

BAYESOVE MREŽE

POGLAVLJE 14.1–3

Prema slajdovima Stuarta Russella (hvala)!

Sadržaj

- ◇ Sintaksa
- ◇ Semantika
- ◇ Parameterizirane distribucije

Bayesove mreže

Jednostavna, **grafička** notacija za tvrdnje o **uvjetnoj nezavisnosti** i za **sažetu** specifikaciju zajedničke (združene) distribucije vjerojatnosti.

Sintaksa **Bayesove mreže**:

- skup **čvorova**, jedan po svakoj varijabli (varijabla = ime čvora),
- **usmjereni, aciklički** graf (engl. “directed acyclic graph”, DAG)
smjer veze \approx “direktni utjecaj” roditelja na dijete,
- **uvjetna** distribucija za svaki čvor, za dane njegove roditelje:
 $P(X_i | Parents(X_i))$ — kvantificira utjecaj roditelja na dijete.

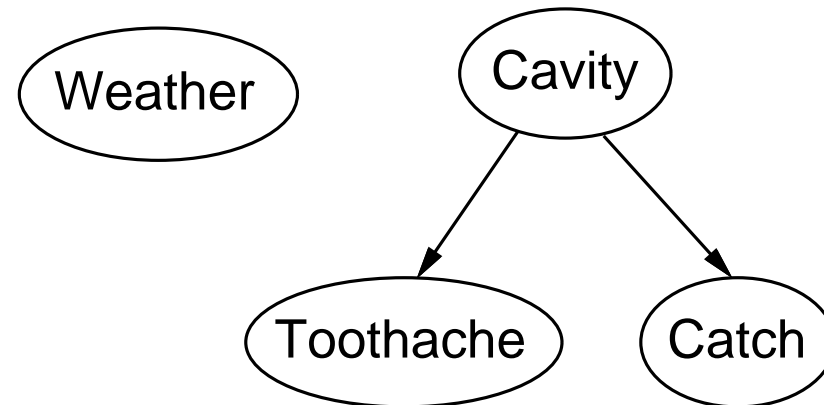
U **diskretnom** slučaju, uvjetna distribucija je reprezentirana

tablicom uvjetne vjerojatnosti (engl. “conditional prob. table”, CPT)

koja daje distribuciju preko svih vrijednosti X_i , za **svaku** kombinaciju vrijednosti roditelja.

Jednostavni primjer

Topologija mreže (grafa) — čvorovi i **veze** među njima, zadaje odnose **uvjetne nezavisnosti** u domeni:



Weather je nezavisna o **svim** preostalim varijablama — **nema** veza.

Veze označavaju da je *Cavity* **direktni uzrok** za *Toothache* i *Catch*.

Toothache i *Catch* su uvjetno nezavisne za **dan** (poznat) *Cavity* **nema** direktne veze između njih.

Primjer

Priča: Imam novi protuprovalni **alarm** kod kuće. On je dosta pouzdan u otkrivanju **provale**, ali katkad reagira i na manje **potrese** (Kalifornija).

Imam dvoje susjeda, **Johna** i **Mary**, koji su obećali da će me **nazvati** na posao, ako **čuju** alarm.

John gotovo uvijek nazove kad čuje alarm, ali ga ponekad zamijeni sa zvonjavom telefona, pa me i tad nazove.

S druge strane, **Mary** voli glasnu muziku i često uopće ne čuje alarm.

Problem: Ako **znam** tko **je** ili **nije zvao** (dokazi), želim znati kolika je vjerojatnost stvarne **provale**.

Na primjer, John **je zvao**, a Mary **nije**.

Primjer — nastavak

Varijable: *Burglary*, *Earthquake*, *Alarm*, *JohnCalls*, *MaryCalls*

Katkad koristimo skraćene oznake **prvim** slovom: *B*, *E*, *A*, *J*, *M*

Topologija mreže reflektira “**kauzalno**” = **uzročno** znanje:

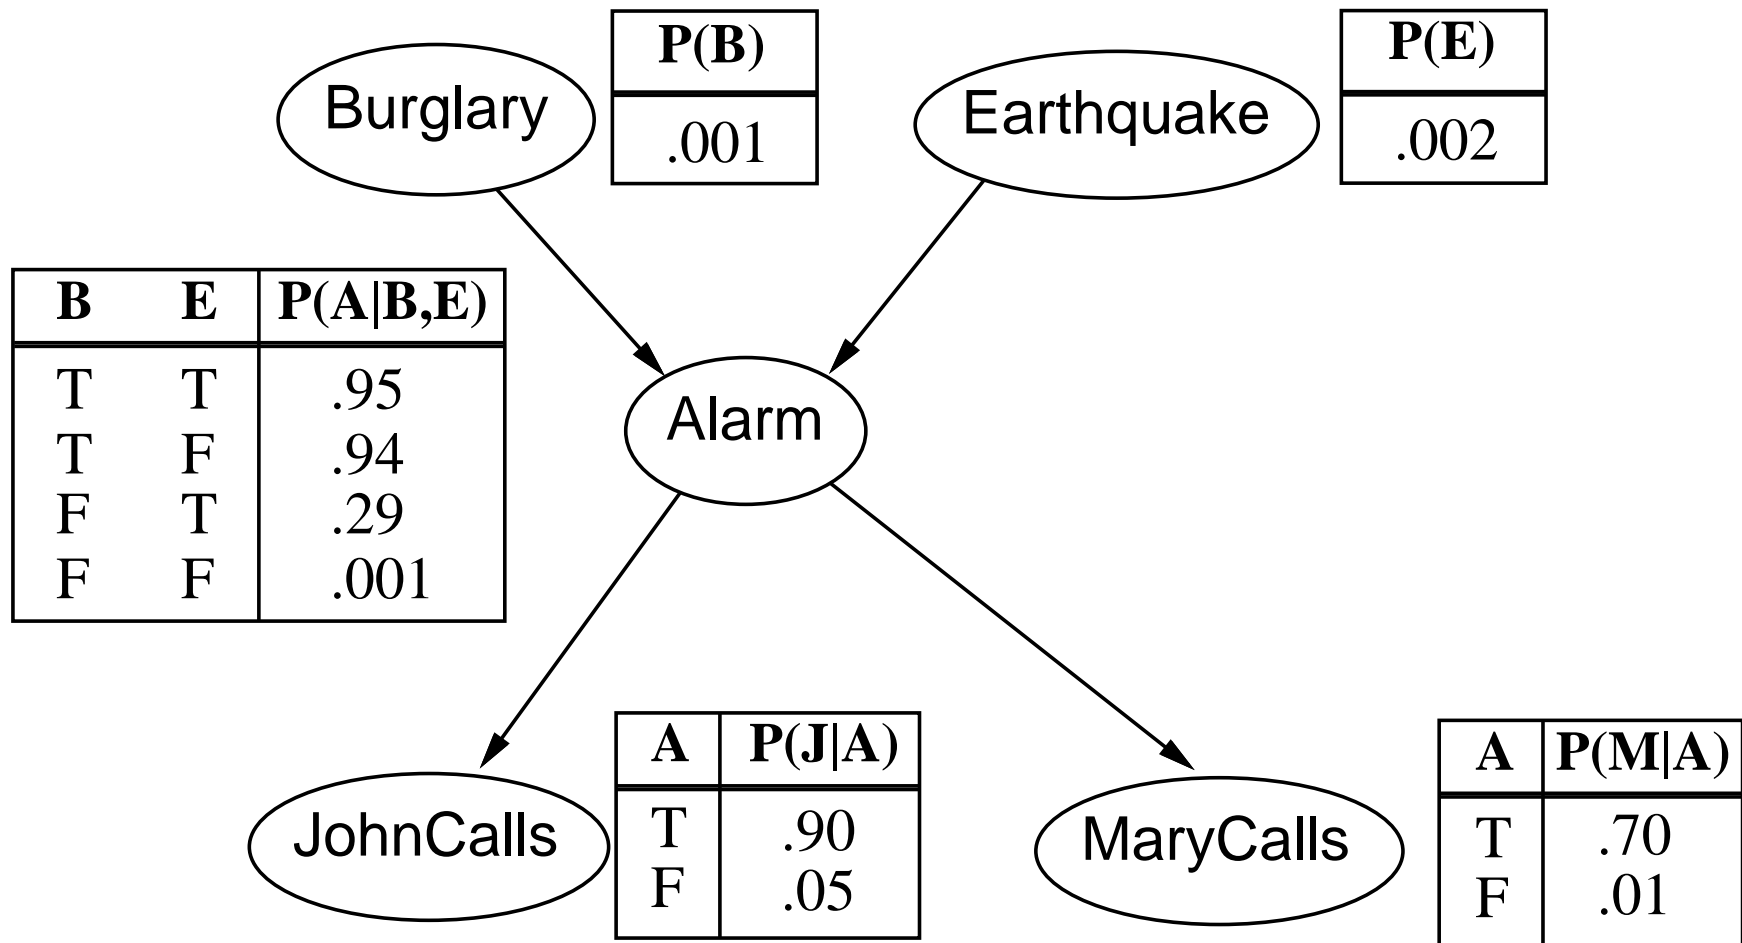
- Provalnik može aktivirati alarm
- Potres može aktivirati alarm
- Alarm može prouzročiti Johnov poziv
- Alarm može prouzročiti Maryin poziv

Uočiti:

- Poziv ovisi samo o alarmu, a ne o stvarnoj provali ili potresu
- Ako čuju alarm, pozivi su nezavisni (ne dogovaraju se o tome).

Evo i mreže, zajedno s tablicama uvjetnih vjerojatnosti u čvorovima.

Primjer — Bayesova mreža



Zapis vjerojatnosti preko CPT

Tablice uvjetnih vjerojatnosti (**CPT**) u čvorovima sadrže:

- po jedan redak za svaku moguću kombinaciju vrijednosti svih roditeljskih čvorova (tzv. “uvjetni slučaj”),
- po jedan stupac za svakog roditelja (prednji dio tablice),
- po jedan stupac za svaku moguću vrijednost varijable u tom čvoru (stražnji dio tablice = popis vjerojatnosti).

U čvoru bez roditelja, **CPT** ima samo jedan redak — to su početne (a priori) vjerojatnosti za svaku moguću vrijednost varijable.

Uočiti: zbroj svakog retka tablice (u stražnjem dijelu) mora biti 1, zato stupac za “zadnju” vrijednost varijable smijemo ispustiti!


Tablični prikaz uvjetnih vjerojatnosti je prikladan za diskretne varijable.

Postoje i drugi prikazi — neki su prikladni i za neprekidne varijable.

Kompaktnost — sažetost zapisa

CPT za Booleovu varijablu X_i s k Booleovih roditelja ima 2^k redaka — za sve kombinacije vrijednosti roditelja.

Svaki redak zahtijeva samo **jedan** broj p za $X_i = true$ (broj za $X_i = false$ je upravo $1 - p$).



