

# Aprendizagem de Dados Simbólicos e/ou Numéricos

Francisco Carvalho

# Árvores de Decisão: Dados Probabilistas

## ➤ Input

- $n$  objetos formando uma partição em  $m$  classes
- cada objeto é descrito por variáveis modais de semântica probabilística.

## ➤ Objetivo

- Descrever, na forma de uma árvore binária, as  $m$  classes da partição
- Construir uma regra de decisão capaz de classificar novos objetos (cuja pertinência a uma das classes é desconhecida)



# Árvores de Decisão: Dados Probabilistas

## Objetos

- $E = \{1, \dots, n\}$  objetos formando uma partição em  $m$  classes disjuntas  $C_1, \dots, C_m$

## Variáveis: cada objeto $k \in \Omega$ é descrito por dois tipos de variáveis

- $C$ : variável que define as classes (variável à explicar)  
 $C$  é uma variável uni-valorada nominal usual
- $Y_1, \dots, Y_p$ ,  $p$  variáveis explicativas  
(variáveis multivaloradas qualitativas e quantitativas com um sistema de pesos associado)

# Árvores de Decisão: Dados Probabilistas

## ➤ Tabela de dados simbólicos

- A cada objeto  $k$  é associado uma descrição

$$a_k = [C(k) = c_k] \wedge [Y_1(k) \sim f_{k1}] \wedge \dots \wedge [Y_p(k) \sim f_{kp}]$$

- Descrição para a variável a explicar  $C$ :  $[C(k) = c_k]$   
A classe de  $k$  é descrita na forma usual por um único valor  $C(k) = c_k \in \{1, \dots, m\}$ , sem imprecisão
- Descrição para a variável explicativa  $Y_j$ :  $[Y_j(k) \sim f_{kj}]$   
Para cada objeto  $k$ , a descrição segundo  $Y_j$  é realizada por uma distribuição de probabilidade (ou de frequências)



# Árvores de Decisão: Dados Probabilistas

➔ Tabela de dados Probabilísticos

k	$Y_1$	...	$Y_p$	C
1				
:				
k	$Y_1(k) \sim f_{k1}$		$Y_p(k) \sim f_{kp}$	$C(k)=c_k$
:				
n				

# Árvores de Decisão: Dados Probabilistas

- Dois tipos de descrições probabilísticas  $f_{kj}$ 
  - $Y_j$  é contínua  
O suporte de  $Y_j$  para  $k$  é um intervalo  $V_{kj} \subset O_j \subseteq \mathfrak{R}$   
Nesse caso,  $Y_j(k)$  tem uma distribuição uniforme  $f_{kj}$  definida em  $V_{kj}$ :  $[Y_j(k) \sim U(V_{kj})]$
  - Exemplo  
 $Y_j(k)$  : tamanho de  $k$   
Se  $Y_j(k)$  é distribuída uniformemente e tem suporte  $[18,27]$ :  $[Y_j(k) \sim U([18,27])]$



# Árvores de Decisão: Dados Probabilistas

- Dois tipos de descrições probabilísticas  $f_{kj}$ 
  - $Y_j$  é discreta  
O suporte de  $Y_j$  para  $k$  é o conjunto  $V_{kj} \subset O_j$   
Nesse caso,  $Y_j(k)$  tem uma distribuição de probabilidade ou de frequências  $f_{kj}$  definida em  $V_{kj}$
  - Exemplo (variável multivalorada nominal)  
 $Y_j(k) : \text{cor de } k \text{ e } [\text{cor}(k) \sim \{1/4(\text{branco}), 3/4(\text{azul})\}]$
  - Exemplo (variável quantitativa discreta)  
[número de pétalas  $\sim \{1/2(7), 1/3(8), 1/6(9)\}$ ]

# Árvores de Decisão: Dados Probabilistas

## ➤ Dados Booleanos

- Associar um sistema de pesos a variável multivalorada
- Exemplos

[tamanho  $R$  [18,27]]  $\rightarrow$  [tamanho  $\sim U$  ([18,27])]

[cor  $R$  {azul, verde}]  $\rightarrow$  [cor  $\sim$  {0.5 (azul), 0.5 (verde)}]

[no de pétalas  $R$  {15,...,20}]  $\rightarrow$  [no de pétalas  $\sim$  { $1/6(15)$ , ...,  $1/6(20)$ }]

[cor  $R$  {azul}]  $\rightarrow$  [cor  $\sim$  {1 (azul)}]



# Árvores de Decisão: Dados Probabilistas

➔ Exemplo de tabela de dados probabilistas

k	Cor	Tamanho	No de pétalas	C
1	1 (verde)	U([60,95])	1 (0.5), 2 (0.5)	1
2	0.5(azul), 0.5 verde)	U([30,40])	1 (0.3), 2 (0.4), 3 (0.30)	2
3	0.3(preto), 0.4 verde, 0.3(branco)	U([35,60])	3 (0.5), 4 (0.5)	1

# Árvores de Decisão: Dados Probabilistas

- Construção de consultas binárias
  - Algoritmo recursivo para subdividir o conjunto  $E$  de objetos
  - A etapa de divisão é baseada em uma consulta binária de resposta sim/não baseada em uma única variável (e nos seus valores observados)



# Árvores de Decisão: Dados Probabilistas

## ➤ Construção de consultas binárias

- Dois tipos de questões binárias segundo se  $O_j$  é ordenado ou não

Variável	Nominal	Ordinal	Contínua
descrição	distribuição	distribuição	intervalo
consulta	$[Y \in V]?$	$[Y \leq c]?$	$[Y \leq c]?$

# Árvores de Decisão: Dados Probabilistas

## ➔ Consultas do tipo $[Y_j \leq c]$

- Caso discreto

Se  $O_j$  tem  $n_j$  valores, constrói-se  $n_j - 1$  questões binárias (o limiar  $c$  é escolhido entre o valores  $v_{j,1}, \dots, v_{j,n_j-1}$ )

- Exemplo

$Y_j$  número de pétalas e  $O_j = \{1,2,3,4\}$

Nesse caso,  $c \in \{1,2,3\}$



# Árvores de Decisão: Dados Probabilistas

## ➔ Consultas do tipo $[Y_j \leq c]$

- Caso contínuo

As descrições são do tipo  $[m_{kj}, M_{kj}]$

O limiar é o ponto médio entre dois limites  $m_{kj}$  e  $M_{kj}$  quaisquer ( $k=1, \dots, n$ )

Existe no máximo  $2n-1$  questões binárias (limiares)

