Inteligenta Artificiala

Universitatea Politehnica Bucuresti
Anul universitar 2010-2011

Adina Magda Florea

http://turing.cs.pub.ro/ia_10 si
curs.cs.pub.ro

Curs nr. 7

Reprezentarea cunostintelor incerte

- Teoria probabilitatilor
- Retele Bayesiene
- Factori de certitudine

1. Teoria probabilitatilor

1.1 Cunostinte incerte

$\forall p$ simpt(p, Dur_d) $\rightarrow$ factor(p,carie)

$\forall p$ simpt(p, Dur_d) $\rightarrow$ factor(p,carie) $\vee$ factor(p,infl_ging) $\vee \ldots$

- LP

- dificultate (« lene »)

- ignoranta teoretica

- ignoranta practica

- Teoria probabilitatilor ➔ un grad numeric de **incredere** sau **plauzibilitate** a afirmatiilor in [0,1]
- Gradul de adevar (fuzzy logic) ≠ gradul de incredere

1.2 Definitii TP

- ***Probabilitatea unui eveniment incert A*** este masura gradului de incredere sau plauzibilitatea produceri unui eveniment
- Camp de probabilitate, S
- ***Probabilitate neconditionata*** (apriori) - inaintea obtinerii de probe pt o ipoteza / eveniment
- ***Probabilitate conditionata*** (aposteriori) - dupa obtinerea de probe

Exemple

P(Carie) = 0.1

P(Vreme = Soare) = 0.7

P(Vreme = Ploaie) = 0.2   P(Vreme = Nor) = 0.1

Vreme - **variabila aleatoare**

- ***Distributie de probabilitate***

Definitii TP - cont

- ***Probabilitate conditionata*** (aposteriori) - P(A|B)

  P(Carie | Dur_d) = 0.8

  Masura probabilitatii producerii unui eveniment A este o functie $P:S \rightarrow R$ care satisface **axiomele**:

- $0 \leq P(A) \leq 1$
- P(S) = 1   (sau P(adev) = 1 si P(fals) = 0)
- $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$

$P(A \vee \sim A) = P(A)+P(\sim A) - P(fals) = P(adev)$

$\Rightarrow P(\sim A) = 1 - P(A)$

Definitii TP - cont

A si B mutual exclusive ➔ $P(A \vee B) = P(A) + P(B)$

$$P(e_1 \vee e_2 \vee e_3 \vee \ldots e_n) =$$
$$P(e_1) + P(e_2) + P(e_3) + \ldots + P(e_n)$$

e(a) – multimea de evenimente atomice mutual exclusive si exhaustive in care apare **a**

$$\boxed{P(a) = \sum_{e_i \in e(a)} P(e_i)}$$

1.3 Regula produsului

Probabilitatea conditionata de producere a evenimentului A ***in conditiile producerii evenimentului B***

- $\mathbf{P(A|B) = P(A \wedge B) / P(B)}$

$$P(A \wedge B) = P(A|B) * P(B)$$

1.4 Teorema lui Bayes

$P(A|B) = P(A \wedge B) / P(B)$ – regula produsului

$$P(A|B) = P(A \wedge B) / P(B)$$

$$P(B|A) = P(A \wedge B) / P(A)$$

$$\boxed{P(B|A) = P(A|B) * P(B) / P(A)}$$

Teorema lui Bayes

$P(B|A) = P(A|B) * P(B) / P(A)$

- Daca **B si ~B sunt mutual exclusive si exhaustive**, probabilitatea de producere a lui A in conditiile producerii lui B se poate scrie

$$\mathbf{P(A)} = P(A \wedge B) + P(A \wedge \sim B) = \mathbf{P(A|B)*P(B) + P(A|\sim B)*P(\sim B)}$$

$$\boxed{\mathbf{P(B|A) = P(A|B) * P(B) / [P(A|B)*P(B) + P(A|\sim B)*P(\sim B)]}}$$

Teorema lui Bayes

Generalizarea la mai multe ipoteze

B - h, A - e

P(h|e) = P(e | h) * P(h) / [P(e|h)*P(h) +P(e| ~h)*P(~h)]

Daca h_i mutual exclusive si exhaustive

$$\boxed{P(h_i|e) = \frac{P(e|h_i)\cdot P(h_i)}{\sum_{j=1}^{k} P(e|h_j)\cdot P(h_j)}, \ i = 1,k}$$

Teorema lui Bayes

Generalizarea la mai multe ipoteze si evenimente

h_i – evenimente / ipoteze probabile (i=1,k);

$e_1,\ldots,e_n$ - probe

$P(h_i)$

$P(h_i \mid e_1,\ldots,e_n)$

$P(e_1,\ldots,e_n \mid h_i)$

$$P(h_i|e_1,e_2,\ldots,e_n) = \frac{P(e_1,e_2,\ldots,e_n|h_i)\cdot P(h_i)}{\sum_{j=1}^{k} P(e_1,e_2,\ldots,e_n|h_j)\cdot P(h_j)},\ i=1,k$$

Teorema lui Bayes - cont

Daca $e_1,\ldots,e_n$ sunt ipoteze independente atunci

$$P(e|h_j) = P(e_1, e_2, \ldots, e_n|h_j) = P(e_1|h_j) \cdot P(e_2|h_j) \cdot \ldots \cdot P(e_n|h_j),\ j = \overline{1,k}$$

