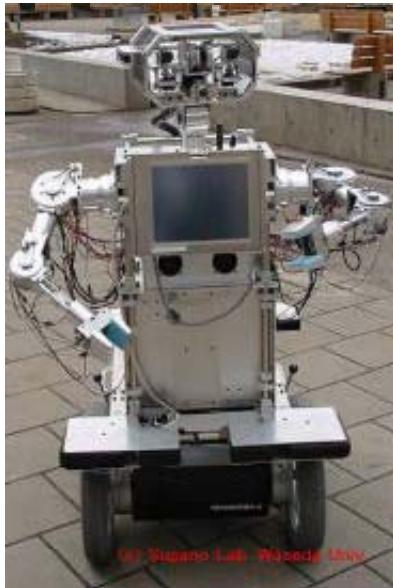


# Lekcija 10: *Gradnja mape robotske okoline*

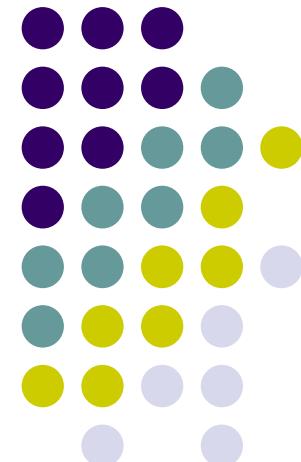
---



Prof.dr.sc. Jasmin Velagić  
Elektrotehnički fakultet Sarajevo

Kolegij: Mobilna robotika

2012/2013





## 10.1. Uvod

- Postupak **gradnje (konstrukcije) mape** modela robotske okoline temelji se na mjerenjima senzora.
- Sposobnost gradnje mape okoline mobilnog robota predstavlja važan zahtjev u mnogim primjenama mobilnog robota.
- Levitt i Lawton (1990) su postavili tri osnovna pitanja koja definiraju mapiranje i navigaciju mobilnih robota:
  - **Gdje sam ja?**
  - **Kako da iz trenutnog položaja stignem do drugih mesta?**
  - **Gdje se nalaze druga mesta u odnosu na mene?**



## Uvod

- Mape obično predstavljaju strukturalne elemente u nekoj apstraktnoj domeni (nprimjer, sa semantičkim oznakama).
- U vezi s tim **mobilni robot mora biti sposoban povezati svoju trenutnu lokaciju direktno sa vlastitom predodžbom svoje okoline.**
- Mape često ovise o interpretativnim sposobnostima osoba koje ih grade i njihovih sposobnosti da načine funkcionalne zaključke, odnosno sposobnosti koje često izostaju u računarskim sistemima.
- Nadalje, **senzorske karakteristike objekata su relevantne u gradnji i razumijevanju mapa.**

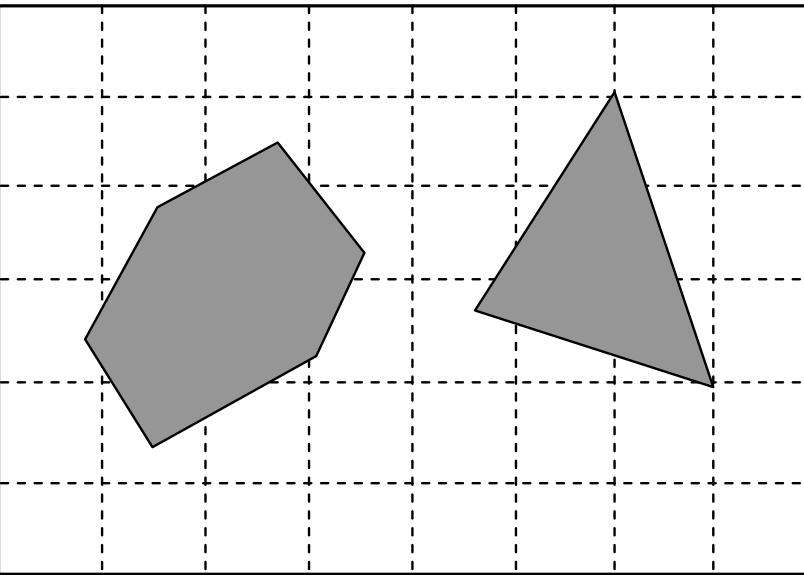


## Uvod

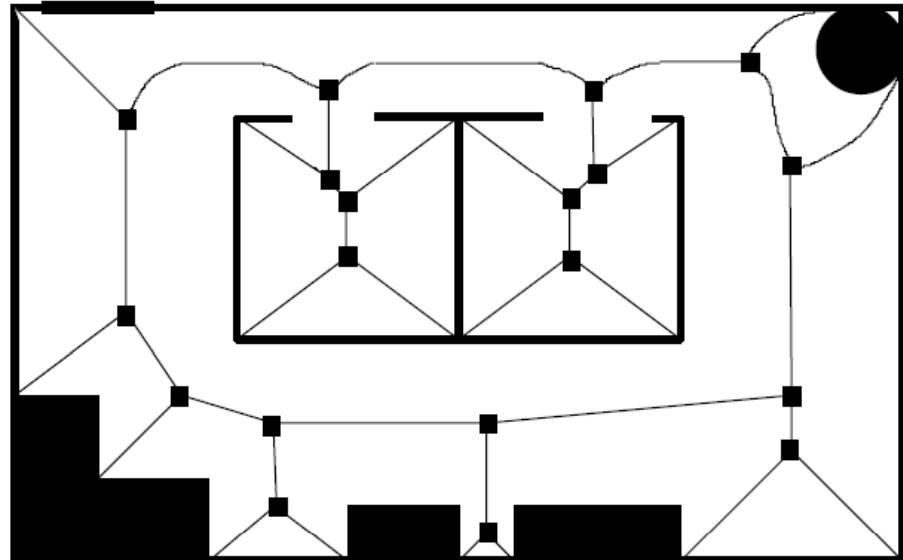
- Mape mogu biti različitih oblika.
- Postoje dvije glavne podjele na:
  - ***Metričke mape***, mape koje se temelje na absolutnom koordinatnom sistemu i numeričkoj estimaciji položaja objekata u prostoru.
  - ***Topološke ili relacijske mape***, odnosno mape koje eksplicitno prikazuju informacije povezivanja, izražene u obliku grafova.



5/81



Primjer metričke mape



Primjer topološke mape



# Uvod

Metričke mape		Topološke mape	
prednosti	<ul style="list-style-type: none"><li>- jednostavna gradnja, prikaz i održavanje,</li><li>- prepoznavanje mesta (temeljeno na geometriji) nije dvoznačno i neovisno je o tački pogleda,</li><li>- sposobnost računanja najkraćeg puta.</li></ul>	prednosti	<ul style="list-style-type: none"><li>- omogućuje efikasno planiranje, mala složenost prostora (rezolucija ovisi o složenosti okoline),</li><li>- ne zahtijeva tačno određivanje robotske pozicije,</li><li>- konvencionalan prikaz za rješavanje simboličkih problema planiranja, prirodni jezici.</li></ul>
nedostaci	<ul style="list-style-type: none"><li>- neefikasno planiranje, rezolucija ne ovisi o složenosti okoline,</li><li>- ne daje tačnu robotsku poziciju,</li><li>- slabo sučelje sa rješavanjem simboličkih problema.</li></ul>	nedostaci	<ul style="list-style-type: none"><li>- otežana konstrukcija i održavanje modela velikih okolina,</li><li>- prepoznavanje mesta zasnovano na pomoćnim objektima (orientiri) nije jednoznačno, osjetljivo na tačku pogleda,</li><li>- može dati neoptimalne putanje.</li></ul>



## Uvod

- Komparirajući prednosti i nedostatke metričkih i topoloških mapa, može se reći sljedeće:  
**metričke mape su lakše za učenje, što je posljedica njihove sposobnosti tačne lokalizacije i jednostavnosti održavanja.**
- **Topološke mape su kompaktnej i shodno tome omogućuju brže planiranje.**
- Da bi se iskoristile prednosti metričkih i topoloških mapa, često je povoljno razmatrati konstrukciju jednog prikaza korištenjem obzervacija iz drugog manje apstraktnog prikaza, odnosno izvršiti integraciju oba pristupa s ciljem postizanja tačnijeg modela okoline.



## Uvod

- Prirodnije je promatrati lokalne nego velike skalirane opise robotske okoline.
- Posljedica toga jesu hijerarhijsko-slojeviti prikazi podataka mape u sljedećih pet slojeva (Dudek (1996)):
  - **Senzorski.**
  - **Geometrijski.**
  - **Lokalno povezani.**
  - **Topološki.**
  - **Semantički.**



## Uvod

- Glavne prednosti upotrebe mapa za navigaciju mobilnih robota su:
  - **Koriste prirodne strukture tipične unutrašnje okoline** za dobivanje informacija o poziciji ne mijenjajući okolinu.
  - **Vremensko ponovno generiranje mape okoline.** Mape okoline su važne za druge zadaće mobilnih robota, kao što su globalno planiranje putanje ili izbjegavanje zamki tipa lokalni minimum u nekim postupcima lokalnog zaobilaženja prepreka.
  - Mape **omogućuju robotu da uči nove okoline i poboljšava tačnost pozicioniranja** tokom istraživanja.



## Uvod

- Nedostaci korištenja mapa su u uskoj vezi sa specifičnim zahtjevima zadovoljavanja problema navigacije.
- Mogući nedostaci su:
  - Zahtjeva postojanje dovoljne stacionarnosti, odnosno jednostavno razlikovanje karakteristika koje mogu biti predmet uspoređivanja.
  - Senzorske mape moraju biti dovoljno tačne da bi bile upotrebljive.
  - Potrebna značajna moć opažanja i procesiranja.



