

LOGIČKI AGENTI


POGLAVLJE 7

Prema slajdovima Stuarta Russella (hvala)!

Pregled

- ◇ Agenti bazirani na znanju (engl. Knowledge-based agents)
- ◇ Wumpusov svijet
- ◇ Općenito o logici—modeli i relacija logičke posljedice
- ◇ Logika sudova (propozicijska, Boolova logika)
- ◇ Ekvivalencija, valjanost, ispunjivost
- ◇ Pravila zaključivanja i dokazivanje teorema
 - metoda rezolucije (razrješavanja) (engl. resolution)
 - ulančavanje unaprijed (engl. forward chaining)
 - ulančavanje unatrag (engl. backward chaining)

Baza znanja



Baza znanja = skup rečenica u **formalnom** jeziku

Deklarativni pristup izgradnji agenta (ili nekog drugog sustava):

KAŽI mu što treba znati (**TELL**)

Tada se agent može **ZAPITATI** (**ASK**) što činiti—odgovori bi trebali slijediti iz baze znanja

Agenti se mogu gledati kao **nivo znanja**

tj., **što znaju**, bez obzira kako se to implementira

Ili, na **implementacijskoj razini**,

strukture podataka u bazi znanja i algoritmi koji njima manipuliraju

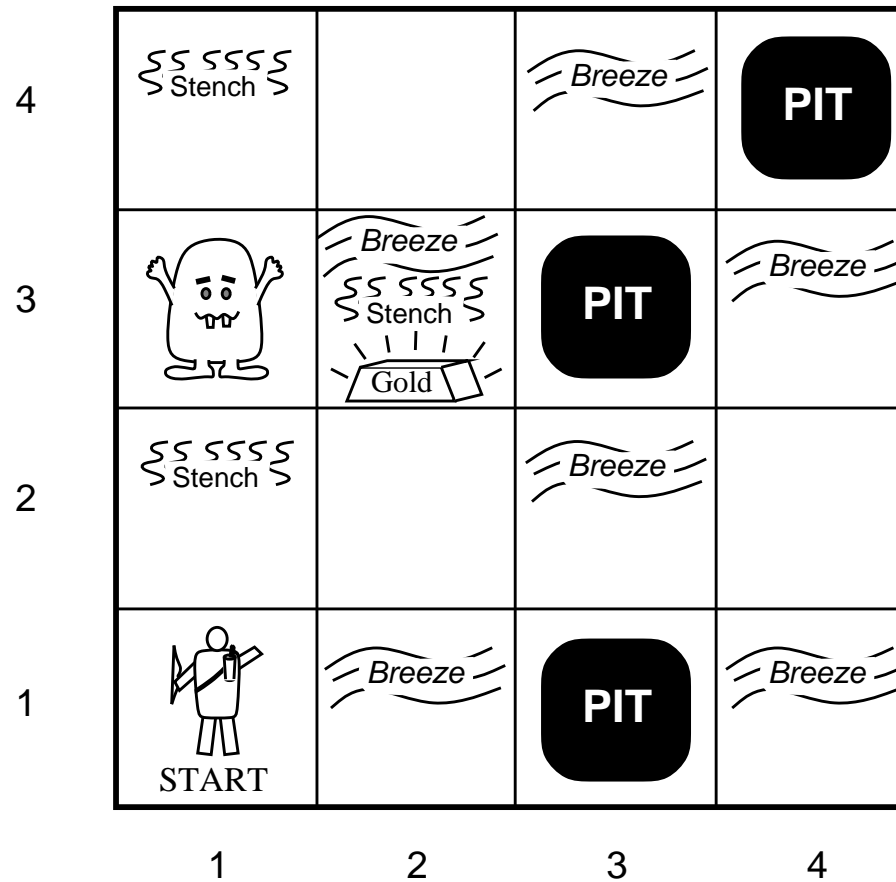
Jednostavni agent baziran na znanju

```
function KB-AGENT(percept) returns an action  
  static: KB, a knowledge base  
           t, a counter, initially 0, indicating time  
  
  TELL(KB, MAKE-PERCEPT-SENTENCE(percept, t))  
  action ← ASK(KB, MAKE-ACTION-QUERY(t))  
  TELL(KB, MAKE-ACTION-SENTENCE(action, t))  
  t ← t + 1  
  return action
```

Agent mora moći:

- reprezentirati stanja, akcije i dr.
- uključivati nove percepcije
- ažurirati internu reprezentaciju svijeta
- zaključivati o skrivenim svojstvima svijeta
- zaključiti koje su odgovarajuće akcije

Wumpusov svijet — jedna mogućnost



Agent se nalazi na polju [1, 1]. Sva ostala polja su slučajna (W, P, G). Polje je ponor (P) s vjerojatnošću 0.2

PEAS opis Wumpusovog svijeta

Mjere učinka:

zlato +1000, smrt -1000

-1 po koraku, -10 za upotrebu strelice

Okolina:

kvadrati susjedni Wumpusovom su smrdljivi

kvadrati susjedni ponoru su vjetroviti

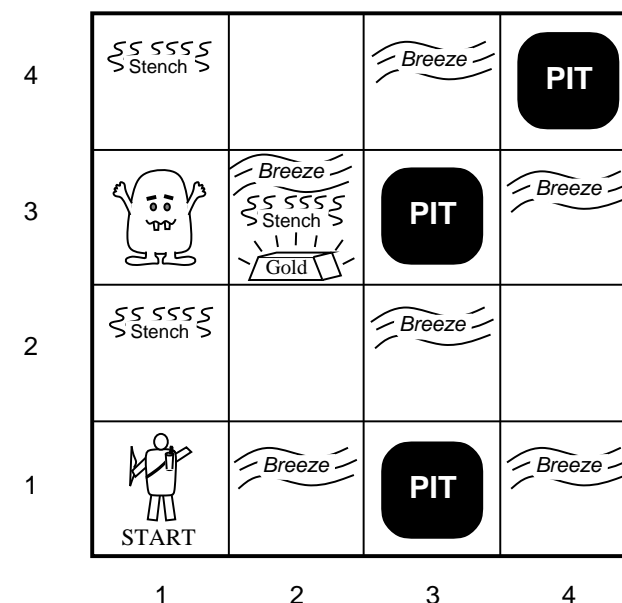
ako je zlato na kvadratu, on blista

pucanje ubija Wumpusa ako je okrenut licem

pucanje koristi samo jednu strelicu

uzimanje zlata—samo s istog kvadrata

ispuštanje zlata—samo na istom kvadratu



Dozvoljene radnje: okret lijevo/desno, naprijed, uzmi, ispusti, pucaj, izlazak iz pećine (samo s kvadrata = polja [1, 1])

Senzori za: vjetrovitost, blistanje, smrad + bum u zid + urlik Wumpusa

Karakterizacija Wumpusovog svijeta

Opažanje??

Karakterizacija Wumpusovog svijeta

Opažanje?? Nema—samo lokalna percepcija

Deterministički??

Karakterizacija Wumpusovog svijeta

Opažanje?? Nema—samo lokalna percepcija

Deterministički?? Da—ishodi su točno specificirani

Epizode??

Karakterizacija Wumpusovog svijeta

Opažanje?? Nema—samo lokalna percepcija

Deterministički?? Da—ishodi su točno specificirani

Epizode?? Ne—sekvencijalan na nivou akcije

Statičan??

Karakterizacija Wumpusovog svijeta

Opažanje?? Nema—samo lokalna percepcija

Deterministički?? Da—ishodi su točno specificirani

Epizode?? Ne—sekvencijalan na nivou akcije

Statičan?? Da—Wumpus i ponori se ne miču

Diskretan??

Karakterizacija Wumpusovog svijeta

Opažanje?? Nema—samo lokalna percepcija

Deterministički?? Da—ishodi su točno specificirani

Epizode?? Ne—sekvencijalan na nivou akcije

Statičan?? Da—Wumpus i ponori se ne miču

Diskretan?? Da

Samo jedan-agent??

Karakterizacija Wumpusovog svijeta

Opažanje?? Nema—samo lokalna percepcija

Deterministički?? Da—ishodi su točno specificirani

Epizode?? Ne—sekvencijalan na nivou akcije

Statičan?? Da—Wumpus i ponori se ne miču

Diskretan?? Da

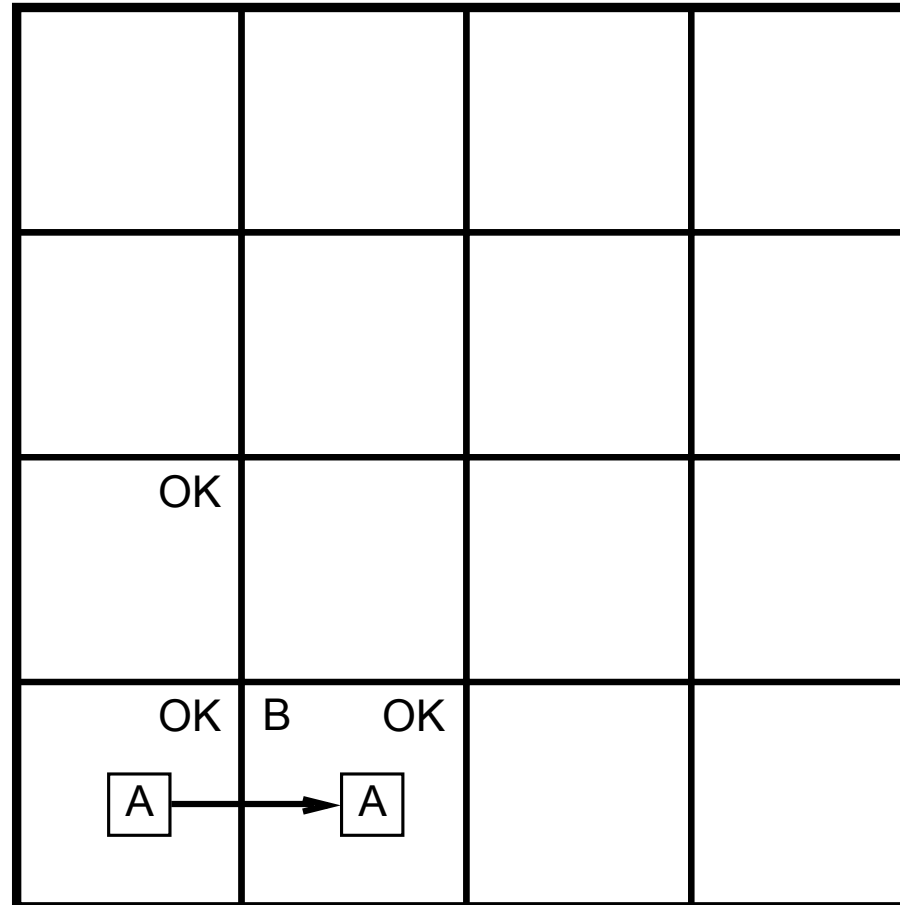
Samo jedan-agent?? Da—Wumpus je u biti fizička značajka
(ne djeluje samostalno, tj. on je kao druga vrsta ponora)

Istraživanje Wumpusovog svijeta

OK			
OK A	OK		


Nema vjetra na $[1, 1] \implies$ polja $[1, 2]$ i $[2, 1]$ su OK
Idemo (na pr.) na $[2, 1]$

Istraživanje Wumpusovog svijeta




Vjetar na $[2, 1] \Rightarrow \dots$

Istraživanje Wumpusovog svijeta




Vjetar na [2, 1] \implies na [3, 1] ili [2, 2] je **ponor** (ne mogu dalje/gore)
Vrati se na [1, 1] (dva okreta + naprijed), okret i idi na [1, 2]

Istraživanje Wumpusovog svijeta



Smrad na [1, 2] \Rightarrow ...