PROSPECTOR

1.5 Inferente din DP si TB

Distributie de probabilitate **P(Carie, Dur_d)**

	Dur_d	~Dur_d
Carie	0.04	0.06
~Carie	0.01	0.89

$P(Carie) = 0.04 + 0.06 = 0.1$

$P(Carie \vee Dur\_d) = 0.04 + 0.01 + 0.06 = 0.11$

$P(Carie|Dur\_d) = P(Carie \wedge Dur\_d) / P(Dur\_d) = 0.04 / 0.05$

Inferente din DP si TB

	Dur_d		~Dur_d	
	Evid	~Evid	Evid	~Evid
Carie	0.108	0.012	0.072	0.008
~Carie	0.016	0.064	0.144	0.576

Distributie de probabilitate **P(Carie, Dur_d, Evid)**

P(Carie) = 0.108 + 0.012 + 0.72 + 0.008 = 0.2
P(Carie ∨ Dur_d) = 0.108 + 0.012 + 0.072 + 0.008 + 0.016 + 0.064 = 0.28

P(Carie, Dur_d, Vreme) – o abela cu 2 x 2 x 3 = 12 intrari
Distributie de probablitate completa

Inferente din DP si TB

	Dur_d		~Dur_d	
	Evid	~Evid	Evid	~Evid
Carie	0.108	0.012	0.072	0.008
~Carie	0.016	0.064	0.144	0.576

P(Carie | Dur_d) = P(Carie $\wedge$ Dur_d) / P(Dur_d)
P(~Carie | Dur_d) = P(~Carie $\wedge$ Dur_d) / P(Dur_d)
α = 1/P(Dur_d) – constanta de normalzare a distributiei

P(Carie | Dur_d) = α **P(Carie $\wedge$ Dur_d)** =
α [P(Carie $\wedge$ Dur_d $\wedge$ Evid) + P(Carie $\wedge$ Dur_d $\wedge$ ~Evid)] =
α [<0.108, 0.16> + <0.012,0.064>] = α <0.12, 0.08> = <0.6, 0.4>
Chiar daca nu cunoastem α, adica P(Dur_d), putem calcula
α = 0.12+0.08

Inferente din DP si TB

Generalizare – procedura generala de inferenta bazata pe DPC
Interogare asupra lui X

X – variabila de interogat (Carie)
E – lista de variabile probe (Dur_d)
e – lista valorilor observate pt aceste variabile E
Y – lista variabilelor neobservate (restul) (Evid)

P(Carie | Dur_d) = $\boldsymbol{\alpha}$ [P(Carie $\wedge$ Dur_d $\wedge$ Evid) + P(Carie $\wedge$ Dur_d $\wedge$ ~Evid)]

Insumarea se face peste toate combinatiile de valori a variab neobs Y

$$\mathbf{P}(X \mid e) = \alpha\, \mathbf{P}(X , e) = \alpha \Sigma_y\, \mathbf{P}(X, e, y)$$

Inferente din DP si TB

$$\mathbf{P}(X \mid e) = \alpha\, \mathbf{P}(X, e) = \alpha \Sigma_y\, \mathbf{P}(X, e, y)$$

Avand DPC ecuatia poate da raspuns la interogari cu variabile discrete

Complex computational

n var Bool – tabela $O(2^n)$

- timp $O(2^n)$

1.6 Independenta conditionala

$P(Dur\_d, Evid, Carie, Nori) =$
$P(Nori|Dur\_d, Evid, Carie) * P(Dur\_d, Evid, carie)$

$P(Nori|Dur\_d, Evid, Carie) = P(Nori)$ – **variabile independente**

$P(A|B) = P(A)$ $\qquad$ $P(B|A) = P(B)$
$P(A \wedge B) = P(A) * P(B)$

$$\mathbf{P}(cauza \mid efect) = \mathbf{P}(efect \mid cauza) * \mathbf{P}(cauza) / \mathbf{P}(efect)$$

$$\mathbf{P}(Y \mid X) = \mathbf{P}(X \mid Y) * \mathbf{P}(Y) / \mathbf{P}(X)$$

$$\mathbf{P}(Y \mid X) = \alpha\, \mathbf{P}(X \mid Y) * \mathbf{P}(Y)$$

$$\mathbf{P}(Y \mid X, e) = \mathbf{P}(X \mid Y, e) * \mathbf{P}(Y|e) / \mathbf{P}(X|e)$$

Independenta conditionala

Dur_d, Evid, Carie – **variabile independente conditional**

Independente in conditiile in care exista Carie

$$\mathbf{P}(\text{Cauza}, \text{Efect}_1, \text{Efect}_2, \ldots) =$$

$$\mathbf{P}(\text{Cauza}) * \Pi_i \, \mathbf{P}(\text{Efect}_i|\text{Cauza})$$

Model Bayesian naiv

1.7 Limitari ale TP

- Cantitate mare de date statistice
- Valoare numerica unica
- Ignoranta = incertitudine
- *Paradoxul lui Hempel*
- $P(h|e)$
- h_1 - toti corbii sunt negrii
- h_2 - orice obiect care nu este negru nu este corb
- e - vaza este verde
- $P(h_2|e)$ h_1 logic echivalent cu h_2 $P(h_1|e)$

2 Retele Bayesiene

- Reprezinta dependente intre variabile aleatoare
- Specificarea distributiei de probabilitate
- Simplifica calculele
- Au asociata o reprezentare grafica convenabila
- DAG care reprezinta relatiile cauzale intre variabile
- Pe baza structurii retelei se pot realiza diverse tipuri de inferente
- Calcule complexe in general dar se pot simplifica pentru structuri particulare

