



Métodos de Minería de Datos

ALGORITMOS SUPERVISADOS

JAIME MIRANDA

Departamento de Ingeniería Industrial
Universidad de Chile

CONCEPTOS BÁSICOS

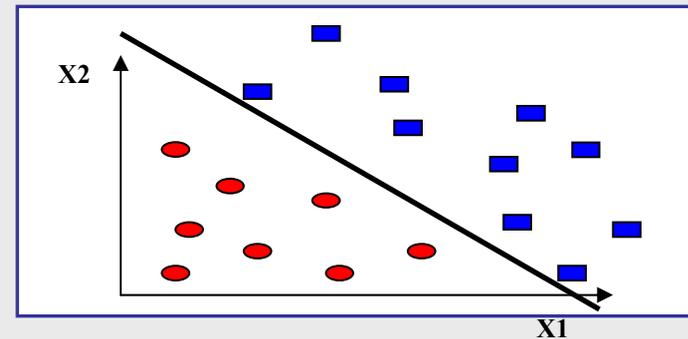
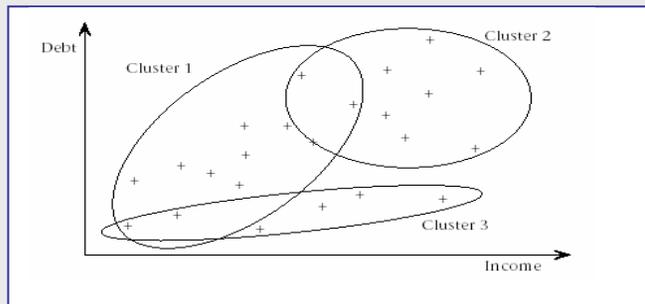
→ Medida de distancia

→ Prototipo o centro de clase más cercana

→ Entre más cerca mayor pertenencia de a la clase

→ Hipersuperficies

→ Clasificación de acuerdo a si los objetos están a uno u otro lado de una hipersuperficie o conjunto de hiperplanos



Regla de Bayes

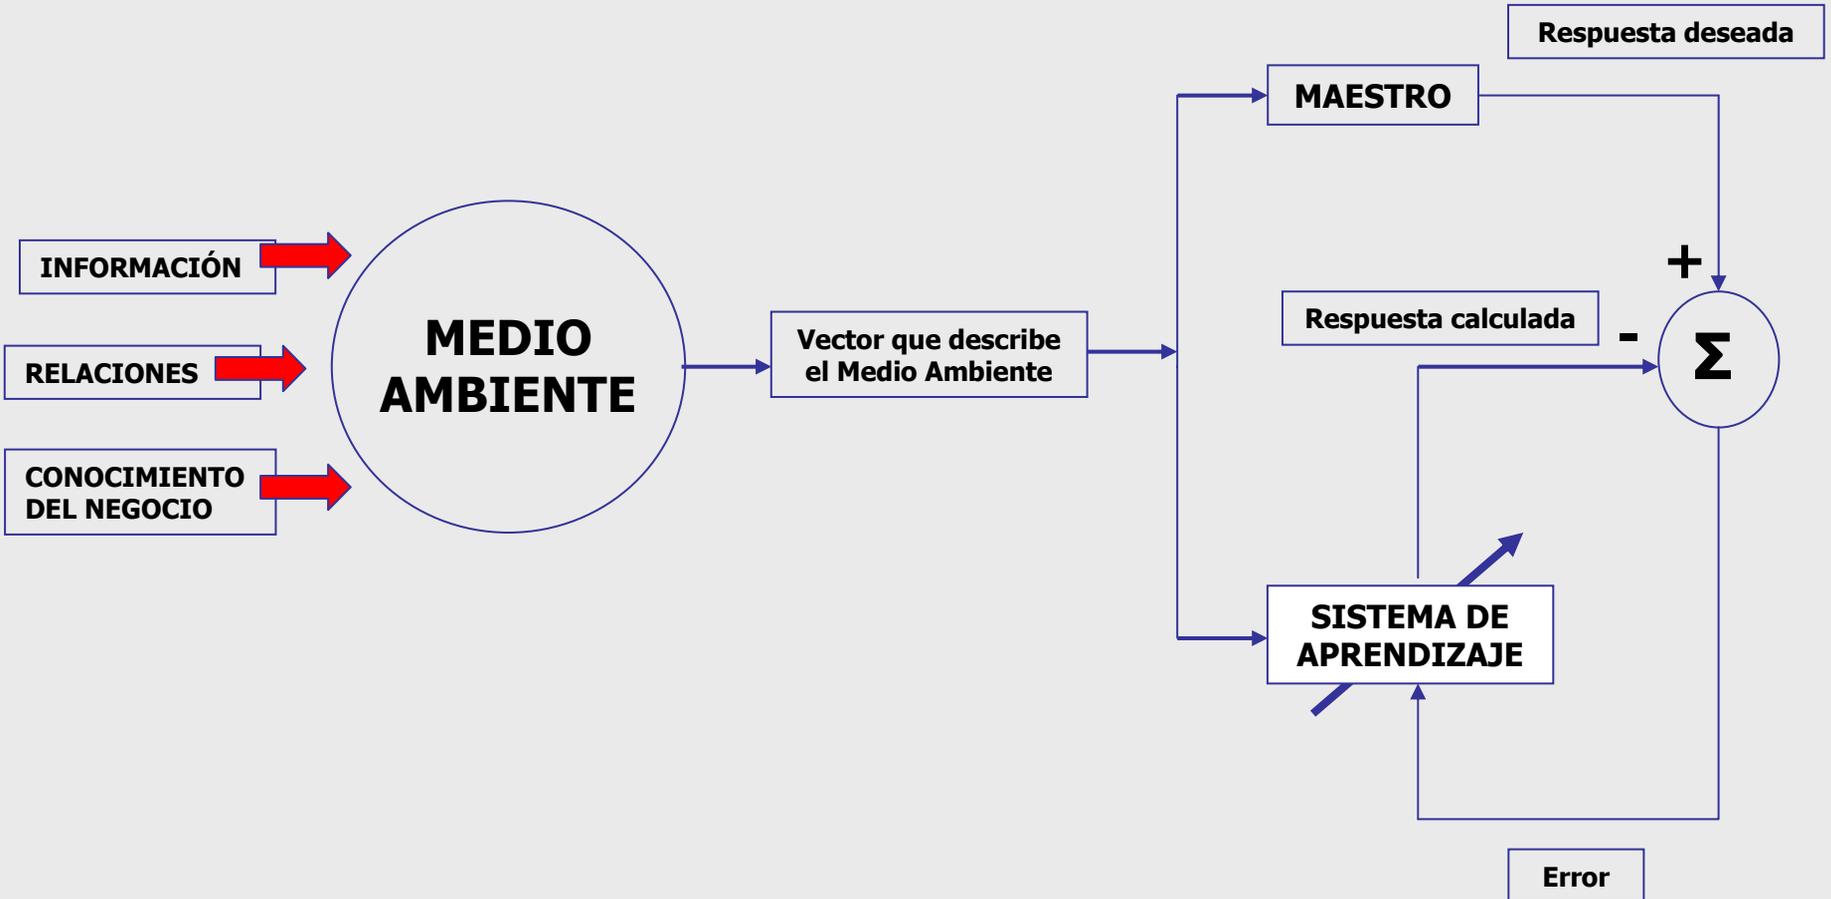
$$p(C_K / X_L) = \frac{p(X_L / C_K) * p(C_K)}{p(X_L)}$$