Sažetost zapisa **potpune** združene distribucije vjerojatnosti preko **CPT**:
ako imamo n Booleovih varijabli (radi jednostavnosti)
i svaka varijabla/čvor ima **najviše** k roditelja,
cjelokupna mreža zahtijeva $O(n \cdot 2^k)$ brojeva.

Ovo raste **linearno** s n , nasuprot $O(2^n)$ za potpunu distribuciju.

Za provalničku mrežu, imamo **samo** $1 + 1 + 4 + 2 + 2 = 10$ brojeva (preostalih 10 su $1 - p$), nasuprot punih $2^5 - 1 = 31$.

Za $n = 30$ i $k = 5$, dovoljno je **960** brojeva (prema 2^{30}).

Semantika Bayesovih mreža

Do sada — opisali što je mreža (kako izgleda), ali **ne** i njezino **značenje**.

Postoje **dva** pogleda na semantiku — naravno, **ekvivalentna**.


Prvi = **globalni**: mreža je prikaz **združene distribucije vjerojatnosti** pomaže u tome kako treba **konstruirati** mreže.

Drugi = **lokalni**: mreža je prikaz skupa činjenica o **uvjetnoj nezavisnosti** pomaže u projektiranju postupaka **zaključivanja**.

Na razini **sintakse**, Bayesova mreža je usmjereni aciklički graf (DAG), s nekim numeričkim **parametrima** vezanim za svaki čvor.

Globalna semantika

Globalna semantika **definira** potpunu združenu distribuciju kao **produkt** odgovarajućih numeričkih **parametara** iz zadanih tablica u čvorovima.



Svaka **pojedina** vrijednost u združenoj distribuciji je vjerojatnost **konjunkcije konkretnih** vrijednosti svake varijable, u oznaci $P(X_1 = x_1, \dots, X_n = x_n) = P(x_1, \dots, x_n)$.

Globalna semantika definira

$$P(x_1, \dots, x_n) = \text{def.} = \prod_{i=1}^n \theta(x_i \mid \text{parents}(X_i)),$$

gdje je $\theta(x_i \mid \text{parents}(X_i))$ odgovarajući **parametar** iz tablice u čvoru X_i , za dane vrijednosti čvora (x_i) i njegovih roditelja ($\text{parents}(X_i)$).

Globalna semantika — nastavak

Iz te definicije **slijedi** da ovi **parametri moraju** biti upravo odgovarajuće uvjetne vjerojatnosti $P(x_i | \text{parents}(X_i))$, pa vrijedi

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i)).$$

Dakle, **tablica** u svakom čvoru je **lokalna uvjetna distribucija**

$$\mathbf{P}(X_i | \text{Parents}(X_i)).$$

Drugim riječima, početna interpretacija je korektna.


Ovo je “numerička” semantika — faktorizacija združene distribucije.

Može se koristiti i za zaključivanje — zbrajanjem (kao prije). Međutim, ima i boljih načina.

Globalna semantika — ilustracija

Globalna semantika definira potpunu združenu distribuciju kao produkt lokalnih uvjetnih distribucija:

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i \mid \text{parents}(X_i)).$$



Nađimo vjerojatnost da se alarm **aktivirao**, s tim da **nije** bilo ni **provale** ni **potresa**, a **zvali** su i **John** i **Mary**.

U skraćenim oznakama, tražimo $P(j, m, a, \neg b, \neg e)$.


Zapisom preko lokalnih uvjetnih vjerojatnosti i množenjem vrijednosti iz tablica, dobivamo

$$\begin{aligned} P(j, m, a, \neg b, \neg e) &= P(j|a) P(m|a) P(a \mid \neg b, \neg e) P(\neg b) P(\neg e) \\ &= 0.90 \times 0.70 \times 0.001 \times 0.999 \times 0.998 \\ &\approx 0.000628 \end{aligned}$$

Lokalna semantika

Lokalna ili “topološka” semantika — kako je opisana u strukturi grafa: svaki čvor je **uvjetno nezavisan** od svojih **nesljedbenika** (nepotomaka) ako su **dani** njegovi **roditelji** (kao uvjet/dokaz).

Na primjer, u provalničkoj Bayesovoj mreži, *JohnCalls* ne ovisi o *Burglary*, *Earthquake* i *MaryCalls*, uz uvjet da znamo vrijednost za *Alarm*.




U lokalnoj semantici, osim tih činjenica o **uvjetnoj nezavisnosti**, **tablica** u svakom čvoru je, po **definiciji**, **lokalna uvjetna distribucija** vjerojatnosti $\mathbf{P}(X_i \mid \mathit{Parents}(X_i))$.

Teorem: **Lokalna semantika** \iff **globalna semantika**, tj. potpunu združenu distribuciju (po točkama) dobivamo kao malo prije

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i \mid \mathit{parents}(X_i)).$$

Lokalna semantika — nastavak


Lokalna ili “topološka” semantika — kako je opisana u strukturi grafa: svaki čvor je **uvjetno nezavisan** od svojih **nesljedbenika** (nepotomaka) ako su **dani** njegovi **roditelji** (kao uvjet/dokaz).



Na primjer, X je **uvjetno nezavisan** od nepotomaka Z_{ij} , uz **uvjet** svojih roditelja U_i — prikazanih u sivoj zoni.


Topološka semantika i Markovljev pokrivač

Topološka semantika implicira još jedno važno svojstvo **nezavisnosti**: svaki čvor je **uvjetno nezavisan** od **svih** ostalih čvorova u mreži, ako su dani (kao uvjet) **njegovi roditelji + djeca + roditelji djece**, tj. njegov **Markovljev pokrivač** — za X , označen sivo na slici



Primjer i grafovska interpretacija

Na primjer, ako znamo *Alarm* i *Earthquake*, onda je *Burglary* uvjetno nezavisan od *JohnCalls* i *MaryCalls*.