2.1 Structura retelelor Bayesiene

O RB este un DAG in care:

- Nodurile reprezinta variabilele aleatoare
- Legaturile orientate $X \rightarrow Y$: X are o influenta directa asupra lui Y, X=Parinte(X)
- Fiecare nod are asociata o tabela de probabilitati conditionate care cuantifica efectul parintilor asupra nodului, $\mathbf{P(X_i \mid Parinti(X_i))}$

Exemplu

- Vreme, Carie $\rightarrow$ Dur_d, Carie $\rightarrow$ Evid

Structura retelelor Bayesiene - cont

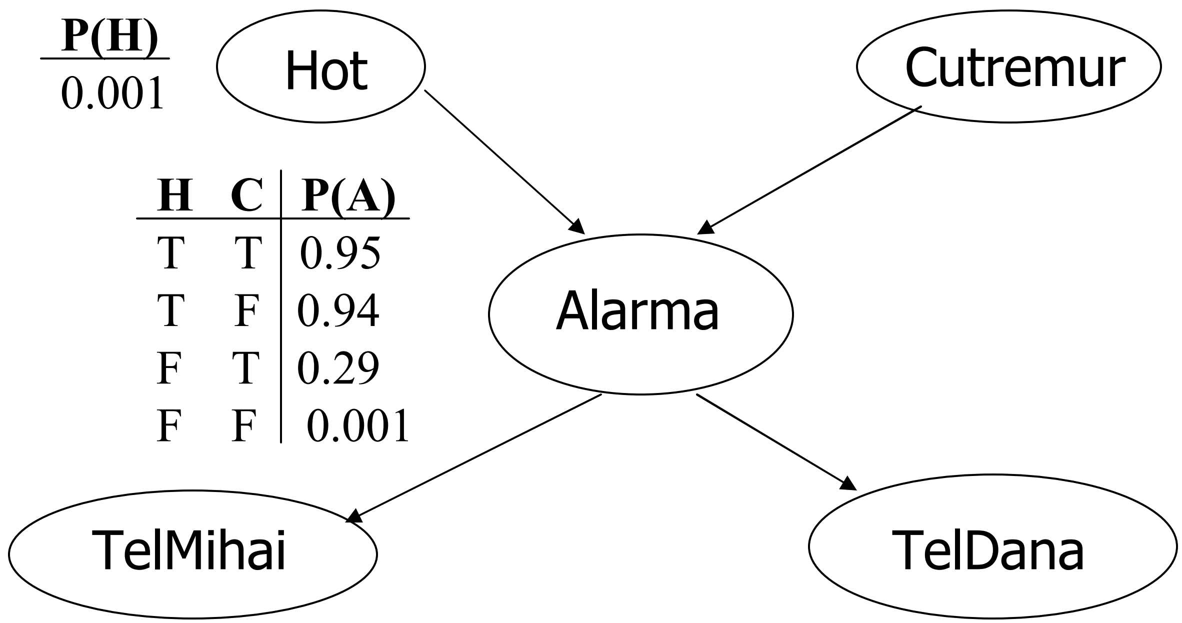

P(H)
0.001

P(C)
0.002

H	C	P(A)
T	T	0.95
T	F	0.94
F	T	0.29
F	F	0.001

A	P(M)
T	0.9
F	0.05

A	P(D)
T	0.7
F	0.01

Tabela de probabilitati conditionate

H	C	P(A | H, C) T	P(A | H, C) F
T	T	0.95	0.05
T	F	0.94	0.06
F	T	0.29	0.71
F	F	0.001	0.999

Structura retelelor Bayesiene

In general X (Cauza) $\rightarrow$ Y(Efect)

- Stabilesc topologia
- Specifica distributia de probabilitati conditionate
- Combinarea topologiei si distributia de probabilitati conditionate este suficienta pentru a specifica (implicit) intreaga DPC
- DPC poate raspunde la interogari
- Si RB la fel, mai eficient

2.2 Semantica retelelor Bayesiene

- Reprezentare a distributiei de probabilitate
- Specificare a independentei conditionale – constructia retelei

- Fiecare valoare din distributia de probabilitate poate fi calculata ca:

$$\mathbf{P(X_1{=}x_1 \wedge \ldots X_n{=}x_n) = P(x_1,\ldots, x_n) = \Pi_{i=1,n}\, P(x_i \mid parinti(x_i))}$$

unde *parinti(x_i)* reprezinat valorile specifice ale variabilelor *Parinti(X_i)*

2.3 Construirea retelei

Cum sa construim o retea a.i. RB/DPC sa fie o buna reprezentare?

Ecuatia $\mathbf{P(x_1,\ldots, x_n) = \Pi_{i=1,n}\ P(x_i \mid parinti(x_i))}$ implica anumite relatii de independenta conditionala care pot ghida construirea retelei

$\mathbf{P(X_1=x_1 \wedge \ldots X_n=x_n) = P(x_1,\ldots, x_n) =}$

$\mathbf{P(x_n \mid x_{n-1},\ldots, x_1) * P(x_{n-1},\ldots, x_1) = \ldots =}$

$\mathbf{P(x_n \mid x_{n-1},\ldots, x_1) * P(x_{n-1} \mid x_{n-2},\ldots, x_1) * \ldots P(x_2|x_1) * P(x_1) =}$

