

NESIGURNOST/NEIZVJESNOST

POGLAVLJE 13

Prema slajdovima Stuarta Russella (hvala)!

Sadržaj

- ◇ Nesigurnost ili neizvjesnost (engl. uncertainty), nepouzdanost
- ◇ Vjerojatnost
- ◇ Sintaksa i semantika
- ◇ Zaključivanje ili rasuđivanje (engl. inference)
- ◇ Nezavisnost i Bayesovo pravilo

Nesigurnost

Neka je akcija A_t = odlazak na aerodrom t minuta prije leta
Hoće li me A_t dovesti tamo na vrijeme?

Problemi:

- 1) parcijalno opažanje (stanje puteva, planovi drugih vozača, itd.)
- 2) senzori sa “šumom” (radio izvještaji o prometu)
- 3) slučajnosti u ishodu (probušena guma na autu i sl.)
- 4) ogromna složenost modeliranja i predviđanja prometa

Stoga, **čisto logički** pristup može dovesti do

- rizika **neistinitosti**: “ A_{90} će me dovesti na vrijeme”
- zaključaka koji su **preslabi** za odluku:

“ A_{90} će me dovesti na vrijeme, ako **nema nesreće** na mostu
i ako **ne pada** kiša i moje gume **ostanu** u dobrom stanju, itd.”

Nesigurnost — nastavak

S druge strane, za A_{1440} može se sa razumnom **sigurnošću** reći da ću **stići na vrijeme**, ali, to znači da moram **prenoćiti** na aerodromu . . .

Dakle, to nije razumna odluka!

U nekom smislu, A_{90} je **razumna** akcija prema nekoj “mjeri uspješnosti”, kad sve uzmem u obzir, (moje/agentove preferencije na bazi znanja o okolini) iako ništa **ne garantira** dobar ishod.

Metode za postupanje s nesigurnostima

Uobičajena ili nemonotona logika (kvalitativno razmišljanje):

Pretpostavi da moj auto nema praznu gumu

Pretpostavi da A_{90} radi, osim ako ne postoji dokazana kontradikcija

Ideja: Vjerujem, dok ne nađem bolji razlog da vjerujem u nešto drugo.

Problemi:

Koje su pretpostavke razumne? Kako se nositi s kontradikcijom?

Pravila s izmišljenim faktorima (engl. “fudge factors”):

$A_{25} \mapsto_{0.3} NaAerodromuNaVrijeme$

$Prskalica \mapsto_{0.99} MokraTrava$

$MokraTrava \mapsto_{0.7} Kiša$

Problemi:

Kombinacije pravila, na primjer, $Prskalica$ uzrokuje $Kiša$??

Metode za postupanje s nesigurnostima — nastavak

Vjerojatnost

Obzirom na raspoložive dokaze (engl. “evidence”),

A_{25} će me dovesti na vrijeme s vjerojatnošću 0.04

Mahaviracarya (9. st.), Cardano (1565.g.) teorija kockanja

Neizrazita ili neodređena logika (engl. “fuzzy logic”)

koristi **stupanj istinitosti**, a **NE nesigurnost** (okomiti pojmovi), t.j.,

MokraTrava je istinito sa stupnjem 0.2.

Ima još pristupa:

Bayesove vjerojatnosti (subjektivno vjerovanje agenta)

Teorija preferencija (bazirana na usporedbama)

Dempster–Shafer teorija neznanja (interval za stupanj vjerovanja)

...

(v. RN, poglavlje 14.7)

Nesigurno (nepouzđano) znanje — uzroci

Osnovni uzrok = nepotpuna slika svijeta (okoline)

- pomanjkanje relevantnih činjenica,
- pomanjkanje “logičke” kategoričnosti (istina/laž)

Znanje o okolini nije potpuno iz raznih razloga:

greške: netočnost u percepciji, mjerenjima

lijenost: nabranje svih mogućih slučajeva, iznimki, pravila
je nemoguće ili traži previše resursa

neznanje:

nedovoljno (manjkavo) teorijsko poznavanje domene
(medicina, ekonomija, industrija, ...)

manjak podataka (čak i kad imamo “svo znanje”)

Nesigurno (nepouzđano) znanje — odluke, akcije

I dalje treba donositi **racionalne** (razumne) odluke i akcije.

Podloga za odluke i akcije:

- relativna **vaŹnost** ciljeva (mjera uspješnosti)
uključivo i negativni efekt nekih mogućih posljedica
- **izglednost** (vjerojatnost/očekivanje) ostvarenja tih ciljeva

Prednost teorije **vjerojatnosti** = bliska veza s **logičkim** zaključivanjem

- ontološko poimanje svijeta je **isto** — **činjenice**
- epistemologija je **različita**
umjesto **laŹ/istina** + ev. nepoznato (diskretno),
numerički stupanj uvjerenja — **između 0** (laŹ) i **1** (istina)

Vjerojatnost

Vjerojatnosne tvrdnje daju **zbirni** ili **sažeti** efekt

lijenosti: neuspjeha u nabranju iznimki, kvalifikacija, i dr.

neznanja: pomanjkanja relevantnih činjenica, početnih uvjeta i dr.

Subjektivna ili **Bayesova** vjerojatnost:

vjer. izjava se odnosi na vlastito **stanje znanja**, a **ne** na stvarni svijet.

Na primjer, ako ništa dodatno ne znam (na samom početku), onda je

$$P(A_{25}) = 0.04.$$

Međutim, ako znam da nema izvještaja o nesreći na putu, onda je

$$P(A_{25} | \text{nema izvještaja o nesreći}) = 0.06$$

To **nisu** tvrdnje o “vjerojatnosnoj tendenciji” u trenutnoj situaciji (ali može se učiti iz stečenog iskustva u sličnim situacijama)

Vjerojatnost — nastavak

Vjerojatnosti tvrdnji **mijenjaju** se s **novim dokazima**.

Na primjer, ako još znamo i da je 5 sati ujutro (mali promet), onda je

$$P(A_{25} | \text{nema izvještaja o nesreći, 5 ujutro}) = 0.15$$

Ovo je analogno statusu logičke posljedice $KB \models \alpha$, a **ne** istinitosti.

Prethodne izjave **nisu** međusobno **kontradiktorne**, već se odnose na **drugačija stanja znanja**.

Usput, ovi primjeri ilustriraju važnost pojma **uvjetne vjerojatnosti**.

Odlučivanje uz nesigurnosti

Pretpostavimo da vjerujem u sljedeće:

$$P(A_{25} \text{ će me dovesti na vrijeme} | \dots) = 0.04$$

$$P(A_{90} \text{ će me dovesti na vrijeme} | \dots) = 0.70$$

$$P(A_{120} \text{ će me dovesti na vrijeme} | \dots) = 0.95$$

$$P(A_{1440} \text{ će me dovesti na vrijeme} | \dots) = 0.9999$$

Koju akciju izabrati?