Intuitivno “objašnjenje” nezavisnosti i uvjetne nezavisnosti na “grafovskom” nivou — preko puteva u DAG:

nezavisnost dva čvora = ne postoji put između njih,

uvjetna nezavisnost X i Y , uz poznati dokaz Z

= dokaz Z prekida ili siječe put između X i Y , i to neovisno o smjeru puteva/strelica — kao da su neusmjereni putevi.

Smjer strelica označava samo kauzalnost veze, a pojam nezavisnosti je simetričan!

Nezavisnost i uvjetna nezavisnost — grafovski

Proširenje ove interpretacije na skupove varijabli (čvorova) X , Y i Z je očito.

Postoji opći “topološki” kriterij (algoritam) zvan **d-separacija** za otkrivanje je su li dva skupa čvorova X i Y uvjetno nezavisna obzirom na dani treći skup Z .

Za kratki opis, pogledati

MO-Web za UI, Predavanje 7 = Bayesove mreže, str. 27–28.

Konstrukcija Bayesovih mreža

Traži se metoda za **konstrukciju** Bayesove mreže tako da

- dobivena **združena** distribucija **dobro** prikazuje domenu (korektna globalna semantika),
- topologija mreže korektno odražava relacije **uvjetne nezavisnosti** među varijablama (korektna lokalna semantika).

Podloga je **lančano pravilo** za distribucije, pisano unatrag po varijablama

$$\mathbf{P}(X_1, \dots, X_n) = \prod_{i=1}^n \mathbf{P}(X_i | X_{i-1}, \dots, X_1).$$

Usporedba s relacijom iz **globalne** semantike

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

daje da za **svaku** varijablu X_i u mreži treba vrijediti

$$\mathbf{P}(X_i | X_{i-1}, \dots, X_1) = \mathbf{P}(X_i | \text{Parents}(X_i)).$$

Ova jednakost osigurava = **garantira globalnu** semantiku.

Konstrukcija Bayesovih mreža — nastavak

Da bismo zadovoljili zadnju jednakost

$$\mathbf{P}(X_i | X_{i-1}, \dots, X_1) = \mathbf{P}(X_i | \text{Parents}(X_i)),$$

za **početak**, treba biti

$$\text{Parents}(X_i) \subseteq \{X_{i-1}, \dots, X_1\}.$$

Dakle, čvorove (varijable) X_i treba numerirati u **poretku** koji je **konzistentan** s parcijalnim uređajem **implicitno** zadanim u strukturi grafa — odražava **kauzalne** veze.

Medjutim, to **nije** dovoljno za jednakost — fali još **nezavisnost**.

Bayesova mreža je **korektna** reprezentacija domene, samo ako je svaki čvor **uvjetno nezavisan** od svojih ostalih **prethodnika** (u poretku čvorova), uz **uvjet** da znamo njegove **roditelje** (kao dokaze).

Konstrukcija Bayesovih mreža — skica algoritma

Prethodni uvjet možemo zadovoljiti na sljedeći način:

1. **Čvorovi**: izaberi neki redosljed (uređaj) varijabli X_1, \dots, X_n
Bilo koji poredak je načelno dobar, ali mreža je **kompaktnija**, ako poštujemo **kauzalni** poredak — uzroci prethode efektima.
2. **Veze**: Za $i = 1$ do n
dodaj X_i u mrežu;
odaberi **minimalan** skup roditelja od X_i između X_1, \dots, X_{i-1}
takav da vrijedi $\mathbf{P}(X_i | \text{Parents}(X_i)) = \mathbf{P}(X_i | X_1, \dots, X_{i-1})$
dodaj u mrežu **vezu** od svakog **roditelja** na X_i ;
za čvor X_i , spremi **CPT** koja sadrži $\mathbf{P}(X_i | \text{Parents}(X_i))$.

Ova metoda garantira da nema ciklusa — dobivamo DAG.

Intuitivno, roditelji čvora X_i su oni čvorovi iz X_1, \dots, X_{i-1} koji **izravno utječu** na X_i (izravna kauzalnost) — ali **nije nužno!**

Primjer — neprirodan poredak

Pretpostavimo da smo uzeli poredak M, J, A, B, E


MaryCalls

JohnCalls

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

Primjer — neprirodan poredak

Pretpostavimo da smo uzeli poredak M, J, A, B, E




$P(J|M) = P(J)$? Ne

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

Primjer — neprirodan poredak

Pretpostavimo da smo uzeli poredak M, J, A, B, E



$P(J|M) = P(J)$? Ne


$P(A|J, M) = P(A|J)$? $P(A|J, M) = P(A)$? Ne

$P(B|A, J, M) = P(B|A)$?

$P(B|A, J, M) = P(B)$?

Primjer — neprirodan poredak

Pretpostavimo da smo uzeli poredak M, J, A, B, E



$$P(J|M) = P(J)? \quad \text{Ne}$$

$$P(A|J, M) = P(A|J)? \quad P(A|J, M) = P(A)? \quad \text{Ne}$$

$$P(B|A, J, M) = P(B|A)? \quad \text{Da}$$


$$P(B|A, J, M) = P(B)? \quad \text{Ne}$$

$$P(E|B, A, J, M) = P(E|A)?$$

$$P(E|B, A, J, M) = P(E|A, B)?$$

Primjer — neprirodan poredak

Pretpostavimo da smo uzeli poredak M, J, A, B, E



$P(J|M) = P(J)$? Ne

$P(A|J, M) = P(A|J)$? $P(A|J, M) = P(A)$? Ne


$P(B|A, J, M) = P(B|A)$? Da

$P(B|A, J, M) = P(B)$? Ne

$P(E|B, A, J, M) = P(E|A)$? Ne

$P(E|B, A, J, M) = P(E|A, B)$? Da

Primjer — neprirodan poredak, komentar



Odlučivanje o uvjetnoj nezavisnosti je teško u **nekauzalnim** smjerovima.

