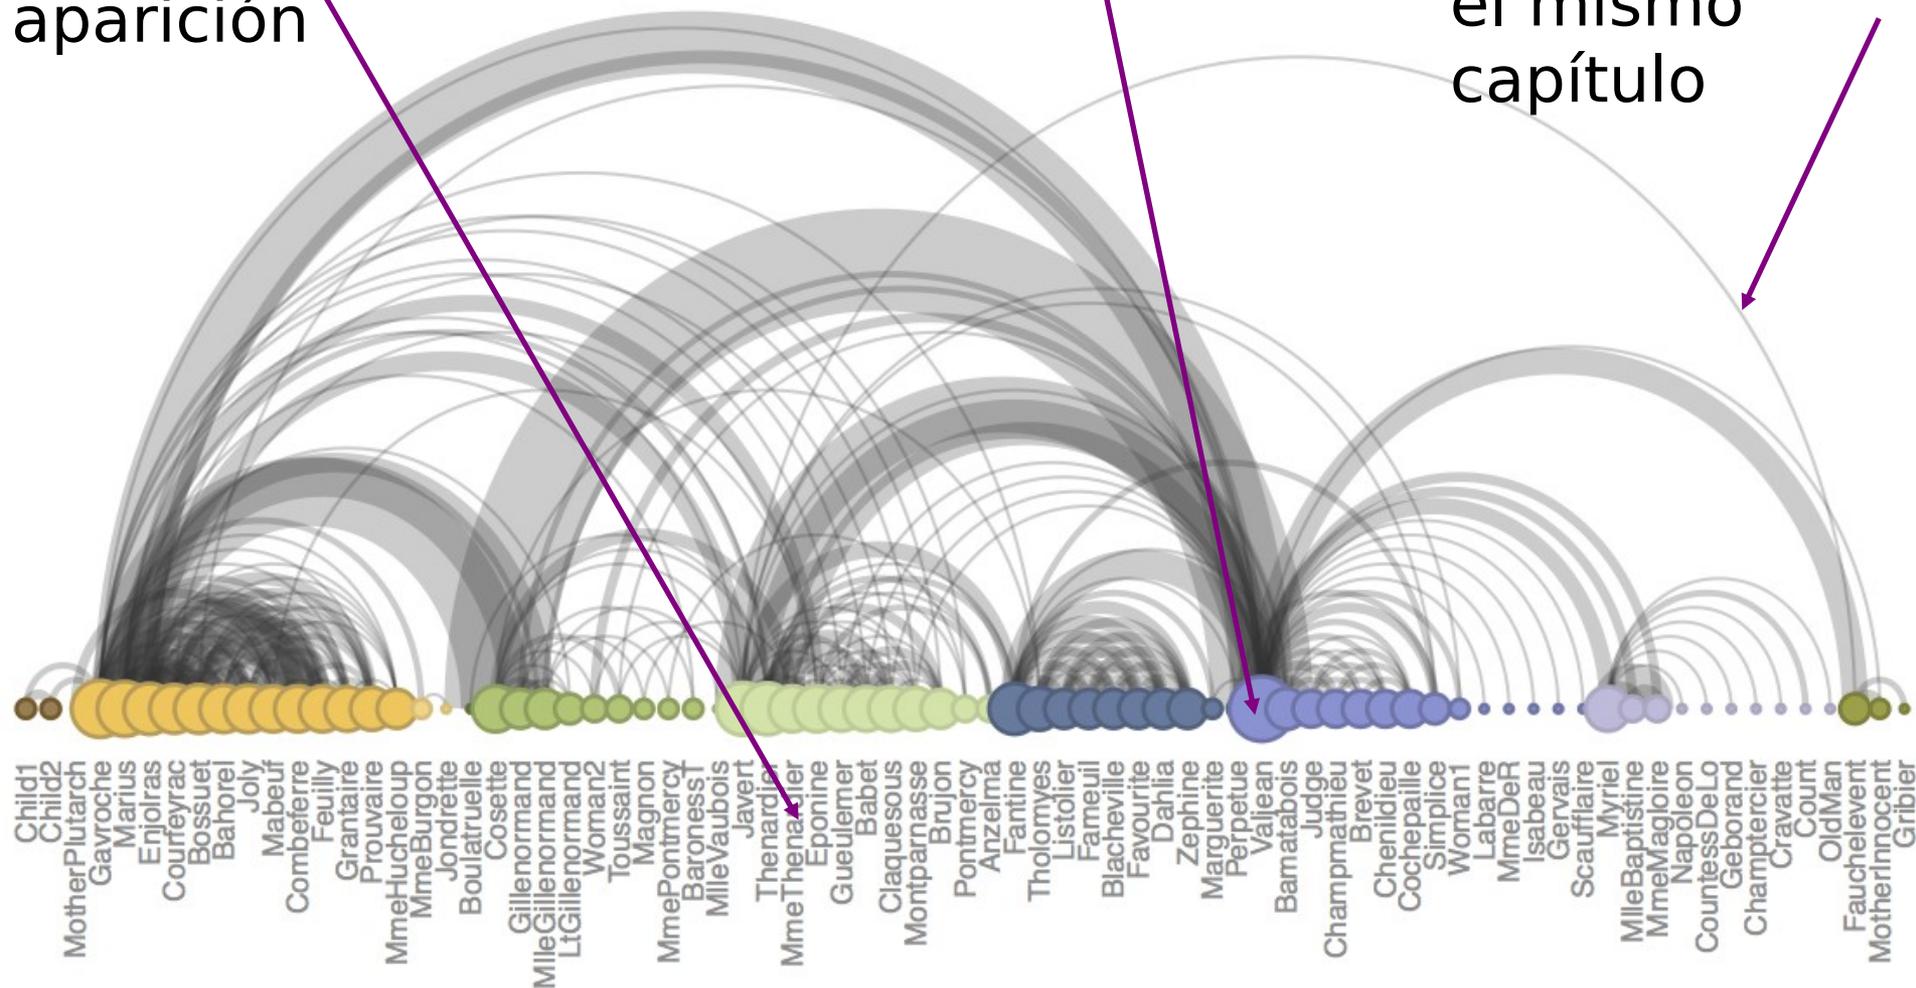
Diagramas de Arco

(Los Miserables, Victor Hugo)

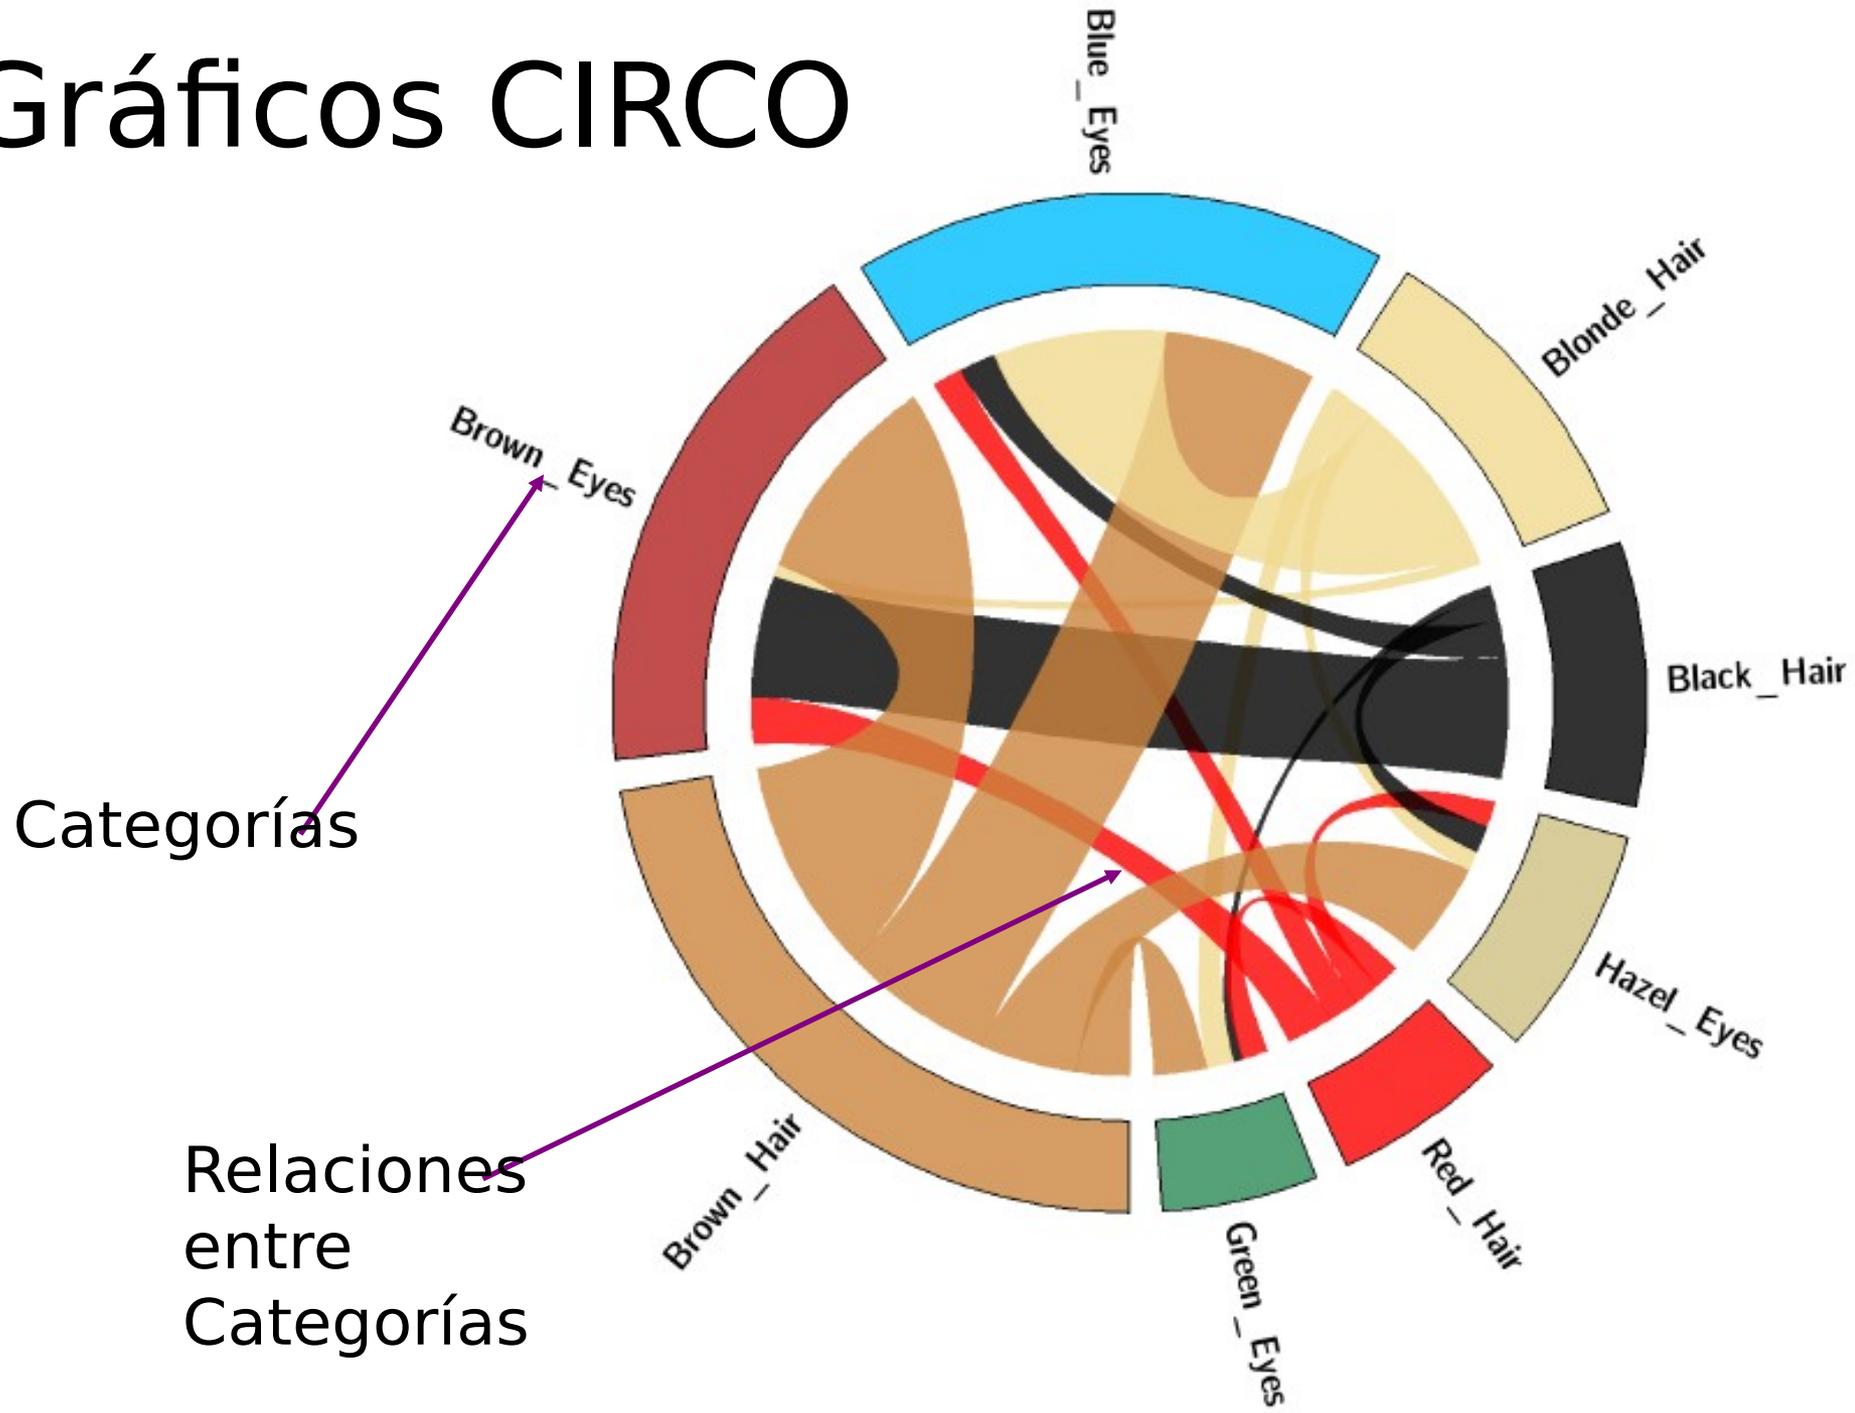
Protagonistas en el libro por orden de aparición

