

# **Directii de Cercetare in Explorarea Datelor**

Prof. Dan A. Simovici

University of Massachusetts Boston

Departmentul de Informatica

Boston, Massachusetts, USA

# Ce este Explorarea Datelor (Data Mining)?

**ED:** Procesul de identificare a unor fapte si proprietati ale datelor.

- ED foloseste o varietate de discipline informatice: base de date, inteligenta artificiala, logica si statistica.
- ED este aplicata frecvent unor volume mari de date; exista numeroase grupuri de date de volum relativ redus care creaza probleme dificile.

# Ce incercam sa descoperim cu ED?

Probleme majore:

- Descoperirea asocierilor intre obiecte.
- Gruparea obiectelor in multimi de obiecte similare. (*clustering*)
- Clasificarea obiectelor bazata pe proprietatile lor
- Evaluarea intersului faptelor si proprietatilor descoperite.
- Prepararea datelor (curatire, discretizare, etc.).

# Cine are nevoie de ED?

- banchi si cei care acorda credit;
- medici si biologi care incearca sa descopere cauzele bolilor si sa formuleze diagnostice;
- organizatii guvernamentale care incearca sa neutralizeze raufacatori;
- informaticieni care dirijeaza retelele informatice si dezvolta algoritmi pentru cercetarea internetului;
- ecologi si biologi intersati sa descopere surse de poluare,
- si multi altii...

# Ce cunostinte practice sunt necesare?

- base de date relationale; SQL si folosirea lui in C++, Java, si alte limbaje;
- algoritmi care lucreaza cu o varietate de structuri de date;
- gestionarea depozitelor de date (data warehousing);
- cunosterea pachetelor de programe principale: Clementine, SAS, WEKA, etc.

# Ce cunostinte teoretice sunt necesare?

- diverse arii de matematica:
  - Clustering spatii metrice
  - algebra lineară și analiză funcțională
- Clasificare teoria informației
- grafuri
- Reguli de latici
- asociere
- teoria complexității : NP- și #P-completitudine
- teoria informației;
- probabilități și statistică.

# Baze de date si data mining

Tycho Brache (1546–1601)	colector de date multe date, dar n-a extras legile astronomice
Johannes Kepler (1571-1630)	minier de date

# Clustering

Important for:

- condensarea datelor (prezentarea concisa a datelor);
- identificarea tendintelor in date.

A. K. Jain (1999): “nu exista un algoritm pentru clustering care este universal aplicabil in decoperirea oricarei structuri prezente in multimi multidimensionale de date”

# Un exemplu de algoritm - clusterizarea incrementală

- date nominale
- clustering incremental

**Caracteristica principală:** Clustering-ul incremental formează grupuri adăugind în mod successiv obiecte la grupuri (clusters) sau formând noi grupuri.

# Date numerice si date nominale

- Date numerice:
  - inaltime: 1.82m, 1.25m, ...
  - temperatura: 38, 41, 54
- Date nominale:
  - culoare: rosu, verde, albastru,...
  - forma: patrat, romb, trapez, cerc,...

Distante pot fi definite in mod natural intre obiecte care au atribute numerice (folosind diferite metrici din  $R^n$ ).

# Dificultati cu datele nominale

Lipsa unei distante “naturale”: singura distanta ce se poate introduce este distanta Hamming, unde  $d(o, o')$  este numarul de atribute in care  $o$  si  $o'$  sunt diferite.

# Istoric

Algoritmi de grupare incrementală:

- Hartigan (1975)
- Fisher (1987) : COBWEB

# Aplicatii

- F. Can et al.: baze de date de documente (1993–1995)
- Langford: detectarea focarelor de infectie din spitale (2001)
- J. Lin: serii temporale
- M. Charikar: regasirea dinamica a informatiei
- M. Ester: magazii de date (data warehouses)

# Interesul clusteringului incremental

- Folosirea memoriei principale este minima
- Cerintele de timp cresc linear cu numarul de obiecte (scalable algorithm)

# Sisteme de obiecte (SO)

Un sistem de obiecte este o pereche  $\mathcal{S} = (S, H)$ , unde

- $S$  este o multime numita multimea de obiecte ale sistemului  $\mathcal{S}$ ,
- $H = \{A_1, \dots, A_m\}$  este o multime de functii definite pe  $S$ .