(Za ljude su kauzalni modeli i uvjetna nezavisnost čvrsto vezani!)

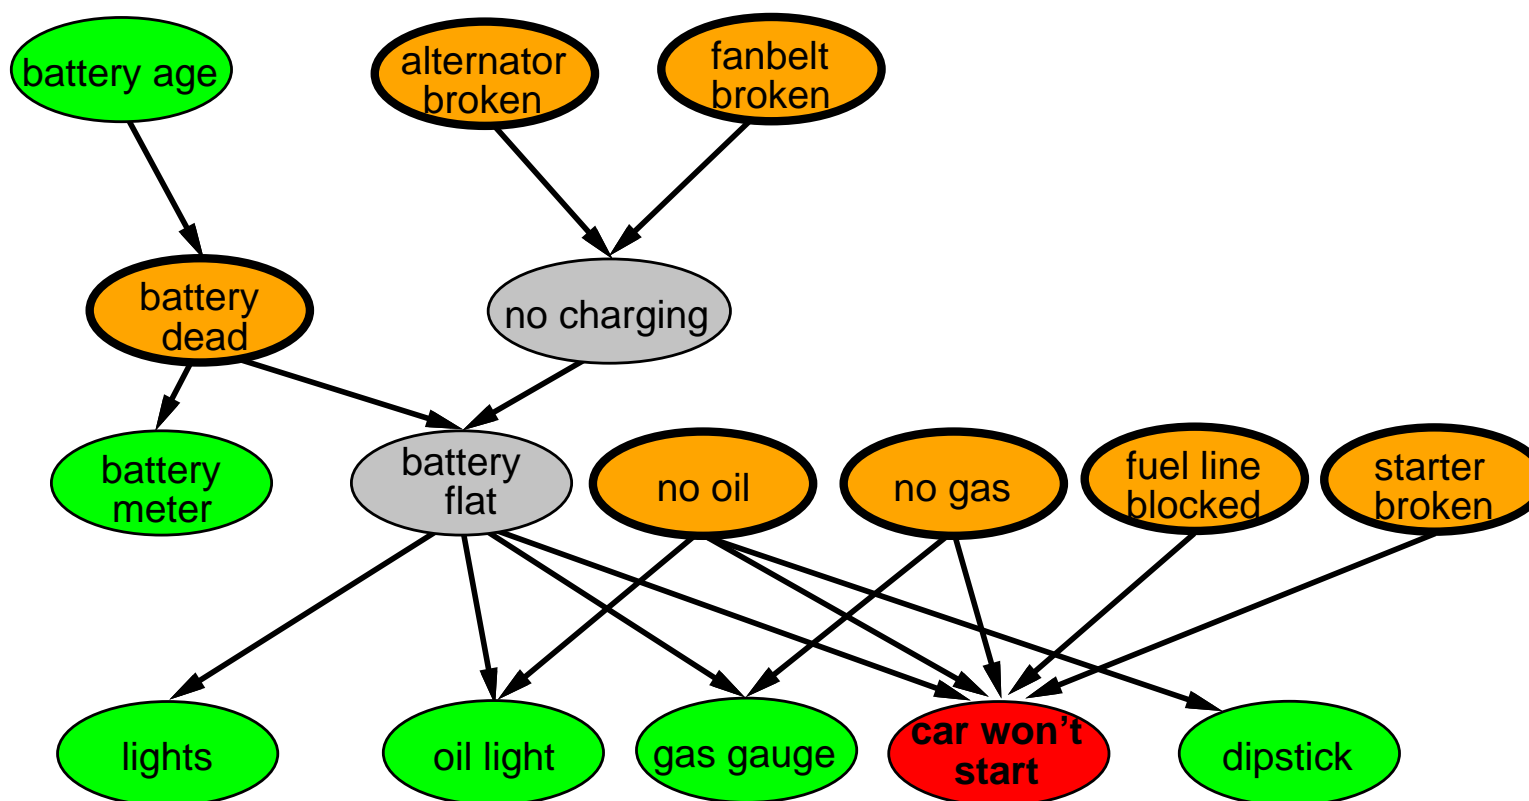
Procjena uvjetne vjerojatnosti je teška u **nekauzalnim** smjerovima.

Mreža je **manje** kompaktna: $1 + 2 + 4 + 2 + 4 = 13$ brojeva je potrebno.