Capítulos del libro

Conexión por aparición en el mismo capítulo



Gráficos CIRCO



Blue_Eyes

Blonde_Hair

Black_Hair

Hazel_Eyes

Red_Hair

Green_Eyes

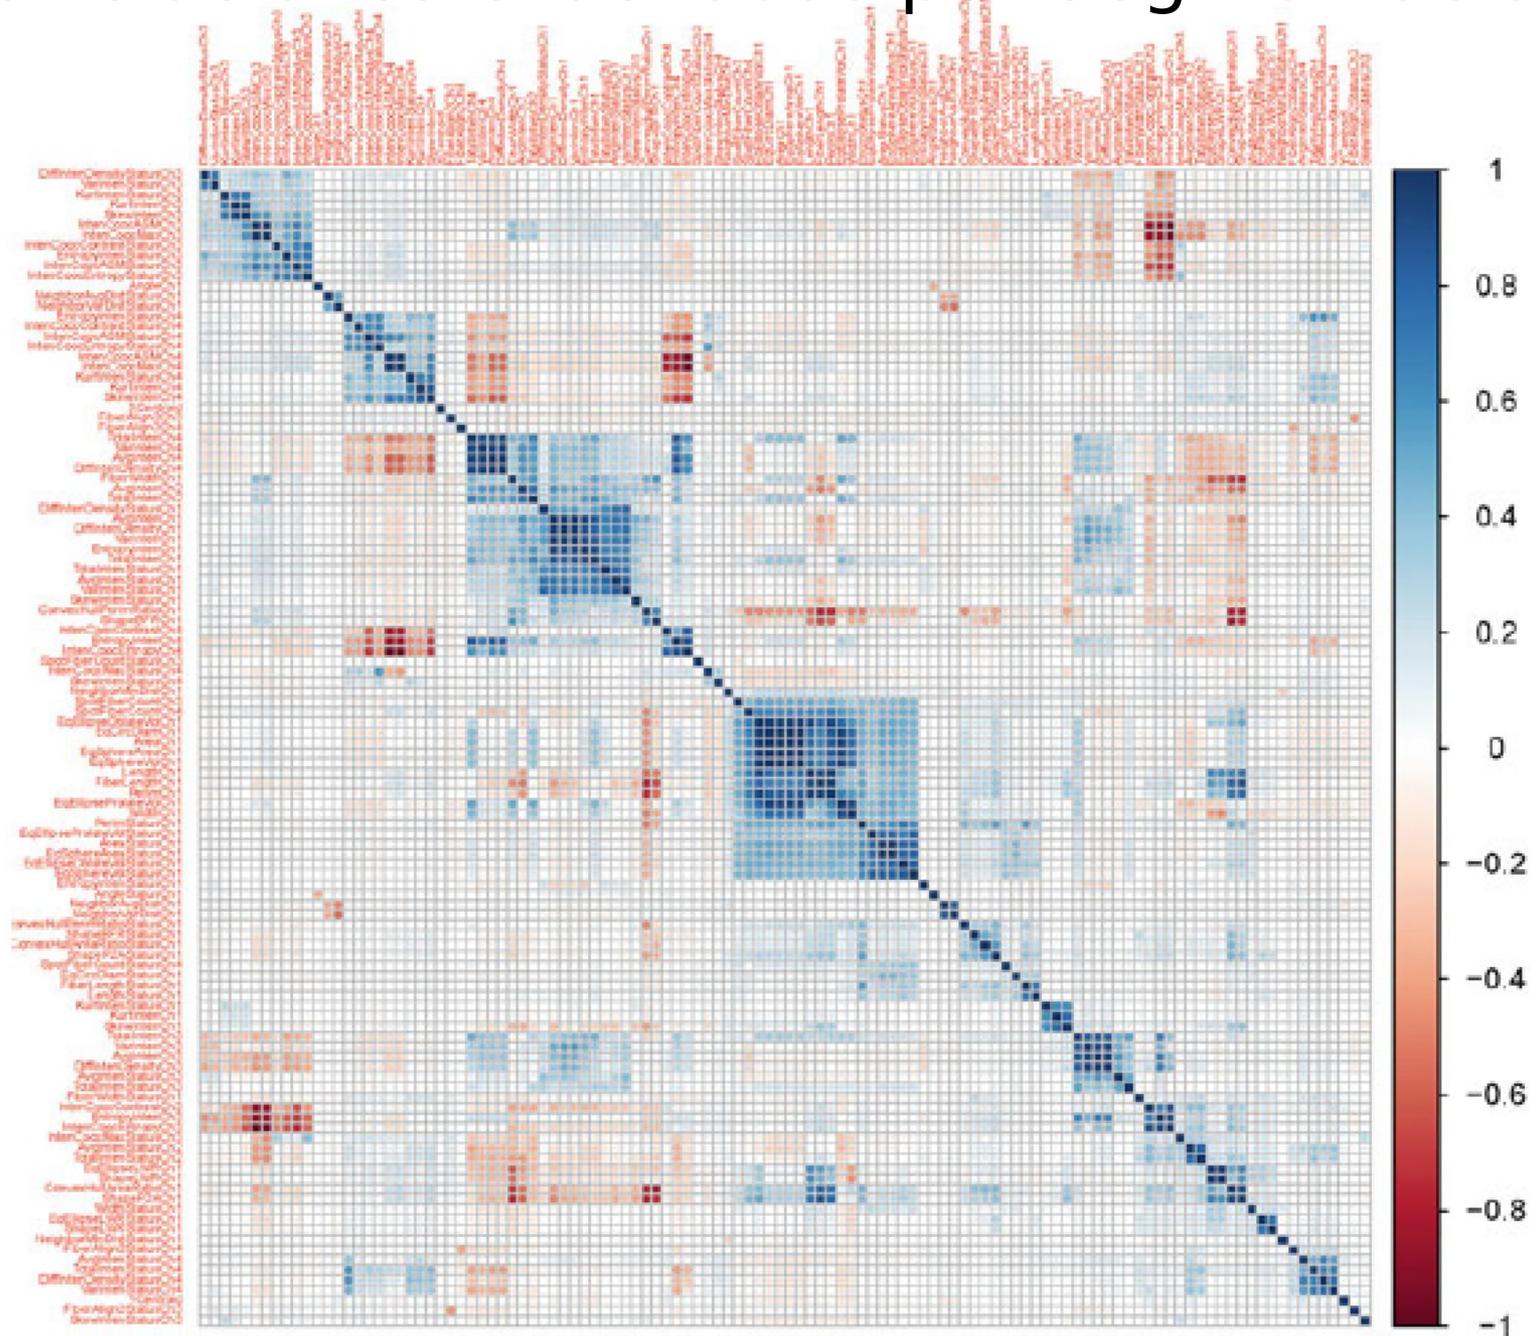
Brown_Hair

Brown_Eyes

Categorías

Relaciones
entre
Categorías

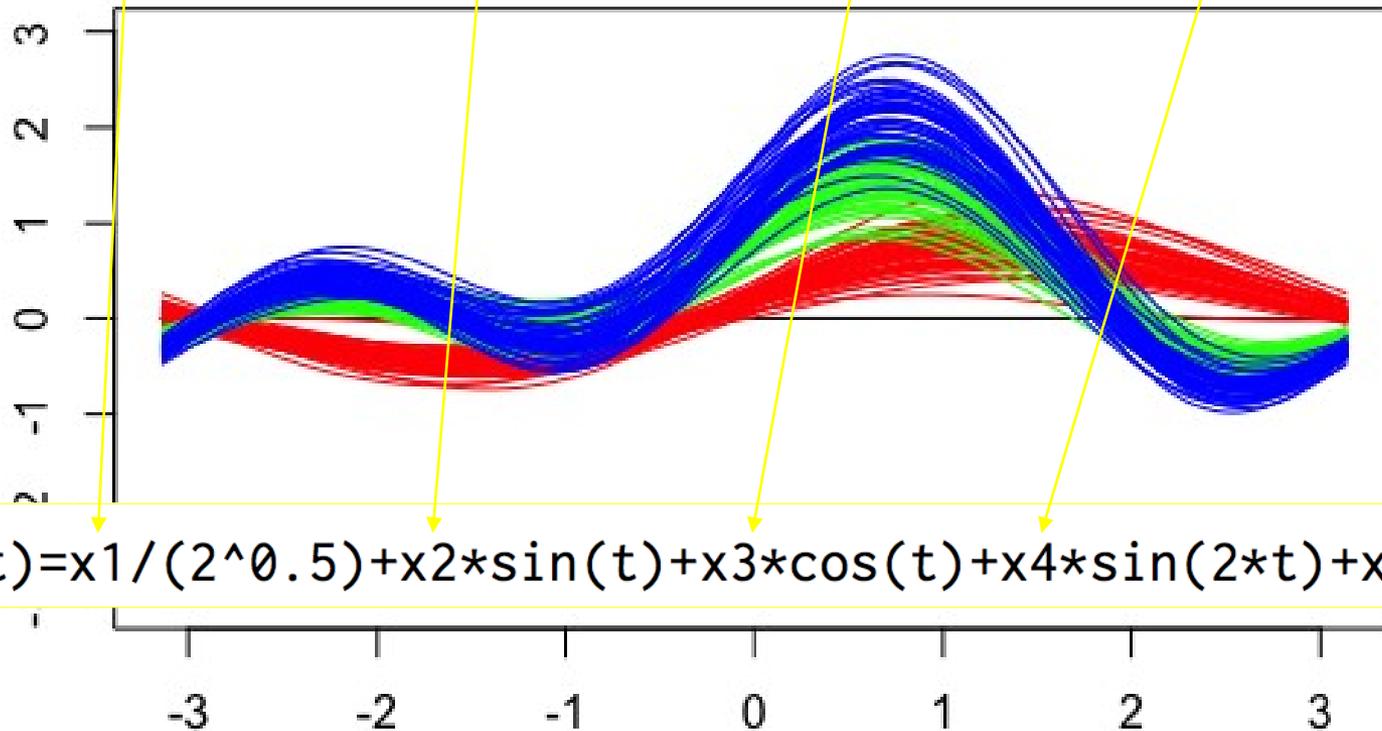
Correlaciones Ordenadas por Segmentación



Curvas de Andrews

Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
5.1	3.5	1.4	0.2	setosa
5.1	3.8	1.5	0.3	setosa
5.6	2.5	3.9	1.1	versicolor
				versicolor
				virginica
				virginica

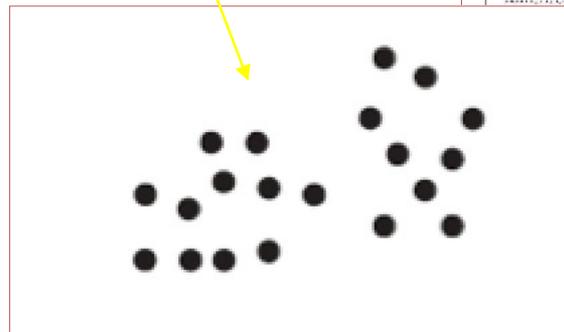
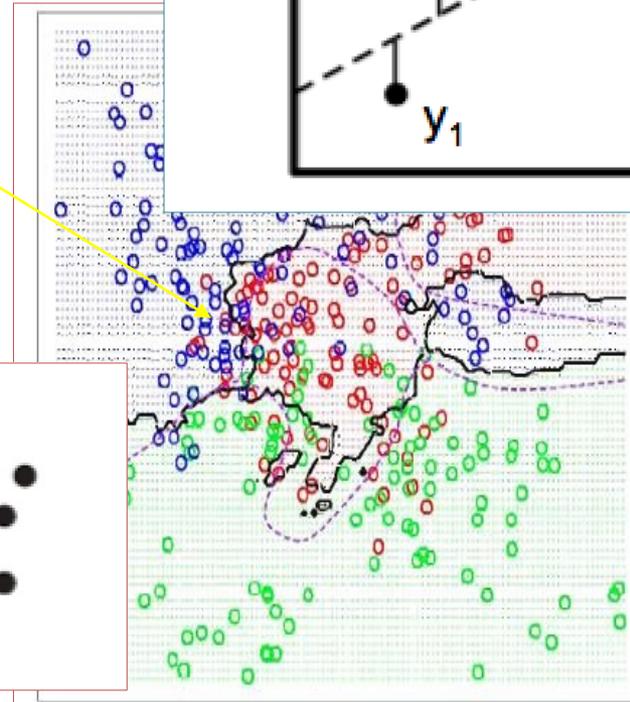
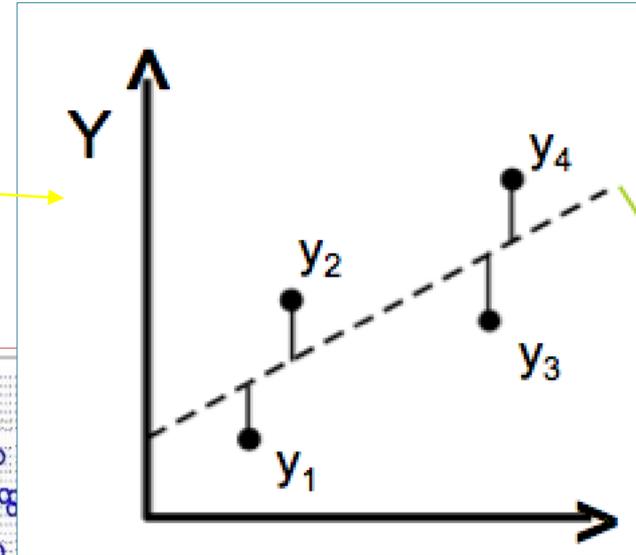
Curvas de Andrews para Iris



$$f(t) = x_1 / (2^{0.5}) + x_2 \sin(t) + x_3 \cos(t) + x_4 \sin(2t) + x_5 \cos(2t) + \dots$$

Benchmarking

- Como medimos la efectividad de los métodos ?
- En regresión ?
- En clasificación ?
- En segmentación ?
- Que métricas utilizamos ?
- Que técnicas empleamos ?



