




Budapesti Műszaki és Gazdaságtudományi Egyetem  
Mérésstechnika és Információs rendszerek Tanszék



**Mesterséges Intelligencia - MI**

**Valószínűségi hálók**

Előadó:


Hullám Gábor

Előadás anyaga:

Dobrowiecki Tadeusz

# Valószínűségi háló (Bayes-háló) → egy gráf

1. Csomópontok: valószínűségi változók egy halmaza
2. Csomópontok között: irányított élek halmaza:  
Az Y csomópontot az X csomóponttal összekötő nyíl →  
az *Y-nak közvetlen befolyása van az X-re*
3. Minden csomópont:  
feltételes valószínűségi tábla →  
szülők hatása a csomópontra  $P(X | \text{Szülők}(X))$



4. A gráf nem tartalmaz irányított kört (= **irányított, körmentes gráf = DAG**).

**Valószínűségi változó = egy állítás a problémáról**

**Pl. X = HMG szint magas (két érték: I/N), vagy**

**X = HMG szint (több érték: Magas / Közepes / Alacsony)**

# Példa

Otthonunkban egy új **riasztót** szereltünk fel. Ez megbízhatóan észleli a **betöréseket**, de kisebb **földrengés** esetén is jelez.

Két szomszédunk, **János** és **Mária**, megígérték, hogy **felhívnak** a munkahelyünkön, ha meghallják a riasztónkat.

János mindig felhív, ha szól a riasztó, de néha összekeveri a telefoncsörgést a riasztó csengésével és ekkor is telefonál.

Mária viszont, mivel szereti hangosan hallgatni a zenét, néha meg sem hallja a riasztót.

Mi tehát a hívások bekövetkezése vagy hiánya alapján szeretnénk megbecsülni a betörés valószínűségét.


(Bináris) változók (tények):

- Betörés** (megtörtént): Igen/ Nem
- Földrengés** (megtörtént): Igen/ Nem
- Riasztás** (megszólalt): Igen/ Nem
- János telefonál**(t-e): Igen/ Nem
- Mária telefonál**(t-e): Igen/ Nem

# Háló topológiája = egy absztrakt tudásbázis

sok esetben érvényes marad, mivel **általános ok-okozati** folyamatokat ír le az adott problémakörben.

A betöréses háló esetén a topológia azt mutatja, hogy a betörés és a földrengés közvetlenül hat a riasztóra, befolyásolja megszólalásának valószínűségét, ellenben János vagy Mária hívásának bekövetkezése csak magán a riasztón múlik – azaz a háló tartalmazza azt a feltevést, hogy ők közvetlenül nem vesznek észre sem a betöréseket, sem a földrengéseket.



# Feltételes valószínűségi tábla – FVT

minden egyes csomópontra.

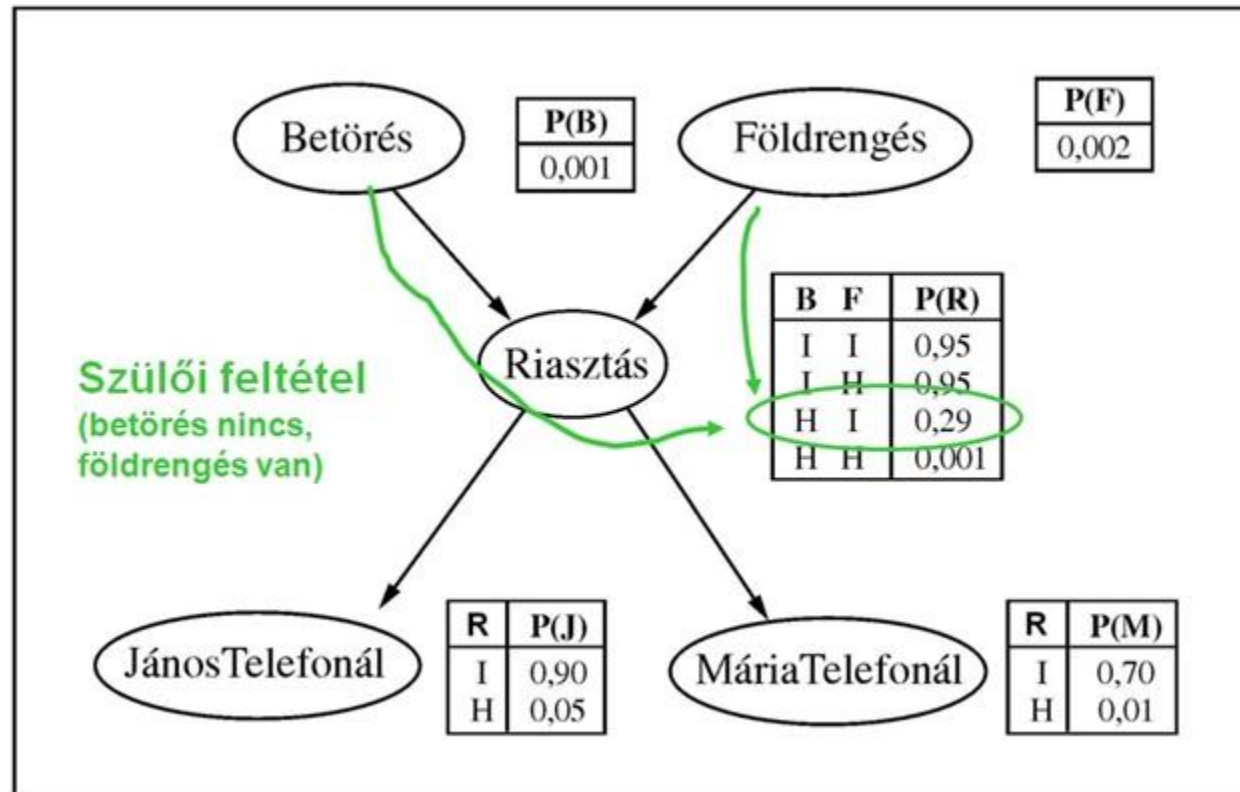
Egy sor a táblázatban az egyes csomóponti értékek feltételes valószínűsége az adott sorhoz tartozó **szülői feltétel** esetén.

**Szülői feltétel:** a szülő csomópontok értékeinek egy lehetséges kombinációja (**egyfajta elemi esemény a szülők között**).

Általánosabban, ha a változó **bináris**, és ha  $n$  **bináris** szülője van:

$2^n - 1$  valószínűség adható meg a feladat alapján.

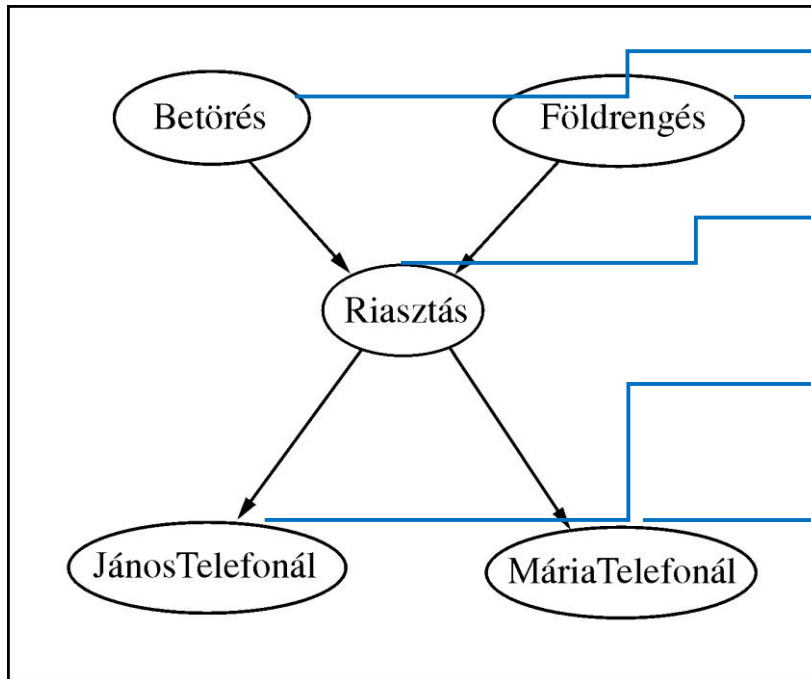
Szülő nélküli csomópont – a változó egyes értékeinek a priori valószínűségei (ha bináris, akkor csak egy).



## Együttes eloszlás:

5 változó

=  $2^5 - 1 = 31$  db valószínűség



## Bayes háló:

2 x 1 db a priori

+

1 x 4 db szülői feltétel

+

2 x 2 db szülői feltétel

= 2 + 4 + 4 = 10 db

Elég-e?

