

ALGORITMO ID3

- ◆ Desarrollado por J. Ross Quinlan en 1983.
- ◆ ID3 significa *Induction Decision Trees*.
- ◆ Pertenece a la familia TDIDT (Top-Down Induction of Decision Trees).

Objetivo

- ◆ Construir un **árbol de decisión** que explique cada instancia de la secuencia de entrada de la manera más compacta posible a partir de una tabla de inducción.

- ◆ En cada momento elige el **mejor atributo** dependiendo de una determinada **heurística**.
- ◆ Determinar las variables que portan información relevante para la solución del problema
- ◆ Establecer la secuencia dentro del árbol de decisión.

Inconveniente

- ◆ Favorece indirectamente a aquellos atributos con muchos valores, los cuales no tienen que ser los más útiles.
- ◆ Genera árboles de decisión a partir de ejemplos de partida.

- ◆ Conflictos en la base de conocimientos donde diferentes soluciones se alcanzan con variables con los mismos valores asociados.
- ◆ Manejo discreto de los valores de las variables (rangos para discretizar una variable continua).
- ◆ Generación de grandes árboles de decisión que no representan garantía de reglas eficientes.
- ◆ Aplicables sólo a problemas de clasificación y diagnóstico.
- ◆ La generación de conclusiones intermedias se encuentra implícito en la generación de reglas a partir de la tabla de inducción (no se aprecia discriminación en el árbol de decisión).

Características

- ◆ Crear un árbol de decisión como un método para aproximar una función objetivo de valores **discretos**, que es resistente al ruido en los datos y que es capaz de hallar o aprender de una disyunción de expresiones.
- ◆ El resultado puede expresarse como un conjunto de reglas **Si-entonces**.
- ◆ Intenta encontrar el árbol más sencillo que separa mejor los ejemplos.
- ◆ Es **recursivo**.
- ◆ No se realiza "***backtracking***".
- ◆ Utiliza la **entropía**.

Estructura

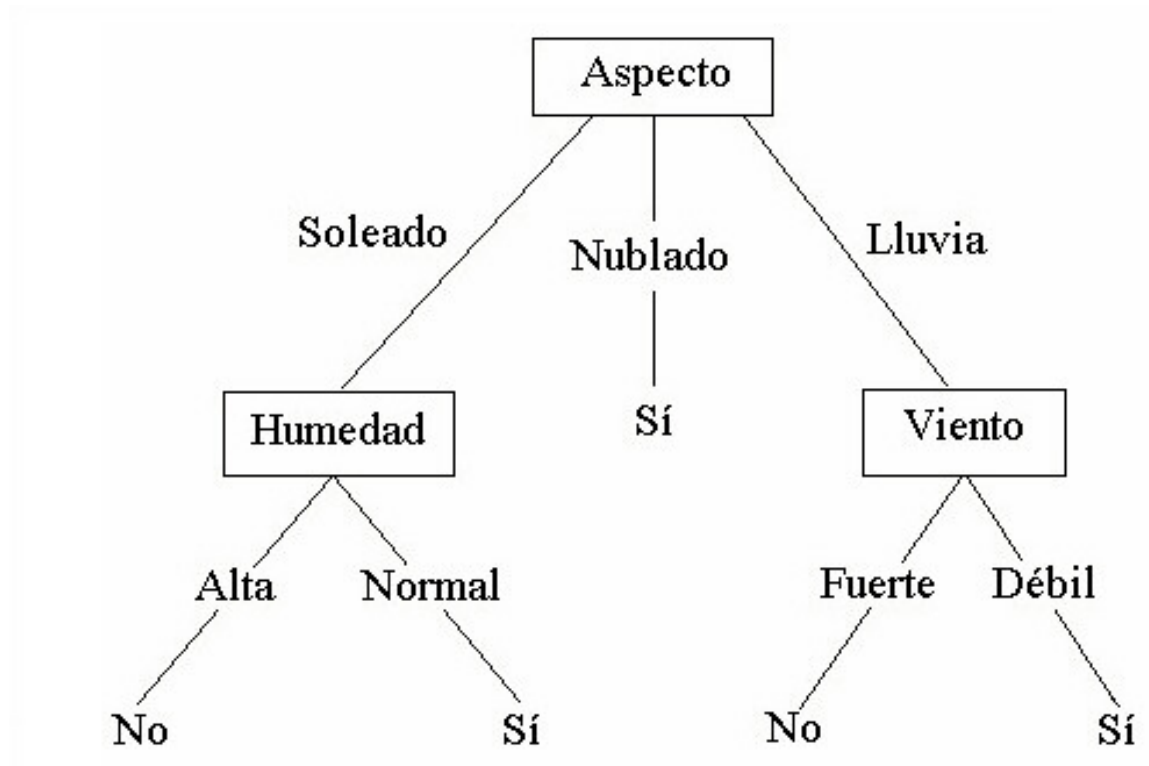
Los árboles de decisión están formados por:

- ◆ **Nodos:** Nombres o identificadores de los atributos.
- ◆ **Ramas:** Posibles valores del atributo asociado al nodo.
- ◆ **Hojas:** Conjuntos ya clasificados de ejemplos y etiquetados con el nombre de una clase.

Un ejemplo de árbol de decisión es el siguiente:

Datos

- **Atributos:** Son los factores que influyen la clasificación o decisión.
- La selección de atributos debe basarse en el conocimiento acumulado por la experiencia.
- En este algoritmo cada atributo forma un nodo intermedio en un árbol cuyas hojas o nodos terminales son las clases o decisiones.
- **Clase:** Posibles valores de solución
- **Ejemplos:** Es el conjunto de combinaciones de atributos dados.
- Dado el conjunto de ejemplos, el ID3 selecciona el atributo que subdivide los ejemplos *de la mejor manera*.



- ◆ **Entropía:** Es la medida de la **incertidumbre** que hay en un sistema. Es decir, ante una determinada situación, la **probabilidad** de que ocurra cada uno de los posibles resultados.

- ◆ La función de entropía más usada es la binaria. Su expresión es con logaritmos base 2:

$$I(p,n) = -(p/(p+n)) * \text{LOG}_2(p/(p+n)) - (n/(p+n)) * \text{LOG}_2(n/(p+n))$$

Recuerde:

Si $10^x = 1,000$ entonces $x = 3$

Es decir, si ... $10^x = y$ entonces $x = \log_{10}(y)$

Si $2^x = y$ entonces $x = \log_2(y)$

Para calcular el logaritmo base 2:

Si $2^x = y$ entonces ...

$$x = \log_{10}(y) / \log_{10}(2)$$

Aplicado a la fórmula de entropía...

$$\log_{10}(p/p+n) / \log_{10}(2)$$

Cálculo del total de la entropía de los atributos:

$$E(A) = ((p_1+n_1) * I(p_1, n_1) + (p_2+n_2) * I(p_2, n_2) + \dots + (p_v+n_v) * I(p_v, n_v)) / (p+n)$$

Interpretación de la entropía:

- Un ejemplo de la entropía binaria podría ser sacar una bola de color blanco o negro de una bolsa.
- Si en la bolsa hay 3 bolas blancas y 3 negras el resultado es completamente

desconocido, es decir la incertidumbre es máxima, es decir la entropía es 1.

- Si en la bolsa hay 6 bolas negras el resultado es conocido de antemano, luego la incertidumbre no existe, y la entropía es 0.
- ♦ **Ganancia:** Es la diferencia entre la entropía de un nodo y la de uno de sus descendientes.
- ♦ En el fondo no es más que una **heurística**, que como veremos nos servirá para la elección del mejor atributo en cada nodo.

$$\text{Ganancia}(A) = I(p,n) - E(A)$$

- Un buen criterio parece ser escoger el atributo que *gana* la mayor información.
- ID3 examina todos los atributos y **escoge el de máxima ganancia**, forma la ramificación y usa el mismo proceso recursivamente para formar sub-árboles a partir de los \checkmark nodos generados

Procedimiento

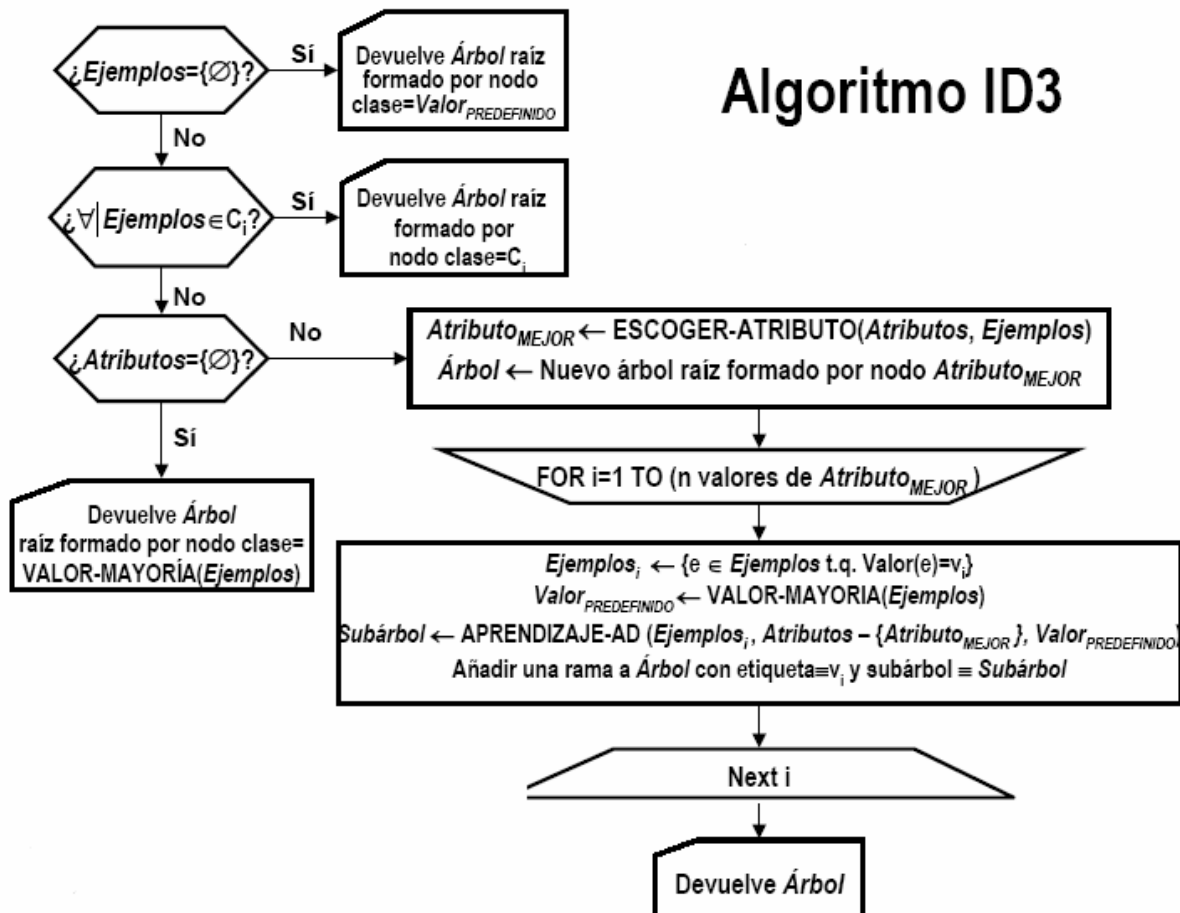
- El árbol de decisión se recorre desde la raíz y tanto en ella como en cada uno de los demás nodos se decide cuál rama tomar basándonos en el valor de algún atributo del ejemplar que se esté clasificando, hasta llegar a un nodo terminal (hoja), que corresponde a la clase en que queda clasificado el ejemplar.
- Los árboles de decisión se adaptan especialmente bien a ciertos tipos de problemas. Básicamente, los casos para