Donde:

C_k denota la clase k del atributo elegido como base.

X_L son los atributos a los cuales se condicionara en probabilidad.

DIAGRAMA DE APRENDIZAJE SUPERVISADO





MODELOS SUPERVISADOS

ÁRBOLES DE DECISIÓN

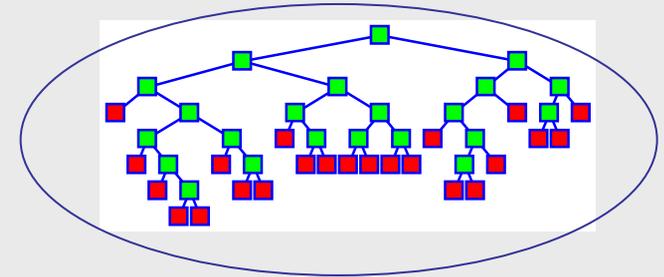
Jaime Miranda

Departamento de Ingeniería Industrial
Universidad de Chile

ÁRBOLES DE DECISIÓN

Aplicaciones

- Segmentación de clientes
- Generación de reglas de clasificación en general



Fortalezas

- Fácil interpretación y entendimiento
- Genera un ranking automático de variables
- Rápida convergencia del algoritmo

Debilidades

- Si poseen mucha “profundidad” son difíciles de interpretar
- Posibilidades discretas: relacionado a variables con muchas categorías

UN PEQUEÑO EJEMPLO...