- Exemplo: Na tabela anterior

$Y_j$  Tamanho

Nesse caso,  $c \in \{32.5, 37.5, 50, 60, 77.5\}$

# Árvores de Decisão: Dados Probabilistas

➔ Consultas do tipo  $[Y_j \in V]$

- Se  $O_j$  tem  $n_j$  valores pode-se construir  $2^{n_j-1} - 1$  questões binárias, isto é, existe  $2^{n_j-1} - 1$  maneiras de dividir um domínio  $O_j$  com  $n_j$  valores
- Exemplo:  $Y_j = \text{cor}$  e  $O_j = \{\text{azul, verde, branco}\}$

$$V = \{\text{verde}\} \quad \bar{V} = \{\text{branco, azul}\} \quad \text{ou}$$

$$V = \{\text{branco}\} \quad \bar{V} = \{\text{azul, verde}\} \quad \text{ou}$$

$$V = \{\text{azul}\} \quad \bar{V} = \{\text{verde, branco}\}$$



# Árvores de Decisão: Dados Probabilistas

➔ Construção de uma nova tabela de variáveis binárias

- Seja  $Q = \{1, \dots, Q\}$  a totalidade das questões binárias correspondentes a variável  $Y_j$

k	1	...	q	...	Q
1					
:					
k			$p_{kq}$		
:					
n					

# Árvores de Decisão: Dados Probabilistas

➡ Construção de uma nova tabela de variáveis binárias

- Hierarquia binária de classes com subclasses a esquerda e a direita (nó) para cada classe
- A pertinência ao nó esquerdo depende da resposta positiva a consulta  $[Y_j \leq c]$  (ou  $[Y_j \in V]$ )
- A pertinência ao nó direito depende da resposta positiva a consulta  $[Y_j > c]$  (ou  $[Y_j \notin V]$ )



# Árvores de Decisão: Dados Probabilistas

➔ Construção de uma nova tabela de variáveis binárias

- $p_{kq}$  : probabilidade que  $k$  seja associado ao nó esquerdo
- $1 - p_{kq}$  : probabilidade que  $k$  seja associado ao nó direito

# Árvores de Decisão: Dados Probabilistas

## ➔ Cálculo de $p_{kq}$

- $Y_j$  é contínua  
descrição  $k$  :  $U([m_k, M_k])$   
questão binária :  $[Y \leq c]$

$$p_{kq} = \begin{cases} 0, & \text{se } c < m_{kj} \\ (c - m_{kj}) / (M_{kj} - m_{kj}), & \text{se } c \in [m_{kj}, M_{kj}] \\ 1, & \text{se } c > M_{kj} \end{cases}$$



# Árvores de Decisão: Dados Probabilistas

## ➔ Cálculo de $p_{kq}$

- $Y_j$  é contínua

Exemplo: Na tabela anterior  $k=1$  e tamanho  $\sim U([80,95])$

Se  $q$ : [tamanho  $\leq 37.5$ ],  $p_{1q} = 0$  e  $1 - p_{1q} = 1$

Se  $q$ : [tamanho  $\leq 87.5$ ],  $p_{1q} = 0.5$  e  $1 - p_{1q} = 0.5$

- $Y_j$  é ordinal

descrição  $k$  :  $f_{kj}$

questão binária :  $[Y \leq c]$

$$p_{kq} = \sum_{v \leq c} f_{kj}(v)$$

# Árvores de Decisão: Dados Probabilistas

## ➔ Cálculo de $p_{kq}$

- $Y_j$  é ordinal

Exemplo: Na tabela anterior  $k=2$  e Número de pétalas  $\sim \{1 (0.3), 2 (0.4), 3 (0.30)\}$

Se  $q$ : [Número de pétalas  $\leq 2$ ],  $p_{1q} = 0.7$  e  $1 - p_{1q} = 0.3$

- $Y_j$  é nominal

descrição  $k$  :  $f_{kj}$

questão binária :  $[Y \in V]$

$$p_{kq} = \sum_{v \in V} f_{kj}(v)$$



# Árvores de Decisão: Dados Probabilistas

## ➔ Cálculo de $p_{kq}$

- $Y_j$  é nominal

Exemplo: Na tabela anterior  $k=3$  e  $Cor \sim \{\text{preto (0.3)}, \text{verde (0.4)}, \text{branco (0.30)}\}$

Se  $q: [Cor \in \{\text{verde}\}]$ ,  $p_{1q} = 0.4$  e  $1 - p_{1q} = 0.6$

# Árvores de Decisão: Dados Probabilistas

## ➔ Algoritmo de Divisão Recursiva

- Objetivo: construir uma árvore binária que fornecerá dois tipos de informação
  - ▼ Uma descrição de cada uma das  $m$  classes a priori na forma de uma conjunção de propriedades
  - ▼ Uma regra de decisão  $d$  capaz de classificar um novo objeto em uma das  $m$  classes a priori
- Dois estágios para obter esses objetivos
  - ▼ Estratégia de construção da árvore
  - ▼ Seleção da melhor sub-árvore