los que son apropiados son aquellos en los que:

- Los ejemplos pueden ser descritos como pares **valor-atributo**.
- La **función objetivo** toma valores **discretos**.
- Podemos tomar hipótesis con **disyunciones**.
- Posible existencia de **ruido** en el conjunto de entrenamiento.
- Los valores de algunos atributos en los ejemplos del conjunto de entrenamiento pueden ser **desconocidos**.

Diagrama de flujo

Algoritmo ID3



Ejemplo

Una persona se dispone a jugar golf y tomará su decisión de asistir considerando los siguientes factores climatológicos:

Caso #	General	Temper.	Humedad	Viento	Clase
1	asoleado	caliente	alta	no	N
2	asoleado	caliente	alta	si	N
3	nublado	caliente	alta	no	P
4	lluvioso	templada	alta	no	P
5	lluvioso	fría	normal	no	P
6	lluvioso	fría	normal	si	N
7	nublado	fría	normal	si	P
8	asoleado	templada	alta	no	N
9	asoleado	fría	normal	no	P
10	lluvioso	templada	normal	no	P
11	asoleado	templada	normal	si	P
12	nublado	templada	alta	si	P
13	nublado	caliente	normal	no	P
14	lluvioso	templada	alta	si	N

- ◆ Nueve objetos son clase P y cinco son clase N
- ◆ La información requerida para la clasificación es:

$$\begin{aligned} I(p,n) &= - (9/14) * \log_2(9/14) - \\ &\quad (5/14) * \log_2(5/14) \\ &= 0.940 \text{ bits} \end{aligned}$$

- ◆ Considerando el atributo **General**, con sus tres valores ($v=3$):
Para el primer valor, hay 5 objetos que lo tienen, 2 clase **P** y 3 clase **N**, entonces (**Soleado**):

$$p1 = 2, n1 = 3, I(p1,n1) = 0.971$$

- ◆ Análogamente, para el segundo valor posible de A (**Nublado**):

$$p2 = 4, n2 = 0, I(p2,n2) = 0$$

Y para el tercer valor de A (**Lluvioso**):

$$p3 = 3, n3 = 2, I(p3,n3) = 0.971$$

Por lo tanto el requisito de información esperada, después de revisar este atributo es:

$$E(\text{General}) = (5 * I(p1, n1) + 4 * I(p2, n2) + 5 * I(p3, n3)) / 14 = 0.694$$

Y la Ganancia de este atributo es:

$$\text{Ganancia (General)} = 0.940 - E(\text{General}) = 0.246$$

Y el mismo procedimiento aplicado a los otros tres atributos da:

Atributo Temperatura

Caliente

$$p1 = 2, n1 = 2, I(p1, n1) = 1$$

$$I(p, n) = -(2/4) * \log_2(2/4) - (2/4) * \log_2(2/4) = 1$$

Templada

$$p1 = 4 , n1 = 2 , I(p1,n1) = 0.918$$

$$I(p,n) = - (4/6) * \log_2(4/6) - (2/6) * \log_2 (2/) = .918$$

Fría

$$p1 = 3, n1 = 1 , I(p1,n1) = 0.811$$

$$I(p,n) = - (3/4) * \log_2 (3/4) - (1/4) * \log_2(1/4) = .811$$

$$E (Temperatura) = (4 * I(p1,n1) + 6 * I(p2,n2) + 4 * I(p3,n3)) / 14$$

$$E (Temperatura) = (4 * (1) + 6 * (.918) + 4 * (.811)) / 14$$

$$E(\text{Temperatura}) = 0.911$$

$$\text{Ganancia (Temperatura)} = 0.940 - E(\text{Temperatura}) = 0.029$$

$$\text{Ganancia (Temperatura)} = 0.940 - .911 = .029$$

Atributo Humedad

Alta

$$p1 = 3, n1 = 4, I(p1, n1) = .985$$

$$I(p, n) = -(3/7) * \log_2(3/7) - (4/7) * \log_2(4/7) = .985$$

Normal

$$p1 = 6, n1 = 1, I(p1, n1) = 0.591$$

$$I(p, n) = -(6/7) * \log_2(6/7) - (1/7) * \log_2(1/7) = .591$$

$$E(\text{Humedad}) = (7 * I(p1, n1) + 7 * I(p2, n2)) / 14$$

$$E(\text{Humedad}) = (7 * (.985) + 7 * (.591)) / 14$$

$$E(\text{Humedad}) = 0.788$$

$$\text{Ganancia}(\text{Humedad}) = 0.940 - E(\text{Humedad}) = 0.151$$

$$\text{Ganancia}(\text{Humedad}) = .940 - .788 = .151$$

Atributo Viento

Si

$$p1 = 3, n1 = 3, I(p1, n1) = 1$$

$$I(p,n) = \\ -(3/6) * \log_2(3/6) - (3/6) * \log_2(3/6) = \\ 1$$

No

$$p1 = 6 , n1 = 2 , I(p1,n1) = 0.811$$

$$I(p,n) = \\ -(6/8) * \log_2(6/8) - (2/8) * \log_2(2/8) = \\ .811$$

$$E(\text{Viento}) = \\ (6 * I(p1,n1) + 8 * I(p2,n2)) / 14$$

$$E(\text{Viento}) = (6 * (1) + 8 * (.811)) / 14$$

$$E(\text{Viento}) = 0.892$$

$$\text{Ganancia}(\text{Viento}) = \\ 0.940 - E(\text{Viento}) = 0.151$$

$$\text{Ganancia}(\text{Viento}) = .940 - .892 = .048$$

Ganancia (Temperatura) = 0.029

Ganancia (Humedad) = 0.151

Ganancia (Viento) = 0.048

Otro ejemplo

Analizar los factores que tienen mayor impacto en diferentes *fondos de inversión*:

- *Tasas de interés*
- Cantidad de *efectivo* en Japón, Europa Occidental y los Estados Unidos
- El nivel de *tensión* internacional (p. ejem. posibles operaciones militares, incidentes de terrorismo, etc.

Basándose en la lista de atributos, se obtienen los siguientes datos históricos:

<i>Tipo de fondo de inversión</i>	<i>Tasas de interés</i>	<i>Efectivo</i>	<i>Tensión</i>	<i>Valor del fondo de inversión (Clase)</i>
<i>Electrónica</i>	Alta	Alta	Media	Media
<i>Electrónica</i>	Baja	Alta	Media	Alta
<i>Electrónica</i>	Media	Baja	Alta	Baja
<i>Acciones de valores</i>	Alta	Alta	Media	Alta
<i>Acciones de valores</i>	Baja	Alta	Media	Media
<i>Acciones de valores</i>	Media	Baja	Alta	Media
<i>Bienes raíces</i>	Alta	Alta	Media	Baja
<i>Bienes raíces</i>	Baja	Alta	Media	Alta
<i>Bienes raíces</i>	Media	Baja	Alta	Baja

- Note que la última columna representa la conclusión que buscará el algoritmo, donde se identifican tres posibilidades de inversión: *alta*, *media* y *baja*.
- El siguiente paso es desarrollar el árbol de decisión obtenido de dicha tabla (aplicando el cálculo de entropía de cada atributo)
- La fórmula de entropía para cualquier atributo A_k es:

$$H(C|A_k) = \sum_{j=1}^{M_k} p(a_{k,j}) \left[- \sum_{i=1}^N p(c_i | a_{k,j}) \log_2 p(c_i | a_{k,j}) \right]$$

donde:

$H(C A_k)$	Entropía de la propiedad de clasificación del atributo A_k
$p(a_{k,j})$	Probabilidad de que el atributo k esté en el valor j
$p(c_i a_{k,j})$	Probabilidad de la clase c_i cuando la variable k está en el valor j
M_k	Número total de valores para el atributo A_k ; $j=1,2.. M_k$
N	Número total de clases $i=1,2..N$
K	Número total de atributos; $k=1,2...K$

De la tabla se obtiene:

- Cuatro atributos (*Tipo de fondo de inversión*, *Tasas de interés*, *Efectivo*, *Tensión*), esto es $K=4$