$\mathbf{\Pi_{i=1,n}\ P(x_i \mid x_{i-1},\ldots, x_1)}$ – valabila in general

- DPC daca, pt fiecare variabila X_i din RB

$\mathbf{P(X_i \mid X_{i-1},\ldots, X_1) = P(x_i \mid Parinti(X_i))}$ cu conditia ca

$\mathbf{Parinti(X_i) \subseteq \{ X_{i-1},\ldots, X_1\}}$

Construirea retelei

Pt fiecare variabila X_i din RB

$\mathbf{P(X_i \mid X_{i-1},\ldots, X_1) = P(x_i \mid Parinti(X_i))}$ cu conditia ca

$$\mathbf{Parinti(X_i) \subseteq \{ X_{i-1},\ldots, X_1\}}$$

- **O RB este o reprezentare corecta a domeniului cu conditia ca fiecare nod sa fie independent conditional de predecesori, fiind dati parintii lui**

Construirea retelei

- Conditia poate fi satisfactuta prin etichetarea nodurilor intr-o ordine consitenta cu DAG

- Intuitiv, parintii unui nod X_i trebuie sa fie toate acele noduri
  $X_{i-1},\ldots, X_1$ care influenteaza direct X_i.

Construirea retelei - cont

- Alege o multime de variabile aleatoare relevante care descriu problema
- Alege o ordonare a acestor variabile
- **cat timp** mai sunt variabile **repeta**

  (a) alege o variabila X_i si adauga un nod corespunzator lui X_i

  (b) atribuie Parinti(X_i) $\leftarrow$ un set minim de noduri deja existente in retea a.i. proprietatea de independenta conditionala este satisfacuta