$A_i$  (numit un atribut al lui  $\mathcal{S}$ ) este o functie  $A_i : S \longrightarrow E_i$ , unde  $E_i$  este domeniul lui  $A_i$ .

# Partitii

O partitie pe o multime  $S$  este o colectie nevida de parti ale lui  $S$  indexata de o multime  $I$ ,  
 $\pi = \{B_i | i \in I\}$  asa fel incit:

- $\bigcup_{i \in I} B_i = S$ , si
- $i \neq j$  implica  $B_i \cap B_j = \emptyset$ .

$B_i$  sunt *blocurile partitiei*  $\pi$ . Multimea partitiilor lui  $S$  este notata cu  $\text{PART}(S)$ .

# Laticea Partitiilor

$\pi \leq \sigma$  daca fiecare block  $B$  al partitiei  $\pi$  este inclus intr-un block al partitiei  $\sigma$ .

Daca  $\pi, \pi' \in \text{PART}(S)$  există o partitie minimală  $\pi_1$  astfel ca  $\pi \leq \pi_1$  și  $\pi' \leq \pi_1$ ; de asemenea, există cea mai mare partitie  $\pi_2$  pentru care  $\pi_2 \leq \pi$  și  $\pi_2 \leq \pi'$ . Prima partitie se notează cu  $\pi \vee \pi'$ ; a doua cu  $\pi \wedge \pi'$ .

# Partitii generate de atribut

Un atribut  $A$  al sistemului  $\mathcal{S} = (S, H)$  genereaza o partitie  $\pi^A \in parts(S)$ : doua obiecte aparțin aceluiași bloc al partitiei  $\pi^A$  dacă au aceeași proiecție pe  $A$ .

$B_a^A$ : blocul lui  $\pi^A$  care constă din obiectele lui  $S$  care au componenta pe  $A$  egală cu  $a$ .

In baze de date relationale  $\pi^A$  se obține folosind opțiunea **group by**  $A$  al frazei **select** in standard SQL.

# Partitii generate de multimi de attribute

$T$			
tid	$\dots$	$L$	$\dots$
$t_1$	$\dots$	$a_1$	$\dots$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$t_i$	$\dots$	$a_i$	$\dots$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$t_n$	$\dots$	$a_n$	$\dots$

$L$  generate o partitie  
a multimii de obiecte

$t_j \equiv_L t_k$  daca si numai daca  $t_j[L] = t_k[L]$

Notam cu  $\pi_L$  partitia  
generata de  $L$

# Partitii si dependente functionale

$T$

tid	...	$L$	...	$K$	...
:	:	:	:	:	:
$t_i$	...	$a_i$	...	$b_i$	...
:	:	:	:	:	:
$t_j$	...	$a_j$	...	$b_j$	...
:	:	:	:	:	:
$t_n$	...	$a_n$	...	$b_n$	...

$T$  satisface dependenta  
functională  $L \rightarrow K$  dacă  
 $a_i = a_j$  implica  $b_i = b_j$   
pentru  $i, j$ , adică,  
 $t_i \equiv_L t_j$  implica  $t_i \equiv_K t_j$ ,  
adică,  $\pi_L \leq \pi_K$

# Clusterizari ca partitii

O clusterizare a unui sistem de obiecte  $\mathcal{S} = (S, H)$  este o partitie  $\kappa$  a multimii de obiecte  $S$ .

Scopul nostru: determinarea grupajelor  $\kappa$  pornind de la legaturile lor cu partitile induse de atrubute  $\pi^A$ .

# Valuari si Metrici

- $v : \text{PART}(S) \longrightarrow \mathbb{R}$  definită de  
 $v(\pi) = \sum_{i=1}^n |B_i|^2$ , unde  $\pi = \{B_1, \dots, B_n\}$  este o valuare inferioară pe  $\text{PART}(S)$ :

$$v(\pi \vee \sigma) + v(\pi \wedge \sigma) \geq v(\pi) + v(\sigma) \quad (1)$$

pentru  $\pi, \sigma \in \text{PART}(S)$ .