- Tres clases (Valor del fondo de inversión: *alta*, *media* o *baja*); esto es $N=3$
- Tres valores para el atributo Tipo de fondo de inversión (Electrónica, Acciones de valores o Bienes raíces); esto es $M_1=3$
- Tres valores para el atributo Tasas de interés (Alta, Media o Baja); esto es $M_2=3$
- Dos valores para el atributo Efectivo (Alta o Baja); esto es $M_3=2$
- Dos valores para el atributo Tensión (Alta o Media); esto es $M_4=2$

El siguiente paso es calcular la entropía para cada atributo, p. ejem. para calcular la entropía del atributo *Efectivo*:

$p(a_{3,1})$ = probabilidad que el *Efectivo* sea Alto = 6/9 (el Efectivo es Alto en 6 de 9 veces)

$p(a_{3,2})$ = probabilidad que el *Efectivo* sea Bajo = 3/9

$p(c_1 | a_{3,1})$ = probabilidad de que un valor de la clase sea Alto cuando el *Efectivo* es Alto = 3/6

$p(c_2 | a_{3,1})$ = probabilidad de que un valor de la clase sea Media cuando el *Efectivo* es Alto = 2/6

$p(c_3 | a_{3,1})$ = probabilidad de que un valor de la clase sea Baja cuando el *Efectivo* es Alto = 1/6

$p(c_1 | a_{3,2})$ = probabilidad de que un valor de la clase sea **Alto** cuando el *Efectivo* es **Baja** = 0/3

$p(c_2 | a_{3,2})$ = probabilidad de que un valor de la clase sea **Media** cuando el *Efectivo* es **Baja** = 1/3

$p(c_3 | a_{3,2})$ = probabilidad de que un valor de la clase sea **Baja** cuando el *Efectivo* es **Baja** = 2/3

Se sustituyen los valores en la fórmula:

$$H(C|A_k) = \sum_{j=1}^{M_k} p(a_{k,j}) \left[- \sum_{i=1}^N p(c_i | a_{k,j}) \log_2 p(c_i | a_{k,j}) \right]$$

y se obtiene:

$$H(C|Efectivo) = \frac{6}{9} \left[-\frac{3}{6} \log_2 \left(\frac{3}{6} \right) - \left(\frac{2}{6} \right) \log_2 \left(\frac{2}{6} \right) - \left(\frac{1}{6} \right) \log_2 \left(\frac{1}{6} \right) \right] + \frac{3}{9} \left[-\frac{0}{3} \log_2 \left(\frac{0}{3} \right) - \left(\frac{1}{3} \right) \log_2 \left(\frac{1}{3} \right) - \left(\frac{2}{3} \right) \log_2 \left(\frac{2}{3} \right) \right] = 1.2787$$

De manera similar se obtiene:

$$H(C|Tasas de interés) = 1.140333$$

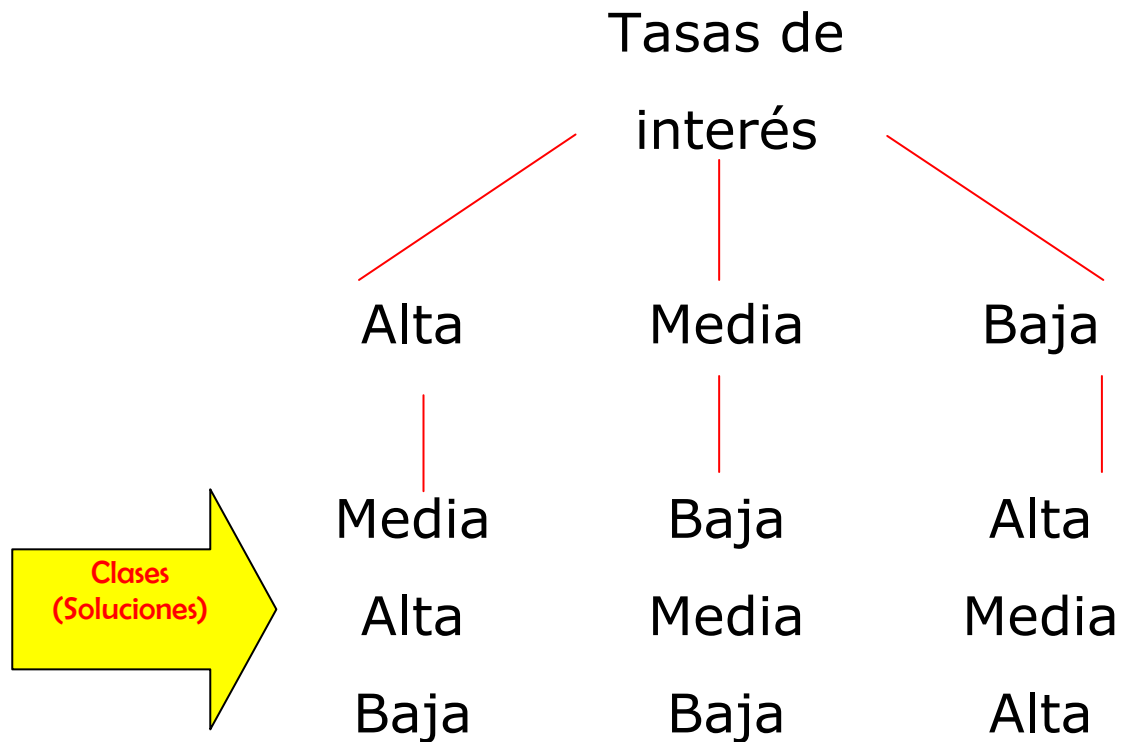
$$H(C|Tensión) = 1.2787$$

$$H(C|Tipo de fondo de inversión) = 1.140333$$

Existe un empate en la entropía más baja entre la *Tasas de interés* y los *Tipos de fondo de inversión*.

- Si se rompe este empate en forma arbitraria y se construye un árbol de decisión teniendo como raíz la *Tasa de interés*, se presenta una clasificación inconclusa, ya que cada opción de dicho

atributo conduce a múltiples soluciones de las clases.



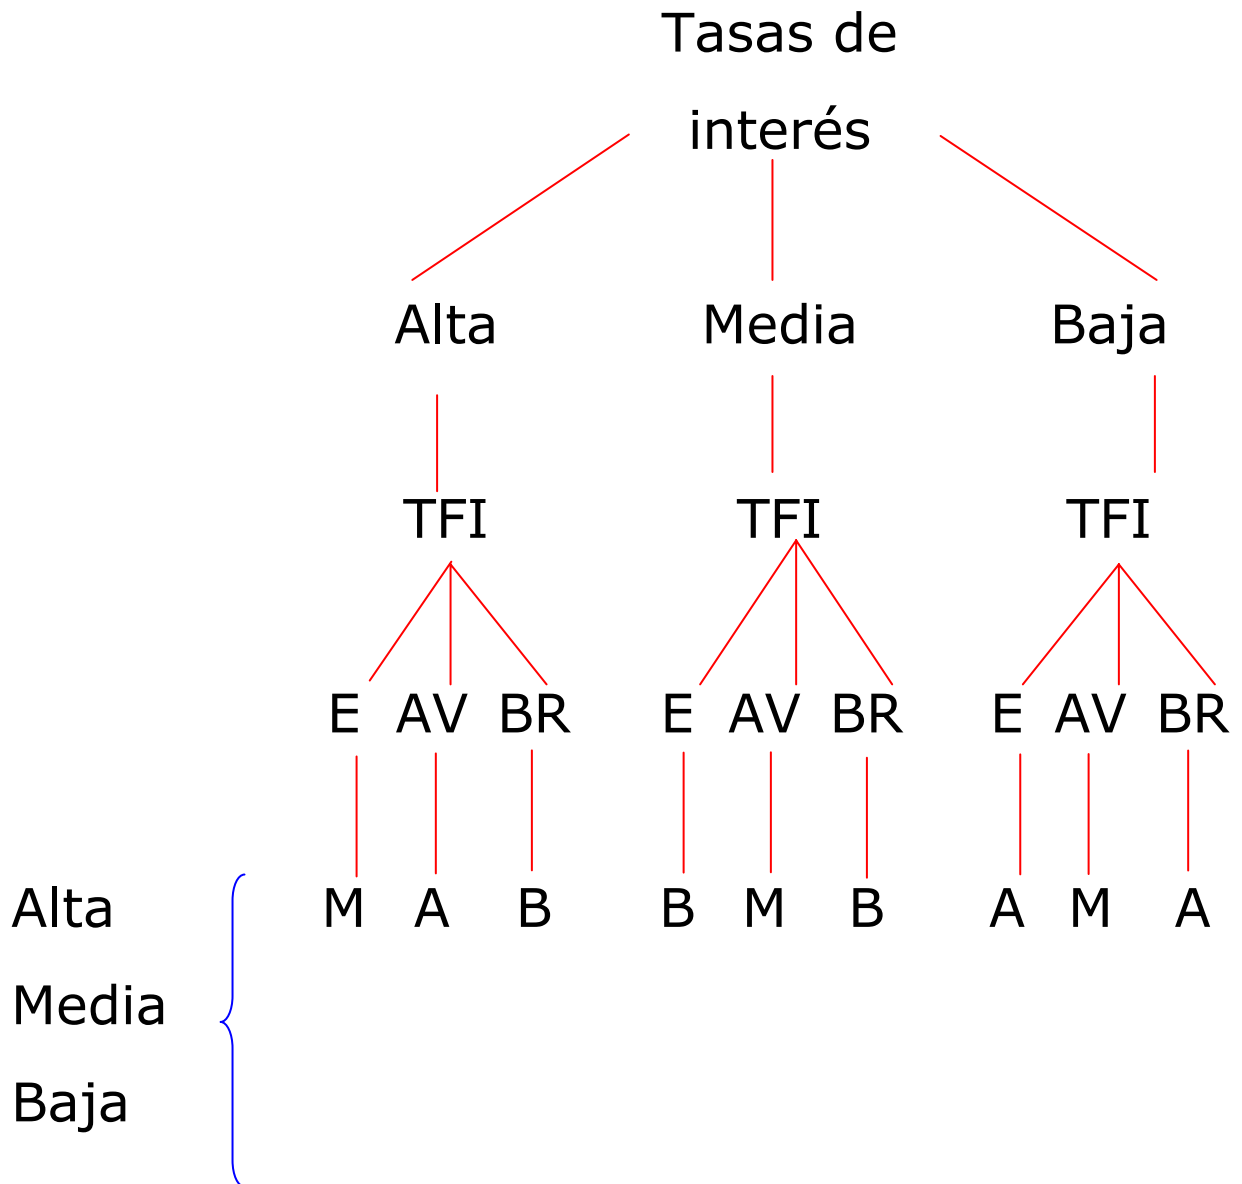
- Una vez ramificado el árbol en el atributo *Tasa de interés*, se elimina dicha columna en la tabla original y se generan 3 sub-tablas (una cuando la *Tasa de interés* es **Alta**, otra cuando es **Media** y otra cuando es **Baja**):