Ovisi o mojim **preferencijama** između mogućih ishoda raznih planova: propušteni let, prema spavanju na aerodromu, kuhinji, itd.

Za predstavljanje preferencija i zaključivanje na osnovu njih koristimo **teoriju korisnosti** (engl. “utility theory”)

Svako stanje ima neki stupanj korisnosti (vrijednosti) za danog agenta.

Teorija odlučivanja = teorija korisnosti + teorija vjerojatnosti

Osnove vjerojatnosti — diskretni događaji

Krećemo od skupa Ω — prostor elementarnih događaja/uzoraka (engl. “sample space”)

na primjer, 6 mogućih ishoda bacanja kocke.

Element $\omega \in \Omega$ je točka uzorka/mogući svijet/elem. ili atomski događaj.

Prostor vjerojatnosti ili vjerojatnosni model je prostor el. događaja Ω , s dodjeljivanjem vjerojatnosti $P(\omega)$ za svaki $\omega \in \Omega$, tako da je

$$0 \leq P(\omega) \leq 1 \quad \text{i} \quad \sum_{\{\omega \in \Omega\}} P(\omega) = 1.$$

Na primjer, $P(1) = P(2) = P(3) = P(4) = P(5) = P(6) = 1/6$.

Događaj A je bilo koji podskup od Ω , a njegova vjerojatnost je

$$P(A) = \sum_{\{\omega \in A\}} P(\omega).$$

Na primjer,

$$P(\text{pao broj} < 4) = P(1) + P(2) + P(3) = 1/6 + 1/6 + 1/6 = 1/2.$$

Slučajne varijable

Slučajna varijabla je funkcija iz prostora Ω u neki skup (kodomen).
Na primjer, u

skup realnih brojeva, ili

logičke vrijednosti $\{false, true\}$ — Booleova slučajna varijabla.

Na primjer, funkcija *Odd* (neparan), pa je $Odd(1) = true$.

Vjerojatnost P inducira distribuciju vjerojatnosti za bilo koju slučajnu varijablu X :

$$P(X = x_i) = \sum_{\{\omega : X(\omega) = x_i\}} P(\omega).$$

Na primjer,

$$P(Odd = true) = P(1) + P(3) + P(5) = 1/6 + 1/6 + 1/6 = 1/2.$$

Propozicije (sudovi) — veza s logikom

Zamislimo **propoziciju** (izjavu, sud) kao **događaj**

= skup svih elementarnih događaja gdje je izjava **istinita**.

Za zadane Booleove slučajne varijable A and B :

događaj a = skup elementarnih događaja gdje je $A(\omega) = true$

događaj $\neg a$ = skup elementarnih događaja gdje je $A(\omega) = false$

događaj $a \wedge b$ = točke gdje je $A(\omega) = true$ i $B(\omega) = true$

U primjenama UI, vrlo često se elementarni događaji **definiraju** kao **vrijednosti** nekog skupa **slučajnih varijabli**,

tj. skup elementarnih događaja je zapravo

Kartezijev produkt kodomena (slika) slučajnih varijabli (a ne Ω).

Veza vjerojatnosti i logike sudova

Kad su slučajne varijable **Booleove**,
elementarni događaj (točka uzorka) = **model** za logiku sudova.

Na primjer, $A = true$, $B = false$, ili skraćeno $a \wedge \neg b$.

Uočiti (može i preko DNF):

Propozicija = **disjunkcija** elementarnih događaja u kojima je **istinita**.

Posljedica: pripadne vjerojatnosti se **zbrajaju** — po definiciji!

Za “slučajne” varijable $True$, $False$ vrijedi $P(true) = 1$, $P(false) = 0$.

Na primjer,

$$(a \vee b) \equiv (\neg a \wedge b) \vee (a \wedge \neg b) \vee (a \wedge b)$$

odakle slijedi

$$P(a \vee b) = P(\neg a \wedge b) + P(a \wedge \neg b) + P(a \wedge b)$$


Zašto koristimo vjerojatnost?

Definicije vjerojatnosti povlače da

određeni logički vezani događaji moraju imati vezane vjerojatnosti.

Na primjer, $P(a \vee b) = P(a) + P(b) - P(a \wedge b)$, (Kolmogorov)

True



Posebno, za $b = \neg a$ dobivamo $P(\neg a) = 1 - P(a)$.

de Finetti (1931): ako se agent kladi prema “vjerojatnostima” koje krše ove aksiome, onda može biti natjeran da se kladi tako da gubi novce, neovisno o ishodu (postoji odgovarajuća kombinacija oklada, v. RN).

Sintaksa (zapis) propozicija — u vjerojatnosti

Slučajne varijable X — oznaka **velikim** slovom.

Moguće vrijednosti (za diskretne varijable) — oznaka **malim** slovom.

Propozicijske ili **Booleove** slučajne varijable

na pr., *Cavity* (imam li rupu u zubu = engl. cavity?)

Cavity = true je propozicija, kratki zapis je *cavity*.

Diskretne slučajne varijable (**konačne** ili **beskonačne** = prebrojive)

na pr., *Weather* je jedno iz skupa $\{sunny, rain, cloudy, snow\}$

Weather = rain je propozicija, kratki zapis je *rain*.

Vrijednosti moraju biti sveobuhvatne i međusobno različite.

Neprekidne slučajne varijable (**ograničene** ili **neograničene**)

na pr., *Temp = 21.6*, a dozvoljeno je i *Temp < 22.0*.

Događaji u UI su propozicije — zadaju se proizvoljnim Booleovim kombinacijama osnovnih propozicija.

Početna (a priori) vjerojatnost

Početna (prethodna) ili bezuvjetna vjerojatnost propozicija (engl. “prior”, “unconditional”)

odgovara uvjerenju u nedostatku bilo kakvih dodatnih informacija, prije saznanja bilo kakvih (novih) “dokaza”.

Na pr., $P(\textit{Cavity} = \textit{true}) = 0.2$ i $P(\textit{Weather} = \textit{sunny}) = 0.72$

Distribucija vjerojatnosti za slučajnu varijablu X , oznaka $\mathbf{P}(X)$, daje vrijednosti vjerojatnosti za sve moguće ishode.

Zapis: poredamo sve moguće elementarne događaje u vektor

$\langle \textit{sunny}, \textit{rain}, \textit{cloudy}, \textit{snow} \rangle$

i distribuciju vjerojatnosti pišemo kao vektor

$\mathbf{P}(\textit{Weather}) = \langle 0.72, 0.1, 0.08, 0.1 \rangle$

(vektor mora biti normaliziran, tj., suma vrijednosti je 1).