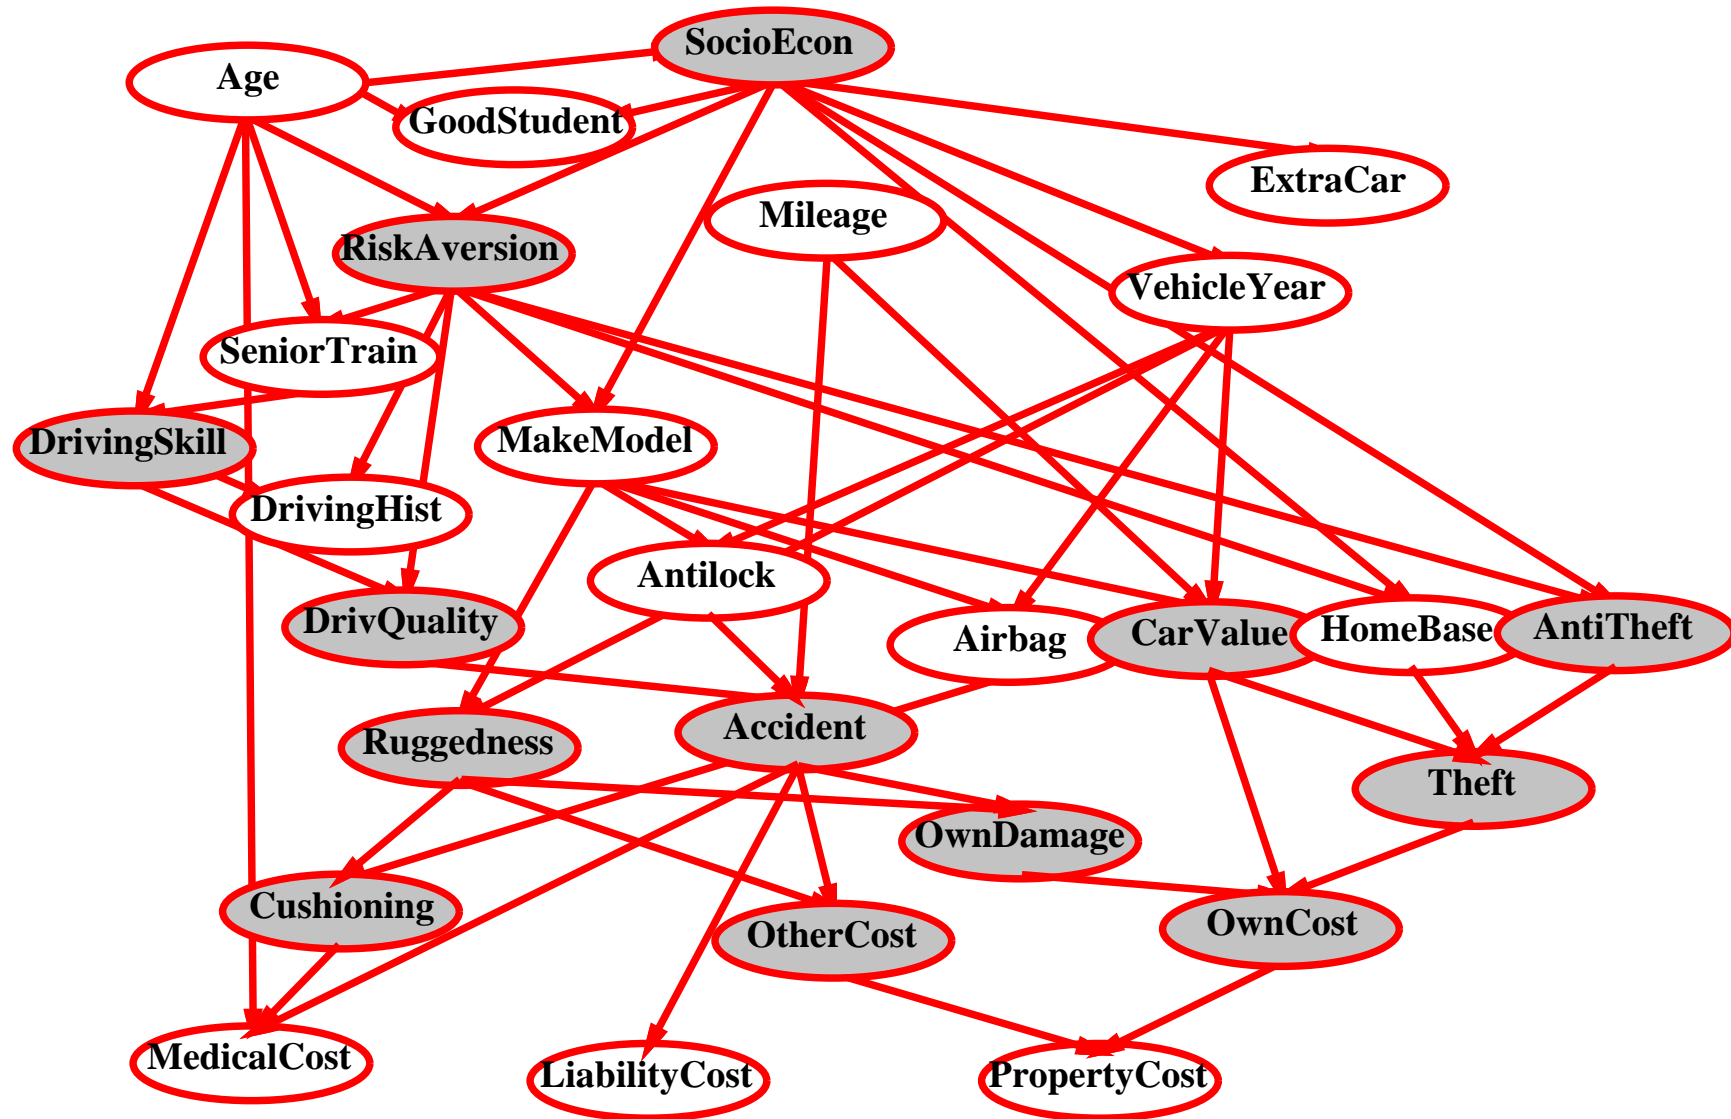
Primjer: dijagnoza kvara automobila

Početni “**dokaz**”: automobil ne želi startati.