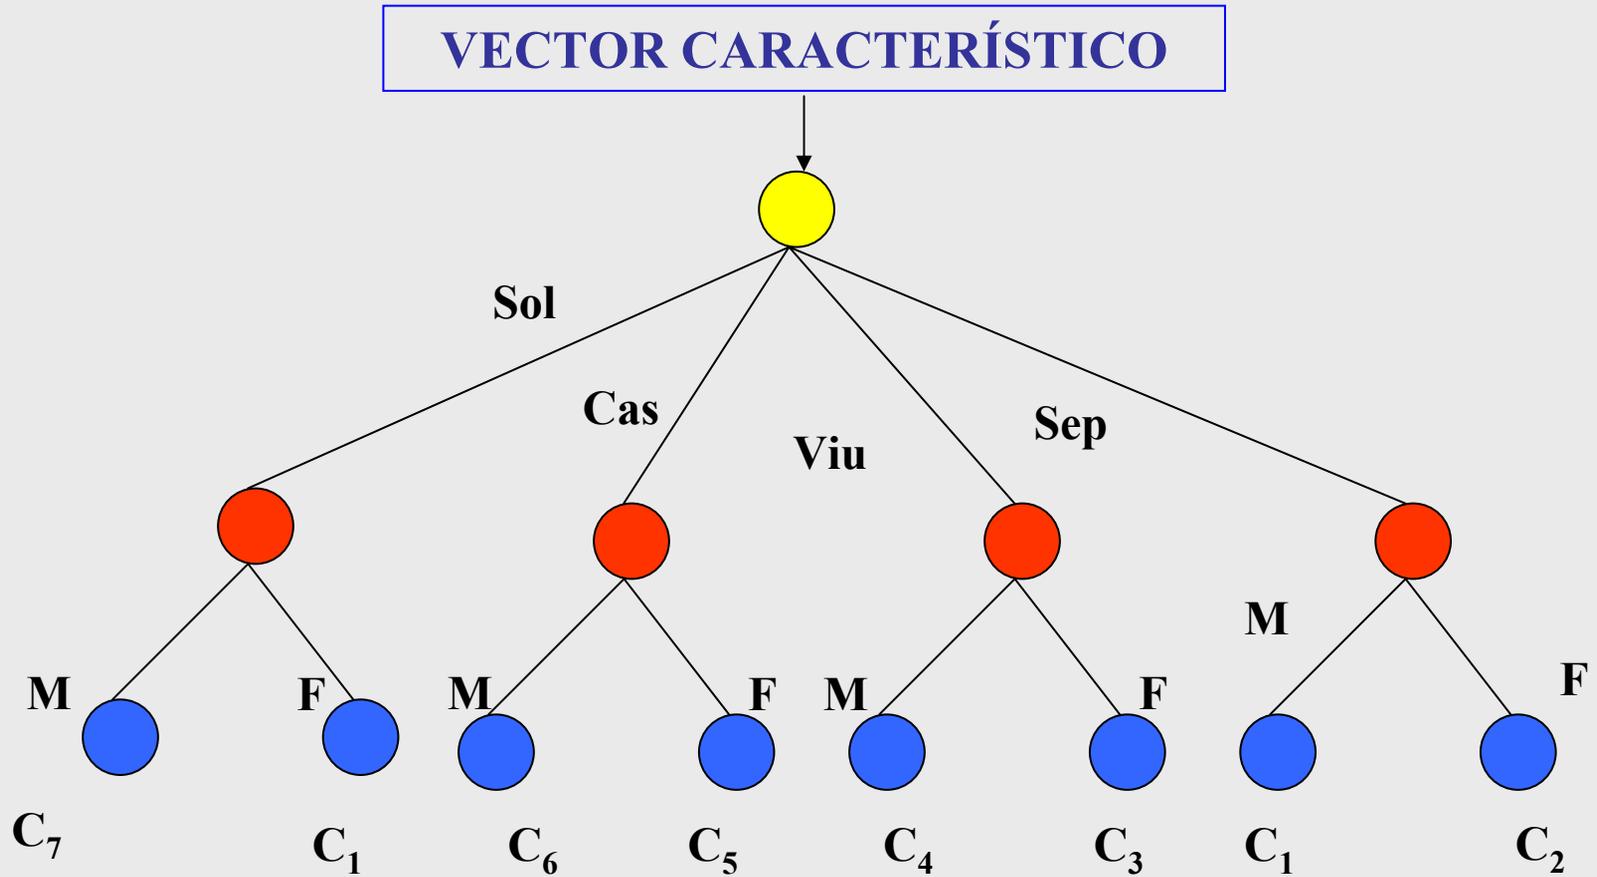
Determinación de la renta usando variables sociodemográficas

	Ck	X1	X2	X3	X4
k	Nivel de Renta	Estado Civil	Nivel Educativo	Rango Edad	Sexo
1	0-200	Soltero	Ed. Media	20-29	Hombres
2	201-400			30-39	
3	401-600	Casado	EUN	40-49	
4	601-800			50-59	
5	801-1000	Separado	Tecnico	60-69	Mujeres
6	1001-2000	Viudo	Universitario	70-79	
7	2001-15000			80-89	

DESCRIPCIÓN :

- Información de clientes completa: **poseen algún valor en todas las variables**
- Un conjunto de clientes que no se les conoce la renta
- **PROBLEMA:** Se desea estimar la renta de un conjunto nuevo de clientes

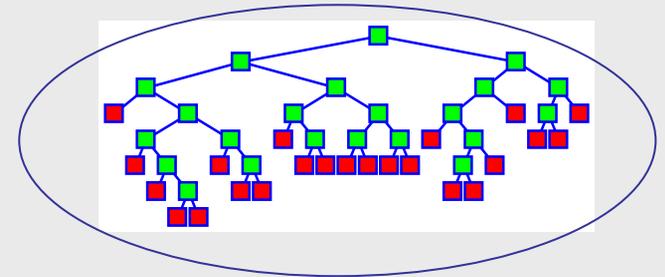
UN PEQUEÑO EJEMPLO...