  (c) defineste tabela de probabilitati conditionate pentru X_i

Deoarece fiecare nod este legat numai la noduri anterioare $\rightarrow$ DAG

2.4 Inferente probabilistice

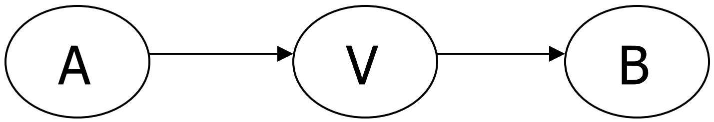

$$P(A \wedge V \wedge B) = P(A) * P(V|A) * P(B|V)$$

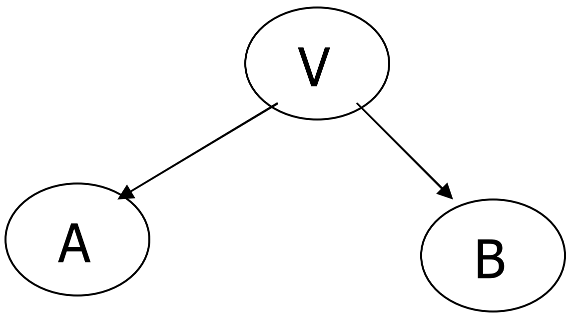

$$P(A \wedge V \wedge B) = P(V) * P(A|V) * P(B|V)$$

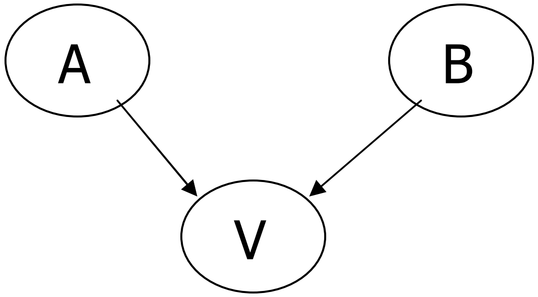

$$P(A \wedge V \wedge B) = P(A) * P(B) * P(V|A,B)$$

Inferente probabilistice

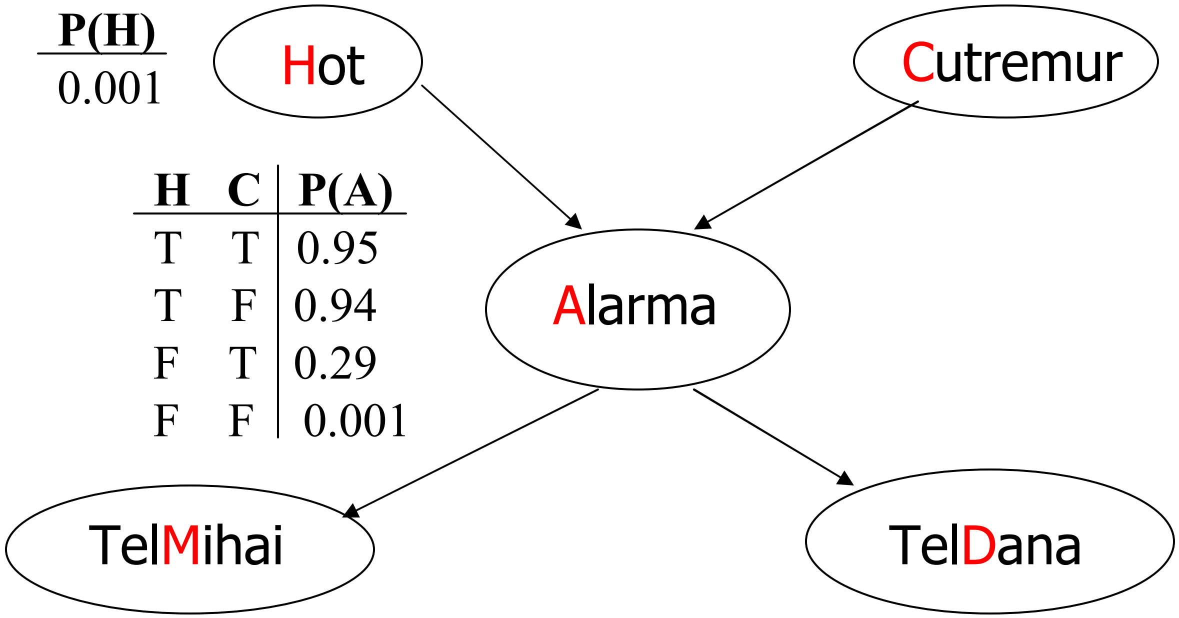

P(H)
0.001

P(C)
0.002

H	C	P(A)
T	T	0.95
T	F	0.94
F	T	0.29
F	F	0.001

A	P(M)
T	0.9
F	0.05

A	P(D)
T	0.7
F	0.01

$P(M \wedge D \wedge A \wedge \sim H \wedge \sim C) =$

$P(M|A) * P(D|A) * P(A|\sim H \wedge \sim C) * P(\sim H) \wedge P(\sim C) =$

$0.9 * 0.7 * 0.001 * 0.999 * 0.998 = 0.00062$

Inferente probabilistice

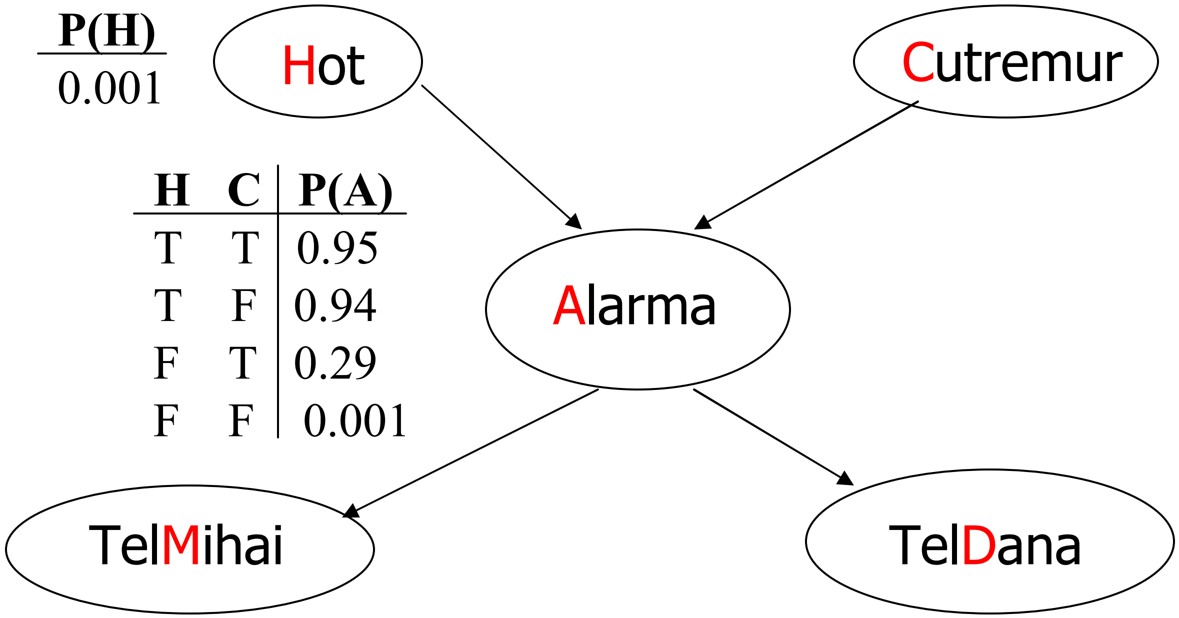

P(H)
0.001

P(C)
0.002

H	C	P(A)
T	T	0.95
T	F	0.94
F	T	0.29
F	F	0.001

A	P(M)
T	0.9
F	0.05

A	P(D)
T	0.7
F	0.01

$$P(A|H) = P(A|H,C) * P(C|H) + P(A|H,\sim C) * P(\sim C|H)$$
$$= P(A|H,C) * P(C) + P(A|H,\sim C) * P(\sim C)$$
$$= 0.95 * 0.002 + 0.94 * 0.998 = 0.94002$$

2.5 Inferenta prin enumerare

1 var de interogare

X – variabila de interogat (Carie)
E – lista de variabile probe (Dur_d)
e – lista valorilor observate pt aceste variabile E
Y – lista variabilelor neobservate (restul) (Evid)

$$\mathbf{P}(X \mid e) = \alpha\, \mathbf{P}(X , e) = \alpha \Sigma y\, \mathbf{P}(X, e, y)$$