## Uvod

- Za uspješno izvođenje misije u unutarnjim prostorijama, mobilni roboti moraju imati sposobnost **gradnje i održavanja modela okoline**.
- Sljedeći faktori ograničavaju robotsku sposobnost učenja i upotrebe tačnih modela okoline:
  - **Senzori.** Senzori često nisu sposobni direktno mjeriti kvantitativne značajke koje su od interesa za danu primjenu. Naprimjer, kamere mijere vrstu boje, osvjetljenje, itd., dok je za navigaciju relevantan iskaz tipa “vrata se nalaze ispred robota”.



## Uvod

- **Perceptualna ograničenja.** Područje percepcije (opažanja) većine senzora (kao što su ultrasonični, kamere) je ograničeno na malo područje oko robota. Za formiranje globalne informacije, robot mora aktivno istražiti svoju okolinu.
- **Šum senzora.** Mjerenja senzora su obično prekrivena šumom. Često je distribucija šuma nepoznata (rijetko se javlja Gausov šum).
- **Drift (pomak) / klizanje.** Kretanja robota su općenito netačna. Nažalost, odometrijske pogreške se akumuliraju sa vremenom. Tada i najmanje pogreške u rotaciji mogu imati snažan utjecaj na pogrešku u translaciji.



## Uvod

- **Složenost i dinamika.** Robotske okoline su složene i dinamične, tako da je principijelno nemoguće održavati stvarne modele istih.
- **Zahtjevi u stvarnom vremenu (real-time).** Vremenski zahtjevi često zahtijevaju da unutarnji model mora biti jednostavan i lahko dostupan. Naprimjer, tačni CAD modeli složenih unutarnjih prostorija su često nezgodni ako se akcije moraju generirati brzo.
- U osnovi postoje dva opća postupka gradnje mape koja se temelje na prethodnom postojanju, odnosno nepostojanju mape okoline. Prvi pristup koristi već **postojeću mapu**, dok drugi **gradi mapu okoline** tokom kretanja robota.



## 10.2. Metričke mape

- **Metričke mape predstavljaju mape sa mrežom ćelija, gdje svaka ćelija sadrži vrijednost koja izražava prisutnost ili nepostojanje prepreka u odgovarajućem području okoline.**
- Metričke mape su poznate i pod imenima **mrežaste mape** i **mape zauzeća**.
- Zajednička osobina postupaka prostorne zauzetosti jest pohrana vrijednosti u mrežu zauzeća koje reflektiraju stupanj zauzetosti svake ćelije: **jedan** za punu zauzetost ćelije, a **nula** za praznu ćeliju.
- Alternativan pristup se sastoji u pohranjivanju izvjesnosti  $P_{zauz}$  o zauzetosti ćelije.
- Treća varijanta iskazuje veličinu zauzetosti: u cijelosti puna, djelomično ili potpuno prazna.



## Metričke mape

- Osnovna ideja je u konstrukciji mreže zauzeća na temelju senzorskih mjerena kada se robot kreće kroz okolinu.
- **Potrebno je povezati mjerena senzora sa odometrijskim informacijama i na temelju toga koristiti neki od postupaka gradnje mape.**
- Tri glavna koraka u obradi senzorskih podataka potrebnih za gradnju mape:
  - **Ekstrakcija značajki iz senzorskih podataka.**
  - **Fuzija podataka iz različitih senzorskih izvora.**
  - **Automatsko generiranje modela okoline sa različitim stupnjevima apstrakcije.**



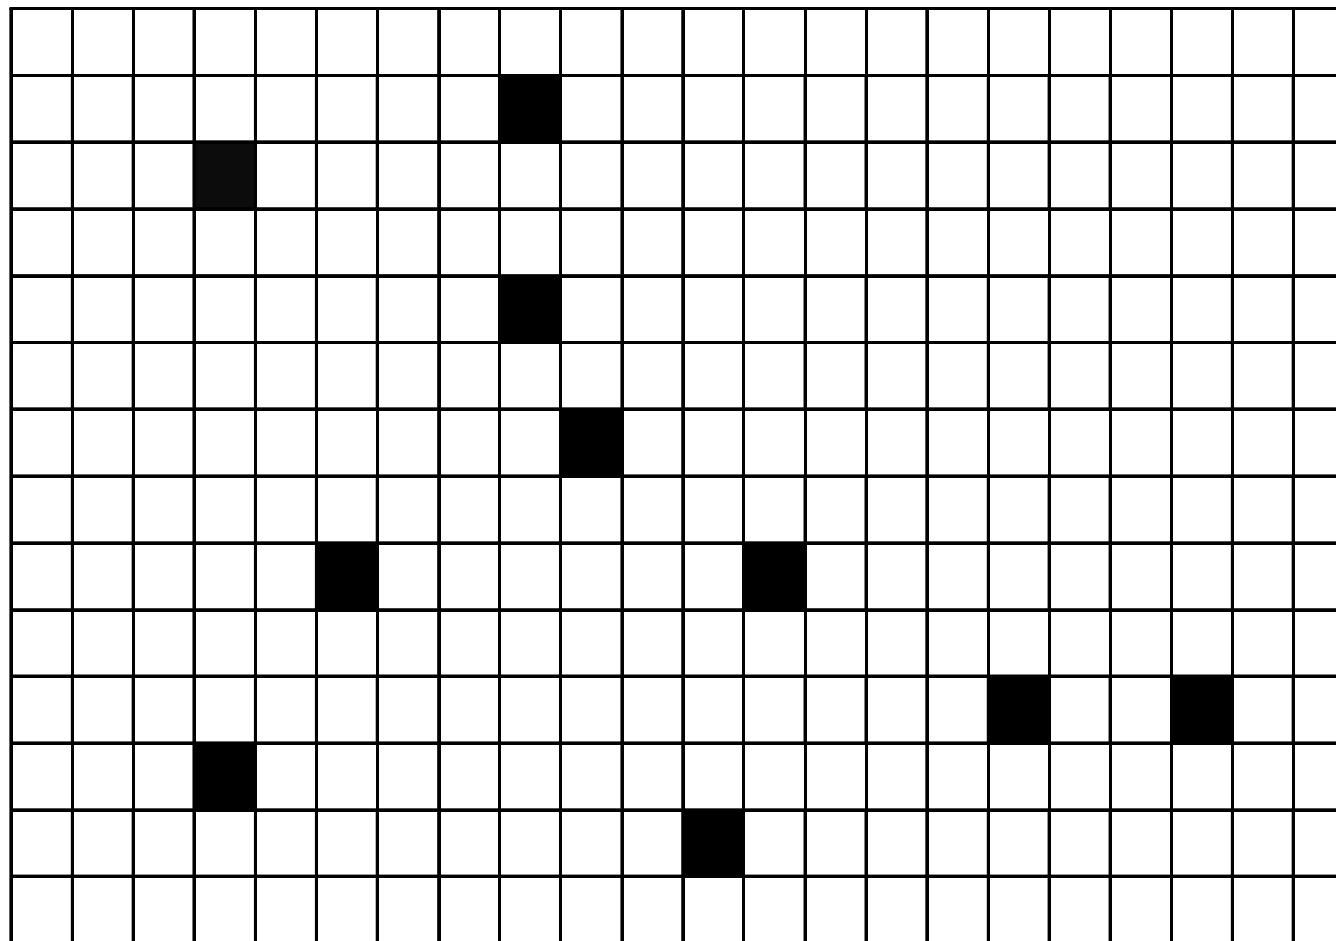
## Metričke mape

- Kod mapa zauzeća su evidentna dva komplementarna prikaza: jedan za izvjesnost da je ćelija prazna, a drugi da je puna, odnosno zauzeta.
- Održavanje i upotreba prikaza zauzetosti obično se obavljaju pomoću metoda vjerojatnosti, kao što su **Bayesova teorija** i **Dempster-Shaferova teorija uvjerenja**.
- Da bi se neka od ovih metoda mogla primijeniti zahtijeva se da vjerojatnosni model senzora povezuje različita, moguća mjerena konfiguracije okoline.
- Za potrebe gradnje metričkih mapa se u praksi, od senzora, najčešće koristi **ultrazvučni senzor** ili **sonar**.



## Metričke mape

- Mrežasta mapa prostora je matrica  $U$ , sa  $m \times n$  ćelija  $C_{ij}$ , svaka veličine  $\sigma \times \sigma$ . Jedna ćelija predstavlja dio prostora.





