



Minería de datos: Modelos de Predicción, Modelos de Descripción, y usos en IN

Jose Aguilar
CEMISID, Escuela de Sistemas
Facultad de Ingeniería
Universidad de Los Andes
Mérida, Venezuela

Modelos de Predicción: clasificación,
regresión, series temporales, etc.

Clasificación

- Dada una colección de registros (conjunto de entrenamiento)
 - Cada registro contiene un conjunto de atributos, uno de los atributos es la clase.
- Encontrar un modelo para cada clase de atributo en función de los valores de otros atributos.
- Meta: registros deben ser asignados a una clase con la mayor precisión posible.
- Un conjunto de prueba se utiliza para determinar la precisión del modelo.
- Por lo general, el conjunto de datos dado se divide en conjunto de entrenamiento y de prueba (utilizado para construir el modelo y para validarlo, respectivamente).

Clasificación

Email: Spam / No es Spam?

Transacciones en línea: Fraudulento (Si / No)?

Tumor: Maligno / Benigno ?



0: “Clase negativa” (tumor benigno)

1: “Clase positiva” (tumor malignano)

Clasificación

categoria

categoria

continuo

clase

Tid	Refund	Marital Status	Taxable Income	Cheat
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

Refund	Marital Status	Taxable Income	Cheat
No	Single	75K	?
Yes	Married	50K	?
No	Married	150K	?
Yes	Divorced	90K	?
No	Single	40K	?
No	Married	80K	?



Clasificación

Detección de Fraude

Objetivo: Predecir casos fraudulentos en las transacciones con tarjetas de crédito.

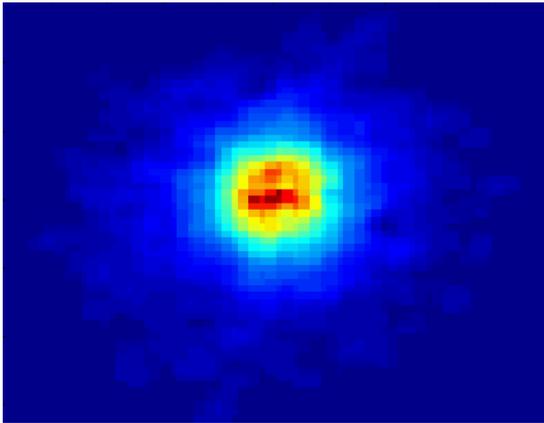
Enfoque:

- Utilice las transacciones con tarjeta de crédito y la información sobre su cuenta de titular como atributos.
 - ¿Cuándo comprar un cliente?, ¿qué quiere comprar?, ¿con qué frecuencia se paga a tiempo?, etc.
- Etiquetar transacciones pasadas, fraude o transacciones justas. Esto forma el atributo de clase.
- Aprende un modelo para la clase de las transacciones.
- Utilice este modelo para detectar el fraude mediante la observación de las transacciones de tarjetas de crédito en una cuenta.

Clasificación

<http://aps.umn.edu>

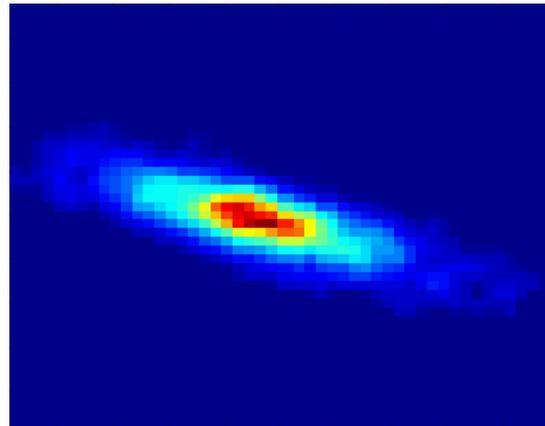
Temprano



Clase:

- Edo Formación

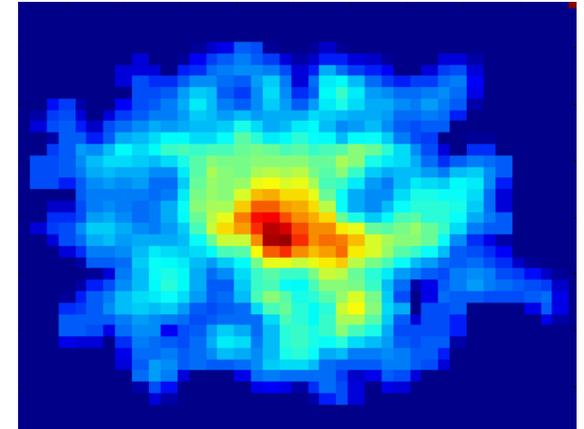
Intermediate



Atributos:

- **Caract. Imagen,**
- **Caract. Ondas luz, etc.**

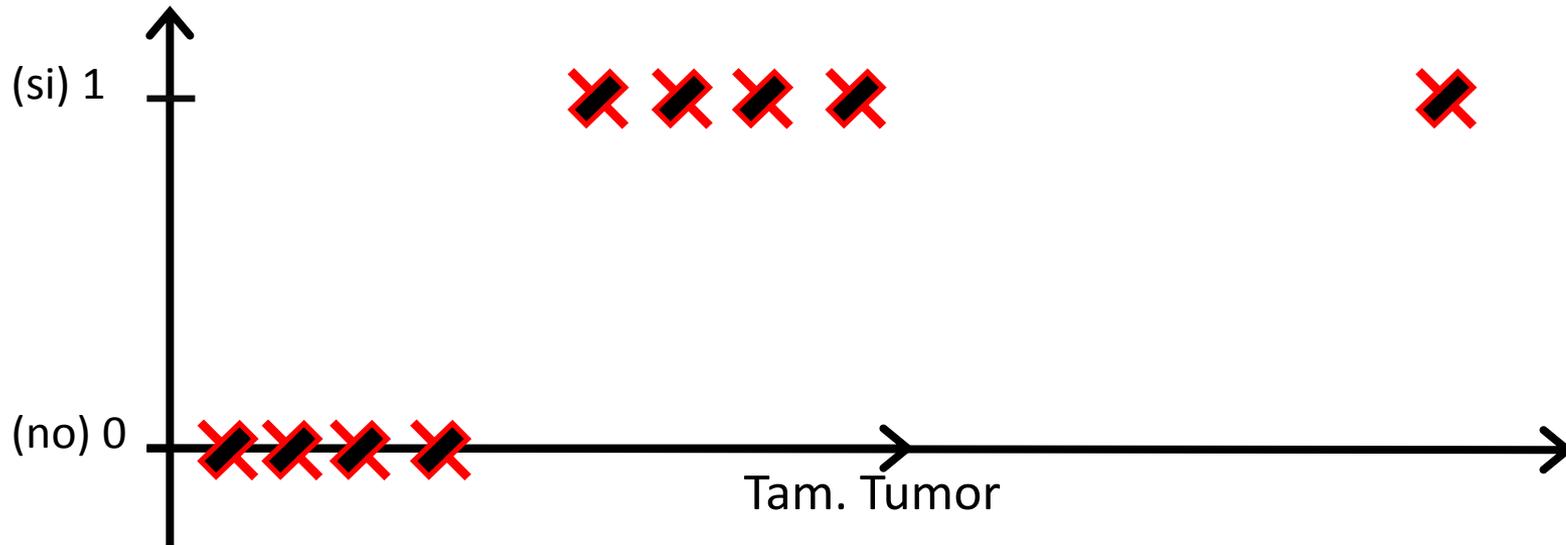
Tarde



Tam. datos:

- 72 millones estrellas, 20 millones galaxias
- BD Objetivo: 9 GB
- BD Imagen: 150 GB

Clasificación



Umbral clasificador

$$h_{\theta}(x) = 0.5:$$

Si , predice "y = 1"

Si , predice "y = 0"

Regresión

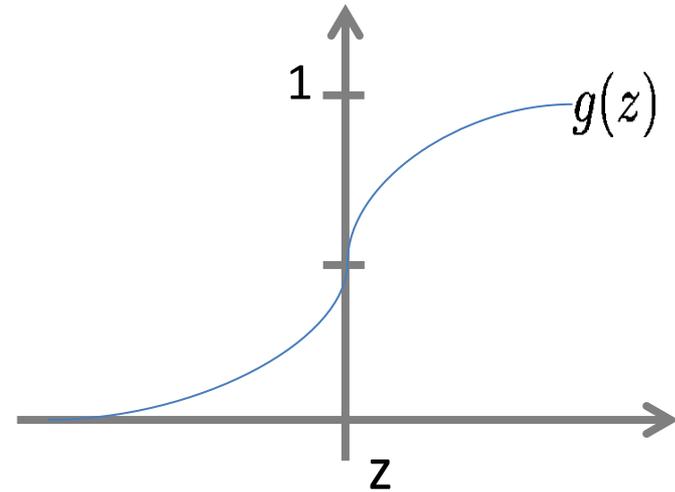
- Predice un valor de una variable valoradas continua dada sobre la base de los valores de otras variables, suponiendo un modelo lineal o no lineal de dependencia.
- Ejemplos:
 - Predecir las ventas de nuevos productos basados en gastos de publicidad.
 - La predicción de la velocidad del viento como una función de la temperatura, humedad, presión de aire, etc.
 - Predicción de series de tiempo de los índices bursátiles.

Clasificación y Regresión

Regresión Lógica :



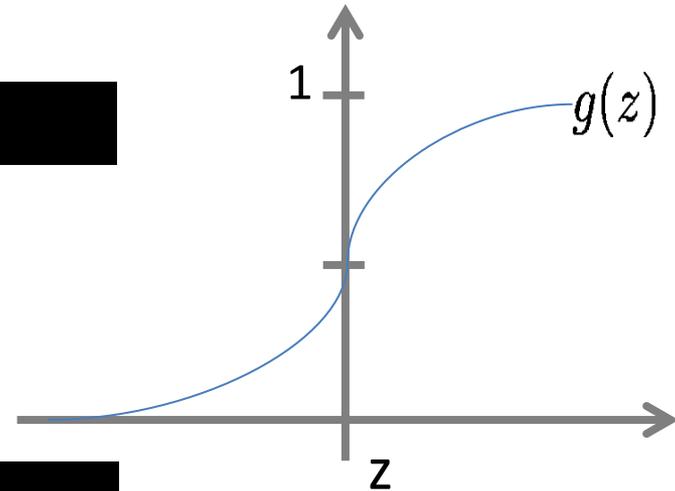
Regresión Lógica



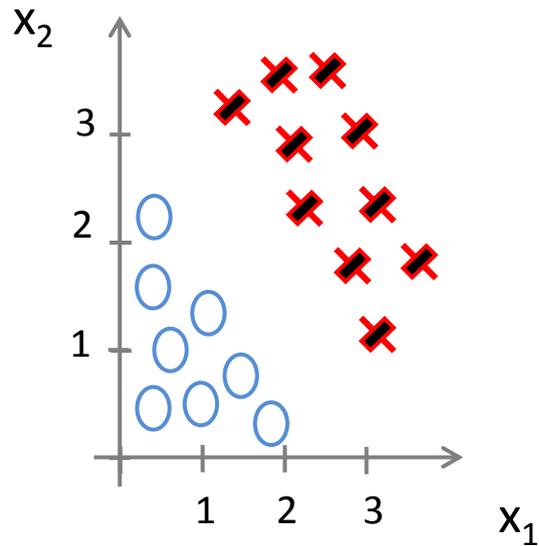
Regresión Lógica: Barrera de decisión

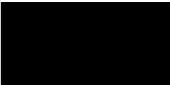
predice " $y = 1$ " si

predice " $y = 0$ " si

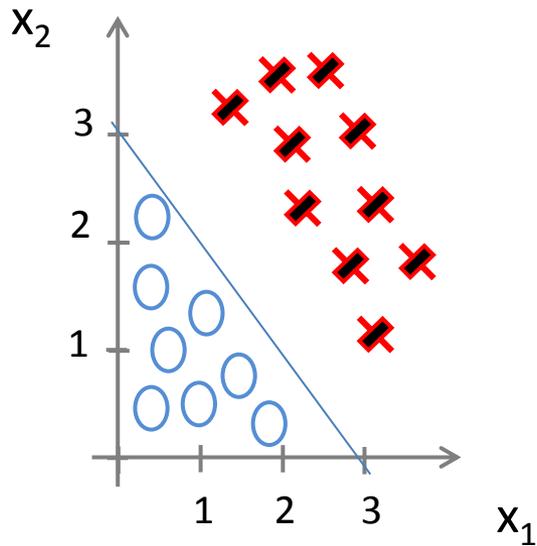


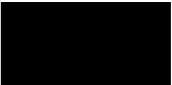
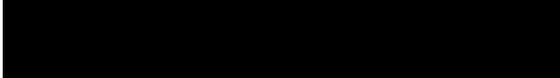
Regresión Lógica: Barrera de decisión



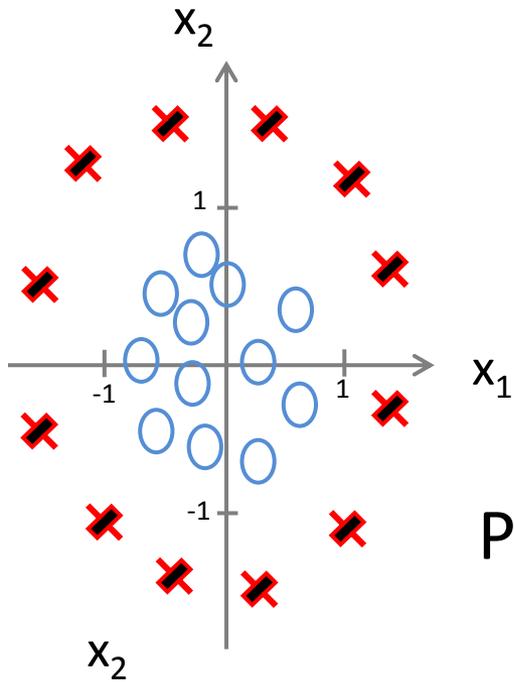
Predice “” si 

Regresión Lógica: Barrera de decisión



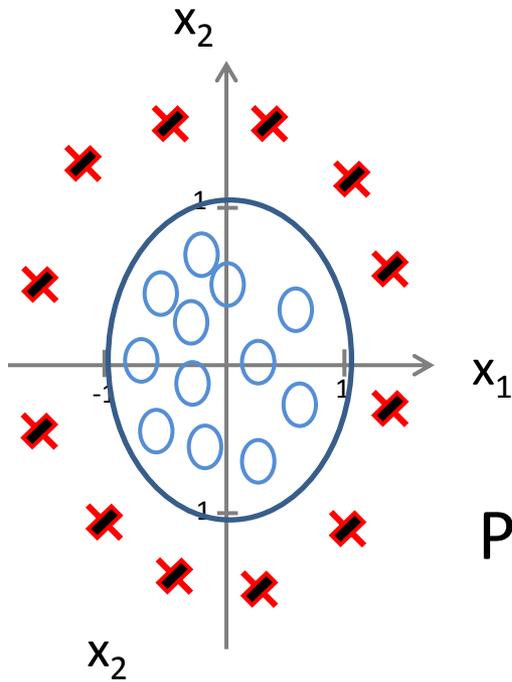
Predice “” si 

Regresión Lógica: Barrera de decisión



Predice “” si 

Regresión Lógica: Barrera de decisión



Predice “” si 

Regresión Lógica: Función de costos

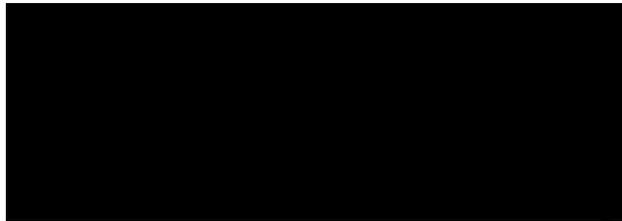
Conjunto de
entrenamiento:



m ejemplos

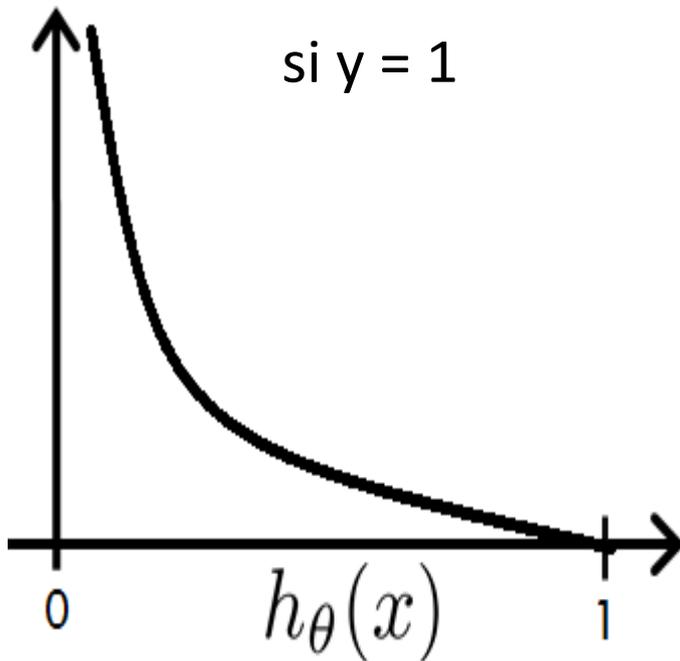
$$x \in \begin{bmatrix} x_0 \\ x_1 \\ \dots \\ x_n \end{bmatrix}$$

$$y \in \{0, 1\}$$



Como escoger los parámetros? ■

Regresión Lógica: Función de costos



si $y = 1$

$Cost = 0$ si $y=1, h_\theta(x) = 1$

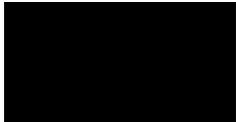
Pero cuando

$$h_\theta(x) \rightarrow 0$$

$$Cost \rightarrow \infty$$

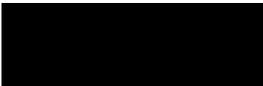
(predice $P(y = 1 | x; \theta) = 0$)

Regresión Lógica: Función de costos



Gradiente descendiente



Queremos  :

Repeat {

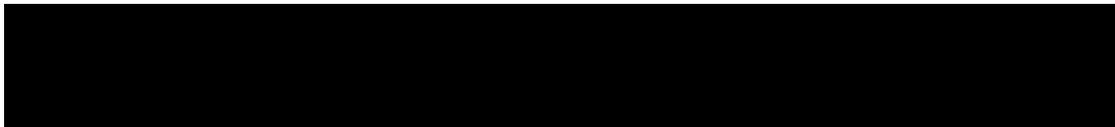
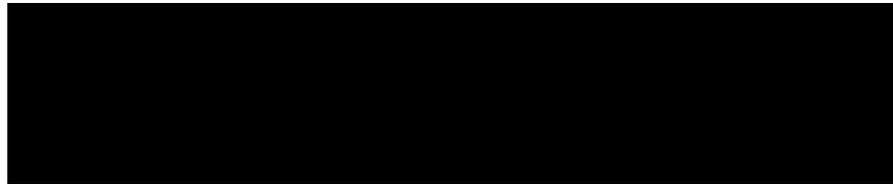


(simultaneously update all θ_j .)