Clasificación cuando la Tasa de Interés es Alta:

<i>Tipo de fondo de inversión</i>	<i>Efectivo</i>	<i>Tensión</i>	<i>Valor del fondo de inversión (Clase)</i>
<i>Electrónica</i>	Alta	Media	Media
<i>Acciones de valores</i>	Alta	Media	Alta
<i>Bienes raíces</i>	Alta	Media	Baja

- Una vez más es necesario calcular la entropía para cada atributo (*Tipo de fondo de inversión*, *Efectivo* y *Tensión*)
- Como resultado se obtiene que el atributo *Tipo de fondo de inversión* tiene la menor entropía (igual a cero).

- Al ramificar el árbol considerando el *Tipo de fondo de inversión*, se obtiene:



De ahí se obtiene que cada rama conduce a una solución única.

Por último, se describen las reglas de producción que forman el Sistema Experto:

Regla 1: IF **tasa_interes** = **alta**
AND **tipo_fondo_inversion** =
electronica
THEN *valor*=**Media**

Regla 2: IF **tasa_interes** = **alta**
AND **tipo_fondo_inversion** =
acciones_valores
THEN *valor*=**Alta**

Regla 3: IF **tasa_interes** = **alta**
AND **tipo_fondo_inversion** =
bienes_raices
THEN *valor*=**Baja**

Regla 4: IF **tasa_interes** = **media**
AND **tipo_fondo_inversion** =
electronica
THEN *valor*=**Baja**

Regla 5: IF **tasa_interes** = **media**
AND **tipo_fondo_inversion** =
acciones_valores
THEN *valor*=**Media**

Regla 6: IF **tasa_interes** = **media**
AND **tipo_fondo_inversion** =
bienes_raices
THEN *valor*=**Baja**

Regla 7: IF **tasa_interes** = **baja**
AND **tipo_fondo_inversion** =
electronica
THEN *valor*=**Alta**

Regla 8: IF **tasa_interes** = **baja**

AND **tipo_fondo_inversion** =
acciones_valores
THEN *valor*=**Media**

Regla 9: IF **tasa_interes** = **baja**
AND **tipo_fondo_inversion** =
bienes_raices
THEN *valor*=**Alta**

También se pueden combinar ciertas reglas:

Regla 5/8: IF **tipo_fondo_inversion** =
acciones_valores
AND **tasa_interes** = **media**
OR **tasa_interes** = **baja**
THEN *valor*=**Media**

Regla 3/6: IF **tipo_fondo_inversion** =
bienes_raices
AND **tasa_interes** = **alta**
OR **tasa_interes** = **media**
THEN *valor*=**Baja**

Sin embargo, algunos paquetes de desarrollo de sistemas expertos no soportan premisas con cláusulas disyuntivas.

Otro ejemplo

<i>Paciente</i>	<i>Presión Arterial</i>	<i>Urea en Sangre</i>	<i>Gota</i>	<i>Hipotiroidismo</i>	<i>Administrar Tratamiento</i>
1	Alta	Alta	Si	No	No
2	Alta	Alta	Si	Si	No
3	Normal	Alta	Si	No	Si
4	Baja	Normal	Si	No	Si
5	Baja	Baja	No	No	Si
6	Baja	Baja	No	Si	No
7	Normal	Baja	No	Si	Si
8	Alta	Normal	Si	No	No
9	Alta	Baja	No	No	Si
10	Baja	Normal	No	No	Si
11	Alta	Normal	No	Si	Si
12	Normal	Normal	Si	Si	Si
13	Normal	Alta	No	No	Si
14	Baja	Normal	Si	Si	No

$$I(p,n) = - (9/14)*\log_2(9/14) - (5/14)*\log_2(5/14) = 0.940 \text{ bits}$$

- ◆ Considerando el atributo **Presión Arterial**, con sus tres valores ($v=3$): Para el primer valor, hay 5 objetos que lo tienen, 2 clase **Si** y 3 clase **No**, entonces (**Alta**):

$$p1 = 2 , n1 = 3 , I(p1,n1) = 0.971$$

- ◆ Análogamente, para el segundo valor posible de A (**Normal**):

$$p2 = 4 , n2 = 0 , I(p2,n2) = 0$$

Y para el tercer valor de A (**Baja**):

$$p3 = 3 , n3 = 2 , I(p3,n3) = 0.971$$

Por lo tanto el requisito de información esperada, después de revisar este atributo es:

$$E (\text{Presion Arterial}) =$$

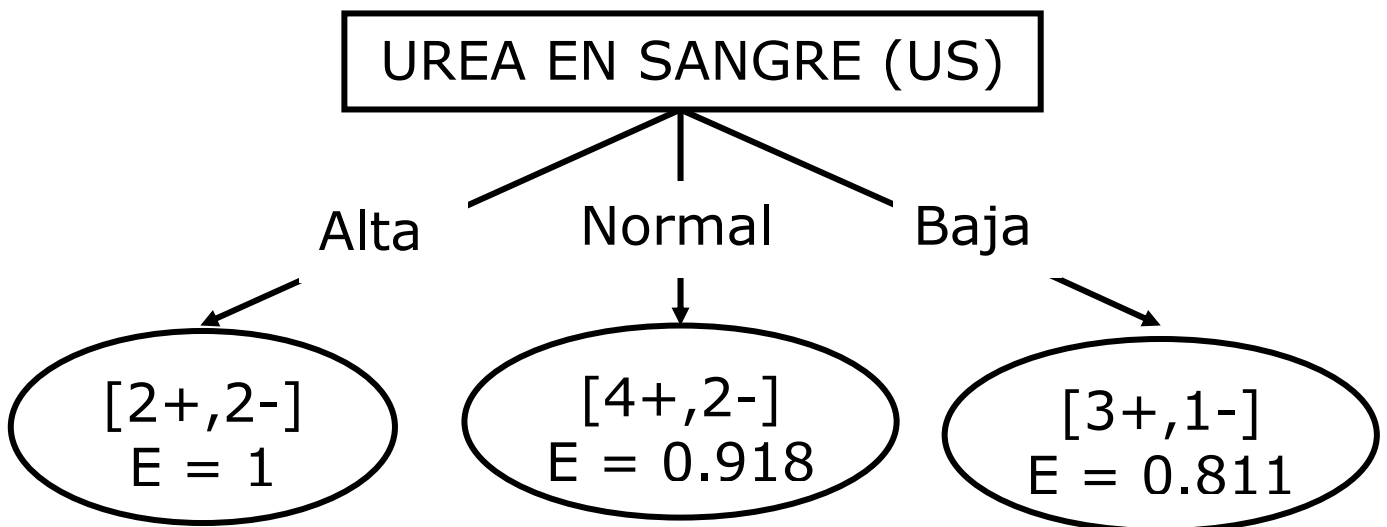
$$(5 * I(p1, n1) + 4 * I(p2, n2) + 5 * I(p3, n3)) / 14 = 0.694$$

Y la Ganancia de este atributo es:

$$\text{Ganancia (Presion Arterial)} = 0.940 - E(\text{Presion Arterial}) = 0.246$$

Y el mismo procedimiento aplicado a los otros tres atributos da:

Atributo Urea en Sangre



Alta

$$p1 = 2, n1 = 2, I(p1, n1) = 1$$

$$I(p, n) =$$

$$-(2/4) * \log_2(2/4) - (2/4) * \log_2(2/4) = 1$$

Normal

$$p1 = 4, n1 = 2, I(p1, n1) = 0.918$$

$$I(p, n) = -(4/6) * \log_2(4/6) - (2/6) * \log_2(2/6) = 0.918$$

Baja

$$p1 = 3, n1 = 1, I(p1, n1) = 0.811$$

$$I(p, n) = -(3/4) * \log_2(3/4) - (1/4) * \log_2(1/4) = 0.811$$

$$E(\text{Urea en Sangre}) = (4 * I(p1, n1) + 6 * I(p2, n2) + 4 * I(p3, n3)) / 14$$