Istraživanje Wumpusovog svijeta



Smrad na [1, 2] \implies Wumpus je na [1, 3]


Ne može biti na [2, 2], jer bi smrdilo i na [2, 1], a ne smrdi tamo

Istraživanje Wumpusovog svijeta — na istom jestu




Nema vjetra na [1, 2] \implies Ponor nije na [2, 2], nego na [3, 1]
Dakle, [2, 2] je OK, idemo tamo (okret, naprijed)

Istraživanje Wumpusovog svijeta




Nema ničega na $[2, 2]$ — ni vjetra, ni smrada, ni blistanja \Rightarrow

Istraživanje Wumpusovog svijeta



Nema ničega na $[2, 2] \implies$ polja $[2, 3]$ i $[3, 2]$ su OK.
 Idemo (na pr.) gore na $[2, 3]$ (okret, naprijed)


Istraživanje Wumpusovog svijeta



Ima svega na [2, 3] — vjetar, smrad, blistanje \implies

Pusti Wumpusa (strelica košta -10), uzmi zlato, idi natrag na [1, 1]!

Neke nezgodne točke




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 0.31



Smrad na $[1, 1]$

⇒ **ne može** se sigurno pomaknuti

Može uzeti strategiju **prisile**:

pucati ravno naprijed

Wumpus je bio tamo ⇒ mrtav ⇒ siguran

Wumpus nije bio tamo ⇒ siguran

Općenito o logici

Logika je formalni jezik za reprezentiranje informacija takvih da se mogu izvesti zaključci

Sintaksa definira rečenice u jeziku

Semantika definira “značenje” rečenica;
tj., definira **istinitost** rečenice u svijetu

Na primjer, jezik je aritmetika

$x + 2 \geq y$ je rečenica; $x^2 + y >$ nije rečenica

$x + 2 \geq y$ je istinita ako i samo ako broj $x + 2$ nije manji od broja y

$x + 2 \geq y$ je istinita u svijetu u kojem vrijedi $x = 7, y = 1$

$x + 2 \geq y$ je lažna u svijetu u kojem vrijedi $x = 0, y = 6$

Relacija logičke posljedice

Logička posljedica znači da jedna stvar **logički slijedi iz** druge:

$$KB \models \alpha$$

Iz baze znanja KB logički slijedi α

ako i samo ako je

α istinita u svim svjetovima u kojima je KB istinita

Npr., iz baze znanja koja sadrži “Dinamo je pobijedio” i “Hajduk je pobijedio” logički slijedi “Dinamo je pobijedio ili Hajduk je pobijedio”

Npr., iz $x + y = 4$ logički slijedi $4 = x + y$

Logička posljedica je relacija među rečenicama (tj., **sintaksa**) koja je utemeljena na **semantici**

Napomena: mozak obrađuje **sintaksu** (neke vrste)

Modeli

Logičari obično razmišljaju u terminima **modela**, tj. formalno strukturiranih svjetova u odnosu na koje možemo ustanoviti **istinitost**

Kažemo da je **m model za** rečenicu **α** ako je **α** istinita u **m**


$M(\alpha)$ je skup svih modela od **α**

Tada, **$KB \models \alpha$** ako i samo ako **$M(KB) \subseteq M(\alpha)$**

Na primjer,

KB = Dinamo je pobijedio i Hajduk je pobijedio

α = Dinamo je pobijedio




Logička posljedica u Wumpusovom svijetu

Situacija nakon

- Nema vjetra (ničega) na [1, 1],
- idi desno na [2, 1],
- Vjetar na [2, 1]








Razmotrimo moguće modele za tri “?”

Pretpostavimo samo ponore (P)




3 Booleovska izbora (ima P/nema P) \Rightarrow 8 mogućih **modela**

Wumpusovi modeli




Imamo ovih 8 modela

Wumpusovi modeli



KB = pravila Wumpusovog svijeta + opažanja do tada


Wumpusovi modeli



KB = pravila Wumpusovog svijeta + opažanja do tada


α_1 = “[1, 2] nema ponor”, $KB \models \alpha_1$, dokazano provjerom modela

Wumpusovi modeli



KB = pravila Wumpusovog svijeta + opažanja do tada

Wumpusovi modeli



KB = pravila Wumpusovog svijeta + opažanja do tada

α_2 = "[2, 2] nema ponor", $KB \not\models \alpha_2$

Može ga biti/ne mora ga biti (nema zaključka)!

Zaključivanje

$KB \vdash_i \alpha$ = rečenica α može biti izvedena iz KB sustavom pravila i

Posljedice od KB su “plast sijena”; α je “igla”.

Logička posljedica = “igla u plastu”; zaključivanje = nalaženje “igle”

Ispravnost: i je ispravan (adekvatan = čuva istinitost) ako

kad god je $KB \vdash_i \alpha$, također vrijedi $KB \models \alpha$

Potpunost: i je potpun ako

kad god je $KB \models \alpha$, također vrijedi $KB \vdash_i \alpha$

“Pogled unaprijed”: Definirat ćemo logiku (logiku prvog reda) koja je dovoljno **izražajna** da iskaže skoro sve što nas zanima, i za koju postoji **ispravan** i **potpun** sustav pravila zaključivanja.

Tj., pravila će odgovoriti na **svako** pitanje čiji odgovor **slijedi** iz onoga što znamo u KB .