Združena (zajednička) distribucija vjerojatnosti

Kad imamo **više** slučajnih varijabli, **združena** ili **zajednička distribucija vjerojatnosti** (engl. “joint probability distribution”) daje vjerojatnost na **Kartezijevom** produktu pripadnih skupova elementarnih događaja.

Oznaka: $\mathbf{P}(X_1, \dots, X_n)$.

Na primjer, $\mathbf{P}(Weather, Cavity) = 4 \times 2$ tablica vrijednosti:

<i>Weather =</i>	<i>sunny</i>	<i>rain</i>	<i>cloudy</i>	<i>snow</i>
<i>Cavity = true</i>	0.144	0.02	0.016	0.02
<i>Cavity = false</i>	0.576	0.08	0.064	0.08

Uočiti: $\mathbf{P}(Weather, Cavity) = \mathbf{P}(Weather) \cdot \mathbf{P}(Cavity)$ zbog **nezavisnosti** pripadnih događaja (v. malo kasnije).

Napomena: produkt \cdot je množenje vektora **po točkama**, **svaki sa svakim**. (Kroneckerov, direktni ili tenzorski produkt). Nadalje, **ne** pišemo “ \cdot ”.

Potpuna združena distribucija vjerojatnosti

Potpuna (ili cijela) združena distribucija vjerojatnosti (engl. “full joint distribution”)

je zajednička distribucija za **sve** slučajne varijable u problemu.

Potpuna združena distribucija daje **odgovor** na **svako pitanje** o domeni — svaki događaj je “suma” elementarnih događaja.

Zvuči dobro, ali za sve iole veće probleme — tablica je **ogromna!**

Naime,


veličina tablice = **produkt** broja mogućih vrijednosti svake varijable, tj. $\prod_{i=1}^n \text{card } X_i(\Omega)$.

Ilustracija malo kasnije.

Vjerojatnost za neprekidne varijable

Izrazimo vjerojatnost kao funkciju vrijednosti slučajne varijable:

$$P(X = x) = U[18, 26](x) = \text{uniformna gustoća između } 18 \text{ i } 26$$



Ovdje je P funkcija gustoće vjerojatnosti — njezin integral je 1.


$P(X = 20.5) = 0.125$ stvarno znači

$$\lim_{dx \rightarrow 0} P(20.5 \leq X \leq 20.5 + dx) / dx = 0.125$$

Gaussova gustoća

Normalna razdioba $N(\mu, \sigma^2)$,
s očekivanjem μ i standardnom devijacijom σ

$$P(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2}$$



Uvjetna (naknadna, a posteriori) vjerojatnost

Uvjetna ili naknadna vjerojatnost (engl. “conditional”, “posterior”):
imamo neku dodatnu informaciju (dokaz) koju smo već otkrili
i tražimo vjerojatnost događaja uz uvjet da je ta informacija poznata.

Oznaka: $P(\text{događaj} | \text{poznato})$.

Na pr., znam da me boli zub (tj. vrijedi *toothache*), pa je
 $P(\text{cavity} | \text{toothache}) = 0.8$.

Točno značenje ovog je:

“uz uvjet da je *toothache* sve što znam, onda ...”,
a ne implikacija: “ako *toothache*, onda imam 80% šanse za *cavity*”.

Ranije, manje određeno uvjerenje $P(\text{cavity}) = 0.2$ još uvijek vrijedi
i nakon što se “dokaz” *toothache* pojavio,
samo više nije naročito korisno (jer imamo dodatne informacije).

Uvjetna vjerojatnost

Ako znamo još više, na pr. odemo kod zubara i on **nađe rupu** u zubu, tj. vrijedi *cavity*, onda je

$$P(\textit{cavity}|\textit{toothache} \wedge \textit{cavity}) = 1.$$

Umjesto veznika \wedge , ponekad samo **nabrajamo** dodatne informacije

$$P(\textit{cavity}|\textit{toothache}, \textit{cavity}) = 1.$$

Novi dokazi mogu biti **irelevantni**, što dozvoljava pojednostavljenje

$$P(\textit{cavity}|\textit{toothache}, \textit{pobjedaXY}) = P(\textit{cavity}|\textit{toothache}) = 0.8$$

Ovaj oblik zaključivanja, na bazi **poznavanje** domene, je bitan!

Napomena: sličnu oznaku koristimo i za **uvjetne distribucije**:

$$\mathbf{P}(\textit{Cavity}|\textit{Toothache})$$

Ovo je **vektor** s 2 elementa, a svaki **element** je opet **vektor** s 2 elementa. Dakle, vektor s 4 broja = vjerojatnosti.

Uvjetna vjerojatnost — produktno pravilo

Definicija uvjetne vjerojatnosti:

$$P(a|b) = \frac{P(a \wedge b)}{P(b)}, \quad \text{ako je } P(b) \neq 0.$$

Vjerojatnost za $a \wedge b$ se “skalira” na domenu u kojoj vrijedi b .

Alternativna formulacija je **pravilo produkta** — pisano u dva oblika:

$$P(a \wedge b) = P(a|b)P(b) = P(b|a)P(a).$$

Združene i uvjetne distribucije — produktno pravilo

Proširenje zapisa vrijedi i za združene distribucije vjerojatnosti. Na pr.,

$$\mathbf{P}(Weather, Cavity) = \mathbf{P}(Weather|Cavity) \mathbf{P}(Cavity)$$

Ovo gledamo kao skup od 4×2 jednačbe, **ne** kao množenje matrica!

Lančano pravilo izlazi višestrukom primjenom pravila produkta:

$$\begin{aligned} \mathbf{P}(X_1, \dots, X_n) &= \mathbf{P}(X_1, \dots, X_{n-1}) \mathbf{P}(X_n|X_1, \dots, X_{n-1}) \\ &= \mathbf{P}(X_1, \dots, X_{n-2}) \mathbf{P}(X_{n-1}|X_1, \dots, X_{n-2}) \\ &\quad \mathbf{P}(X_n|X_1, \dots, X_{n-1}) \\ &= \dots \\ &= \prod_{i=1}^n \mathbf{P}(X_i|X_1, \dots, X_{i-1}) \end{aligned}$$

Prvi faktor u produktu je samo $\mathbf{P}(X_1)$.

Zaključivanje enumeracijom (pobrojavanjem)

Najjednostavnija metoda za **probabilističko** zaključivanje bazira se na **potpunoj združenoj distribuciji** svih varijabli (= baza znanja)

i svodi se (doslovno) na

pobrojavanje svih mogućnosti iz upita i

zbrajanje pripadnih vjerojatnosti (uz eventualnu normalizaciju).

Primjer: imamo samo **3** Booleove slučajne varijable

Toothache — boli me zub

Catch — zubarska čelična proba se “zakači” u zubu (to boli)

Cavity — imam rupu u zubu.

