

Tema 8: Árboles de Clasificación

Abdelmalik Moujahid, Iñaki Inza, Pedro Larrañaga

Departamento de Ciencias de la Computación e Inteligencia Artificial

Universidad del País Vasco

<http://www.sc.ehu.es/isg/>


Contenido

- Introducción
- El algoritmo básico TDIDT (Top Down Induction of Decision Trees)
- El algoritmo ID3 (Quinlan 1986)
- El algoritmo C4.5 (Quinlan 1993)

Introducción


- Un árbol de clasificación es un conjunto de condiciones organizadas en una estructura jerárquica, de tal manera que la decisión final a tomar se puede determinar siguiendo las condiciones que se cumplen desde el nodo raíz hasta alguna de sus hojas.
- Particionamiento recursivo del dominio de definición de las variables predictoras en particiones disjuntas.
- Una partición es un conjunto de reglas excluyentes y exhaustivas.

El algoritmo básico



Representación en el plano de distintos patrones caracterizados por 2 variables predictoras X_1 y X_2 y una variable clase C con dos posibles valores

El algoritmo básico



Árbol de clasificación correspondiente al ejemplo representado anterior

Conjunto de reglas equivalentes al árbol de clasificación:

R_1 : If $X_1 > 1,5$ then $C = 2$

R_2 : If $1 < X_1 < 1,5$ then $C = 1$

R_3 : If $X_1 < 1$ and $X_2 < 1$ then $C = 1$

R_4 : If $X_1 < 1$ and $X_2 > 1$ then $C = 2$

El algoritmo básico

Input: D conjunto de N patrones etiquetados, cada uno de los cuales está caracterizado por n variables predictoras $X_1, \dots, X_n$ y la variable clase C

Output: Árbol de clasificación

Begin TDIDT (Top Down Induction of Decision Trees)

if todos los patrones de D pertenecen a la misma clase c

then

 resultado de la inducción es un nodo simple (nodo hoja) etiquetado como c

else

begin

 1. Seleccionar la variable más informativa X_r con valores $x_r^1, \dots, x_r^{n_r}$

 2. Particionar D de acorde con los n_r valores de X_r en $D_1, \dots, D_{n_r}$

 3. Construir n_r subárboles $T_1, \dots, T_{n_r}$ para $D_1, \dots, D_{n_r}$

 4. Unir X_r y los n_r subárboles $T_1, \dots, T_{n_r}$ con los valores $x_r^1, \dots, x_r^{n_r}$

end

endif

End TDIDT

El algoritmo básico

El buen funcionamiento de un algoritmo de aprendizaje de árboles de clasificación depende de dos puntos importantes:

- Las particiones a considerar
- El criterio de selección de las particiones


El algoritmo ID3

- ID3 (Quinlan, 1986) selecciona la variable más informativa en base a la cantidad de información mutua: $I(X_i, C) = H(C) - H(C|X_i)$ (*ganancia en información*)
- Matemáticamente se demuestra que este criterio favorece la elección de variables con mayor número de valores
- Selección de variables previa (*prepruning*) basada en un test de independencia entre cada variable predictora X_i y la variable clase C

El algoritmo C4.5

- C4.5 (Quinlan, 1993) selecciona la variable más informativa en base al *ratio de ganancia*:
 $I(X_i, C)/H(X_i)$
- Matemáticamente se demuestra que este criterio evita que se favorezca la elección de variables con mayor número de valores
- Incorporación de una poda del árbol inducido (*postpruning*), basada en un test de hipótesis que trata de responder a la pregunta de si merece la pena expandir o no una determinada rama

El algoritmo C4.5



Ejemplo para el proceso de pos-poda del algoritmo C4.5

El algoritmo C4.5

Proceso de poda del árbol

- $N(t) = 35$, ejemplos en el nodo $t = 26$
- $e(t) = 10 + 5 = 15$, ejemplos mal clasificados en el nodo t
- $n'(t) = e(t) + \frac{1}{2} = 15,5$, corrección por continuidad de $e(t)$
- T_t , subárbol a expandir a partir del nodo t
- $h(T_t) = 4$, número de hojas del subárbol T_t
- $n'(T_t) = \sum_{i=1}^{h(T_t)} e(i) + \frac{h(T_t)}{2} = 2 + 0 + 6 + 2 + \frac{4}{2} = 12$, número de errores existentes en las hojas terminales del subárbol T_t
- $S(n'(T_t)) = \sqrt{\frac{n'(T_t)[N(t)-n'(T_t)]}{N(t)}} = \sqrt{\frac{12(35-12)}{35}} \simeq 2,8$, desviación de $n'(T_t)$

El nodo t se expande $\Leftrightarrow n'(T_t) + S(n'(T_t)) < n'(t) \Leftrightarrow 12 + 2,8 < 15,5$

El nodo 26 se expande considerándose los nodos 28, 29, 30 y 31