## Metričke mape

- Ovaj skup ćelija može se opisati na sljedeći način:

$$U = \{C_{ij} \mid i \in [1, m], j \in [1, n]\}$$

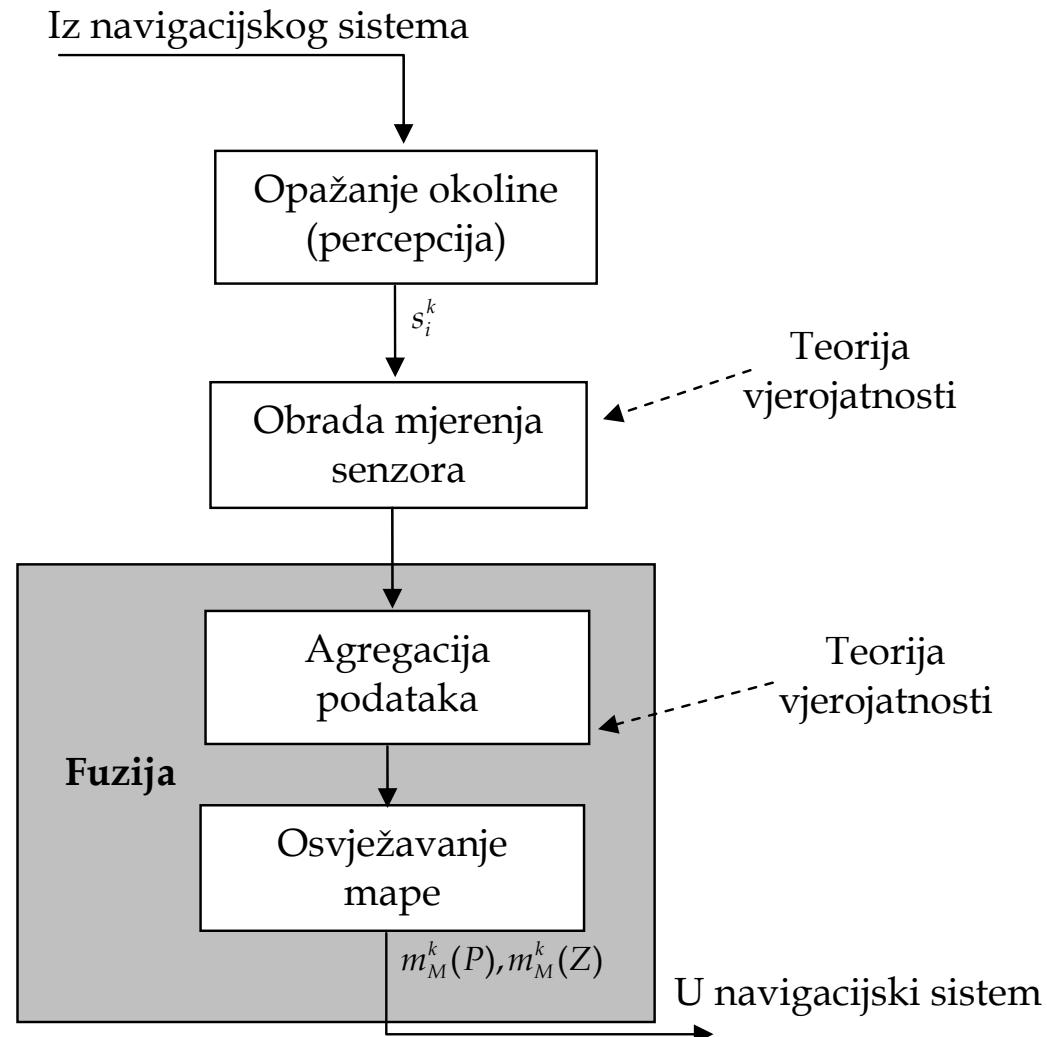
- Neka je dan skup očitanja senzora  $r = \{r_1, \dots, r_p\}$ , sakupljen sa poznatih lokacija  $L = \{l_1, \dots, l_q\}$ .
- Sistem za gradnju mape, zasnovan na mjerenu sonara, je ustvari fuzija podataka dobivenih duž staze  $[l_1 l_2 \dots l_q]$ .
- Kao rezultat, svaka ćelija  $C_{ij}$  može poprimiti vrijednost uvjerenja da je prazna ili puna.
- Ćelije obojene crnom bojom su popunjene, a bijelom prazne (pogledati prethodnu sliku).



19/81

## Metričke mape

- Dijagram toka odvijanja procesa gradnje mape prikazan je na slici.



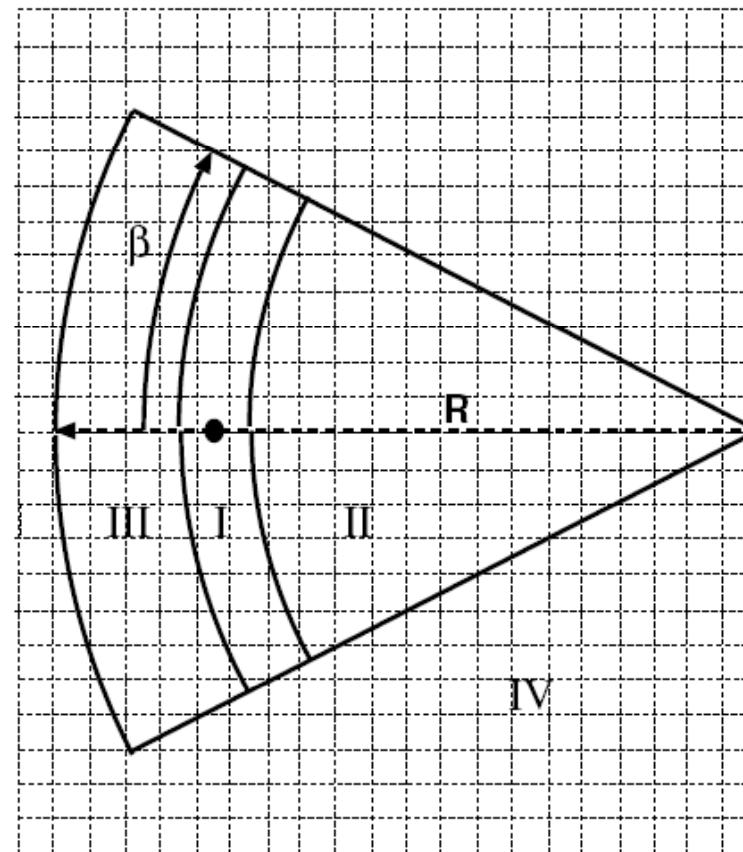


## Metričke mape

- Proces gradnje mape prostora sastoji se od tri koraka:
  - **Percepcija** - aktiviranje sonara u odgovarajućoj sekvenci dok se ne prikupi paket od  $n$  mjerenja.
  - **Obrada podataka** - ultrazvučna mjerenja se obrađuju kako bi se izgradio lokalni prikaz okoline u smislu praznog i zauzetog prostora.
  - **Fuzija** – lokalni prikaz okoline se integrira u globalni, odbacujući kontradiktorne i nedovoljne informacije.

## 10.2.1. Model sonarnog senzora

- Uvjerenje o zauzeću ćelija dobiva se projekcijom odziva sonara u mrežu zauzeća pomoću njegovog modela.
- Model sonara je funkcija ugla  $\beta$  i područja čitanja sonara  $R$ .





## Model sonarnog senzora

- Svaki element mreže sadrži vrijednost koja predstavlja uvjerenje da li je ćelija zauzeta ili prazna.
- Na prethodnoj slici je polje pogleda podijeljeno u tri regiona:
  - **Region I: postoji vjerojatnoća da je ćelija u ovom području zauzeta.**
  - **Region II: postoji vjerojatnoća da je ćelija u ovom području prazna.**
  - **Region III: vjerojatnoća o zauzeću ćelije je neodređena.**



## 10.2.2. Gradnja mape Bayesovom teorijom

- Bayesova teorija predstavlja jednu od najpoznatijih tehnika u fuziji senzorskih podataka, njihovom preslikavanju u vjerojatnoće zauzeća i kombiniranju ovih vjerojatnoća.
- Elfes i Moravec su pioniri u korištenju Bayesove teorije za potrebe gradnje mrežastih mapa zauzeća (1985).
- Ako se koriste sonarni senzori tada se može opaziti samo jedan događaj, odnosno, da li je segment ili element (ćelija)  $C_{ij}$  mape zauzet ili prazan.
- Ovo se može napisati kao  $H=\{C_O, C_E\}$ , gdje  $C_O$  označava zauzetu ćeliju i  $C_E$  praznu ćeliju.



## Gradnja mape Bayesovom teorijom

- Vjerojatnost da se  $H$  zaista dogodio je predstavljena sa  $P(H)$  i može poprimiti vrijednosti od 0 do 1:

$$0 \leq P(H) \leq 1$$

- Vjerojatnost da ćelija  $C_{ij}$  nije zauzeta može se napisati kao:

$$P(C_E) = 1 - P(C_O) \quad (*)$$

- Iz ovog izraza slijedi da se  $P(C_E)$  može izračunati ako je poznato  $P(C_O)$ .
- Vjerojatnosti  $P(H)$  i  $P(\neg H)$  se nazivaju **neuvjetne vjerojatnosti**.



## Gradnja mape Bayesovom teorijom

- Ove vjerojatnosti nisu interesantne u gradnji mape jer osiguravaju samo apriori informacije.
- Mnogo je korisnije da robot koristi funkciju koja će računati vjerojatnost da je segment  $C_{ij}$  zauzet, ili prazan, za pojedinačno mjerjenje senzora  $s$ .
- Ova vjerojatnost se naziva **uvjetna vjerojatnost**.
- U Bayesovom pristupu model senzora generira uvjetne vjerojatnosti u obliku  $P(s | H)$ , dok Bayesova pravila računaju vjerojatnosti  $P(H | s)$ .
- Uvjetna vjerojatnost  $P(H | s)$  označava vjerojatnost da je neki segment  $H$  zauzet za zadano očitanje senzora  $s$ , dok  $P(s | H)$  predstavlja vjerojatnost da mobilni robot vidi očitanje senzora  $s$  uz uvjet da je neki segment  $H$  zauzet.



## Gradnja mape Bayesovom teorijom

- Iz izraza (\*) slijedi da za neuvjetne vjerojatnosti vrijedi da je  $P(H | s) + P(\neg H | s) = 1$ .
- U mrežastoj mapi zauzeća za svaki njen element, odnosno ćeliju  $C_{ij}$ , koji je prekriven skeniranjem senzora računa se  $P(C_O | s)$  i  $P(C_E | s)$ .
- U svaku ćeliju mreže se pohranjuju vrijednosti vjerojatnosti da je ćelija zauzeta i prazna.
- Drugim riječima, ovom vjerojatnošću se izražava izvjesnost o zauzeću ćelije mreže.
- Zbog toga je neophodno imati **funkciju koja će transformirati pojedinačno mjerjenje sonara u vjerojatnost za svaku ćeliju**, kako je prikazano na slici sa slajda broj 21.