# Árvores de Decisão: Dados Probabilistas

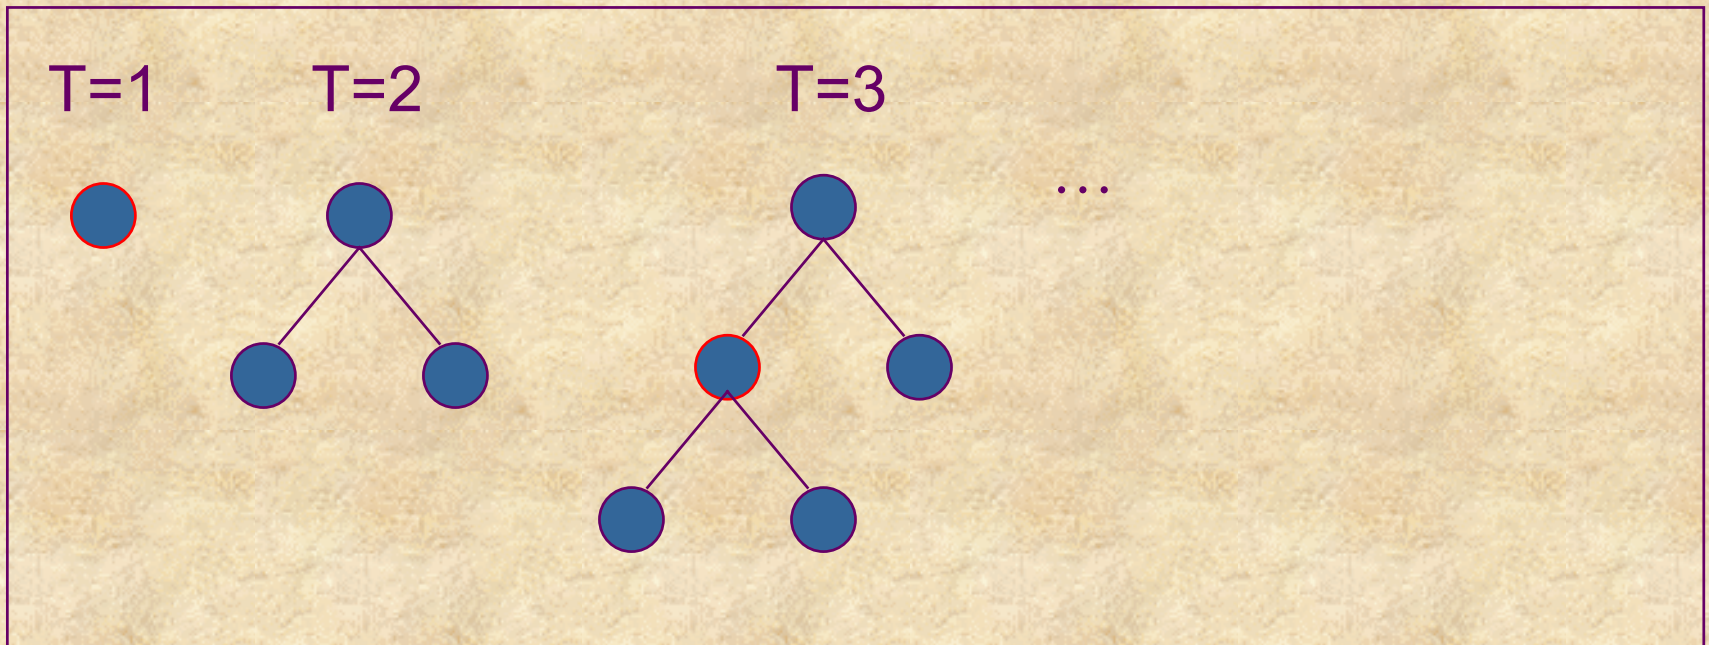
## ➤ Estratégia de construção da árvore

- Em um dado passo do algoritmo, a estratégia consiste em dividir o nó terminal que fornece o melhor critério
- O passo  $T$  do algoritmo consiste no exame dos  $T-1$  nós terminais de  $A_{T-1}$  para selecionar a melhor divisão binária que produz a melhor árvore  $A_T$  com  $T$  nós terminais
- Esse procedimento é aplicado recursivamente até ue uma condição de parada seja satisfeita

# Árvores de Decisão: Dados Probabilistas

## ➔ Estratégia de construção da árvore

- Constrói-se uma seqüência de árvores binárias encaixadas  $A_1, \dots, A_T, \dots, A_{\max}$





