

Bizonytalanságkezelés

Bizonytalanság forrásai

– Hiányzó adat mellett történő következtetés

- Mi lehet a páciens betegsége?

– Bizonytalan adatra épülő következtetés

objektív

Pontatlan műszerek pontatlan leolvasása: $80\text{ °C} \pm 2\text{ °C}$

szubjektív

– Következmény bizonytalansága:

- Mennyi az esélye, hogy egy sárga bőrű páciens hepatitiszes, ha ismerjük a *sárga bőrű hepatitiszesek / sárga bőrű betegek* arányát?

– Elmosódott jelentésű állítások:

- A nadrág erősen szennyezett

szubjektív

objektív

– Ellentmondó adatokból vagy ellentmondó következtetésekből származtatott következmény

Bizonytalanságkezelés alapkérdései

- Hogyan **reprezentáljuk** a bizonytalanságot?
 - Az ismeretekhez numerikus vagy szimbolikus értéket rendelünk
- Hogyan **kombináljuk** a bizonytalanságot?
 - A logikai műveletek mentén komponált összetett ismeret bizonytalanságát a komponensek bizonytalanságából számoljuk.
- Hogyan **következtessünk** bizonytalan információból?
 - Mennyire (milyen mértékben) bizonytalan az a következmény, amelyre bizonytalan ismeretekből indulva bizonytalan következtetési szabállyal következtetünk?

1. Klasszikus valószínűség számítás

- A központi kérdés az, hogy egy bizonytalan $B \rightarrow A$ szabály alapján milyen bizonyossággal állítható az, hogy ha B igaz, akkor A is?
- Ugyanez másképpen is megfogalmazható: mi az A esemény bekövetkezésének valószínűsége, amikor a B esemény bekövetkezik.

Feltételes valószínűség:

$$p(A \mid B) = \frac{p(A \wedge B)}{p(B)} \quad \text{ha } p(B) > 0$$

Állítás = esemény

- A továbbiakban az állítások mindig egy esemény bekövetkezéséről szólnak majd, így azokat (diszkrét) valószínűségi változók segítségével fogalmazhatjuk meg.

- $X_i = x_i$ esemény esetén

X_i a diszkrét valószínűségi változó,
 x_i a változó értéke.

- Speciális jelölés:

- Amikor az X_i értéke csak *igaz* vagy *hamis* lehet, akkor használjuk

$X_i = igaz$ helyett X_i ,

$X_i = hamis$ helyett $\neg X_i$

Megjegyzés

- Egy adott problémakör (eseményrendszer) összes feltételes valószínűségét az események együttes valószínűségi eloszlásának ismeretében könnyen kiszámolhatjuk.
- De a gyakorlatban az együttes valószínűségi eloszlás
 - többnyire nem ismert explicit módon
 - túl sok apriori adat tárolását igényelné (a memória igény exponenciálisan nő az elemi események számával növelésével)
- Ezért egy feltételes valószínűség közvetlen kiszámolásához különféle elkerülő technikákat alkalmazunk.

Bayes tétel különféle alakjai

a) **Klasszikus**

$$p(B | A) = \frac{p(A | B) \cdot p(B)}{p(A)}$$

b) **Háttértudás (E) mellett**

$$p(B | A, E) = \frac{p(A | B, E) \cdot p(B | E)}{p(A | E)}$$

c) **Általánosított** (B_1, \dots, B_n teljes és független)

$$p(B_i | A) = \frac{p(A | B_i) \cdot p(B_i)}{\sum_k p(A | B_k) \cdot p(B_k)}$$

Szuvas-e egy fog, ha lyukas és fáj?

Russel-Norvig: AI

□ $p(\text{szuvas} \mid \text{lyukas}, \text{fáj}) = ?$

apriori ismeretek:

- $p(\text{szuvas}) = 0.65$
- $p(\text{fáj} \mid \text{szuvas}) = 0.5$
- $p(\text{fáj} \mid \neg \text{szuvas}) = 0.1$
- $p(\text{lyukas} \mid \text{szuvas}) = 0.95$
- $p(\text{lyukas} \mid \neg \text{szuvas}) = 0.01$

$$p(\text{szuvas} \mid \text{lyukas}, \text{fáj}) = ?$$

Példa folytatása (Bayes tételek alkalmazása)

- Ha a **klasszikus Bayes tételt** alkalmazzuk, akkor hamar elakadunk, mert csak a $p(\text{sz})$ -t ismerjük.

$$p(\text{sz} \mid \text{ly}, f) = \frac{p(f, \text{ly} \mid \text{sz}) \cdot p(\text{sz})}{p(f, \text{ly})}$$