Dakle, potpuna združena distribucija ima $2 \times 2 \times 2 = 8$ vrijednosti.

Pišemo ih u obliku **tablice**, a ne vektora.

Zbroj svih vrijednosti je (naravno) jednak **1**.

Zaključivanje enumeracijom

Početak = potpuna združena distribucija:

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

Za bilo koju propoziciju ϕ , zbroji elementarne događaje gdje je istinita:

$$P(\phi) = \sum_{\omega \in \phi} P(\omega)$$

Preciznije bi bilo pisati domenu sumacije kao $\{\omega : \omega \models \phi\}$.

Međutim, elementarni događaji su elementi **Kartezijevog produkta** svih mogućih vrijednosti slučajnih varijabli (ima ih 8),

a propozicija je neki **događaj** = **podskup** u tom produktu.

Zaključivanje enumeracijom

Početak = potpuna združena distribucija:

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

Za bilo koju propoziciju ϕ , zbroji elementarne događaje gdje je istinita:

$$P(\phi) = \sum_{\omega \in \phi} P(\omega)$$

Vjerojatnosti za pojedinačne vrijednosti varijabli:

$$P(\textit{toothache}) = 0.108 + 0.012 + 0.016 + 0.064 = 0.2$$

$$P(\textit{cavity}) = 0.108 + 0.012 + 0.072 + 0.008 = 0.2$$

Tzv. **marginalizacija** = sumiranje po **svim** vrijednostima ostalih varijabli (= eliminacija tih varijabli iz jednadžbe).

Zaključivanje enumeracijom

Početak = potpuna združena distribucija:

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

Za bilo koju propoziciju ϕ , zbroji elementarne događaje gdje je istinita:

$$P(\phi) = \sum_{\omega \in \phi} P(\omega)$$

$$P(\text{cavity} \vee \text{toothache})$$

$$= 0.108 + 0.012 + 0.072 + 0.008 + 0.016 + 0.064 = 0.28$$

Zaključivanje enumeracijom

Početak = potpuna združena distribucija:

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

Možemo izračunati i **uvjetne** vjerojatnosti (uz dane **dokaze**):

$$\begin{aligned}
 P(\neg cavity | toothache) &= \frac{P(\neg cavity \wedge toothache)}{P(toothache)} \\
 &= \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = \frac{0.08}{0.2} \\
 &= 0.4
 \end{aligned}$$

Normalizacija vjerojatnosti

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

Uvjetna distribucija varijable *Cavity*, uz uvjet (dokaz) *toothache*
 – **ne treba** izračunati $P(\text{toothache})$ u nazivniku!

Nazivnik = **normalizacijska konstanta** α , tako da **zbroj** bude jednak 1:

$$\begin{aligned}
 P(Cavity|toothache) &= \alpha P(Cavity, toothache) \\
 &= \alpha [P(Cavity, toothache, catch) + P(Cavity, toothache, \neg catch)] \\
 &= \alpha [\langle 0.108, 0.016 \rangle + \langle 0.012, 0.064 \rangle] = \alpha \langle 0.12, 0.08 \rangle \\
 &= \{ \text{normalizacija na zbroj} = 1, \alpha = 5 \} = \langle 0.6, 0.4 \rangle
 \end{aligned}$$

Zaključivanje enumeracijom — nastavak

Interesantno za **praksu**: **uvjetna združena distribucija** nekih varijabli, uz dane **dokaze** (fiksne vrijednosti) za neke druge varijable.

Ideja: fiksiraj **dokaze** i **zbroji** preko svih ostalih (tzv. **skrivenih**) varijabli.

Neka je

X popis **traženih varijabli** iz upita (*Cavity* u primjeru).

E popis **dokaznih** varijabli (*Toothache* u primjeru) i

e popis njihovih opaženih (**dokaznih**) vrijednosti (*toothache*).

Y popis svih preostalih (neopaženih = skrivenih) varijabli (samo *Catch* u primjeru).

Upit je $P(\mathbf{X}|\mathbf{e})$ i može se izračunati kao **zbroj** (uz normalizaciju na 1):

$$P(\mathbf{X}|\mathbf{e}) = \alpha P(\mathbf{X}, \mathbf{e}) = \alpha \sum_{\mathbf{y}} P(\mathbf{X}, \mathbf{e}, \mathbf{y})$$

gdje suma ide po **svim** mogućim kombinacijama vrijednosti neopaženih varijabli **Y** (**eliminacija** skrivenih varijabli, sumiranjem po njima).

Zaključivanje enumeracijom — kraj i problemi

Zašto to radi? \mathbf{X} , \mathbf{E} , i \mathbf{Y} su **sve** varijable u domeni, pa se $\mathbf{P}(\mathbf{X}, \mathbf{e}, \mathbf{y})$ naprosto “čitaju” iz potpune združene distribucije!

Oznake:

n = broj varijabli (u praksi je lako $n \geq 100$)

d = najveći broj mogućih vrijednosti neke varijable (Boole $d \geq 2$)

Veličina tablice potpune združene distribucije je $O(d^n)$.

Očiti problemi = **složenost!**

1. Vremenska složenost (najgori slučaj) je $O(d^n)$.
2. Prostorna složenost je opet $O(d^n)$ za **spremanje** tablice.

Najveći problem — tablica **nije** prirodna:

3. Kako **naći** tih $O(d^n)$ brojeva u tablici???

Naime, u tablici (potpune) združene distribucije “svi brojevi su **isti**”
– **nije jasno** što je **uzrok**, a što **posljedica** veze među varijablama.

Nezavisnost

U praksi — nisu **sve** varijable **uzajamno** “uvjetno” vezane neki **događaji** su **nezavisni**, neke **varijable** su **nezavisne**.

Događaji a i b su **nezavisni** ako i samo ako

$$P(a|b) = P(a) \quad \text{ili} \quad P(b|a) = P(b) \quad \text{ili} \quad P(a \wedge b) = P(a)P(b)$$

Varijable X i Y su **nezavisne** ako i samo ako

$$\mathbf{P}(X|Y) = \mathbf{P}(X) \quad \text{ili} \quad \mathbf{P}(Y|X) = \mathbf{P}(Y) \quad \text{ili} \quad \mathbf{P}(X, Y) = \mathbf{P}(X) \mathbf{P}(Y)$$

Primjer: ranijim varijablama *Toothache*, *Catch*, *Cavity*, dodamo još i varijablu *Weather*, s 4 vrijednosti (od prije).

Potpuna združena distribucija


$$\mathbf{P}(\textit{Toothache}, \textit{Catch}, \textit{Cavity}, \textit{Weather})$$

onda ima $2 \times 2 \times 2 \times 4 = 8 \times 4 = 32$ vrijednosti.