## Gradnja mape Bayesovom teorijom

- Za svaku ćeliju mreže unutar Regionala I vjerojatnoća zauzeća se računa na sljedeći način:

$$P(O) = \frac{\left(\frac{R-r}{R}\right)^+ \left(\frac{\beta-\alpha}{\beta}\right)}{2} \times Max_O \quad (**)$$
$$P(E) = 1 - P(O)$$

gdje  $r$  i  $\alpha$  označavaju udaljenost do elementa mreže i ugao koji zatvara pravac usmjeren prema elementu mreže i pravac koji se proteže sredinom konusa sonarnog senzora, respektivno.

## Gradnja mape Bayesovom teorijom

- Izraz  $(\beta - \alpha)/\beta$  govori da element mreže ima veće uvjerenje o zauzeću ako se nalazi bliže akustičnoj osi.
- Isto tako, element bliži ishodištu snopa isijavanja sonara također ima veće uvjerenje o zauzeću.
- Izraz  $Max_O$  izražava pretpostavku o tome da uvjerenje o zauzeću elementa mreže nikad ne poprima punu vrijednost, odnosno 1.
- Tako, naprimjer,  $Max_O = 0.98$  znači da vjerojatnost zauzeća elementa mreže nikad ne može biti veći od 0.98.



## Gradnja mape Bayesovom teorijom

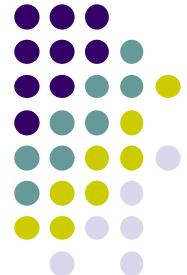
- Važno je naglasiti da region I na slici sa slajda 21. ima konačne dimenzije.
- Usljed rezolucije sonara područje čitanja 0.87 metara može u stvarnosti biti između 0.82 i 0.92, odnosno  $0.87 \pm 0.05$  metara.
- Vrijednost  $\pm 0.05$  metara naziva se **tolerancija**.
- Svaki element mreže u Regionu II se osvježava korištenjem sljedećih jednadžbi:

$$P(O) = 1 - P(E)$$

(\*\*\*\*)

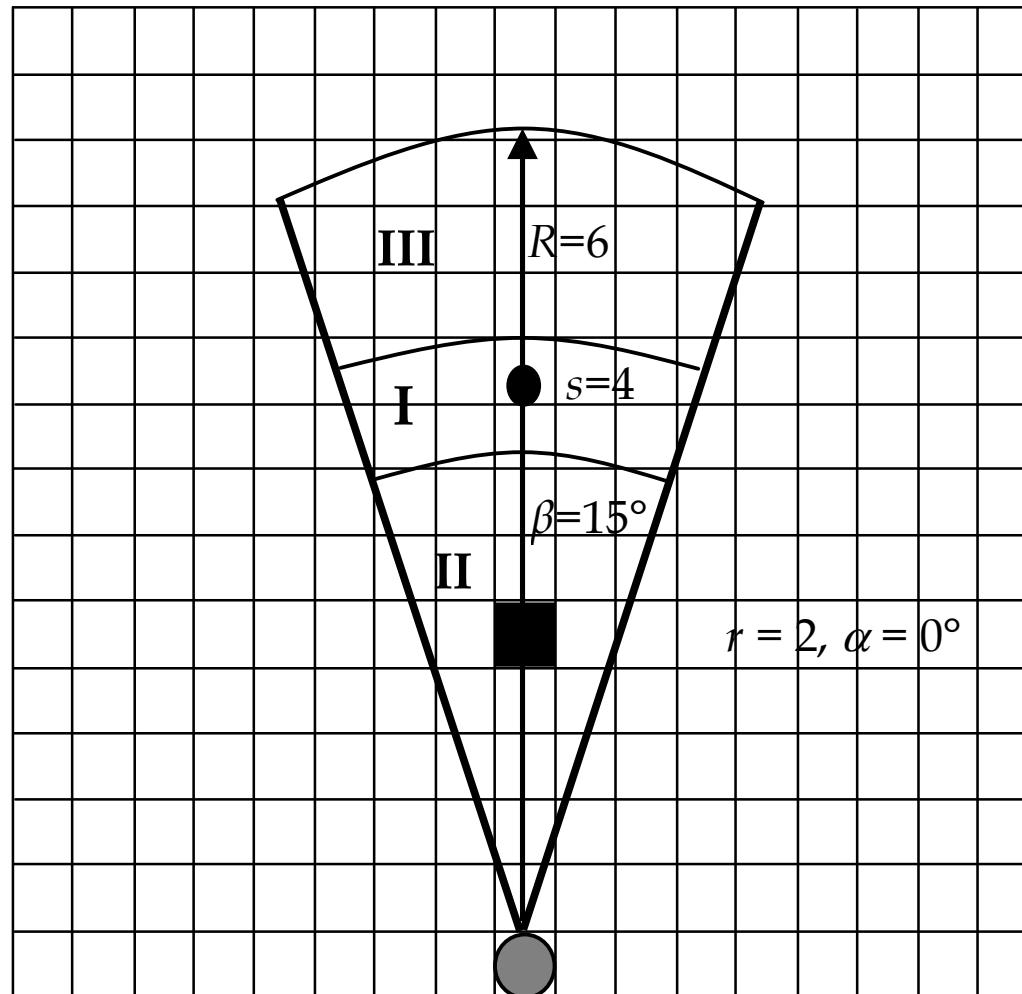
$$P(E) = \frac{\left( \frac{R-r}{R} \right) + \left( \frac{\beta-\alpha}{\beta} \right)}{2}$$

Za razliku od Regiona I, vjerojatnost da je element mreže unutar Regiona II prazan iznosi 1.



## Primjer 1.

- Na slici je prikazana mrežasta mapa zauzeća sa robotom unutar nje.



## Primjer 1.

- Robot je prikazan krugom.
- Sonarni senzor vraća vrijednost mjerenja unutar 4 metara sa tolerancijom  $\pm 0.5$  metara.
- Maksimalna vjerojatnost zauzeća elementa mreže iznosi  $Max_O = 0.98$ .
- Na udaljenosti 2 metra od ishodišta snopa isijavanja sonar registrira prepreku ( $r = 2$ ).
- Budući da je  $(4 - 0.5) > 2$  slijedi da je registrirani element mreže u Regionu II.
- Ugao pod kojim sonar vidi taj element je  $\alpha = 0^\circ$ .
- Nakon identificiranja regiona kojem pripada registrirani element mrežaste mape koriste se izrazi za računanje vjerojatnosti zauzeća ćelije.

## Primjer 1.

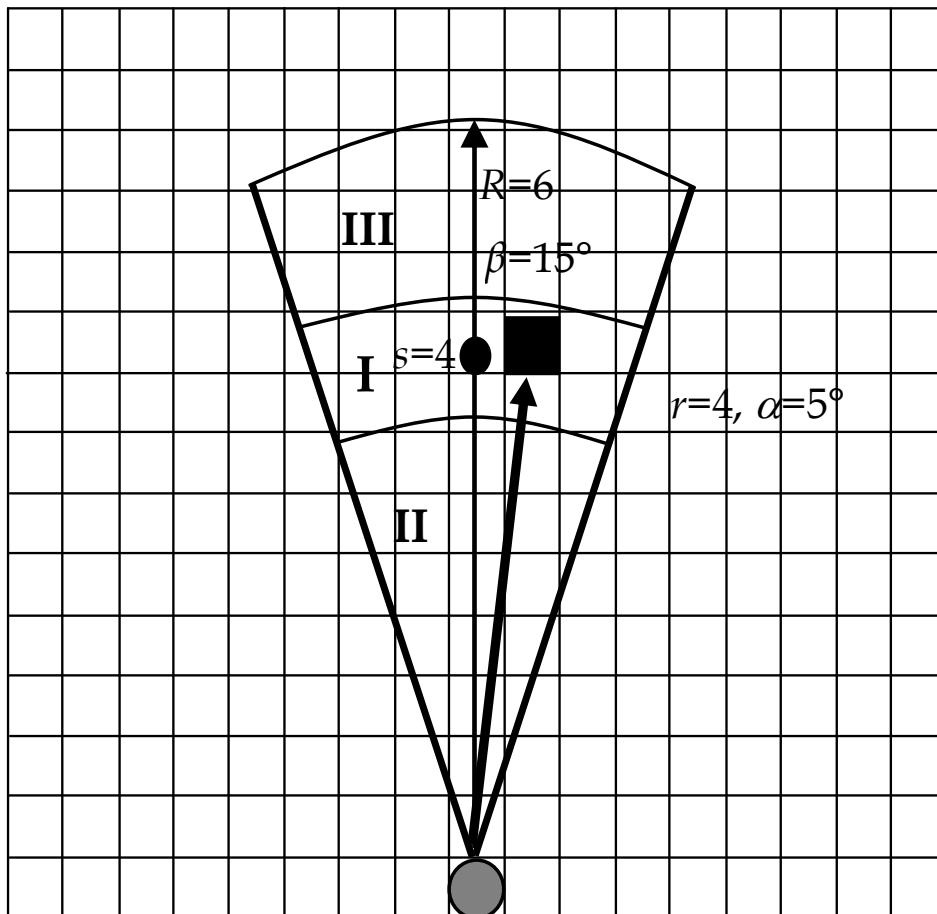
- Za zadane vrijednosti  $r$ ,  $R$ ,  $\alpha$  i  $\beta$  dobivaju se sljedeće vrijednosti vjerojatnosti zauzeća, korištenjem jednadžbi (\*\*):

$$P(E) = \frac{\left(\frac{6-2}{6}\right) + \left(\frac{15-0}{15}\right)}{2} = 0.83$$

$$P(O) = 1 - 0.83 = 0.17$$

## Primjer 2.

- Na slici ispod sonarni senzor je registrirao objekat koji prekriva ćeliju na udaljenosti  $r = 4$  metra i pod ugлом  $\alpha = 5^\circ$  i nalazi se u regionu I.