- Keressünk más utat! (**Bayes-i frissítés módszere**)
 - Először a **háttér tudás melletti Bayes tételt** alkalmazzuk a *fáj* eseményre, mint háttértényre,
 - És az ehhez szükséges $p(\text{sz} \mid f)$ -re a **közönséges Bayes tételt** írjuk fel.

$$p(\text{sz} \mid \text{ly}, f) = \frac{p(\text{ly} \mid \text{sz}, f) \cdot p(\text{sz} \mid f)}{p(\text{ly} \mid f)} = \frac{p(\text{ly} \mid f, \text{sz}) \cdot p(f \mid \text{sz}) \cdot p(\text{sz})}{p(\text{ly} \mid f) \cdot p(f)}$$

Feltételes függetlenség


- Közöséges függetlenség: $p(A,B) = p(A) \cdot p(B)$
- Az A és a B események feltételesen függetlenek az E eseményre nézve (nincs közöttük közvetlen függőségi kapcsolat, csak az E -n keresztül), ha

$$p(A,B | E) = p(A | E) \cdot p(B | E)$$


- Az A és a B feltételesen függetlenek az E -re nézve, akkor $p(A | B,E) = p(A | E)$ illetve $p(B | A,E) = p(B | E)$

Feltételes függetlenség esetei


- Az A és a B feltételesen függetlenek az E -re nézve:
 - A is, B is függ az E -től, de más kapcsolat nincs köztük



- A -tól függ az E , és E -től függ a B , de más kapcsolat nincs köztük




- B -től függ az E , és E -től függ a A , de más kapcsolat nincs köztük



$$p(\text{szuvas} \mid \text{lyukas}, \text{fáj}) = ?$$

Példa folytatása (feltételes függetlenség kihasználása)

- A lyukas fogat és a fogfájást a szuvasodás kapcsolja össze, mindkettő következménye a szuvasodásnak, ettől eltekintve függetlenek: Az *ly* **feltételesen független** az *f*-től az *sz*-re nézve, azaz $p(\text{ly} \mid f, \text{sz}) = p(\text{ly} \mid \text{sz})$



- Hozzáolvasva ezt az eddigiekhez:

$$p(\text{sz} \mid \text{ly}, f) = \frac{p(\text{ly} \mid \text{sz}) \cdot p(f \mid \text{sz}) \cdot p(\text{sz})}{p(\text{ly} \mid f) \cdot p(f)}$$

- Már csak a nevezőbeli valószínűségeket nem ismerjük. Az apriori tudásunk alapján a számlálóbeli valószínűségeket akkor is ismernénk, ha ott az *sz* helyére $\neg \text{sz}$ -t írnánk. Ilyenkor alkalmazhatjuk a **normalizálás** technikáját.

Normalizálás

- Amikor egy eseménynek és az ellentetjének a valószínűségét ugyanazon, de ismeretlen együtthatóval számoljuk ki más valószínűségekből:

$$- p(A) = \alpha \cdot u \quad \text{és} \quad p(\neg A) = \alpha \cdot v$$

- akkor az együttható könnyen meghatározható:

$$1 = p(A) + p(\neg A) = \alpha \cdot [u + v]$$

$$\alpha = 1 / [u + v]$$

$$p(\text{szuvas} \mid \text{lyukas, fáj}) = ?$$

Példa folytatása (normalizálás)

- ugyanaz sz -re és $\neg sz$ -re:

$$p(sz \mid ly, f) = \frac{p(ly \mid sz) \cdot p(f \mid sz) \cdot p(sz)}{p(ly \mid f) \cdot p(f)} = \alpha \cdot p(ly \mid sz) \cdot p(f \mid sz) \cdot p(sz)$$

$$p(\neg sz \mid ly, f) = \frac{p(ly \mid \neg sz) \cdot p(f \mid \neg sz) \cdot p(\neg sz)}{p(ly \mid f) \cdot p(f)} = \alpha \cdot p(ly \mid \neg sz) \cdot p(f \mid \neg sz) \cdot p(\neg sz)$$

- összeg:

$$1 = \alpha \cdot [p(ly \mid sz) \cdot p(f \mid sz) \cdot p(sz) + p(ly \mid \neg sz) \cdot p(f \mid \neg sz) \cdot p(\neg sz)]$$