Benchmarking en Regresión

- Mean Squared Error (MSE) $\rightarrow \sum (y_i - \hat{y}_i)^2$
- Mean Absolute Error (MAE) $\rightarrow \frac{1}{n} \sum_{i=1}^n |e_i|$
- Proportional Mean Absolute Error (PMAE)
- Coeficiente de Determinación (R²)
- Correlación – Pearson - Spearman

$$R^2 = \frac{SCR_{eg}}{SCT} = 1 - \frac{SCE}{SCT} ; 0 \leq R^2 \leq 1$$

$$\sum (\hat{y}_i - \bar{y})^2$$

$$\sum (y_i - \bar{y})^2$$

Benchmarking en Clasificación

- Accuracy

$$ACC = (TP + TN) / (P + N)$$

- Sensibilidad

$$TPR = TP / P = TP / (TP + FN)$$

- Especificidad

$$SPC = TN / N = TN / (FP + TN)$$

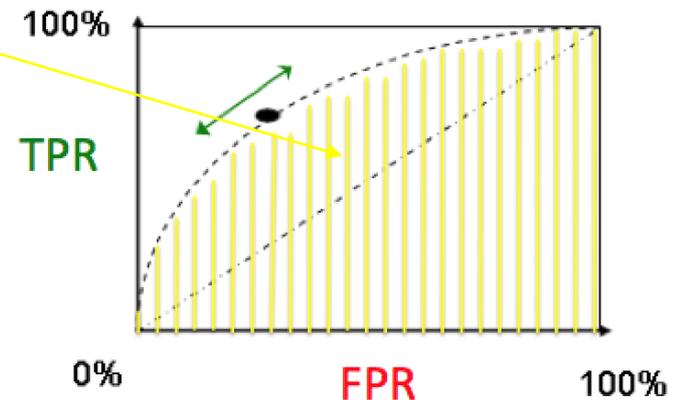
- False Discovery Rate

$$FDR = FP / (FP + TP) = 1 - PPV$$

- Presición

$$PPV = TP / (TP + FP)$$

- Area bajo la curva



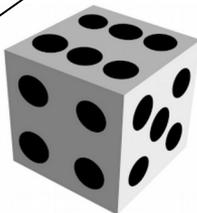
Coeficiente Kappa de Cohen

Accuracy
Obtenida

$$ACC = (TP + TN) / (P + N)$$

$$\kappa = \frac{\Pr(a) - \Pr(e)}{1 - \Pr(e)}$$

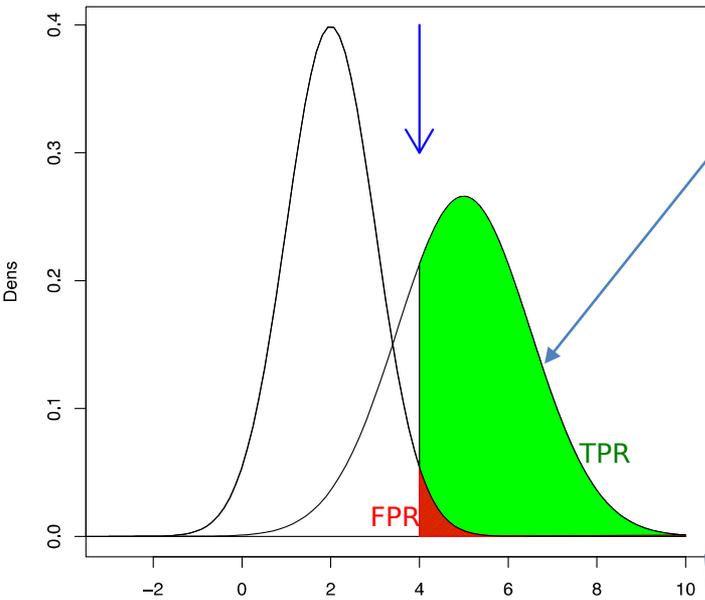
Accuracy que se
obtendría por
AZAR



Curvas ROC

- Método gráfico que muestra el desempeño de un procedimiento de **Clasificación**.
- Contempla la **asimetría** en el error.
- Sólo viable en casos de procedimientos con **Scores continuos**
- Interpretación Probabilística: Es la Probabilidad que una Observación Positiva (tomada al azar) tenga un score mayor que una Observación Negativa (tomada al azar).

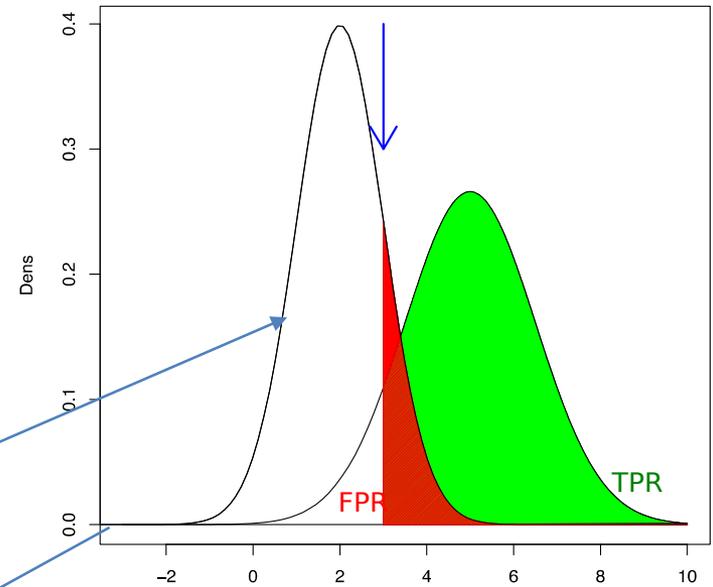
$c = 4$



Distribución del score de la Población TP

Distribución del score de la Población TN

$c = 3$



100%

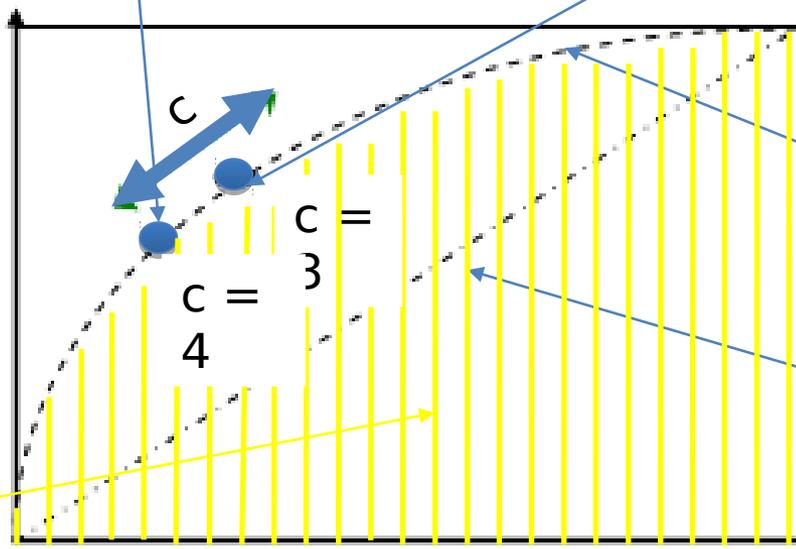
TPR

Area bajo la curva (AUC)

0%

FPR

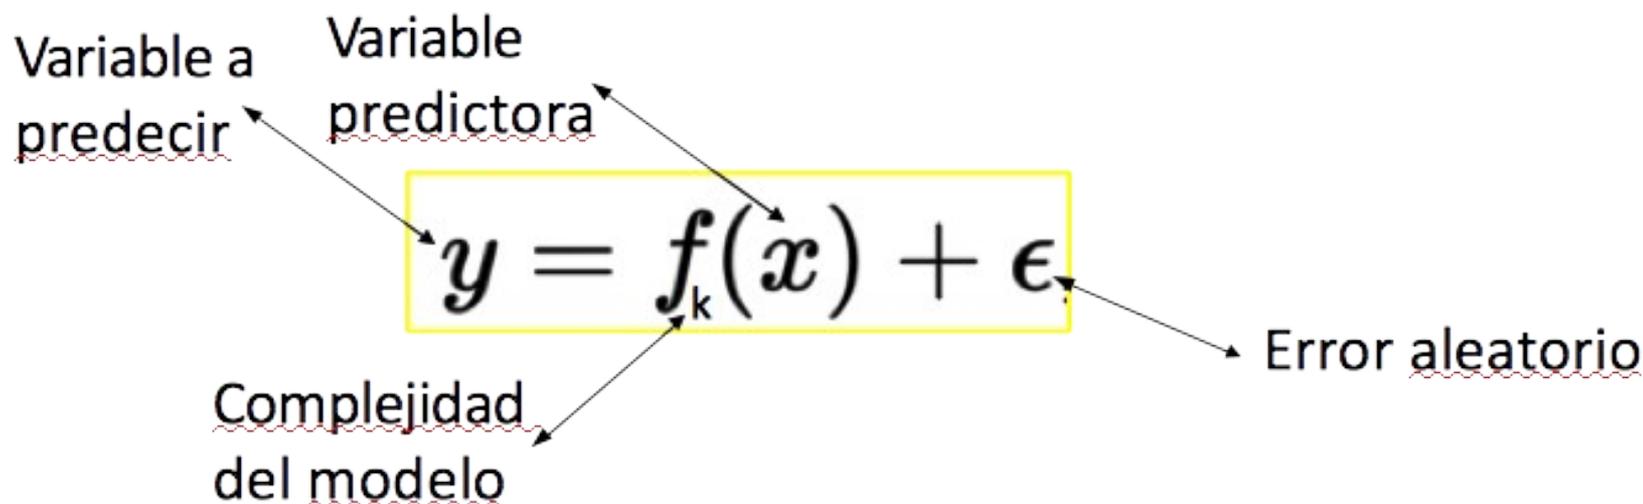
100%



Curva ROC

Curva de peor desempeño

Trade-off Sesgo-Varianza



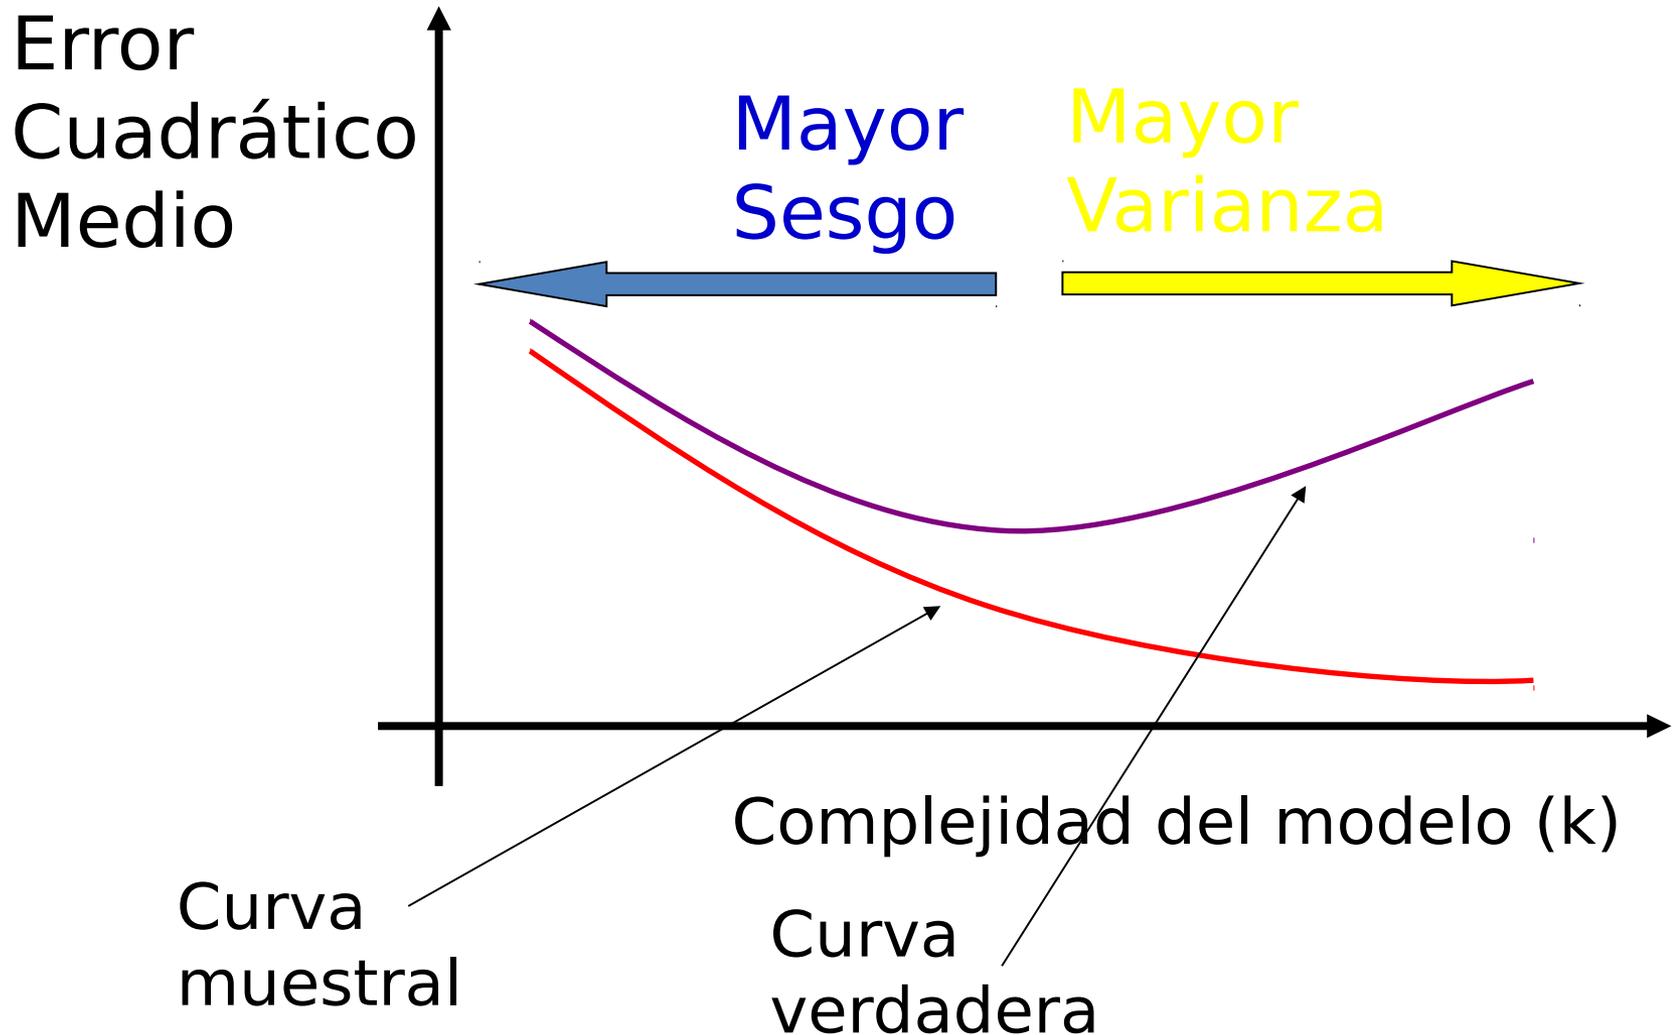
$$\mathbf{E} \left[(y - \hat{f}(x))^2 \right] = \mathbf{Bias} [\hat{f}(x)]^2 + \mathbf{Var} [\hat{f}(x)] + \sigma^2$$