# Árvores de Decisão: Dados Probabilistas

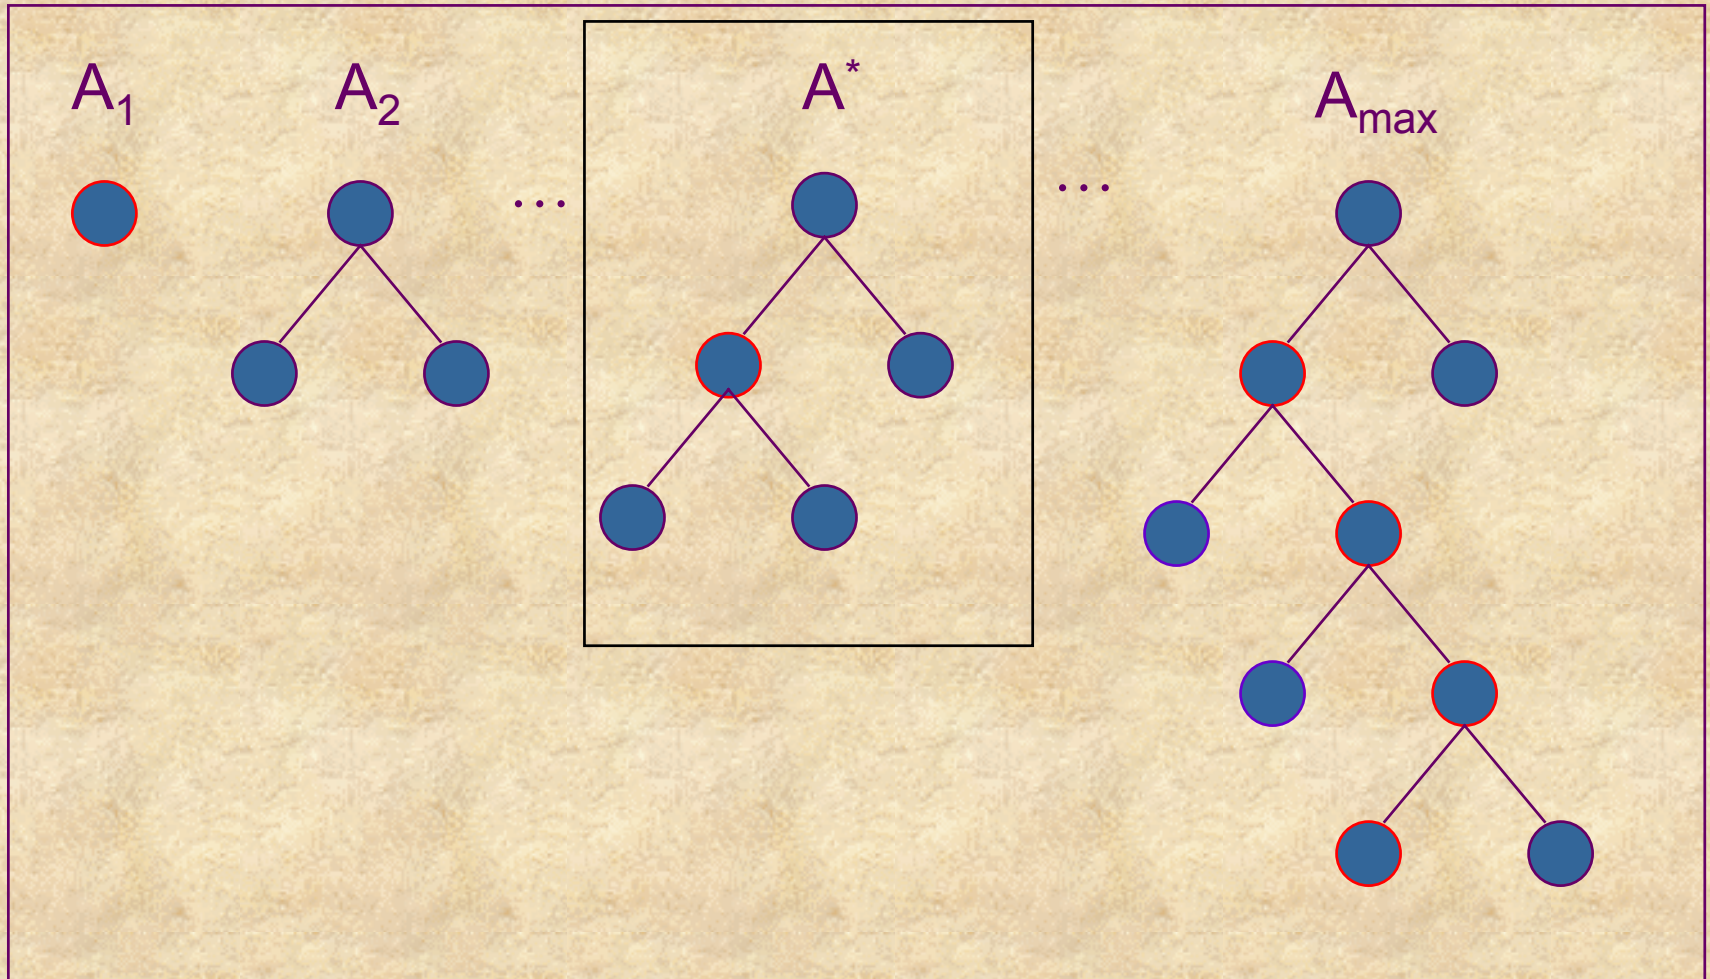
## ➔ Seleção da melhor sub-árvore

- Objetivo: fornecer uma árvore  $A^*$  associada com a melhor regra de decisão
- A qualidade de uma regra de decisão é função da taxa de acertos.
- $R(A_T)$  é a taxa associada a árvore  $A_T$
- Esse estágio consiste em selecionar a melhor sub-árvore na seqüência prévia de arvores encaixadas

$$A^* = \operatorname{argmin}_{A \in \{A_1, \dots, A_{\max}\}} R(A)$$

# Árvores de Decisão: Dados Probabilistas

Selecção da melhor sub-árvore





# Árvores de Decisão: Dados Probabilistas

## Notação

- $T_A$ : conjunto de nós terminais admissíveis para a divisão em um dado estágio do algoritmo (nós para os quais a condição de parada não é satisfeita)
- $T_D$ : conjunto de nós terminais definitivos durante a fase de crescimento da árvore (que satisfazem a condição de parada)
- $T_C$ : conjunto de todos os nós terminais em um dado estágio do algoritmo:  $T_C = T_A \cup T_D$ . Consideraremos também o conjunto de nós terminais correntes em um dado estágio do algoritmo

# Árvores de Decisão: Dados Probabilistas

## Notação

- $Q_A(t)$ : conjunto de consultas admissíveis em um nó  $t$ .
- $Q_C(t)$ : conjunto de consultas candidatas em um nó  $t$ .  
Consultas binárias cujos nós filhos “não são tão pequenos” e que fornecem “um mínimo de informação”
- $P_t(i)$ : probabilidade condicional de observar a classe  $i$  no nó  $t$
- $p_k(t)$ : probabilidade de pertinência do objeto  $k$  ao nó  $t$
- $p_{kq}$ : probabilidade que  $k$  satisfaça a consulta  $q$



# Árvores de Decisão: Dados Probabilistas

## Notação

- $W(t,q)$ : informação fornecida pela consulta  $q$  no nó  $t$  (qualidade da divisão binária produzida por  $q$ )
- $q_t^*$ : melhor consulta no nó  $t$
- $q^*$ : melhor consulta entre todos os nós terminais em uma dada etapa da divisão
- $l, n_l$ : nó esquerdo criado pela divisão e seu efetivo associado
- $r, n_r$ : nó direito criado pela divisão e seu efetivo associado

# Árvores de Decisão: Dados Probabilistas

- ➡ Algoritmo Geral da Árvore de Decisão
- ➡ Inicie com a raiz
- ➡ WHILE<sup>(1)</sup> (o tamanho da árvore é admissível) AND (existe nós terminais admissíveis)  $T_A \neq \emptyset$ 
  - (para cada nó admissível  $t$ )  $\forall t \in T_A$ 
    - ▼ (para cada questão admissível  $q$  no nó  $t$ )  $\forall q \in Q_A(t)$ 
      - ▢ (2) Divida  $t$  em dois nós terminais temporários  $l$  e  $r$ :  $T_C \leftarrow T_C \setminus \{t\} \cup \{l, r\}$
      - ▢ (3) calcule os efetivos dos nós  $l$  e  $r$ :  $n_l$  e  $n_r$
      - ▢ IF (4) ambos os nós são admissíveis: ( $n_l > \text{limiar}$ ) AND ( $n_r > \text{limiar}$ )



# Árvores de Decisão: Dados Probabilistas

## ➔ Algoritmo Geral da Árvore de Decisão

- ✓ <sup>(5)</sup> calcule a qualidade da divisão:  $W(t,q)$
- ✓ IF a qualidade é suficiente:  $W(t,q) > \text{limiar}$
- ✓ THEN  $q$  é candidato para o nó  $t$ :  $q \in Q_C(t)$
- ✓ ELSE renuncie a consulta  $q$ 
  - ▣ ELSE renuncie a questão  $q$
- ▼ END  $q$

# Árvores de Decisão: Dados Probabilistas

## ➡ Algoritmo Geral da Árvore de Decisão

- ▼ IF não existe consulta candidata no nó  $t$ :  $Q_C(t)=\emptyset$ 
  - ▣ THEN  $t$  é um nó terminal:  $T_D \leftarrow T_D \cup \{t\}$
  - ▼ ELSE <sup>(6)</sup> selecione a melhor questão no nó  $t$ :  $q_t^*$
- END  $t$
- IF não existe nó  $t$  para dividir:  $Q_C(t)=\emptyset, \forall t \in T_A$ 
  - ▼ THEN pare
- ELSE <sup>(7)</sup> selecione a melhor divisão no melhor nó:  $q^*$



# Árvores de Decisão: Dados Probabilistas

- Atualize os nós da árvore
  - ▼ IF o efetivo do nó filho  $l$  é suficiente AND  $l$  não é um nó puro THEN  $T_A \leftarrow T_A \cup \{l\}$
  - ▼ ELSE  $l$  é um nó terminal:  $T_D \leftarrow T_D \cup \{l\}$
  - ▼ IF o efetivo do nó filho  $r$  é suficiente AND  $r$  não é um nó puro THEN  $T_A \leftarrow T_A \cup \{r\}$
  - ▼ ELSE  $r$  é um nó terminal:  $T_D \leftarrow T_D \cup \{r\}$
  - ▼  $T_C \leftarrow T_A \cup T_D$

# Árvores de Decisão: Dados Probabilistas

- (8) Calcule a informação descritiva associada aos novos nós
- (9) Estime a taxa  $R(A)$  para a árvore corrente

➡ END WHILE



# Árvores de Decisão: Dados Probabilistas

- Descrição detalhada das diferentes etapas
- Tamanho e admissibilidade dos nós filhos  $l, r$  com os pesos  $n_l, n_r$  (passo 4 do algoritmo)