- együttható:

$$\alpha = 1 / [p(ly \mid sz) \cdot p(f \mid sz) \cdot p(sz) + p(ly \mid \neg sz) \cdot p(f \mid \neg sz) \cdot p(\neg sz)]$$

$$p(\text{szuvas} \mid \text{lyukas}, \text{fáj}) = ?$$

Példa befejezése

apriori ismeretek:

$$p(\text{ly} \mid \text{sz}) = 0.7$$

$$p(f \mid \text{sz}) = 0.5$$

$$p(\text{sz}) = 0.65$$

$$p(\text{ly} \mid \neg \text{sz}) = 0.01$$

$$p(f \mid \neg \text{sz}) = 0.1$$

Bayes-i frissítés és a feltételes függetlenség felhasználása miatt:

$$p(\text{sz} \mid \text{ly}, f) = \alpha \cdot p(\text{ly} \mid \text{sz}) \cdot p(f \mid \text{sz}) \cdot p(\text{sz}) = \alpha \cdot 0.7 \cdot 0.5 \cdot 0.65$$

normalizálás:

$$\begin{aligned} \alpha &= 1 / [p(\text{ly} \mid \text{sz}) \cdot p(f \mid \text{sz}) \cdot p(\text{sz}) + p(\text{ly} \mid \neg \text{sz}) \cdot p(f \mid \neg \text{sz}) \cdot p(\neg \text{sz})] \\ &= 1 / [0.7 \cdot 0.5 \cdot 0.65 + 0.01 \cdot 0.1 \cdot 0.35] = 4.38885 \end{aligned}$$

eredmény:

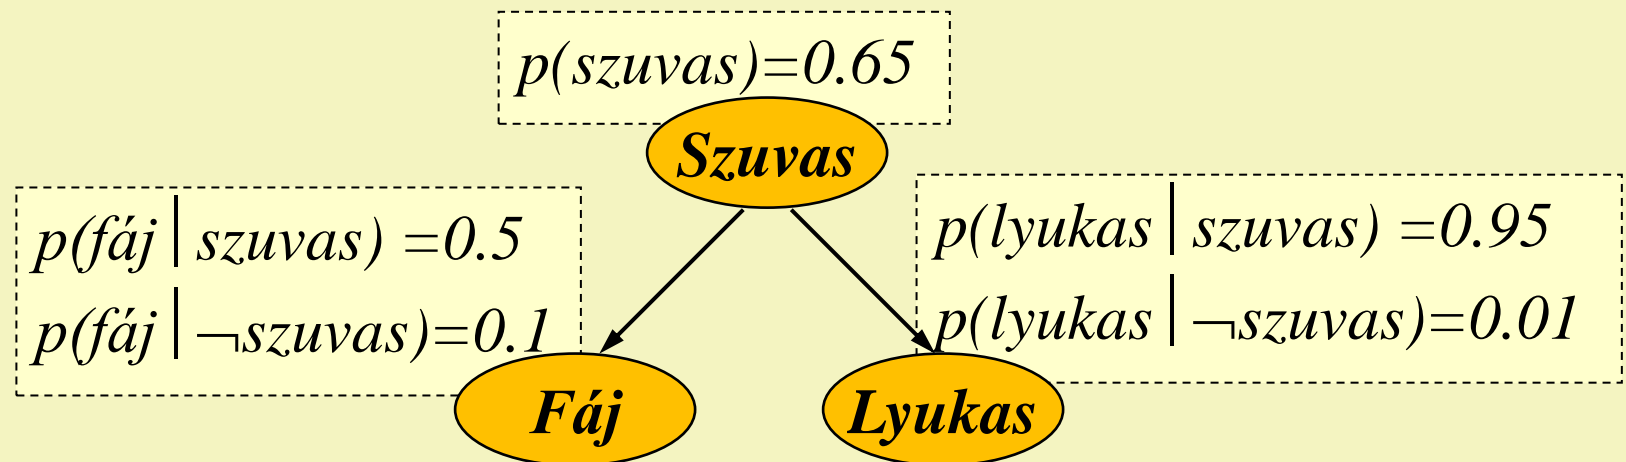
$$p(\text{sz} \mid \text{ly}, f) = 4.38885 \cdot 0.2275 = 0.99846$$

Bayes modell értékelése

- ❑ Az apriori valószínűségekhez nehéz hozzájutni.
- ❑ Még a bevetett trükkök ellenére is sok apriori valószínűséget kell beszerezni és tárolni hozzá.
- ❑ A következtetés túl ötletszerűnek tűnik, nehéz algoritmizálni.
- ❑ Matematikailag jól megalapozott, de igen számításigényes, és magyarázatadásra nem alkalmas.
- ❑ A modell új ismeretekkel nehezen bővíthető. Nem elég ugyanis egy új esemény és a vele kapcsolatos feltételes események valószínűségeit megadni, ilyenkor a korábbi valószínűségi értékeket is felül kell bírálni.

2. Bayes (valószínűségi) hálók

- Az előző példa megoldásánál alkalmazott módszert általánosíthatnánk, ha a minimálisan szükséges apriori valószínűségeket úgy tárolnánk (**tömör reprezentáció**), hogy a **feltételes függetlenségek felismerése** egyértelmű és automatizálható legyen.