}

Función de costos

Regresión lineal:



Optimización

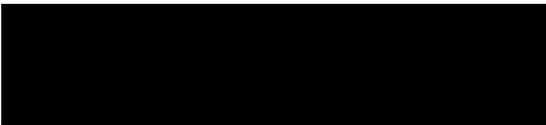
$J(\theta)$ 

Dado θ , queremos calcular

- $J(\theta)$

- 

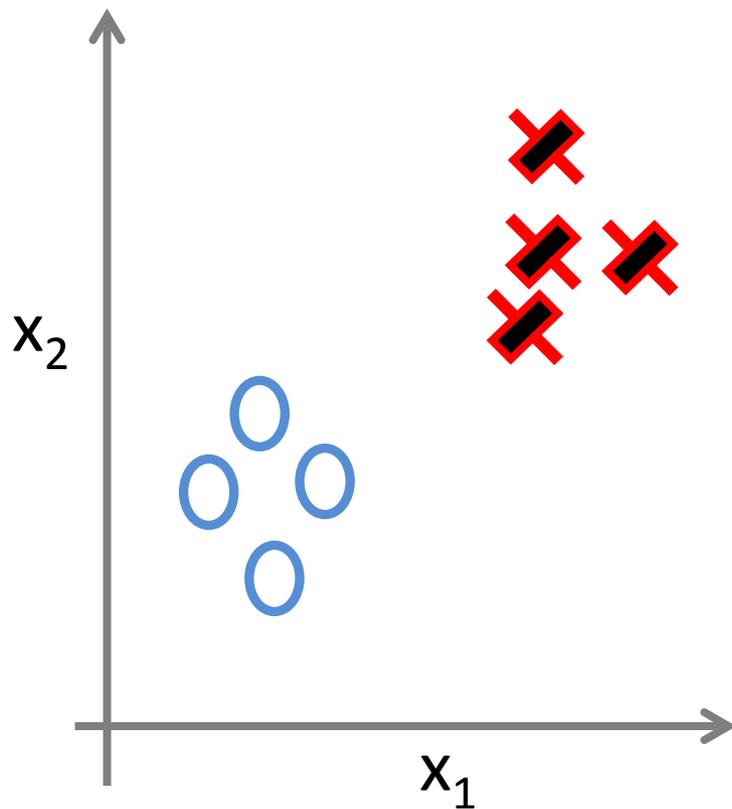
(for  {



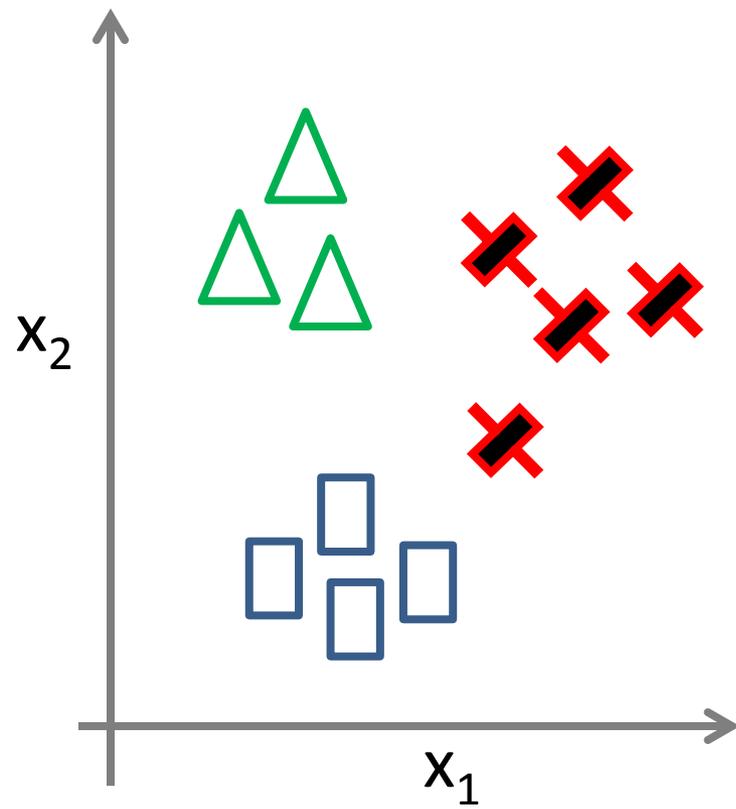
}

Clasificación multi-clases

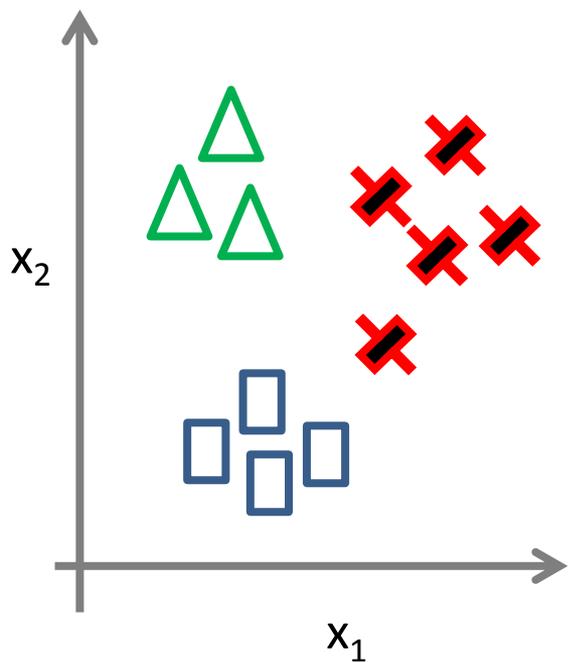
Clasificación Binaria



Clasificación Multi-clases



Una-vs-todos (uno-vs-resto):



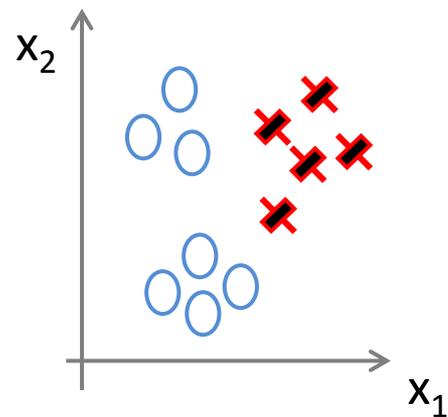
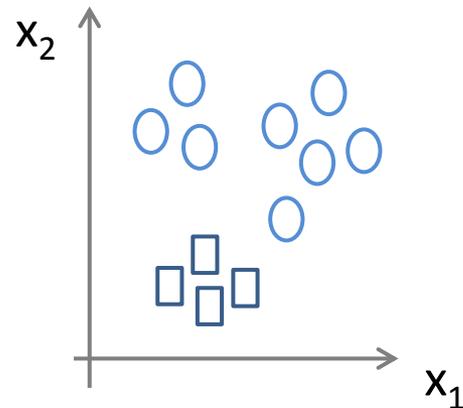
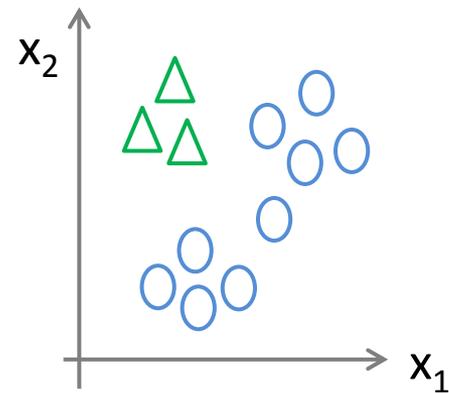
Clase 1: 

Clase 2: 

Clase 3: 



$(i = 1, 2, 3)$

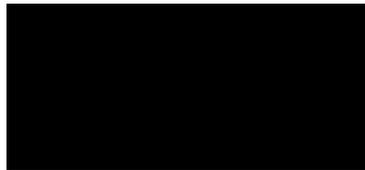


Uno vs Todo

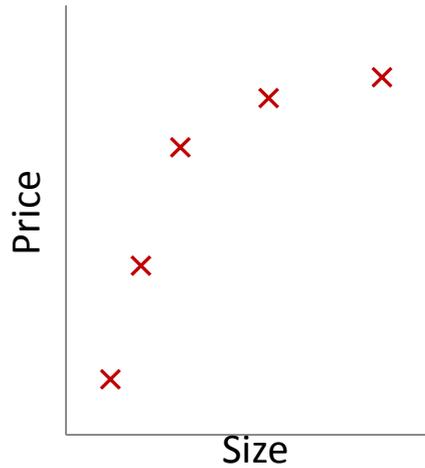
Entrenar a un clasificador de regresión logística $h_{\theta}^{(i)}(x)$
por cada clase \blacksquare para predecir la probabilidad de



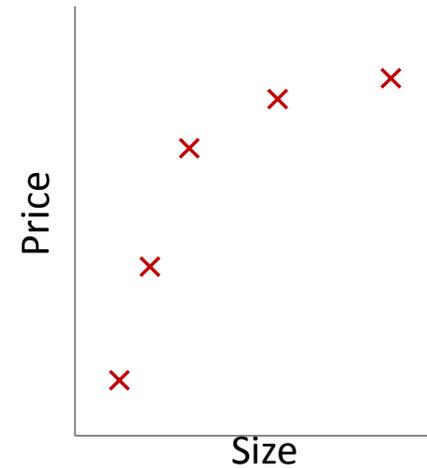
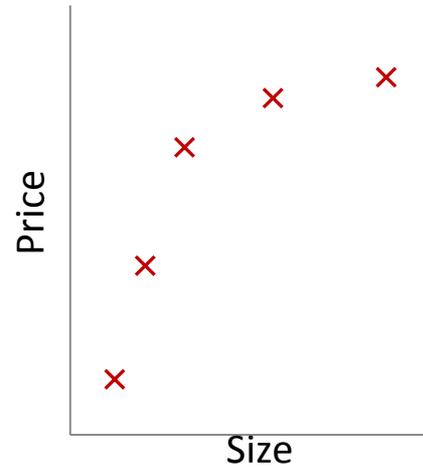
Con una nueva entrada \blacksquare , para hacer predicción se
toma la clase \blacksquare que maximice



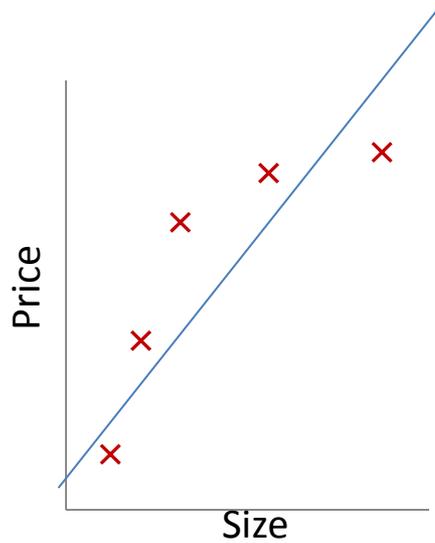
Sobre-ajustamiento (Overfitting)



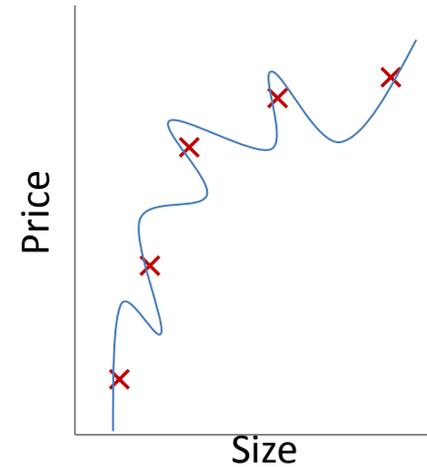
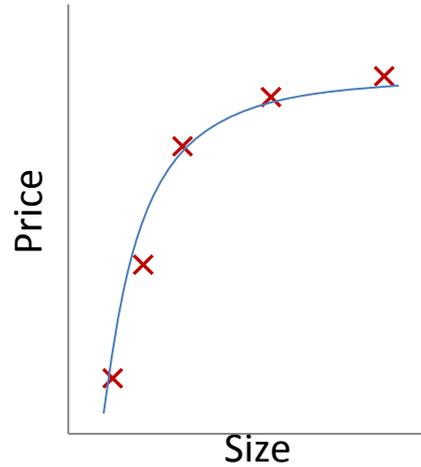
$$\theta_0 + \theta_1 x$$



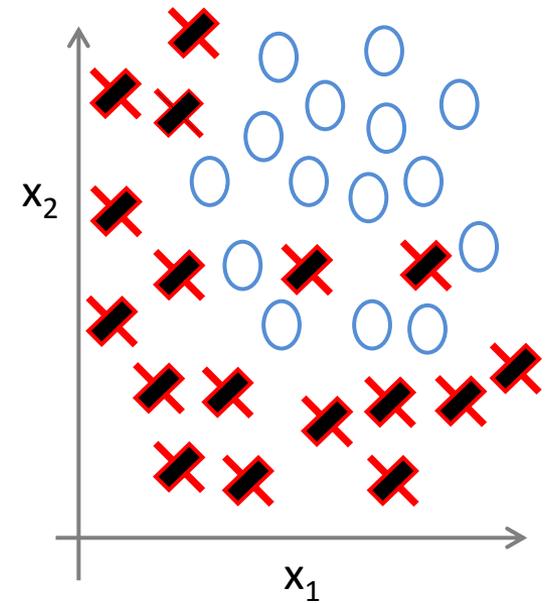
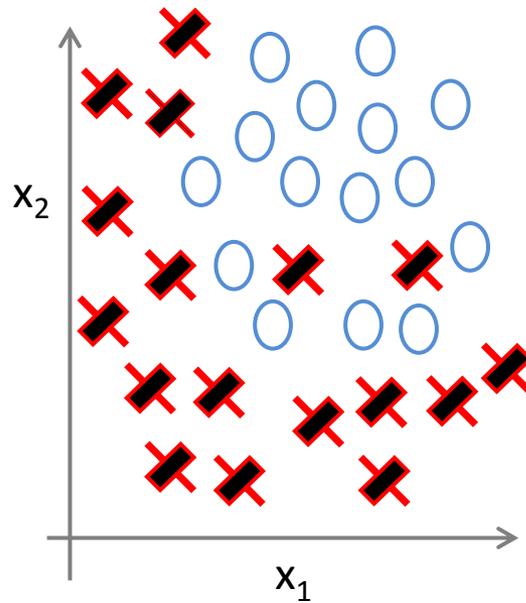
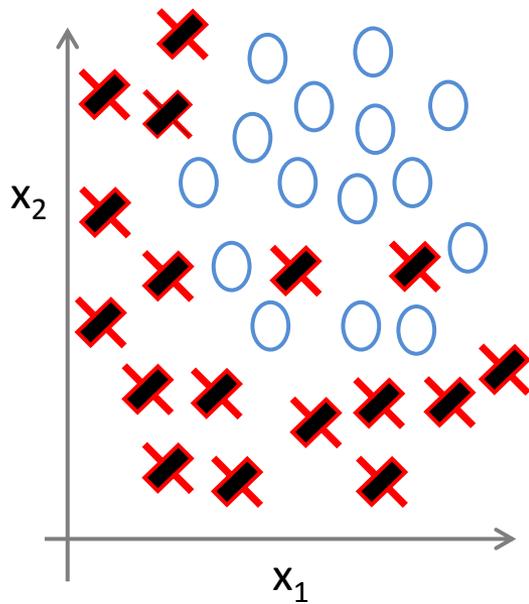
Sobre-ajustamiento (Overfitting)



$$\theta_0 + \theta_1 x$$

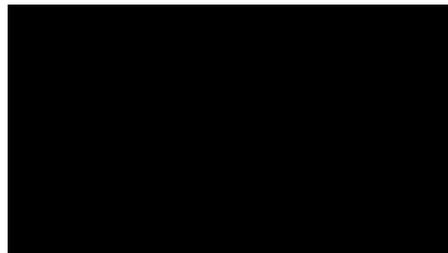


Sobre-ajustamiento (Overfitting)

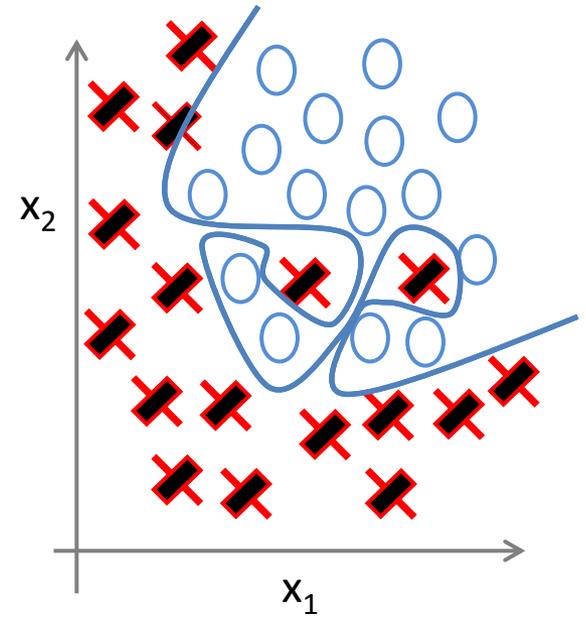
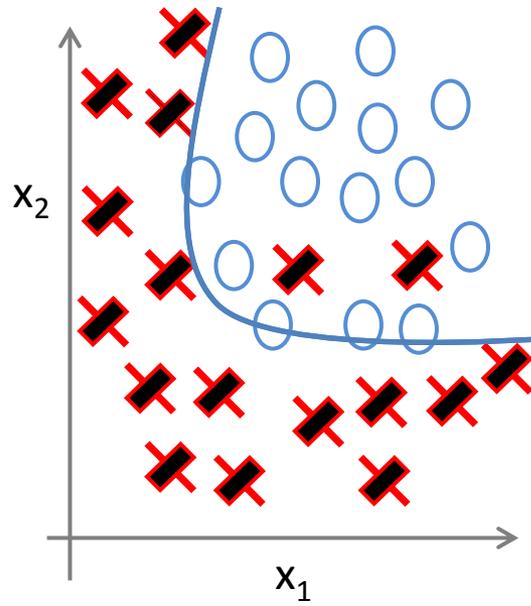
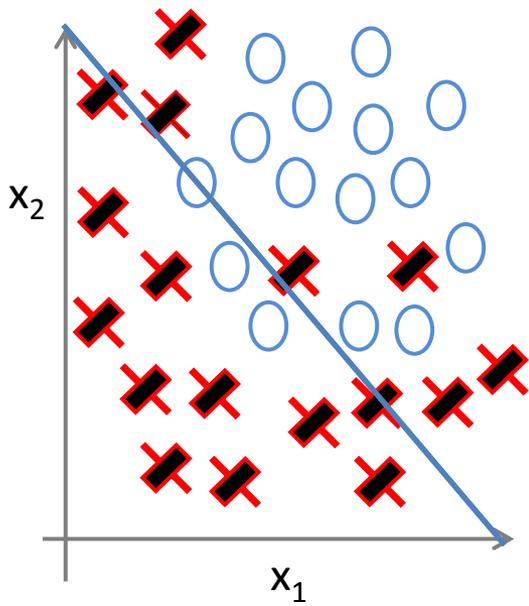


$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2)$$


(g = función sigmoïdal)



sigmoidal



$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2)$$

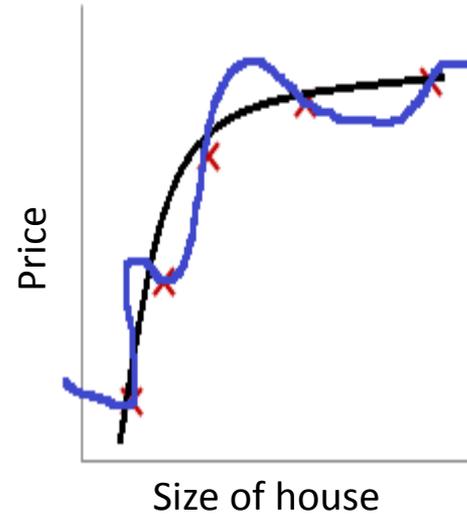
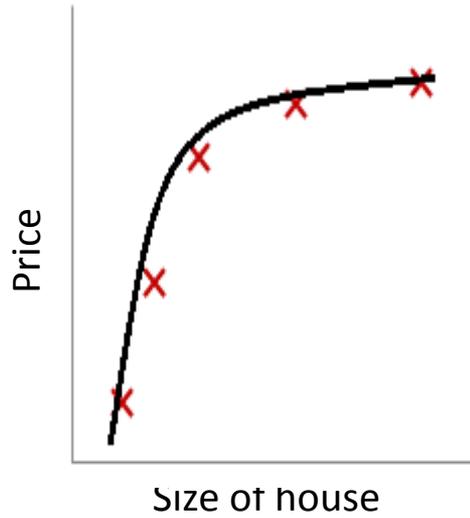


Sobre-ajustamiento (Overfitting)

Opciones:

- Reducir el número de características.
 - Seleccionar manualmente las características que desea conservar.
 - Algoritmo de selección de modelo.
- Regularización.
 - Mantener todas las características, pero reducir la magnitud/valores de los parámetros.
 - Funciona bien cuando tenemos una gran cantidad de características, cada una de las cuales contribuye un poco a la predicción.