$$\mathbf{Bias} [\hat{f}(x)] = \mathbf{E} [\hat{f}(x) - f(x)]$$

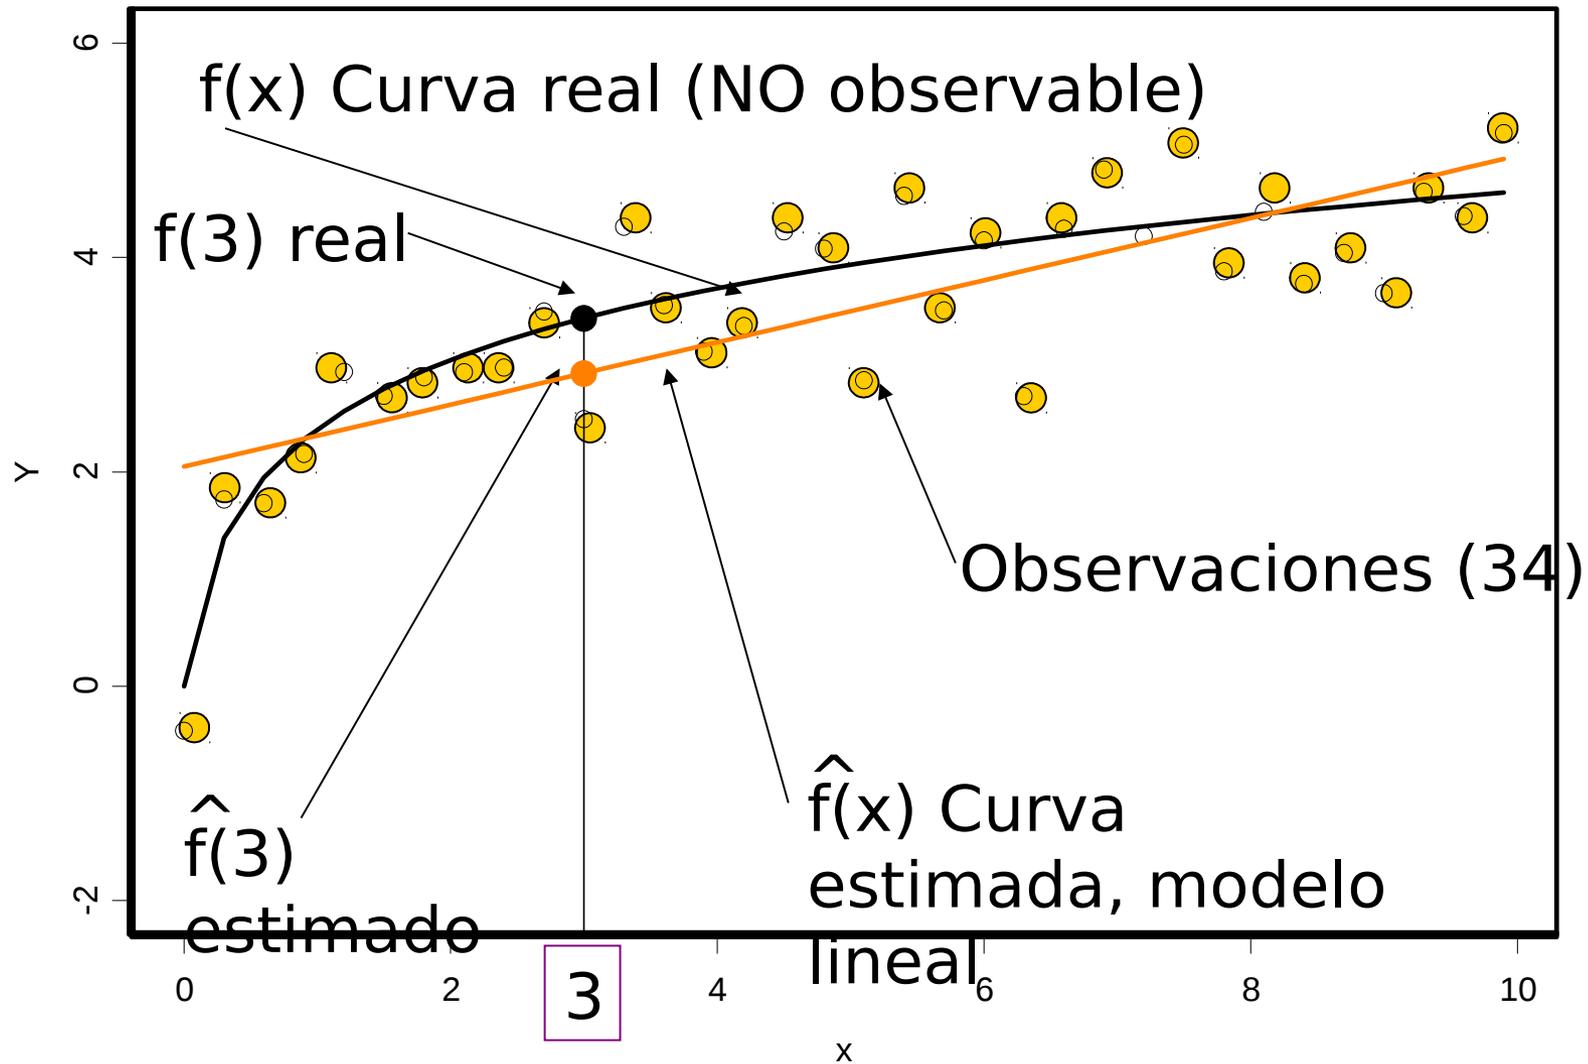
Variabilidad irreductible

$$\mathbf{Var} [\hat{f}(x)] = \mathbf{E} [\hat{f}(x)^2] - \mathbf{E} [\hat{f}(x)]^2$$

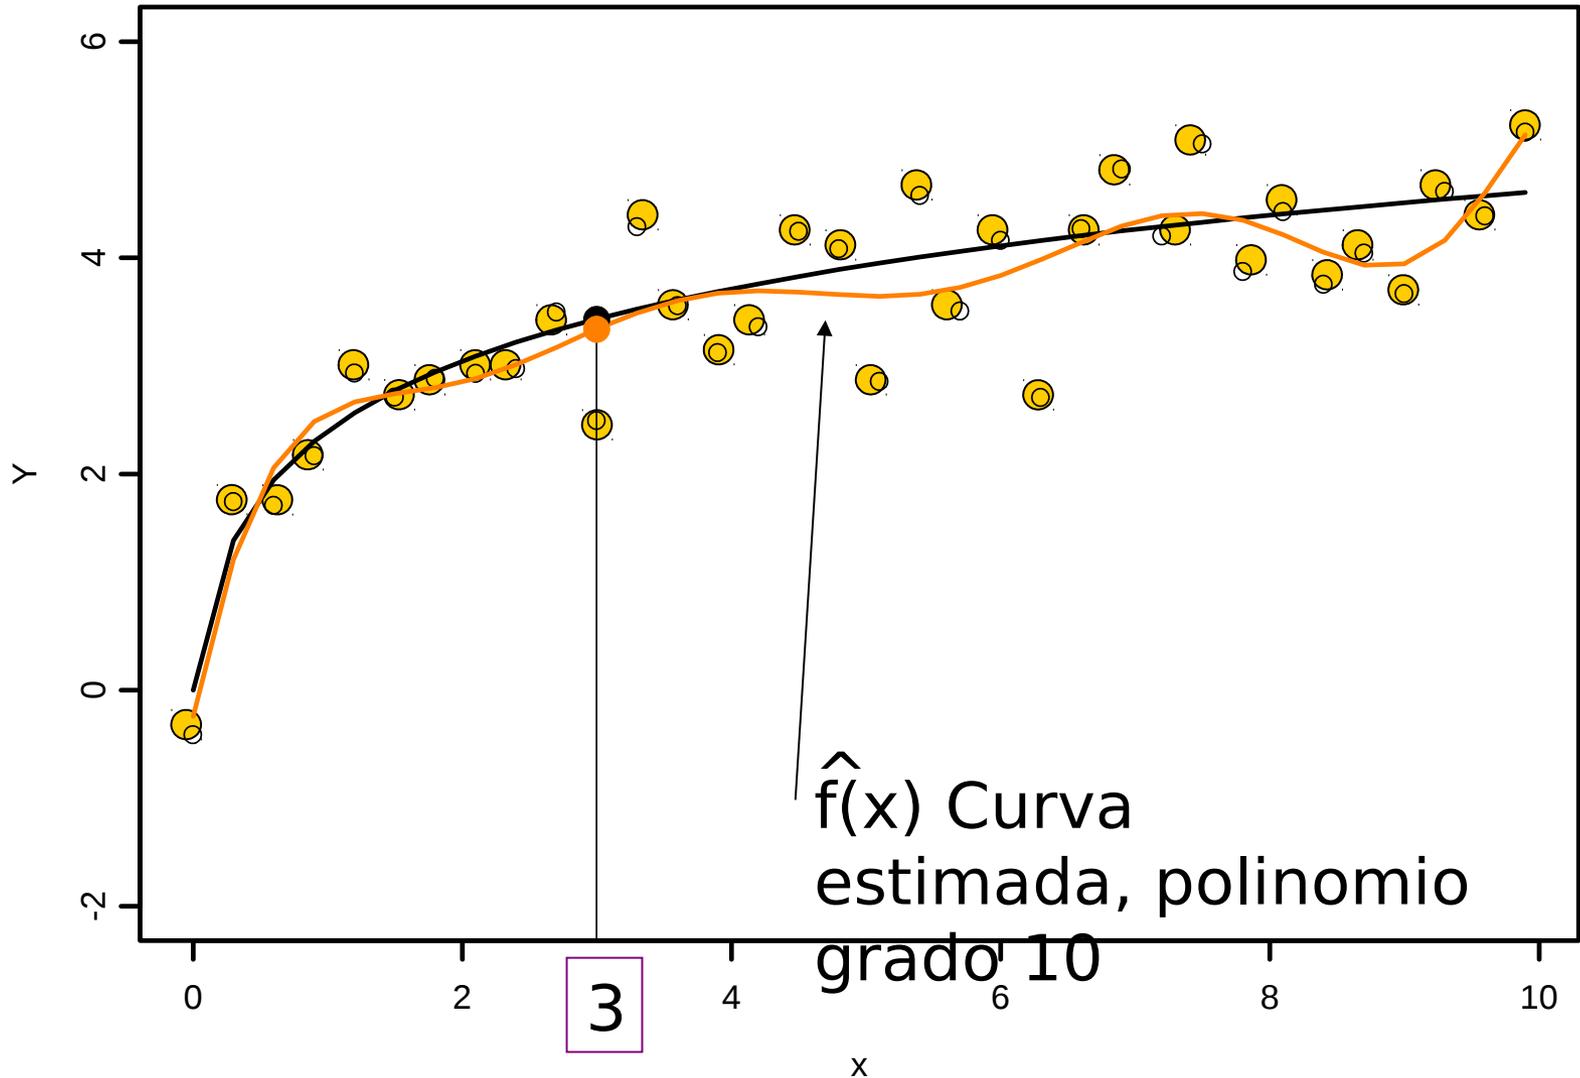
Tradeoff Sesgo - Varianza



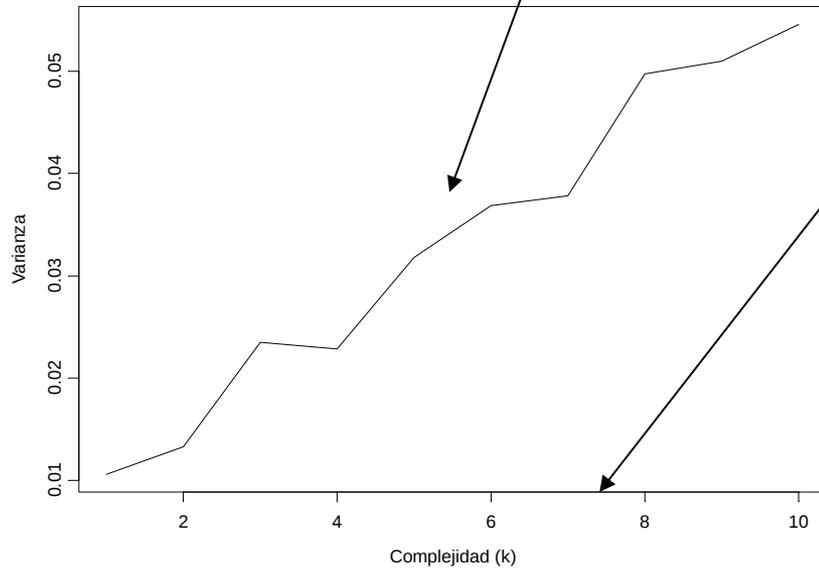
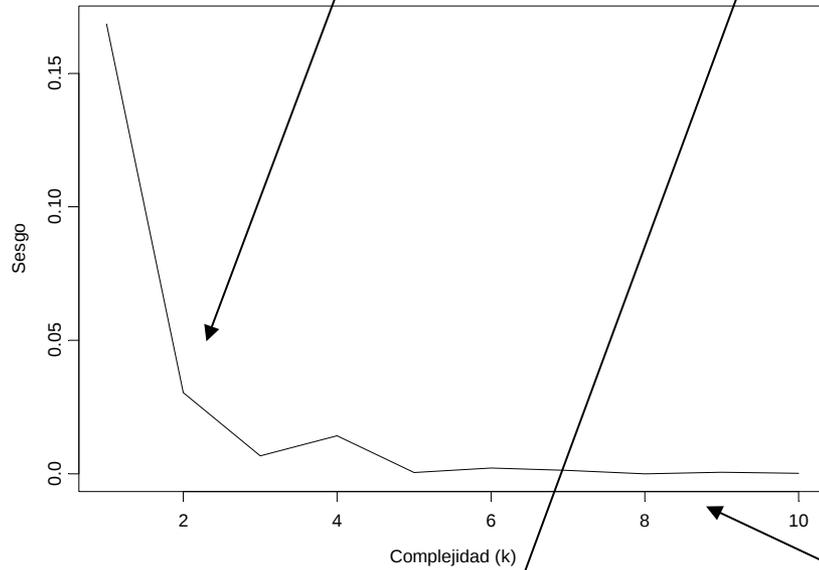
$$\text{Ajuste de } Y = f(X) + \varepsilon = \text{Ln}(10 * X + 1) + \varepsilon$$



$$\text{Ajuste de } Y = f(X) + \varepsilon = \text{Ln}(10 * X + 1) + \varepsilon$$