- Pentru fiecare valuare inferioară  $v$ , funcția  $d : (\text{PART}(S))^2 \longrightarrow \mathbb{R}$  data de  $d(\pi, \sigma) = v(\pi) + v(\sigma) - 2v(\pi \wedge \sigma)$  este o distanță pe  $\text{PART}(S)$ .

# Criteriul de Optimalitate

Se cauta o grupare  $\kappa = \{C_1, \dots, C_n\} \in \text{PART}(S)$  astfel ca distanta totala de la  $\kappa$  la partitiile atributelor:

$$D(\kappa) = \sum_{i=1}^n d(\kappa, \pi^{A_i})$$

sa fie **minima**.

# Grupaje si partitiile atributelor

$$d(\kappa, \pi^A) = \sum_{i=1}^n |C_i|^2 + \sum_{j=1}^{m_A} |B_{a_j}^A|^2 - 2 \sum_{i=1}^n \sum_{j=1}^{m_A} |C_i \cap B_{a_j}^A|^2,$$

# AMICA

(A Metric Incremental Clustering Algorithm)

Fie  $t \notin S$ , si fie  $Z = S \cup \{t\}$ . Urmatoarele situatii pot avea loc:

1. obiectul  $t$  este adagat unui grup(cluster) existent  $C_k$ , sau
2. un nou grup,  $C_{n+1}$  este creat care consista doar din  $t$ .

Relativ la  $\pi^A$ ,  $t$  se adauga blocului  $B_{t[A]}^A$ .

# Obiectul se adauga unui cluster existent

$$\kappa_{(k)} = \{C_1, \dots, C_{k-1}, C_k \cup \{t\}, C_{k+1}, \dots, C_n\}$$

$$\pi^{A'} = \{B_{a_1}^A, \dots, B_{t[A]}^A \cup \{t\}, \dots, B_{a_{m_A}}^A\}$$

$$d(\kappa_{(k)}, \pi^{A'}) - d(\kappa, \pi^A) = 2|C_k \oplus B_{t[A]}^A|.$$

Cresterea minima a  $d(\kappa_{(k)}, \pi^{A'})$  este data de:

$$\min_k \sum_A 2|C_k \oplus B_{t[A]}^A|.$$

# Obiectul formeaza un nou cluster

$$\kappa' = \{C_1, \dots, \dots, C_n, \{t\}\}$$

$$\pi^{A'} = \{B_{a_1}^A, \dots, B_{t[A]}^A \cup \{t\}, \dots, B_{a_{m_A}}^A\}$$

$$d(\kappa', \pi^{A'}) - d(\kappa, \pi^A) = 2|B_{t[A]}^A|.$$

# Directie de actionare

$$D(\kappa') - D(\kappa) = \begin{cases} 2 \cdot \sum_A |C_k \oplus B_{t[A]}^A| & \text{in Case 1} \\ 2 \cdot \sum_A |B_{t[A]}^A| & \text{in Case 2.} \end{cases}$$

Daca  $\min_k \sum_A |C_k \oplus B_{t[A]}^A| < \sum_A |B_{t[A]}^A|$  se adauga  $t$  la clusterul  $C_k$  pentru care  $\sum_A |C_k \oplus B_{t[A]}^A|$  este minima; altfel se creaza un nou cluster cu un singur obiect.

# Dificultatile grupajului incremental

- Algoritmii de grupare incrementală sunt afectate, în general, de ordinea de prelucrare a obiectelor.
- Fiecare algoritm procedează într-o manieră “hill-climbing” care produce minime locale (și nu globale).

# Limitarea efectului ordonarii obiectelor

Am folosit tehnica “not-yet” introdusa de Roure si Talavera:

**NOT-YET**: Un nou grupaj este creat numai daca conditia

$$r(t) = \frac{\sum_A |B_{t[A]}^A|}{\min_k \sum_A |C_k \oplus B_{t[A]}^A|} < \alpha,$$

este satisfacuta, adica, numai daca efectul adaugarii obiectului  $t$  asupra distantei totale  $r(t)$  este suficient de semnificativ.