Logika sudova: sintaksa

Logika sudova je najjednostavnija logika—ilustrira osnovne ideje

Propozicionalne varijable P_1, P_2 su rečenice

Ako je S rečenica, $\neg S$ je rečenica (negacija)

Ako su S_1 i S_2 rečenice, $S_1 \wedge S_2$ je rečenica (konjunkcija)

Ako su S_1 i S_2 rečenice, $S_1 \vee S_2$ je rečenica (disjunkcija)

Ako su S_1 i S_2 rečenice, $S_1 \Rightarrow S_2$ je rečenica (implikacija, kondicional)

Ako su S_1 i S_2 rečenice, $S_1 \Leftrightarrow S_2$ je rečenica (bikondicional)

Logika sudova: semantika

Svaki **model** određuje **istinitost** za svaku propozicionalnu varijablu

Na primjer: $P_{1,2}$ $P_{2,2}$ $P_{3,1}$
false false true

(S tim varijablama može se automatski pobrojati 8 mogućih modela.)

Pravila za određivanje istinitosti obzirom na model m :

$\neg S$ je istinita akko	S je lažna
$S_1 \wedge S_2$ je istinita akko	S_1 je istinita i S_2 je istinita
$S_1 \vee S_2$ je istinita akko	S_1 je istinita ili S_2 je istinita
$S_1 \Rightarrow S_2$ je istinita akko	S_1 je lažna ili S_2 je istinita
tj., je lažna akko	S_1 je istinita i S_2 je lažna
$S_1 \Leftrightarrow S_2$ je istinita akko	$S_1 \Rightarrow S_2$ je istinita i $S_2 \Rightarrow S_1$ je istinita

Jednostavnom rekurzivnom primjenom ovih pravila računa se istinitost bilo koje rečenice

Tablice istinitosti za veznike

P	Q	$\neg P$	$P \wedge Q$	$P \vee Q$	$P \Rightarrow Q$	$P \Leftrightarrow Q$
<i>false</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>
<i>false</i>	<i>true</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>false</i>
<i>true</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>
<i>true</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>

Rekurzivnom primjenom tablice računa se istinitost bilo koje rečenice

Na primjer: $P_{1,2}$ $P_{2,2}$ $P_{3,1}$
false false true

pa za rečenicu $\neg P_{1,2} \wedge (P_{2,2} \vee P_{3,1})$ dobivamo

$$\neg P_{1,2} \wedge (P_{2,2} \vee P_{3,1}) = \textit{true} \wedge (\textit{false} \vee \textit{true}) = \textit{true} \wedge \textit{true} = \textit{true}$$

Rečenice Wumpusovog svijeta — opis svijeta

KB za svijet Wumpusa = stvari koje su **fiksne** u svijetu
(varijabilnost/ovisnost tek u logici prvog reda)

Treba opisati stanje svakog polja (kvadrata) obzirom na osnovne stvari
 P = ponor, B = vjetar (breeze), S = smrad (stench),
 W = Wumpus, G = blistanje (glitter) za zlato

Neka je $P_{i,j}$ istinita ako postoji ponor na $[i, j]$.

Neka je $B_{i,j}$ istinita ako postoji vjetar na $[i, j]$.

Neka je $S_{i,j}$ istinita ako postoji smrad na $[i, j]$.

Neka je $W_{i,j}$ istinita ako postoji Wumpus na $[i, j]$.

Neka je $G_{i,j}$ istinita ako postoji blistanje na $[i, j]$.

U nastavku gledamo samo početno zaključivanje o **ponorima** (P) na osnovu opažanja **vjetra** (B).

Rečenice Wumpusovog svijeta

Neka je $P_{i,j}$ istinita ako postoji ponor na $[i, j]$.

Neka je $B_{i,j}$ istinita ako postoji vjetar na $[i, j]$.

Rečenice označavamo s R_k za kasniji poziv na nju

1. **Početno** stanje svijeta = **nema** ponora na polju $[1, 1]$:

$$R_1 : \quad \neg P_{1,1}$$

Rečenice Wumpusovog svijeta

Neka je $P_{i,j}$ istinita ako postoji ponor na $[i, j]$.

Neka je $B_{i,j}$ istinita ako postoji vjetar na $[i, j]$.

Rečenice označavamo s R_k za kasniji poziv na nju

1. **Početno** stanje svijeta = **nema** ponora na polju $[1, 1]$:

$$R_1 : \quad \neg P_{1,1}$$

2. Ponori uzrokuju vjetar na susjednim poljima, tj.

Na danom polju je vjetar **ako i samo ako** je ponor na susjednom polju

$$R_2 : \quad B_{1,1} \Leftrightarrow (P_{1,2} \vee P_{2,1})$$

$$R_3 : \quad B_{2,1} \Leftrightarrow (P_{1,1} \vee P_{2,2} \vee P_{3,1})$$

Rečenice Wumpusovog svijeta

Neka je $P_{i,j}$ istinita ako postoji ponor na $[i, j]$.

Neka je $B_{i,j}$ istinita ako postoji vjetar na $[i, j]$.

Rečenice označavamo s R_k za kasniji poziv na nju

1. **Početno** stanje svijeta = **nema** ponora na polju $[1, 1]$:

$$R_1 : \quad \neg P_{1,1}$$

2. Ponori uzrokuju vjetar na susjednim poljima, tj.

Na danom polju je vjetar **ako i samo ako** je ponor na susjednom polju

$$R_2 : \quad B_{1,1} \Leftrightarrow (P_{1,2} \vee P_{2,1})$$

$$R_3 : \quad B_{2,1} \Leftrightarrow (P_{1,1} \vee P_{2,2} \vee P_{3,1})$$

3. Dodajmo još konkretna **opažanja** agenta za prva dva polja

$$R_4 : \quad \neg B_{1,1}$$

$$R_5 : \quad B_{2,1}$$

Tablice istinitosti za zaključivanje

$B_{1,1}$	$B_{2,1}$	$P_{1,1}$	$P_{1,2}$	$P_{2,1}$	$P_{2,2}$	$P_{3,1}$	R_1	R_2	R_3	R_4	R_5	KB
<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>false</i>	<i>false</i>
<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>false</i>
<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<u><i>true</i></u>
<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<u><i>true</i></u>
<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<u><i>true</i></u>
<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>false</i>
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>false</i>

Pobrojimo sve retke = sve različite vrijednosti istinitosti za varijable, ovdje je **128** redaka za **7** varijabli.