Általános eset:

Mi van, pl. ha


5 db szülő csomópont bináris értékű

2 db szülő csomópont 3-as értékű

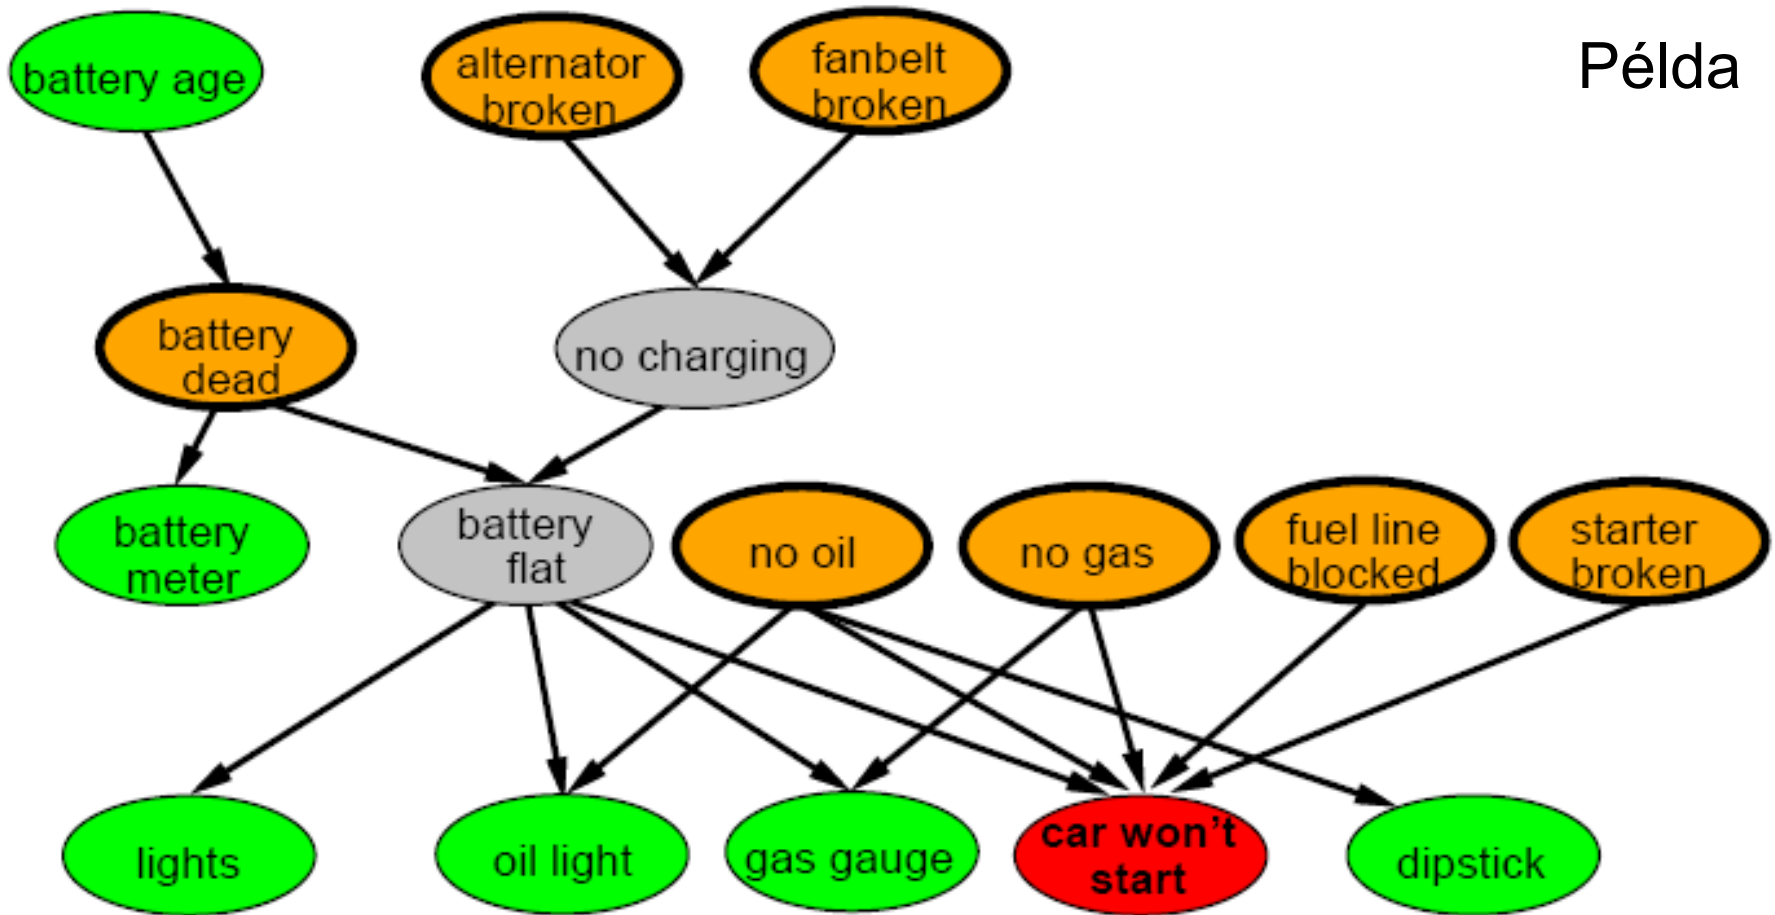
1 db szülő csomópont 4-es értékű és

az eredmény csomópont egy 5-ös értékű

változó?



Példa



16 (bináris) változó =  $2^{16}-1 = 16383$  valószínűség  
háló =  $7 + 4 \times 2 + 4 \times 4 + 1 \times 32 = 63$  valószínűség (x 260)





# Biológiai és környezeti folyamatok modellezése

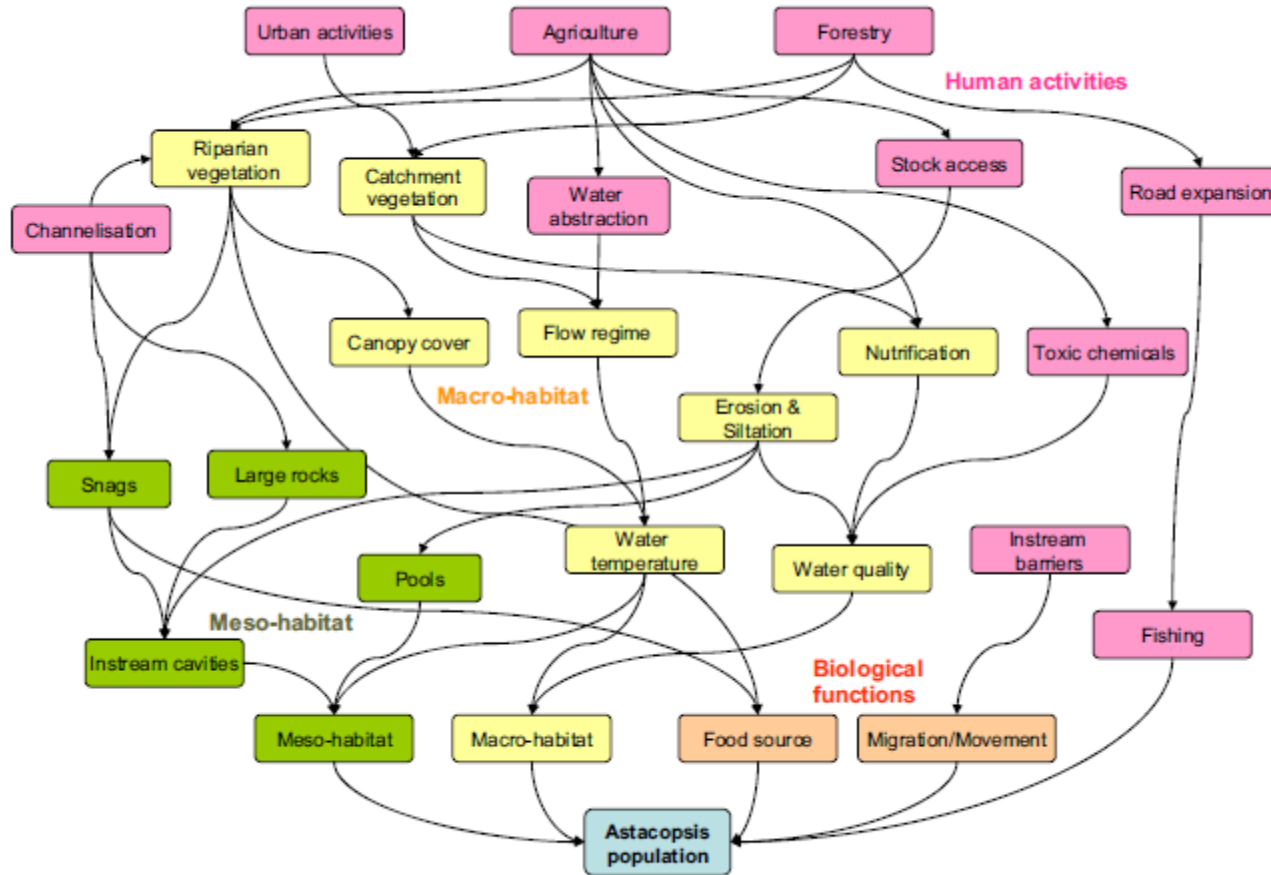
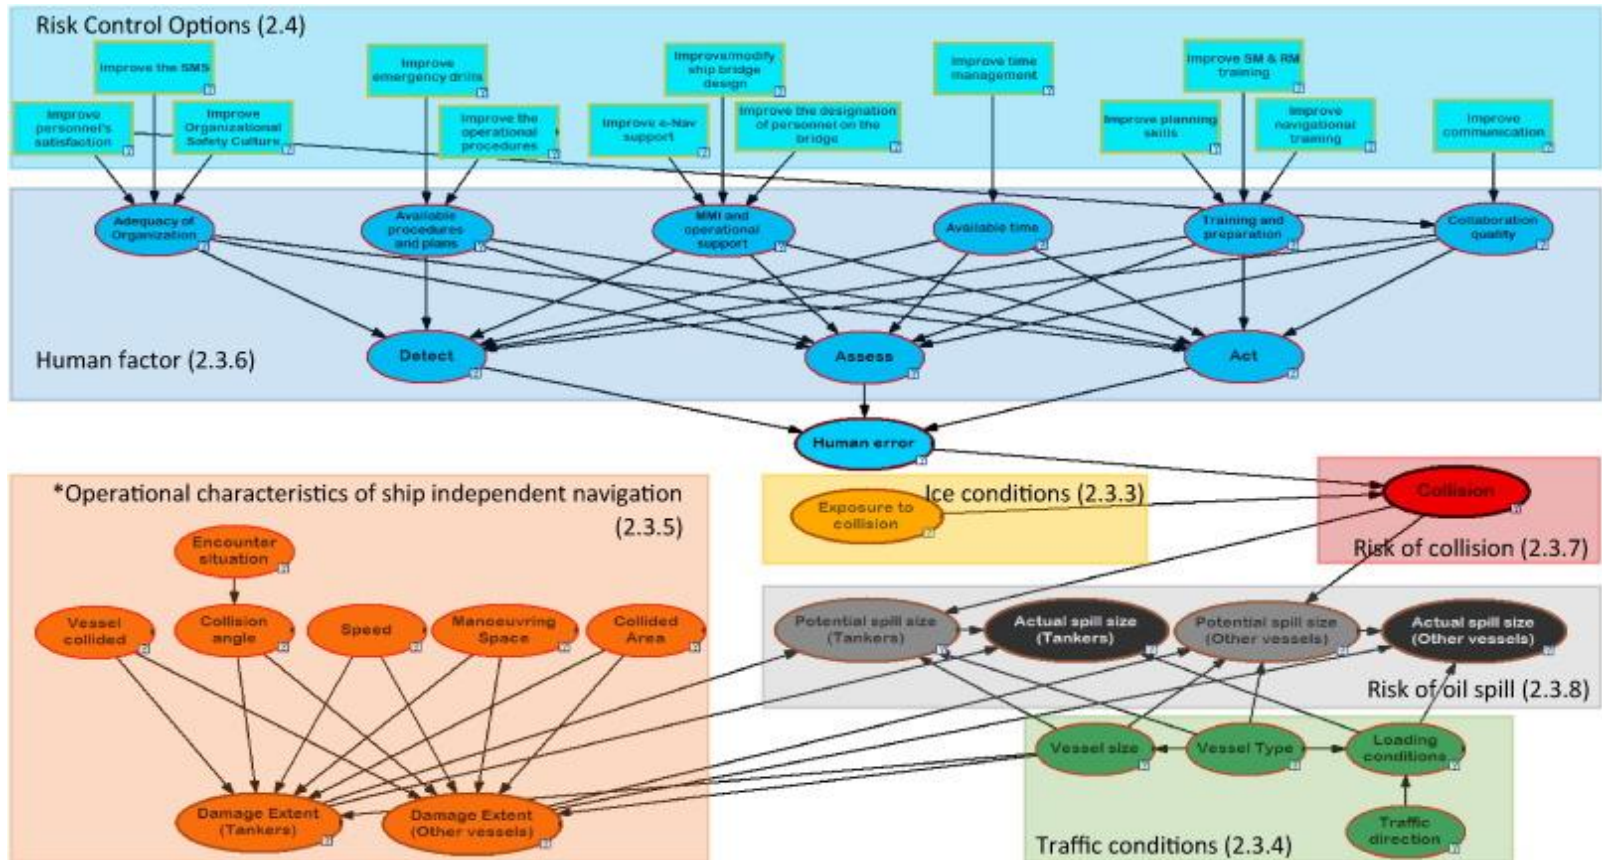