- calculo da probabilidade de pertinência de um objeto  $k$  aos nós filhos  $l, r$  do nó  $t$

$$p_k(l) = p_k(t) p_{kq}$$

$$p_k(r) = p_k(t) (1 - p_{kq})$$

- No primeiro passo do algoritmo,  $p_k(t) = 1$ ,  $k = 1, \dots, n$ , pois todos os indivíduos pertencem completamente a raiz
- nos passos seguintes as probabilidades  $p_{kq}$  são computadas uma vez escolhida a melhor divisão

# Árvores de Decisão: Dados Probabilistas

- ➔ Tamanho e admissibilidade dos nós filhos  $l, r$  com os pesos  $n_l, n_r$  (passo 4 do algoritmo)
  - calculo de  $n_l, n_r$

$$n_l = \sum_{k=1}^n p_k(l)$$

$$n_r = \sum_{k=1}^n p_k(r)$$



# Árvores de Decisão: Dados Probabilistas

➔ Tamanho e admissibilidade dos nós filhos  $l, r$  com os pesos  $n_l, n_r$  (passo 4 do algoritmo)

- Condição de admissibilidade para o tamanho das classes  $n_l, n_r$

A qualidade da divisão binária  $q$  do nó  $t$  (a ser definida) é calculada apenas se

$$n_l \geq \text{limiar mínimo} \quad \text{e} \quad n_r \geq \text{limiar mínimo}$$

onde *limiar mínimo* é escolhido a priori

# Árvores de Decisão: Dados Probabilistas

➔ Busca da melhor divisão (passos 6 e 7 do algoritmo)

- Busca da melhor questão  $q$  (melhor divisão) em um dado nó  $t$
- Passo preliminar: atualização do conjunto de nós terminais correntes  $T_C$ : dois nós filhos  $l$  e  $r$  substituem o nó  $t$
- A qualidade da divisão é calculada em relação ao novo conjunto

$$T_C \leftarrow T_C \setminus \{t\} \cup \{l, r\}$$



# Árvores de Decisão: Dados Probabilistas

Qualidade  $W(t, q)$  de uma divisão  $q$  no nó  $t$  (passo 5 do algoritmo)

- A qualidade da divisão induzida pela questão  $q$  no nó  $t$  é definida pela seguinte log-verossimilhança

$$W(t, q) = \log \prod_{k=1}^n \sum_{s \in T_C} p_k(s) P_s(c_k)$$

$p_k(s)$ : probabilidade de que o objeto  $k$  seja afetado ao nó  $s$

$P_s(c_k)$  é a probabilidade de que a classe  $C(k)=c_k$  é observada, condicionalmente ao nó  $s$

# Árvores de Decisão: Dados Probabilistas

➔ Qualidade  $W(t,q)$  de uma divisão  $q$  no nó  $t$  (passo 5 do algoritmo)

$$P_s(c_k) = P_s(i) \quad \text{se } k \in C_i$$

ou

$$P_s(c_k) = P_s(1)^{c_{k1}} \times \dots \times P_s(K)^{c_{km}} \quad \text{onde } c_{ki} = 1 \Leftrightarrow k \in C_i$$

- Como o interesse é apenas na informação associada com os dois nós filhos

$$W(t,q) = \log \prod_{k=1}^n (p_k(l)P_l(c_k) + p_k(r)P_r(c_k) + \lambda_k)$$



# Árvores de Decisão: Dados Probabilistas

➔ Qualidade  $W(t,q)$  de uma divisão  $q$  no nó  $t$  (etapa 5 do algoritmo)

- $\lambda_k$  é fixo e depende apenas de  $p_k(s)$  e  $P_s(c_k)$  associadas aos nós  $s$  previamente definidos, mas que não são essenciais no passo de divisão

$$\lambda_s = \sum_{\substack{s \in T_C \\ s \notin \{l,r\}}} p_k(s) P_s(c_k)$$

- Para calcular a qualidade da divisão é necessário estimar, para cada  $t$  e  $q$  fixados, as probabilidades condicionais  $P_l(1), \dots, P_l(m)$  e  $P_r(1), \dots, P_r(m)$  das  $m$  classes

# Árvores de Decisão: Dados Probabilistas

➔ O Algoritmo EM para estimar as probabilidades condicionais  $P_l(i), P_r(i)$

- Idéia básica: encontrar os valores dos parâmetros que maximizam a verossimilhança iterativamente
- Os parâmetros são as probabilidades condicionais

$$P_l^h(i) \quad \text{e} \quad P_r^h(i), \quad i = 1, \dots, K$$

- Cada iteração do Algoritmo EM consiste na repetição de duas etapas: Expectation (E) e Maximisation (M)



# Árvores de Decisão: Dados Probabilistas

➔ O Algoritmo EM para estimar as probabilidades condicionais  $P_l(i), P_r(i)$

- Etapa E: Calcula-se a probabilidade de que  $k$  pertence ao nó  $l$  e  $r$  na iteração ( $h$ ) do algoritmo

$$E^{(h)}(k, l) = \frac{P_l^{(h)}(c_k) p_k(l)}{P_l^{(h)}(c_k) p_k(l) + \lambda_k}, \quad k = 1, \dots, n$$

$$E^{(h)}(k, r) = \frac{P_r^{(h)}(c_k) p_k(r)}{P_r^{(h)}(c_k) p_k(r) + \lambda_k}, \quad k = 1, \dots, n$$

# Árvores de Decisão: Dados Probabilistas

➔ O Algoritmo EM para estimar as probabilidades condicionais  $P_l(i), P_r(i)$

- Etapa M: Calcula-se as novas probabilidades condicionais

$$P_l^{(h+1)}(i) = \frac{\sum_{k=1}^n c_{ki} E^{(h)}(k, l)}{\sum_{k=1}^n E^{(h)}(k, l)} = \frac{\sum_{k \in C_i} E^{(h)}(k, l)}{\sum_{k=1}^n E^{(h)}(k, l)}, \quad i = 1, \dots, m$$

$$P_r^{(h+1)}(i) = \frac{\sum_{k=1}^n c_{ki} E^{(h)}(k, r)}{\sum_{k=1}^n E^{(h)}(k, r)} = \frac{\sum_{k \in C_i} E^{(h)}(k, r)}{\sum_{k=1}^n E^{(h)}(k, r)}, \quad i = 1, \dots, m$$