$P(H|M,D) = \alpha\, P(H,M,D) =$

$$\alpha\, \Sigma_C\, \Sigma_A\, P(H)P(C)P(A|H,C)P(M|A)P(D|A)$$

n var bool -> $O(n2^n)$

2.5 Inferenta prin enumerare

$$P(H|M,D) = \alpha\, \Sigma_C\, \Sigma_A\, P(H)P(C)P(A|H,C)P(M|A)P(D|A)$$

$$P(H|M,D) = \alpha\, P(H)\, \Sigma_C\, P(C)\, \Sigma_A\, P(A|H,C)P(M|A)P(D|A)$$

$$= \alpha <0.00059224, 0.0014919> =_{aprox} <0.284, 0.716>$$

Complexitate spatiu – $O(n)$

Complexitate timp $O(2^n)$

$P(M|A)P(D|A)$ si $P(M|\sim A)P(D|\sim A)$ se calculeaza de 2 ori

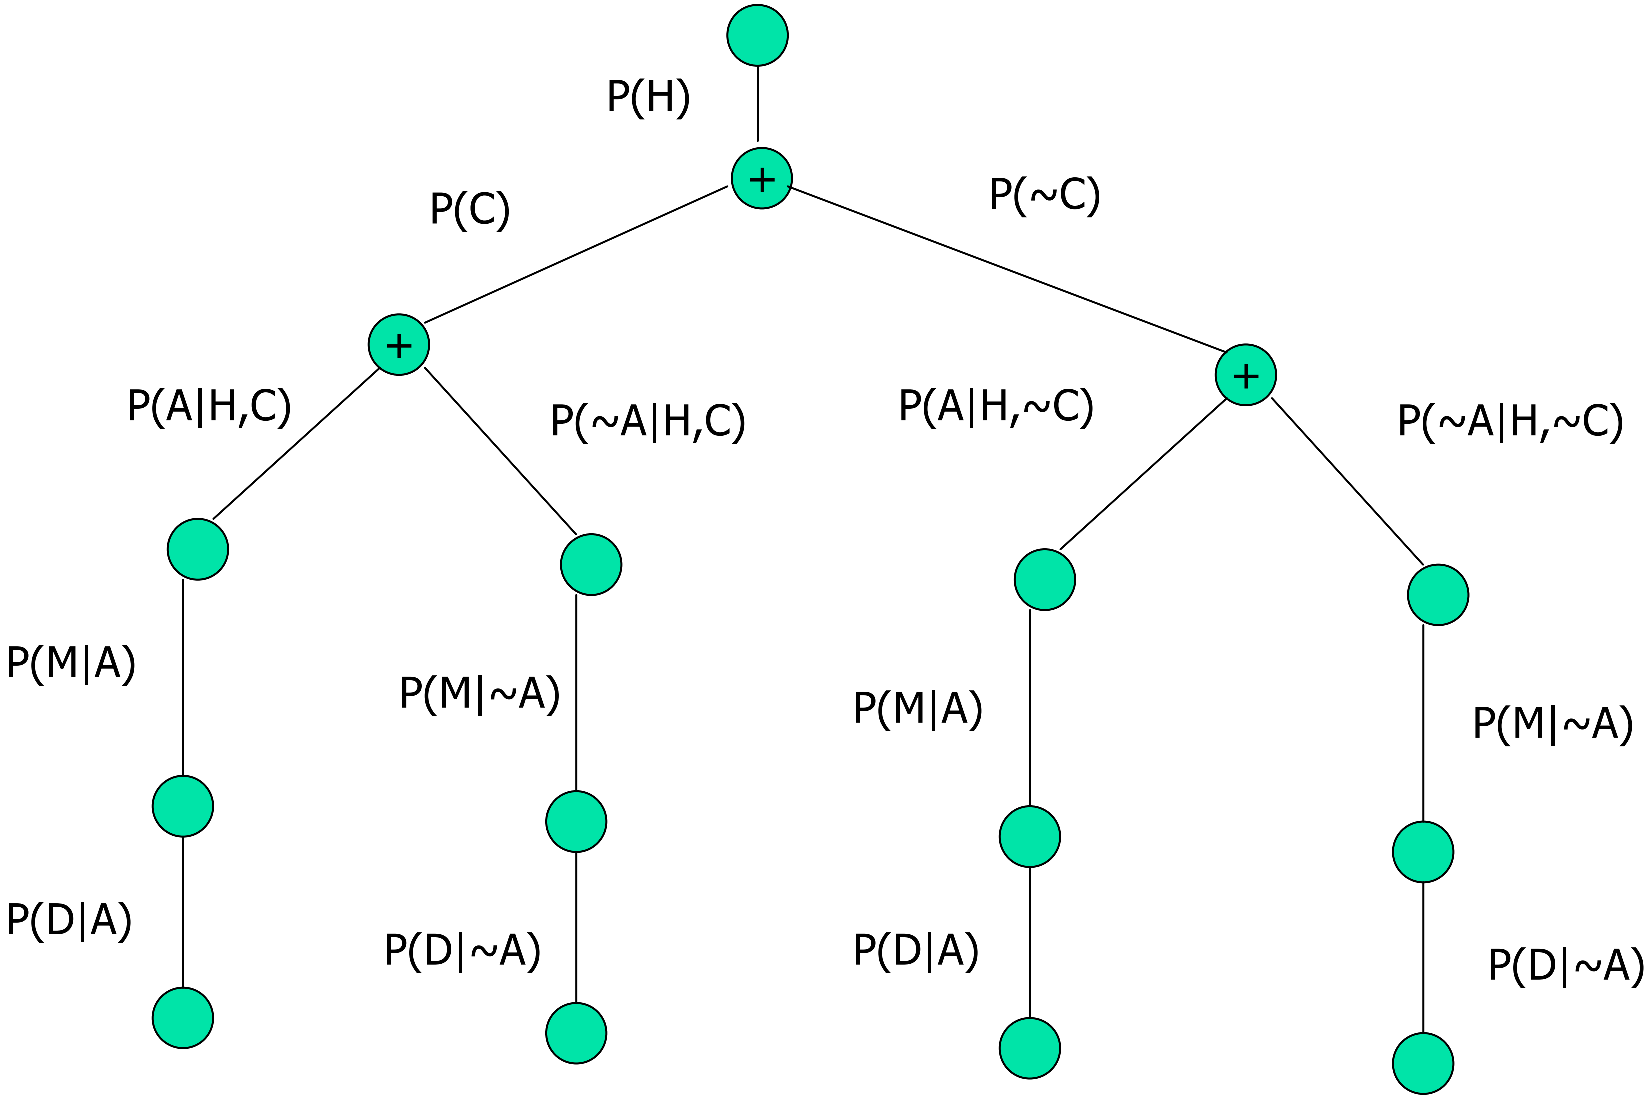
P(H)
P(C)
P(~C)
P(A|H,C)
P(~A|H,C)
P(A|H,~C)
P(~A|H,~C)
P(M|A)
P(M|~A)
P(M|A)
P(M|~A)
P(D|A)
P(D|~A)
P(D|A)
P(D|~A)