Función de costo



Supongamos que penalizamos θ_3 θ_4

Patrones Secuenciales

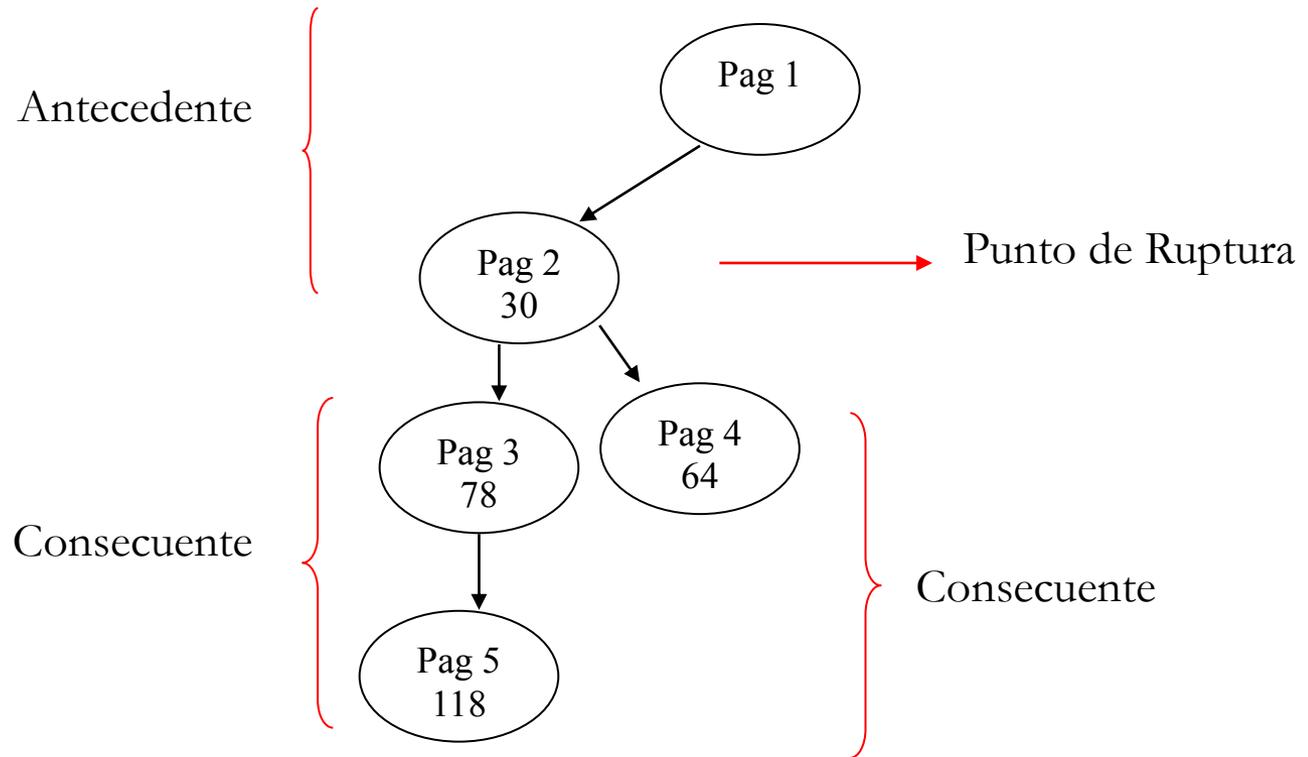
- Descubrir patrones en los cuales la presencia de un conjunto de ítems es seguido por otro ítem en orden temporal.
- Ejemplo: Encontrar y predecir el comportamiento de los visitantes de un sitio Web con respecto al tiempo.

$[x1 \rightarrow x2 \rightarrow x3] \rightarrow [y1 \rightarrow y2]$ en t días

`[/public/team.jsp ->]---->/public/findUsers.jsp->
/private/mycourses/website/folders/assignment/assignment_view.jsp->
/public/portalDocument.js
en 2 días`

Patrones Secuenciales

Generación FBP-Árbol (Matriz FTM, Lista de Caminos)



Patrones Secuenciales

Algoritmo Patrones (FBP-Arbol, soporte, confianza)

- La confianza de una *regla de comportamiento-frecuente* se representa como $conf(PIND \rightarrow PDEP)$ y define la probabilidad de recorrer el camino PDEP una vez se ha recorrido el camino PIND.
- Se recorre el árbol desde las hojas al nodo raíz.
- Teniendo en cuenta el soporte de cada camino las reglas son calculados como sigue.
- Buscar en hojas el punto de ruptura.
 - Si la hoja no es Punto ruptura, ir a hoja anterior.
 - Si la hoja es Punto Ruptura, calcular confianza.
 - Si $conf > confianza$, genera Patrón
 - Si $conf < confianza$, podar rama de árbol.

Modelos de Agrupamiento, Segmentación y Asociación

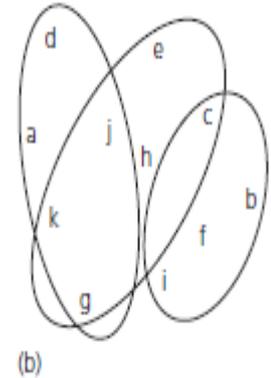
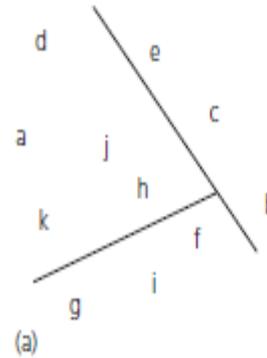
Agrupamiento (Clustering)

Dado un conjunto de puntos de datos, cada uno con un conjunto de atributos, y una medida de similitud entre ellos, encontrar grupos de tal manera que

- Los puntos de datos en un clúster son más similares entre sí.
- Los puntos de datos en grupos separados son menos similares entre sí.

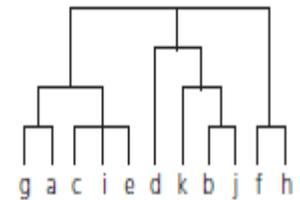
Clusters

A menudo una técnica muy usada en la cual se infiere un **árbol de decisión** o **conjunto de reglas** que asigna a cada instancia al grupo al que pertenece



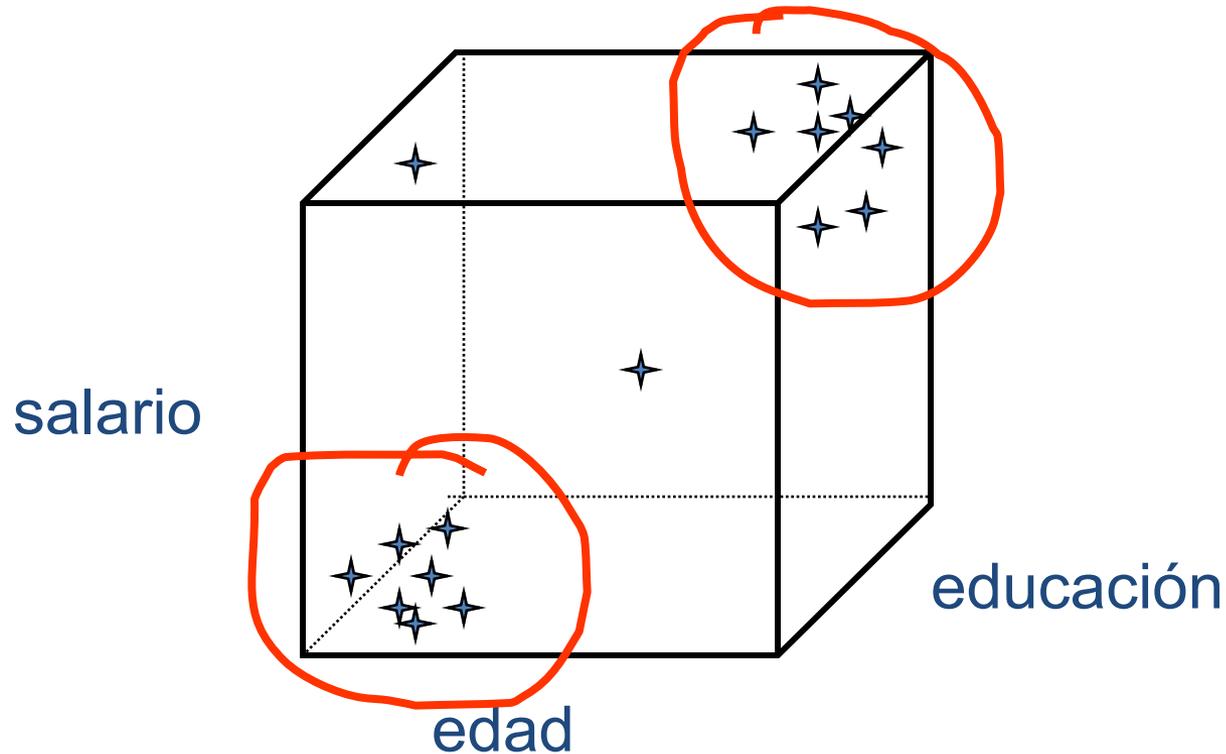
	1	2	3
a	0.4	0.1	0.5
b	0.1	0.8	0.1
c	0.3	0.3	0.4
d	0.1	0.1	0.8
e	0.4	0.2	0.4
f	0.1	0.4	0.5
g	0.7	0.2	0.1
h	0.5	0.4	0.1

(c)



(d)

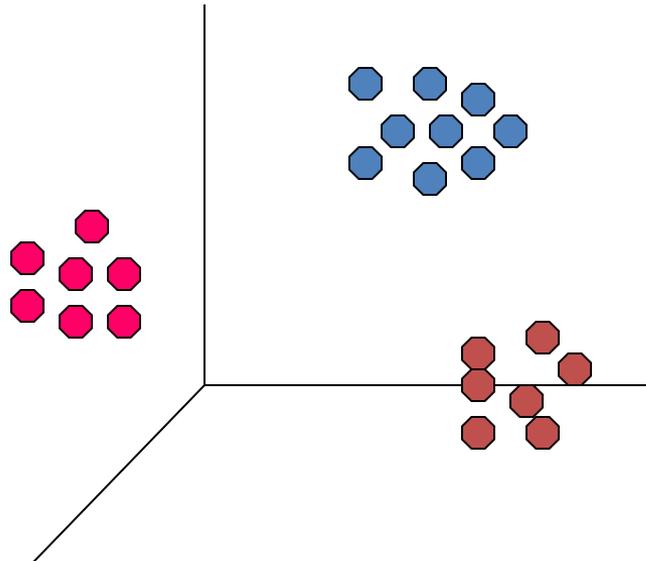
Agrupamiento (Clustering)



Agrupamiento (Clustering)

Distancias Intracluster
son minimizadas

Distancias Intercluster
son maximizadas



Ejemplo de Clustering

Agrupación de documento:

- **Objetivo:** encontrar grupos de documentos que son similares entre sí sobre la base de los términos importantes que aparecen en ellos.
- **Enfoque:** Identificar términos que aparecen con frecuencia en cada documento. Formar una medida de similitud basada en las frecuencias de los diferentes términos. Úsalo para clúster.

Agrupación de documento

- 3204 Artículos de un periódico.
- Medida Similitud: ¿Cuántas palabras son comunes en estos documentos (después de algún tipo de filtrado de palabras).

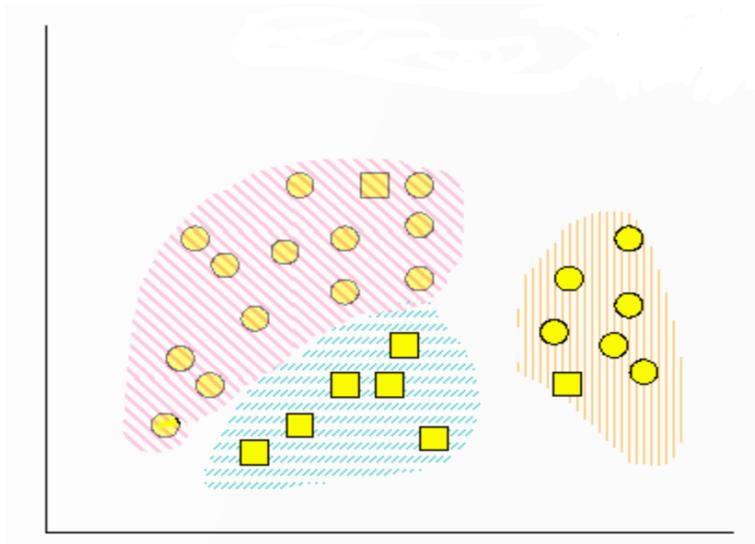
<i>Categoría</i>	<i>Total Articulos</i>	<i>Correcto asignado</i>
<i>Financiero</i>	555	364
<i>Extranjero</i>	341	260
<i>Nacional</i>	273	36
<i>Ciudad</i>	943	746
<i>Deportes</i>	738	573
<i>Entretenimiento</i>	354	278

Tipos de clustering

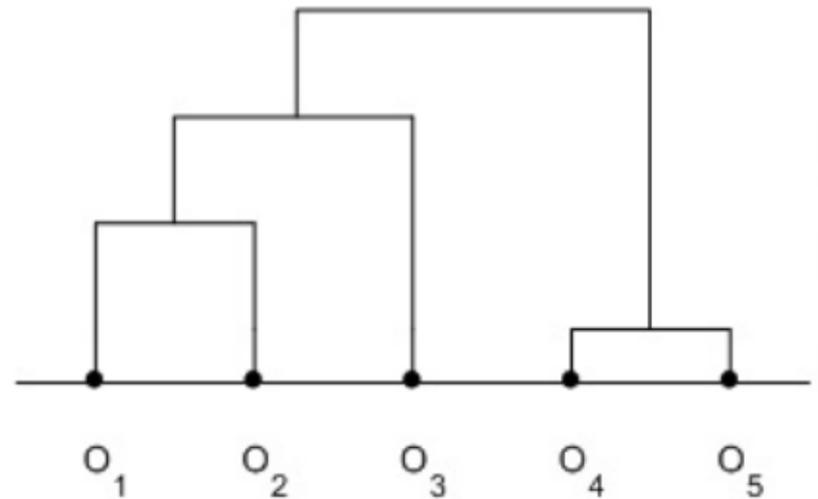
- **Clustering particional**
 - Partición de los objetos en grupos o clusters. Todos los objetos pertenecen a alguno de los k clusters, los cuales son disjuntos. Problema \Rightarrow elección de k
- **Clustering ascendente jerárquico**
 - Crear un dendograma, es decir, crear un conjunto de agrupaciones anidadas hasta construir un árbol jerárquico

Clusterización

- Dados unos datos sin etiquetar, el objetivo es encontrar grupos naturales de instancias



a) Particional



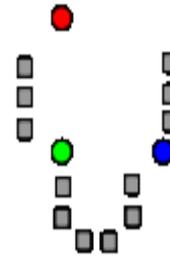
b) Jerárquico

Algoritmo K-medias

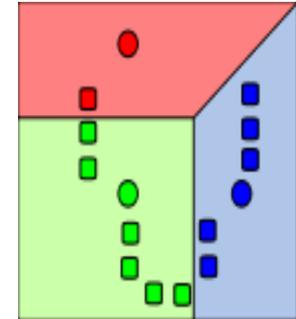
- Método más utilizado de clustering particional
- La idea es situar los prototipos o centros en el espacio, de forma que los datos pertenecientes al mismo prototipo tengan características similares
- Los datos se asignan a cada centro según la menor distancia, normalmente usando la distancia euclídea
- Una vez introducidos todos los datos, se desplazan los prototipos hasta el centro de masas de su nuevo conjunto, esto se repite hasta que no se desplazan más.

Algoritmo K-medias

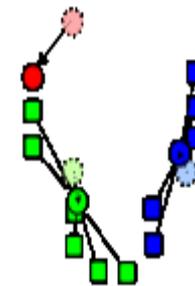
es un método de agrupamiento, que tiene como objetivo la partición de un conjunto (n) en k grupos en el que cada observación pertenece al grupo más cercano a la media.



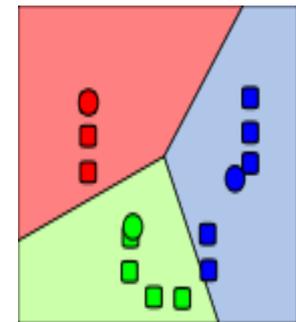
1) k centroides iniciales generados aleatoriamente (en este caso $k=3$)



2) k grupos son generados asociándole el punto



3) El centroide de cada uno de los k grupos se recalcula



4) Pasos 2 y 3 se repiten hasta que se logre la convergencia.

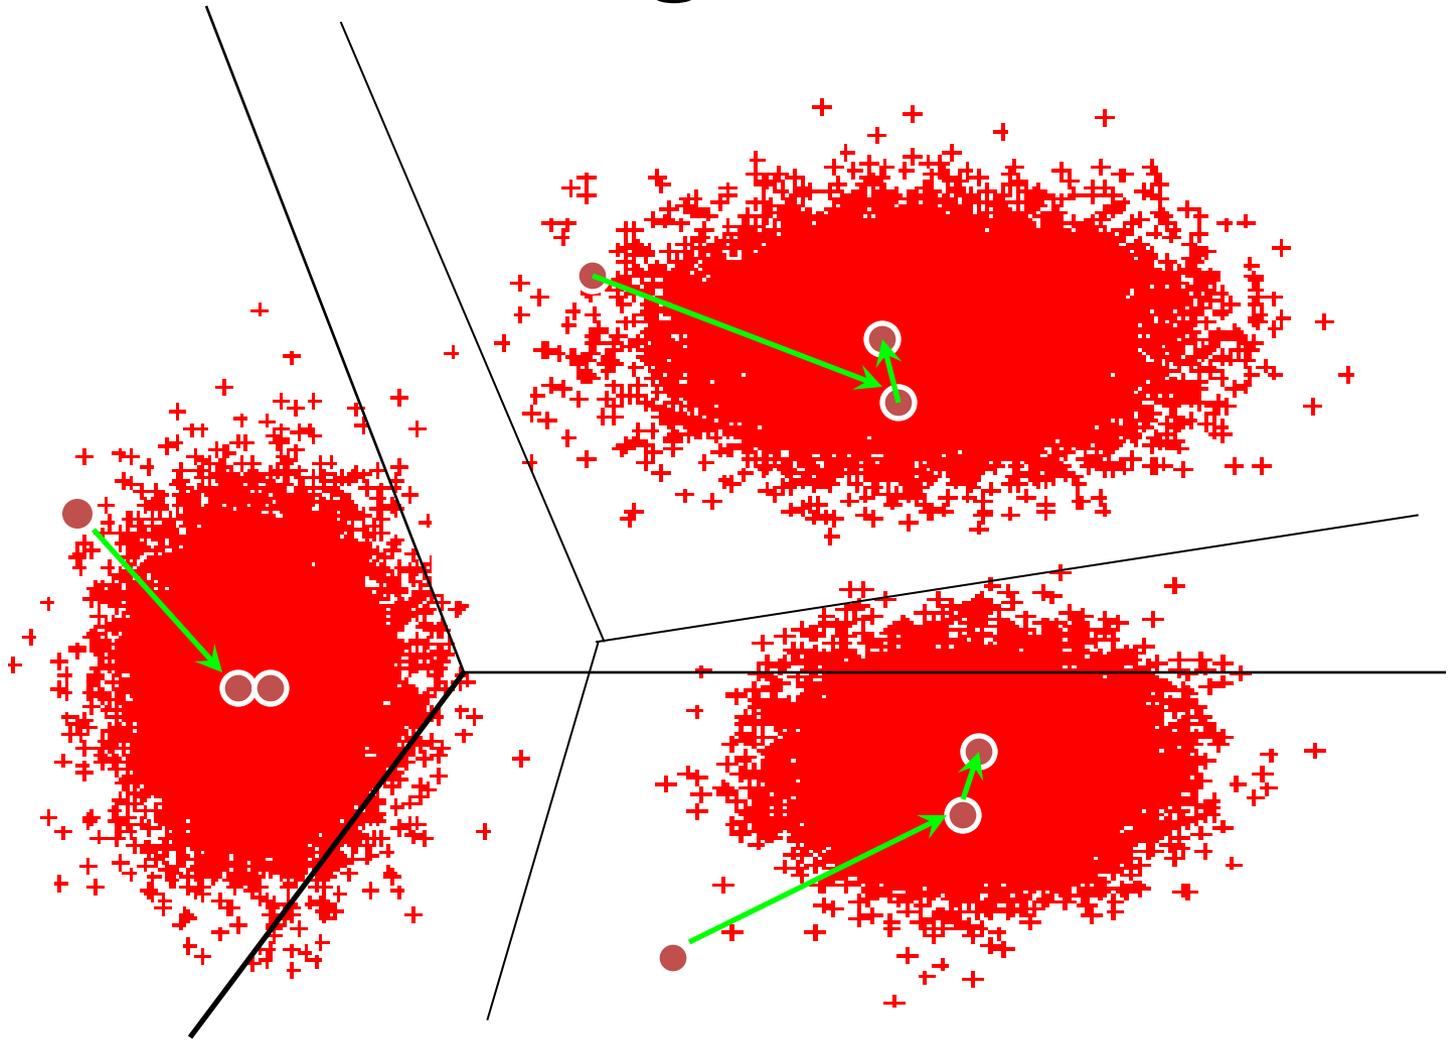
Clusterización: Algoritmo K-Medias

1. Seleccionar centroides aleatorios
2. Asignar cada objeto al grupo cuyo centróide sea el más cercano al objeto.
3. Cuando todos los objetos hayan sido asignados, recalcular la posición de los k centroides.
4. Repetir los pasos 2 y 3 hasta que los centroides no varíen