Separan datos en conjuntos de reglas que probablemente respondan a un efecto o variable objetivo

Son un conjunto:

- Conexo
- Acíclico
- Dirigido.



Permite tener :

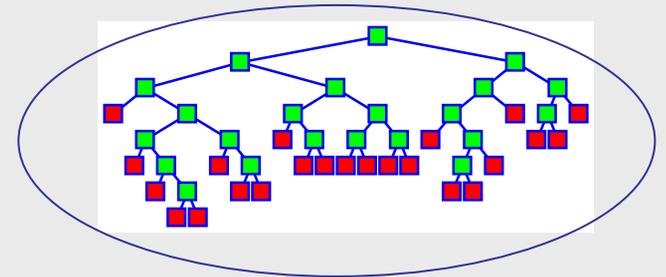
- Valores mal clasificados.
- Valores perdidos.
- Una ilustración sobre la manera en que se pueden desglosar los problemas y la secuencia del proceso de decisión (subproblemas).

CLASIFICACIÓN

- Se trata de encontrar el grado de pertenencia de un objeto a una clase específica

REGRESIÓN

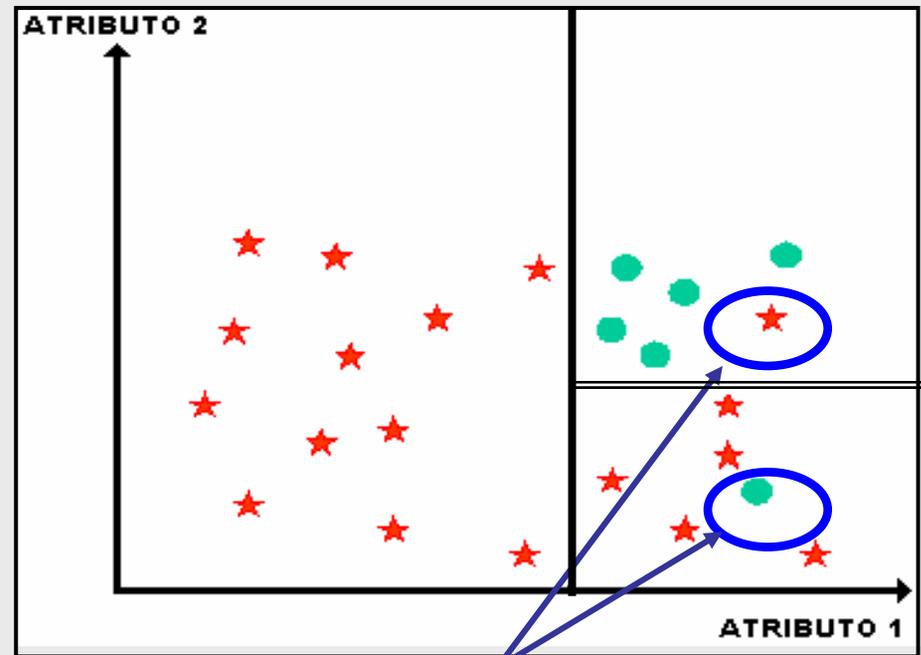
- Se trata de predecir un valor futuro de una variable en base a su comportamiento pasado
- Usado principalmente en series temporales



EN FORMA GENERAL ...

OBJETIVO

“Obtener modelos que discrimine las instancias de entrada en diferentes clases de equivalencia por medio de los valores de diferentes atributos.”



**Errores de
clasificación**

ARQUITECTURA DEL ÁRBOL

NODO

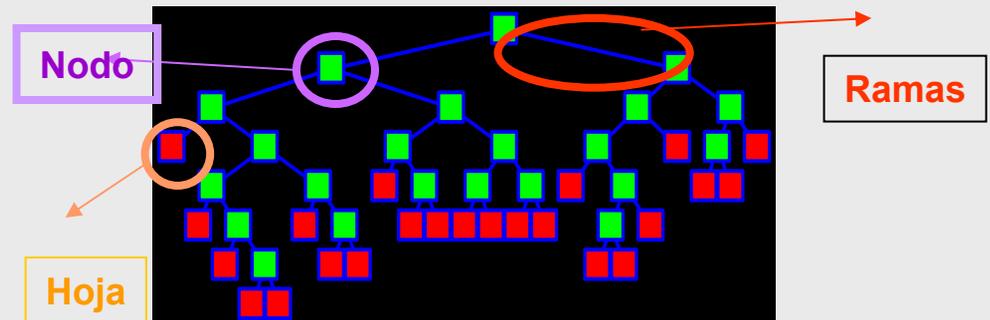
→ es un punto de unión, donde se representa un lugar en el que se debe tomar una decisión.