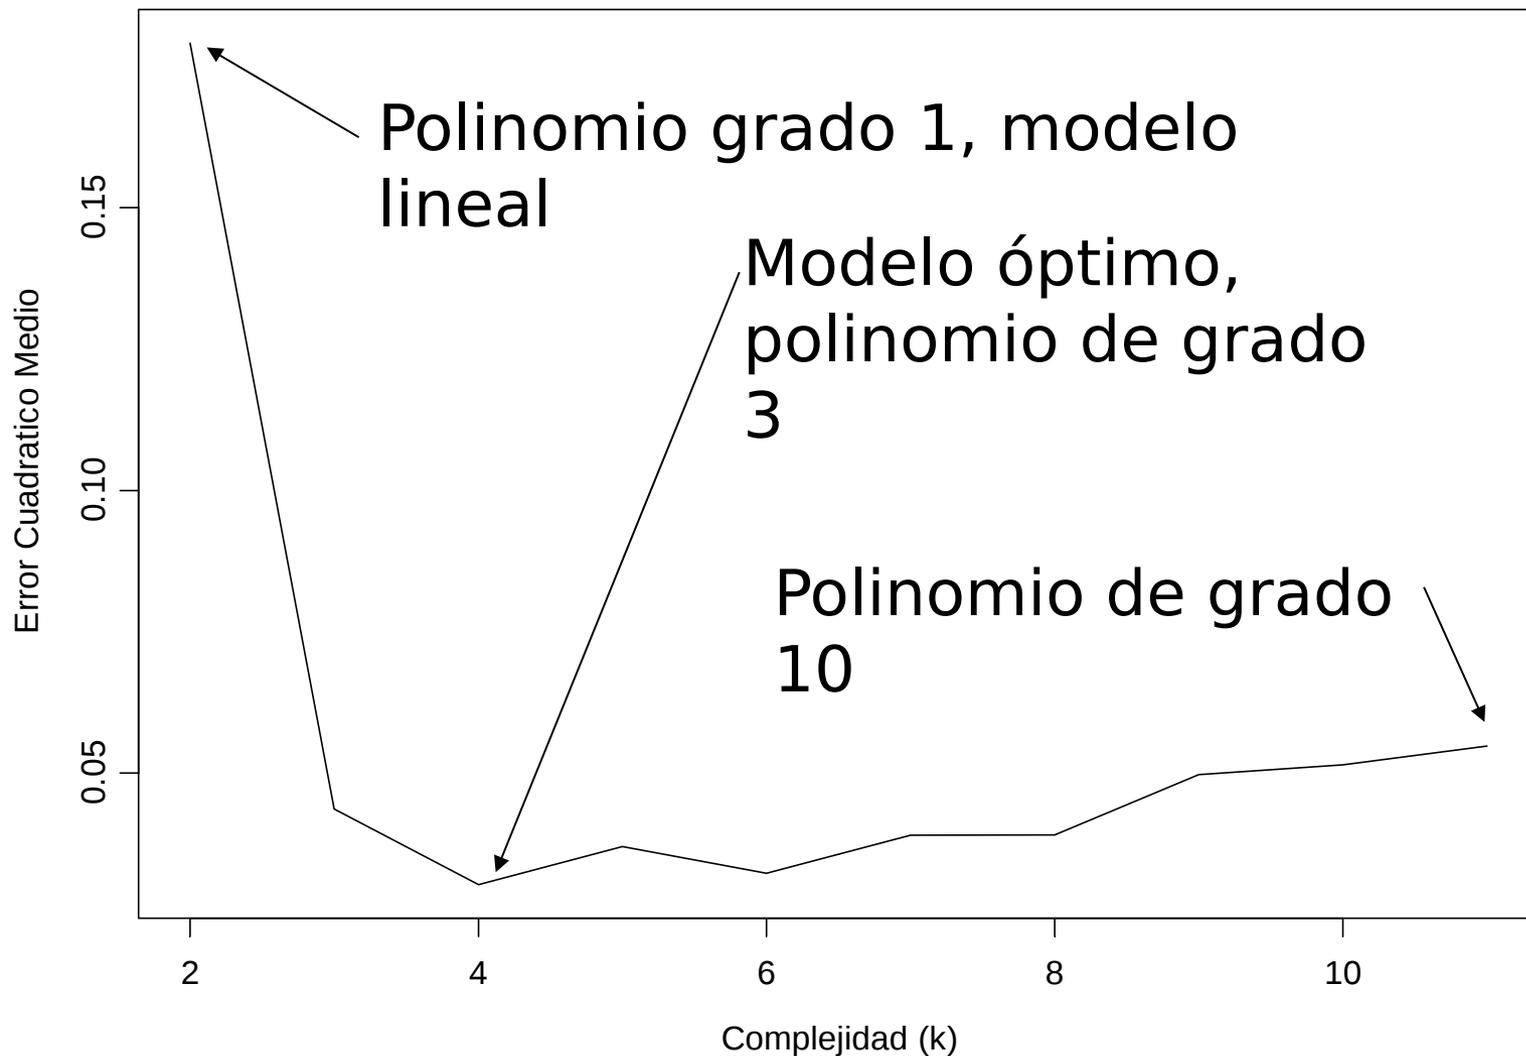


Tradeoff Sesgo - Varianza



Complejidad del Modelo = Grados del Polinomio

Curva de Error Cuadrático Medio

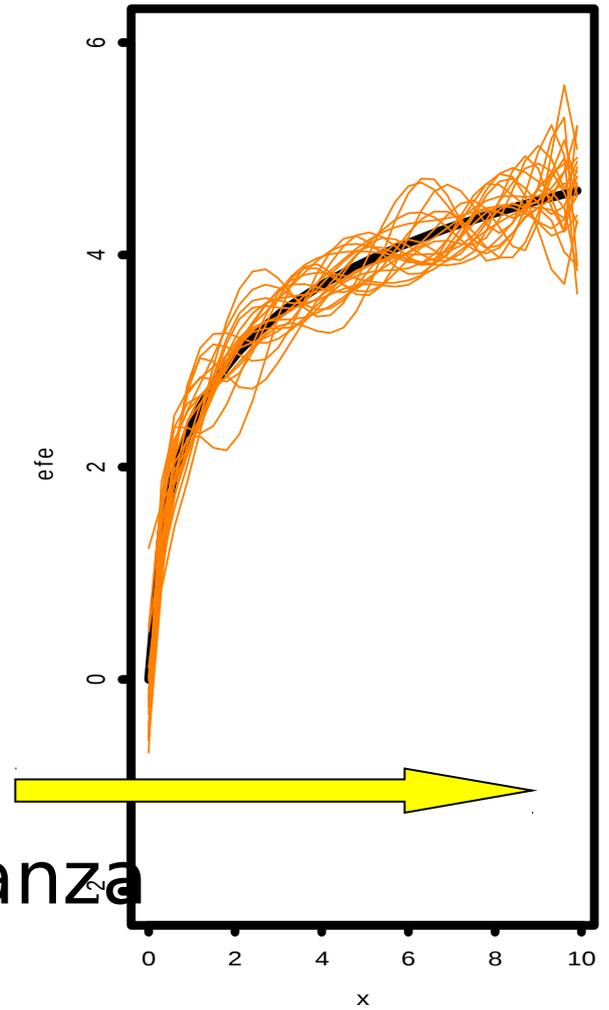
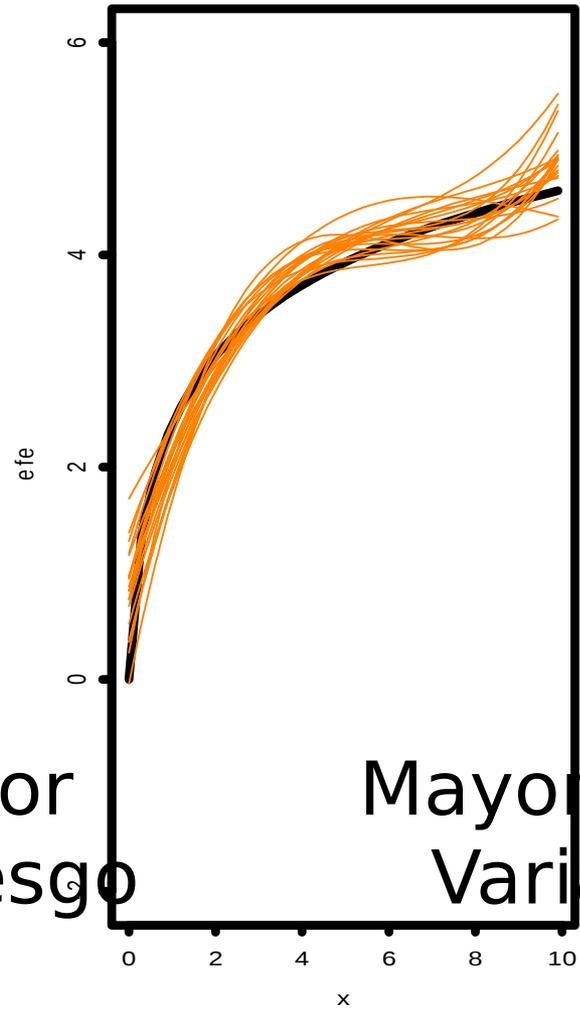
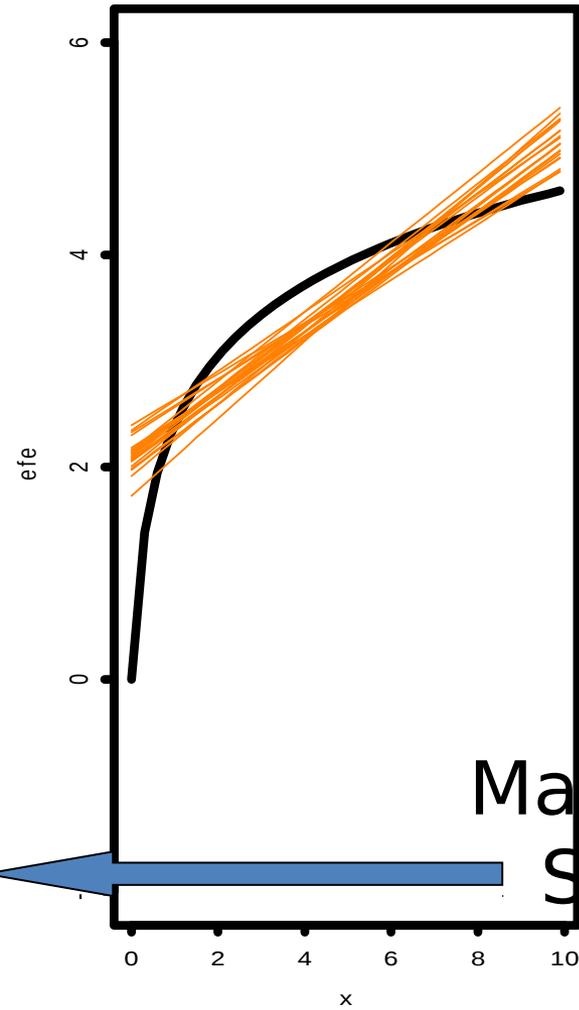


Tradeoff Sesgo-Varianza

Complejidad $k=2$
Polinomio grado 1

Complejidad $k=4$
Polinomio grado 3

Complejidad $k=11$
Polinomio grado 10



Overfitting (sobreajuste)