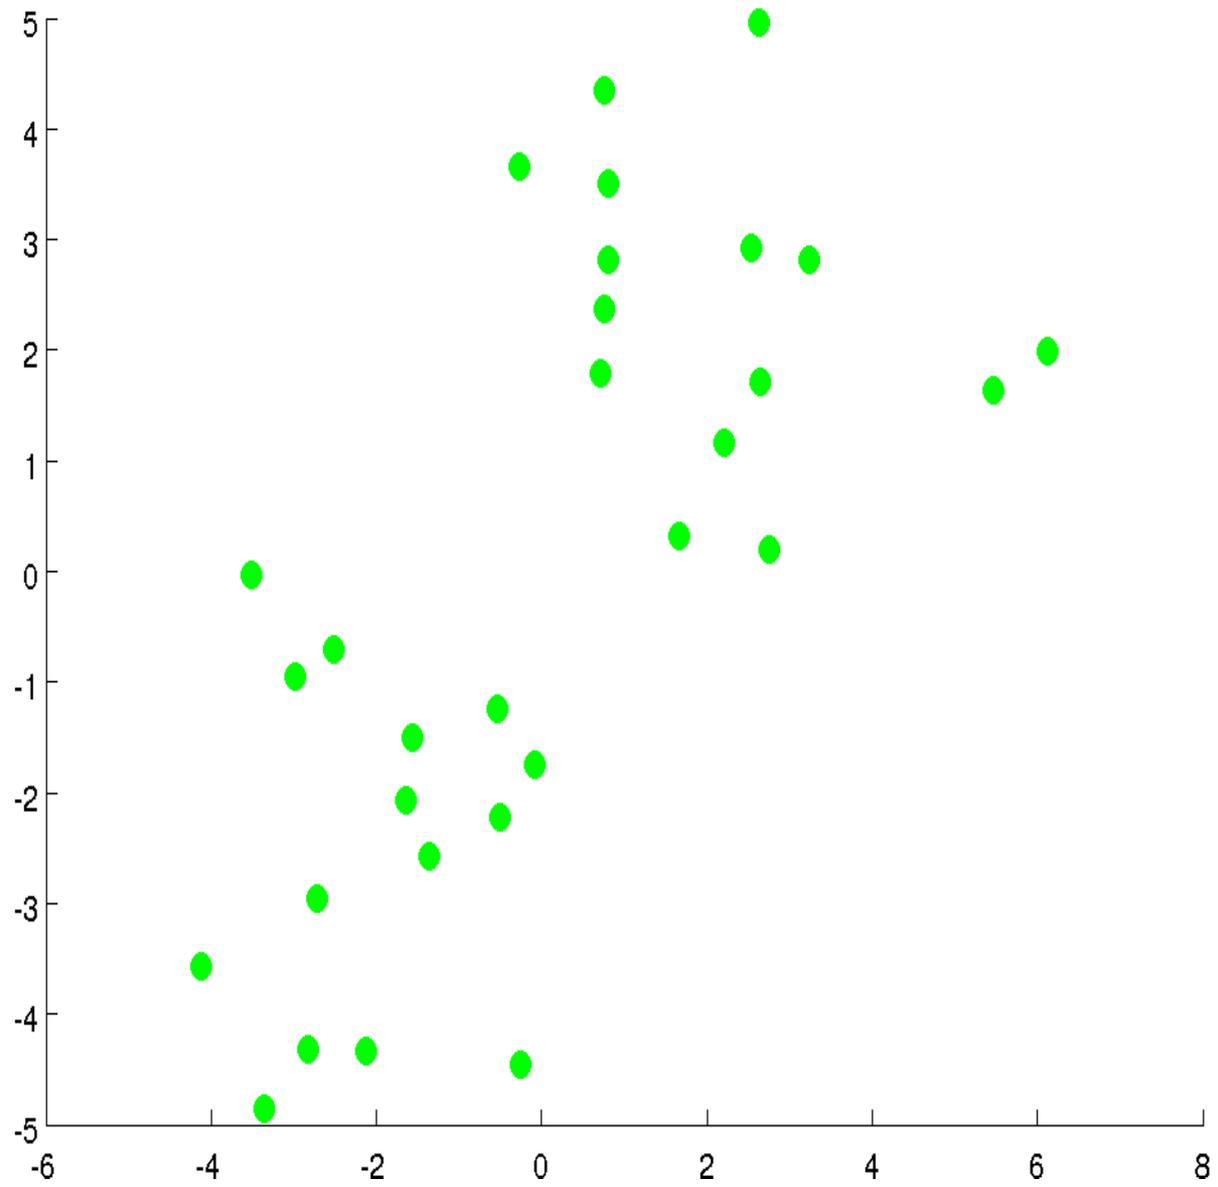
$$\text{Distancia Euclídea } \delta^2 E (X_i, X_j) = || X_i - X_j ||^2 = (X_i - X_j)^T (X_i - X_j)$$