Reprezentáció Bayes hálóval

- Tekintsük a tárgyprobléma valószínűségi változóit.
- Feleltessük meg a változókat egy **körmentes irányított gráf** csúcsainak.
- Ábrázoljuk az irányított élekkel a változók közötti közvetlen **okozati összefüggéseket** (ez által implicit módon rögzítjük a feltételes függetlenségeket is).
- Adjuk meg az csúcsok **feltételes valószínűségi tábláit** (FVT):
$$p(X_i=x_i \mid \text{szülő}(X_i)=x_{i1}, \dots, x_{ik})$$
ahol a $\text{szülő}(X_i)$ az X_i változó csúcsának szülőcsúcsaihoz rendelt X_{i1}, \dots, X_{ik} változók együttesét jelöli.

Feltételes függetlenség felismerése Bayes hálóban

- Legyenek A , B és E összetett (több csúcs) események.
- Az A és B feltételesen független az E -re nézve, ha minden A és B -beli csúcs közti irányítatlan útvonalra az alábbi 4 eset valamelyike teljesül:



Bayes háló kifejező ereje

- Az együttes valószínűségi eloszlás (a lánc-szabály alapján)

$$\begin{aligned} p(X_1=x_1, \dots, X_n=x_n) &= \\ &= p(X_n=x_n \mid X_1=x_1, \dots, X_{n-1}=x_{n-1}) \cdot p(X_1=x_1, \dots, X_{n-1}=x_{n-1}) = \\ &= \dots = \prod_{i=1 \dots n} p(X_i=x_i \mid X_1=x_1, \dots, X_{i-1}=x_{i-1}) \end{aligned}$$

- Sorszámozzuk meg úgy a változókat, hogy ha $i > j$, akkor X_i -ből ne vezessen irányított út X_j -be: ekkor $\forall i: \text{szülő}(X_i) \subseteq \{X_1, \dots, X_{i-1}\}$, és ekkor a feltételes függetlenség miatt

$$p(X_i=x_i \mid X_1=x_1, \dots, X_{i-1}=x_{i-1}) = p(X_i \mid \text{szülő}(X_i)=x_{i1}, \dots, x_{ik})$$

- Az adott tárgykör együttes valószínűségi eloszlása tehát a Bayes háló FVT-iből közvetlenül megkapható.

$$p(X_1=x_1, \dots, X_n=x_n) = \prod_{i=1 \dots n} p(X_i=x_i \mid \text{szülő}(X_i)=x_{i1}, \dots, x_{ik})$$

Bayes hálók tervezése

- Határozzuk meg a tárgytartományt leíró változók halmazát, majd meghatározott sorrendben dolgozzuk fel őket:
 1. Válasszunk ki olyat, amely kizárólag a már háléhoz csatolt változóktól függ, és új csúcsként vegyük fel azt a hálóba
 2. A hálóbeli változóknak vegyük azt a minimális halmazát, amelyek közvetlenül hatnak az új változóra. Rajzoljuk be ezeket a függőségeket reprezentáló éleket.
 3. Töltsük ki az új csúcs FVT-jét.
 4. GOTO 1.

*A szomszédunk telefonált, hogy
szól a betörés-riasztónk a lakásunkban.
Betörtek volna hozzánk? Russel-Norvig: AI*

Betörés

$$p(B) = 0.001$$

Riasztás

$$p(R|B) = 0.95$$

$$p(R|\neg B) = 0.001$$

Szomszéd

$$p(Sz|R) = 0.9$$

$$p(Sz|\neg R) = 0.05$$

$$p(B|Sz) = p(Sz|B) \cdot p(B) / p(Sz) \quad \text{Bayes tétel}$$

$$= \alpha \cdot p(Sz|B) \cdot p(B) \quad \text{normalizálás}$$

$$= \alpha \cdot [p(Sz,R|B) + p(Sz,\neg R|B)] \cdot p(B) \quad \text{telj fgl rsz}$$

$$= \alpha \cdot [p(Sz|R,B) \cdot p(R|B) + \quad \text{lánc szabály}$$

$$p(Sz|\neg R,B) \cdot p(\neg R|B)] \cdot p(B)$$

$$= \alpha \cdot [p(Sz|R) \cdot p(R|B) + \quad \text{felt. fgl.}$$

$$p(Sz|\neg R) \cdot p(\neg R|B)] \cdot p(B)$$

$$= \alpha \cdot 0.0008575$$

$$p(\neg B|Sz) = \alpha \cdot 0.0507991$$

$$\alpha = 19.3585$$

normalizálás vége

$$p(B|Sz) = 0.0166$$

Következtetés Bayes hálóokban

- ❑ Célja egy feltételes valószínűség meghatározása a Bayes módszerre alapuló számítással (Bayes tételek, normalizálás, felbontás teljes fgl. eseményrendszerre, lánc-szabály, feltételes fgl.)
- ❑ Egy feltételes valószínűség kiszámolására egy (rekurzív) algoritmus készíthető, amelynek számításigénye erősen függ a háló bonyolultságától.
- ❑ Egyszeresen kötött hálókra (**fa-gráfokra**), ahol az irányítást figyelmen kívül hagyva két csúcs között nincsenek alternatív irányítatlan útvonalak, van lineáris futási idejű algoritmus.
- ❑ Többszörösen kötött hálók esetén különféle redukáló módszereket alkalmazhatunk.