Korištenjem jednadžbi (\*\*)  
dobivaju se sljedeće  
vrijednosti vjerojatnosti  
zauzeća registriranog  
elementa mrežaste mape:

$$P(O) = \frac{\left(\frac{6-4}{6}\right) + \left(\frac{15-5}{15}\right)}{2} \times 0.98 = 0.49$$

$$P(E) = 1 - 0.49 = 0.51$$



## Gradnja mape Bayesovom teorijom

- Navedena dva primjera su demonstrirala računanje neuvjetne vjerojatnosti.
- Ranije je navedeno da je za senzorske modele mnogo prihvatljivije računati uvjetne vjerojatnosti.
- U slučaju uvjetne vjerojatnosti model senzora prikazuje  $P(s|H)$ .
- Korištenjem Bayesovog pravila izračunava se vjerojatnost zauzeća elementa mreže  $P(H|s)$  za zadano mjerjenje senzora:

$$P(H | s) = \frac{P(s | H)P(H)}{P(s | H)P(H) + P(s | \neg H)P(\neg H)}$$

(\*\*\*\*)



## Gradnja mape Bayesovom teorijom

- Prevodeći prethodni izraz u oblik sa zauzećem elementa mreže  $H$  slijedi:

$$P(O | s) = \frac{P(s | O)P(O)}{P(s | O)P(O) + P(s | E)P(E)}$$

- Vrijednosti  $P(s|O)$  i  $P(s|E)$  su poznate iz modela senzora. Neuvjetne vjerojatnosti  $P(O)$  i  $P(E)$  su ranije (unaprijed) poznate.
- Uvrštavanjem ovih vrijednosti u prethodni izraz dobiva se trenutna vrijednost zauzeća promatranog elementa mrežaste mape.
- Važno je napomenuti da u mnogim slučajevima nema unaprijed znanja na temelju kojeg bi se izračunale neuvjetne vjerojatnosti.



## Gradnja mape Bayesovom teorijom

- U tim slučajevima se uzima da je  $P(O) = P(E) = 0.5$ .
- Ako su  $P(s = 4|O) = 0.58$  i  $P(s = 4|E) = 0.42$ , tada se korištenjem izraza (\*\*\*\*) za element mrežaste mape  $C_{ij}$  dobivaju sljedeće vrijednosti vjerojatnosti zauzeća:

$$P(O | s = 4) = \frac{(0.58)(0.5)}{(0.58)(0.5) + (0.42)(0.5)} = 0.58$$

$$P(E | s = 4) = \frac{(0.42)(0.5)}{(0.42)(0.5) + (0.58)(0.5)} = 0.42$$



## Gradnja mape Bayesovom teorijom

- Svi do sada ilustrirani primjeri su razmatrali pojedinačno mjerenje i na temelju njega izračunavali neuvjetne i uvjetne vjerojatnosti zauzeća elementa mrežaste mape.
- Sada se postavlja pitanje: "**Kako kombinirati ovo mjerenje sa drugim mjeranjima (fuzija)?**".
- Prvo ovježavanje je jednostavno. Svaki element mrežaste mape je inicializiran sa a priori vjerojatnostima o zauzeću elementa mape (prazan i zauzet).
- Ako a priori vjerojatnosti zauzeća elementa mape nisu poznate, pretpostavlja se da je  $P(H) = P(\neg H) = 0.5$ .
- Nakon toga se primjenom Bayesovog pravila računaju nove vrijednosti vjerojatnosti zauzeća elementa mreže koje zamjenjuju stare, dok je a priori vrijednosti ( $P(H) = 0.5$ ).



## Gradnja mape Bayesovom teorijom

- U slučaju kada više senzora registrira zauzeće istog elementa mrežaste mape tada Bayesovo pravilo postaje (za  $n$  obzervacija  $s_1, s_2, \dots, s_n$ ):

$$P(H | s_1, s_2, \dots, s_n) = \frac{P(s_1, s_2, \dots, s_n | H)P(H)}{P(s_1, s_2, \dots, s_n | H)P(H) + P(s_1, s_2, \dots, s_n | \neg H)P(\neg H)}$$

- Ovdje se sada javlja problem generiranja  $P(s_1, s_2, \dots, s_n)$ .
- Idealno bi bilo da model sonara daje vrijednosti zauzeća svih elemenata mreže  $C_{ij}$  za  $n$  kombinacija senzorskih očitanja.
- Ako se očitanje senzora  $s_1$  može smatrati kao rezultat eksperimenta različitog od onog za  $s_2$  i ostale senzore, tada se  $P(s_1, s_2, \dots, s_n | H)$  pojednostavljuje izrazom  $P(s_1 | H) \cdot P(s_2 | H) \cdot \dots \cdot P(s_n | H)$ .



## Gradnja mape Bayesovom teorijom

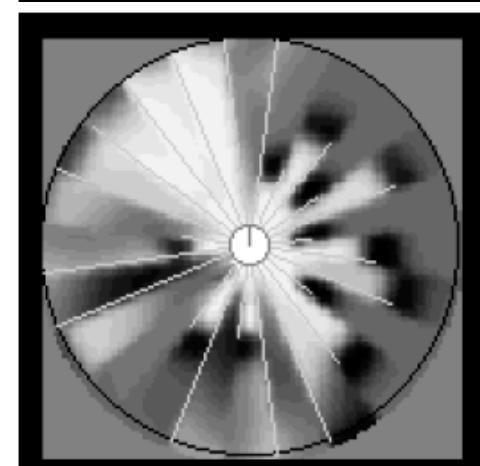
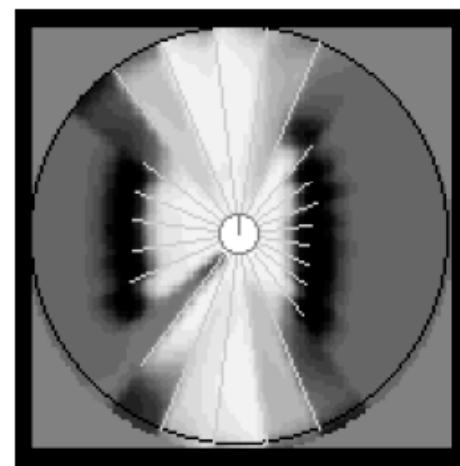
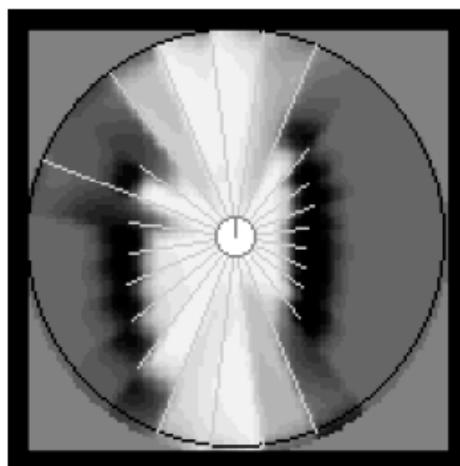
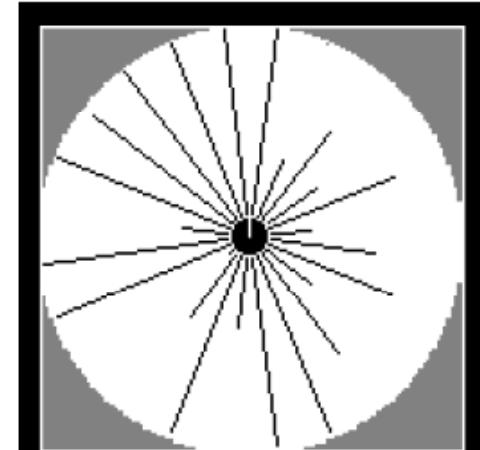
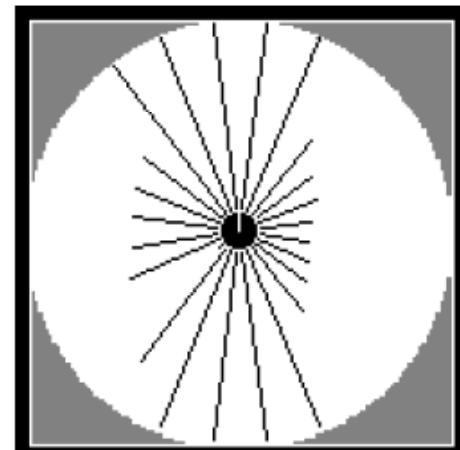
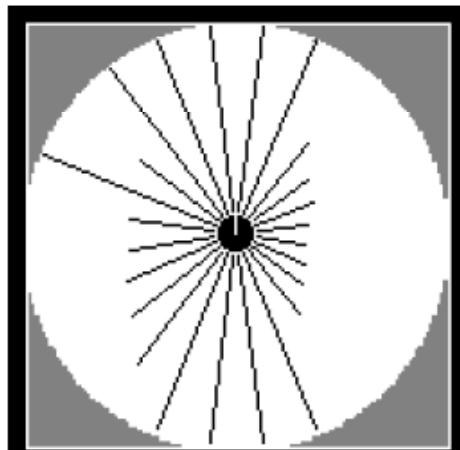
- Program mora moći zapamtiti svih  $n-1$  mjerenja (očitanja).
- Budući da ne postoji način predikcije koliko dugo će pojedinačni segment mreže biti opažen to će ovo stvarati priličan programerski problem.
- Na sljedećoj slici su prikazana tri skeniranja sonarnog senzora (slike u prvom redu) i na temelju njih generirane mreže zauzeća pomoću neuronske mreže (Thrun & Bücken, 1996).