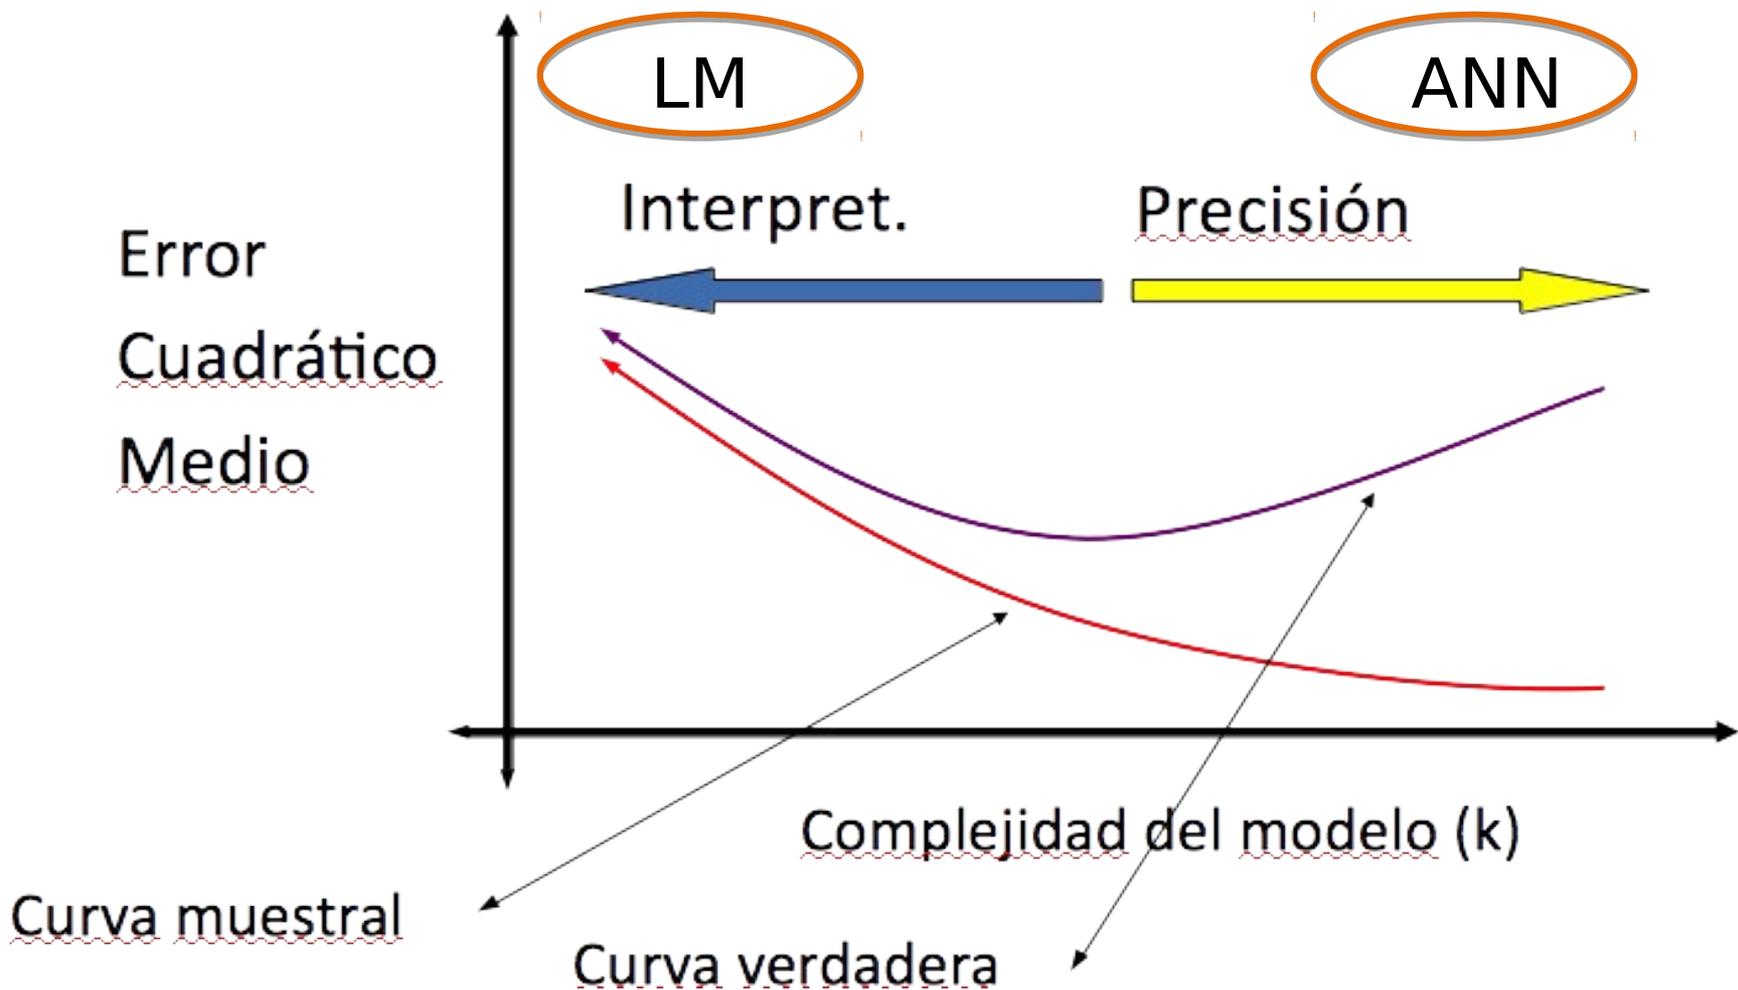
- Efecto nocivo que proviene de ajustar modelos con mas complejidad (menos parsimonia) que la que la cantidad de información muestral admite.
- Resultado de la **ALTA VARIABILIDAD** del estimador.
- Es MUCHO mas común que el SUBAJUSTE.
- Estamos genéticamente Programados para el OVERFITING !



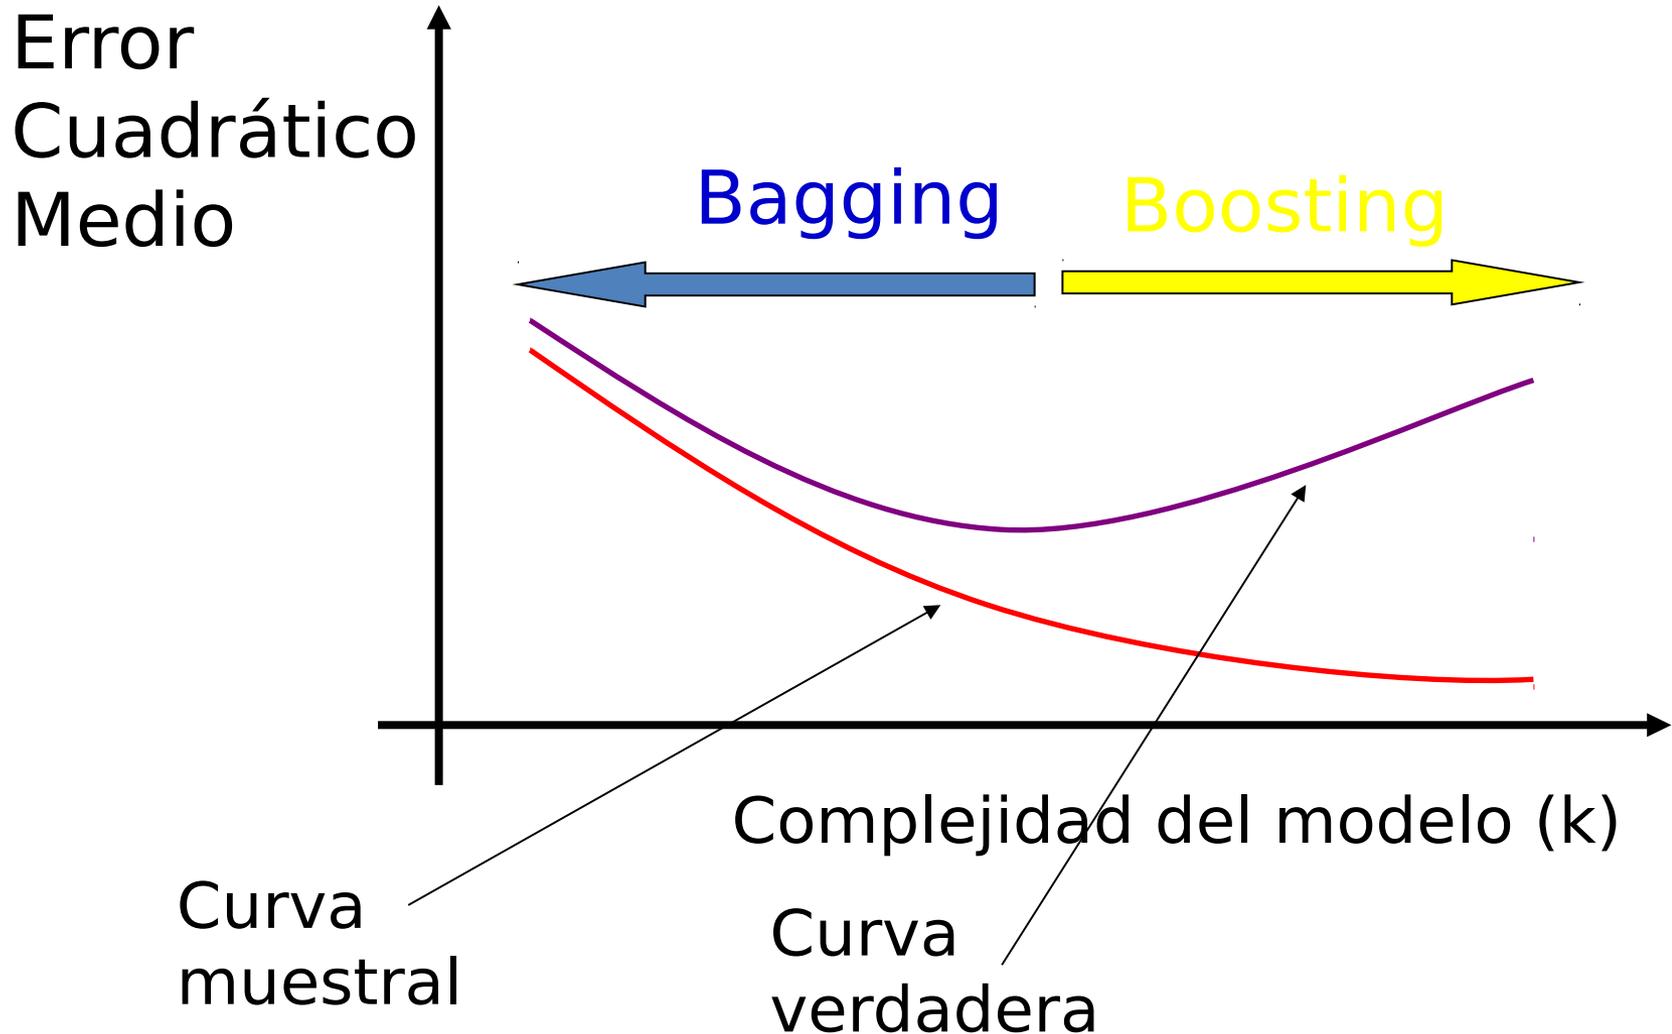
Solución al Overfitting

- Usar modelos poco complejos (mas parsimoniosos)
- Partir la muestra: Entrenamiento / Testeo
- Usar validación cruzada
- Bootstrap y Bagging
- Usar técnicas de “**Shrinkage**”, como:
 - Ridge Regression
 - LASSO Regression
 - Penalización o **Regularización**

Tradeoff Precisión - Interpretabilidad



Meta - Heurísticas



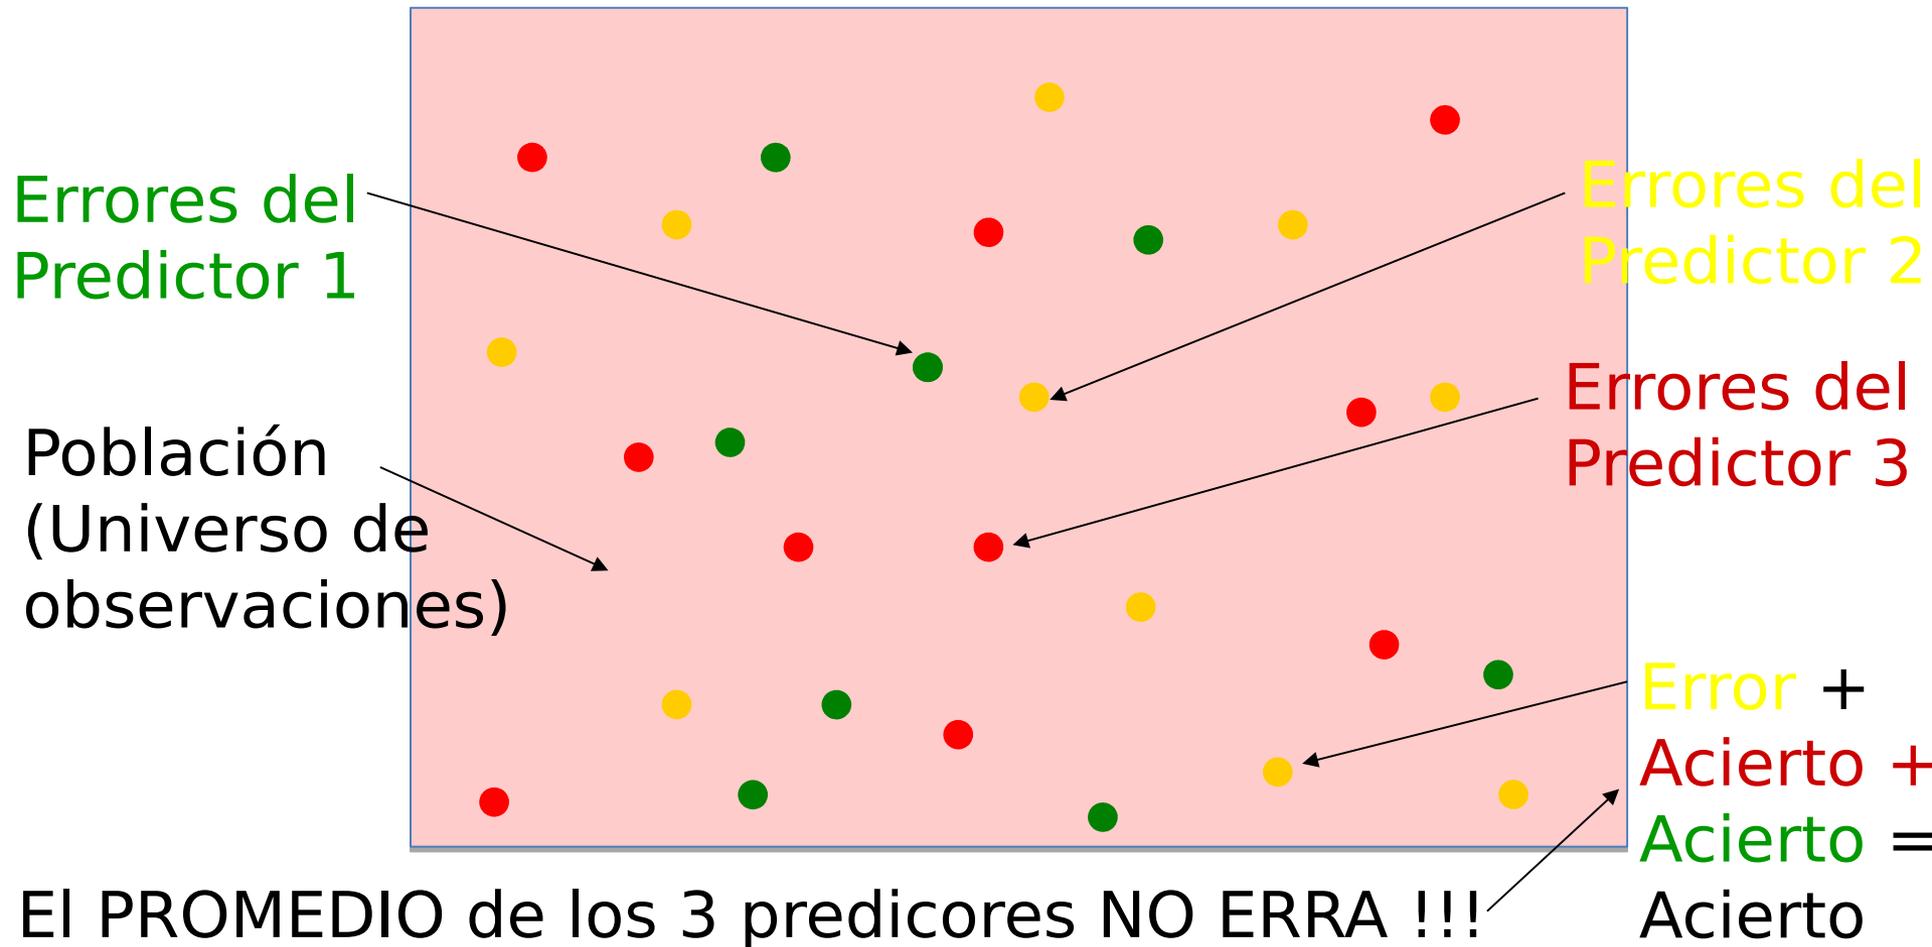
Bagging (Bootstrap Aggregating)

- Se basa en **PROMEDIAR** los resultados de iterar la aplicación de modelos **COMPLEJOS**, “**bootstrapeando**” la muestra de entrenamiento.
- Esta técnica reduce la **VARIANZA** típico de los modelos **COMPLEJOS**.