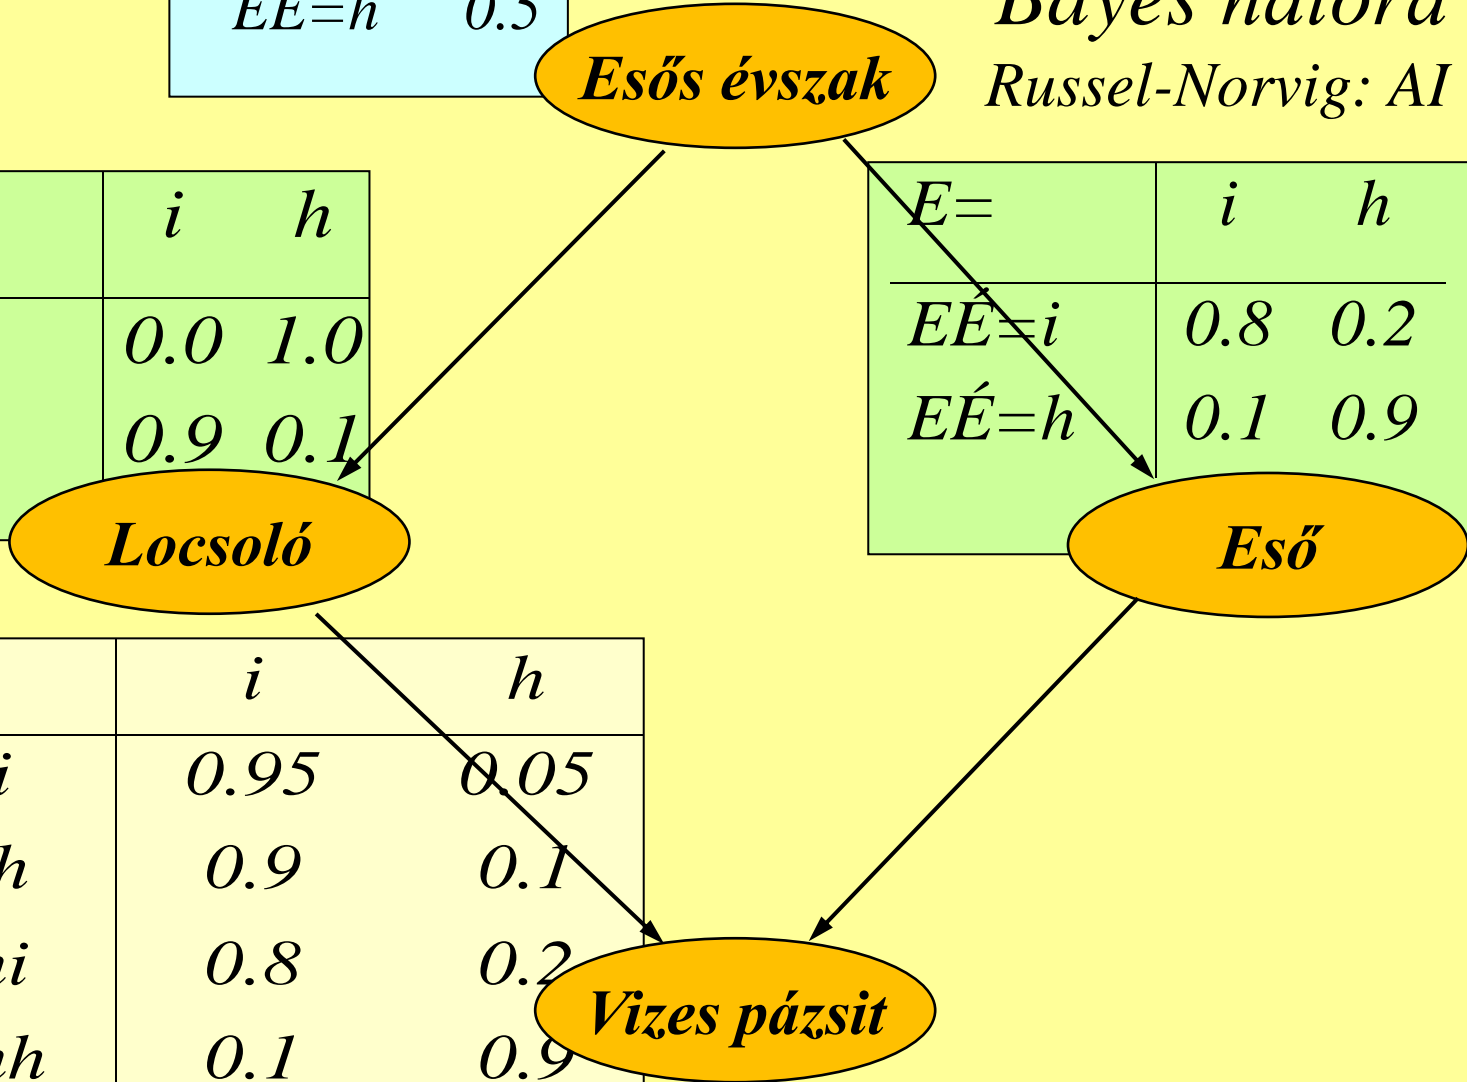
*Példa kétszeresen kötött
Bayes hálóra
Russel-Norvig: AI*