Fig. 2. Conceptual model of the key factors affecting *Astacopsis gouldi* populations.

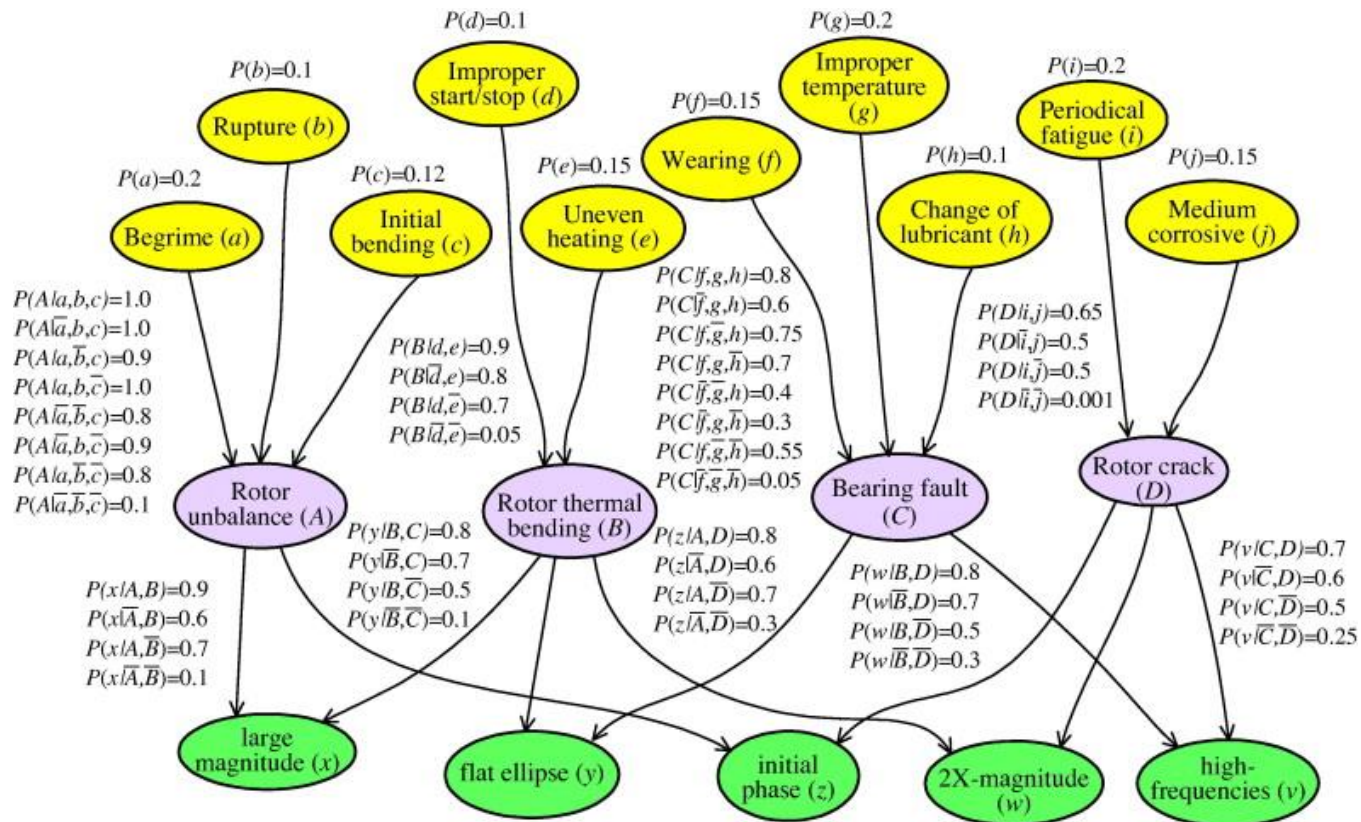
Serena H. Chen & Carmel A. Pollino: Good practice in Bayesian network modelling

# Kockázatmodellezés



Osiris A.Valdez et al. : Risk management model of winter navigation operations, Marine Pollution Bulletin, Volume 108, Issues 1–2, 15 July 2016, Pages 242-262

# Hibamodellezés és következtetés



Bin GangXu: Intelligent fault inference for rotating flexible rotors using Bayesian belief network, Expert Systems with Applications, Volume 39, Issue 1, January 2012, Pages 816-822

# Modelltípusok

egy rendszer belső működésének modellezése szerint


- Black box



Pl.: Neurális hálók

A rendszer belső működését nem modellezi

- White box



Pl.: Bayes- hálók

A rendszer belső működését modellezi

(Grey box)

# A valószínűségi hálók szemantikája

(1) a háló = **együttes valószínűségi eloszlás** egy leírása,

(2) a háló = **feltételes függetlenségekről szóló állítások** együttese.

A két szemlélet **ekvivalens**

az első abban segít, hogy hogyan **hozzunk létre** egy hálót

a második abban, hogy hogyan **tervezzünk** következtetési eljárásokat.

## Feltételes függetlenség

Ha a szülő (szülői feltétel) ismert, nem érdekes az ősz:

$$P(X_i | X_{i-1}, \dots, X_1) = P(X_i | \mathbf{Szülők}(X_i)), \quad i=1 \dots n,$$

ha  $\mathbf{Szülők}(X_i) \subseteq \{ X_{i-1}, \dots, X_1 \}$ .

Ez utóbbi könnyen teljesíthető a csomópontok olyan sorszámozásával, ami konzisztens a gráf implicit részleges rendezésével.

$$P(X_i | \mathbf{Szülők}(X_i), \mathbf{Ősök}(X_i)) = P(X_i | \mathbf{Szülők}(X_i))$$

# Az együttes valószínűségi eloszlásfüggvény leírása

A valószínűségi hálóban található információk alapján:  
az együttes valószínűségi eloszlás bármely bejegyzése kiszámítható.