Test-varijable (zeleno), “**pokvareno, popravi**” varijable (narančasto),
Skrivene varijable (sivo) daju rijetku strukturu, reduciraju parametre.



Primjer: osiguranje automobila



Sažeti prikaz uvjetnih distribucija

Problem: Veličina CPT raste eksponencijalno (2^k) s brojem roditelja k .
Ako su roditelj ili dijete neprekidne, CPT postaje beskonačna.

Rješenje: kanonske distribucije koje su sažeto (kompaktno) definirane,
prema nekom standardnom “predlošku”,
eventualno uz zadavanje nekoliko parametara.

Deterministički čvorovi su najjednostavniji slučaj:

$$X = f(\text{Parents}(X)) \text{ za neku funkciju } f.$$

Na primjer, Booleove funkcije

$$\text{NorthAmerican} \Leftrightarrow \text{Canadian} \vee \text{US} \vee \text{Mexican}$$

Na primjer, numeričke relacije među neprekidnim varijablama

$$\frac{\partial \text{Level}}{\partial t} = \text{inflow} + \text{precipitation} - \text{outflow} - \text{evaporation}$$

Sažeti prikaz uvjetnih distribucija — nastavak

Nesigurne (nedeterminističke) veze često se mogu opisati tzv. **logičkim** vezama “**sa šumom**” ili “**bukom**” (engl. “noisy”).

Standardni primjer je tzv. “**II-sa šumom**” (engl. “noisy-OR”) veza, kao generalizacija logičkog II.

II-sa šumom distribucija modelira višestruke nezavisne **uzroke** (nema međudjelovanja). **Pretpostavke** modela:

1. Roditelji U_1, \dots, U_k uključuju **sve** moguće uzroke. Ako neki uzroci **fale**, dodamo pomoćni čvor za njih (tzv. “leak node”).
2. **Izostanak** jednog uzroka je **nezavisan** od **izostanka** ostalih uzroka.

Trebamo samo vjerojatnosti **neuspjeha** q_i za svaki uzrok **zasebno**.

Za sve **kombinacije** uzroka onda vrijedi

$$P(X | U_1, \dots, U_j, \neg U_{j+1}, \dots, \neg U_k) = 1 - \prod_{i=1}^j q_i$$

Sažeti prikaz — primjer za ILI–sa šumom

Uzmimo da **samo** prehlada, gripa i malarija izazivaju groznicu.


Trebamo znati $q_i =$ **nemam** groznicu, a **imam točno jedan** od tri uzroka.

<i>Cold</i>	<i>Flu</i>	<i>Malaria</i>	$P(\text{Fever})$	$P(\neg \text{Fever})$
F	F	F	0.0	1.0
F	F	T	0.9	0.1
F	T	F	0.8	0.2
F	T	T	0.98	$0.02 = 0.2 \times 0.1$
T	F	F	0.4	0.6
T	F	T	0.94	$0.06 = 0.6 \times 0.1$
T	T	F	0.88	$0.12 = 0.6 \times 0.2$
T	T	T	0.988	$0.012 = 0.6 \times 0.2 \times 0.1$

Broj parametara je **linearan** u broju roditelja.

Hibridne (diskretne + neprekidne) mreže

Varijable: diskretne (*Subsidy?* i *Buys?*), neprekidne (*Harvest* i *Cost*).



Pristupi:

- Diskretizacija neprekidnih varijabli po intervalima — često izaziva velike greške, vrlo velike CPT.
- Kanonske familije neprekidnih f-a gustoće s konačno parametara.

Ovisno o tipu djece, trebamo dvije nove vrste uvjetnih distribucija:

1. Neprekidne varijable, diskretni+neprekidni roditelji (na pr. *Cost*)
2. Diskretne varijable, neprekidni roditelji (na pr. *Buys?*)

Neprekidne varijable djece

Za *Cost*: trebamo po **jednu uvjetnu funkciju gustoće** za varijablu-dijete **neprekidnih** roditelja, za **svaku** vrijednost **diskretnih** roditelja.

Najčešće se koristi **linearni Gaussov (LG) model**, na pr.:

$$\begin{aligned} P(\text{Cost} = c \mid \text{Harvest} = h, \text{Subsidy?} = \text{true}) \\ &= N(a_t h + b_t, \sigma_t^2)(c) \\ &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right) \end{aligned}$$

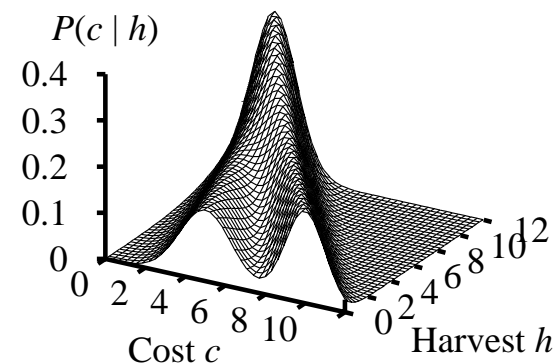


Analogno za *Subsidy? = false*, s parametrima a_f , b_f , σ_f .

Očekivanje za *Cost* varira **linearno** s *Harvest*, varijanca je **fiksna**.

Linearna varijacija očekivanja je **nerazumna** za cijeli raspon, ali radi **dobro** ako je **očekivani** raspon varijable *Harvest* **uzak**.

Neprekidne varijable djece — nastavak

Tri **uvjetne** distribucije $P(\text{Cost} | \text{Harvest})$ — za subsidy , $\neg\text{subsidy}$ i u prosjeku (a priori pola-pola, za subsidy i $\neg\text{subsidy}$):




Potpuno neprekidna mreža s LG distribucijama

⇒ potpuna zajednička distribucija je **multivarijantna Gaussova**.