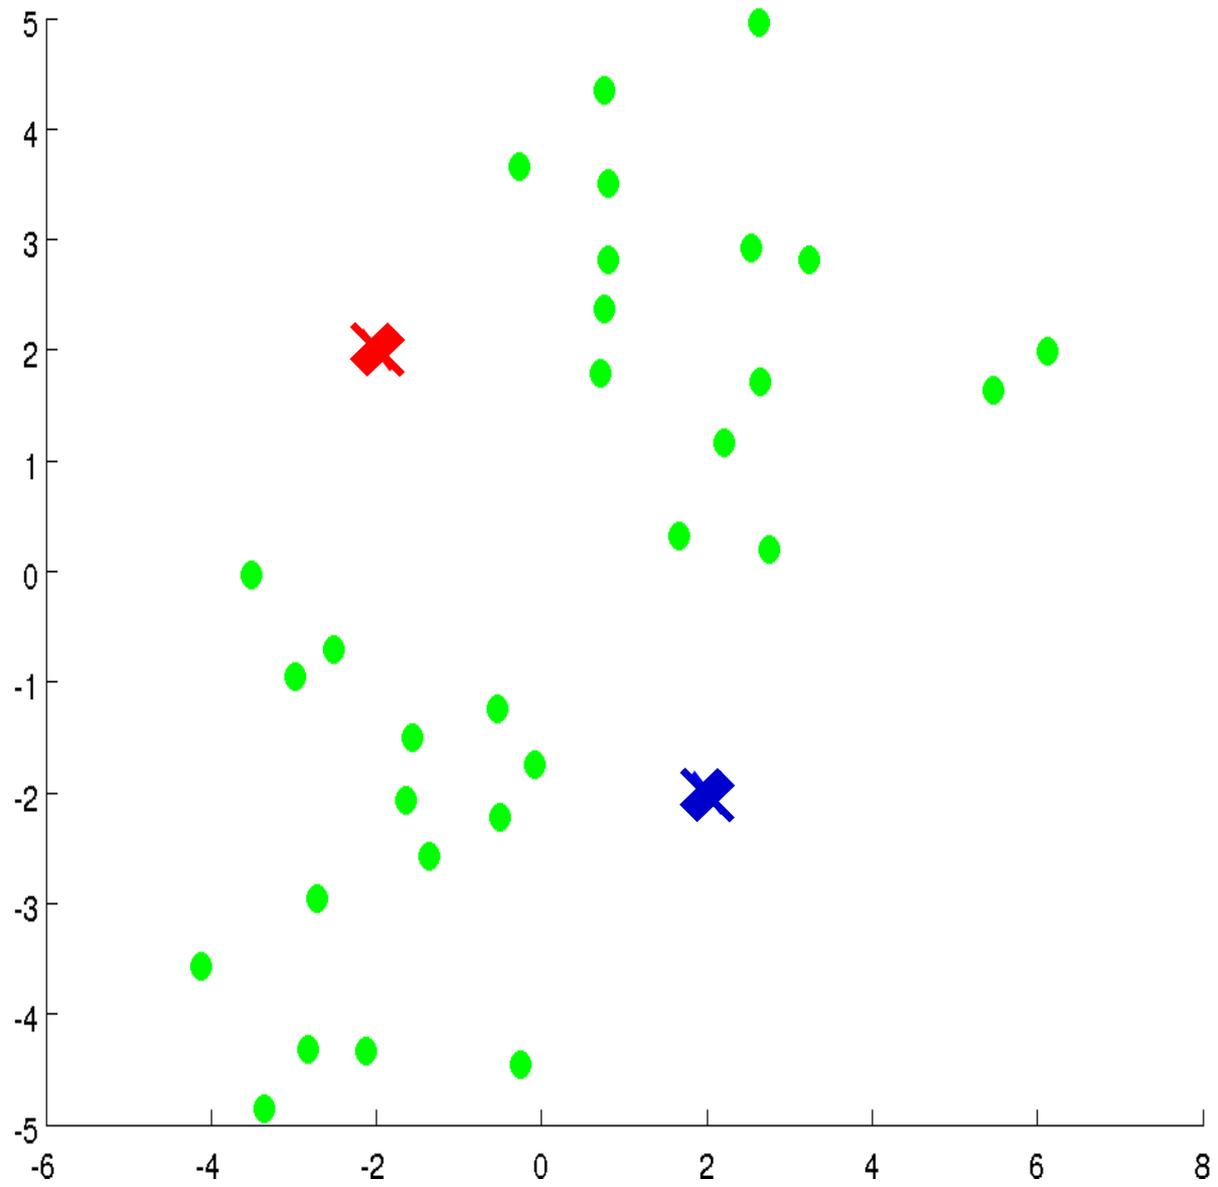
Determinar la media de cada grupo

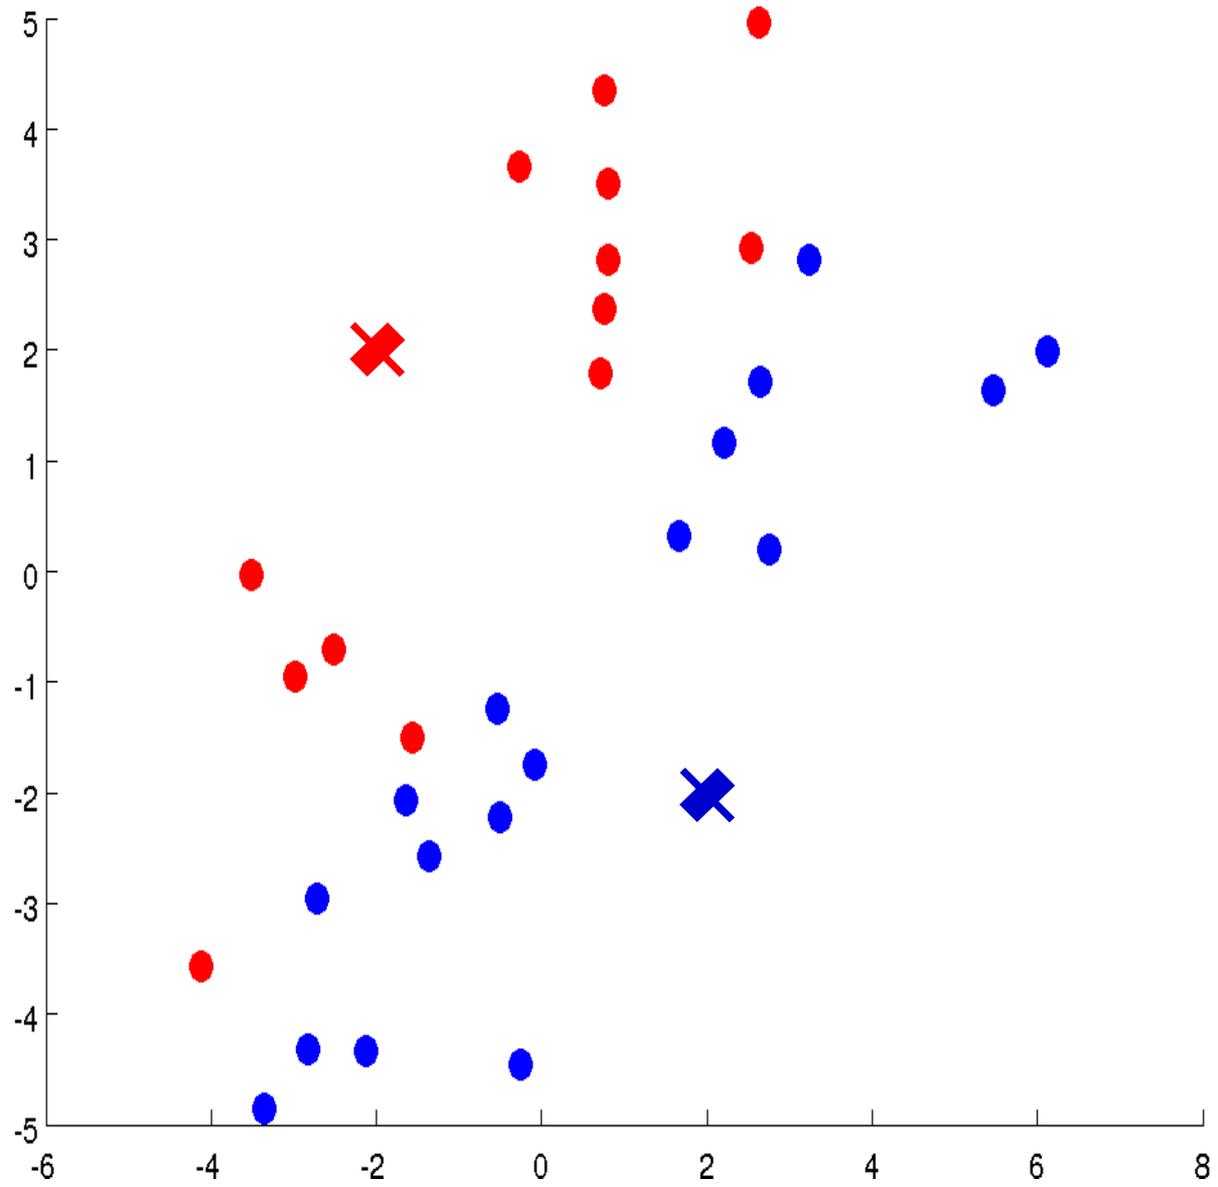
Clusterización: Algoritmo K-Medias

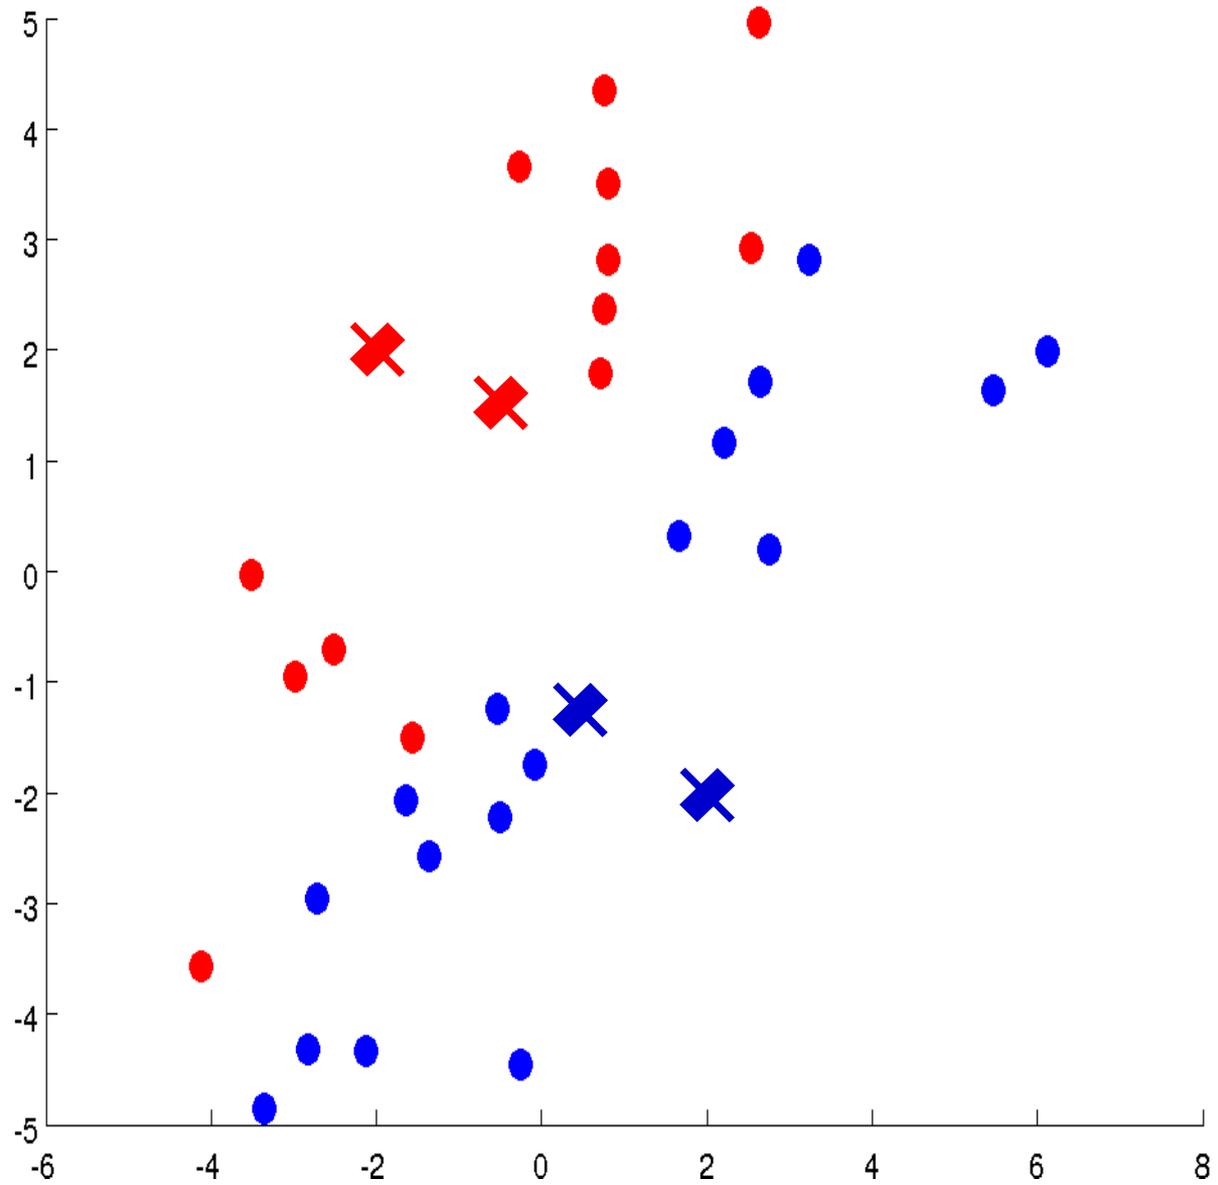


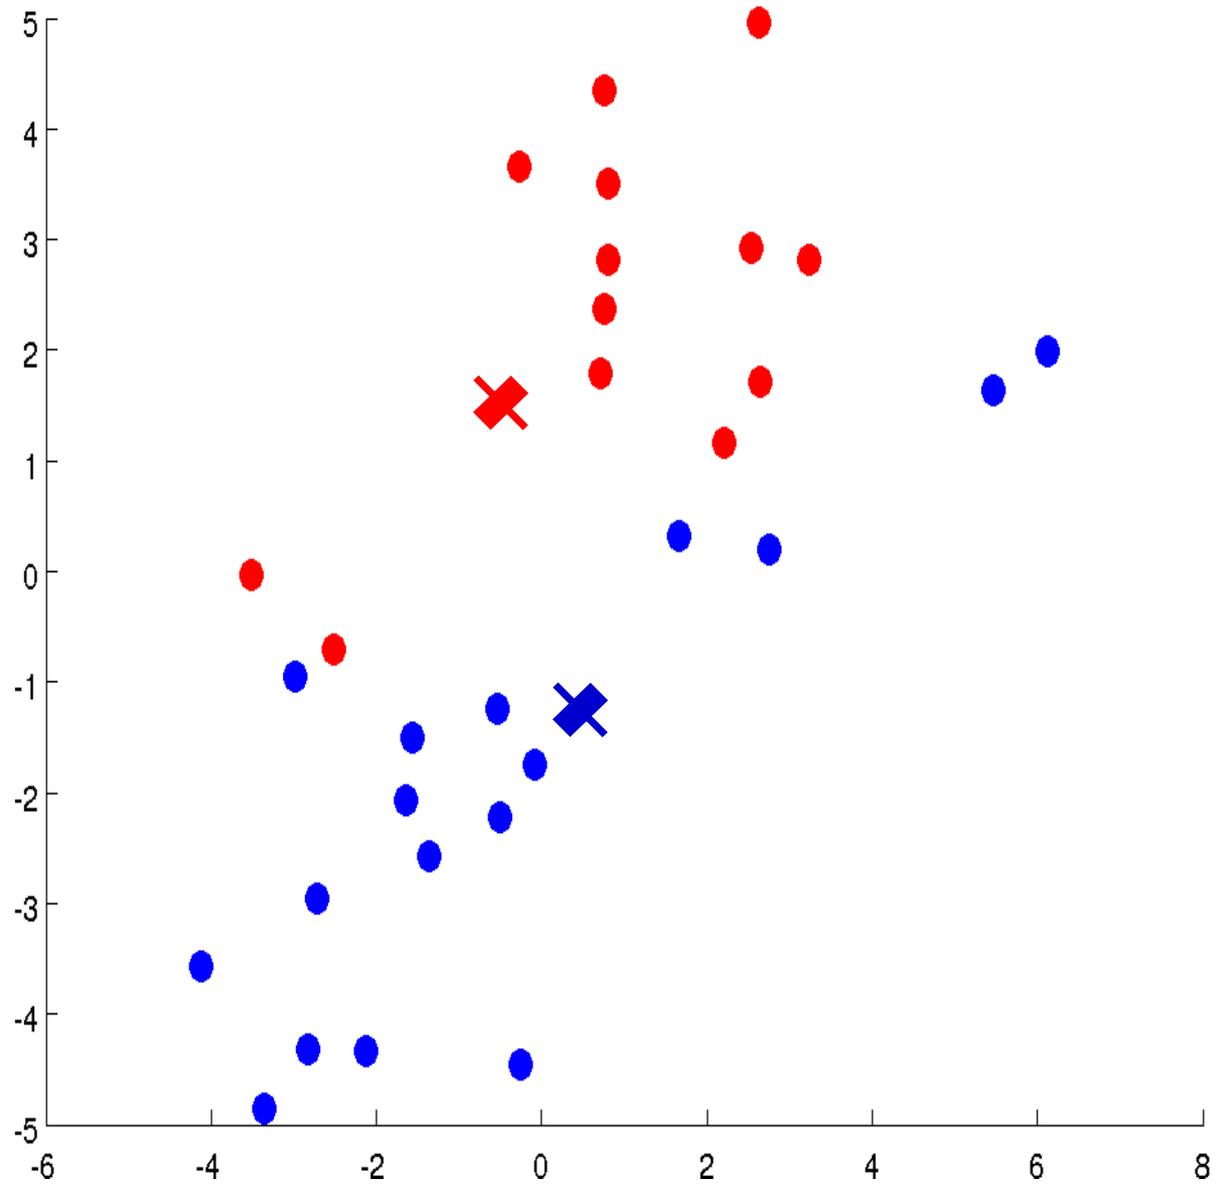
Corrida en frio K-means

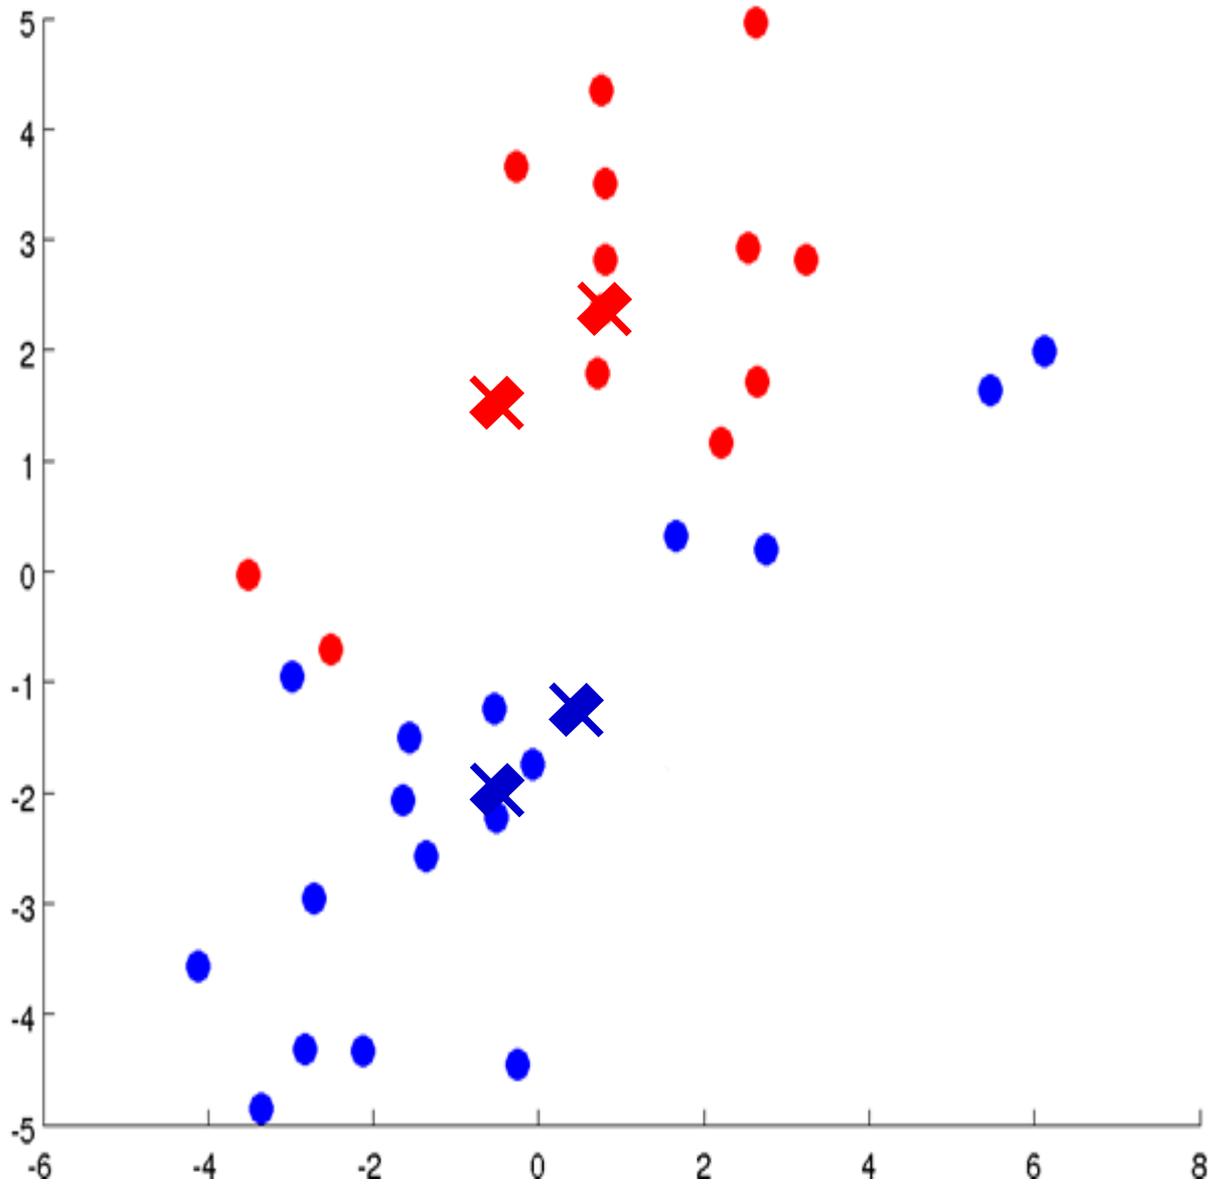


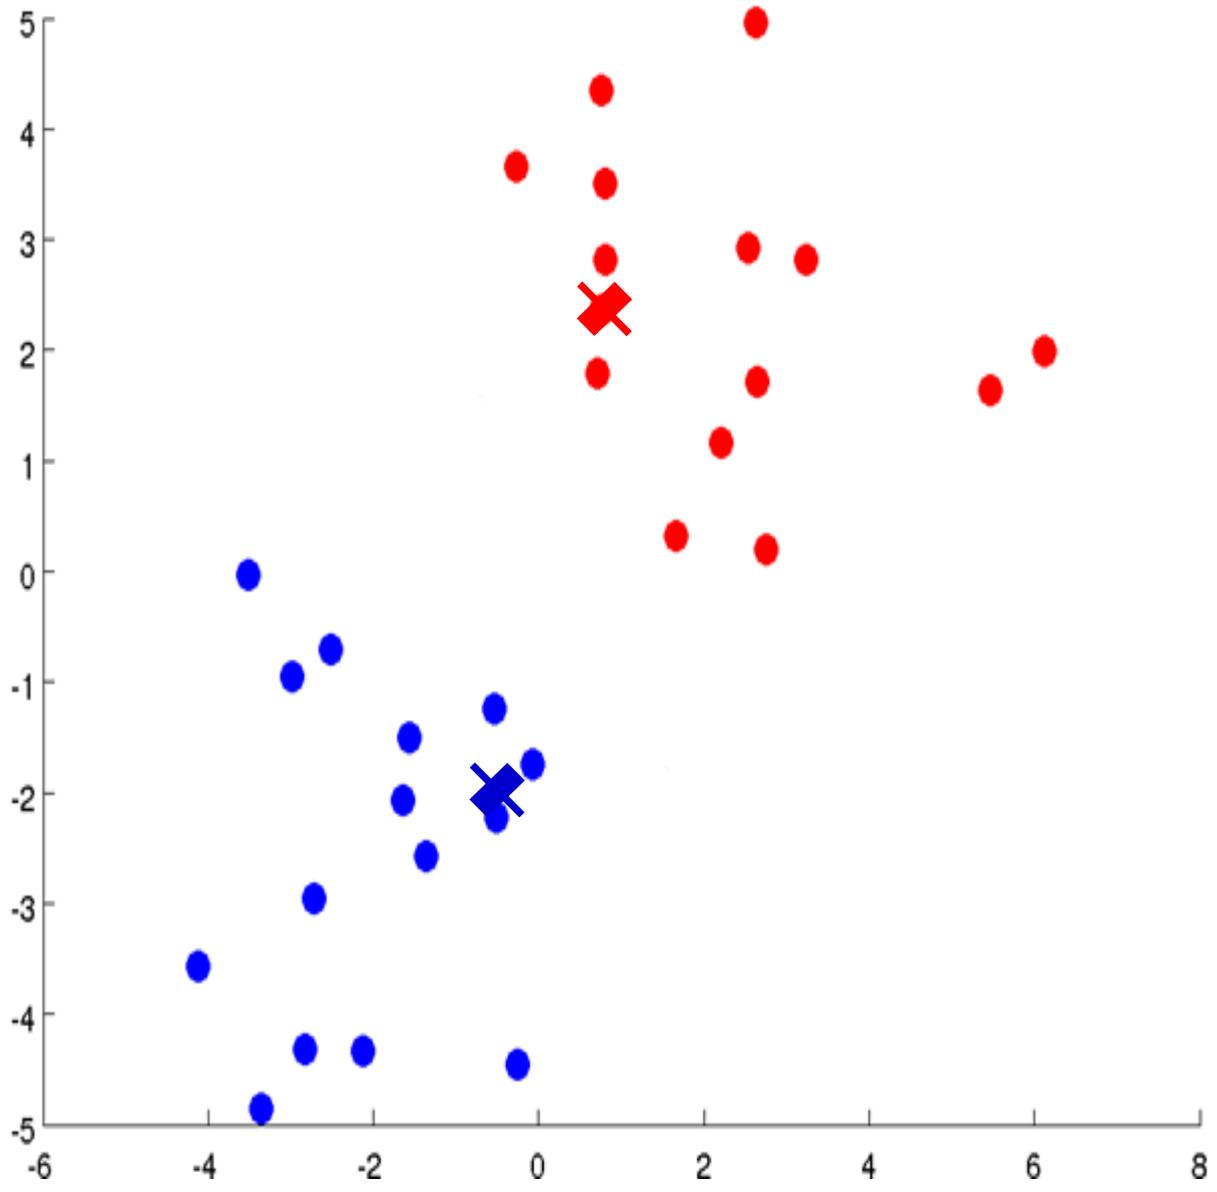


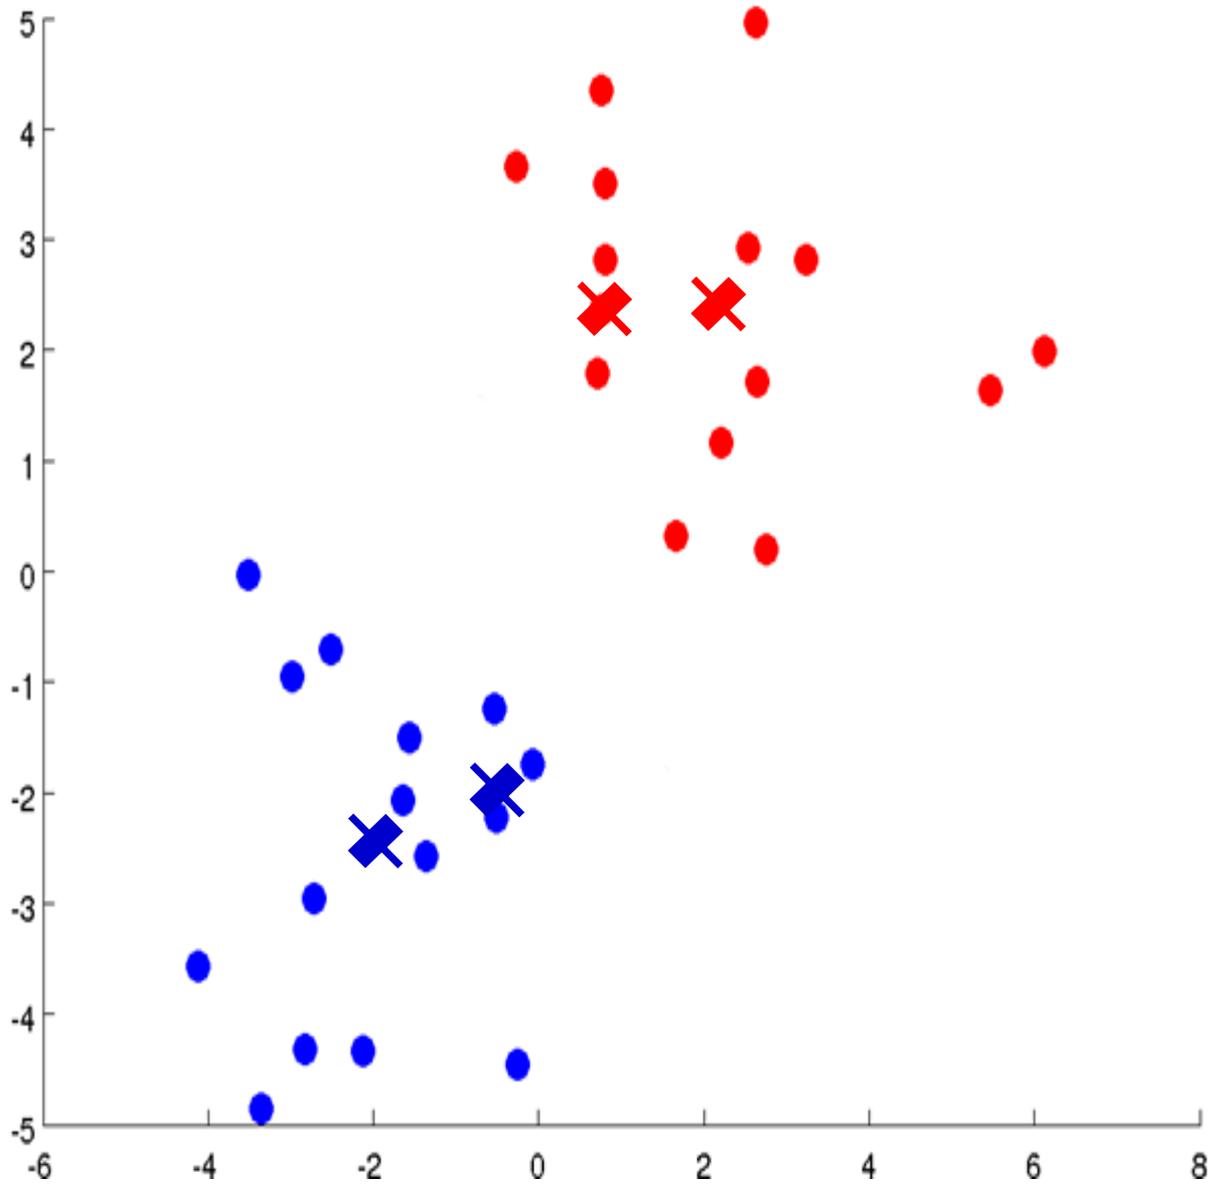


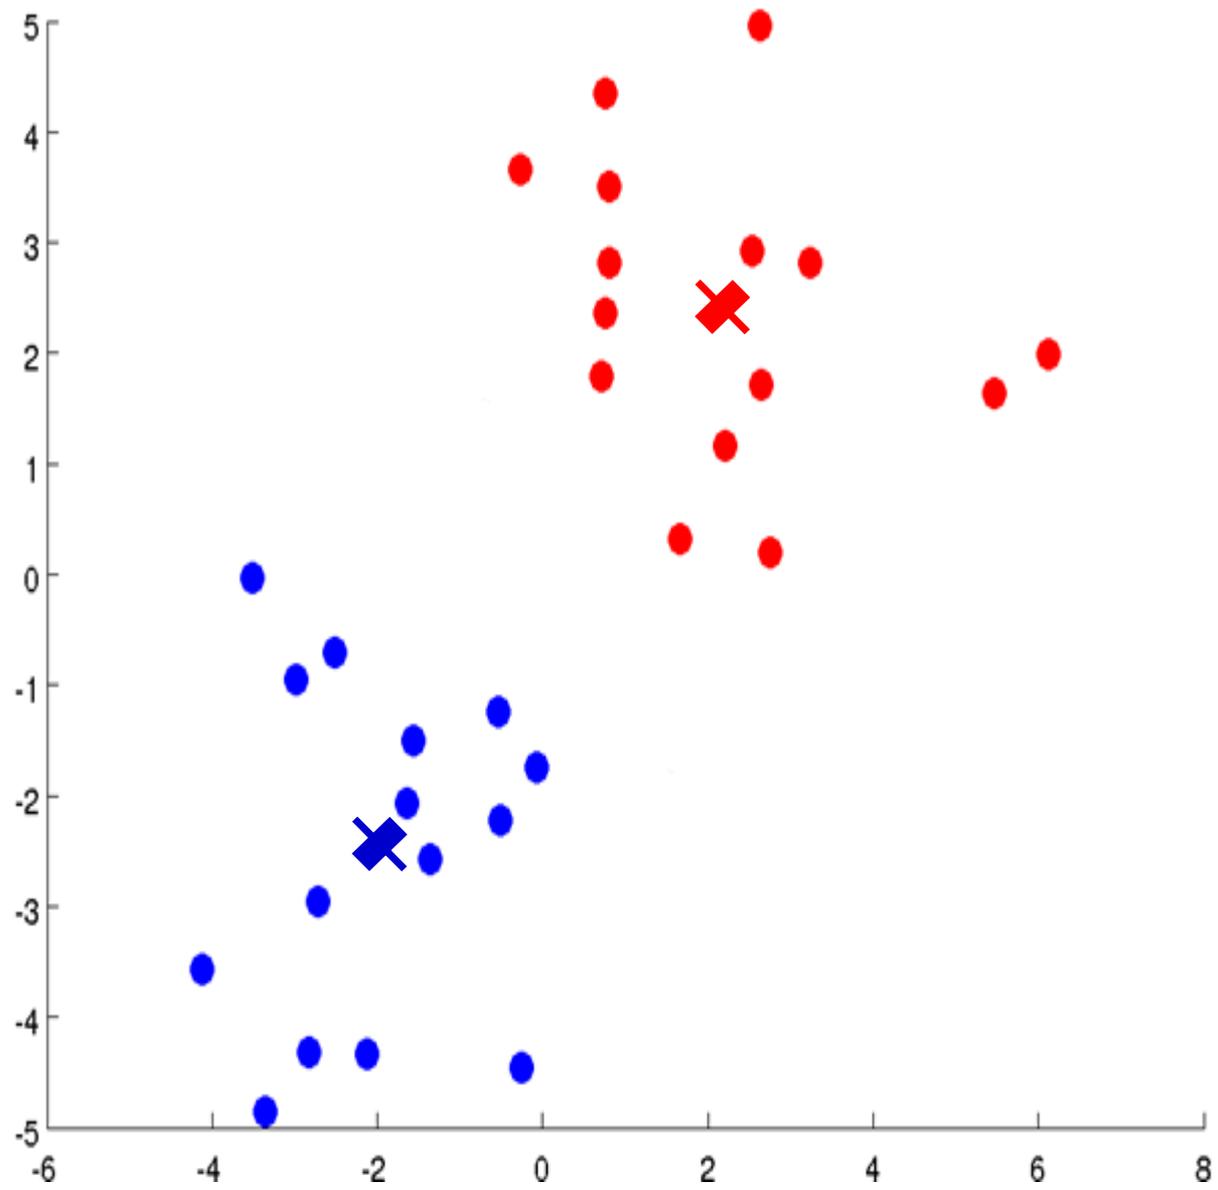




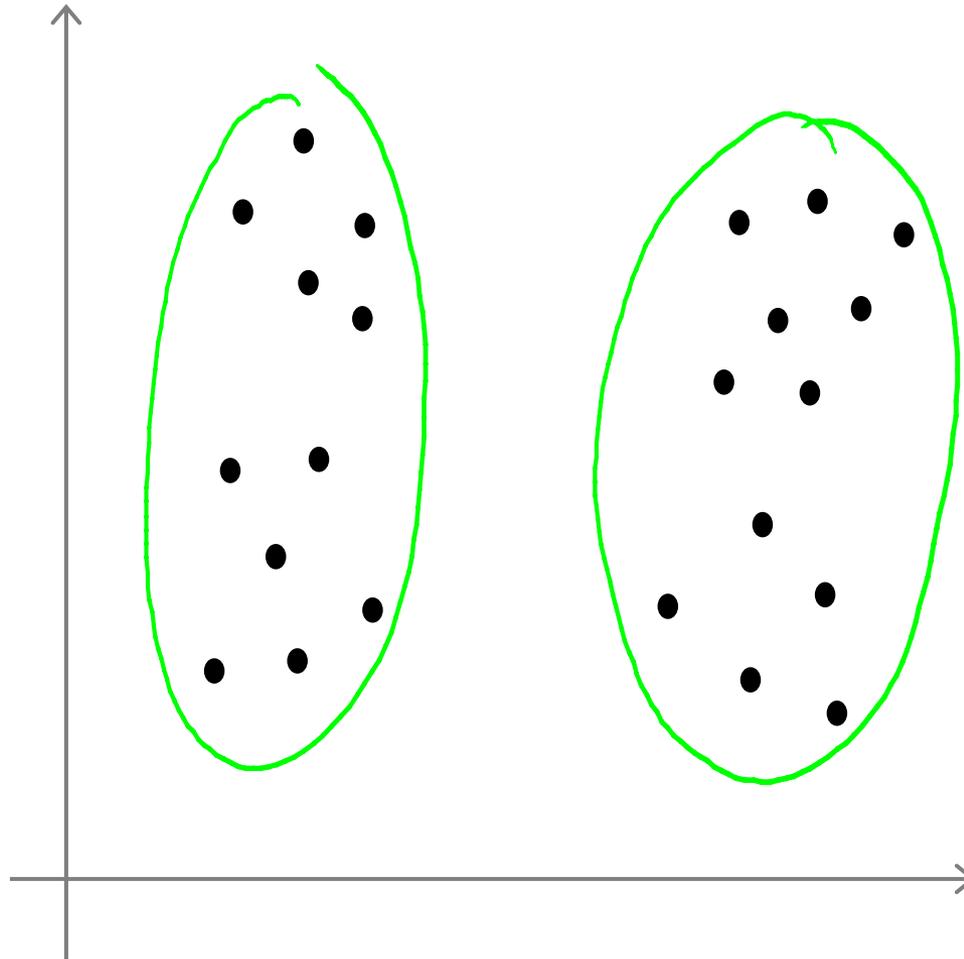






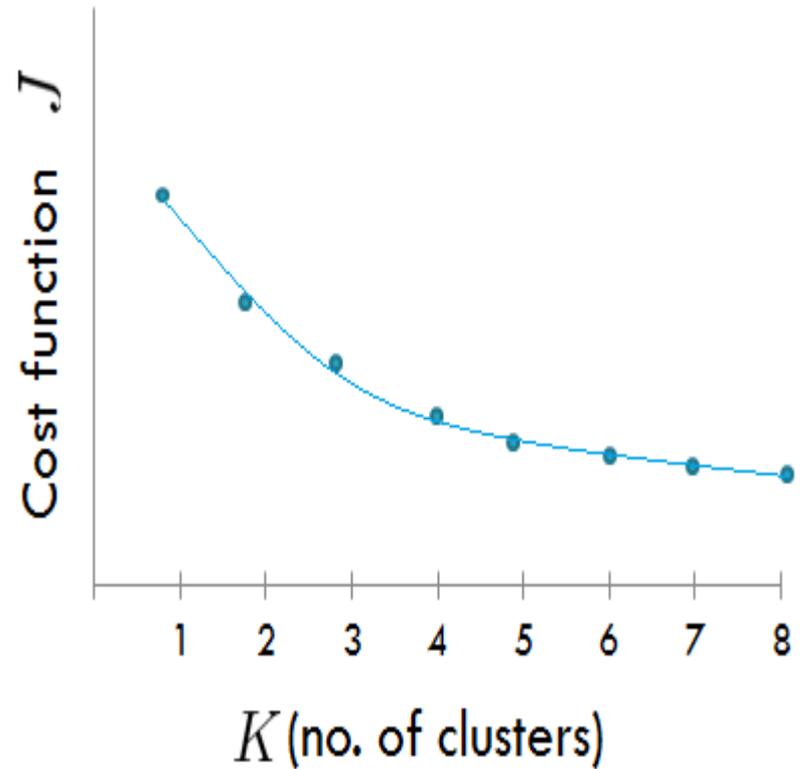
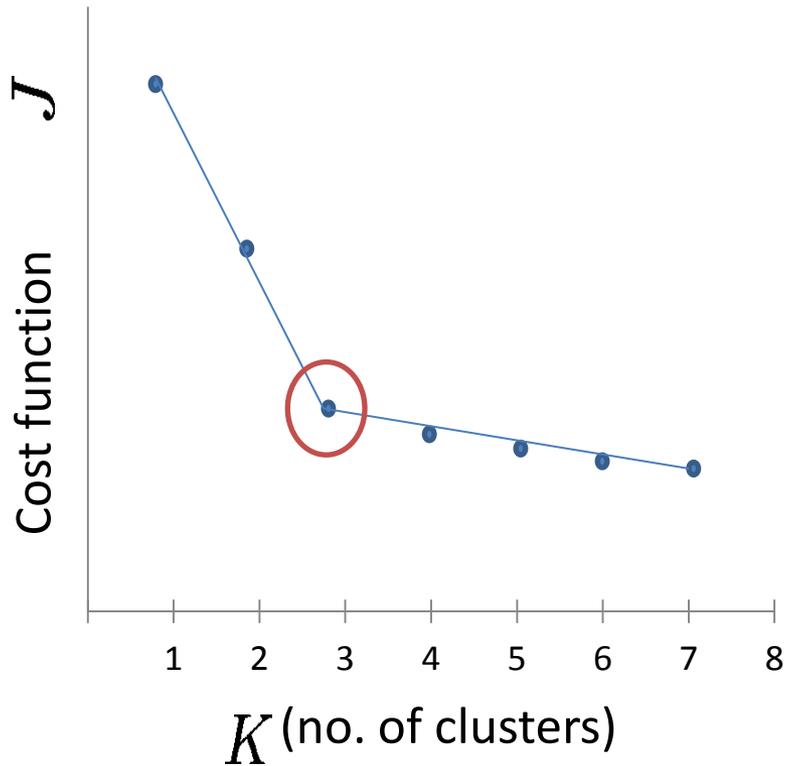


Cual es el correcto valor de K?



Escogiendo el valor de K

Método del codo:

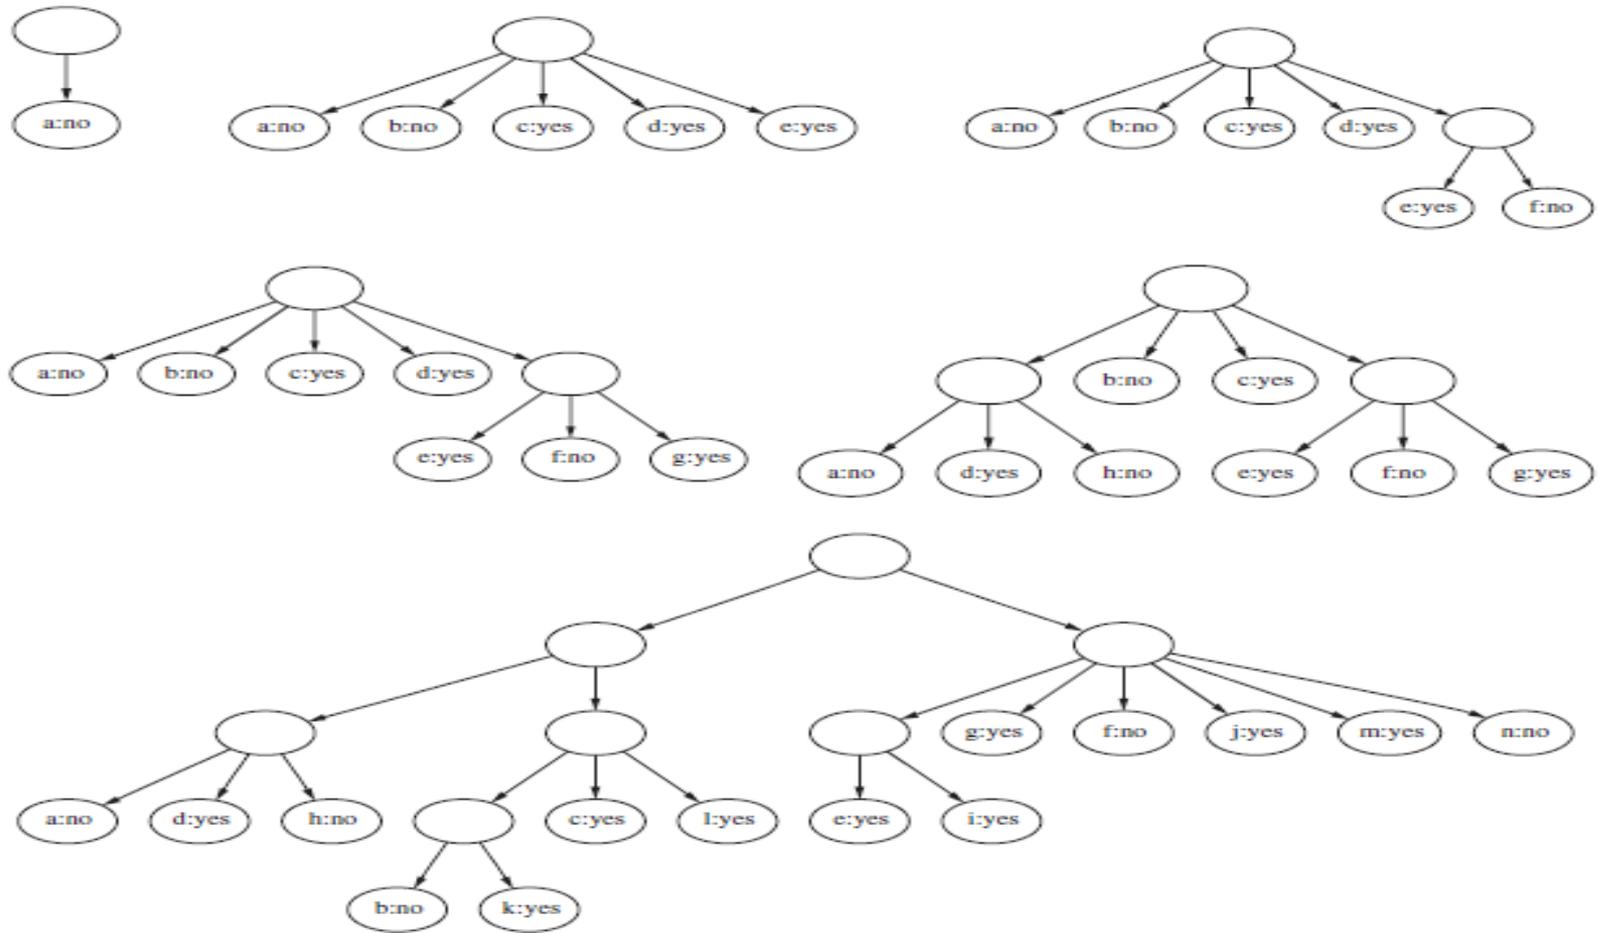


Clustering Incremental

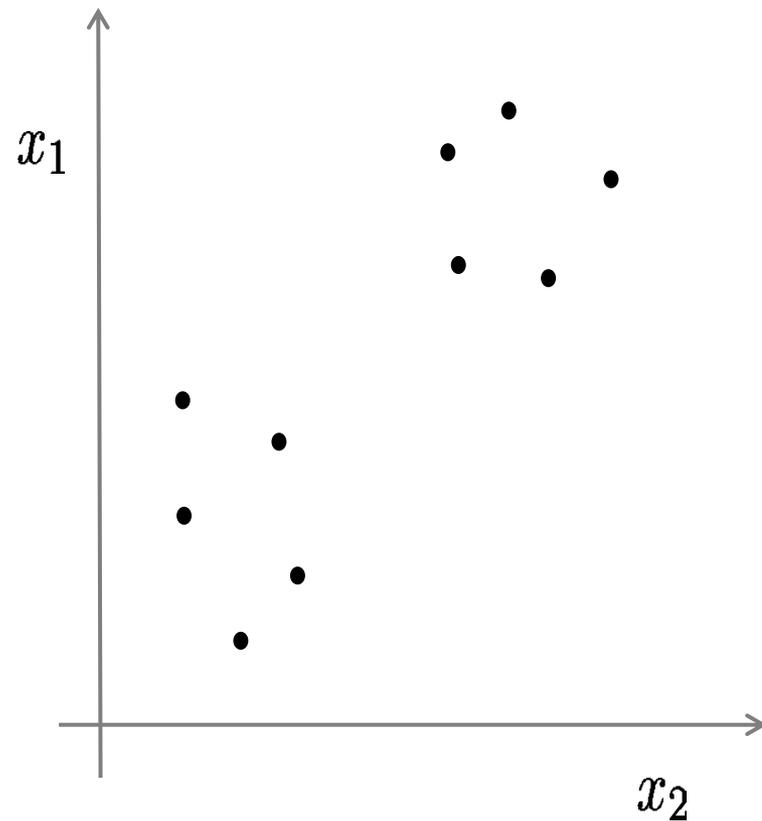
Datos de tiempo

ID code	Outlook	Temperature	Humidity	Windy	Play
a	sunny	hot	high	false	no
b	sunny	hot	high	true	no
c	overcast	hot	high	false	yes
d	rainy	mild	high	false	yes
e	rainy	cool	normal	false	yes
f	rainy	cool	normal	true	no
g	overcast	cool	normal	true	yes
h	sunny	mild	high	false	no
i	sunny	cool	normal	false	yes
j	rainy	mild	normal	false	yes
k	sunny	mild	normal	true	yes
l	overcast	mild	high	true	yes
m	overcast	hot	normal	false	yes
n	rainy	mild	high	true	no

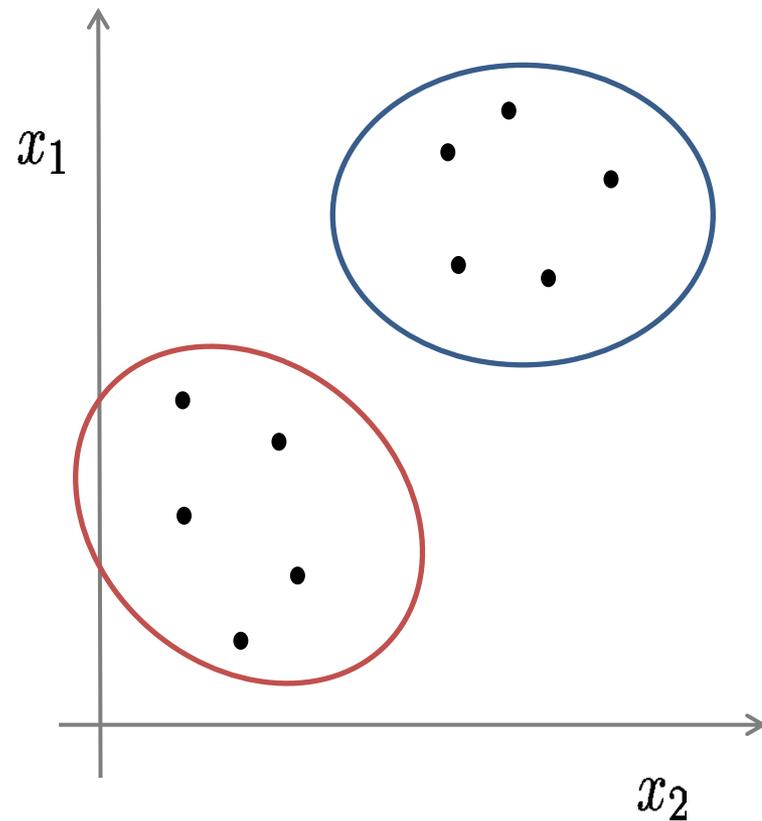
Clustering Incremental



Algoritmo no supervisionado



Algoritmo no supervisionado



Weka

Weka

(Data Mining Tool)

- Weka es una herramienta de minería de datos de código abierto desarrollado en Java.
- Se utiliza para la investigación, la educación, y las aplicaciones.
- Se puede ejecutar en Windows, Linux y Mac.



<http://www.cs.waikato.ac.nz/ml/weka/>

Weka

- Weka es una colección de algoritmos de aprendizaje automático para tareas de minería de datos.
- Los algoritmos bien se pueden aplicar directamente a un conjunto de datos (con interfaz gráfica de usuario) o llamados desde su propio código Java (usando biblioteca Weka de Java).
- Weka contiene herramientas para **pre-procesamiento de los datos , clasificación, regresión, clustering, reglas de asociación, selección de características y la visualización.**



Weka

- Entrada de datos a Weka (Input)