$\alpha \leq 1$  este un parametru dat de utilizator (daca  $\alpha = 1$  obiectele nu sunt trimise la buffer).

# Algorithmul AMICA

**Intrari:** Setul de date  $S$  și  $\alpha$

**Iesiri:** clustering  $C_1, \dots, C_{n_C}$

**Metoda:**

$\text{nc} = 0; \ell = 1;$

while  $S \neq \emptyset$  do

    select an object  $t$ ;  $S = S - \{t\}$ ;

    if  $\sum_A |B_{t[A]}^A| \leq \alpha \min_{1 \leq k \leq \text{nc}} \sum_A |C_k \oplus B_{t[A]}^A|$

        then

$\text{nc} ++$ ; create a new single-object cluster  $C_{\text{nc}} = \{t\}$ ;

        else

$r(t) = \sum_A |B_{t[A]}^A| / \min_{1 \leq k \leq \text{nc}} \sum_A |C_k \oplus B_{t[A]}^A|$

            if  $r(t) > 1$

                then  $k = \arg \min_k \sum_A |C_k \oplus B_{t[A]}^A|$

                    add  $t$  to cluster  $C_k$ ;

                else /\* this means  $\alpha < r(t) \leq 1$  \*/

                    place  $t$  in NOT-YET buffer;

    end if;

# Experimente cu date produse sintetic

- Date sintetice: produse de un algoritm care genereaza obiecte cu componente reale grupate in jurul unui numar dat de centre.
- Datele au fost discretizate folosind un numar specific de intervale de discretizare, ceea ce ne permite sa tratam datele ca date nominale.
- Am experimentat cu cteva multimi de date cu un numar crescind de obiecte, cu un numar crescind de dimensiuni, folosind cteva permutari ale obiectelor.
- Toate experimentele folosesc  $\alpha = 0.95$ .

# Stabilitatea Grupurilor

- Experiment executat pe o baza de date care consta din 10,000 de obiecte (grupate in jurul a 6 centroizi)
- O prima aplicare a algoritmului genereaza 11 grupuri.
- Cele mai multe obiecte (9895) sunt concentrate in 6 grupuri, ceea ce reprezinta o buna aproximare a grupurilor “naturale” produse de algoritmul de generare.

# AMICA este relativ imuna la permutari

Initial		Permutatare Aleatoare			
Cluster	Mar.	Cluster	Mar.	Distributie (cluster original)	
1	1548	1	1692	1692 (2)	
2	1693	2	1552	1548 (1), 3 (3), 1 (2)	
3	1655	3	1672	1672 (5)	
4	1711	4	1711	1711 (4)	
5	1672	5	1652	1652 (3)	
6	1616	6	1616	1616 (6)	
7	1	7	85	85 (8)	
8	85	8	10	10 (9)	
9	10	9	8	8 (10)	
10	8	10	1	1 (11)	
11	1	11	1	1 (7)	

# Scalabilitate

Numar de obiecte	Timp pt. 3 permutari (ms)			Timp mediu (ms)
2000	131	140	154	141.7
5000	410	381	432	407.7
10000	782	761	831	794.7
20000	1103	1148	1061	1104

# Setul de date CIUPERCI

- Setul de date contine 8124 descrieri de ciuperci si este tipic folosit pentru probleme de clasificare.
- Algoritmii de clasificare incearca sa determine daca un tip de ciuperca este comestibil sau otravitor.
- Atributul (otravitor/comestibil) este eliminat si AMICA a fost aplicat la setul de date fara acest atribut.