KB je **istinita** u nekom retku $\leftrightarrow R_1, \dots, R_5$ **istinite** = samo **3** retka

Provjerimo je li α istinita na **tim** mjestima

$P_{1,2}$ **nije** = **nema** ponora na $[1, 2]$, $P_{2,2}$ može/ne mora biti

Zaključivanje pobrojavanjem

Pobrojavanje prvo-u-dubinu (DFS) svih modela je ispravno i potpuno

function **TT-ENTAILS?**(KB, α) **returns** *true* or *false*

inputs: KB , the knowledge base, a sentence in propositional logic

α , the query, a sentence in propositional logic

$symbols \leftarrow$ a list of the proposition symbols in KB and α

return **TT-CHECK-ALL**($KB, \alpha, symbols, []$)

function **TT-CHECK-ALL**($KB, \alpha, symbols, model$) **returns** *true* or *false*

if **EMPTY?**($symbols$) **then**

if **PL-TRUE?**($KB, model$) **then return** **PL-TRUE?**($\alpha, model$)

else return *true*

else do

$P \leftarrow$ **FIRST**($symbols$); $rest \leftarrow$ **REST**($symbols$)

return **TT-CHECK-ALL**($KB, \alpha, rest, \text{EXTEND}(P, true, model)$) **and**

TT-CHECK-ALL($KB, \alpha, rest, \text{EXTEND}(P, false, model)$)

$O(2^n)$ za n varijabli; problem je **co-NP-potpun**

Logička ekvivalencija

Dvije rečenice su **logički ekvivalentne** akko su istinite na **istim** modelima:

$\alpha \equiv \beta$ ako i samo ako $\alpha \models \beta$ i $\beta \models \alpha$

Standardne logičke ekvivalencije = “zakoni”:

$(\alpha \wedge \beta) \equiv (\beta \wedge \alpha)$	komutativnost \wedge
$(\alpha \vee \beta) \equiv (\beta \vee \alpha)$	komutativnost \vee
$((\alpha \wedge \beta) \wedge \gamma) \equiv (\alpha \wedge (\beta \wedge \gamma))$	asocijativnost \wedge
$((\alpha \vee \beta) \vee \gamma) \equiv (\alpha \vee (\beta \vee \gamma))$	asocijativnost \vee
$\neg(\neg\alpha) \equiv \alpha$	eliminacija dvostruke negacije
$(\alpha \Rightarrow \beta) \equiv (\neg\beta \Rightarrow \neg\alpha)$	kontrapozicija
$(\alpha \Rightarrow \beta) \equiv (\neg\alpha \vee \beta)$	eliminacija implikacije
$(\alpha \Leftrightarrow \beta) \equiv ((\alpha \Rightarrow \beta) \wedge (\beta \Rightarrow \alpha))$	eliminacija bikondicionala
$\neg(\alpha \wedge \beta) \equiv (\neg\alpha \vee \neg\beta)$	De Morgan
$\neg(\alpha \vee \beta) \equiv (\neg\alpha \wedge \neg\beta)$	De Morgan
$(\alpha \wedge (\beta \vee \gamma)) \equiv ((\alpha \wedge \beta) \vee (\alpha \wedge \gamma))$	distributivnost \wedge prema \vee
$(\alpha \vee (\beta \wedge \gamma)) \equiv ((\alpha \vee \beta) \wedge (\alpha \vee \gamma))$	distributivnost \vee prema \wedge

Valjanost i ispunjivost

Rečenica je **valjana** (tautologija) ako je istinita na **svakom** modelu,
npr., $True$, $A \vee \neg A$, $A \Rightarrow A$, $(A \wedge (A \Rightarrow B)) \Rightarrow B$

Valjanost je vezana uz **zaključivanje** teoremom dedukcije:

$KB \models \alpha$ ako i samo ako je $(KB \Rightarrow \alpha)$ valjana

Rečenica je **ispunjiva** ako je istinita na **nekome** modelu (problem SAT)
npr., $A \vee B$, C

Rečenica je **neispunjiva** (antitautologija, kontradikcija) ako nije istinita
nit na jednom modelu

npr., $A \wedge \neg A$ (zakon kontradikcije)

Ispunjivost je vezana uz **zaključivanje** na sljedeći način:

$KB \models \alpha$ ako i samo ako $(KB \wedge \neg \alpha)$ je neispunjiva

tj., dokaži α pomoću *svodjenja na kontradikciju*

Metode dokazivanja

Metode dokazivanja dijele se (okvirno) u dvije vrste:

Primjena pravila zaključivanja

- Legitimno (tj. ispravno) stvaranje novih rečenica iz već postojećih
- **Dokaz** = niz primjena pravila zaključivanja
 - Pravila zaključivanja mogu se koristiti kao **operatori** u standardnim algoritmima **pretrage**
- Uobičajeno zahtijeva prevođenje rečenica u **normalnu formu**

Provjera modela (model checking)

pobrojavanje tablice istinitosti (uvijek eksponencijalno u n)
unaprijeđeni backtracking, tj. Davis–Putnam–Logemann–Loveland
heuristička pretraga prostora modela (ispravno, ali nepotpuno)
na pr., min-conflicts-like hill-climbing algoritmi

Rezolucija (razlučivanje/razrješavanje)

v. FER, UI-5, str. 42–61.