- Weka para Data Mining
- Salida desde Weka (Output)

Entrada de datos a Weka (Input)

- El maps popular formato is “arff” (“arff” es la extensión del nombre del archivo).

FILE FORMAT

@relation RELATION_NAME

@attribute ATTRIBUTE_NAME ATTRIBUTE_TYPR

@attribute ATTRIBUTE_NAME ATTRIBUTE_TYPR

@attribute ATTRIBUTE_NAME ATTRIBUTE_TYPR

@attribute ATTRIBUTE_NAME ATTRIBUTE_TYPR

@data

DATAROW1

DATAROW2

DATAROW3

Entrada de datos a Weka (Input)

archivo "arff"

@relation heart-disease-simplified

@attribute age numeric

@attribute sex { female, male}

@attribute chest_pain_type { typ_angina, asympt, non_anginal, atyp_angina}

@attribute cholesterol numeric

@attribute exercise_induced_angina { no, yes}

@attribute class { present, not_present}

@data

63,male,typ_angina,233,no,not_present

67,male,asympt,286,yes,present

67,male,asympt,229,yes,present

38,female,non_anginal,?,no,not_present

...

Atributo numérico

Atributo nominal

Weka para Data Mining

- Con interfaz gráfica de usuario
- O usando biblioteca Weka de Java

Weka GUI

The screenshot displays the Weka 3.5.5 GUI. At the top, the menu bar includes Program, Applications, Tools, Visualization, Windows, and Help. Below it is the Explorer window, which contains several tabs: Preprocess, Classify, Cluster, Associate, Select attributes, and Visualize. A red box highlights these tabs, with a red arrow pointing to the text "Herramientas de análisis".

Below the tabs are buttons for "Open file...", "Open URL...", "Open DB...", "Generate...", "Undo", "Edit...", and "Save...".

The "Filter" section shows a "Choose" button and a "None" selection. Below it, the "Current relation" section displays "Relation: labor-neg-data" and "Instances: 57". The "Attributes" section has buttons for "All", "None", "Invert", and "Pattern".

A table lists 17 attributes, with the "class" attribute selected. A red box highlights this list, with a red arrow pointing to the text "Atributos a escoger".

The "Selected attribute" section shows "Name: class", "Missing: 0 (0%)", "Distinct: 2", and "Type: Nominal". Below this is a table with two columns: "Label" and "Count".