Nezavisnost

Međutim, teško da moji zubni problemi imaju **utjecaja** na vrijeme. Dakle, *Weather* je **nezavisna** od ostale tri varijable, pa je

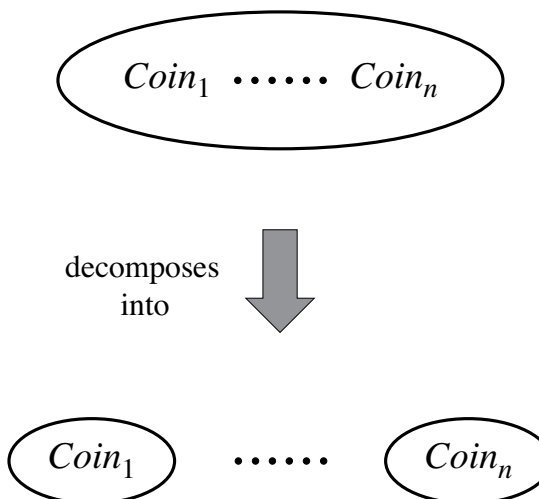
$$\begin{aligned} & \mathbf{P}(Toothache, Catch, Cavity, Weather) \\ &= \mathbf{P}(Weather) \mathbf{P}(Toothache, Catch, Cavity) \end{aligned}$$



Tablica potpune združene distribucije se “**faktorizira**” u **produkt** tablica
– umjesto $8 \times 4 = 32$ vrijednosti, **dovoljno** je pamtiti $8 + 4 = 12$.

Nezavisnost i faktORIZACIJA

Za n nezavisnih bacanja n novčića (svaki ima svoju distribuciju), imamo potpunu faktORIZACIJU, $2^n \rightarrow 2n$. Za iste novčiće, samo 2.



Apsolutna nezavisnost je vrlo **jako** svojstvo — ali **rijetko** u praksi.

Na pr., zubarstvo — ima na desetke bolesti i stotine simptoma, i sve varijable su međusobno **vezane** — **nema nezavisnih!**

Što činiti? Treba nam “**blaži**” koncept nezavisnosti.

Bayesovo pravilo (teorem)

Kod definicije **uvjetne** vjerojatnosti imali smo dva **pravila produkta**:

$$P(a \wedge b) = P(a|b)P(b) = P(b|a)P(a).$$

Iz zadnje jednakosti dobivamo vezu **uvjetnih** vjerojatnosti

$$P(b|a) = \frac{P(a|b)P(b)}{P(a)}$$

koja se zove **Bayesovo pravilo** (teorem). Ova jednadžba je u pozadini većine modernih sustava za **probabilističko zaključivanje** u UI.

Zapis u obliku distribucija vjerojatnosti za slučajne varijable je

$$\mathbf{P}(Y|X) = \frac{\mathbf{P}(X|Y) \mathbf{P}(Y)}{\mathbf{P}(X)} = \alpha \mathbf{P}(X|Y) \mathbf{P}(Y)$$

gdje je α normalizacijska konstanta (da zbroj bude 1).

Bayesovo pravilo — nastavak

Prošireni “uvjetni” oblik pravila, uz “dokaze” e (poznate vrijednosti)

$$P(Y|X, e) = \frac{P(X|Y, e) P(Y|e)}{P(X|e)}$$

Ovo su samo **skraćeni** zapisi cijelog **sustava** jednadžbi (množenje i dijeljenje su po elementima, nema dijeljenja vektora).

Jednostavna primjena pravila — na pr., u medicini:

često, kao dokaz, opažamo **efekt** nekog **nepoznatog uzroka** i želimo **otkriti** uzrok.

Oznake: *effect* = efekt (simptomi), *cause* = uzrok (bolest),
 $P(\textit{effect}|\textit{cause})$ = vjerojatnost u **kauzalnom (uzročnom)** smjeru,
 $P(\textit{cause}|\textit{effect})$ = vjerojatnost u **dijagnostičkom** smjeru.

Primjena Bayesovog pravila — za dijagnostiku

Nalaženje **dijagnostičke** vjerojatnosti iz **kauzalne** vjerojatnosti:

$$P(\textit{cause}|\textit{effect}) = \frac{P(\textit{effect}|\textit{cause})P(\textit{cause})}{P(\textit{effect})}$$

Na primjer, neka je M = meningitis, a S = ukočen vrat, i doktor zna:

$P(s|m) = 0.7$ — meningitis često izaziva ukočen vrat,

$P(m) = 1/50000$ — beuvjetna vjerojatnost za meningitis je mala,

$P(s) = 0.01$ — ukočeni vrat je mnogo češći.

Dijagnostika: imam ukočen vrat, kolika je vjerojatnost da imam meningitis

$$P(m|s) = \frac{P(s|m)P(m)}{P(s)} = \frac{0.7 \times 1/50000}{0.01} = 0.0014$$

Napomena: naknadna vjerojatnost za meningitis je još uvijek vrlo mala (samo oko 1 od 700 pacijenata s ukočnim vratom ima meningitis).

Kombiniranje više dokaza

Kauzalno znanje je često **bolje** od **dijagnostičkog**, tj. dosta često imamo informaciju $P(\textit{effect}|\textit{cause})$.

Kako to iskoristiti kad imamo **više** opaženih **efekata** (više simptoma), nazovimo ih $\textit{effect}_1, \dots, \textit{effect}_n$?

Baš ovo je bitno u praksi — medicina, kriminalistika, ... ,

Na primjer, što zubar može zaključiti (**o rupi**), ako njegova čelična proba **zapne** u **bolećem** zubu pacijenta?

Traži se **dijagnoza** $\mathbf{P}(\textit{Cavity}|\textit{toothache} \wedge \textit{catch})$.

Ako znamo potpunu združenu distribuciju, iz tablice se lako čita

$$\mathbf{P}(\textit{Cavity}|\textit{toothache} \wedge \textit{catch}) = \alpha \langle 0.108, 0.016 \rangle \approx \langle 0.871, 0.129 \rangle.$$

No, za veći broj varijabli to ne ide — tablica je **prevelika**.

Kombiniranje dokaza — Bayesovo pravilo

Primjena Bayesovog pravila daje

$$\begin{aligned} \mathbf{P}(Cavity|toothache \wedge catch) \\ = \alpha \mathbf{P}(toothache \wedge catch|Cavity) \mathbf{P}(Cavity) \end{aligned}$$

U prvom članu, trebaju nam uvjetne vjerojatnosti *toothache* \wedge *catch* za svaku vrijednost varijable *Cavity*.

To je lako za samo dvije dokazne varijable (*Toothache* i *Catch*).

No, kad imamo n varijabli dokaza (ishodi raznih dijagnostičkih testova) onda imamo (barem) 2^n mogućih kombinacija opaženih vrijednosti za koje treba znati uvjetne vjerojatnosti.