Primjer 2 = Diplomatski problem — treba str. 33–34.

Rezolucija (razlučivanje/razrješavanje)

Konjunktivna Normalna Forma (CNF—općenita)

konjunkcija klauzula, klauzula = disjunkcija literala

Na pr., $(A \vee \neg B) \wedge (B \vee \neg C \vee \neg D)$


Rezolucijsko pravilo zaključivanja (za CNF): potpuno za logiku sudova

$$\frac{l_1 \vee \dots \vee l_i \vee \dots \vee l_k, \quad m_1 \vee \dots \vee m_j \vee \dots \vee m_n}{l_1 \vee \dots \vee l_{i-1} \vee l_{i+1} \vee \dots \vee l_k \vee m_1 \vee \dots \vee m_{j-1} \vee m_{j+1} \vee \dots \vee m_n}$$

gdje su l_i i m_j međusobno **komplementarni** literali.

Na pr.,

$$\frac{P_{1,3} \vee P_{2,2}, \quad \neg P_{2,2}}{P_{1,3}}$$



Rezolucija (opovrgavanjem) je **ispravna** i **potpuna** za logiku sudova

Pretvorba u CNF

$B_{1,1} \Leftrightarrow (P_{1,2} \vee P_{2,1})$ = pravilo za **vjetar** na početku, na [1, 1]

1. Eliminiraj \Leftrightarrow , zamjenom $\alpha \Leftrightarrow \beta$ s $(\alpha \Rightarrow \beta) \wedge (\beta \Rightarrow \alpha)$.

$$(B_{1,1} \Rightarrow (P_{1,2} \vee P_{2,1})) \wedge ((P_{1,2} \vee P_{2,1}) \Rightarrow B_{1,1})$$

2. Eliminiraj \Rightarrow , zamjenom $\alpha \Rightarrow \beta$ s $\neg\alpha \vee \beta$.

$$(\neg B_{1,1} \vee P_{1,2} \vee P_{2,1}) \wedge (\neg(P_{1,2} \vee P_{2,1}) \vee B_{1,1})$$

3. Makni \neg unutra do literala, po de Morganovim pravilima i eliminiraj dvostruke negacije:

$$(\neg B_{1,1} \vee P_{1,2} \vee P_{2,1}) \wedge ((\neg P_{1,2} \wedge \neg P_{2,1}) \vee B_{1,1})$$

4. Primijeni distributivnost (\vee prema \wedge) i sredi:

$$(\neg B_{1,1} \vee P_{1,2} \vee P_{2,1}) \wedge (\neg P_{1,2} \vee B_{1,1}) \wedge (\neg P_{2,1} \vee B_{1,1})$$

Algoritam rezolucije (opovrgavanjem)

Dokaz kontradikcijom, tj., pokaži da je $KB \wedge \neg\alpha$ neispunjiva

```
function PL-RESOLUTION( $KB, \alpha$ ) returns true or false
  inputs:  $KB$ , the knowledge base, a sentence in propositional logic
          $\alpha$ , the query, a sentence in propositional logic

   $clauses \leftarrow$  the set of clauses in the CNF representation of  $KB \wedge \neg\alpha$ 
   $new \leftarrow \{ \}$ 
  loop do
    for each  $C_i, C_j$  in  $clauses$  do
       $resolvents \leftarrow$  PL-RESOLVE( $C_i, C_j$ )
      if  $resolvents$  contains the empty clause then return true
       $new \leftarrow new \cup resolvents$ 
  if  $new \subseteq clauses$  then return false
   $clauses \leftarrow clauses \cup new$ 
```