# Rezultate experimentale

Cl. no.	O/C	Total	Procentul grupului dominant
1	825/2752	3577	76.9%
2	8/1050	1058	99.2%
3	1304/0	1304	100%
4	0/163	163	100%
5	1735/28	1763	98.4%
6	0/7	7	100%
7	0/192	192	100%
8	36/16	52	69%
9	8/0	8	100%


# Stabilitate la Permutari

$C_i$	Grupuri Calculate									
	Permutatare aleatoare									
	$C'_1$	$C'_2$	$C'_3$	$C'_4$	$C'_5$	$C'_6$	$C'_7$	$C'_8$	$C'_9$	$C'_{10}$
	3540	1797	1095	192	1296	8	36	7	137	16
3577	3540	0	37	0	0	0	0	0	0	0
1058	0	0	1058	0	0	0	0	0	0	0
1304	0	8	0	0	1296	0	0	0	0	0
163	0	26	0	0	0	0	0	0	137	0
1763	0	1763	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	7	0	0
192	0	0	0	192	0	0	0	0	0	0
52	0	0	0	0	0	0	36	0	0	16
8	0	0	0	0	0	8	0	0	0	0

# Probleme inrudite

- Continuarea studiului experimental cu alte valori ale factorului “not-yet”  $\alpha$ .
- Combinarea algoritmului AMICA cu tehnici speciale de discretizare pentru extinderea algoritmului la date cu caracter mix,
- Grupare incrementală în varianta “Semi-supervised” bazată pe AMICA.
- IC aplicat la date de tip “stream”

# Arbore de decizie



# Cum classifica arborii de decizie

(**Vreme** = soare, **Temperatura** = cald,  
**Umiditate** = mare, **Vint** = puternic)

Orice arbore de decizie este reprezentat de o disjunctie de conjunctii:

$$\begin{aligned} & ((\textbf{Vreme} = \text{soare} \wedge (\textbf{Umiditate} = \text{normala})) \\ & \vee (\textbf{Vreme} = \text{acoperit}) \\ & \vee ((\textbf{Vreme} = \text{ploaie} \wedge (\textbf{Vint} = \text{slab})) \end{aligned}$$

# Entropia lui Shannon

$X : \begin{pmatrix} a_1 & \cdots & a_n \\ p_1 & \cdots & p_n \end{pmatrix}$ , where  $p_1 + \cdots + p_n = 1$ .

Entropia lui  $X$  este

$$\mathcal{H}(X) = p_1 \log_2 \frac{1}{p_1} + \cdots + p_n \log_2 \frac{1}{p_n}.$$


Daca  $\pi = \{B_1, \dots, B_n\}$  este o partitie a multimii  $A$  atunci entropia lui  $\pi$  este:

$$\mathcal{H}(\pi) = - \sum_{i=1}^n \frac{|B_i|}{|A|} \log_2 \frac{|B_i|}{|A|}.$$

# Urma unei partitii

Fie  $\pi = \{B_1, \dots, B_n\}$  a partitie a multimii  $A$  si  $C \subseteq A$ .

Urma partitiei  $\pi$  pe  $C$  este  $\pi_C = \{B_i \cap C | B_i \cap C \neq \emptyset\}$



# Entropia Conditională a Partitiilor

$$\begin{array}{lcl} \text{Fie} & \pi = & \{B_1, \dots, B_n\} \\ & \sigma = & \{C_1, \dots, C_m\} \end{array}$$

două partitii alese multimii  $A$ . The **entropia conditională** a lui  $\pi$  prin  $\sigma$  este:

$$\mathcal{H}(\pi|\sigma) = \sum_{j=1}^m \frac{|C_j|}{|C|} \mathcal{H}(\pi_{C_j})$$

**Cistigul** lui  $\pi$  relativ la  $\sigma$  este:

$$\text{Gain}(\pi, \sigma) = \mathcal{H}(\pi) - \mathcal{H}(\pi|\sigma)$$

# Partitii si Arbori de Decisie

Alegera atributului de separare (splitting attribute) intr-un arbore de decizie se face in (ID3, sau C5.1 - Quinlan) folosind **cistigul informational**:

Fie  $K$  este atributul care defineste clasa, atunci alegera atributului de separare  $A$  se face maximizind

$$\text{Gain}(\pi_K, \pi_A) = \mathcal{H}(\pi_K) - \mathcal{H}(\pi_K | \pi_A)$$

(Quinlan's ID3 or C4.5,...)