Egy bejegyzés értéke (globális szemantika):

$$P(X_1 \dots X_n) = \prod_{i=1 \dots n} P(X_i | \text{Szülők}(X_i)), i=1 \dots n$$

Az együttes valószínűségi eloszlás minden bejegyzése felbontható a FVT megfelelő elemeinek a szorzatára.



**FVT-k: az együttes valószínűségi eloszlás dekomponált leírása.**

*Egy elemi esemény: pl. a riasztó megszólal, de sem betörés, sem földrengés nem volt, azonban János is és Mária is telefonál:*

$$\begin{aligned} P(J M R \neg B \neg F) &= P(J | M R \neg B \neg F) P(M R \neg B \neg F) \\ &= P(J | R) P(M | R \neg B \neg F) P(R \neg B \neg F) \\ &= P(J | R) P(M | R) P(R | \neg B \neg F) P(\neg B) P(\neg F) \\ &= .90 \times .70 \times .001 \times .999 \times .998 = .00062 \end{aligned}$$

## Lokális (topológiai) szemantika:

- Minden csomópont ( $X$ ) feltételesen független a nem leszármazottjaitól ( $Z$ ), ha a **szülői** adottak ( $U$ ).
- Minden csomópont ( $X$ ) feltételesen független minden mástól, ha a **Markov-takarója** adott (szülői+gyerekei+gyerekeinek szülői).
- d-elválasztás ...**





## Az általános eljárás egy háló fokozatos megépítésére:

1. Határozzuk meg a problémát leíró változókat (miről érdemes beszélni).
2. Határozzunk meg **egy sorrendet**.
3. Ameddig maradt még érintetlen változó:
  - a) Válasszuk a következő  $X_i$  változót és adjunk egy csomópontot a hálóhoz.
  - b) Legyen a  $Szülők(X_i)$  a csomópontok azon minimális halmaza, amik már szerepelnek a hálóban és a feltételes függetlenség tulajdonságát teljesítik – húzzuk be a kapcsolatokat.
  - c) Definiáljuk  $X_i$  csomópont feltételes valószínűségi tábláját.

Mindegyik csomópontot csak korábbi csomópontokhoz csatlakoztathatunk  
= a háló körmentes lesz.

A valószínűségi háló nem tartalmaz redundáns valószínűségi értékeket, kivéve soronkénti bejegyzéseket a feltételes valószínűségi táblában.

## Tömörség és a csomópontok sorrendje

Egy valószínűségi háló gyakran sokkal **tömörebb**, mint az együttes valószínűségi eloszlásfüggvény.

A valószínűségi háló tömörsége a **lokálisan strukturált** (vagy **ritka**) rendszerek egy példája.

**Lokálisan strukturált rendszer:** egy komponense csak korlátos számú más komponenssel van kapcsolatban közvetlenül, függetlenül a komponensek teljes számától. Lokális struktúrák: **inkább a lineáris, mint az exponenciális komplexitás** növekedés.

Valószínűségi háló  $n$  változóból: legtöbb esetben egy változót csak  $k$  számú más változó befolyásol, bináris változók =  $n \times 2^k$  érték. Együttes valószínűségi eloszlás =  $2^n - 1$  érték.

Példa: 20 cs.pont ( $n = 20$ ), max. 5 szülője legyen ( $k = 5$ ), valószínűségi háló: **640** érték, együttes valószínűségi eloszlás: > **egy millió**.

**A gyakorlatban előforduló információcsökkenés miatt lép fel, hogy a valós problémák igen strukturáltak, amit a hálók könnyűszerrel képesek kihasználni.**

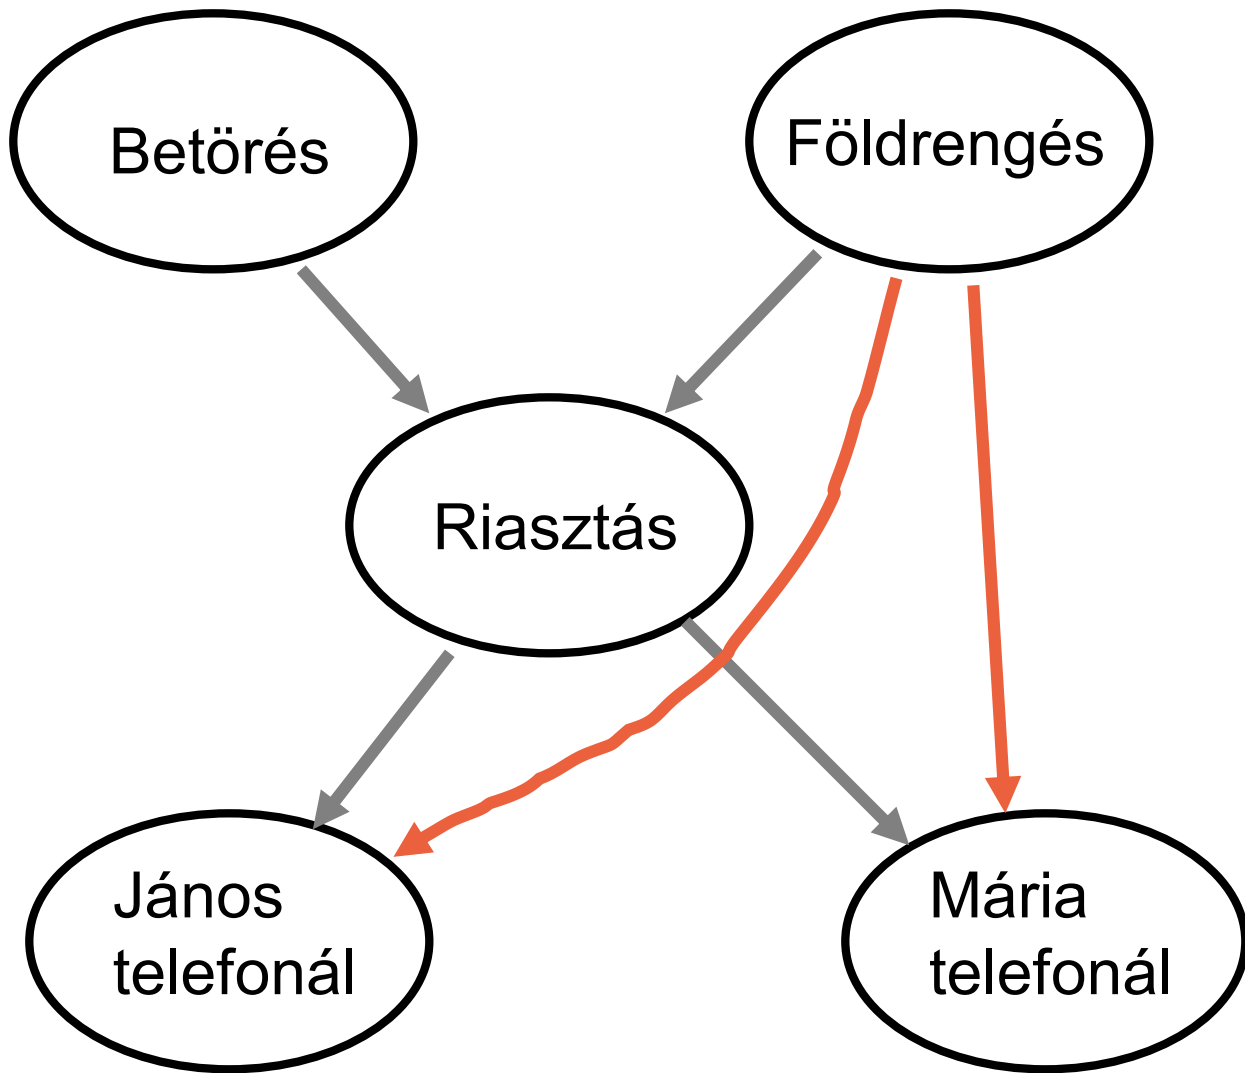
## Tömörség és a csomópontok sorrendje

Bizonyos tárgytartományokban létezhetnek olyan **jelentéktelennek tűnő függőségek**, amiket feltétlenül modellezni kell egy új kapcsolat felvételével.

De ha ezek a függőségek ténylegesen jelentéktelenek, akkor lehet, hogy nem éri meg a háló komplexitását megnövelni a pontosság kismértékű növelésének érdekében.

Pl.:

hogya földrengés van, akkor Mária és János akkor sem telefonálna, ha hallanák a riasztót, mivel feltételezik, hogy a földrengés okozta.



$$2 + 4 + 2 + 2 = 10 \text{ (eddig)}$$

$$2 + 4 + 4 + 4 = 14$$

Megéri-e?

## Tömörség és a csomópontok sorrendje

A konstrukciós eljárás működése miatt előbb a „közvetlen befolyásolókat”-at kell a hálózathoz adni, ha azt szeretnénk, hogy szülőknél tudjuk őket választani az általuk befolyásolt csomópontnál.

Ezért a helyes sorrend a csomópontok hozzáadásánál: először az „alapvető okokat” adjuk a hálózathoz, majd a változókat, amiket befolyásolnak, és ezt addig folytatjuk, amíg el nem érjük a „leveleket”, amiknek már nincs közvetlen okozati hatása más változókra (azaz a kauzalitás sorrendjében).