Reprezentacija CNF = skup skupova, svaki “podskup” je klauzula

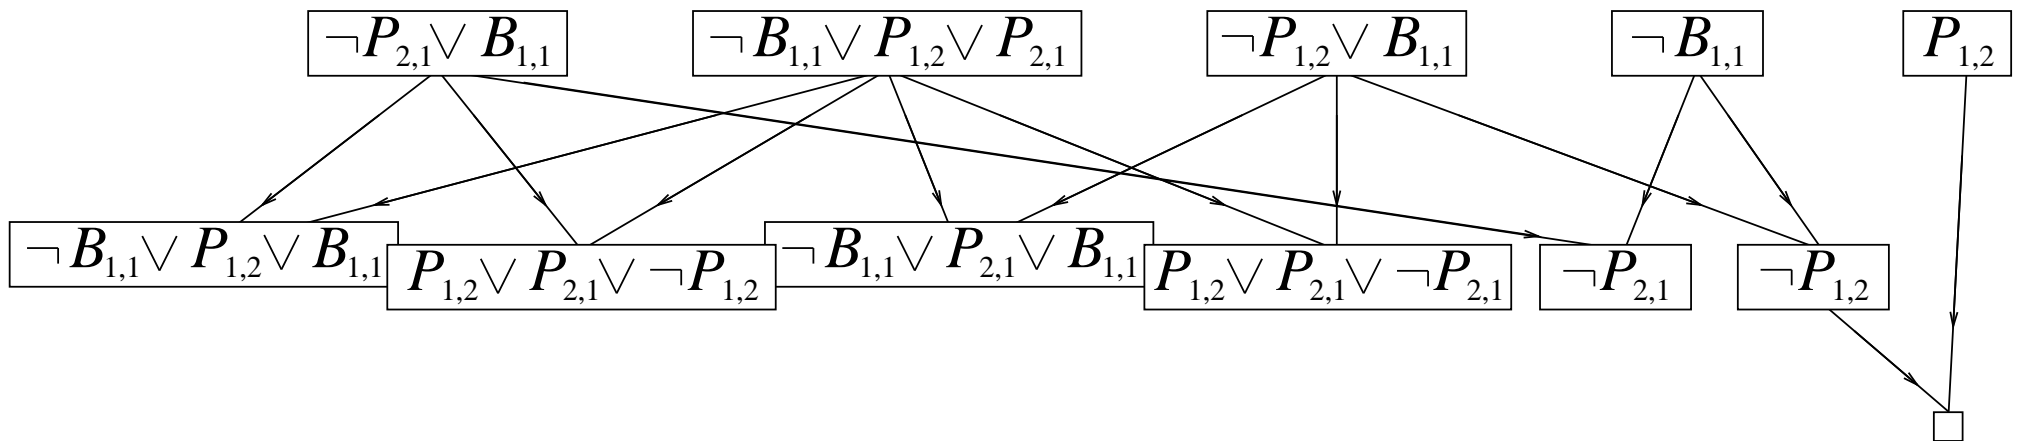
Primjer rezolucije

$$KB = (B_{1,1} \Leftrightarrow (P_{1,2} \vee P_{2,1})) \wedge \neg B_{1,1}$$

dodamo opažanje da **nema vjetra** na [1, 1]

$$\alpha = \neg P_{1,2} = \text{zaključak da } \textbf{nema ponora} \text{ na [1, 2]}$$

Uvrstimo CNF za lijevu stranu i “dodamo” $\neg\alpha$, tj. $P_{1,2}$



Spajamo parove iz prvog reda koji imaju **komplementarne** literale
 elimineramo ih pravilom rezolucije i pišemo **rezolvente**
 (može ih biti više za jedan par klauzula — prve dvije, druge dvije)

Hornova forma CNF

Hornova forma (ograničena CNF)

KB = **konjunkcija Hornovih klauzula**

Hornova klauzula =

- ◇ propozicionalna varijabla; ili
- ◇ (konjunkcija varijabli) \Rightarrow varijabla

Ekvivalentno: klauzula u kojoj je **najviše jedan** literal pozitivan.

Na pr., $C \wedge (B \Rightarrow A) \wedge (C \wedge D \Rightarrow B)$

Negacijom “premise” dobivamo klauzulu (disjunkciju) s negativnim literalima i dodamo zaključak (pozitivan ili ga nema = false)!

Podjela prema broju **pozitivnih** literala — ako je točno jedan:

- implikacija = točno **jedan** pozitivni literal (glava)
- ako nema premise = činjenica

Ako ih **nema** = nema zaključka = kao da je **false** = **ciljna klauzula**!

Ulančavanje unaprijed i unatrag

Modus Ponens (za Hornovu formu): potpun za Hornove baze znanja

$$\frac{\alpha_1, \dots, \alpha_n, \quad \alpha_1 \wedge \dots \wedge \alpha_n \Rightarrow \beta}{\beta}$$

Može biti korišten s **ulančavanjem unaprijed** ili **ulančavanjem unatrag**.

Ti algoritmi su vrlo prirodni i izvršavaju se u **linearnom** vremenu u veličini **KB**.

Reprezentacija klauzula u Hornovoj formi

- premisa je **tijelo** (engl. body), kad je ima
- zaključak je **glava** (engl. head), kad ga ima
(svagdje osim u ciljnoj klazuli)

Idealno za reprezentaciju listama (LISP)

Ulančavanje unaprijed (Forward chaining)

Ideja: uzmi bilo koju implikaciju čije premise su zadovoljene u KB , dodaj pripadni zaključak u KB , sve dok ne nađeš upit.

$$P \Rightarrow Q$$

$$L \wedge M \Rightarrow P$$


$$B \wedge L \Rightarrow M$$

$$A \wedge P \Rightarrow L$$

$$A \wedge B \Rightarrow L$$

A

B



Broj označava koliko premise svake implikacije je još **nepoznato**.
Kad stigne na **nula** — dodamo zaključak (simbol) u KB

Ulančavanje unaprijed — algoritam


```
function PL-FC-ENTAILS?(KB, q) returns true or false
  inputs: KB, the knowledge base, a set of propositional Horn clauses
           q, the query, a proposition symbol
  local variables: count, a table, indexed by clause, initially the number of premises
                    inferred, a table, indexed by symbol, each entry initially false
                    agenda, a list of symbols, initially the symbols known in KB

  while agenda is not empty do
    p ← POP(agenda)
    unless inferred[p] do
      inferred[p] ← true
      for each Horn clause c in whose premise p appears do
        decrement count[c]
        if count[c] = 0 then do
          if HEAD[c] = q then return true
          PUSH(HEAD[c], agenda)

  return false
```

Vodimo računa o već “zaključenim” simbolima


Ulančavanje unaprijed — primjer



Start: Upit = Q samo A i B su u KB

Broj označava koliko premisa svake implikacije je još **nepoznato**.


Ulančavanje unaprijed — primjer



A je u KB premisa za $A \wedge P \Rightarrow L$ i $A \wedge B \Rightarrow L$

Pripadni brojevi tih implikacija padaju za jedan — na 1 i 1

Ulančavanje unaprijed — primjer




B je u KB premisa za $A \wedge B \Rightarrow L$ i $B \wedge L \Rightarrow M$

Pripadni brojevi tih implikacija padaju za jedan — na 0 i 1

Slijedi L je u KB

Ulančavanje unaprijed — primjer




L je u KB premisa za $B \wedge L \Rightarrow M$ i $L \wedge M \Rightarrow P$

Pripadni brojevi tih implikacija padaju za jedan — na 0 i 1

Slijedi M je u KB

Ulančavanje unaprijed — primjer




M je u KB premisa za $L \wedge M \Rightarrow P$

Pripadni broj te implikacije pada za jedan — na 0

Slijedi P je u KB

Ulančavanje unaprijed — primjer




P je u KB premisa za $A \wedge P \Rightarrow L$ i $P \Rightarrow Q$

Pripadni brojevi tih implikacija padaju za jedan — na 0 i 0

Slijedi L je u KB i Q je u KB


Ulančavanje unaprijed — primjer



L je već u KB , pa ga ne dodajemo ponovno

Implikacija $A \wedge B \Rightarrow L$ je “višak” u KB , irelevantna za zaključak (petlja u zaključku)