# Árvores de Decisão: Dados Probabilistas

➔ O Algoritmo EM para estimar as probabilidades condicionais  $P_l(i), P_r(i)$

- Calcula-se o novo valor do critério  $W^{(h+1)}(t,s)$  usando-se as estimativas das probabilidades condicionais  $P_l^{(h+1)}$  e  $P_r^{(h+1)}$
- Regra de Parada: O algoritmo EM para quando

$$W^{(h+1)}(t,q) - W^{(h)}(t,q) < \varepsilon$$

onde  $\varepsilon > 0$  é próximo de zero

# Árvores de Decisão: Dados Probabilistas

➔ O Algoritmo EM para estimar as probabilidades condicionais  $P_l(i), P_r(i)$

- Valores iniciais das probabilidades condicionais para o algoritmo EM

$$P_l^{(0)}(i) = \frac{\sum_{k=1}^n c_{ki} p_k(l)}{\sum_{k=1}^n p_k(l)} = \frac{\sum_{k \in C_i} p_k(l)}{n_l} \quad i = 1, \dots, m$$

$$P_r^{(0)}(i) = \frac{\sum_{k=1}^n c_{ki} p_k(r)}{\sum_{k=1}^n p_k(r)} = \frac{\sum_{k \in C_i} p_k(r)}{n_r} \quad i = 1, \dots, m$$



# Árvores de Decisão: Dados Probabilistas

➔ O Algoritmo EM para estimar as probabilidades condicionais  $P_l(i), P_r(i)$

- Condições de admissibilidade baseada na qualidade da divisão

Guarda-se provisoriamente a questão  $q$  se a informação  $W(t,q)$  é maior do que um dado limiar

if  $[W(t,q) > \text{limiar min}]$  então  $[q \in Q_C(t)]$

diz-se então que  $q$  é um candidato para o nó  $t$

# Árvores de Decisão: Dados Probabilistas

## ➔ Seleção da melhor divisão

Essa seleção é realizada em duas etapas:

- Seleção da melhor questão  $q$  em cada nó terminal  $t$ :  $q_t^*$  (etapa 6 do algoritmo)
- Seleção da melhor questão  $q_t^*$  entre todos os nós terminais  $t$ :  $q^*$  (etapa 7 do algoritmo)
- Em conseqüência, a melhor divisão é aquela que produz a melhor árvore de  $(T+1)$  nós, dada uma árvore de  $T$  nós
- “Melhor” significa um valor de máximo verossimilhança  $W$



# Árvores de Decisão: Dados Probabilistas

➔ Informações Descritivas calculadas para os novos nós (etapa 8 do algoritmo)

- Os seguintes tipos de informação são calculados para cada novo nó  $t$
- *Informação relacionada com a descrição do nó*  
[ $Y_j \in V$ ], [ $Y_j < c$ ], ...
- *Informações relativas aos indivíduos*
  - ▼ Probabilidade de pertinência dos objetos  $k$  ao nó  $t$ :  
 $p_k(t)$
  - ▼ O conjunto de indivíduos afetados a  $t$  com base na regra da maioria

$$\text{no}(t) = \{k \mid p_k(t) > p_k(s), \forall s \neq t\}$$

# Árvores de Decisão: Dados Probabilistas

Informações Descritivas calculadas para os novos nós (etapa 8 do algoritmo)

- Informações das Classes de uma dada partição a priori*  
Define-se a seguinte tabela que fornece informações gerais sobre as  $K$  classes a priori no nó  $t$ :

	Tamanho	Prob.	d
classe 1	$n_+(1)$	$P_+(1)$	
...	...	...	
classe $i$	$n_+(i)$	$P_+(i)$	♣
...	...	...	
classe $m$	$n_+(m)$	$P_+(m)$	



# Árvores de Decisão: Dados Probabilistas

➔ Informações Descritivas calculadas para os novos nós (etapa 8 do algoritmo)

- *Informações das Classes de uma dada partição a priori*

Onde

- ▼  $P_t(i)$ : probabilidade condicional de observar a classe  $i$  no nó  $t$
- ▼  $n_t(i)$ : tamanho da classe  $i$  no nó  $t$ : isso é calculado com base na lista de objetos afetados ao nó  $t$ :  
 $n_t(i) = \{k \mid k \in \text{nó}(t) \text{ e } k \in C_i\}$
- ▼ a ultima coluna indica a classe majoritária no nó ( $*$ ) segundo as probabilidades condicionais:  
 $[d(t) = i] \Leftrightarrow [P_t(i) > P_t(l), \forall l \neq i]$

# Árvores de Decisão: Dados Probabilistas

➡ Informações Descritivas calculadas para os novos nós (etapa 8 do algoritmo)

- *Informações das Classes de uma dada partição a priori*

Onde

- ▼ O cálculo do tamanho total do nó  $n_t$  e a probabilidade  $p(t)$  de alcançá-lo é como segue:

$$n(t) = \sum_{i=1}^m n_t(i)$$

$$p(t) = \sum_{k=1}^n p_k(t) p(k) = \frac{1}{n} \sum_{k=1}^n p_k(t)$$

Supõe-se que cada objeto tem um peso  $p(k) = 1/n$



# Árvores de Decisão: Dados Probabilistas

## ➡ Condições de Parada

- O crescimento da árvore é interrompido se ao menos uma das condições abaixo for satisfeita:
  - ▼ A árvore é muito grande:  $\text{card}(T_C) > \text{limiar max}$
  - ▼ Não é possível realizar novas divisões:  $T_A = \emptyset$

Essa condição ocorre quando os nós terminais são puros (inclui indivíduos de apenas uma classe) ou quando o tamanho deles é muito pequeno

# Árvores de Decisão: Dados Probabilistas

## Componentes da Decisão

- Um dos objetivos desse método é fornecer uma regra de decisão que é capaz de classificar novos objetos com um mínimo de erros
- Para isso é necessário selecionar a melhor sub-árvore (e a sua regra de decisão associada) dentre a seqüência de árvores embutidas.
- Questões preliminares:
  - ▼ Como construir uma regra de decisão
  - ▼ Como medir a qualidade da mesma



# Árvores de Decisão: Dados Probabilistas

## Regra de Decisão

- Seja  $D$  o conjunto de todos os vetores de descrições simbólicas relevantes para a situação em estudo
- Uma regra de decisão  $d$  associada com uma árvore binária é uma função

$$d : D \rightarrow \{1, \dots, i, \dots, m\}$$

que permite afetar cada objeto  $k$  de vetor de descrição  $x_k \in D$  a uma classe  $i$  da partição a priori.