Intuición del Bagging en Clasificación

Los círculos de colores representan a las observaciones en las que los predictores erran.

Con 3 predictores COMPLEJOS (insesgados y muy variables) e INDEPENDIENTES



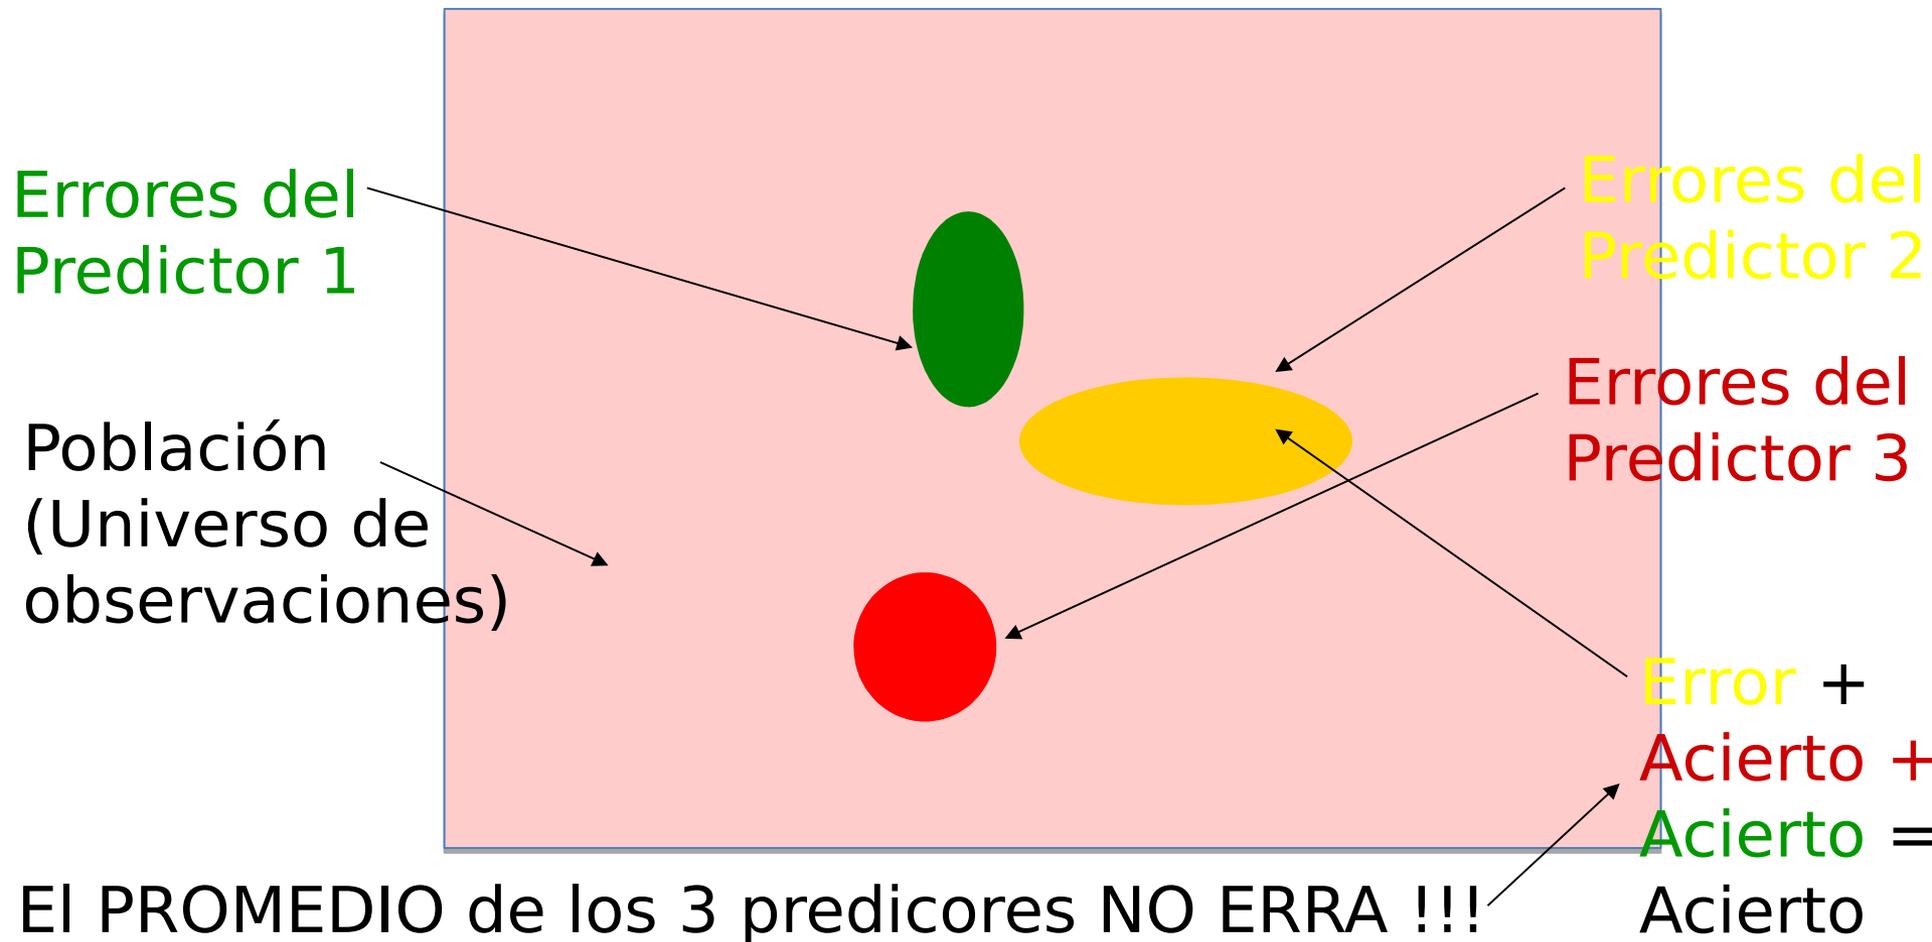
Boosting

- Se basa en **RE-ENTRENAR** iterativamente modelos **SIMPLES** aumentando la ponderación de las observaciones PEOR predichas.
- Esta técnica reduce el **SESGO** típico de los modelos **SIMPLES**.

Intuición del Boosting en Clasificación

Los círculos de colores representan a las observaciones en las que los predictores erran.

Con 3 predictores SIMPLES (sesgados y poco variables) e INDEPENDIENTES

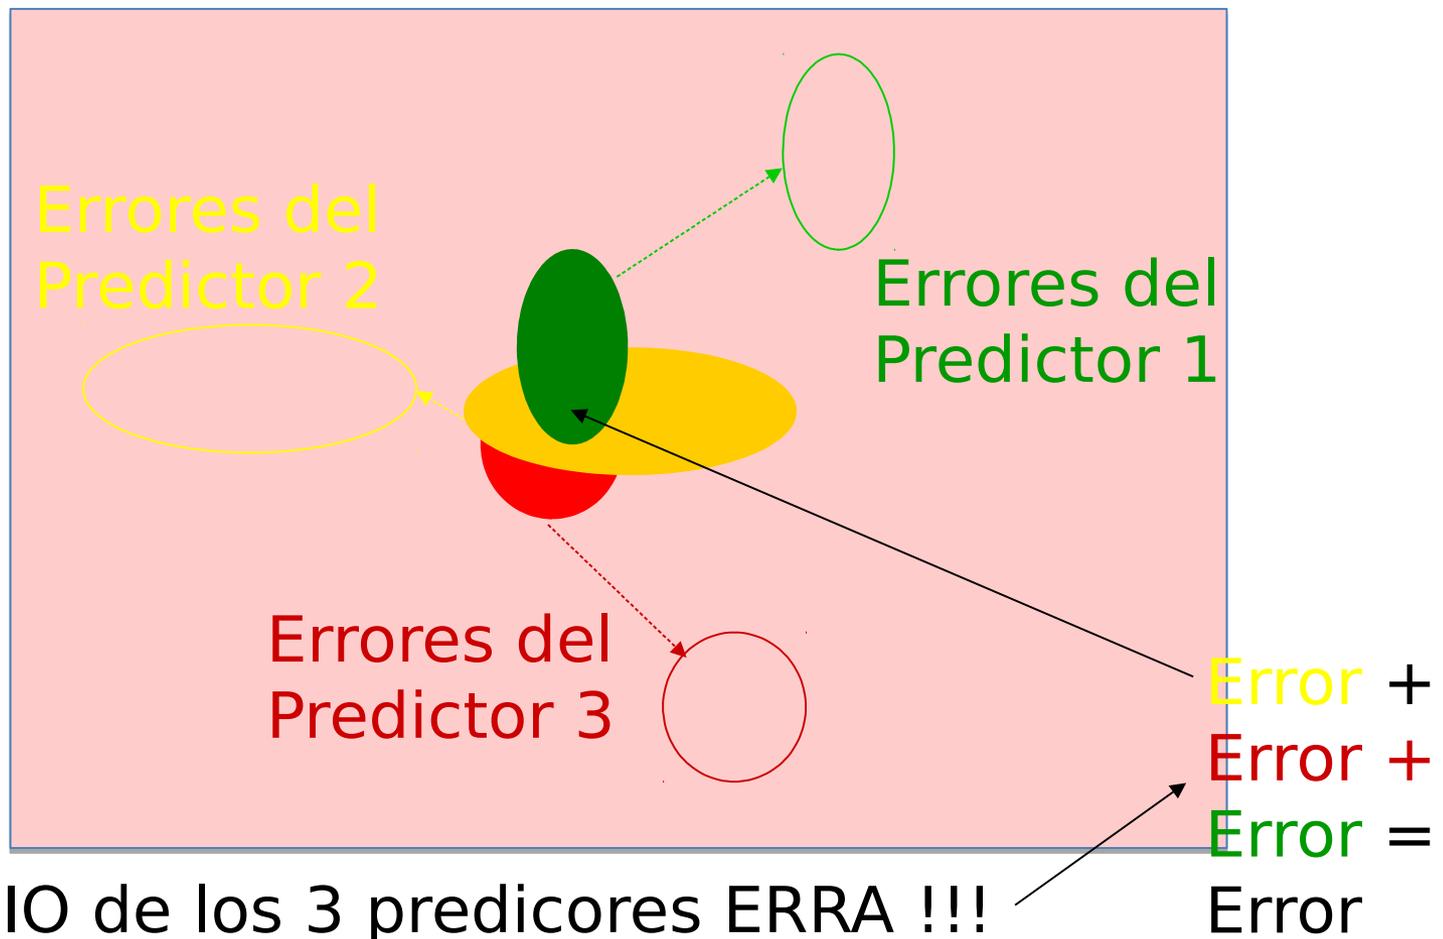


En la Práctica: Boosting en Clasificación

Con 3 predictores SIMPLES (sesgados y poco variables) que

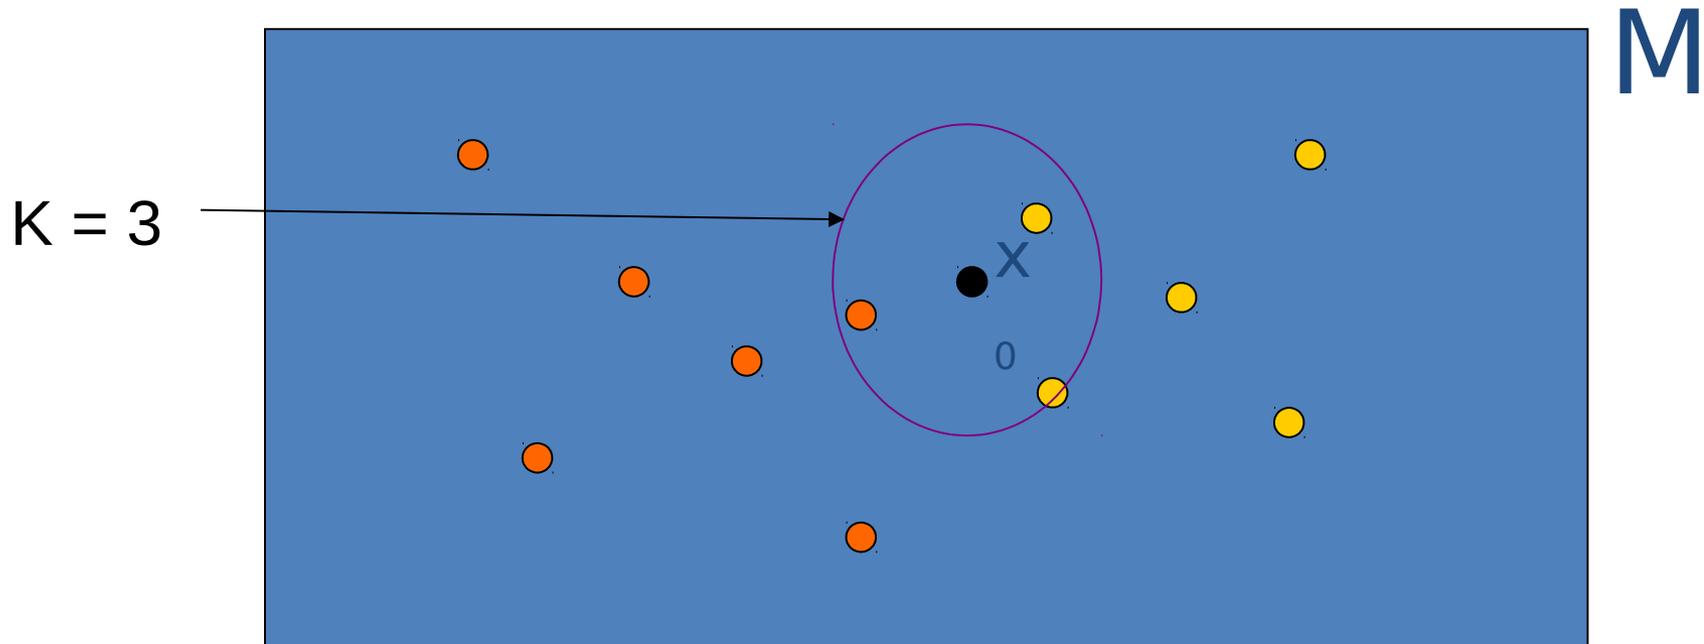
NO SON INDEPENDIENTES

¿ Como SEPARAMOS las regiones de ERROR de los predictores?