Inferenta prin enumerare - algoritm

algoritm **Enumerare(X,e,rb)** **intoarce** distributie X

X – var de interogare

e – valorori observate pt E

rb – RB cu var $\{X\} \cup E \cup Y$

1. $Q(X) \leftarrow$ o distributie X, initial vida
2. **pentru** fiecare valoare x_i a lui X **repeta**

   $Q(x_i) \leftarrow$ **EnumToate**(rb.Vars, e_{xi})

   unde e_{xi} este e extins cu $X=x_i$
3. **intoarce** Normalizare(Q(x))

sfarsit

Inferenta prin enumerare - algoritm

algoritm EnumToate(Vars,e) intoarce un numar real

1. daca Vars = [] atunci intoarce 1.0
2. Y $\leftarrow$ first(Vars)
3. **daca** Y are valoare y in e

   atunci intoarce P(y|parinti(Y)) * **EnumToate**(Rest(Vars),e)

   altfel intoarce

   Σ_y P(y|parinti(Y)) * **EnumToate**(Rest(Vars),e_y)

   unde e_y este e extins cu Y=y

sfarsit

2.5 Forme de inferenta

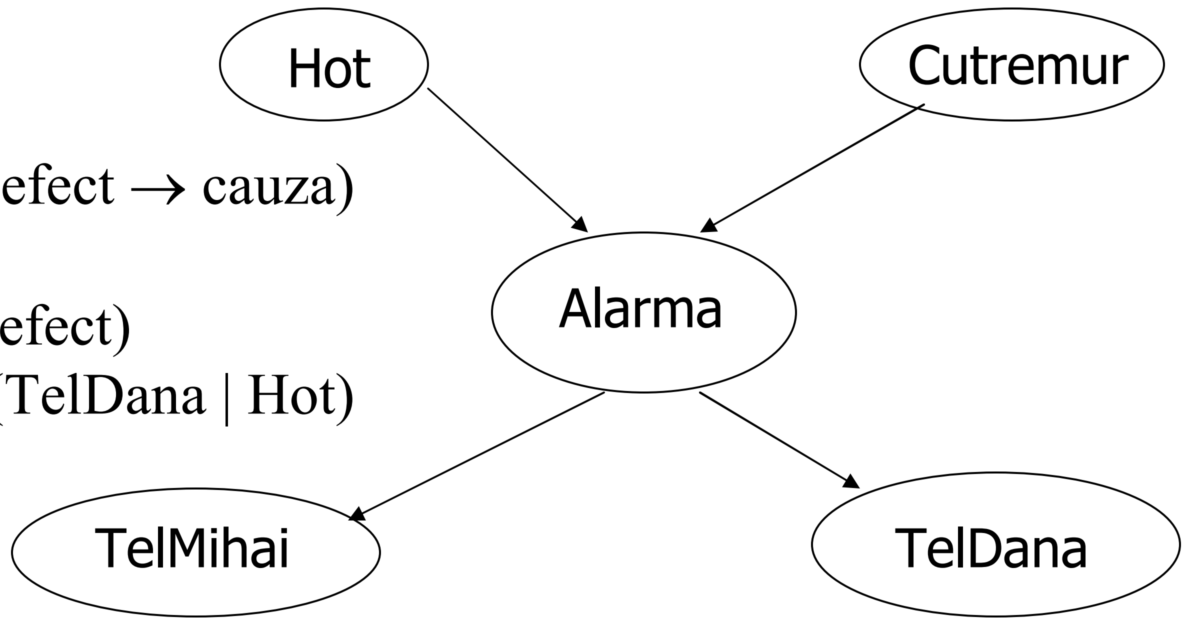

Inferente de diagnosticare (efect → cauza)

P(Hot | TelMihai)

Inferente cauzale (cauza → efect)

P(TelMihai |Hot), P(TelDana | Hot)

Inferente intercauzale (intre cauza si efecte comune)

P(Hot | Alarma ∧Cutremur)

Inferente mixte

P(Alarma | TelMihai ∧ ~Cutremur) → diag + cauzal

P(Hot | TelMihai ∧ ~Cutremur) → diag + intercauzal

3. Factori de certitudine

- Modelul MYCIN - euristic
- Factori de certitudine / Coeficienti de incredere (CF)
- Model euristic al reprezentarii cunostintelor incerte
- In sistemul MYCIN se folosesc doua functii probabilistice pentru a modela increderea si neincrederea intr-o ipoteza:
  - *functia de masura a increderii*, notata MB
  - *functia de masura a neincrederii*, notata MD
- MB[h,e] - reprezinta masura cresterii increderii in ipoteza h pe baza probei e
- MD[h,e] - reprezinta masura cresterii neincrederii in ipoteza h pe baza probei e