$E\acute{E}=i$	0.5
$E\acute{E}=h$	0.5

$L=$	i	h
$E\acute{E}=i$	0.0	1.0
$E\acute{E}=h$	0.9	0.1

$E=$	i	h
$E\acute{E}=i$	0.8	0.2
$E\acute{E}=h$	0.1	0.9


$VP=$	i	h
$L+E=ii$	0.95	0.05
$L+E=ih$	0.9	0.1
$L+E=hi$	0.8	0.2
$L+E=hh$	0.1	0.9



Következtetés többszörösen kötött hálókbán

- **Összevonásos eljárások**
 - Változók (csúcsok) összevonásával fa-gráfot kapunk, amelyben meg kell határozni az összevont csúcsok FVT-it.
- **Vágóhalmaz feltételezésen alapuló eljárások**
 - Változók (csúcsok) elhagyásával annyi azonos szerkezetű fa-gráfot kapunk, ahányféleképpen az elhagyott változók értékét rögzíthetjük. Egy-egy fa-gráf súlya az a valószínűség, amely mellett az elhagyott változók a fa-gráfban rögzített értékeiket felveszik. A fa-gráfok FVT-it újra kell számolni. A válasz az egyes (esetleg csak a valószínűbb) fa-gráfokból kiszámolt eredmények súlyozott átlaga lesz.
- **Sztocasztikus szimulációs eljárások**
 - A háló valószínűségi értékeket figyelembe véve **példákat generálunk**. A válasz a jó példának az összes példához vett relatív gyakorisága.