Dakle, ništa bolje od potpune tablice.

Zato su nastale približne metode kombiniranja dokaza.

Iako su odgovori netočni, trebaju puno manje brojeva da daju neki (bilo kakav) odgovor.

Uvjetna nezavisnost

Spas je **dodatno znanje** o domeni — **profinjenjem** pojma nezavisnosti u **uvjetnu nezavisnost**, što onda omogućava pojednostavljenje izraza.

Uočimo da **potpuna** združena tablica $\mathbf{P}(Toothache, Catch, Cavity)$ ima $2^3 - 1 = 7$ **nezavisnih** elemenata (zbroj mora biti 1).

Bilo bi lijepo da su **dokazne** varijable *Toothache* i *Catch* **nezavisne**, ali one to **nisu**:

ako se proba **zakači**, onda je izgledno da imam **rupu** i da ta rupa izaziva **zubobolju**.

Uočiti da ovisnost ide **indirektno** — preko *Cavity*.

Međutim, ove dokazne varijable **jesu nezavisne** — **uvjetno**, ako **znamo** da rupe **ima**, ili da rupe **nema**.

Uvjetna nezavisnost — nastavak

Rupa **izravno** “uzrokuje” i jedno i drugo (*Toothache* i *Catch*), ali ni jedan od dokaza **nema izravan** utjecaj na drugog.

Ako **imam** rupu, vjerojatnost da se proba **zakači** u njoj **ne ovisi** o tome imam li **zubobolju** ili ne:

$$(1) \quad P(\textit{catch}|\textit{toothache}, \textit{cavity}) = P(\textit{catch}|\textit{cavity})$$

Analogno, ista nezavisnost vrijedi i ako **nemam** rupu:

$$(2) \quad P(\textit{catch}|\textit{toothache}, \neg\textit{cavity}) = P(\textit{catch}|\neg\textit{cavity})$$

Catch je **uvjetno nezavisna** od *Toothache*, uz **uvjet** da znamo *Cavity*:

$$\mathbf{P}(\textit{Catch}|\textit{Toothache}, \textit{Cavity}) = \mathbf{P}(\textit{Catch}|\textit{Cavity}), \text{ odnosno,}$$

$$\mathbf{P}(\textit{Toothache}|\textit{Catch}, \textit{Cavity}) = \mathbf{P}(\textit{Toothache}|\textit{Cavity}).$$

Uvjetna nezavisnost — opća definicija

Dvije slučajne varijable X i Y su **uvjetno nezavisne** uz **zadanu** treću varijablu Z , ako za njihove distribucije vjerojatnosti vrijedi **produktna** formula

$$\mathbf{P}(X, Y|Z) = \mathbf{P}(X|Z) \mathbf{P}(Y|Z).$$

Ekvivalentne formule bez produkta su (kao i kod obične nezavisnosti)

$$\mathbf{P}(X|Y, Z) = \mathbf{P}(X|Z), \quad \mathbf{P}(Y|X, Z) = \mathbf{P}(Y|Z).$$

Slično kao i za **apsolutne** nezavisnosti, čim imamo **uvjetne** nezavisnosti u domeni, to omogućava

faktorizaciju potpune združene tablice u **manje** blokove.

Za **razliku** od apsolutne nezavisnosti, koja je **rijetka** u praksi,

Uvjetna nezavisnost je naš **osnovni** i **najjači** oblik **znanja** o **nesigurnim** okolinama.

Uvjetna nezavisnost — nastavak

Ekvivalentne izreke za **uvjetnu** nezavisnost *Catch* i *Toothache* uz **uvjet** da znamo *Cavity*:

$$\mathbf{P}(Toothache|Catch, Cavity) = \mathbf{P}(Toothache|Cavity)$$

$$\begin{aligned} \mathbf{P}(Toothache, Catch|Cavity) \\ = \mathbf{P}(Toothache|Cavity) \mathbf{P}(Catch|Cavity) \end{aligned}$$

Kombinacija (konjunkcija) **dokaznih** varijabli je **faktorizirana** u pojedinačne **kauzalne** vjerojatnosti!

Ovo je nešto **jače** svojstvo od **uvjetne** nezavisnosti samo “**pozitivnih**” ishoda *catch* i *toothache*, uz **uvjet** *Cavity*:

$$\begin{aligned} \mathbf{P}(toothache \wedge catch|Cavity) \\ = \mathbf{P}(toothache|Cavity) \mathbf{P}(catch|Cavity) \end{aligned}$$

Bayesovo pravilo i uvjetna nezavisnost

Kad se vratimo u Bayesovo pravilo, dobivamo

$$\begin{aligned} \mathbf{P}(Cavity|toothache \wedge catch) \\ &= \alpha \mathbf{P}(toothache \wedge catch|Cavity) \mathbf{P}(Cavity) \\ &= \alpha \mathbf{P}(toothache|Cavity) \mathbf{P}(catch|Cavity) \mathbf{P}(Cavity) \end{aligned}$$

U dijagnozi ostaju samo kauzalne vjerojatnosti pojedinačnih dokaza.

Na razini potpune združene distribucije, dobivamo

$$\begin{aligned} \mathbf{P}(Toothache, Catch, Cavity) &= \{ \text{produktno pravilo} \} \\ &= \mathbf{P}(Toothache, Catch|Cavity) \mathbf{P}(Cavity) \\ &= \{ \text{produktno pravilo za uvjetnu nezavisnost} \} \\ &= \mathbf{P}(Toothache|Cavity) \mathbf{P}(Catch|Cavity) \mathbf{P}(Cavity) \end{aligned}$$

Početna tablica je faktorizirana u produkt tri male tablice.

Drugim riječima, trebamo $2 + 2 + 1 = 5$ nezavisnih brojeva za tablicu.

Bayesovo pravilo i uvjetna nezavisnost

Ovo smanjenje **ne izgleda** kao bitno, jer je primjer mali.

$$\begin{aligned} & \mathbf{P}(Toothache, Catch, Cavity) \\ &= \mathbf{P}(Toothache|Cavity) \mathbf{P}(Catch|Cavity) \mathbf{P}(Cavity) \end{aligned}$$

Uvjetna nezavisnost na **dvije** varijable eliminira samo **dva** broja.

U čemu je poanta? Konceptualno,

uzrok *Cavity* **separira** **dokazne** varijable *Toothache* i *Catch*, jer je **izravni uzrok** za obje, ali njih dvije **nemaju** **izravan** međusobni utjecaj.

U većini slučajeva, korištenje uvjetne nezavisnosti smanjuje veličinu prikaza združene distribucije — s **eksponencijalne** u n , na **linearnu** u n .

Rastav **velikih** probabilističkih domena u

slabo povezane podskupove — preko **uvjetne** vjerojatnosti, jedno je od **najvažnijih** modernih dostignuća UI.