# Zile favorabile pt. tenis

Zi	Vreme	Temp.	Umid.	Vint	Tenis	
z1	soare	cald	rid	slab	nu	
z2	soare	cald	rid	tare	nu	
z3	acoperit	cald	rid	slab	da	
z4	ploaie	mod	rid	slab	da	
z5	ploaie	rece	nor	slab	da	$\mathcal{H}(\pi_{tenis}) =$
z6	ploaie	rece	nor	tare	nu	$-\frac{5}{14} \log \frac{5}{14}$
z7	acoperit	rece	nor	tare	da	$-\frac{9}{14} \log \frac{9}{14}$
z8	soare	mod	rid	slab	nu	
z9	soare	rece	nor	slab	da	$= 0.940$
z10	ploaie	mod	nor	slab	da	
z11	soare	mod	nor	tare	da	
z12	acoperit	mod	rid	tare	da	
z13	acoperit	cald	nor	slab	da	
z14	ploaie	mod	rid	tare	nu	

# Continuarea Exemplului

Pentru vreme:

$$C_{soare} = \{z1, z2, z8, z9, z11\}$$

$$C_{acoperit} = \{z3, z7, z12, z13\}$$

$$C_{ploaie} = \{z4, z5, z6, z10, z14\}$$

Urmele partitiei  $\pi_{tenis}$ :

$$\pi_{tenis_{C_{soare}}} = \{\{z1, z2, z8\}, \{z9, z11\}\}$$

$$\pi_{tenis_{C_{acoperit}}} = \{\{z3, z7, z12, z13\}\}$$

$$\pi_{tenis_{C_{ploaie}}} = \{\{z6, z14\}, \{z4, z5, z10\}\}$$

Următoarele partitie de  $\pi_{tenis}$ :

$$\begin{aligned}\pi_{tenis_{C_{soare}}} &= \{\{z1, z2, z8\}, \{z9, z11\}\} \\ \pi_{tenis_{C_{acoperit}}} &= \{\{z3, z7, z12, z13\}\} \\ \pi_{tenis_{C_{ploaie}}} &= \{\{z6, z14\}, \{z4, z5, z10\}\}\end{aligned}$$

$$\begin{aligned}\mathcal{H}(\pi_{tenis_{C_{soare}}}) &= -\frac{3}{5} \log \frac{3}{5} - \frac{2}{5} \log \frac{2}{5} = 1.116 \\ \mathcal{H}(\pi_{tenis_{C_{acoperit}}}) &= -\frac{4}{4} \log \frac{4}{4} = 0 \\ \mathcal{H}(\pi_{tenis_{C_{ploaie}}}) &= -\frac{2}{5} \log \frac{2}{5} - \frac{3}{5} \log \frac{3}{5} = 1.116\end{aligned}$$

# Calcule Similară

$$\text{Gain}(\pi_{tenis}, \pi_{vreme}) = 0.247$$

$$\text{Gain}(\pi_{tenis}, \pi_{umiditate}) = 0.151$$

$$\text{Gain}(\pi_{tenis}, \pi_{vint}) = 0.048$$

$$\text{Gain}(\pi_{tenis}, \pi_{vreme}) = 0.029$$

Atributul de scindare: **vreme**

# Probleme generate de criteriul de cistig

- Alegera atributului de scindare este pur locala. Arborele care rezulta nu este optimal in mod necesar.
- Arborii care rezulta pot avea multe virfuri terminale, ceea ce provoaca o fragmentare excesiva a datelor.

# Metrici si arbori de decizie

López de Mántaras introduce o distanță bazată pe entropia Shannon.

$$d(\pi, \sigma) = \mathcal{H}(\pi|\sigma) + \mathcal{H}(\sigma|\pi).$$

Un nou criteriu de alegere a attributului de scindare:

$$A = \arg \min d(\pi_K, \pi_A)$$

# Suma a două partitii

Daca  $M \cap P = \emptyset$  si

$$\begin{aligned}\pi &= \{B_1, \dots, B_m\} \in \text{PART}(M), \\ \sigma &= \{C_1, \dots, C_n\} \in \text{PART}(P),\end{aligned}$$

definim  $\pi + \sigma$  ca partitia multimii  $M \cup P$ :

$$\pi + \sigma = \{B_1, \dots, B_m, C_1, \dots, C_n\}.$$

Daca  $M, P, Q$  sunt disjuncte si

$\pi \in \text{PART}(M)$ ,  $\sigma \in \text{PART}(P)$ ,  $\tau \in \text{PART}(Q)$ , atunci