RAMA

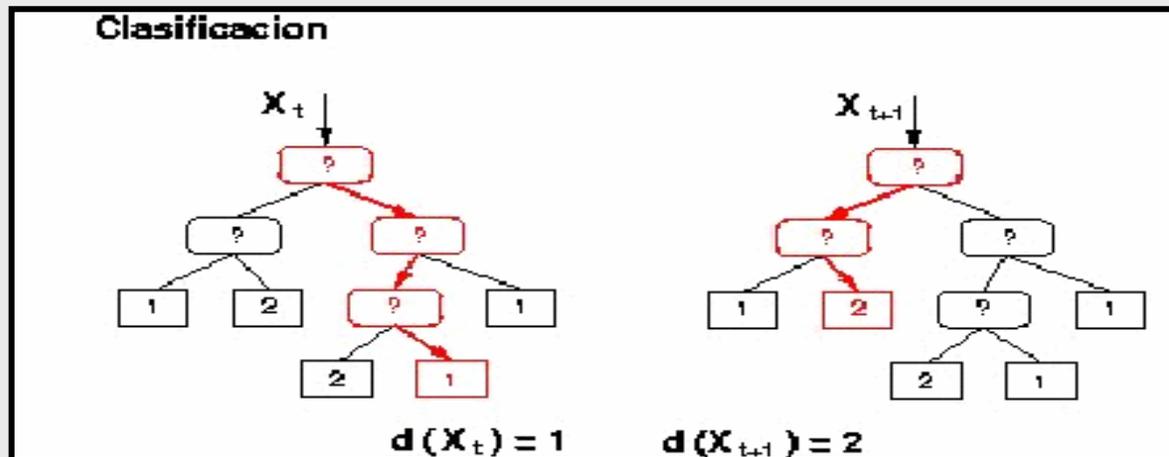
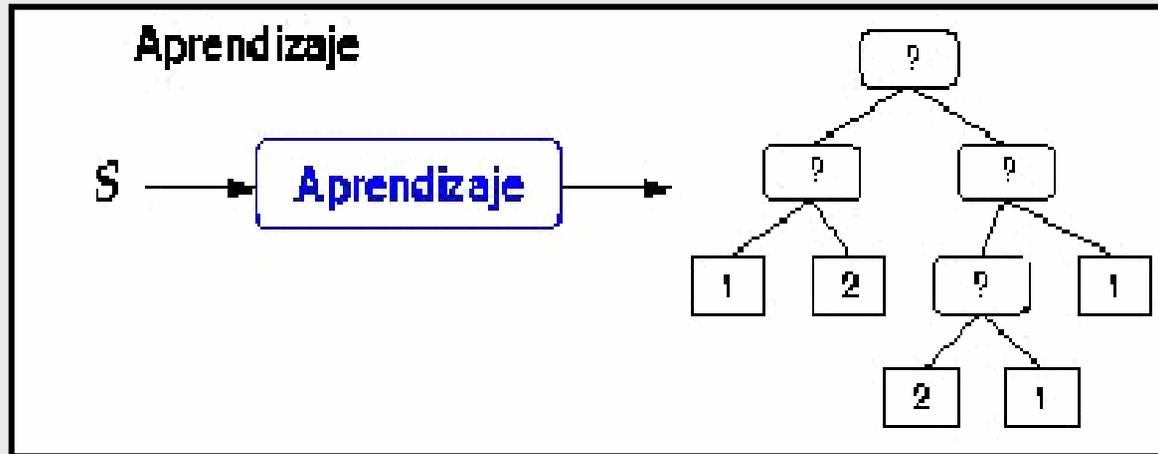
→ representa un arco de conexión entre nodos.

HOJA

→ es un nodo terminal (sin hijos)



ETAPAS ENTRENAMIENTO



RESPECTO A LAS DIVISIONES...

Existen varios criterios para poder hacer la división en el nodo (+ 15)