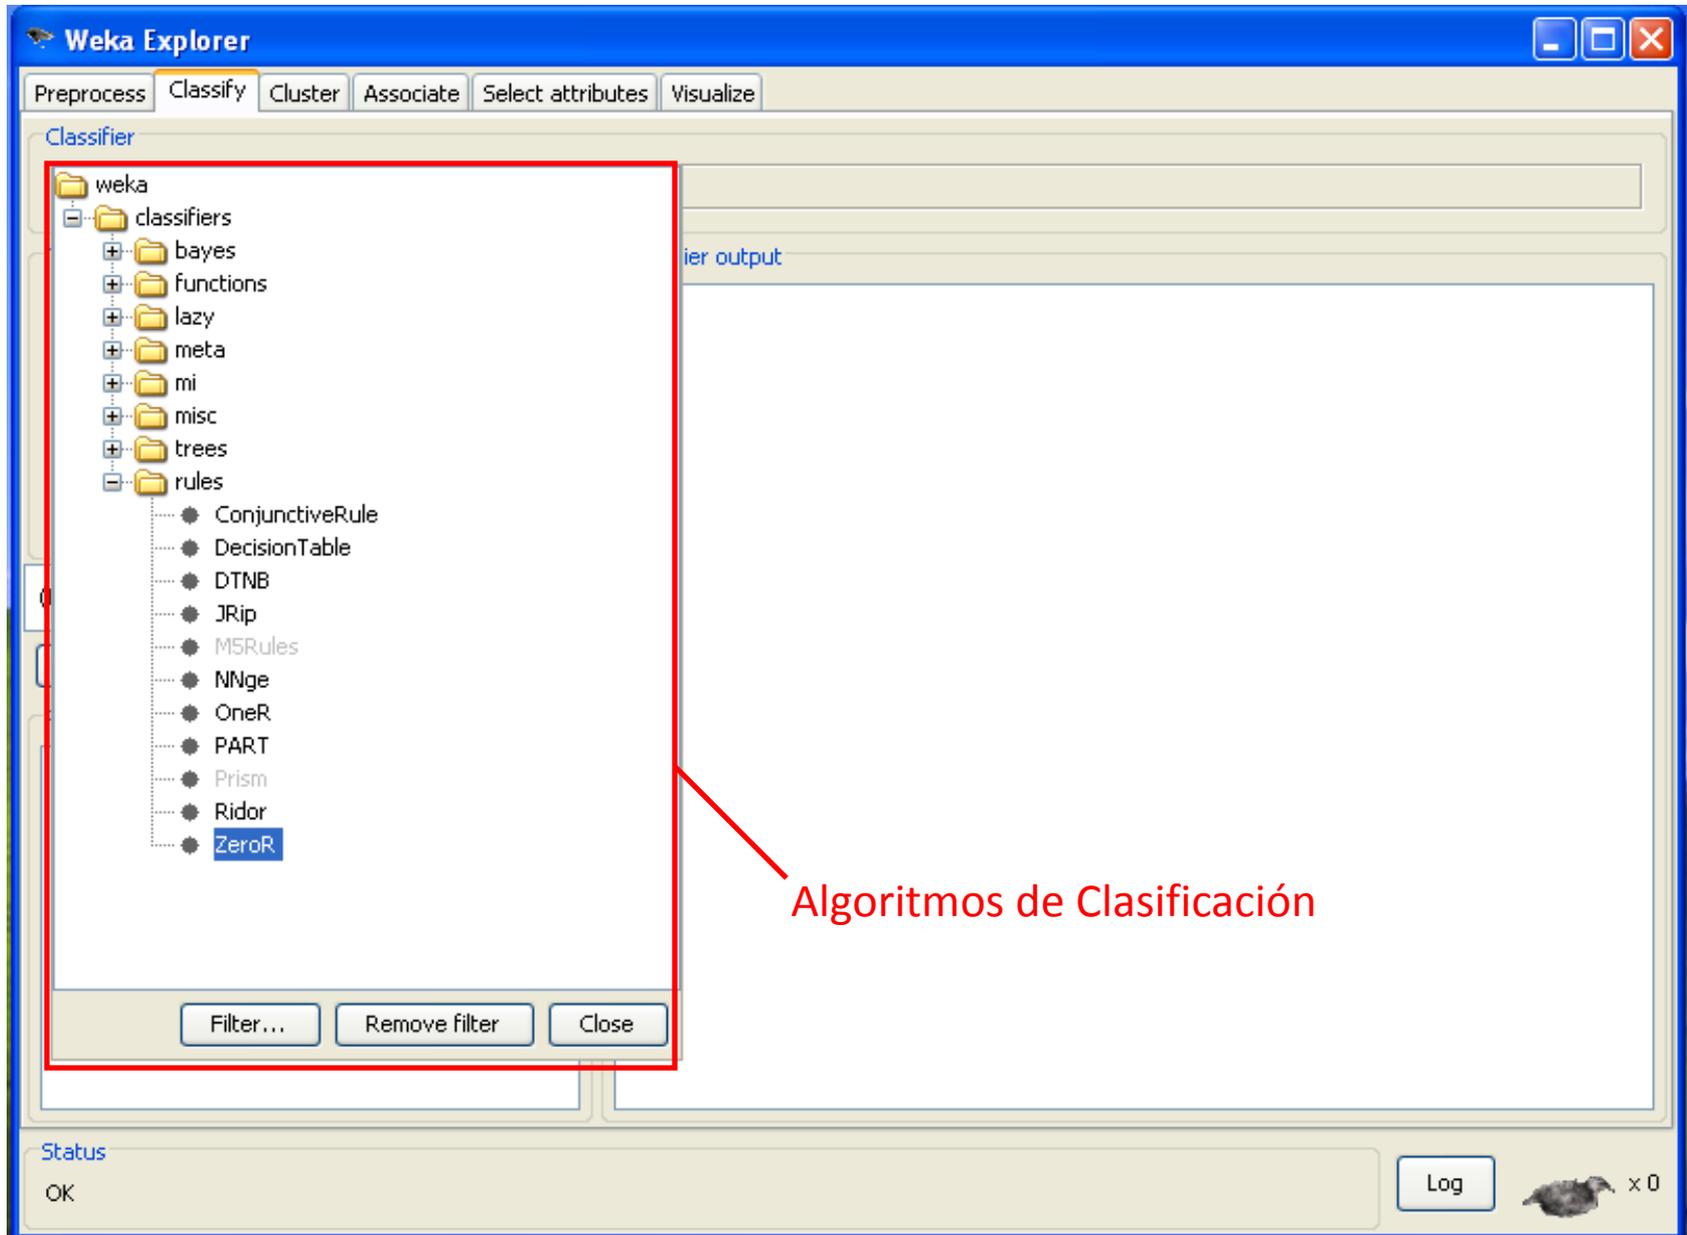
Label	Count
bad	20
good	37

A red box highlights this table, with a red arrow pointing to the text "Valores de un atributo escogido".

At the bottom, a bar chart titled "Class: class (Nom)" shows two bars: a blue bar for "bad" with a count of 20, and a red bar for "good" with a count of 37. A red box highlights the chart, with a red arrow pointing to the text "Valores de un atributo escogido".

The "Status" bar at the bottom left shows "OK", and the bottom right has a "Log" button and a small icon.

Weka GUI



Weka Java library

- Clases para carga de datos
- Clases para los clasificadores
- Clases para la evaluación

Clases para carga de datos

- weka.core.Instances
 - weka.core.Attribute
-
- Cada DataRow -> Instance, Every Attribute -> Attribute, Whole -> Instances

```
# Load a file as Instances
FileReader reader;
reader = new FileReader(path);
Instances instances = new Instances(reader);
```

Clases para carga de datos

- Instances contains Attribute and Instance
 - como recuperar un valor de una instancia?

```
# Get Instance  
Instance instance = instances.instance(index);  
# Get Instance Count  
int count = instances.numInstances();
```

- Como recuperar un atributo?

```
# Get Attribute Name  
Attribute attribute = instances.attribute(index);  
# Get Attribute Count  
int count = instances.numAttributes();
```

Clases para carga de datos

- como recuperar el valor del atributo para cada Instancia?

```
# Get value  
instance.value(index);    or  
instance.value(attrName);
```

- **Indice de Clase**

```
# Get Class Index  
instances.classIndex();          or  
instances.classAttribute(index());  
# Set Class Index  
instances.setClass(attribute);   or  
instances.setClassIndex(index);
```

Clases para los clasificadores

- Clases Weka para C4.5, Naïve Bayes, and SVM
 - Clasificadores:
 - C4.5: `weka.classifier.trees.J48`
 - NaiveBayes: `weka.classifiers.bayes.NaiveBayes`
 - SVM: `weka.classifiers.functions.SMO`
- Cómo construir un clasificador?

```
# Build a C4.5 Classifier
Classifier c = new weka.classifier.trees.J48();
c.buildClassifier(trainingInstances);
Build a SVM Classifier
Classifier e = weka.classifiers.functions.SMO();
e.buildClassifier(trainingInstances);
```

Clases para la evaluación

- weka.classifiers.CostMatrix
- weka.classifiers.Evaluation

- Como usarlas?

```
# Use Classifier To Do Classification
CostMatrix costMatrix = null;
Evaluation eval = new Evaluation(testingInstances, costMatrix);

for (int i = 0; i < testingInstances.numInstances(); i++){
    eval.evaluateModelOnceAndRecordPrediction(c,testingInstances.instance(i));
    System.out.println(eval.toSummaryString(false));
    System.out.println(eval.toClassDetailsString()) ;
    System.out.println(eval.toMatrixString());
}
```

Clases para la evaluación

Validación Cruzada

- Divide un único conjunto de datos en N partes iguales.
- Toma la $N-1$ como un conjunto de datos de entrenamiento, el resto se utilizará como prueba de conjunto de datos.

Clases para la evaluación

- Obtención conjunto de entrenamiento

```
Random random = new Random(seed);
instances.randomize(random);
instances.stratify(N);

for (int i = 0; i < N; i++)
{
    Instances train = instances.trainCV(N, i , random);
    Instances test = instances.testCV(N, i , random);
}
```

Salida desde Weka (Output)

=== Summary ===

Correctly Classified Instances	46	65.7143 %
Incorrectly Classified Instances	24	34.2857 %
Kappa statistic	0.2398	
Mean absolute error	0.3654	
Root mean squared error	0.5367	
Relative absolute error	75.2288 %	
Root relative squared error	108.9601 %	
Total Number of Instances	70	

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	0.878	0.655	0.655	0.878	0.75	0.632	Y
	0.345	0.122	0.667	0.345	0.455	0.632	N
Weighted Avg.	0.657	0.434	0.66	0.657	0.628	0.632	

=== Confusion Matrix ===

```
a b <-- classified as
36 5 | a = Y
19 10 | b = N
```



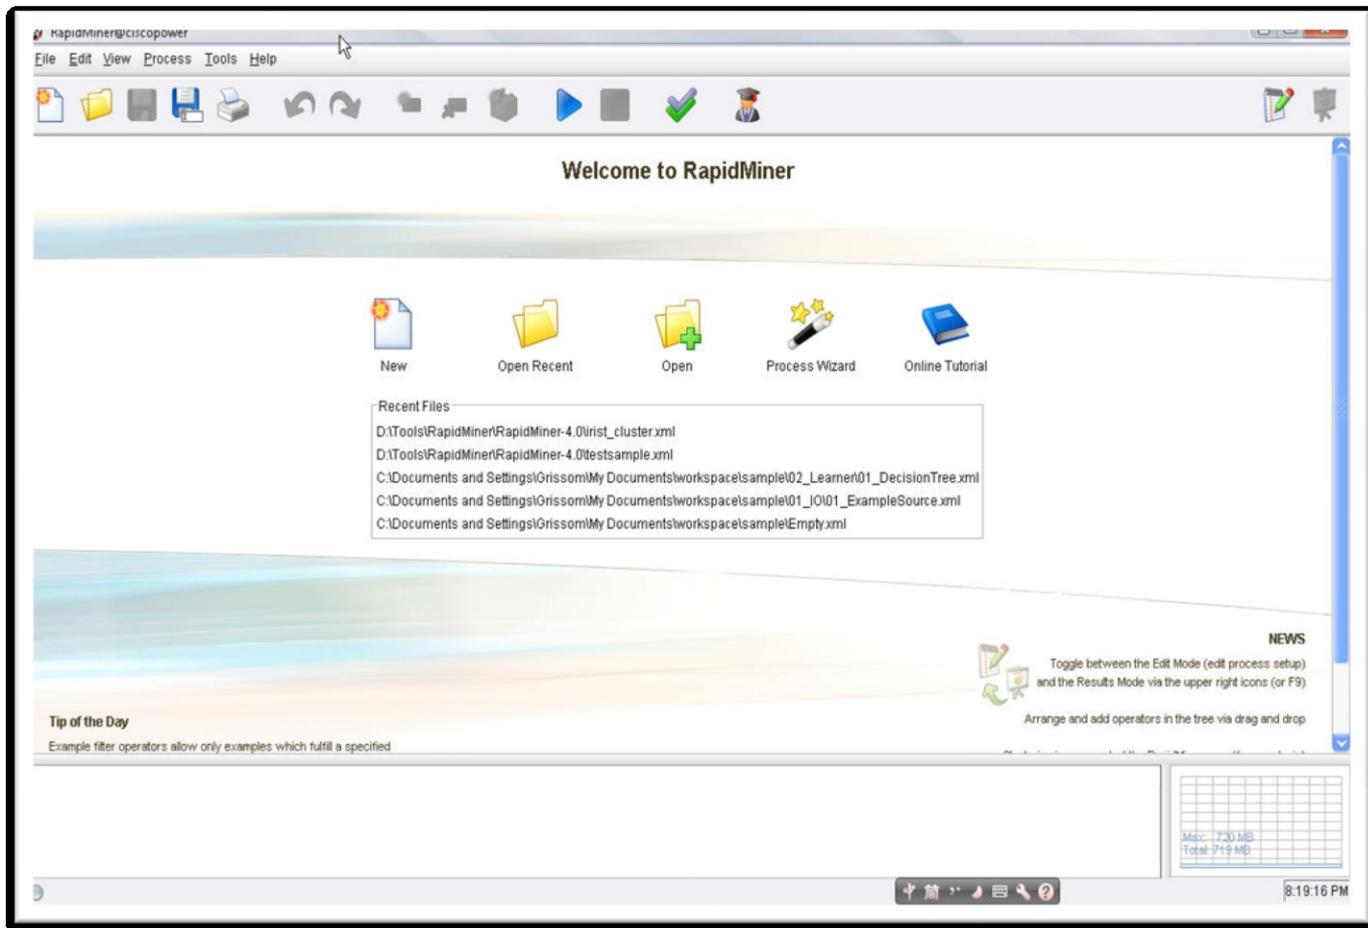
Tres pasos para el uso

- Asignar el archivo de datos primero
- Seleccionar funcionalidad
- Ejecutar Función utilizando rápido Minero

Los conjuntos de datos pueden utilizar formato ARFF, pero otros formatos también

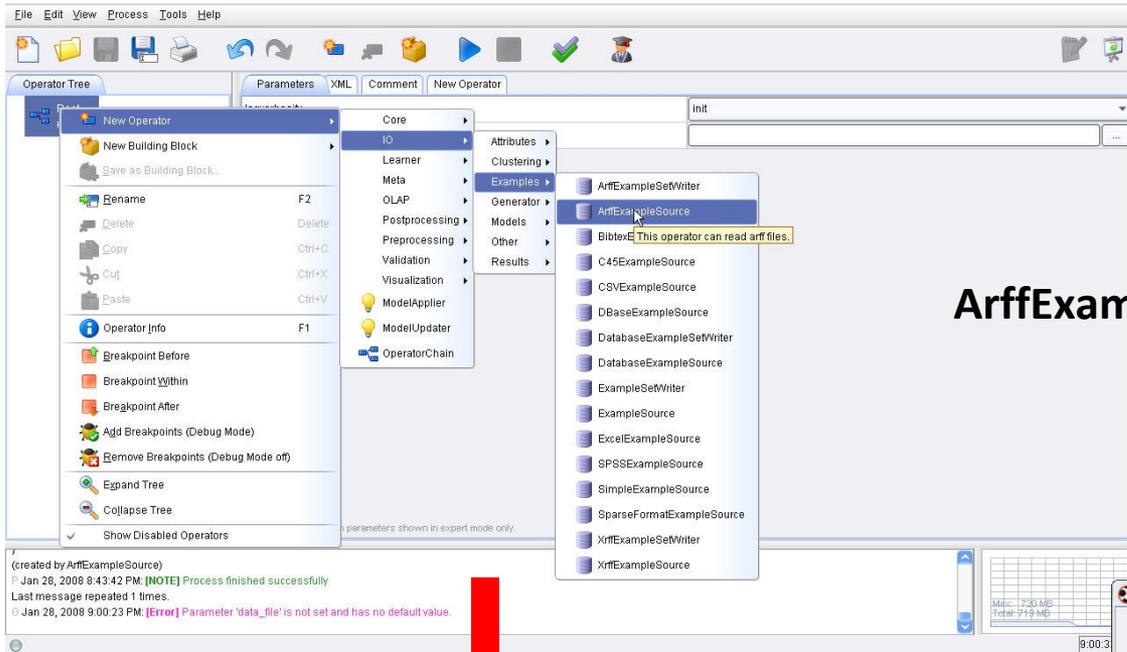
<http://rapid-i.com/content/view/130/82/>

➤ Crear un proyecto Rapid Miner (opción “new”)

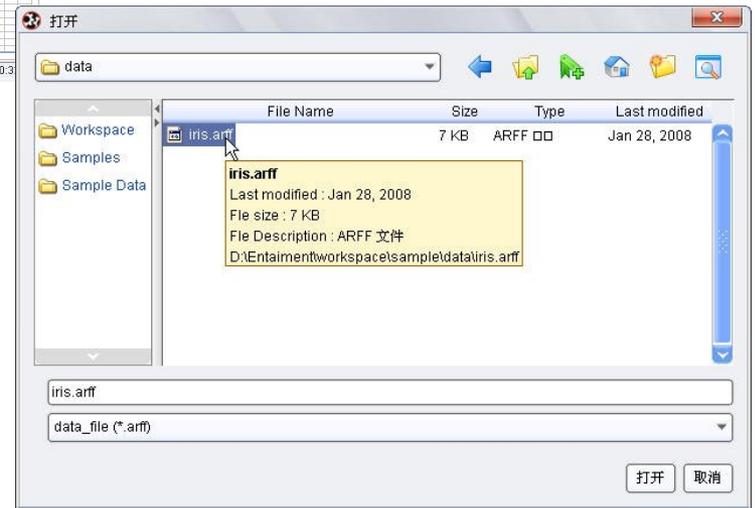
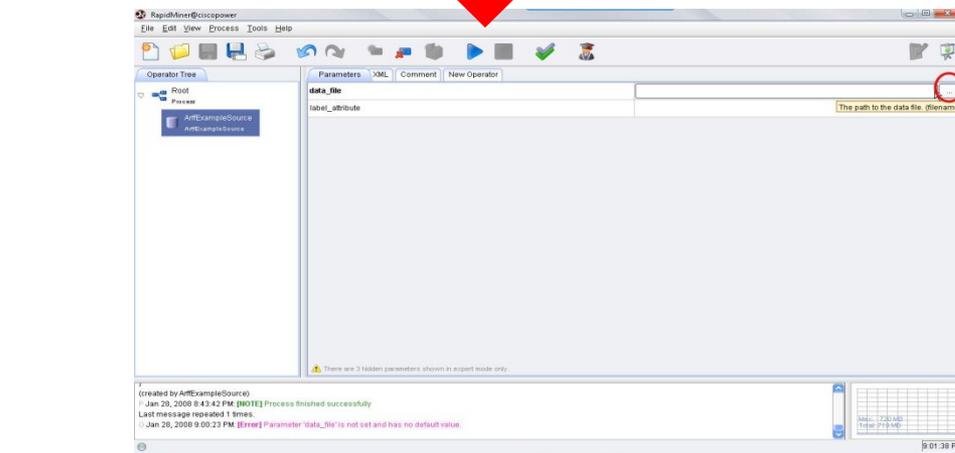