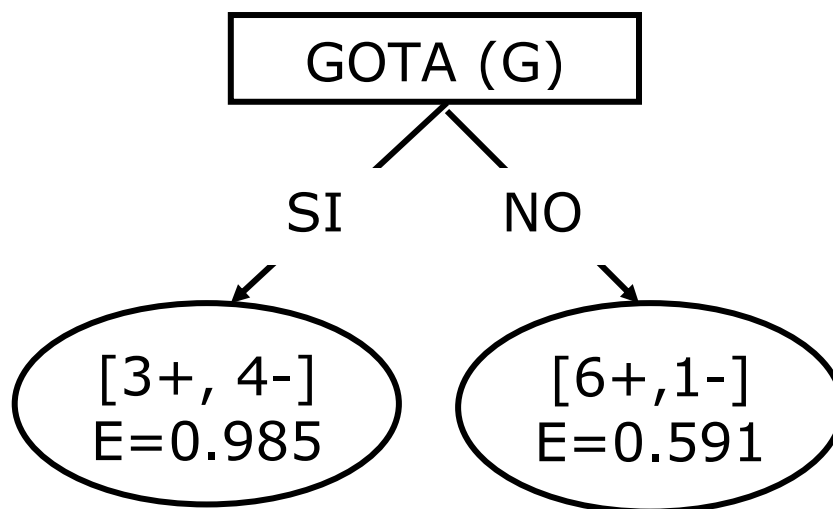
$$E(\text{Urea en Sangre}) = (4 * (1) + 6 * (0.918) + 4 * (0.811)) / 14$$

$$E(\text{Urea en Sangre}) = 0.911$$

$$\text{Ganancia (Urea en Sangre)} = 0.940 - E(\text{Urea en Sangre}) = 0.571$$

$$\text{Ganancia (Urea en Sangre)} = 0.940 - 0.911 = 0.029$$

Atributo Gota



Si

$$p1 = 3, n1 = 4, I(p1, n1) = 0.985$$

$$I(p, n) = -(3/7) * \log_2(3/7) - (4/7) * \log_2(4/7) = 0.985$$

No

$$p1 = 6, n1 = 1, I(p1, n1) = 0.591$$

$$I(p,n) = -(6/7) * \log_2(6/7) - (1/7) * \log_2(1/7) = 0.591$$

$$E(\text{Gota}) = (7 * I(p_1, n_1) + 7 * I(p_2, n_2)) / 14$$


$$E(\text{Gota}) = (7 * (0.985) + 7 * (0.591)) / 14$$

$$E(\text{Gota}) = 0.788$$

$$\text{Ganancia}(\text{Gota}) = 0.940 - E(\text{Gota}) = 0.152$$

$$\text{Ganancia}(\text{Gota}) = 0.940 - 0.788 = 0.152$$

Atributo Hipotiroidismo



Si

$$p1 = 3 , n1 = 3 , I(p1,n1) = 1$$

$$\begin{aligned}
 I(p,n) &= \\
 &= -(3/6) * \log_2(3/6) - (3/6) * \log_2 \\
 &= (3/6) = 1
 \end{aligned}$$

No

$$p1 = 6 , n1 = 2 , I(p1,n1) = 0.811$$

$$\begin{aligned}
 I(p,n) &= \\
 &= -(6/8) * \log_2(6/8) - (2/8) * \log_2 \\
 &= (2/8) = 0.811
 \end{aligned}$$

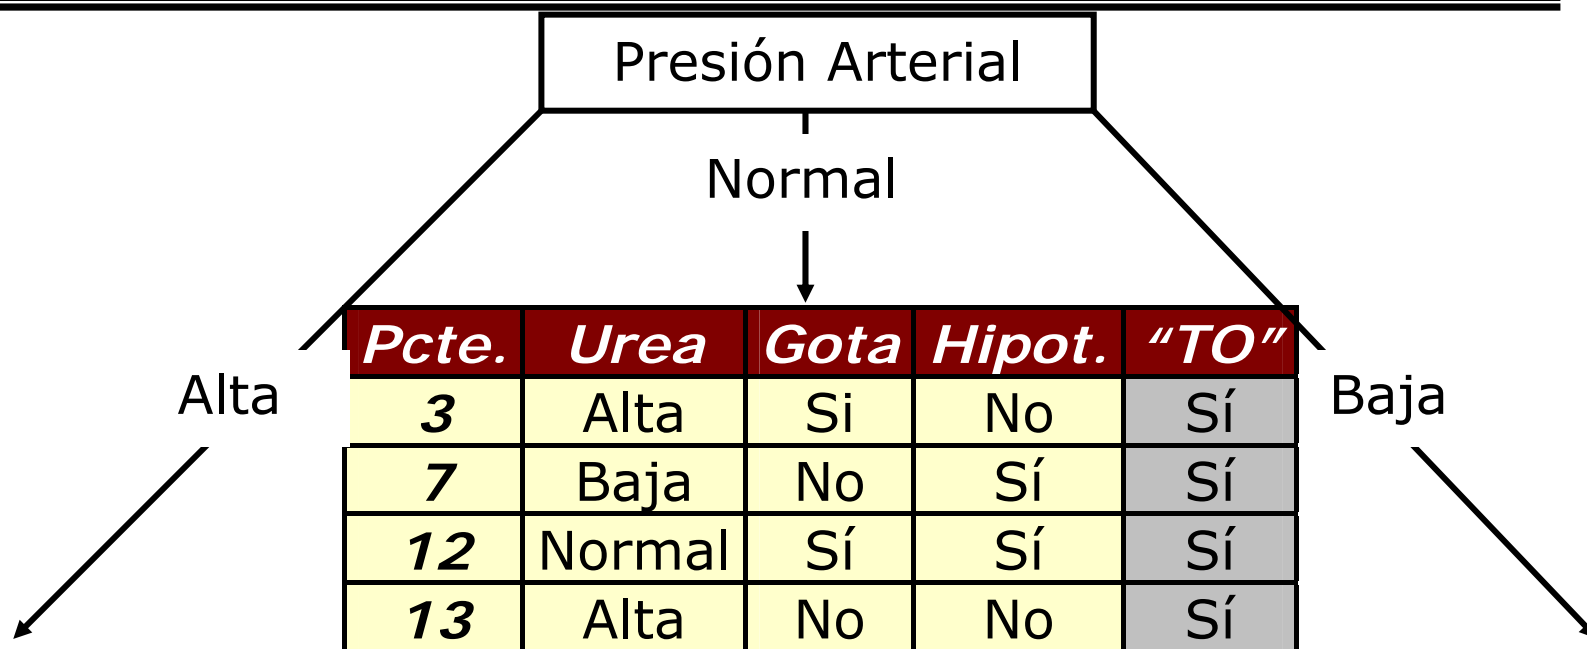
$$E(\text{Hipotiroidismo}) = (6 * I(p1, n1) + 8 * I(p2, n2)) / 14$$

$$E(\text{Hipotiroidismo}) = (3 * (1) + 2 * (0.811)) / 14$$

$$E(H) = 0.892$$

$$\text{Ganancia (Hipotiroidismo)} = 0.940 - E(\text{Hipotiroidismo}) = 0.048$$

$$\text{Ganancia (Hipotiroidismo)} = 0.940 - 0.892 = 0.048$$



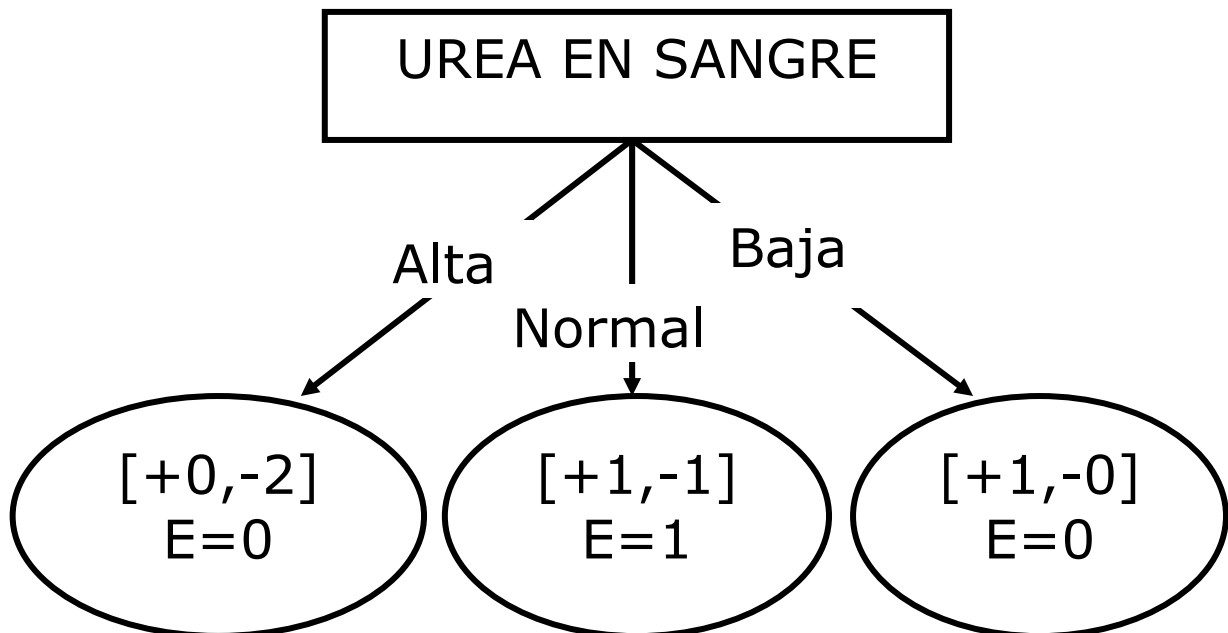
<i>Pcte.</i>	<i>Urea</i>	<i>Gota</i>	<i>Hipot.</i>	<i>"TO"</i>
1	Alta	Si	No	No
2	Alta	Sí	Sí	No
8	Normal	Sí	No	No
9	Baja	No	No	Sí
11	Normal	No	Sí	Sí

<i>Pcte.</i>	<i>Urea</i>	<i>Gota</i>	<i>Hipot.</i>	<i>"TO"</i>
4	Normal	Si	No	Sí
5	Baja	No	No	Sí
6	Baja	No	Sí	No
10	Normal	No	No	Sí
14	Normal	Sí	Sí	No

Presión Arterial Alta

$$I(p,n) = - (2/5) * \log_2(2/5) - (3/5) * \log_2(3/5) = 0.971 \text{ bits}$$

Atributo Urea en Sangre



Alta

$$p1 = 0, n1 = 2, I(p1, n1) = 0$$

$$I(p,n) = -(0/2) * \log_2(0/2) - (2/2) * \log_2(2/2) = 0$$

Normal

$$p1 = 1, n1 = 1, I(p1, n1) = 1$$

$$I(p, n) = - (1/2) * \log_2(1/2) - (1/2) * \log_2(1/2) = 1$$

Baja

$$p1 = 1, n1 = 0, I(p1, n1) = 0$$

$$I(p, n) = - (1/1) * \log_2(1/1) - (0/1) * \log_2(0/1) = 0$$

$$E(\text{Urea en sangre}) = (4 * I(p1, n1) + 6 * I(p2, n2) + 4 * I(p3, n3)) / 5$$