Uvjetna nezavisnost dokaza — naivni Bayesov model



Ovo je primjer u kojem **jedan uzrok** proizvodi **mного efekata** (dokaza), koji su svi **uvjetno nezavisni** za dani **uzrok**.

Uz drugačiji **poredak** varijabli — prvo **uzrok**, onda **dokazi**,

$$\begin{aligned} & \mathbf{P}(Cavity, Toothache, Catch) \\ &= \mathbf{P}(Cavity) \mathbf{P}(Toothache|Cavity) \mathbf{P}(Catch|Cavity) \end{aligned}$$

to je primjer tzv. **naivnog Bayesovog** modela, u kojem je:


$$\mathbf{P}(Cause, Effect_1, \dots, Effect_n) = \mathbf{P}(Cause) \prod_i \mathbf{P}(Effect_i|Cause)$$



Ukupni broj parametara je **linearan** u n .

Wumpusov svijet — nezgodna situacija

Sjetite se Wumpusovog svijeta — mogućih ponora i opažanja vjetra.



Vjetar na $[1, 2]$ i $[2, 1]$

⇒ **nema sigurne akcije**

Uz pretpostavku da su ponori uniformno distribuirani,

$[2, 2]$ ima ponor s vjerojatnošću **0.86**,
nasuprot samo **0.31** za ostala dva polja.

Odakle ovi zaključci???

Nesigurnost/neizvjesnost je posljedica **djelomičnog** opažanja svijeta.

U ovoj situaciji — na pitanje “kamo je treba krenuti”
čisto “**logičko**” rezoniranje **ne može** dati odgovor.

Probabilistički agent može izabrati “**najbolji**” potez.

Wumpusov svijet — vjerojatnost ponora

Cilj: izračunati vjerojatnost da svako od označena tri polja ima ponor.

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1 OK	2,1 B OK	3,1	4,1

Ignoriramo Wumpusa i zlato. Bitne stvari u vjerojatnosnom modelu:

- (1) **ponor** izaziva **vjetar** u svim **susjednim** poljima,
- (2) osim $[1, 1]$, svako ostalo polje ima **ponor** s vjerojatnošću **0.2**, i to **neovisno** o ostalim poljima.

Vjerojatnosni model

Booleove varijable, slično kao u propozicijskom modelu:

$P_{ij} = true$ ako i samo ako $[i, j]$ ima **ponor**,

$B_{ij} = true$ ako i samo ako na $[i, j]$ ima **vjetra**.

Vjerojatnosni model uključuje samo $B_{1,1}, B_{1,2}, B_{2,1}$ za **opažena** polja.

Potpuna združena distribucija je $\mathbf{P}(P_{1,1}, \dots, P_{4,4}, B_{1,1}, B_{1,2}, B_{2,1})$.

Iskoristimo pravilo **produkta** i to **tako** da dobijemo **uvjetne** vjerojatnosti oblika $P(\textit{Effect} | \textit{Cause})$ — u **kauzalnom** obliku:

$$\begin{aligned} & \mathbf{P}(P_{1,1}, \dots, P_{4,4}, B_{1,1}, B_{1,2}, B_{2,1}) \\ &= \mathbf{P}(B_{1,1}, B_{1,2}, B_{2,1} | P_{1,1}, \dots, P_{4,4}) \mathbf{P}(P_{1,1}, \dots, P_{4,4}) \end{aligned}$$

Prvi član (faktor):

vrijednosti su **1** ako su vjetrovi **susjedni** ponorima, a **0** u protivnom.

Vjerojatnosni model — nastavak

Drugi član (faktor) $\mathbf{P}(P_{1,1}, \dots, P_{4,4})$:

ponori su **slučajno** raspodijeljeni po poljima, s vjerojatnošću **0.2**,
neovisno o ostalim poljima

Nezavisnost daje faktorizaciju

$$\mathbf{P}(P_{1,1}, \dots, P_{4,4}) = \prod_{i,j=1,1}^{4,4} \mathbf{P}(P_{i,j}).$$

Za konfiguraciju svijeta u kojoj imamo točno n **ponora** vrijedi

$$P(P_{1,1}, \dots, P_{4,4}) = 0.2^n \times 0.8^{16-n}.$$

Opažanja (dokazi) i upiti

U opisanoj situaciji, raspolažemo sa sljedećim **dokazima**:
stanje **vjetra** = ima/nema na svim **posjećenim** poljima (tri polja),
svako od tih polja **nije ponor** — inače smo umrli.

U skraćenim oznakama, činjenice koje **znamo** su:

$$b = \neg b_{1,1} \wedge b_{1,2} \wedge b_{2,1}$$

$$known = \neg p_{1,1} \wedge \neg p_{1,2} \wedge \neg p_{2,1}.$$

Upit je $\mathbf{P}(P_{1,3} | known, b) =$

Koliko je izgledno da $[1, 3]$ ima ponor?

Analogno, gledamo pojedinačne upite za ostala dva polja $[2, 2]$, $[3, 1]$.

Napomena: iz slike odmah možemo uočiti simetriju, tj.

polje $[3, 1]$ je ekvivalentno s $[1, 3]$.

Zaključivanje enumeracijom

Standardni pristup — zaključivanje **enumeracijom**, vodi na:

zbrajanje po **svim ostalim** varijablama u potpunoj združenoj distribuciji (= eliminacija preostalih varijabli iz sume).

Oznaka za **ostale** varijable (neopažene ili skrivene) — neka je:

Unknown = skup svih preostalih varijabli P_{ij} , osim $P_{1,3}$ i *Known*.

Odgovor enumeracijom na upit je (uz normalizaciju na zbroj = 1)

$$\mathbf{P}(P_{1,3} \mid \textit{known}, b) = \alpha \sum_{\textit{unknown}} \mathbf{P}(P_{1,3}, \textit{known}, b, \textit{unknown}).$$

Dakle, sve znamo — do na **količinu** računanja:

Imamo **12 nepoznatih** polja u skupu *Unknown*, pa gornja suma ima $2^{12} = 4096$ članova!


Ovo raste **eksponencijalno** s brojem polja!

Korištenje susjedstva — uvjetna nezavisnost

Ključna stvar = “susjedstvo” ponora i vjetra (što ga $[4, 4]$ ima s $[1, 3]$)!

Samo **susjedi** posjećenih polja su bitni, kao “uzroci” vjetra.

Nepoznate varijable **ponora** (bez upita) dijelimo u dva disjunktna skupa
 $Unknown = Fringe \cup Other$, kao na slici




Fringe (ili *Frontier*) — za “granična” polja = susjedna posjećenim, osim upita, tj. za polja $[2, 2]$ i $[3, 1]$,

Other — za sva ostala nepoznata polja (ima ih 10).