**Mi történik, ha történetesen egy rossz sorrendet választunk?**

pl.

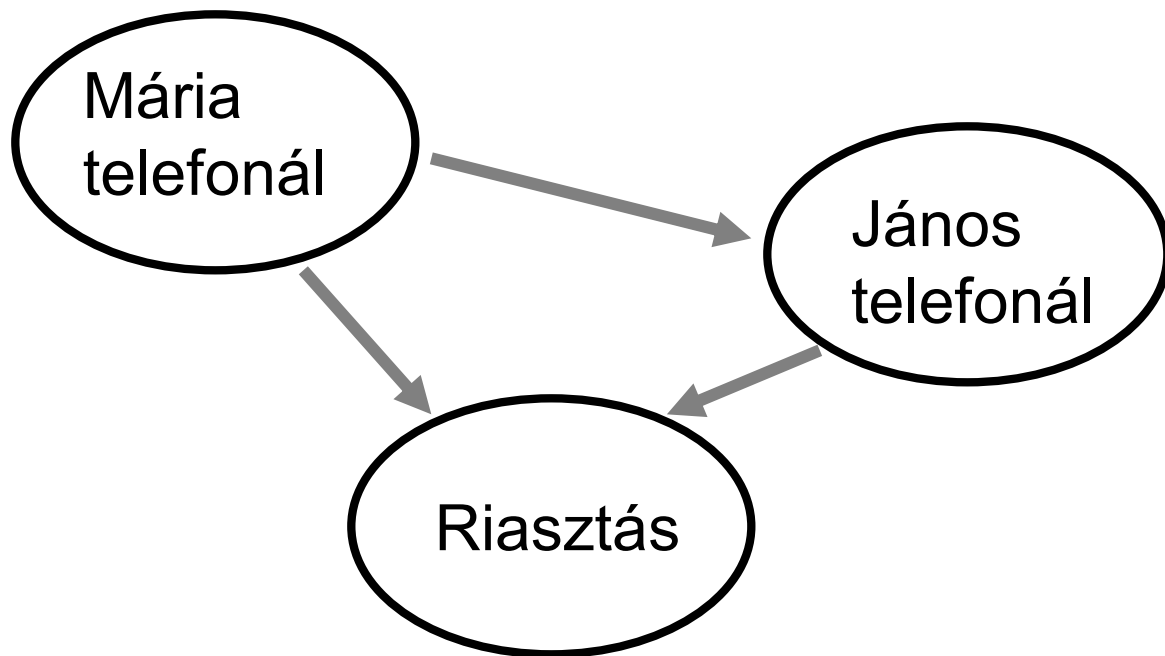
*MáriaTelefonál → JánosTelefonál → Riasztás → Betörés → Földrengés.*



Mária  
telefonál



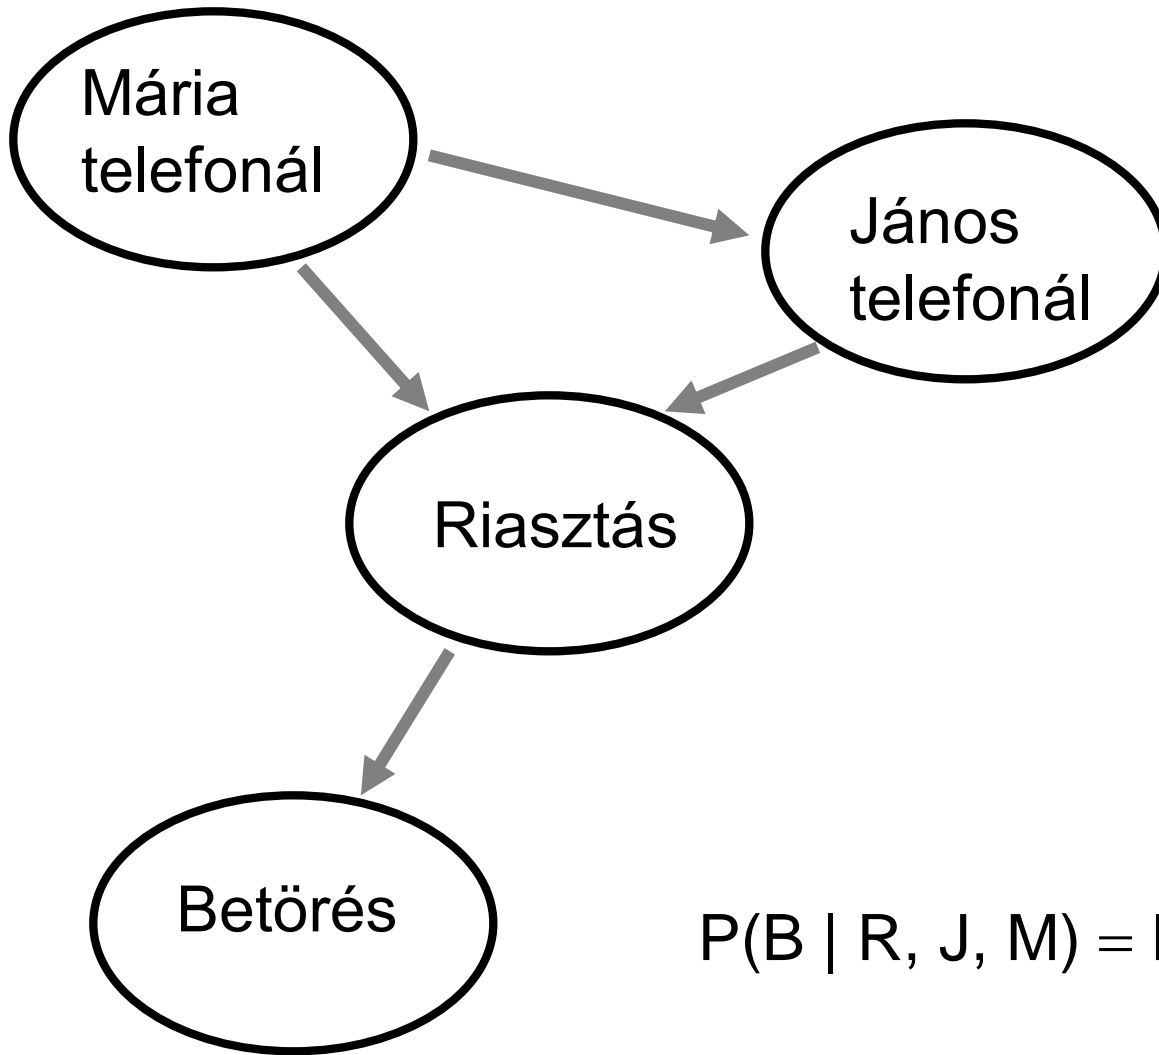
$P(J | M) = P(J)$ ? Nem (azaz van nyíl)