40/81

## Gradnja mape Bayesovom teorijom

- Skeniranje sonarnim senzorom i generiranje mrežaste mape zauzeća



## Gradnja mape Bayesovom teorijom

- Primjer mrežaste mape dobivene pomoću AAAI robota (Thrun & Bücken, 1996) upotrebor Bayesove teorije vjerojatnosti na temelju mjerenja sonarnih senzora prikazan je na slici.





### 10.2.3. Gradnja mape D-S teorijom

- **Dempster-Shaferova teorija uvjerenja spada u skupinu subjektivno probabilističkih tehnika koje imaju mogućnost suočavanja sa neizvjesnim i nekompletним informacijama.**
- Ona je istovremeno teorija uvjerenja, jer koristi stupanj potpore temeljen na uvjerenju, i teorija vjerojatnosti, budući da koristi kombinaciju uvjerenja.
- Također, Dempsterova teorija se temelji na pojedinačnom mišljenju i mnogo je interesantnija u području uvjerenja i vjerodostojnosti nego vjerojatnosti.
- Ova teorija omogućuje prikaz neznanja i stoga je funkcija djelomičnog znanja.



## Gradnja mape D-S teorijom

- Probabilističke tehnike (npr. Bayesova), razmatraju pojedinačne propozicije i pridružuju svakoj kauzalni utjecaj ili numeričku estimaciju stupnja uvjerenja kojeg ona može imati.
- **Jedno od ograničenja probabilističkih pristupa jest da oni koriste pojedinačne kvantitete za mjeru (svakoj propoziciji se pridružuje jedna vrijednost), što može biti veoma složena situacija.**
- Dempster-Shaferova teorija uvjerenja razmatra **skupove propozicija i pridružuje svakoj od njih interval** [uvjerenje, vjerodostojnost], unutar kojeg moraju postojati stupnjevi uvjerenja za svaku propoziciju.
- Ova mjera uvjerenja, označena sa *Bel*, rangirana je od nule, što znači neuvjerenje za skup propozicija, do jedan, što predstavlja uvjerenje izvjesnosti.

## Elementi D-S teorije uvjerenja

- Dempster-Shaferova teorija uvjerenja karakterizirana je **sistemom razlikovanja** (engl. frame of discernment, *FOD*), **dodjeljivanjem osnovne vjerojatnosti** (engl. basic probability assignment, *BPA*), **uvjerenjem** (engl. belief, *Bel*), **vjerodostojnošću** (engl. plausibility, *Pls*) i **Dempsterovim pravilom kombiniranja** (engl. Dempster's rule of combination).
- **Definicija 1.** **Sistem razlikovanja** (*FOD*), označen sa  $\Theta$ , definiran je kao konačni skup oznaka (engl. labels) koje predstavljaju uzajamno isključive događaje (engl. mutually exclusive events).



## Elementi D-S teorije uvjerenja

- **Definicija** 2. **Pridruživanje osnovne vjerojatnosti** (BPA) je funkcija  $m: \Psi \rightarrow [0, 1]$ , gdje je  $\Psi$  skup svih podskupova  $\Theta$ . Moć skupa  $\Theta$  je  $\Psi = 2^{\Theta}$ . Funkcija  $m$  može se interpretirati kao distribucija vjerojatnosti svake od oznaka u  $\Psi$ -u, sa zadovoljenjem sljedećeg kriterija:

$$\sum_{A \subset \Psi} m(A) = 1$$
$$m(\emptyset) = 0$$

gdje je  $\emptyset$  prazan skup

- Tako je oznaci  $A$  pridružena osnovna vjerojatnost izražena brojem  $m(A)$ , koja opisuje stupanj uvjerenja da je to stvarno  $A$ .



## Elementi D-S teorije uvjerenja

- Međutim, totalno uvjerenje pripisano A-u je suma svih brojčano izraženih vjerojatnosti pridruženih A-u i njegovim podskupovima:

$$Bel(A) = \sum_{\forall B: B \subseteq A} m(B)$$

- Definicija 3.** Funkcija uvjerenja  $Bel: \mathcal{P} \rightarrow [0,1]$  je kvantitet uvjerenja koji podržava propozicije  $A$  i  $B$  i ima sljedeća svojstva:

$$Bel(\emptyset) = 0$$

$$Bel(\Theta) = 1$$

$$Bel(A) + Bel(\neg B) \leq 1$$

$$Bel(A) \leq Bel(B), \text{ ako je } A \subset B$$

$$Bel(A \cap B) = \min(Bel(A), Bel(B))$$



## Elementi D-S teorije uvjerenja

- **Definicija** 4. Vjerodostojnost ( $Pls$ ) propozicije  $A$  može se izraziti kao vrijednost uvjerenja koja ne podržava njenu negaciju (negaciju od  $A$ ). Ona je definirana kao  $Pls: \Psi \rightarrow [0, 1]$ , sa sljedećim svojstvima:

$$Pls(A) = 1 - Bel(\neg A) = 1 - \sum_{\forall B: A \not\subset B} m(B)$$

$$Pls(A) - Bel(B) \geq 0$$

$$Pls(A \cup B) = \max(Pls(A), Pls(B))$$

## Elementi D-S teorije uvjerenja

- **Definicija 5.** Stanje svake oznake (opisano sa BPA) ponovno se postavlja kombiniranjem novog neovisnog izvora uvjerenja korištenjem Dempsterovog pravilo kombinacije, odnosno zaključivanja, na sljedeći način:

$$m_1 \oplus m_2(A) = \frac{\sum_{\forall B, C \in \Psi : B \cap C = A} m_1(B)m_2(C)}{1 - \sum_{\forall B, C \in \Psi : B \cap C = \emptyset} m_1(B)m_2(C)}$$
$$m_1 \oplus m_2(\emptyset) = 0$$



## Primjer 3.

- Pretpostavimo da je  $\Theta = \{A, B, C\}$  i  $m_1(\{A\}) = 0.5$ ,  
 $m_1(\{A, B\}) = 0.5$ ,  $m_1(\{A, B, C\}) = 0.5$ ,  $m_1(\text{ostali}) = 0$ ,  
 $m_2(\{B, C\}) = 0.4$ ,  $m_2(\{A, B, C\}) = 0.6$ ,  $m_2(\text{ostali}) = 0$ .  
Izračunati  $m_1 \oplus m_2$ .
- Moć skupa  $\Theta$  je:

$$2^{\Theta} = \{\emptyset, \{A\}, \{B\}, \{C\}, \{A, B\}, \{B, C\}, \{A, C\}, \{A, B, C\}\}$$

- Suma  $\Gamma = \sum_{\forall X, Y \in \Psi : X \cap Y = \emptyset} m_1(X)m_2(Y)$  jednaka je:

$$\begin{aligned}\Gamma &= \sum_{\forall X, Y \in \Psi : X \cap Y = \emptyset} m_1(X)m_2(Y) = m_1(\{A\})m_2(\{B, C\}) + m_1(\{B\})m_2(\{A, C\}) + m_1(\{C\})m_2(\{A, B\}) \\ &\quad + m_1(\{A, C\})m_2(\{B\}) + m_1(\{A, B\})m_2(\{C\}) + m_1(\{B, C\})m_2(\{A\}) \\ &\quad + m_1(\{\emptyset\})m_2(\{A, B, C\}) + m_1(\{A, B, C\})m_2(\{\emptyset\}) \\ &= 0\end{aligned}$$

## Primjer 3.

- Korištenjem Dempsterovog pravila kombiniranja dobivaju se sljedeće sume:

$$\begin{aligned}
 (m_1 \oplus m_2)(\{A\}) &= \frac{1}{1-\Gamma} [m_1(\{A\})m_2(\{A,C\}) + m_1(\{A\})m_2(\{A,B\}) + m_1(\{A,B\})m_2(\{A\}) \\
 &\quad + m_1(\{A,C\})m_2(\{A\}) + m_1(\{A\})m_2(\{A,B,C\}) + m_1(\{A,B,C\})m_2(\{A\}) \\
 &\quad + m_1(\{A,C\})m_2(\{A,B\}) + m_1(\{A,B\})m_2(\{A,C\})] \\
 &= 1 \times (0 + 0 + 0 \times 0.6 + 0.5 \times 0 + 0 + 0.5 \times 0 + 0.5 \times 0) \\
 &= 0
 \end{aligned}$$

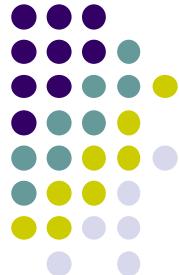
$$\begin{aligned}
 (m_1 \oplus m_2)(\{B\}) &= \frac{1}{1-\Gamma} [m_1(\{B\})m_2(\{B,C\}) + m_1(\{B\})m_2(\{A,B\}) + m_1(\{A,B\})m_2(\{B\}) \\
 &\quad + m_1(\{B,C\})m_2(\{B\}) + m_1(\{B\})m_2(\{A,B,C\}) + m_1(\{A,B,C\})m_2(\{B\}) \\
 &\quad + m_1(\{A,B\})m_2(\{B,C\}) + m_1(\{B,C\})m_2(\{A,B\})] \\
 &= 1 \times (0 \times 0.4 + 0 + 0 \times 0.6 + 0.5 \times 0 + 0 + 0.5 \times 0 + 0.5 \times 0.4 + 0) \\
 &= 0.2
 \end{aligned}$$