$$\pi + (\sigma + \tau) = (\pi + \sigma) + \tau.$$

# Axiomatizarea Entropiei Generalizate

Fie  $\Phi : \mathbb{R}_{\geq 0}^2 \longrightarrow \mathbb{R}_{\geq 0}$  o functie continua, unde  $\Phi(x, y) = \Phi(y, x)$ ,  $\Phi(x, 0) = x$  pentru  $x, y \in \mathbb{R}_{\geq 0}$  si  $\beta \in \mathbb{R}$ ,  $\beta > 0$ .

Sistemul de axiome  $(\Phi, \beta)$  pentru  $\mathcal{H} : \text{PART}(A) \longrightarrow \mathbb{R}_{\geq 0}$  consta din

**(P1)** Daca  $\pi, \pi' \in \text{PART}(A)$ ,  $\pi \leq \pi'$ , atunci  $\mathcal{H}(\pi') \leq \mathcal{H}(\pi)$ .

**(P2)** Daca  $A, B$  sunt doua multimi finite,  $|A| \leq |B|$ , atunci  $\mathcal{H}(\iota_A) \leq \mathcal{H}(\iota_B)$ .

**(P3)** Pentru  $A, B$ ,  $A \cap B = \emptyset$ ,  $\pi \in \text{PART}(A)$  si  $\sigma \in \text{PART}(B)$  avem:

$$\begin{aligned} & \mathcal{H}(\pi + \sigma) \\ &= \left( \frac{|A|}{|A| + |B|} \right)^\beta \mathcal{H}(\pi) + \left( \frac{|B|}{|A| + |B|} \right)^\beta \mathcal{H}(\sigma) \\ &+ \mathcal{H}(\{A, B\}). \end{aligned}$$

**(P4)** Daca  $\pi \in \text{PART}(A)$  si  $\sigma \in \text{PART}(B)$ , atunci

$$\mathcal{H}(\pi \times \sigma) = \Phi(\mathcal{H}(\pi), \mathcal{H}(\sigma)).$$

- $\beta$  determină o entropie  $\mathcal{H}_\beta$  pînă la un factor constant.  $\beta$  determină și funcția  $\Phi$ .
- Dacă  $\beta \neq 1$  atunci pentru o partition  $\pi = \{A_1, \dots, A_n\} \in \text{PART}(A)$  avem:

$$\mathcal{H}_\beta(\pi) = \frac{k}{\beta - 1} \left( 1 - \sum_{j=1}^n \left( \frac{|A_j|}{|A|} \right)^\beta \right),$$

unde  $k$  este o constantă astfel că  $k(\beta - 1) > 0$ .

- Daca  $\beta \neq 1$  avem  $\Phi(x, y) = x + y - \frac{1}{k}xy$  pentru  $x, y \in \mathbb{R}_{\geq 0}$ .
- Daca  $\beta = 2$  avem indexul Gini:

$$\mathcal{H}_2(\pi) = c \left( 1 - \sum_{j=1}^n \left( \frac{|A_j|}{|A|} \right)^2 \right).$$

- Cazul limita  $\beta \rightarrow 1$  da entropia Shannon, adica

$$\mathcal{H}_1(\pi) = -c \sum_{j=1}^n \frac{|A_j|}{|A|} \log_2 \frac{|A_j|}{|A|}.$$

si  $\Phi(x, y) = x + y$  for  $x, y \in \mathbb{R}_{\geq 0}$ .

*Entropia conditională* data de  $(\Phi, \beta)$ -entropie  $\mathcal{H}$  este  
 $\mathcal{H}_\beta : \text{PART}^2 \longrightarrow \mathbb{R}_{\geq 0}$ :

$$\mathcal{H}_\beta(\pi|\sigma) = \sum_{j=1}^n \left( \frac{|C_j|}{|A|} \right)^\beta \mathcal{H}_\beta(\pi_{C_j}),$$

unde  $\pi, \sigma \in \text{PART}(A)$  și  $\sigma = \{C_1, \dots, C_n\}$ .  
 $\mathcal{H}_\beta(\pi|\omega_A) = \mathcal{H}_\beta(\pi)$ .