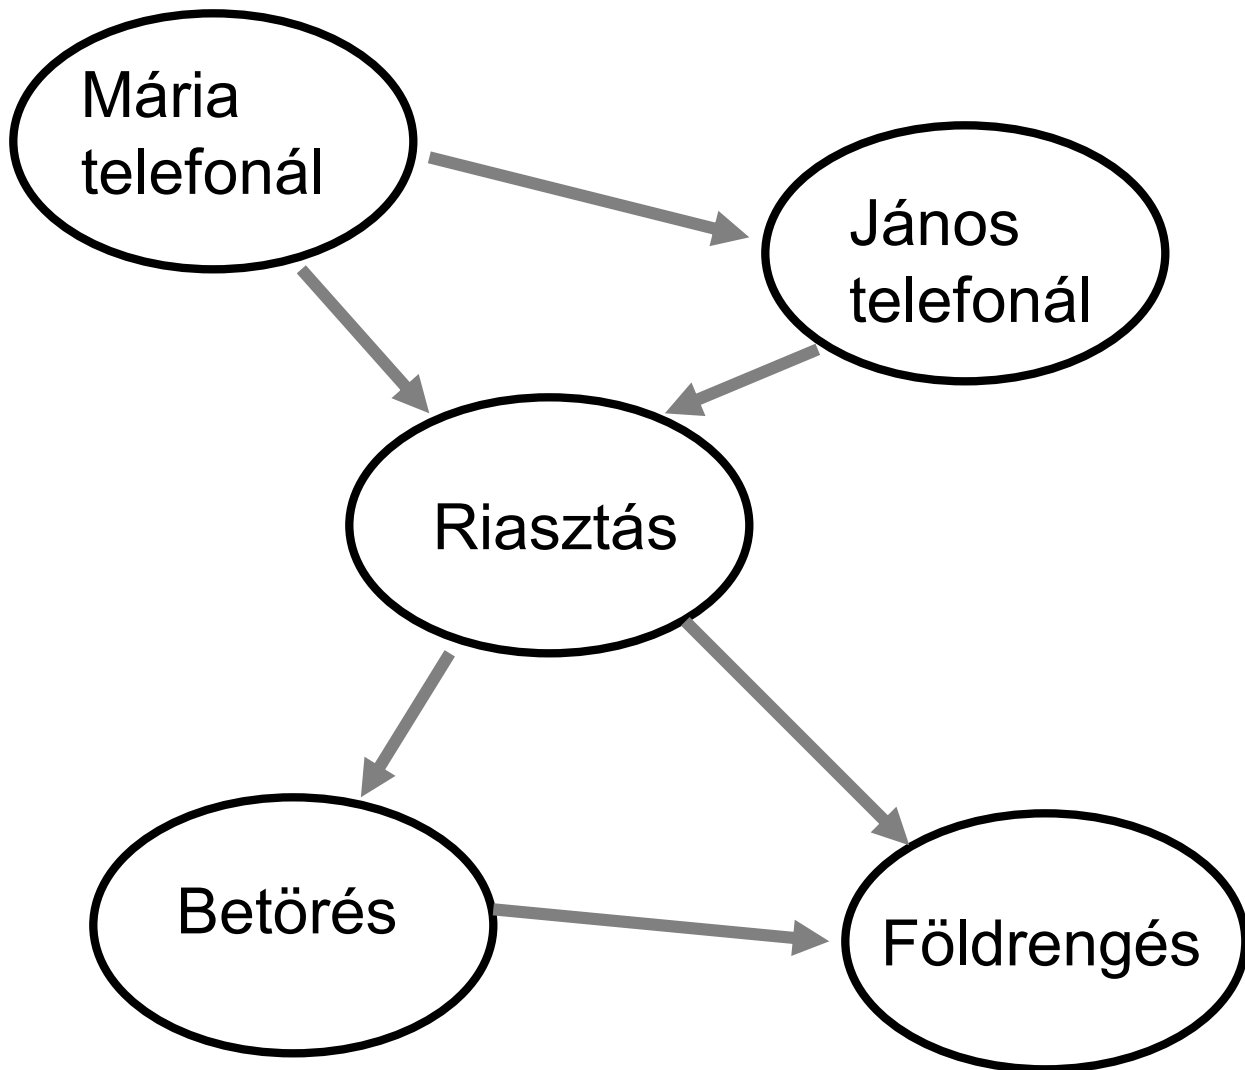
$$P(R | J, M) = P(R | J)?$$

$$P(R | J, M) = P(R)? \quad \text{Nem}$$





$P(B \mid R, J, M) = P(B \mid R)?$  Igen



$$\begin{aligned}
 &1 + 2 + 4 \\
 &+ 2 + 4 \\
 &= 13
 \end{aligned}$$

$$P(F \mid B, R, J, M) = P(F \mid B, R)? = P(F \mid R)?$$

Igen
Nem

Mi történik, ha történetesen egy nagyon rossz sorrendet választunk?