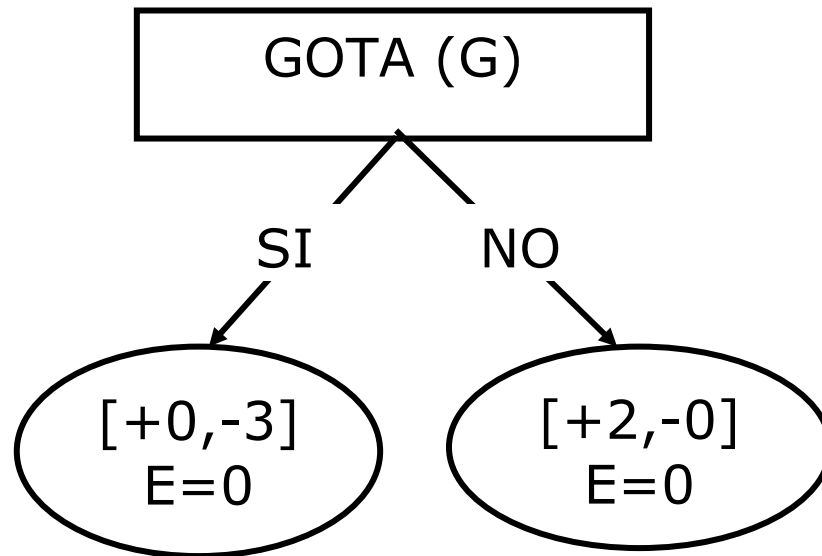
$$E(\text{Urea en sangre}) = (2 * (0) + 2 * (1) + 1 * (0)) / 5$$

$$E(\text{Urea en sangre}) = 0.4$$

$$\text{Ganancia (Urea en sangre)} = 0.971 - E(\text{Urea en sangre}) = 0.571$$

$$\text{Ganancia (Urea en Sangre)} = 0.971 - 0.4 = 0.571$$

Atributo Gota



Si

$$p1 = 0, n1 = 3, I(p1, n1) = 0$$

$$I(p, n) = -(0/3) * \log_2(0/3) - (3/3) * \log_2(3/3) = 0$$

No

$$p1 = 2, n1 = 0, I(p1, n1) = 0$$

$$I(p, n) =$$

$$- (2/2) * \log_2(2/2) - (0/2) * \log_2(0/2) = 0$$

$$E(\text{Gota}) =$$

$$(3 * I(p1, n1) + 2 * I(p2, n2)) / 5$$

$$E(\text{Gota}) =$$

$$(3 * (0) + 2 * (0)) / 5$$

$$E(\text{Gota}) = 0$$


$$\text{Ganancia}(\text{Gota}) =$$

$$0.971 - E(\text{Gota}) = 0.971$$

$$\text{Ganancia}(\text{Gota}) =$$

$$0.971 - 0 = 0.971$$

Atributo Hipotiroidismo



Si

$$p1 = 1, n1 = 1, I(p1, n1) = 1$$

$$I(p, n) = -\left(\frac{1}{2}\right) * \log_2\left(\frac{1}{2}\right) - \left(\frac{1}{2}\right) * \log_2\left(\frac{1}{2}\right) = 1$$

No

$$p1 = 1, n1 = 2, I(p1, n1) = 0.919$$

$$I(p,n) = - (1/3) * \log_2(1/3) - (2/3) * \log_2(2/3) = 0.919$$

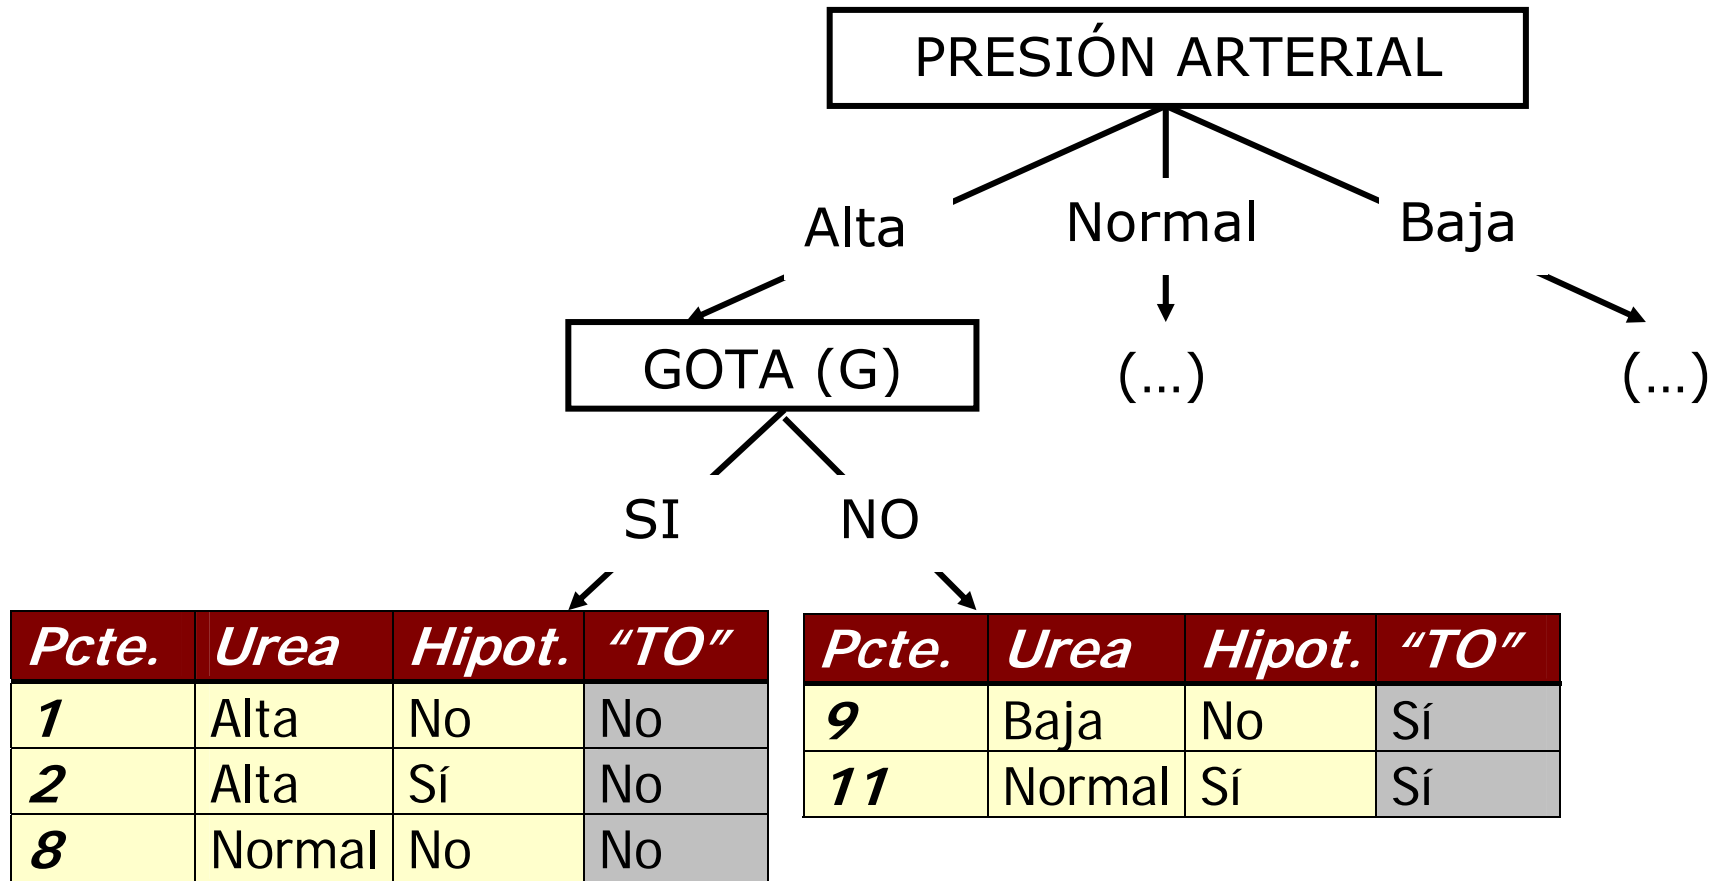
$$E(\text{Hipotiroidismo}) = (2 * I(p1,n1) + 3 * I(p2,n2)) / 5$$

$$E(\text{Hipotiroidismo}) = (2 * (1) + 3 * (0.919)) / 5$$

$$E(\text{Hipotiroidismo}) = 0.9514$$

$$\text{Ganancia}(\text{Hipotiroidismo}) = 0.971 - E(\text{Hipotiroidismo}) = 0.020$$