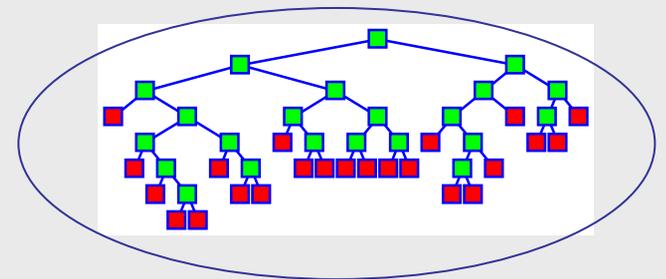
→ Gini Index

→ Twoing

→ CHAID

Cada partición depende de un único atributo

La gran mayoría se basa en medidas de diversidad o “desorden” del nodo



GINI INDEX

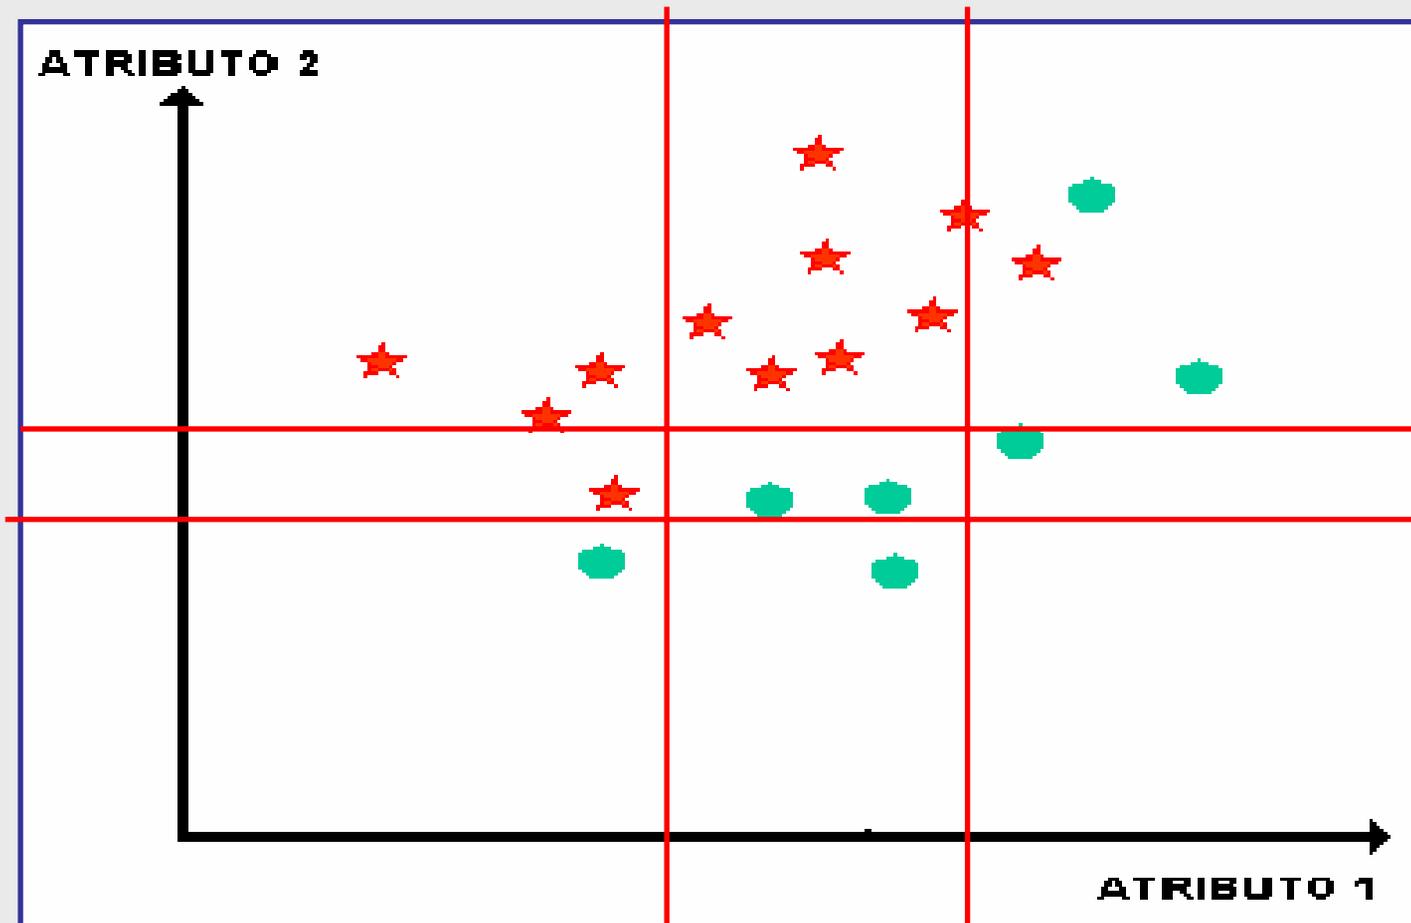
$$Gini(V) = \sum_{i=j} p(v) * \sum_{i \neq j} p(i \setminus v) * p(j \setminus v)$$