- Nesse método, vale a seguinte regra:

$$[d(x_k) = i] \Leftrightarrow [p_k(i) > p_k(j) \quad \text{para} \quad j = 1, \dots, m, j \neq i]$$

# Árvores de Decisão: Dados Probabilistas

## Regra de Decisão

- A probabilidade de pertinência  $p_k(i)$  é calculada como a média ponderada (em relação a todos os nós terminais) das probabilidades condicionais  $P_t(i)$ , com pesos  $p_k(t)$

$$p_k(i) = \sum_{t=1}^T P_t(i) p_k(t)$$

- Ela consiste na soma das probabilidades de que um indivíduo pertença a classe  $i$ , para todos os nós terminais  $t$ , essas probabilidades sendo ponderadas pelas probabilidades de que esse objeto alcance as diferentes folhas



# Árvores de Decisão: Dados Probabilistas

➔ Qualidade de uma regra de decisão d

- Taxa de previsões corretas

A qualidade da regra pode ser definida através de uma *taxa de previsões corretas*

$$R(A) = \frac{n_A}{n_t}$$

onde  $n_A$  é número de objetos corretamente classificados pela árvore A e  $n_t$  é o número total de objetos a ser classificado

# Árvores de Decisão: Dados Probabilistas

➔ Qualidade de uma regra de decisão  $d$

- Taxa de previsões corretas

Um objeto  $k$  pertencente a classe  $i$  é dito ser *corretamente classificado* pela regra de decisão  $d$  associada com a árvore  $A$  se

$$[d(x_k) = i] \quad \text{e} \quad [c_k = i]$$

são ambos verdadeiros, isto é, se  $k$  é corretamente afetado a classe  $i$  com base no seu vetor de descrição

$\mathbf{x}_k$



# Árvores de Decisão: Dados Probabilistas

## ➡ Qualidade de uma regra de decisão d

- População ou Amostra

Duas situações consideradas

- ▼ o conjunto de objetos pode ser considerado como uma população exaustiva.

Nesse caso é calculada a taxa de previsão correta  $R(A)$  classificando-se os  $n$  ( $= n_t$ ) objetos de  $E$

- ▼ o conjunto de objetos pode ser considerado como uma amostra de uma população mais geral  
Nesse caso, a taxa  $R(A)$  é calculada com base em um conjunto de teste:  $n_t$  é o tamanho do conjunto de teste e  $n_A$  é igual a totalidade de casos que são classificados corretamente

# Árvores de Decisão: Dados Probabilistas

➔ Qualidade de uma regra de decisão  $d$

- Seleção de sub-árvores

Tendo-se definido a qualidade de uma árvore, é possível selecionar a “melhor árvore”  $A^*$  da seqüência de árvores encaixadas  $A_1, \dots, A_T, \dots, A_{\max}$ , isto é, a árvore associada com a maior taxa  $R(A)$

- ▼ Tratando-se de uma população, o valor máximo de  $R(A)$  é alcançado quando  $A = A_{\max}$

Refinando-se a árvore binária sempre se consegue melhorar a taxa de previsões corretas no conjunto de aprendizagem



# Árvores de Decisão: Dados Probabilistas

➔ Qualidade de uma regra de decisão  $d$

- Seleção de sub-árvores
  - ▼ Tratando-se de uma amostra, a melhor árvore binária geralmente é muito menor do que  $A_{\max}$  por conta do sobre-ajustamento

Após uma dada etapa do algoritmo, o crescimento da árvore leva a uma regra de decisão mais eficiente no conjunto de treinamento e uma degradação da sua qualidade em relação a toda população

## Exemplo 3

### Tabela de dados probabilísticos

$K_k$	$Y_1$			$Y_2$			$Y_3$		
	1	2	3	1	2	3	1	2	3
1	0.10	0.30	0.60	0.40	0.30	0.30	0.05	0.70	0.25
2	0.20	0.40	0.40	0.10	0.50	0.40	0.10	0.80	0.10
3	0.50	0.20	0.30	0.15	0.35	0.50	0.40	0.20	0.40
4	0.40	0.10	0.50	0.30	0.30	0.40	0.35	0.20	0.45



## Tabela de questões binárias

	1	2	3	4	5	6
K	$Y_1 \leq 1$	$Y_1 \leq 2$	$Y_2 \leq 1$	$Y_2 \leq 2$	$Y_3 \leq 1$	$Y_3 \leq 2$
1	0.10	0.40	0.40	0.70	0.05	0.75
2	0.20	0.60	0.10	0.60	0.10	0.90
3	0.50	0.70	0.15	0.50	0.40	0.60
4	0.40	0.50	0.30	0.60	0.35	0.55

## Etapa 1

$$t = 1, \quad Y_1 \leq 1$$

$$p_k(e) = p_k(t) \cdot p_{kq} \quad k = 1, 2, 3, 4 \quad p_k(d) = p_k(t) \cdot (1 - p_{kq}) \quad k = 1, 2, 3, 4$$

$$p_1(e) = p_1(t) \times p_{1q} = 1 \times 0.10 = 0.10$$

$$p_1(d) = p_1(t) \times (1 - p_{1q}) = 1 \times 0.90 = 0.90$$

$$p_2(e) = p_2(t) p_{2q} = 1 \times 0.20 = 0.20$$

$$p_2(d) = p_2(t) \cdot (1 - p_{2q}) = 1 \times 0.80 = 0.80$$

$$p_3(e) = p_3(t) \cdot p_{3q} = 1 \times 0.50 = 0.50$$

$$p_3(d) = p_3(t) \cdot (1 - p_{3q}) = 1 \times 0.50 = 0.50$$

$$p_4(e) = p_4(t) \cdot p_{4q} = 1 \times 0.40 = 0.40$$

$$p_4(d) = p_4(t) \cdot (1 - p_{4q}) = 1 \times 0.60 = 0.60$$



$$P_e^0(1) = \frac{\sum_{k \in C_1} p_k(e)}{\sum_{k=1}^n p_k(e)} = \frac{0.10 + 0.20}{0.1 + 0.20 + 0.5 + 0.40} = 0.25$$

$$P_e^0(2) = 1 - P_e^0(1) = 0.75$$

$$P_d^0(1) = \frac{\sum_{k \in C_2} p_k(e)}{\sum_{k=1}^n p_k(e)} = \frac{0.90 + 0.80}{0.90 + 0.80 + 0.50 + 0.60} = 0.60$$

$$P_d^0(2) = 1 - P_d^0(1) = 0.40$$

$$\begin{aligned} W(t, q) &= \log \prod_{k=1}^n (p_k(e) \cdot P_e(c_k) + p_k(d) \cdot P_d(c_k)) \\ &= \log( (0.10 \times 0.25 + 0.90 \times 0.60) \cdot \\ &\quad (0.20 \times 0.25 + 0.80 \times 0.60) \cdot \\ &\quad (0.50 \times 0.75 + 0.50 \times 0.40) \cdot \\ &\quad (0.40 \times 0.75 + 0.60 \times 0.40) \cdot \\ &= \log(0.0913) = -2.394 \end{aligned}$$