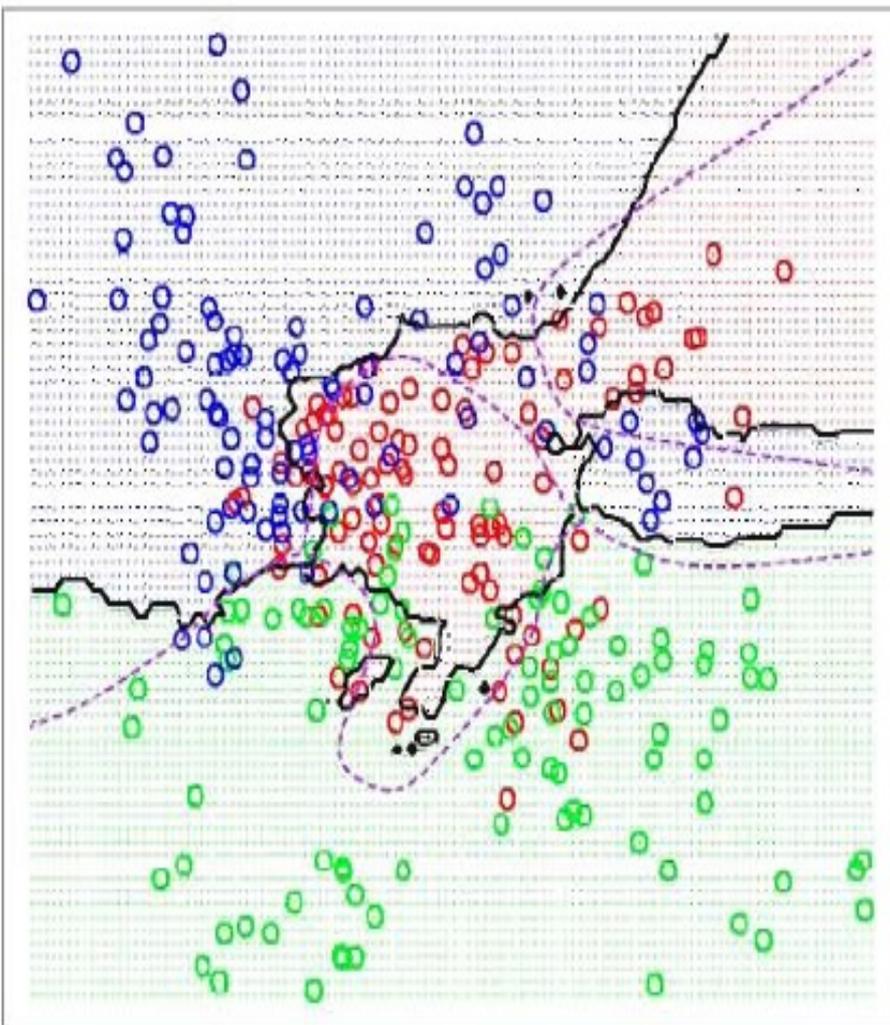
K vecinos mas cercanos (KNN)

- Dada una nueva observación X_0 , la clasifico en aquella población que posee una representación mayoritaria entre los K vecinos mas cercanos a X_0 .

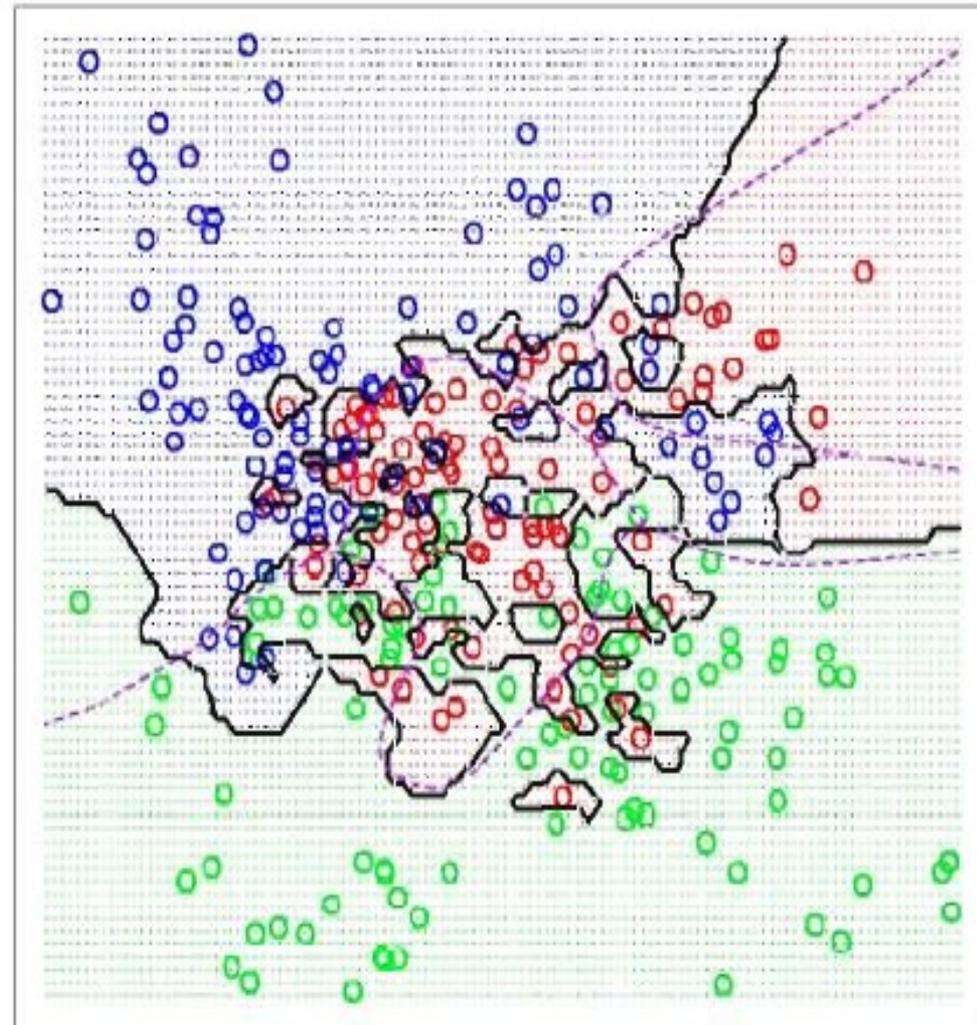


Ejemplo gráfico

15-Nearest Neighbors



1-Nearest Neighbor



Estimando el error de testeo

TRAIN /
TEST

Se divide la muestra en 2 partes: muestra de entrenamiento y muestra de testeo.

Se ajusta el modelo usando la muestra de entrenamiento y el modelo ajustado se usa para predecir las respuestas de la muestra de testeo

El error cuadrático medio calculado con las observaciones de la muestra de testeo es un estimador del error de testeo.

LOOCV

Validación cruzada *Leave one out*

Una sola observación se usa como muestra de testeo y todas las demás como muestra de entrenamiento. Supongamos que sacamos (\mathbf{x}_1, y_1)

$$ECM_1 = (y_1 - \hat{y}_1)^2$$

es un estimador "aproximadamente insesgado" del error de testeo. Este procedimiento se repite n veces, dejando afuera una observación cada vez. Obtenemos

$$ECM_1, ECM_2, \dots, ECM_n.$$

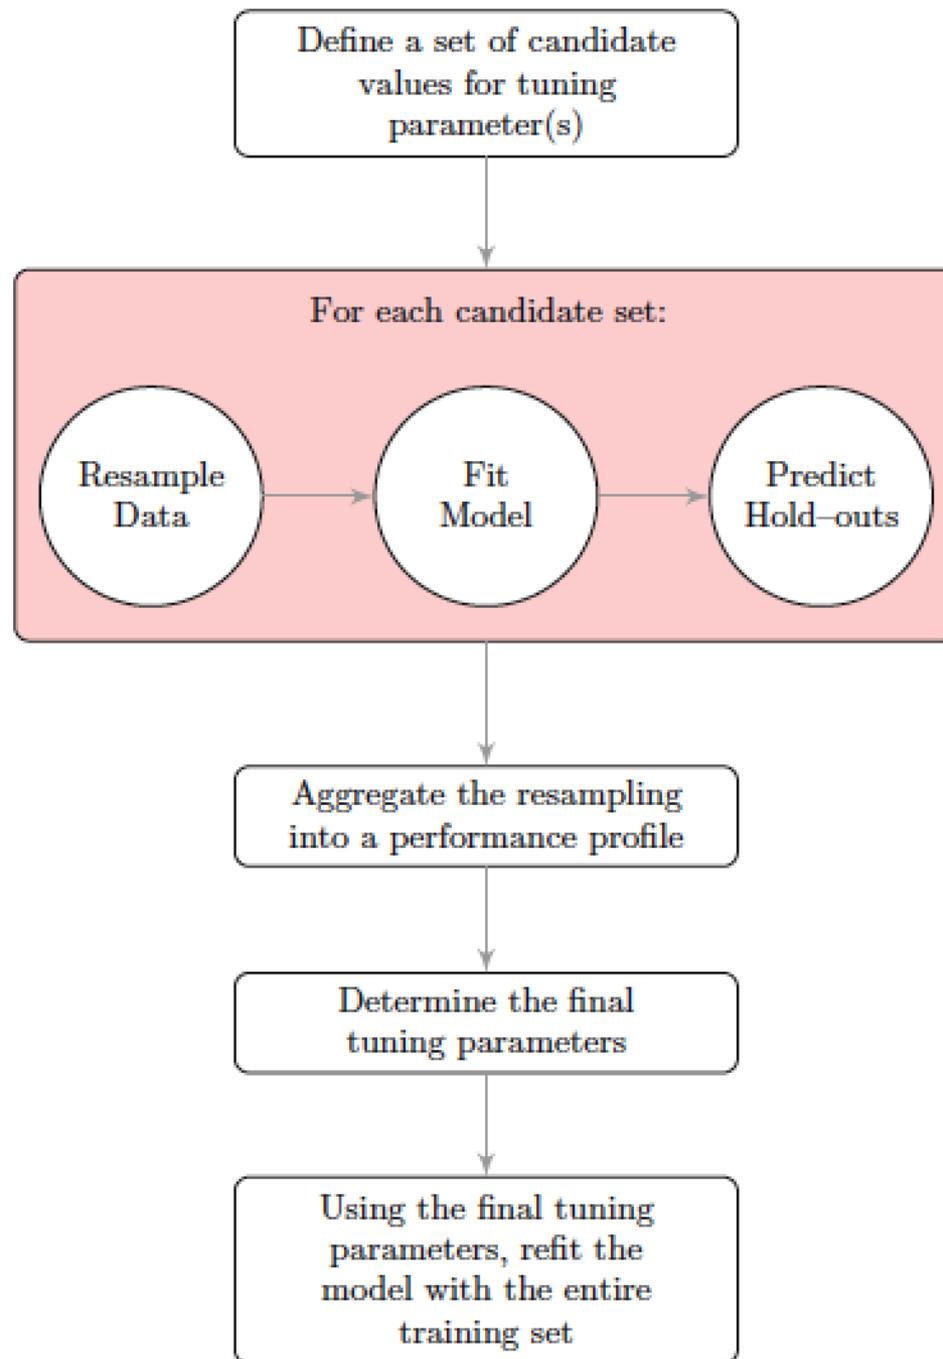
El estimador *LOOCV* del error de testeo es el promedio de estos :

$$ECM_k = \frac{1}{n} \sum_{i=1}^n ECM_i.$$

LOOCV Versus TRAIN/TEST

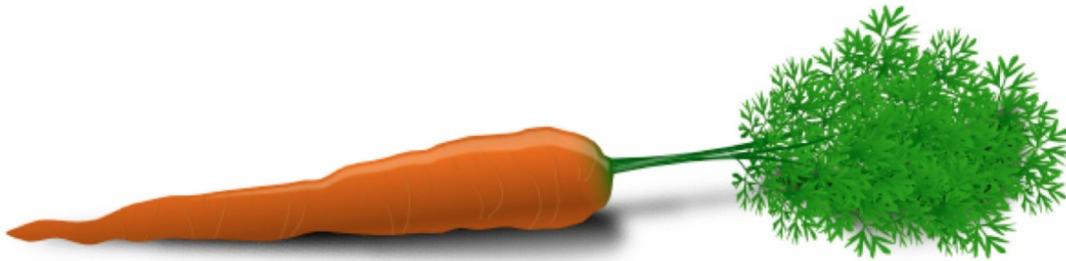
- ▶ Dividir a la muestra en submuestra de entrenamiento y de testeo da un estimador del error de **testeo sesgado**.
- ▶ LOOCV da estimadores aproximadamente insesgados del error de testeo, pero tienen **mayor varianza**.
- ▶ 5-fold o 10-fold cv es conveniente porque da un buen compromiso entre sesgo y varianza.

K-fold CV



The caret R package

the caret package



The **caret** package (short for Classification And REgression Training) is a set of functions that attempt to streamline the process for creating predictive models. The package contains tools for:

<http://caret.r-forge.r-project.org/>

Links

[train Model List](#)

Topics

[Main Page](#)

[Data Sets](#)

[Visualizations](#)

[Pre-Processing](#)