$$\text{Ganancia}(\text{Hipotiroidismo}) = 0.971 - 0.951 = 0.020$$

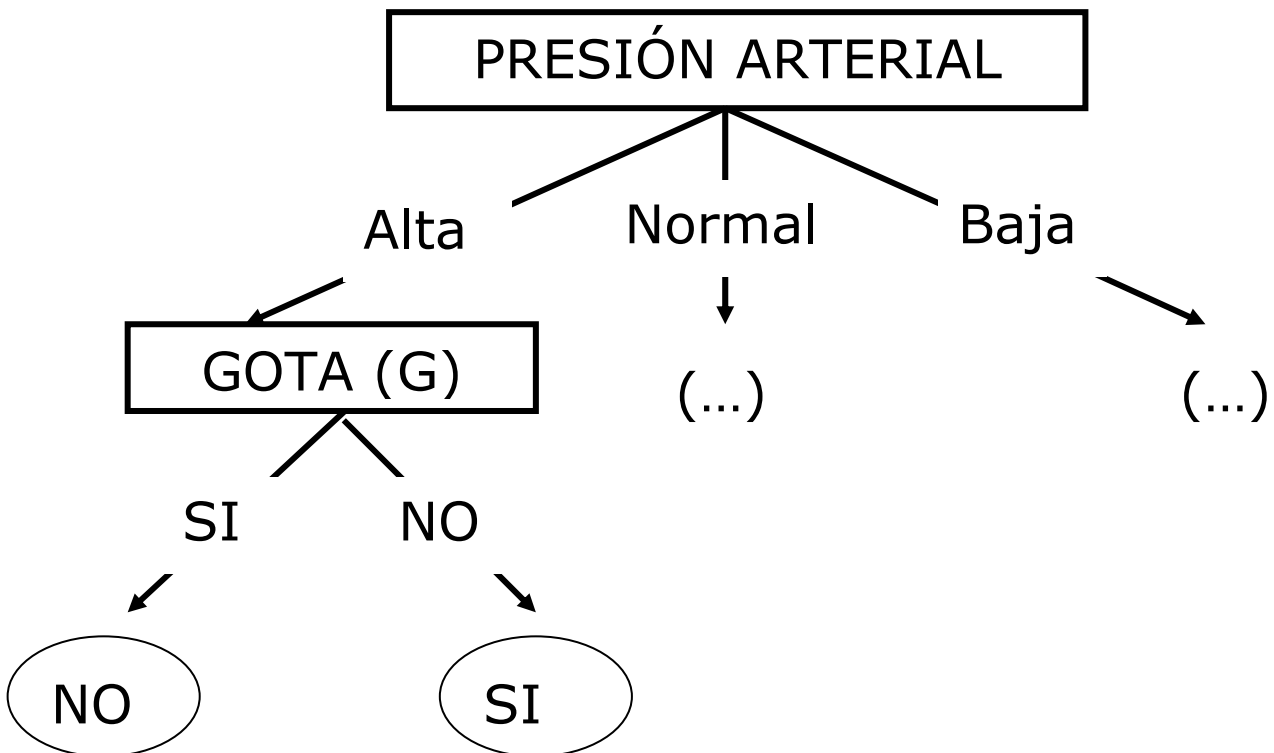


Gota - Si

$$I(p,n) = - (0/3) \cdot \log_2(0/3) - (3/3) \cdot \log_2(3/3) = 0 \text{ bits}$$

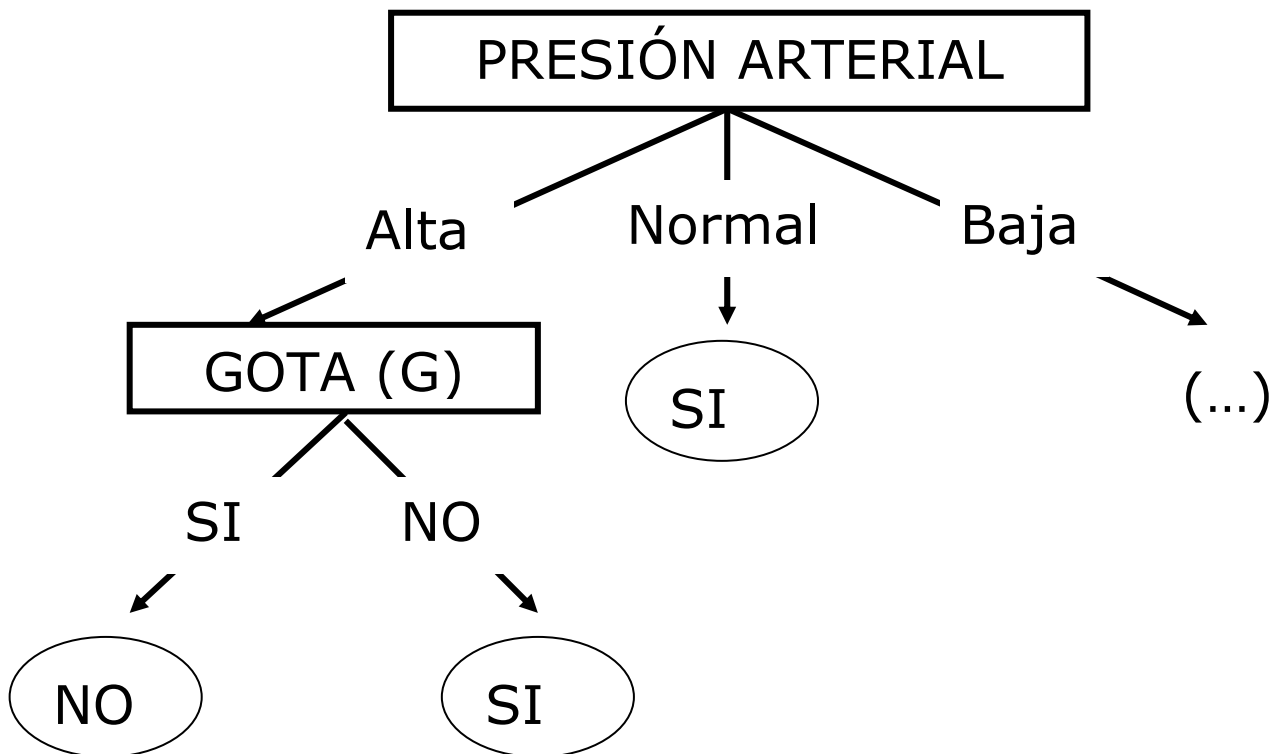
Gota - No

$$I(p,n) = - (2/2) \cdot \log_2(2/2) - (0/2) \cdot \log_2(0/2) = 0 \text{ bits}$$



Presión Arterial Normal

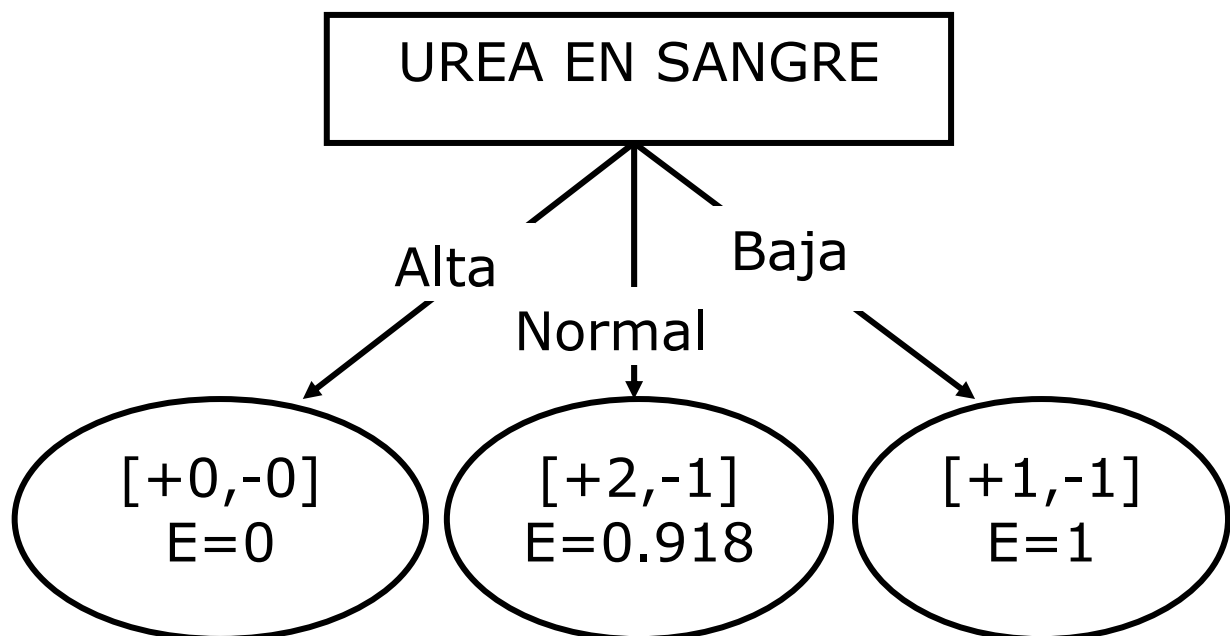
$$I(p,n) = - (4/4) * \log_2(4/4) - (0/4) * \log_2(0/4) = 0 \text{ bits}$$



Presión Arterial Baja

$$\begin{aligned}
 I(p,n) &= - (3/5) * \log_2(3/5) - \\
 &\quad (2/5) * \log_2(2/5) \\
 &= 0.971 \text{ bits}
 \end{aligned}$$

Atributo Urea en Sangre



Alta

$$p1 = 0 , n1 = 0 , I(p1,n1) = 0$$

$$\begin{aligned}
 I(p,n) &= \\
 &= -(0/0) * \log_2(0/0) - (0/0) * \log_2 \\
 &\quad (0/0) = 0
 \end{aligned}$$

Normal

$$p1 = 2, n1 = 1, I(p1, n1) = 0.918$$

$$I(p, n) = - (2/3) * \log_2(2/3) - (1/3) * \log_2(1/3) = 0.918$$

Baja

$$p1 = 1, n1 = 1, I(p1, n1) = 1$$

$$I(p, n) = - (1/2) * \log_2(1/2) - (1/2) * \log_2(1/2) = 1$$

$$E(\text{Urea en sangre}) = (0 * I(p1, n1) + 3 * I(p2, n2) + 2 * I(p3, n3)) / 5$$