*Mária Telefonál*

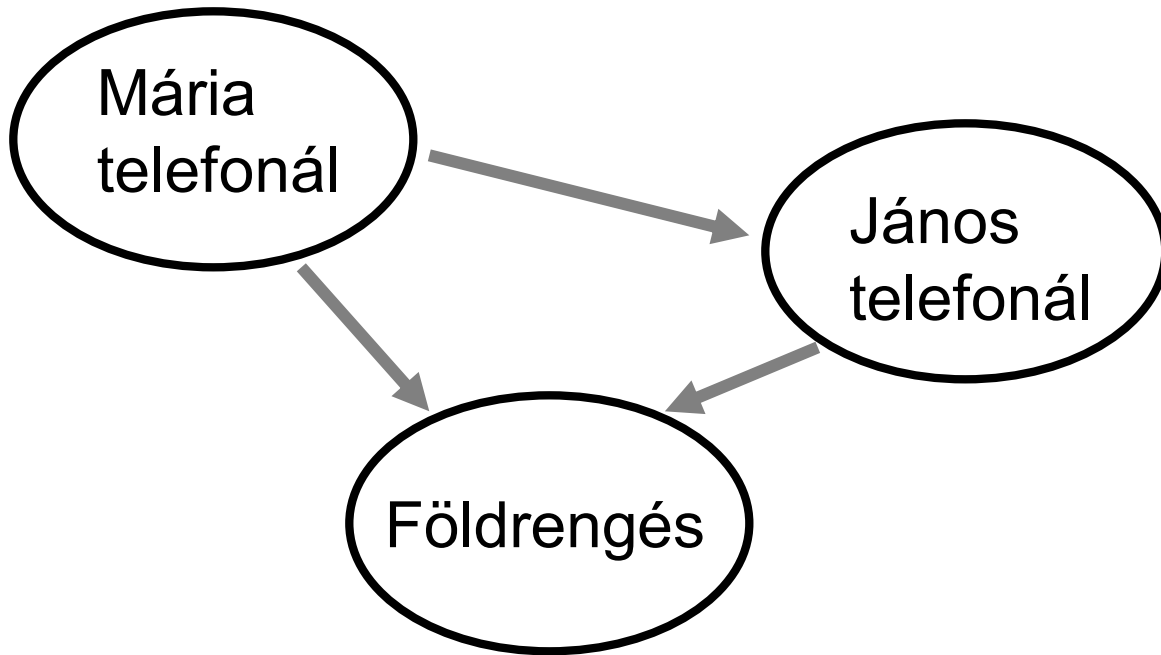
*János Telefonál*

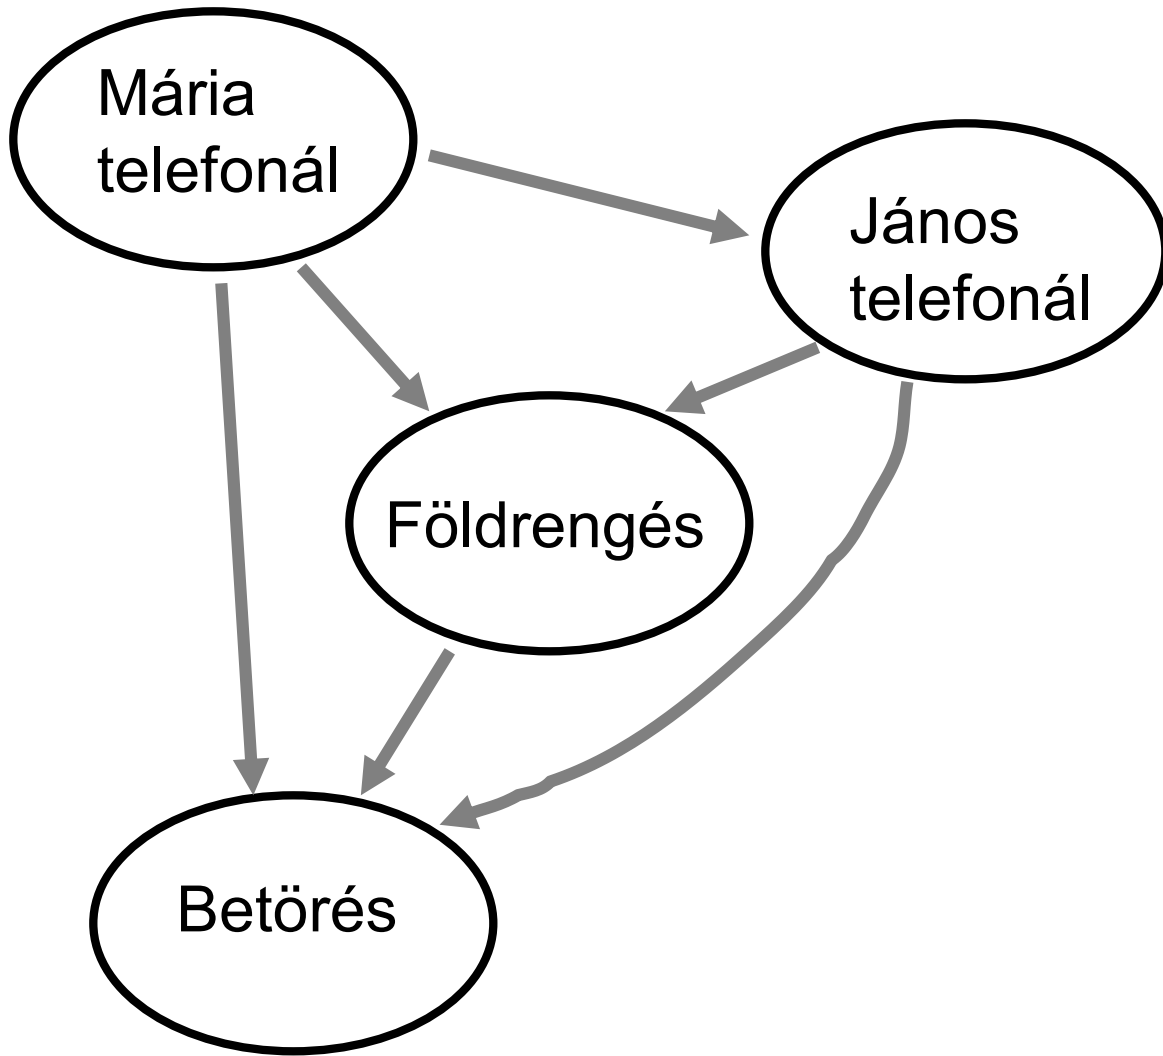
*Földrengés.*

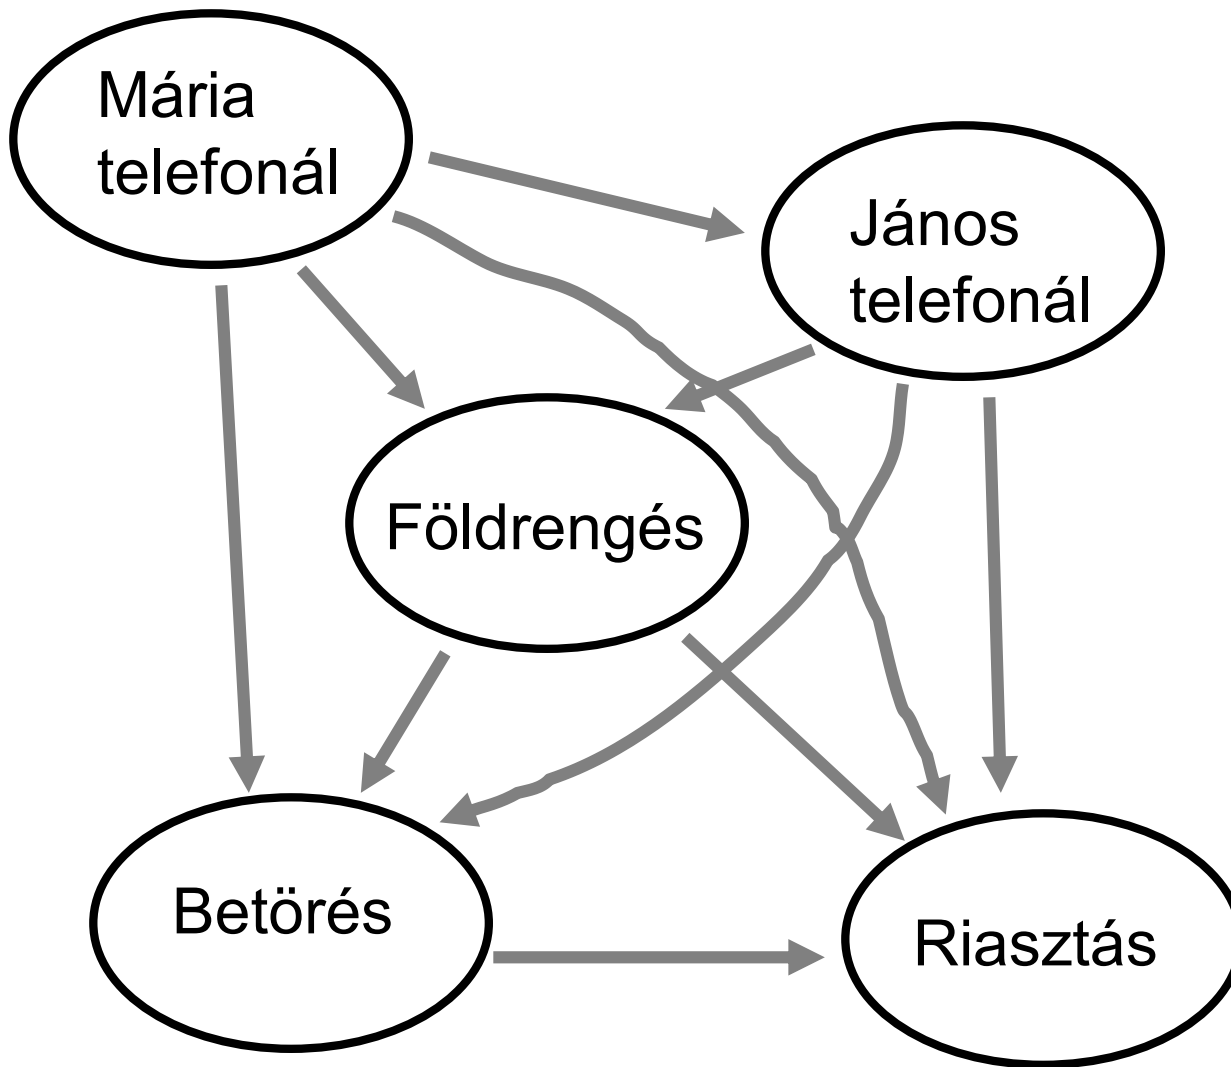
*Riasztás*

*Betörés*









$$\begin{aligned} &1 + 2 + 4 \\ &+ 8 + 16 \\ &= 31 \\ &= 2^5 - 1 \end{aligned}$$

## Sok (elméletileg exponenciális számú) **valószínűség**

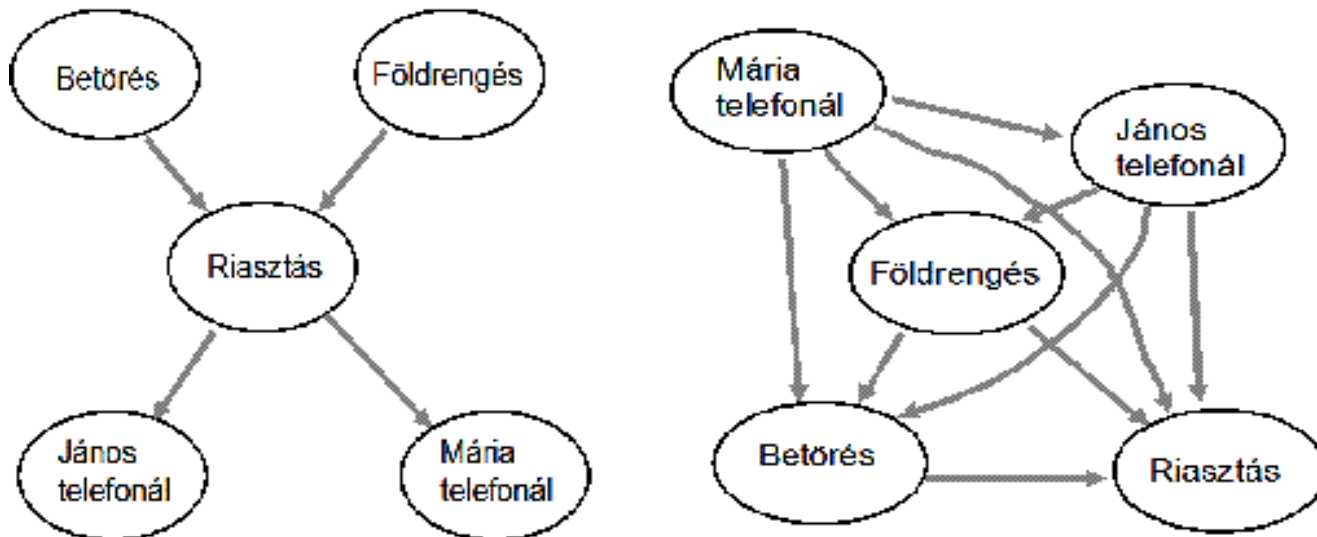
De a legrosszabb következmény:

néhány kapcsolat furcsa viszonyt reprezentál, ami nehéz és **nem természetes valószínűségi ítéleteket igényel**, pl.

$P(\text{Földrengés} \mid \text{Mária} \dots, \text{János} \dots)$  ?

$P(\text{Betörés} \mid \text{Földrengés})$  ? ... ..

Okozati (kauzális) modell: kevesebb, megbízhatóbb érték, az értékeket gyakran könnyebb elérni



# Következtetés valószínűségi hálóknban

Az alapvető feladat:

kiszámítani az **a posteriori** valószínűséget a **lekérdezéses változókra**, ha a **tény ill. bizonyíték (evidencia) változóknak** az értékei adottak:

$$P(\text{Lekérdezéses} \mid \text{Bizonyíték})$$

A riasztós példában, pl.:

$$P(\text{Betörés} \mid \text{MáriaTelefonál és JánosTelefonál})$$

Általában az ágens az érzékeléséből (vagy egyéb következtetésből) kap értékeket a tény változókhöz, és más változók lehetséges értékeiről kérdez, hogy el tudja dönteni milyen cselekvéseket végezzen.

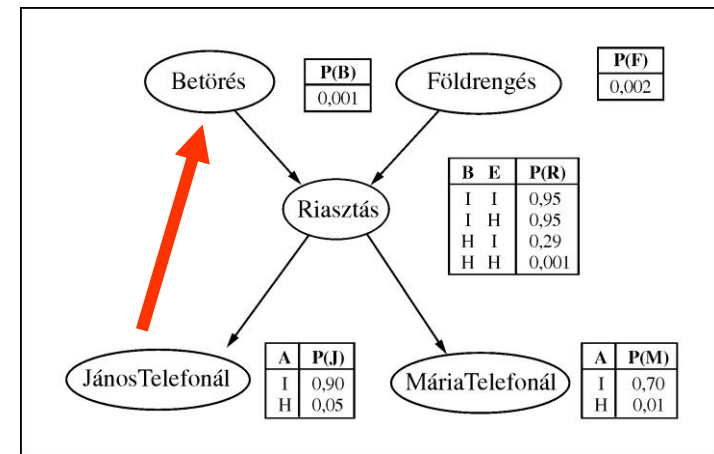


## Diagnosztikai következtetés

(hatásról az okra)

Ha adott a *JánosTelefonál*, akkor kiszámíthatjuk pl., hogy

$$P(\text{Betörés} \mid \text{JánosTelefonál}) = 0,016.$$

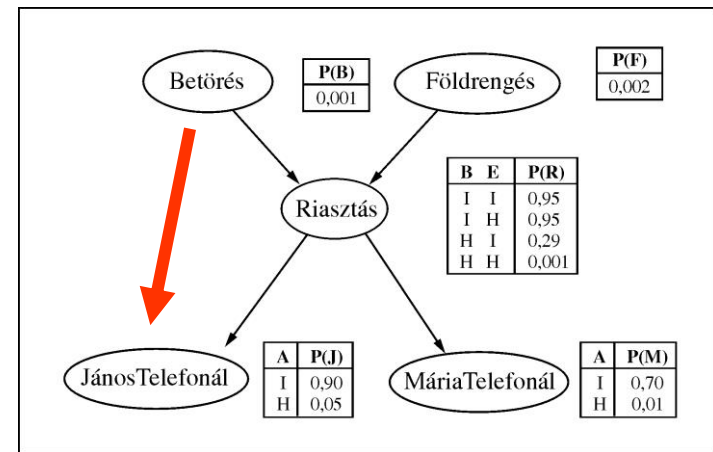


## Okozati következtetés

(okról a hatásra)