Korištenje uvjetne nezavisnosti

Opaženi vjetrovi (iz b) su **uvjetno nezavisni** od ostalih skrivenih polja, tj. od varijabli iz *Other*, uz uvjet da znamo **poznate, granične i upitnu** varijablu ponora.



Dakle, vrijedi

$$\mathbf{P}(b \mid P_{1,3}, \textit{Known}, \textit{Unknown}) = \mathbf{P}(b \mid P_{1,3}, \textit{Known}, \textit{Fringe}).$$

Ostaje: **pretvoriti upit** u oblik u kojem se to može **iskoristiti!**

Transformiranje upita za uvjetnu nezavisnost

$$\begin{aligned}
 \mathbf{P}(P_{1,3} \mid \textit{known}, b) &= \alpha \sum_{\textit{unknown}} \mathbf{P}(P_{1,3}, \textit{known}, b, \textit{unknown}) \\
 &= \{ \text{pravilo produkta} \} \\
 &= \alpha \sum_{\textit{unknown}} \mathbf{P}(b \mid P_{1,3}, \textit{known}, \textit{unknown}) \\
 &\quad \cdot \mathbf{P}(P_{1,3}, \textit{known}, \textit{unknown}) \\
 &= \{ \text{rastav, nezavisnost } P(\textit{unknown}) = P(\textit{fringe})P(\textit{other}) \} \\
 &= \alpha \sum_{\textit{fringe}} \sum_{\textit{other}} \mathbf{P}(b \mid P_{1,3}, \textit{known}, \textit{fringe}, \textit{other}) \\
 &\quad \cdot \mathbf{P}(P_{1,3}, \textit{known}, \textit{fringe}, \textit{other}) \\
 &= \{ \text{uvjetna nezavisnost u prvom članu — } \textit{other} \text{ nije bitan} \} \\
 &= \alpha \sum_{\textit{fringe}} \sum_{\textit{other}} \mathbf{P}(b \mid P_{1,3}, \textit{known}, \textit{fringe}) \\
 &\quad \cdot \mathbf{P}(P_{1,3}, \textit{known}, \textit{fringe}, \textit{other}).
 \end{aligned}$$

Transformiranje upita — nastavak

Prvi član u prethodnoj sumi **ne ovisi** o varijablama iz *Other*, pa ga izlučimo ispred druge sume:

$$\begin{aligned} & \mathbf{P}(P_{1,3} \mid \textit{known}, b) \\ &= \alpha \sum_{\textit{fringe}} \mathbf{P}(b \mid P_{1,3}, \textit{known}, \textit{fringe}) \\ & \quad \cdot \sum_{\textit{other}} \mathbf{P}(P_{1,3}, \textit{known}, \textit{fringe}, \textit{other}). \end{aligned}$$

Sad iskoristimo **nezavisnost** svih varijabli ponora za faktorizaciju, pa je

$$\begin{aligned} & \mathbf{P}(P_{1,3}, \textit{known}, \textit{fringe}, \textit{other}) \\ &= \mathbf{P}(P_{1,3}) P(\textit{known}) P(\textit{fringe}) P(\textit{other}). \end{aligned}$$

Uočimo da $\mathbf{P}(P_{1,3})$ i $P(\textit{known})$ **ne ovise** o indeksima sumacije *fringe* i *other* — izlučimo ih **ispred** svega.

Također, $P(\textit{fringe})$ može ispred zadnje sume.

Transformiranje upita — nastavak

Nakon izlučivanja svega što se može izlučiti, dobivamo:

$$\begin{aligned} & \mathbf{P}(P_{1,3} \mid \textit{known}, b) \\ &= \alpha P(\textit{known}) \mathbf{P}(P_{1,3}) \\ & \quad \cdot \sum_{\textit{fringe}} \mathbf{P}(b \mid P_{1,3}, \textit{known}, \textit{fringe}) P(\textit{fringe}) \sum_{\textit{other}} P(\textit{other}). \end{aligned}$$

Na kraju, definiramo novu normalizacijsku konstantu $\alpha' = \alpha P(\textit{known})$ i uočimo da zadnja suma **mora** biti jednaka **1** (*other nestaje*), pa je

$$\begin{aligned} & \mathbf{P}(P_{1,3} \mid \textit{known}, b) \\ &= \alpha' \mathbf{P}(P_{1,3}) \sum_{\textit{fringe}} \mathbf{P}(b \mid P_{1,3}, \textit{known}, \textit{fringe}) P(\textit{fringe}). \end{aligned}$$

Zadnja suma ima **samo 4** člana po graničnim varijablama $P_{2,2}$ i $P_{3,1}$, a ostala polja su potpuno **eliminirana**!

Korištenje uvjetne nezavisnosti — nastavak


U zadnjoj sumi po *fringe*, vjerojatnost $P(b \mid P_{1,3}, \textit{known}, \textit{fringe})$ ima samo dvije moguće vrijednosti:

- 1 — ako je granica konzistentna s opažanjima vjetra, i
- 0 — inače.


Dakle, za svaku vrijednost varijable $P_{1,3}$ (istina, laž), treba zbrojiti sve logičke modele u kojima su vrijednosti na granici u skladu s poznatim činjenicama.

Svi takvi modeli (3 za istina, 2 za laž) i pripadne početne (a priori) vjerojatnosti dane su na sljedećoj slici (sljedeća stranica):


Odgovori na upite




$$0.2 \times 0.2 = 0.04$$




$$0.2 \times 0.8 = 0.16$$



$$0.8 \times 0.2 = 0.16$$



$$0.2 \times 0.2 = 0.04$$



$$0.2 \times 0.8 = 0.16$$

Početne vjerojatnosti treba pomnožiti s pripadnom vjerojatnošću $P_{1,3}$.

$$\mathbf{P}(P_{1,3} \mid \textit{known}, b) = \alpha \langle 0.2 (0.04 + 0.16 + 0.16), 0.8 (0.04 + 0.16) \rangle \\ \approx \langle 0.31, 0.69 \rangle$$

Dakle, polje $[1, 3]$ (i $[3, 1]$, po simetriji) ima **ponor** s vjerojatnošću **31%**.

Na isti način izlazi

$$\mathbf{P}(P_{2,2} \mid \textit{known}, b) \approx \langle 0.86, 0.14 \rangle.$$

Dakle, naš agent svakako treba **izbjegavati** polje $[2, 2]$.

Sažetak

Vjerojatnost je strogi formalizam za nesigurno znanje

Združena distribucija vjerojatnosti daje vjerojatnost svakog elementarnog događaja

Na upite se može odgovoriti zbrajanjem po elementarnim događajima

U netrivialnim domenama, treba pronaći način za smanjenje veličine potpune tablice

Nezavisnost i uvjetna nezavisnost su sredstvo za to