Establecer una fuente de datos para el proyecto

➤ Arff, excel , etc

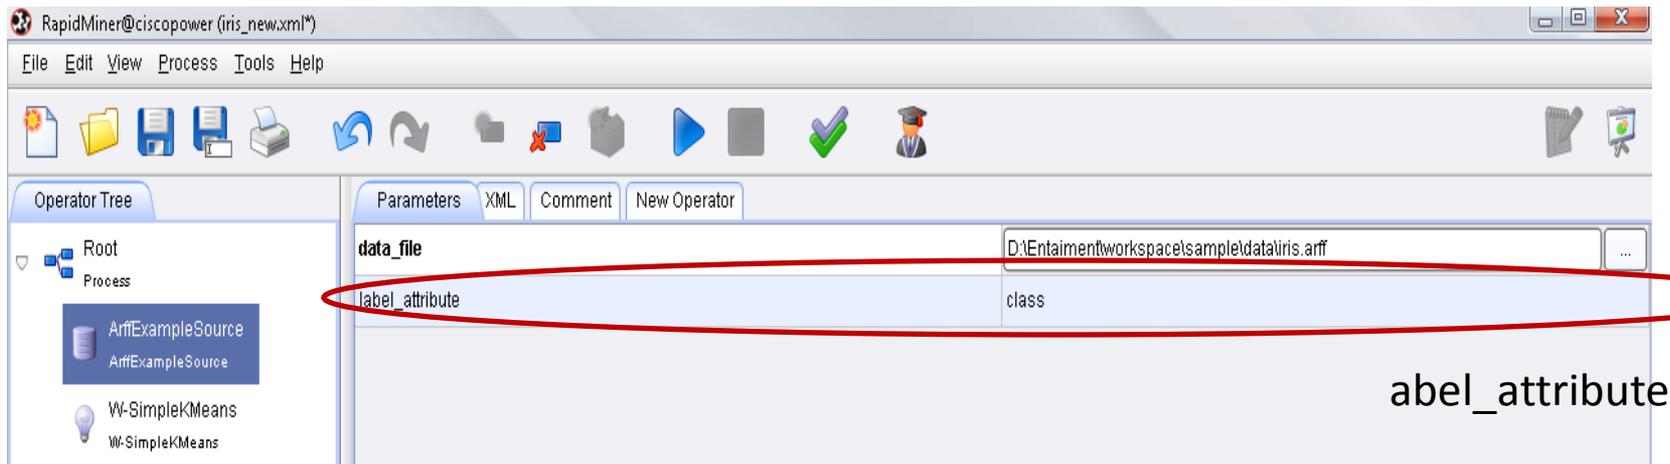


ArffExampleSource" menu



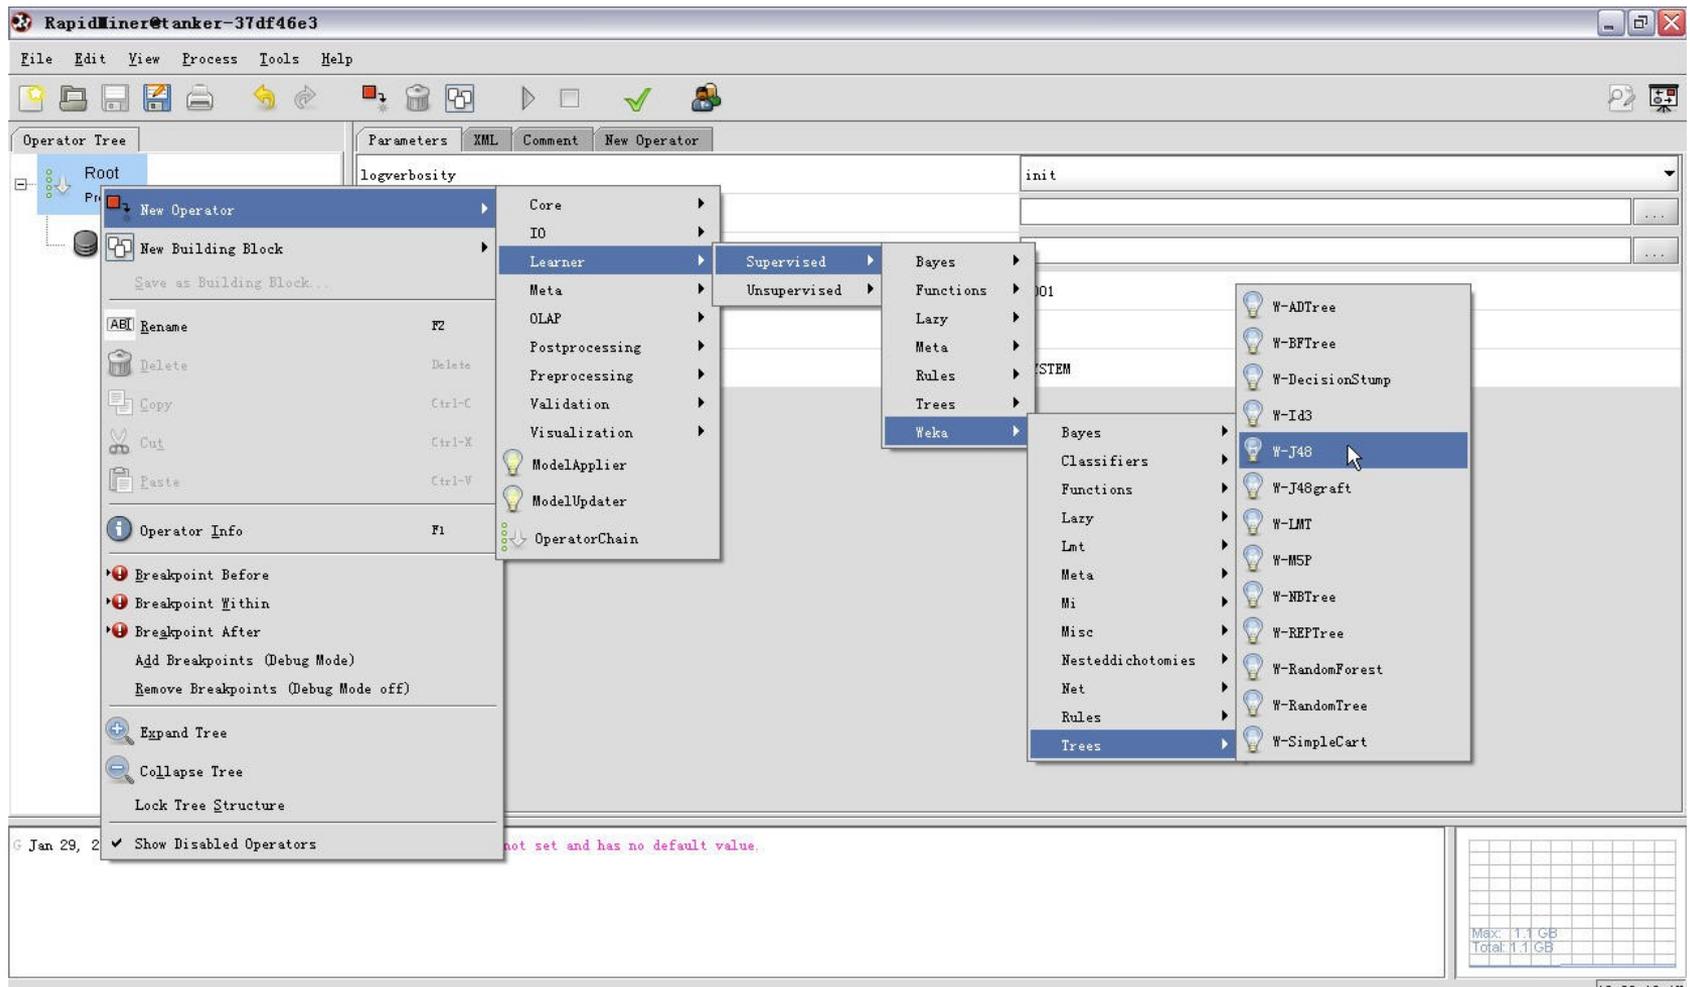
Escoger etiqueta atributo

➤ qué atributo en el origen de datos es el atributo de clase.



Selecccion funcionalidad

clustering, classification, decision tree, etc.



Escoger parámetros

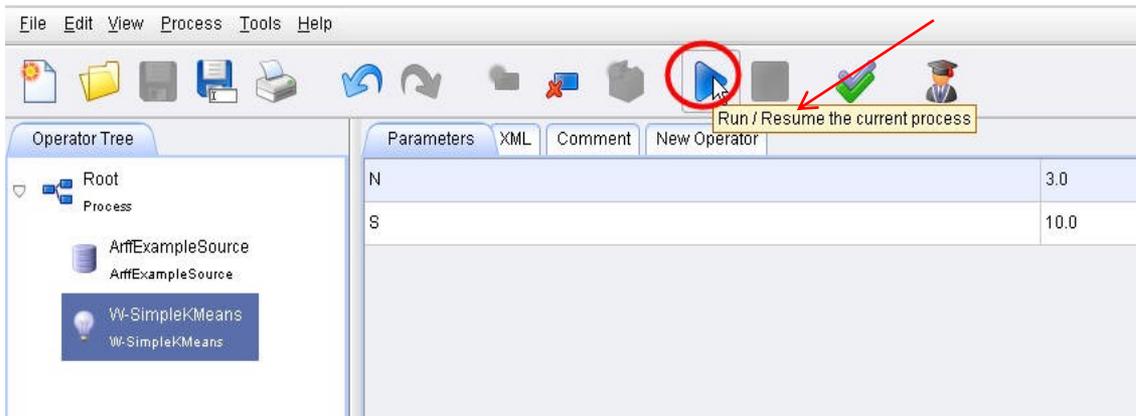
The screenshot displays the RapidMiner interface with the following components:

- Operator Tree:** Shows a process flow starting with 'AmExampleSource' and a 'W-J48' operator.
- Parameters Panel:** Lists various parameters for the W-J48 operator, each with a description and a checkbox. The 'C' parameter is currently set to 0.25.
- Output Console:** Displays the generated decision tree rules and statistics.
- System Monitor:** Shows memory usage (Mem: 1.1 GB, Total: 1.1 GB).
- Timestamp:** 12:03:02 AM.

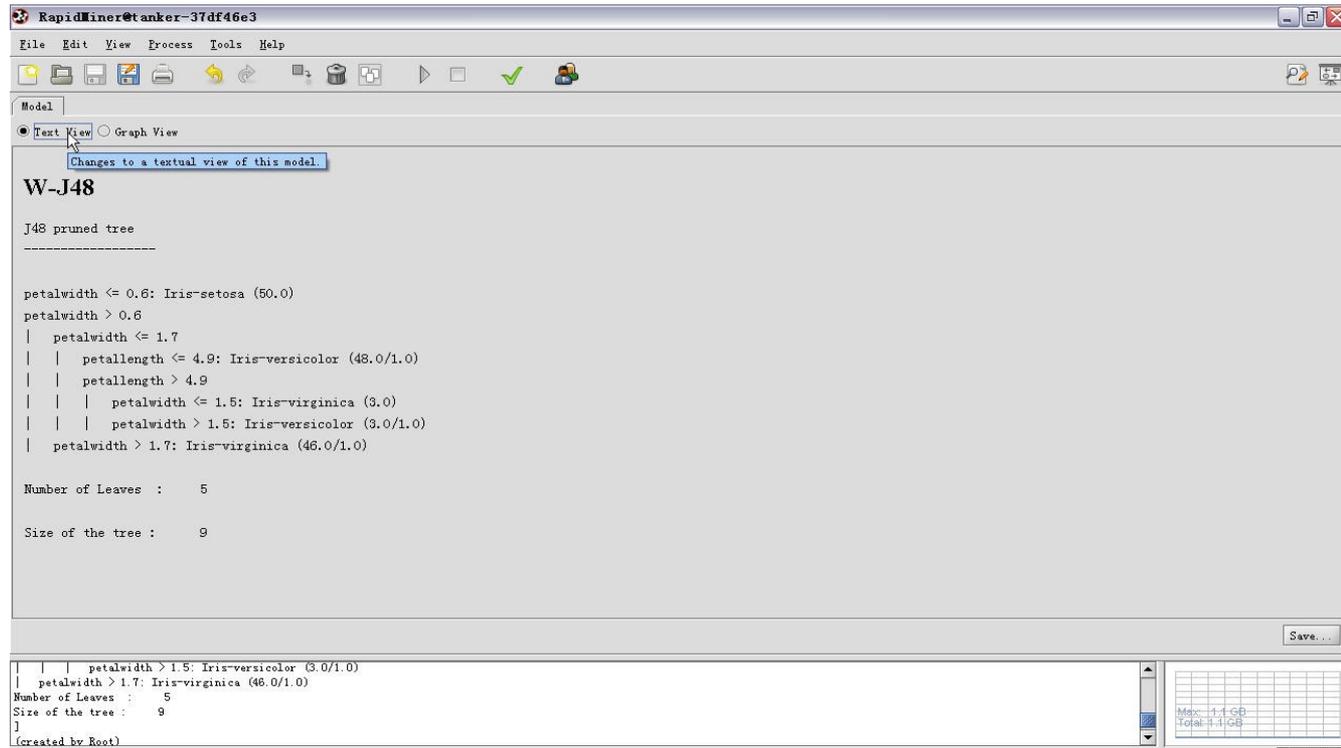
Parameter	Description	Value	Checkbox
keep_example_set	Indicates if this input object should also be returned as output. (boolean, default: false)		<input type="checkbox"/>
U	Use unpruned tree. (boolean, default: false)		<input type="checkbox"/>
C	Set confidence threshold for pruning. (default 0.25) (real, -∞+∞)	0.25	<input type="checkbox"/>
M	Set minimum number of instances per leaf. (default 2) (real, -∞+∞)		<input type="checkbox"/>
R	Use reduced error pruning. (boolean, default: false)		<input type="checkbox"/>
N	Set number of folds for reduced error pruning. One fold is used as pruning set. (default 3) (string)		<input type="checkbox"/>
B	Use binary splits only. (boolean, default: false)		<input type="checkbox"/>
S	Don't perform subtree raising. (boolean, default: false)		<input type="checkbox"/>
L	Do not clean up after the tree has been built. (boolean, default: false)		<input type="checkbox"/>
A	Laplace smoothing for predicted probabilities. (boolean, default: false)		<input type="checkbox"/>
Q	Seed for random data shuffling (default 1) (string)		<input type="checkbox"/>

```
| | | petalwidth > 1.5: Iris-versicolor (3.0/1.0)
| | | petalwidth > 1.7: Iris-virginica (46.0/1.0)
Number of Leaves : 5
Size of the tree : 9
]
(created by Root)
```

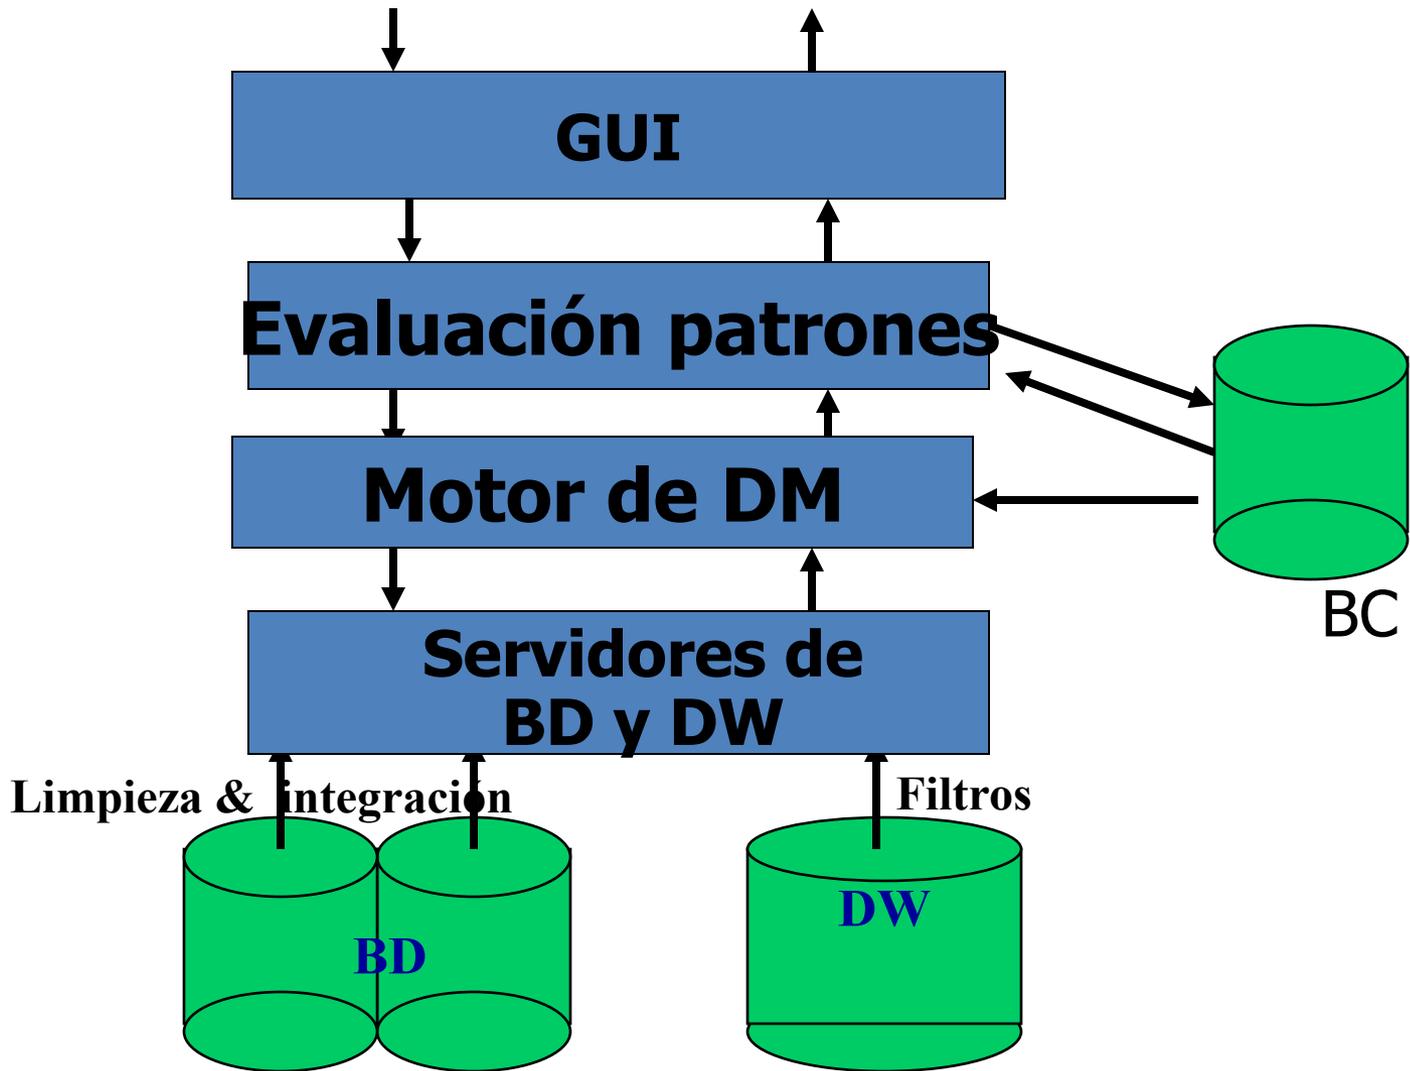
Ejecutar



resultados



Minería de Datos e Inteligencia de Negocio



Minería de Datos e Inteligencia de Negocio

- Financieras
- Comercio
- Seguros
- Educación
- Medicina
- Bioinformática
- Otras áreas

Minería de Datos e Inteligencia de Negocio

Agente comercial: ¿Debo conceder una hipoteca a un cliente?

Datos:

cid	Credit-p (years)	Credit-a (euros)	Salary (euros)	Own House	Defaulter accounts	...	Returns-credit
101	15	60.000	2.200	yes	2	...	no
102	2	30.000	3.500	yes	0	...	yes
103	9	9.000	1.700	yes	1	...	no
104	15	18.000	1.900	no	0	...	yes
105	10	24.000	2.100	no	0	...	no
...

Modelo generado:

Minería de datos



If Defaulter-accounts > 0 **then** Returns-credit = no

If Defaulter-accounts = 0 **and** [(Salary > 2500) **or** (Credit-p > 10)] **then** Returns-credit = yes

Minería de Datos e Inteligencia de Negocio

Supermercado: ¿Cuándo los clientes compran huevos, también compran aceite?

Datos:

BasketId	Eggs	Oil	Nappies	Wine	Milk	Butter	Salmon	Endive	...
1	yes	yes	no	yes	no	yes	yes	yes	...
2	no	yes	no	no	yes	no	no	yes	...
3	no	no	yes	no	yes	no	no	no	...
4	no	yes	yes	no	yes	no	no	no	...
5	yes	yes	no	no	no	yes	no	yes	...
6	yes	no	no	yes	yes	yes	yes	no	...
7	no	no	no	no	no	no	no	no	...
8	yes	yes	yes	yes	yes	yes	yes	no	...
...

Modelo generado:



Minería de datos

Eggs -> Oil: Confianza = 75%, Soporte = 37%

Minería de Datos e Inteligencia de Negocio

Gestión de personal de una empresa: ¿Qué clases de empleados hay contratados?

Datos:

Id	Salary	Married	Car	Children	Rent/Owner	Union	Off sick/year	Work years	Gender
1	10000	yes	no	0	Rent	no	7	15	M
2	20000	no	yes	1	Rent	yes	3	3	F
3	15000	yes	yes	2	Owner	yes	5	10	M
4	30000	yes	yes	1	Rent	no	15	7	F
5	10000	yes	yes	0	Owner	yes	1	6	M
6	40000	no	yes	0	Rent	yes	3	16	F
7	25000	no	no	0	Rent	yes	0	8	M
8	20000	no	yes	0	Owner	yes	2	6	F
15	8000	no	yes	0	Rent	no	3	2	M
...

Modelo generado:



Minería de datos

Grupo 1: Sin niños y en una casa alquilada. Bajo número de uniones. Muchos días enfermos

Grupo 2: Sin niños y con coche. Alto número de uniones. Pocos días enfermos. Más mujeres y en una casa alquilada

Grupo 3: Con niños, casados y con coche. Más hombres y normalmente propietarios de casa. Bajo número de uniones

Minería de Datos e Inteligencia de Negocio

Tienda de TV: ¿Cuántas televisiones planas se venderán el próximo mes?

Datos:

PRODUCT	Month-12	...	Month-4	Month-3	Month-2	Month-1	Month
Flat TV 30'	20	...	52	14	139	74	?
Video-dvd-recorder	11	...	43	32	26	59	?
Discman	50	...	61	14	5	28	?
Five star fridge	3	...	21	27	1	49	?
Three star fridge	14	...	27	2	25	12	?
...

Modelo generado:

Minería de datos

Modelo lineal: número de televisiones para el próximo mes

$$V(\text{month})_{flatTV} = 0.62 V(\text{Month-1})_{flat-TV} + 0.33 V(\text{Month-2})_{flat-TV} + 0.12 V(\text{Month-1})_{DVD-Recorder} - 0.05$$