## Resultados de $W(t,q)$ para Etapa 1

$$Y_1 \leq 1$$

$$W(t,q) = -2.394$$

$$Y_1 \leq 2$$

$$W(t,q) = -2.7806$$

$$Y_2 \leq 1$$

$$W(t,q) = -2.975$$

$$Y_2 \leq 2$$

$$W(t,q) = -2.682$$

$$Y_3 \leq 1$$

$$W(t,q) = -2.763$$

$$Y_3 \leq 2$$

$$W(t,q) = -2.521$$





$Y_1 \leq 1$

$Y_1 > 1$

$$P_t(1) = \frac{0.10 + 0.20}{0.10 + 0.20 + 0.50 + 0.40} = 0.25$$

$$P_t(1) = \frac{0.30 + 0.60 + 0.40 + 0.40}{0.30 + 0.60 + 0.4 + 0.40 + 0.20 + 0.30 + 0.50 + 0.10} = 0.56$$

$$P_t(2) = 1 - 0.25 = 0.75$$

$$P_t(2) = 1 - 0.56 = 0.44$$

## Cálculo do R(A)

$$p_1(1) = 0.10 \times 0.25 + 0.90 \times 0.56 = 0.529$$

Objeto 1 → Classe 1

$$p_1(2) = 0.10 \times 0.75 + 0.90 \times 0.44 = 0.471$$

$$p_2(1) = 0.498$$

Objeto 2 → Classe 2

$$p_2(2) = 0.502$$

$$p_3(1) = 0.40$$

Objeto 3 → Classe 2

$$p_3(2) = 0.502$$

$$p_4(1) = 0.43$$

Objeto 4 → Classe 2

$$p_4(2) = 0.77$$

$R(A) = 75\%$



## Etapa 2

### Partição $Y_1 \leq 1$

#### $Y_2 \leq 1$

$$p_1(e) = p_1(t) \cdot p_{1q} = 0.10 \times 0.4 = 0.04$$

$$p_1(d) = p_1(t) \cdot (1 - p_{1q}) = 0.10 \times 0.60 = 0.06$$

$$p_2(e) = p_2(t) \cdot p_{2q} = 0.20 \times 0.10 = 0.02$$

$$p_2(d) = p_2(t) \cdot (1 - p_{2q}) = 0.20 \times 0.90 = 0.18$$

$$p_3(e) = p_3(t) \cdot p_{3q} = 0.075$$

$$p_3(d) = p_3(t) \cdot (1 - p_{3q}) = 0.425$$

$$p_4(e) = p_4(t) \cdot p_{4q} = 0.12$$

$$p_4(d) = p_4(t) \cdot (1 - p_{4q}) = 0.28$$

$$P_e^0(1) = \frac{0.04 + 0.02}{0.04 + 0.02 + 0.075 + 0.12} = 0.34$$

$$P_e^0(2) = 1 - P_e^0(1) = 0.56$$

$$P_d^0(1) = 0.25$$

$$P_d^0(2) = 1 - P_d^0(1) = 0.75$$

$$W(t, q) = -8.873$$

## Resultados de $W(t,q)$ para Etapa 2

### Partição $Y_1 \leq 1$

$$Y_2 \leq 1$$

$$W(t,q) = -8.873$$

$$Y_2 \leq 2$$

$$W(t,q) = -8.805$$

$$Y_3 \leq 1$$

$$W(t,q) = -8.740$$

$$Y_3 \leq 2$$

$$W(t,q) = -6.265$$

### Partição $Y_1 > 1$

$$Y_2 \leq 1$$

$$W(t,q) = -4.398$$

$$Y_2 \leq 2$$

$$W(t,q) = -3.963$$

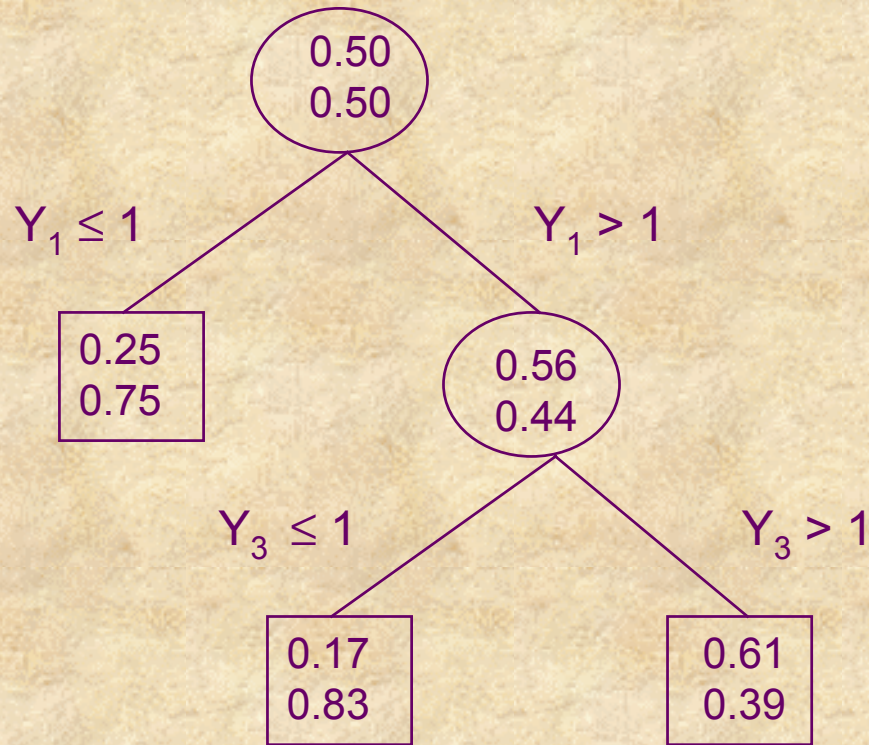
$$Y_3 \leq 1$$

$$W(t,q) = -3.849$$

$$Y_3 \leq 2$$

$$W(t,q) = -4.135$$





Classe 1 [  $Y_1 \in [2,3] \wedge Y_3 \in [2,3]$  ]

Classe 2 [  $Y_1 \in [0,1]$  ]

[  $Y_1 \in [2,3] \wedge Y_3 \in [0,1]$  ]

## Cálculo do R(A)

$$p_1(1) = 0.25 \times 0.10 + 0.61 \times [(0.30 + 0.60) \times (0.70 + 0.25) + 0.17 \times [(0.30 + 0.60) \times 0.05]] = 0.55 \quad \text{Objeto 1} \rightarrow \text{Classe 1}$$

$$p_1(2) = 0.45$$

$$p_2(1) = 0.504 \quad \text{Objeto 2} \rightarrow \text{Classe 2}$$

$$p_2(2) = 0.496$$

$$p_3(1) = 0.342 \quad \text{Objeto 3} \rightarrow \text{Classe 2}$$

$$p_3(2) = 0.658$$

$$p_4(1) = 0.369 \quad \text{Objeto 4} \rightarrow \text{Classe 2}$$

$$p_4(2) = 0.631$$

$$R(A) = 100\%$$