

APPRENTISSAGE ARTIFICIEL: ARBRE DE DÉCISIONS

M. Serrurier
IRIT, Toulouse, France


December 8, 2015

ARBRES DE DÉCISION

// EXEMPLES

- ▶ Les arbres de décision sont des classifieurs pour des instances représentées dans un formalisme attribut/valeur
 - ▶ les noeuds de l'arbre testent les attributs
 - ▶ Il y a une branche pour chaque valeur de l'attribut testé
 - ▶ Les feuilles spécifient les classes (deux ou plus)

exemple




ARBRES DE DÉCISION

// EXEMPLE

Cas	Prévisions	Température	Humidité	Vent	Sport
E1	Soleil	Chaude	Elevée	Faible	-
E2	Soleil	Chaude	Elevée	Fort	-
E3	Couvert	Chaude	Elevée	Faible	+
E4	Pluie	Douce	Elevée	Faible	+
E5	Pluie	Froide	Normale	Faible	+
E6	Pluie	Froide	Normale	Fort	-
E7	Couvert	Froide	Normale	Fort	+
E8	Soleil	Douce	Elevée	Faible	-
E9	Soleil	Froide	Normale	Faible	+
E10	Pluie	Douce	Normale	Faible	+
E11	Soleil	Douce	Normale	Fort	+
E12	Couvert	Douce	Elevée	Fort	+
E13	Couvert	Chaude	Normale	Faible	+

ARBRES DE DÉCISION


// EXEMPLES



- ▶ SI Prévisions= Soleil et Humidité = Forte ALORS Sport=
- ▶ SI Prévisions= Couvert ALORS Sport=
- ▶

ARBRES DE DÉCISION

// EXERCICE





- ▶ Transformer cet arbre en un ensemble de règles
- ▶ Simplifier l'ensemble de règles
- ▶ Peut-on retransformer cet ensemble de règles en un arbre ?

ARBRE DE DÉCISION

- ▶ Méthode de classification et de prédiction
- ▶ Les attributs apparaissant dans l'arbre sont les attributs pertinents pour le problème considéré
- ▶ Un arbre est équivalent à un ensemble de règles de décision

- ▶ construireNoeud(E)
 - ▶ Si tous les exemples de E sont dans la même classe C_i
 - ▶ affecter l'étiquette C_i au noeud courant
 - ▶ Sinon sélectionner un attribut A avec les valeurs $v_1 \dots v_n$
Partitionner E selon $v_1 \dots v_n$ en E_1, \dots, E_n
 - ▶ Pour chacune des branches n construireNoeud(E_j).

CHOIX DU MEILLEUR ATTRIBUT ?



- ▶ S est un ensemble d'exemples
- ▶ p^+ proportion d'ex. positifs dans S
- ▶ p^- proportion d'ex. négatifs dans S
- ▶ L'entropie mesure l'impureté de S
- ▶ $\text{Ent}(S) = -p^+ \log_2 p^+ - p^- \log_2 p^-$
- ▶ $\text{Ent}(S)$ = Nombre de bits nécessaire pour coder la classe(+ ou -) d'un élément tiré au hasard

- ▶ $\text{Gain}(S, A) = \text{réduction d'entropie due au test de l'attribut } A$

$$\text{Gain}(S, A) = \text{Ent}(s) - \sum_{v \in \text{Valeurs}(A)} \frac{|S_v|}{|S|} \text{Ent}(S_v)$$


- ▶ Si on travaille avec plus de 2 classes, la formule d'entropie peut être généralisée

$$\text{Ent}(s) = - \sum_s f_s \log_{|s|} f_s$$

- ▶ où f_s est la proportion de la classe s

Implémentations

- ▶ C4.5, ID3 (basé sur l'entropie)
- ▶ CART (basé sur le Gini index)



- ▶ $\text{Gain}(S, \text{Hum.}) = 0.940 - 7/14 * 0.985 - 7/14 * 0.592 = 0.151$
- ▶ $\text{Gain}(S, \text{Vent}) = 0.940 - 8/14 * 0.811 - 6/14 * 1. = 0.048$

Soit $S = \{8^+; 8^-\}$ un ensemble d'exemples Calculer :

- ▶ L'entropie de S
- ▶ Soit A l'attribut binaire qui sépare les en $A_1\{8^+, 0^-\}$ et $A_2\{0^+, 8^-\}$. Calculer l'entropie de A_1 et de A_2 . Calculer le gain.
- ▶ Soit B l'attribut binaire qui sépare les en $B_1\{3^+, 3^-\}$ et $B_2\{5^+, 5^-\}$. Calculer l'entropie de B_1 et de B_2 Calculer le gain.

ARBRE DE DÉCISION

// SPAM

blacklist	connu	type	fautes	spam
F	T	texte	F	-
T	F	image	F	+
T	T	texte	F	+
F	T	imetttexte	T	-
T	T	imetttexte	T	+
F	F	texte	T	+
F	F	texte	F	-

Exercice

Sachant que le premier attribut sélectionné est type, continuer la construction de l'arbre de décision correspondant à cette base en utilisant l'algorithme vu en cours et le critère d'entropie.

ARBRE DE DÉCISION

// COUPS DE SOLEIL

cheveux	taille	poids	crème solaire	coup de soleil
blond	moyenne	léger	non	+
blond	grande	moyen	oui	-
brun	petite	moyen	oui	-
blond	petite	moyen	non	+
roux	moyenne	lourd	non	+
brun	grande	lourd	non	-
brun	moyenne	lourd	non	-
blond	petite	léger	oui	-

Exercice

Construire l'arbre de décision correspondant à cette base


- ▶ Attributs à valeur continue
- ▶ Attributs à facteurs de branchement différents
- ▶ Valeurs manquantes
- ▶ Sur-apprentissage
- ▶ Recherche gloutonne
- ▶ Variance des résultats :
 - ▶ arbres différents à partir de données peu différentes

ATTRIBUTS À VALEURS CONTINUES

- ▶ Créer dynamiquement un attribut binaire à partir des valeurs observées, dans le nœud considéré, pour un attribut A continu
- ▶ On trie les valeurs observées pour A
- ▶ On cherche une seuil
 - ▶ $s(A < s \text{ ou } A > s)$?
 - ▶ qui donne le meilleur gain d'information

ATTRIBUTS À VALEURS CONTINUES

// ILLUSTRATION



SURAJUSTEMENT DE L'ARBRE DE DÉCISION

- ▶ Surajustement= arbre trop "proche" des données
- ▶ Arbre peu performant pour la prédiction Le bruit dans les exemples peut conduire à un surajustement de l'arbre
 - ▶ E15= (Soleil,Chaude,Normale, Fort, NON)
 - ▶ Conséquences pour l'arbre construit ?
- ▶ Elagage de l'arbre

- ▶ Comment éviter le surajustement ?
 - ▶ Arrêter de construire l'arbre quand la séparation des exemples n'est plus significative
 - ▶ Construire l'arbre complet puis l'élaguer
 - ▶ Transformer l'arbre en ensemble de règles et simplifier les règles