## Primjer 3.

$$\begin{aligned}(m_1 \oplus m_2)(\{C\}) &= \frac{1}{1-\Gamma} [m_1(\{C\})m_2(\{A,C\}) + m_1(\{C\})m_2(\{B,C\}) + m_1(\{A,C\})m_2(\{C\}) \\&\quad + m_1(\{B,C\})m_2(\{C\}) + m_1(\{C\})m_2(\{A,B,C\}) + m_1(\{A,B,C\})m_2(\{C\}) \\&\quad + m_1(\{A,C\})m_2(\{B,C\}) + m_1(\{B,C\})m_2(\{A,C\})] \\&= 1 \times (0 + 0 \times 0.4 + 0 \times 0.6 + 0 + 0 + 0.5 \times 0 + 0.5 \times 0.4 + 0) \\&= 0\end{aligned}$$

$$\begin{aligned}(m_1 \oplus m_2)(\{A,B\}) &= \frac{1}{1-\Gamma} [m_1(\{A,B\})m_2(\{A,B\}) + m_1(\{A,B\})m_2(\{A,B,C\}) \\&\quad + m_1(\{A,B,C\})m_2(\{A,B\})] \\&= 1 \times (0.5 \times 0 + 0.5 \times 0.6 + 0.5 \times 0) \\&= 0.3\end{aligned}$$



## Primjer 3.

$$\begin{aligned}(m_1 \oplus m_2)(\{A, C\}) &= \frac{1}{1-\Gamma} [m_1(\{A, C\})m_2(\{A, C\}) + m_1(\{A, C\})m_2(\{A, B, C\}) \\&\quad + m_1(\{A, B, C\})m_2(\{A, C\})] \\&= 1 \times (0 + 0 \times 0.6 + 0.5 \times 0) \\&= 0\end{aligned}$$

$$\begin{aligned}(m_1 \oplus m_2)(\{B, C\}) &= \frac{1}{1-\Gamma} [m_1(\{B, C\})m_2(\{B, C\}) + m_1(\{B, C\})m_2(\{A, B, C\}) \\&\quad + m_1(\{A, B, C\})m_2(\{B, C\})] \\&= 1 \times (0 \times 0.4 + 0 \times 0.6 + 0.5 \times 0.4) \\&= 0.2\end{aligned}$$

$$\begin{aligned}(m_1 \oplus m_2)(\{A, B, C\}) &= \frac{1}{1-\Gamma} [m_1(\{A, B, C\})m_2(\{A, B, C\})] \\&= 1 \times (0.5 \times 0.6) \\&= 0.3\end{aligned}$$

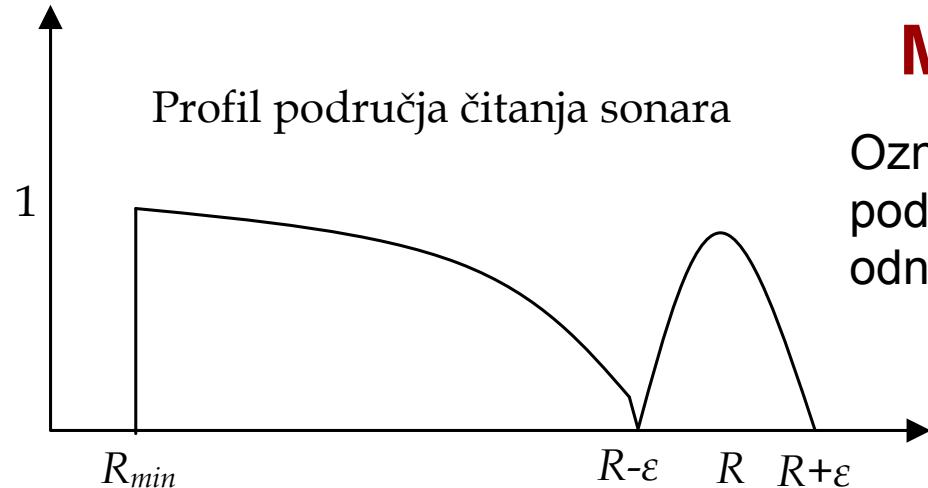
## Gradnja mape D-S teorijom

- Treba napomenuti da tokom faze percepcije sonarni senzori emitiraju pakete impulsa sa takvim razmacima da je interferencija svedena na minimum.
- Da bi se mogle uzeti u obzir osobine senzora u modeliranju znanja o zauzeću ćelija koristi se Dempster-Shaferova teorija uvjerenja.
- Uvjerenje o zauzeću ćelija dobiva se projekcijom odziva sonara u mrežu zauzeća pomoću modela sonara.
- **Model sonara je funkcija ugla i područja čitanja sonara** (sljedeća slika).



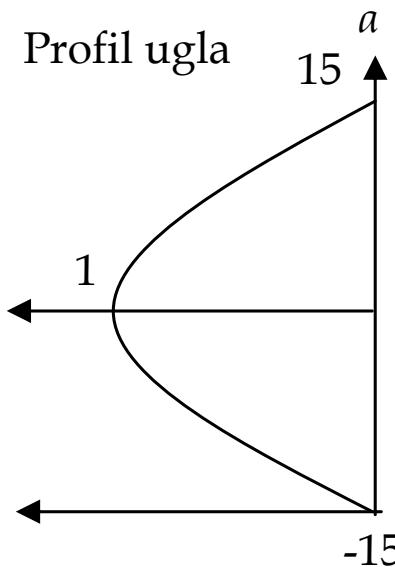
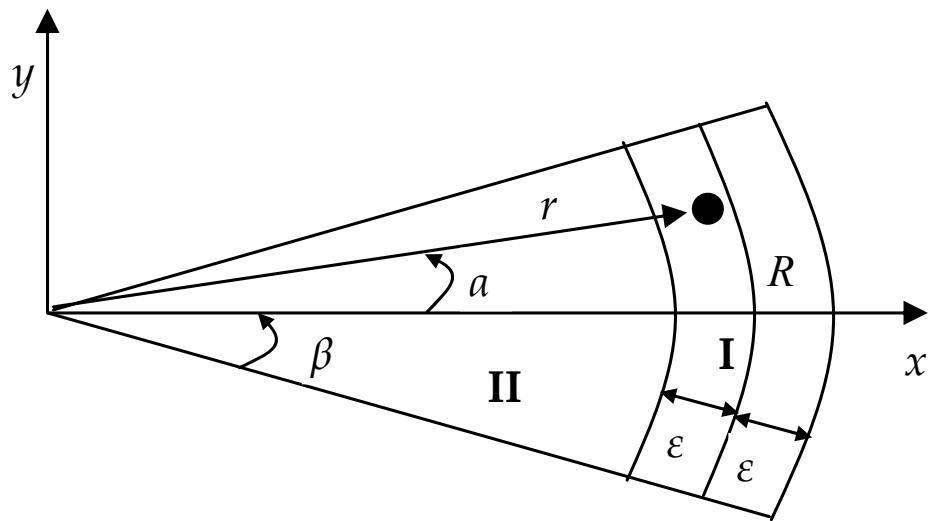
54/81

# Gradnja mape D-S teorijom



## Model sonara

Oznakama I i II prikazana su područja eventualno zauzetog, odnosno, praznog prostora.





## Gradnja mape D-S teorijom

- Uvjerenja o zauzeću ćelija unutar ovih područja su (Elfes, 1987):
- a) Područje I, gdje je  $R-\varepsilon < r < R+\varepsilon$ :

$$m(O) = \frac{\left(\frac{\beta - \alpha}{\beta}\right)^2 + \left(\frac{\varepsilon - |R - r|}{\varepsilon}\right)^2}{2} \times Max_O$$

$$m(E) = 0$$

$$m(\{E, O\}) = 1 - m(O)$$



## Gradnja mape D-S teorijom

- b) Područje II, gdje je  $R_{min} < r < R-\varepsilon$ :

$$m(O) = 0$$

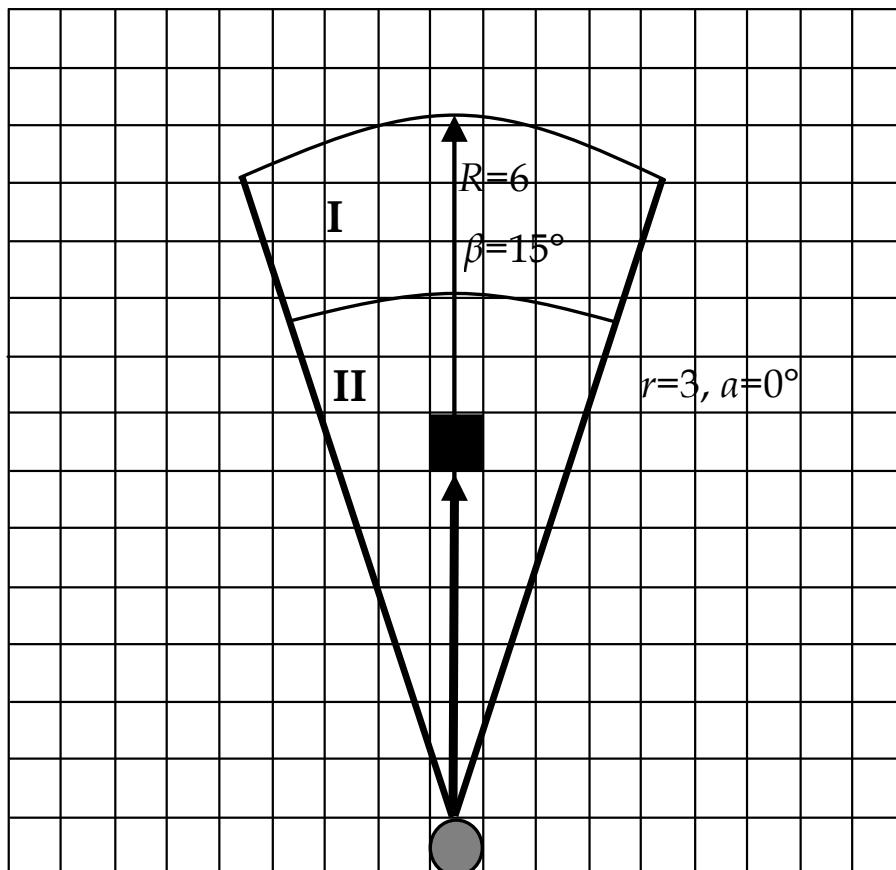
$$m(E) = \frac{\left(\frac{\beta - \alpha}{\beta}\right)^2 + \left(\frac{R - \varepsilon - r}{R - \varepsilon}\right)^2}{2}$$

$$m(\{E, O\}) = 1 - m(E)$$

gdje su  $(r, \alpha)$  koordinate tačke unutar konusa sonara (pozicija i orijentacija), a  $\varepsilon$  označava toleranciju za područje zauzeća. Izbor prikladnog  $\varepsilon$ -a je bitan za pravilnu interpretaciju zauzeća ćelija na temelju mjerjenja sonara.