3.1 Functii de incredere

$$MB[h,e] = \begin{cases} 1 & \text{daca } P(h) = 1 \\ \dfrac{\max(P(h|e), P(h)) - P(h)}{\max(0,1) - P(h)} & \text{in caz contrar} \end{cases}$$

$$MD[h,e] = \begin{cases} 1 & \text{daca } P(h) = 0 \\ \dfrac{\min(P(h|e), P(h)) - P(h)}{\min(0,1) - P(h)} & \text{in caz contrar} \end{cases}$$

- *Factorul* (coeficientul) *de certitudine*

$$CF[h,e] = MB[h,e] - MD[h,e]$$

Functii de incredere - caracteristici

- *Domeniul de valori*

$$0 \le MB[h,e] \le 1 \qquad 0 \le MD[h,e] \le 1 \qquad -1 \le CF[h,e] \le 1$$

- *Ipotezele sustinute de probe sunt independente*
- Daca se stie ca h este o ipoteza sigura, i.e. P(h|e) = 1, atunci

$$MB[h,e] = \frac{1 - P(h)}{1 - P(h)} = 1 \qquad MD[h,e] = 0 \qquad CF[h,e] = 1$$

- Daca se stie ca negatia lui h este sigura, i.e. , P(h|e) = 0 atunci

$$MB[h,e] = 0 \qquad MD[h,e] = \frac{0 - P(h)}{0 - P(h)} = 1 \qquad CF[h,e] = -1$$

MYCIN - Exemplu de utilizare CF

- Regula in sistemul MYCIN

  daca tipul organismului este gram-pozitiv, si
  morfologia organismului este coc, si
  conformatia cresterii organismului este lant
  atunci exista o incredere puternica (0.7)
  ca identitatea organismului este streptococ.

- Exemple de fapte in sistemul MYCIN :

  (identitate organism-1 pseudomonas 0.8)
  (identitate organism-2 e.coli 0.15)
  (loc cultura-2 git 1.0)

3.2 Functii de combinare a incertitudinii

(1) Probe adunate incremental

- Aceeasi valoare de atribut, h, este obtinuta pe doua cai de deductie distincte, cu doua perechi diferite de valori pentru CF, CF[h,s1] si CF[h,s2]
- Cele doua cai de deductie distincte, corespunzatoare probelor sau ipotezelor s1 si s2 pot fi ramuri diferite ale arborelui de cautare generat prin aplicarea regulilor sau probe indicate explicit sistemului de medic.
- **CF[h, s1&s2] = CF[h,s1] + CF[h,s2] – CF[h,s1]*CF[h,s2]**
- (identitate organism-1 pseudomonas 0.8)
- (identitate organism-1 pseudomonas 0.7)

Functii de combinare a incertitudinii

(2) Conjunctie de ipoteze

- Se aplica pentru calculul CF asociat unei premise de regula care contine mai multe conditii

daca A = a1 si B = b1 **atunci** …

ML: (A a1 s1 cf1) (B b1 s2 cf2)

- **CF[h1&h2, s] = min(CF[h1,s], CF[h2,s])**

- Se generalizeaza pt mai multe conditii

Functii de combinare a incertitudinii

(3) Combinarea increderii

- O valoare incerta este dedusa pe baza unei reguli care are drept conditie de intrare alte valori incerte (deduse eventual prin aplicarea altor reguli).
- Permite calculul factorului de certitudine asociat valorii deduse pe baza aplicarii unei reguli care refera valoarea in concluzie, tinind cont de CF-ul asociat premisei regulii.
- CF[s,e] - increderea intr-o ipoteza s pe baza unor probe anterioare e
- CF[h,s] - CF in h in cazul in care s este sigura
- CF'[h,s] = CF[h,s] * CF [s,e]

Functii de combinare a incertitudinii

(3) Combinarea increderii – cont

daca A = a1 si B = b1 **atunci** C = c1 0.7

ML: (A a1 0.9)   (B b1 0.6)

CF(premisa) = min(0.9, 0.6) = 0.6

CF (concluzie) = CF(premisa) * CF(regula) = 0.6 * 0.7

ML: (C c1 0.42)

3.3 Limitari ale modelului CF

- Modelul coeficientilor de certitudine din MYCIN presupune ca ipotezele sustinute de probe sunt independente.
- Un exemplu care arata ce se intimpla in cazul in care aceasta conditie este violata.

Fie urmatoarele fapte:

A: Aspersorul a functionat noaptea trecuta.

U: Iarba este uda dimineata.

P: Noaptea trecuta a plouat.

Limitari ale modelului CF - cont

A: Aspersorul a functionat noaptea trecuta.

U: Iarba este uda dimineata.

P: Noaptea trecuta a plouat.

si urmatoarele doua reguli care leaga intre ele aceste fapte:

R1: **daca** aspersorul a functionat noaptea trecuta

atunci exista o incredere puternica (0.9) ca iarba este uda dimineata

R2: **daca** iarba este uda dimineata

atunci exista o incredere puternica (0.8) ca noaptea trecuta a plouat

Limitari ale modelului CF - cont

- CF[U,A] = 0.9
- deci proba aspersor sustine iarba uda cu 0.9

- CF[P,U] = 0.8
- deci iarba uda sustine ploaie cu 0.8

- CF[P,A] = 0.8 * 0.9 = 0.72
- deci aspersorul sustine ploaia cu 0.72
- **Solutii**