Probabilidad de estar en el nodo v

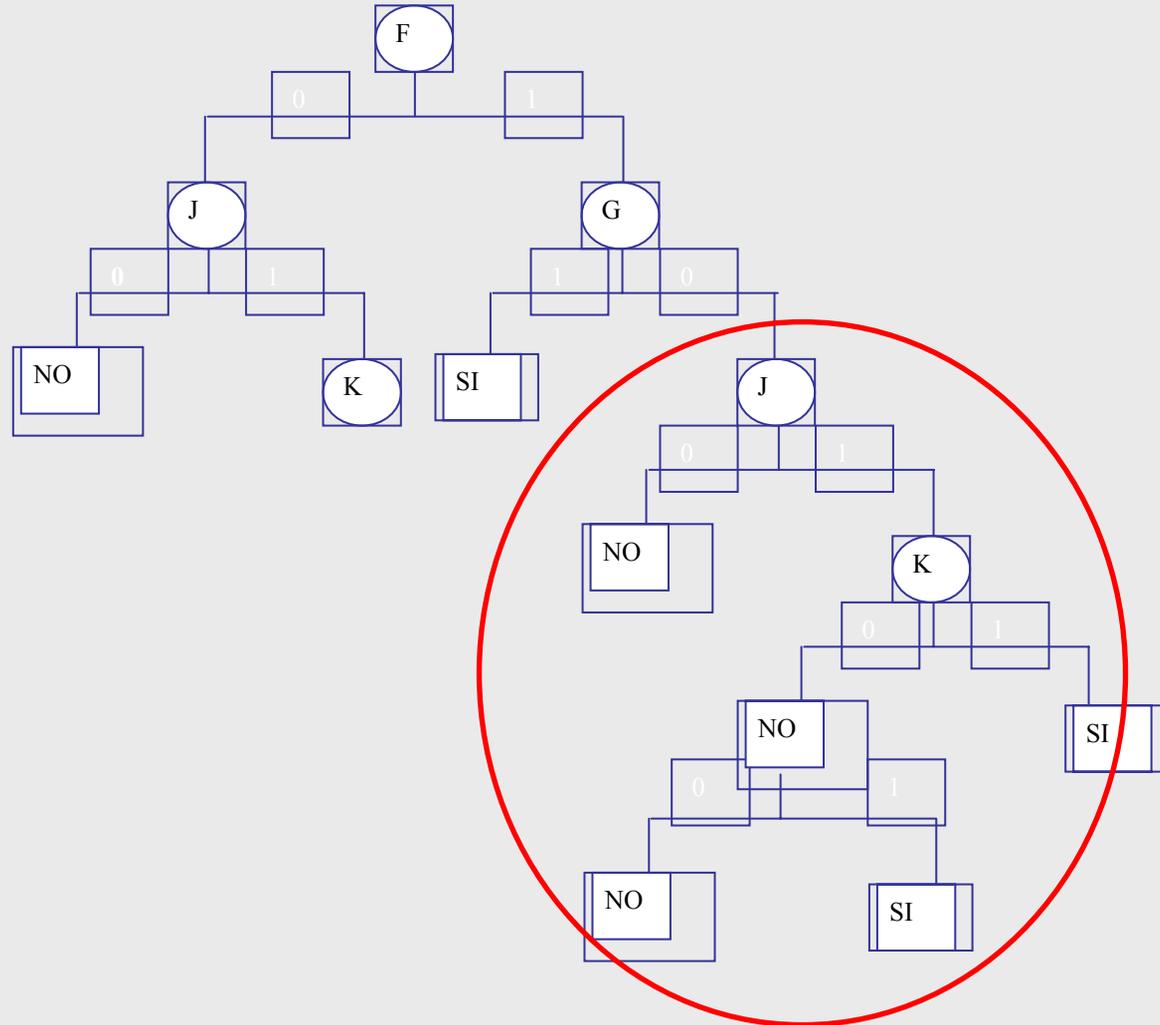
Probabilidad de pertenecer a la clase i/j dado que estoy en v

- Se elige el atributo que posee el mayor índice de GINI
- A medida que se baja en el árbol el atributo posee menor índice de GINI
- Este índice ve que tan heterogéneo es el nodo respecto a los elementos que lo conforman