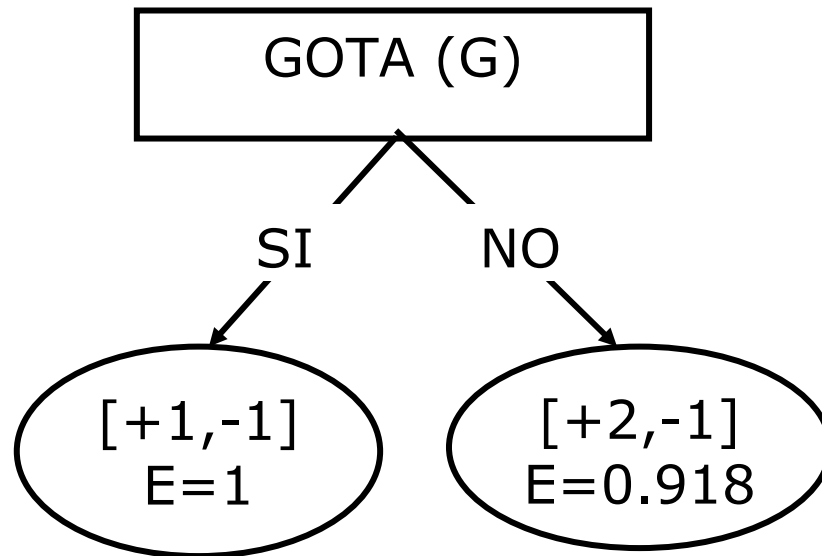
$$E(\text{Urea en sangre}) = (0 * (0) + 3 * (0.918) + 2 * (1)) / 5$$

$$E(\text{Urea en sangre}) = 0.951$$

$$\text{Ganancia (Urea en sangre)} = 0.971 - E(\text{Urea en sangre}) = 0.020$$

$$\text{Ganancia (Urea en Sangre)} = 0.971 - 0.951 = 0.020$$

Atributo Gota



Si

$$p1 = 1, n1 = 1, I(p1, n1) = 0$$

$$I(p, n) = -(1/2) * \log_2(1/2) - (1/2) * \log_2(1/2) = 1$$

No

$$p1 = 2, n1 = 1, I(p1, n1) = 0.918$$

$$I(p, n) = -(2/3) * \log_2(2/3) - (1/3) * \log_2(1/3) = 0.918$$

$$E(\text{Gota}) = (2 * I(p1, n1) + 3 * I(p2, n2)) / 5$$


$$E(\text{Gota}) = (2 * (1) + 3 * (0.918)) / 5$$

$$E(\text{Gota}) = 0.020$$

$$\text{Ganancia}(\text{Gota}) = 0.971 - E(\text{Gota}) = 0.020$$

$$\text{Ganancia}(\text{Gota}) = 0.971 - 0.951 = 0.020$$

Atributo Hipotiroidismo



Si

$$p1 = 0, n1 = 2, I(p1, n1) = 0$$

$$\begin{aligned}
 I(p, n) &= \\
 &= -(0/2) * \log_2(0/2) - (2/2) * \log_2 \\
 &= (2/2) = 0
 \end{aligned}$$

No

$$p1 = 3, n1 = 0, I(p1, n1) = 0$$

$$\begin{aligned}
 I(p, n) &= \\
 &= -(3/3) * \log_2(3/3) - (0/3) * \log_2 \\
 &= (0/3) = 0
 \end{aligned}$$

$$E(\text{Hipotiroidismo}) =$$

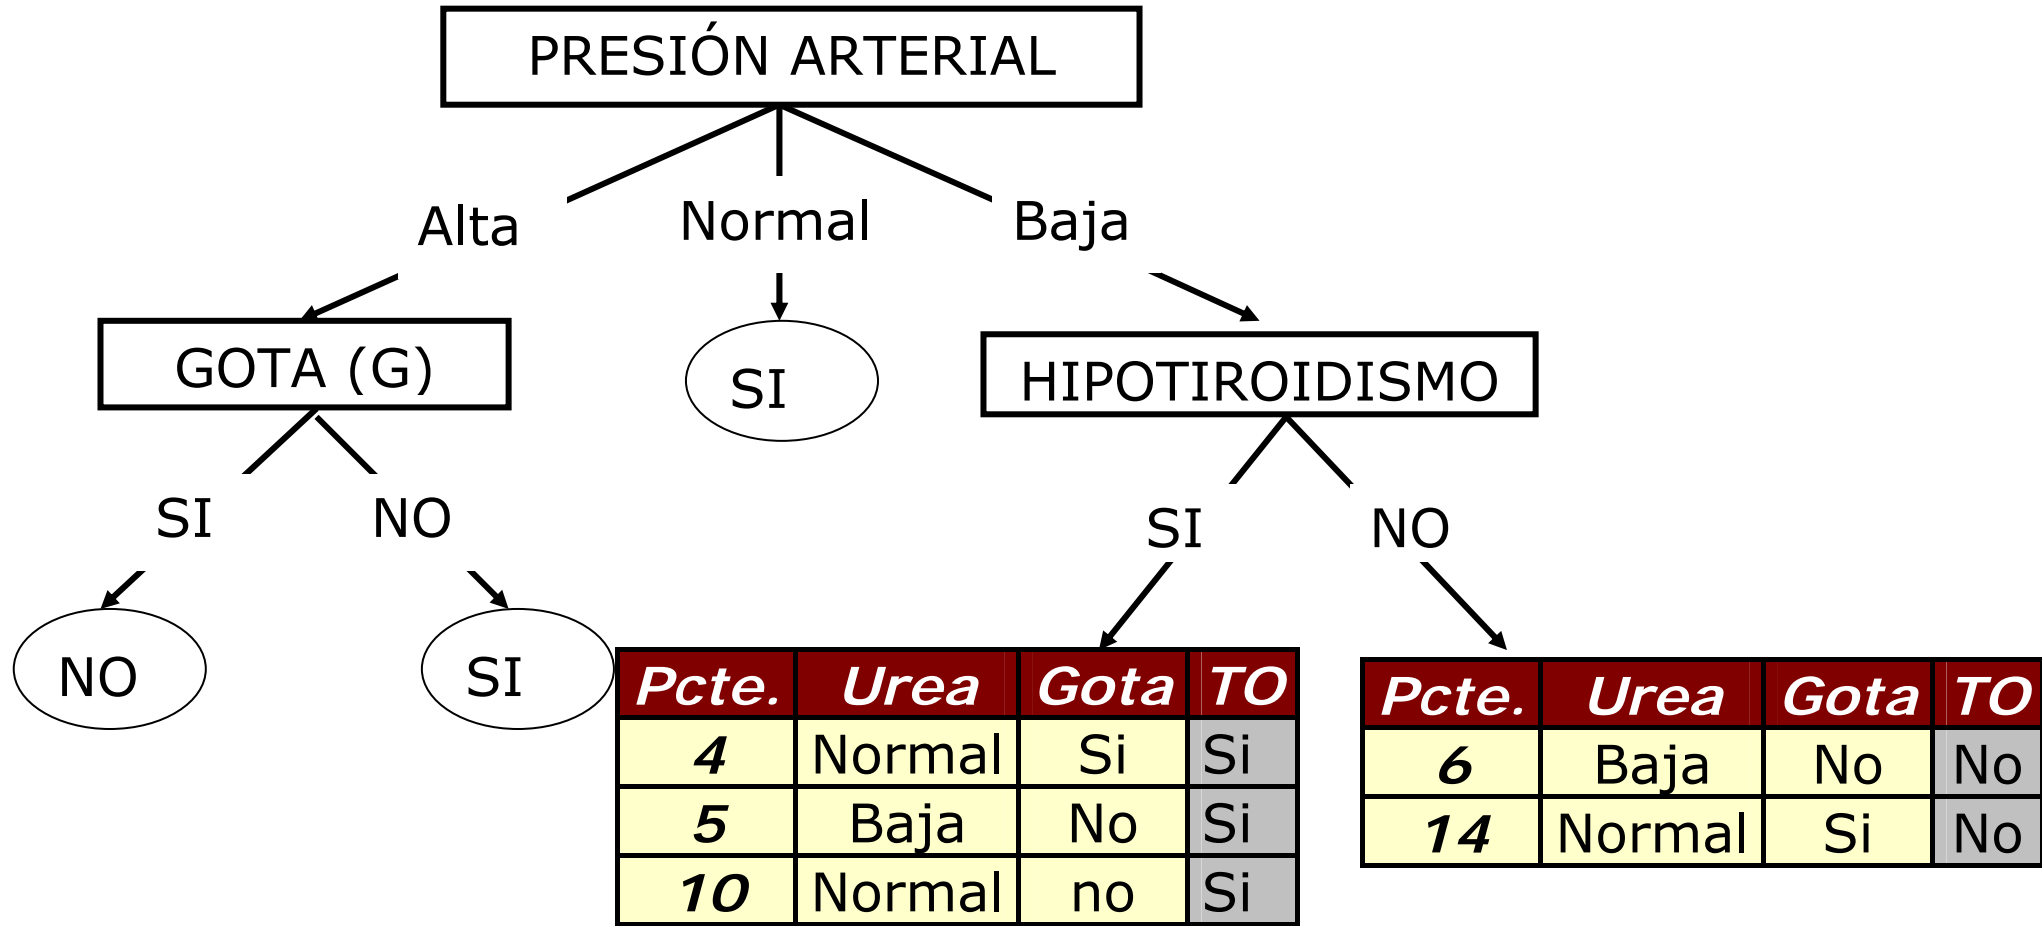
$$(3 * I(p1, n1) + 2 * I(p2, n2)) / 5$$

$$E(\text{Hipotiroidismo}) = \\ (3 * (0) + 2 * (0)) / 5$$

$$E(\text{Hipotiroidismo}) = 0$$

$$\text{Ganancia}(\text{Hipotiroidismo}) = \\ 0.971 - E(\text{Hipotiroidismo}) = 0.971$$

$$\text{Ganancia}(\text{Hipotiroidismo}) = \\ 0.971 - 0 = 0.971$$



Hipotiroidismo - SI

$$I(p,n) = - (3/3) \cdot \log_2(3/3) - (0/3) \cdot \log_2(0/3) = 0 \text{ bits}$$

Hipotiroidismo - NO

$$I(p,n) = - (0/2) \cdot \log_2(0/2) - (2/2) \cdot \log_2(2/2) = 0 \text{ bits}$$