a) Összevonás



$E\acute{E}=i$	0.5
$E\acute{E}=h$	0.5

Esős évszak

$L=$	i	h
$E\acute{E}=i$	0.0	1.0
$E\acute{E}=h$	0.9	0.1

$L+E=$	ii	ih	hi	hh
$E\acute{E}=i$	0	0	0.8	0.2
$E\acute{E}=h$	0.09	0.81	0.01	0.09


Locsoló+Eső

$E=$	i	h
$E\acute{E}=i$	0.8	0.2
$E\acute{E}=h$	0.1	0.9

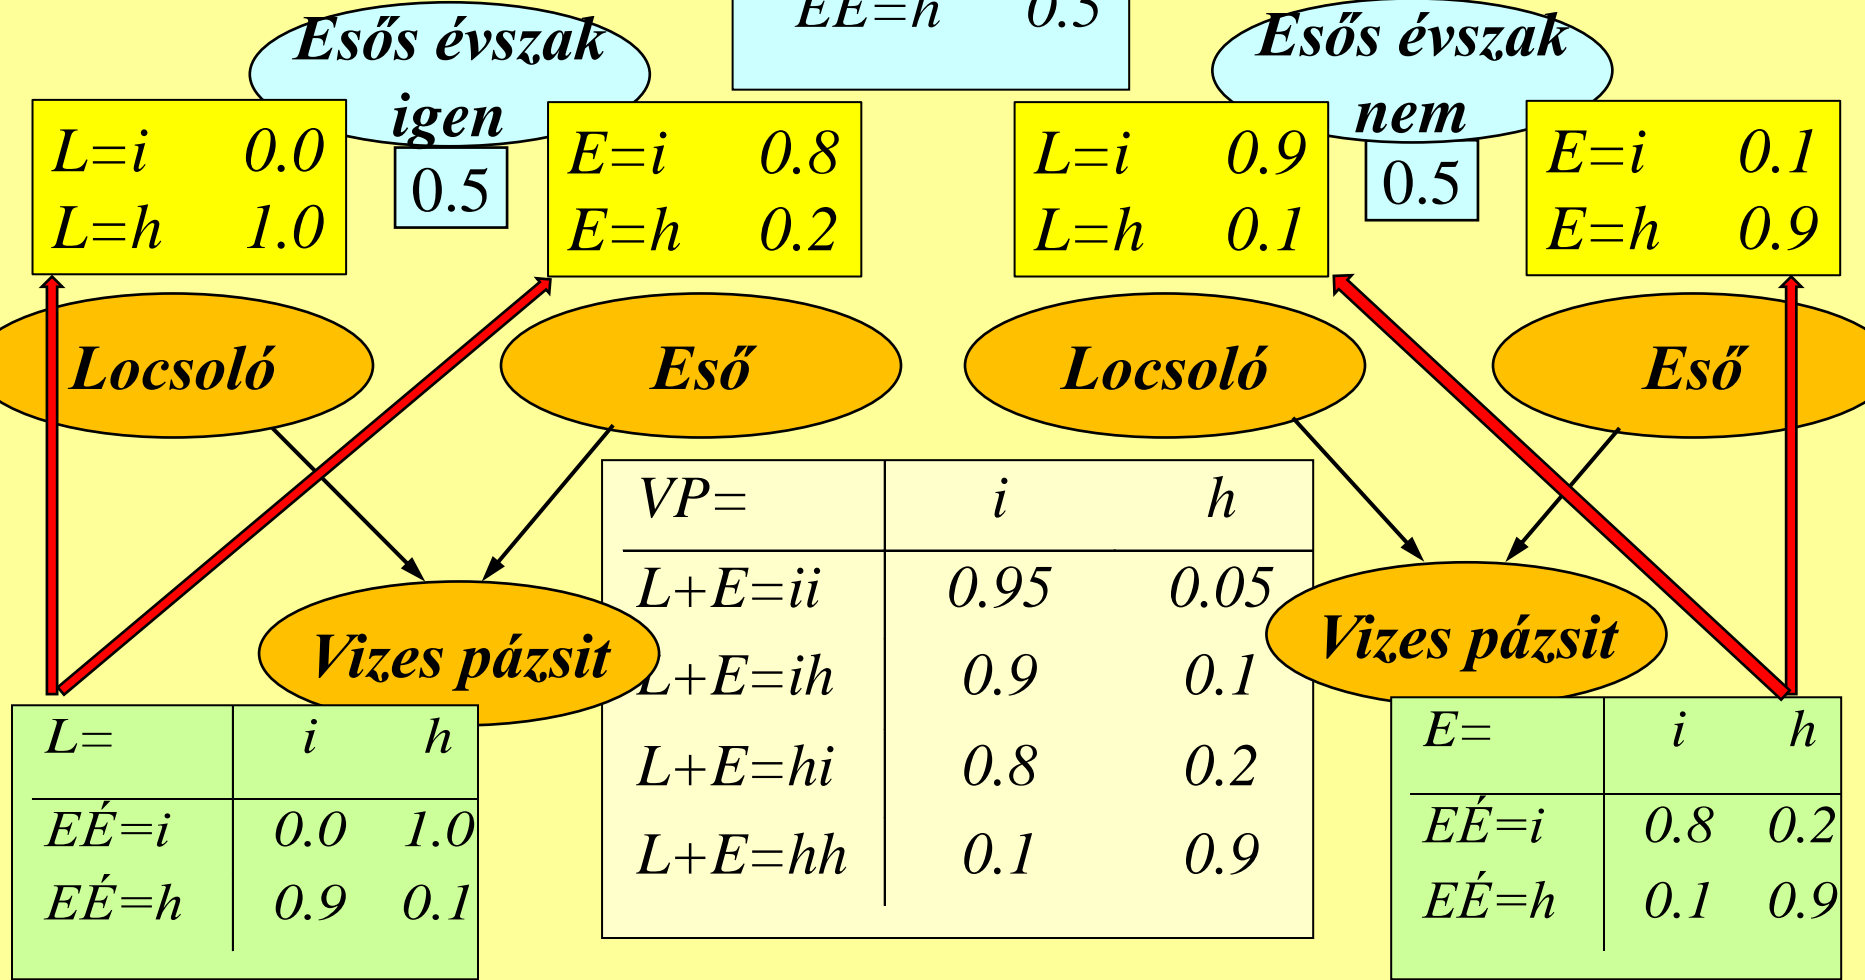
$VP=$	i	h
$L+E=ii$	0.95	0.05
$L+E=ih$	0.9	0.1
$L+E=hi$	0.8	0.2
$L+E=hh$	0.1	0.9