Daca  $\pi \in \text{PART}(A)$  avem:

- $\mathcal{H}(\pi) = 0$  daca si numai daca  $\pi = \omega_A$ .
- Daca  $\pi, \sigma \in \text{PART}(A)$  avem  $\mathcal{H}_\beta(\pi|\sigma) = 0$  daca si numai daca  $\sigma \leq \pi$ .

- Fie  $\pi, \sigma, \sigma' \in \text{PART}(A)$ . Daca  $\sigma \leq \sigma'$  atunci  $\mathcal{H}_\beta(\pi|\sigma) \leq \mathcal{H}_\beta(\pi|\sigma')$  for  $\beta > 0$ .
- Fie  $\pi, \sigma \in \text{PART}(A)$  si  $\beta > 0$ . Avem  $\mathcal{H}_\beta(\pi|\sigma) \leq \mathcal{H}_\beta(\pi)$ .
- Daca  $\pi, \pi', \sigma \in \text{PART}(A)$  astfel ca  $\pi \leq \pi'$  atunci  $\mathcal{H}_\beta(\pi|\sigma) \geq \mathcal{H}_\beta(\pi'|\sigma)$ .
- Pentru  $\beta \geq 1$  avem  $\mathcal{H}_\beta(\pi \wedge \sigma) \leq \mathcal{H}_\beta(\pi) + \mathcal{H}_\beta(\sigma)$ .

Daca  $\beta \geq 1$  si  $\pi, \sigma, \tau \in \text{PART}(A)$  avem inegalitatea:

$$\mathcal{H}_\beta(\pi|\sigma) + \mathcal{H}_\beta(\sigma|\tau) \geq \mathcal{H}_\beta(\pi|\tau).$$

Rezultatul nostru generalizeaza rezultatul lui López de Mántaras:

Daca  $\beta \geq 1$  fie  $d_\beta : \text{PART}(A)^2 \longrightarrow \mathbb{R}_{\geq 0}$  definita de  $d_\beta(\pi, \sigma) = \mathcal{H}_\beta(\pi|\sigma) + \mathcal{H}_\beta(\sigma|\pi)$  for  $\pi, \sigma \in \text{PART}(A)$ .  $d_\beta$  este o metrica pe  $\text{PART}(A)$ .




O noua alegere a atributului de scindare:

$$A = \arg \min d(\pi_K, \pi_A)$$


O noua problema: alegerea cea mai buna a parametrului  $\beta$  pentru o multime de date depinde de proprietatile ei statistice.

- Am experimentat cu 33 baze de date din colectia UCI.
- Fiecare experiment a folosit o 5-validere incruisata; media a fost obtinuta pentru 5 experimente.

- Dimensiunea si numarul de virfuri terminale descreste pentru 18 din cele 33 baze de date si creste pentru celelalte 15.
- Cea mai importanta reducere a fost obtinuta pentru primary-tumor, unde numarul total de noduri a fost redus cu 37% pentru  $\beta = 2.5$ , iar numarul de noduri terminale a fost redus cu 38.8% in comparatie cu algoritmul standard (C5.0).



The  $\beta$  factor:






$$\beta = 1 \quad \equiv$$


$$\beta = 1.5 \quad \equiv$$

$$\beta = 2 \quad \equiv$$

$$\beta = 2.5 \quad \equiv$$



The  $\beta$  factor:



$$\beta = 1 \equiv \boxed{\text{---}}$$

$$\beta = 1.5 \equiv \boxed{\text{---}}$$

$$\beta = 2 \equiv \boxed{\text{---}}$$

$$\beta = 2.5 \equiv \boxed{\text{---}}$$

# Unde ne putem informa despre DM?

- Conferinte principale:
  - KDD (USA)
  - PKDD (Europa)
  - PAKDD (Asia si Australia)
  - ICDM (anul acesta la Brighton, UK)
  - ICML
- TKDE (IEEE), Journal of Data Mining
- KD Nuggets
- Internetul (CiteSeer)