Ulančavanje unaprijed — primjer



Q je u KB — upit je **istinit**

Dokaz potpunosti — gruba skica

FC izvodi **sve** atomske rečenice koje su posljedica KB

1. FC stiže na **fiksnu točku** = **nema** izvoda novih atomskih rečenica
2. Pogledajmo **završno** stanje kao model m , i dodijelimo vrijednosti istina/laž svim simbolima

3. Svaka klauzula iz originalne KB je **istinita** u m

Dokaz: (Suprotno) Neka je klauzula $a_1 \wedge \dots \wedge a_k \Rightarrow b$ **lažna** u m

Onda je $a_1 \wedge \dots \wedge a_k$ **istinita** u m i b je **lažna** u m

Stoga, algoritam sigurno **nije** stigao u fiksnu točku (nije gotov)!

4. Dakle, m je model za KB

5. Ako $KB \models q$, q je istina u **svakom** modelu od KB , uključujući m

Opća ideja: konstruiraj bilo koji model za KB koristeći ispravno zaključivanje, provjeri α

Ulančavanje unatrag (Backward chaining)

Ideja: idi **unatrag** od upita q :

da dokažemo q putem BC,

provjeri je li q već **poznat** (istina/laž), ili

dokaži putem BC sve **premise** neke implikacije iz koje **slijedi** q


Izjegni petlje: provjeri je li novi podcilj već na stogu ciljeva

Izbjegni ponavljanje posla: provjeri je li novi podcilj

1) već **dokazan** kao istinit, ili

2) već **propao** = opovrgnut (lažan)


Ulančavanje unatrag — primjer



Start: Upit = Q samo A i B su u KB , tj. već **dokazani**

Q nije dokazan, dodaj ga u stog = Q


Ulančavanje unatrag — primjer



Q slijedi iz $P \Rightarrow Q$

P nije dokazan, dodaj ga u stog = P, Q


Ulančavanje unatrag — primjer



P slijedi iz $L \wedge M \Rightarrow P$

L i M nisu dokazani, dodaj ih u stog = L, M, P, Q

Ulančavanje unatrag — primjer




L slijedi iz $A \wedge P \Rightarrow L$

P nije dokazan, ali je već na stogu, stog = L, M, P, Q

A je već dokazan (istinita činjenica u KB), pa ne ide na stog

Ulančavanje unatrag — primjer




Dakle, situacija ostaje ista kao i prije (irelevantna implikacija)

stog = L, M, P, Q

Tražimo daljnje implikacije za podciljeve u KB

Ulančavanje unatrag — primjer




L slijedi iz $A \wedge B \Rightarrow L$

A i B su već **dokazani** (istinite činjenice u KB), pa ne idu na stog


Zaključak: L je **dokazan**

Ulančavanje unatrag — primjer



L je dokazan, pa ga brišemo sa stoga, stog = *M, P, Q*

Ulančavanje unatrag — primjer




M slijedi iz $B \wedge L \Rightarrow M$

B i L su već dokazani

Zaključak: M je dokazan, pa ga brišemo sa stoga, stog = P, Q

Ulančavanje unatrag — primjer




P slijedi iz $L \wedge M \Rightarrow P$

L i M su već dokazani

Zaključak: P je dokazan, pa ga brišemo sa stoga, stog = Q

Ulančavanje unatrag — primjer




Q slijedi iz $P \Rightarrow Q$

P je već dokazan

Zaključak: Q je dokazan, pa ga brišemo sa stoga, stog = prazan

Ulančavanje unatrag — primjer



stog = prazan = gotovo

Q je dokazan, dakle Q je u KB — upit je istinit

Ulančavanje unaprijed vs. unatrag

FC je **vođeno podacima**, tj. automatska, “nesvjesna” obrada, na pr., za prepoznavanje objekata, rutinske odluke

Može raditi puno posla koji je **irelevantan** za cilj

BC je **vođeno ciljem**, primjereno za rješavanje problema, na pr., “Gdje su moji ključevi?”, “Kako se upišem na doktorski studij?”

Složenost **BC** može biti **mного manja** od linearne u veličini **KB**.

Sažetak

Logički agenti koriste **zaključivanje** na temelju **baze znanja** (KB) za izvođenje novih informacija i donošenje odluka

Osnovni koncepti logike:

- **sintaksa**: formalna struktura **rečenica**
- **semantika**: **istinitost** rečenica obzirom na **modele**
- **posljedičnost**: nužna istinitost rečenice za zadanu drugu
- **zaključivanje**: izvođenje rečenica iz drugih rečenica
- **ispravnost**: izvođenje daje **samo** posljedične rečenice
- **potpunost**: izvođenje daje **sve** posljedične rečenice

Wumpusov svijet treba mogućnost za prikaz djelomičnih i negiranih informacija, razmišljanje prema slučaju, itd.

Rezolucija (opovrgavanjem) je **potpuna** za logiku sudova FC i BC — **linearno** vrijeme (u vel. KB), **potpuni** za Hornove klauzule

Zaključak i kamo dalje

Logika sudova (propozicionalna logika) **nije** dovoljno **izražajna**

Potrebna je “jača” logika za detaljniji prikaz stvari i odnosa među njima
tzv. logika prvog reda (FOL) = logika ili račun predikata