Vizes pázsit

b) Vágóhalmaz feltételezés



$E\acute{E}=i$	0.5
$E\acute{E}=h$	0.5



$L=i$	0.0
$L=h$	1.0

igen
0.5

$E=i$	0.8
$E=h$	0.2

$L=i$	0.9
$L=h$	0.1

nem
0.5

$E=i$	0.1
$E=h$	0.9

$VP=$	i	h
$L+E=ii$	0.95	0.05
$L+E=ih$	0.9	0.1
$L+E=hi$	0.8	0.2
$L+E=hh$	0.1	0.9

$L=$	i	h
$E\acute{E}=i$	0.0	1.0
$E\acute{E}=h$	0.9	0.1

$E=$	i	h
$E\acute{E}=i$	0.8	0.2
$E\acute{E}=h$	0.1	0.9


Adott pontosságú vágóhalmaz feltételezés

- ❑ Nem szükséges az összes fa-gráfra kiszámolni a keresett feltételes valószínűséget.
- ❑ Sokszor elég csak a legvalószínűbb hálókra súlyozott átlagot számolni, mert már ez is jól közelítheti a pontos választ.
 - A számolási hiba a ki nem értékelt hálók valószínűségeinek összege.

c) Sztochasztikus szimuláció

$$p(A | B) = \frac{p(A,B)}{p(B)} = \frac{\text{Jó hasznos példák száma}}{\text{Összes hasznos példa száma}}$$

- A példa hasznos, ha a feltételt (B) teljesíti
- Annak érdekében, hogy csak hasznos példát generáljunk, a feltételt (B) alkotó tényváltozók értékét rögzítjük, de az így generált példát azzal a valószínűséggel súlyozzuk, amely mellett ezek a tényváltozók a számukra kijelölt értékeket felveszik. A relatív gyakoriságot a példák így súlyozott darabszáma alapján számítjuk.



Egy hasznos példa előállítására a $p(\text{Vizes pázsit} \mid \text{Eső})$ számára

- $E\bar{E} = \text{Random}(0.5)$ mert $p(E\bar{E}) = 0.5$

 - TF: $E\bar{E} = \text{hamis}$.
- $L = \text{Random}(0.9)$ mert $p(L \mid \neg E\bar{E}) = 0.9$

 - TF: $L = \text{igaz}$.
- E tényváltozó, értéke igaz, és $p(E \mid \neg E\bar{E}) = 0.2$

 - Ezért $E = \text{igaz} (0.2)$

Ez garantálja a példa hasznosságát

Ez a példa súlya
- $VP = \text{Random}(0.95)$ mert $p(VP \mid E, L) = 0.95$

 - TF: $VP = \text{igaz}$.

Ez tehát egy jó hasznos példa

Bayes hálók tanulása

- Adott háló-struktúrában az **FVT tanulása** példákból nyert relatív gyakorisági értékek számolásával valósítható meg.
 - Probléma: ha a példák hiányosak, azaz nem ismerjük, hogy egy példában bizonyos változó milyen értéket vesz fel.
- A **háló szerkezetének tanulása** során metrikát definiálunk a feladat és az azt leíró háló „távolságára” és ez alapján keressük a legjobban illeszkedő struktúrát.

Bayes hálók értékelése

- ❑ Kevesebb a priori valószínűséget kell benne tárolni ahhoz képest, ha az együttes valószínűségi eloszlásfüggvényt akarnánk ábrázolni.
- ❑ Egyszerűen bővíthető anélkül, hogy eddigi valószínűségeket újra kellene gondolni.
- ❑ A következtetés felhasználható magyarázatadásra.
- ❑ Matematikailag jól megalapozott, de – az erőfeszítéseink ellenére is – igen számításigényes.

3. Heurisztikus technikák

□ „Betörés-riasztó-szomszéd” probléma:

– szabályok:

ha a szomszéd hallani véli a riasztót akkor szól a riasztónk

$$Sz \rightarrow R \quad (0.9)$$

ha szól a riasztónk akkor betörtek hozzánk

$$R \rightarrow B \quad (0.95)$$

– tény: *a szomszéd telefonál, hogy hallja a riasztót*

$$Sz$$

□ Betörtek-e hozzánk?

– $Sz, Sz \rightarrow R \Rightarrow R ; R, R \rightarrow B \Rightarrow B$

– Új következtetési elv: $T(p), T \rightarrow K(q) \Rightarrow K(p \cdot q)$

– $Sz(1) \Rightarrow R(0.9) \Rightarrow B(0.855)$

Ismert heurisztikus technológiák

- ❑ MYCIN bizonytalanság kezelési technikája
- ❑ Dempster-Shafer elmélet
- ❑ Fuzzy következtetés