Diskretna + neprekidna LG mreža je **uvjetno Gaussova** mreža, tj. multivarijantna **Gaussova** po svim **neprekidnim** varijablama, za **svaku** kombinaciju vrijednosti **diskretnih** varijabli.

Diskretne varijable s neprekidnim roditeljima

Vjerojatnost od *Buys?* za dani *Cost* trebala bi imati “meku” granicu:



Probit distribucija koristi integral Gaussove gustoće = f-a distribucije:

$$\Phi(x) = \int_{-\infty}^x N(0, 1)(x) dx$$


$$P(\text{Buys?} = \text{true} \mid \text{Cost} = c) = \Phi((-c + \mu)/\sigma).$$

Na slici je $P(\text{Buys?} = \text{false}) = 1 - \text{ovo iznad} = \Phi((c - \mu)/\sigma)$.

Zašto probit?

Probit = kratica za “probability unit”.

1. Ima **dobar** oblik — za **neprekidnu** vezu između vrijednosti 0 i 1.
2. Pogled = “**čvrsta**” granica, čija **lokacija** ovisi o Gaussovom “**šumu**”:



Odakle probit?

Definicija funkcije **probit**: Ako je Φ funkcija **distribucije** za $N(0, 1)$, funkcija **probit** je njezin **inverz**, tj. **probit** = Φ^{-1} — **nije** distribucija!

Razlog za primjenu na **diskretne** varijable s **neprekidnim** roditeljima:

Stvarno, imamo samo **dvije** vrijednosti za vjerojatnost: **0** i **1**, tj. imamo “**čvrstu**” ili “**oštru**” granicu = stepenasta ili **Heavisideova** funkcija.

Traži se “**omekšanje**” ove **skokovite** granice za vrijednost Y
= **neprekidna** veza (“**fitting**”) između dvije **diskretne** granice.

Ideja: linearizirati **zavisnu** varijablu Y nekom funkcijom $F : [0, 1] \rightarrow \mathbf{R}$, a zatim naći **pravac** koji je odgovarajuća aproksimacija (fitting)

$$F(Y) = \text{pravac u } X,$$

i onda “**vratiti**” aproksimaciju u $Y = F^{-1}(\text{pravac})$.


Vrlo **prirodan** izbor je baš $F = \Phi^{-1}$, pa je $Y = \Phi(\text{pravac})$.

Diskretne varijable s nepr. roditeljima — nastavak

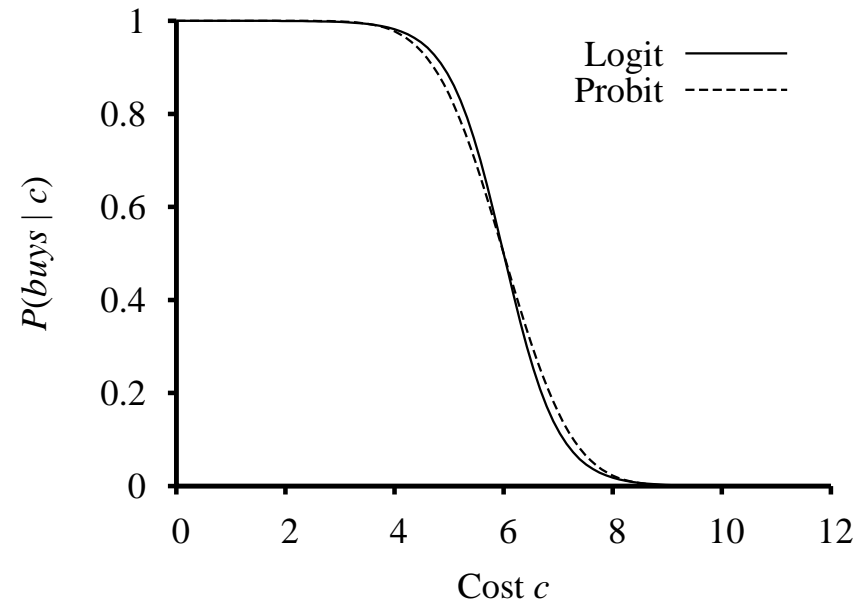

Sigmoidna ili **logit** distribucija, $F^{-1} = 1/(1 + e^{-x})$, često se koristi u neuralnim mrežama:

$$P(\text{Buys?} = \text{true} \mid \text{Cost} = c) = \frac{1}{1 + \exp\left(-2\frac{-c+\mu}{\sigma}\right)}$$

Logit distribucija ima **sličan** oblik kao probit, ali mnogo **dulje repove**:



Diskretne varijable s nepr. roditeljima — nastavak



Normalna (Gaussova) distribucija za granicu cijene $Cost = c$,
s očekivanjem $\mu = 6.0$ i standardnom devijacijom $\sigma = 1.0$,

Logit i probit distribucije za vjerojatnost $P(Buys? = true | Cost = c)$,
s parametrima $\mu = 6.0$ i $\sigma = 1.0$.

Sažetak

Bayesove mreže daju prirodnu reprezentaciju uzročno induciranih uvjetnih nezavisnosti

Topologija + CPT = sažeta reprezentacija zajedničke distribucije

Općenito jednostavno i (ne)ekspertima za konstrukciju

Kanonske (standardne) distribucije (na pr., ILL-sa šumom) = sažeta reprezentacija CPT

Neprekidne varijable \Rightarrow parameterizirane distribucije (na pr., linearna Gaussova)