Ha adott a *Betörés*, akkor kiszámíthatjuk pl., hogy

$$P(\text{JánosTelefonál} \mid \text{Betörés}) = 0,67.$$



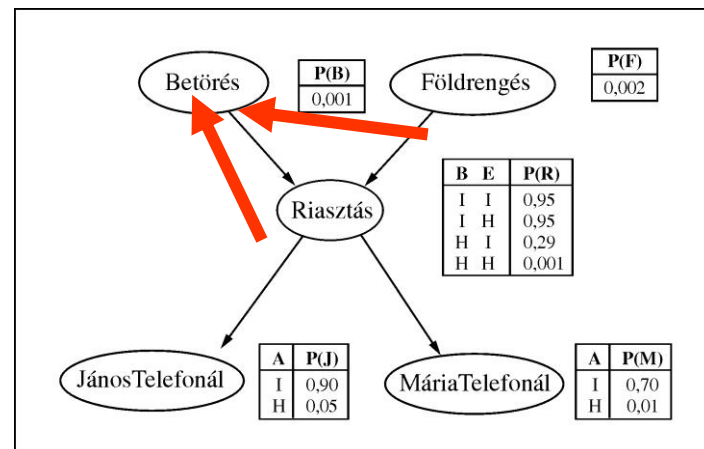
# Okok közötti következtetés

(következtetés egy közös hatás okai között)

Ha adott a *Riasztás*,  
akkor  $P(\text{Betörés} \mid \text{Riasztás}) = 0.376$ .

Ha azonban hozzávesszük azt a tényt is,  
hogy a *Földrengés* igaz,  
akkor  $P(\text{Betörés} \mid \text{Riasztás}, \text{Földrengés}) = 0.003$ .

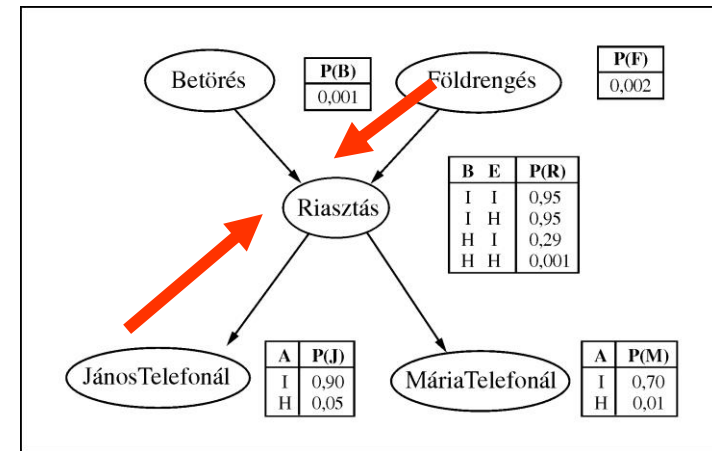
Bár a betörések és a földrengések függetlenek, az egyik jelenléte a másik valószínűségét csökkenti.  
Ez a fajta következtetési mód a **kimagyarázás**.



## Kevert következtetések

(a fentiek kombinált használata).

Ha a *JánosTelefonál* okozat igaz és a *Földrengés* ok hamis, akkor



$$P(\text{Riasztás} \mid \text{JánosTelefonál}, \neg \text{Földrengés}) = 0,03.$$

Ez a diagnosztikai és okozati következtetés együttes felhasználása.

Hasonlóan,

$$P(\text{Betörés} \mid \text{JánosTelefonál}, \neg \text{Földrengés}) = 0,017.$$


Ez a diagnosztikai és az okok közötti következtetés kombinálása.

**Érzékenységi vizsgálat** elvégzése, annak érdekében, hogy megértsük, hogy a modell mely vonatkozásának van a legnagyobb hatása a lekérdezéses változókra nézve.

# Naiiv Bayes-hálók

Feltevéssek:

- 1.) Kétféle csomópont lehetséges: a „ok” és „következmény”.
- 2.) A következmények egymástól feltételesen függetlenek egymástól feltéve az okot.



# Naiiv Bayes-hálók

## Változók (csomópontok)

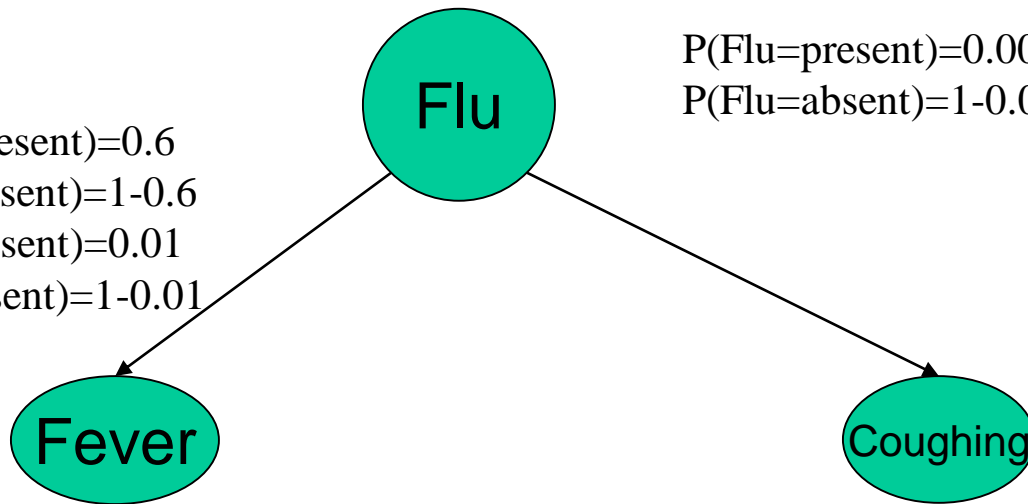
Flu (Influenza): {jelen, nincs jelen}

Fever (Láz): {jelen, nincs jelen}

Coughing (Köhögés): {jelen, nincs jelen}

## Modell

$P(\text{Fever}=\text{present}|\text{Flu}=\text{present})=0.6$   
 $P(\text{Fever}=\text{absent}|\text{Flu}=\text{present})=1-0.6$   
 $P(\text{Fever}=\text{present}|\text{Flu}=\text{absent})=0.01$   
 $P(\text{Fever}=\text{absent}|\text{Flu}=\text{absent})=1-0.01$



$P(\text{Flu}=\text{present})=0.001$   
 $P(\text{Flu}=\text{absent})=1-0.001$

$P(\text{Coughing}=\text{present}|\text{Flu}=\text{present})=0.3$   
 $P(\text{Coughing}=\text{absent}|\text{Flu}=\text{present})=1-0.3$   
 $P(\text{Coughing}=\text{present}|\text{Flu}=\text{absent})=0.02$   
 $P(\text{Coughing}=\text{absent}|\text{Flu}=\text{absent})=1-0.02$

# Naiv Bayes-háló

Együttes valószínűség-eloszlás dekompozíciója:

$$\begin{aligned} P(Y, X_1, \dots, X_n) &= P(Y) \prod_i P(X_i | Y, X_1, \dots, X_{i-1}) \quad // \text{lánc szabály miatt} \\ &= P(Y) \prod_i P(X_i | Y) \quad // \text{naiv BN feltevés} \end{aligned}$$


2n+1 paraméter

Diagnosztikus következtetés:

$$P(Y | x_{i1}, \dots, x_{ik}) = P(Y) \prod_j P(x_{ij} | Y) / P(x_{i1}, \dots, x_{ik})$$

$$p(\text{Flu} = \text{present} | \text{Fever} = \text{absent}, \text{Coughing} = \text{present})$$

$$\propto p(\text{Flu} = \text{present}) p(\text{Fever} = \text{absent} | \text{Flu} = \text{present}) p(\text{Coughing} = \text{present} | \text{Flu} = \text{present})$$




# Gyakorlati példa: SPAM filter

## SPAM filter

SPAM: yes/no [suspicious..]

Attributes

Sender, subject, link, attachment, ..




# A valószínűségi hálók szemantikája

- (1) a háló = **együttes valószínűségi eloszlás** egy leírása,
- (2) a háló = **feltételes függetlenségekről szóló állítások** együttese.
- (3) a háló = **oksági kapcsolatok** együttese.


**FONTOS: oksági kapcsolat  $\neq$  asszociációs kapcsolat**

## Reichenbach's Common Cause Principle:


„a correlation between events  $X$  and  $Y$  indicates either that  $X$  causes  $Y$ , or that  $Y$  causes  $X$ , or that  $X$  and  $Y$  have a common cause.”




X okozza Y-t




Y okozza X-et



Létezik közös ok  
(pure confounding)



Y okozza X-et,  
de emellett számos más  
változónak is van zavaró  
hatása



„X és Y asszociált”  $D(X, Y)$