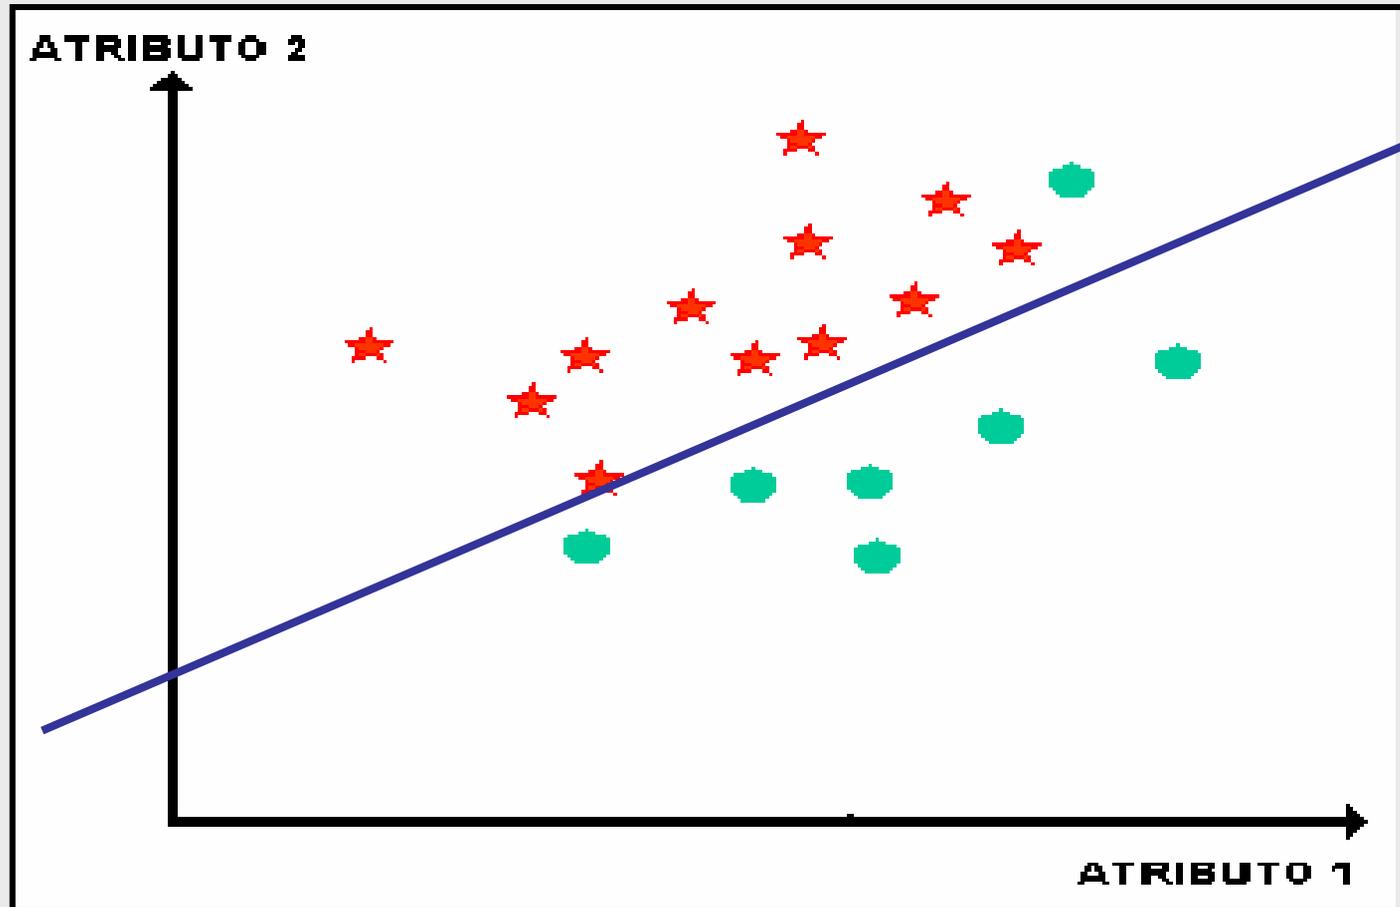
SOBREAJUSTE DEL MODELO



SOBREAJUSTE EN FORMA GRAFICA



SOLUCIÓN LINEAL

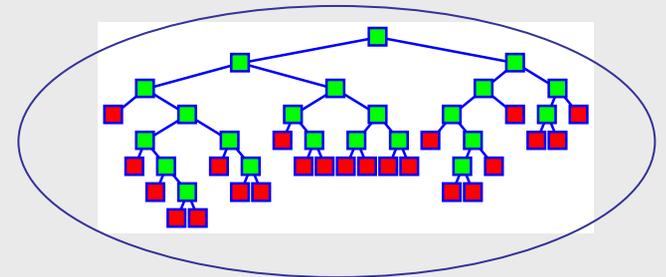


EXPLICABILIDAD

- Es intuitivo y da claras reglas de decisión
- Da una buena descripción visual en problemas

FÁCIL IMPLEMENTACIÓN Y CONSTRUCCIÓN

- Las reglas pueden ser implementadas en cualquier lenguaje lógico
- No necesitan de un fuerte apoyo computacional



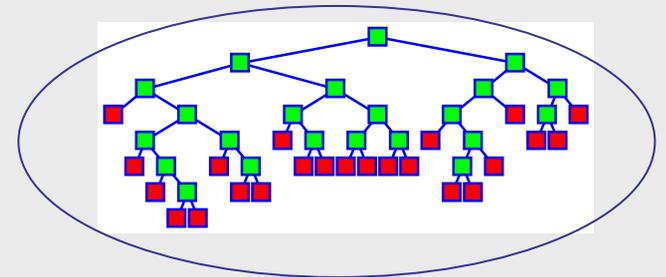
ATRIBUTOS CON NUMEROSOS VALORES

→ Es debido a que inducen particiones más finas, que no sean significativos

TENER DEMASIADOS NIVELES

→ Al tener mayor profundidad la explicabilidad decae

→ Necesidad de altos volúmenes de información



RUIDO

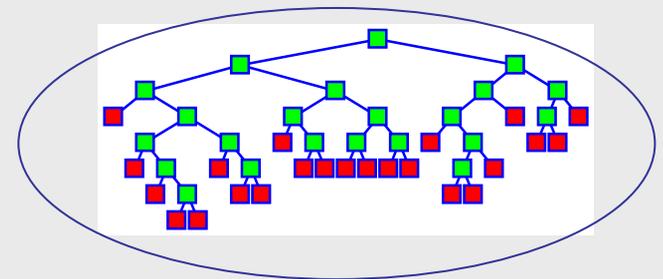
- Ejemplos con la misma descripción pero distinta clase
- **Consecuencia:** error no nulo en ejemplos de entrenamiento.

POSIBILIDADES DISCRETAS

- Solo es posible tener un número finito de “ramas” y no un continuo.

SOBREAJUSTE

- Uso de atributos no relevantes para ajustar árbol a datos
- **Consecuencia:** disminuye capacidad generalización del modelo.





Métodos de Minería de Datos

ALGORITMOS SUPERVISADOS

JAIME MIRANDA

Departamento de Ingeniería Industrial
Universidad de Chile