## Primjer 4.

- Pretpostavimo da se robot nalazi u elementu mreže  $C_{15,9}$  i da je potrebno ispitati zauzeće elementa  $C_{8,9}$  na slici.



Element mrežaste mape  $C_{8,9}$  nalazi se u regionu II, pa vrijedi:

$$m(O) = 0$$

$$m(E) = \frac{\left(\frac{15-0}{15}\right)^2 + \left(\frac{6-1-3}{6-1}\right)^2}{2} = \frac{1 + \frac{2}{5}}{2} = \frac{7}{10}$$

$$m(\{E, O\}) = 1 - \frac{7}{10} = \frac{3}{10}$$

Prema tome preovladava uvjerenje da je ćelija (8,9) prazna.

# Gradnja mape D-S teorijom

## Fuzija senzorskih podataka

- Dva su osnovna zadatka fuzije: **agregacija podataka iz različitih izvora i osvježavanje mape.**
- Kod gradnje mape prvo se specificira kako obraditi mjerenja senzora da bi se svakoj ćeliji pridružile osnovne vrijednosti (BPA).
- Pridruživanje osnovnih vrijednosti  $m_{i,j}^{S(r)}(E)$ ,  $m_{i,j}^{S(r)}(O)$  i  $m_{i,j}^{S(r)}(\{O, E\})$ , koje odgovaraju mjerenu senzora  $S(r)$  dobivenog na udaljenosti  $r$ , obavlja se na temelju jednadžbi sa slajdova 55 i 56.
- Funkcije  $m_{i,j}(E)$ ,  $m_{i,j}(O)$  i  $m_{i,j}(E, O)$  označavaju uvjerenja da je ćelija  $i, j$  prazna, zauzeta i nepoznata.
- Prema tome, stanje svake ćelije je opisano brojevima koji izražavaju pridruživanje osnovne vjerojatnosti svakoj oznaci u  $\Psi$ .

# Gradnja mape D-S teorijom

## Fuzija senzorskih podataka

- Međutim poznato je da za svaku ćeliju  $i, j$  u mreži vrijedi:

$$m_{i,j}(\phi) = 0$$

$$\sum_{A \subset \Psi} m_{i,j}(A) = m_{i,j}(\phi) + m_{i,j}(E) + m_{i,j}(O) + m_{i,j}(\{E, O\}) = 1$$

- Svaka ćelija u mapi se prvo inicijalizira sljedećim vrijednostima:

$$m_{i,j}(E) = m_{i,j}(O) = 0, \quad m_{i,j}(\{E, O\}) = 1 \quad (\text{*****})$$

# Gradnja mape D-S teorijom

## Fuzija senzorskih podataka

- Dok se robot kreće, vrši se skeniranje okoline i tako dobiveni podaci se ubacuju u mapu.
- Osvježavanje mape obavlja se na temelju osnovnih vjerojatnosti pridruženih ćelijama ranije mape i trenutnim mjeranjima senzora.
- Ekplizitno, osvježene osnovne vjerojatnosti za svaku ćeliju u mapi postaju:

$$m_M^t(E) = m_M^{t-1} \oplus m_S^t(E) = \frac{m_M^{t-1}(E)m_S^t(E) + m_M^{t-1}(E)m_S^t(\{E, O\}) + m_M^{t-1}(\{E, O\})m_S^t(E)}{1 - m_M^{t-1}(E)m_S^t(O) - m_M^{t-1}(O)m_S^t(E)}$$

$$m_M^t(O) = m_M^{t-1} \oplus m_S^t(O) = \frac{m_M^{t-1}(O)m_S^t(O) + m_M^{t-1}(O)m_S^t(\{E, O\}) + m_M^{t-1}(\{E, O\})m_S^t(O)}{1 - m_M^{t-1}(E)m_S^t(O) - m_M^{t-1}(O)m_S^t(E)}$$



## Gradnja mape D-S teorijom

### Fuzija senzorskih podataka

- U procesu fuzije mjerjenja senzora se kombiniraju sa ranjom mapom i na taj način se dobiva nova mapa.
- Mapa se na ovaj način osvježava tokom kretanja mobilnog robota.
- Zbog potreba navigacije u realnom vremenu mapa je lokalnog karaktera i informacije o zauzeću ćelija pređene ravnine se ne pamte, zbog računarske uštede.
- Samo ćelije koje se nalaze u vidokrugu sonara se pamte i osvježavaju.



## Gradnja mape D-S teorijom

### Fuzija senzorskih podataka

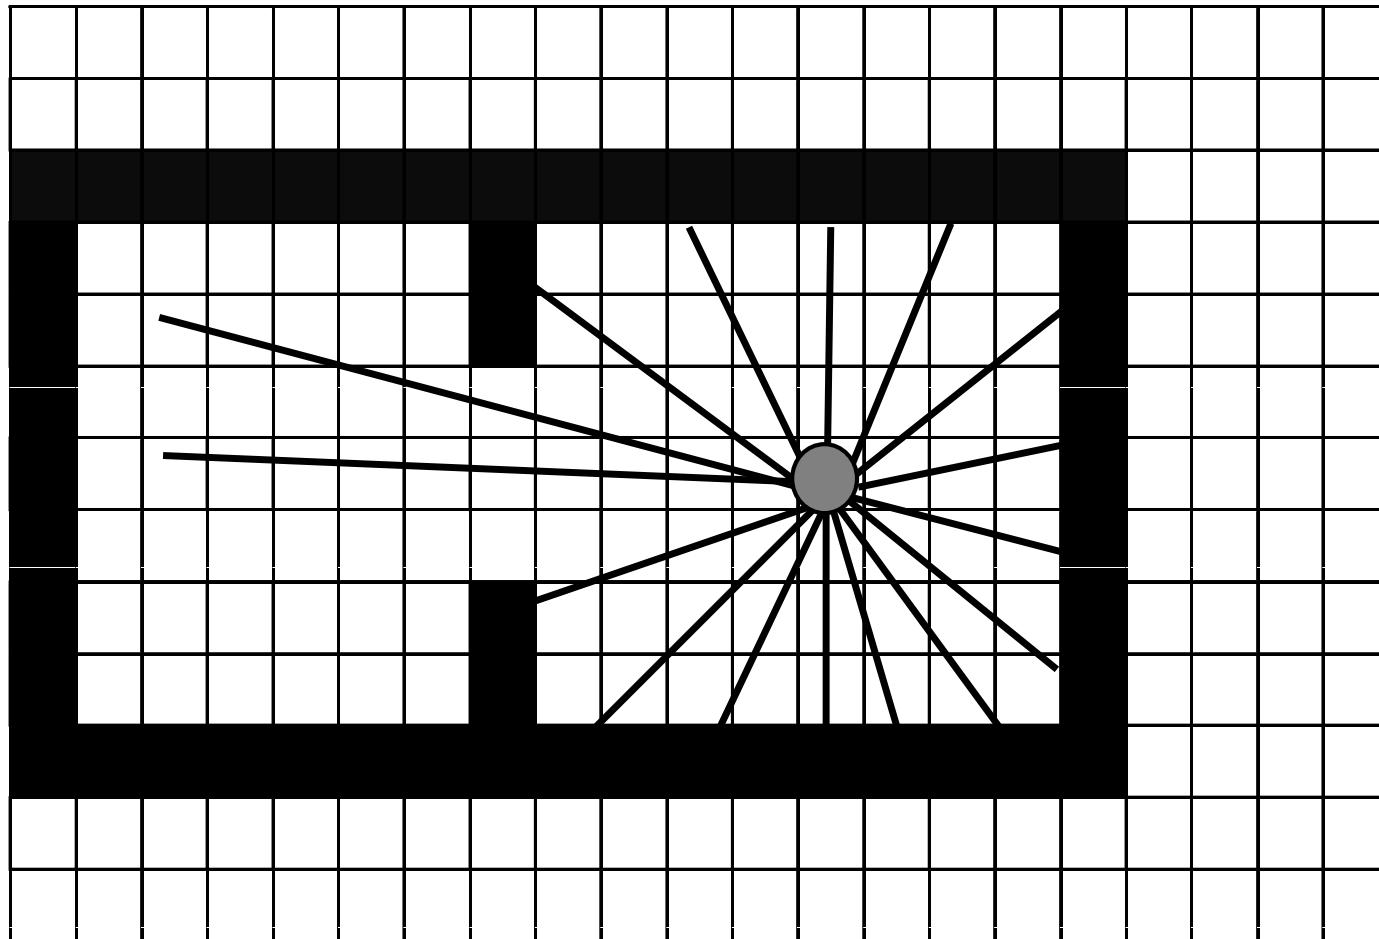
- Prednost ovog pristupa je da eksplisitni prikaz dvoznačnosti nije samo u mjerenjima senzora  $m_S(E, O)$ , već i u pohranjenom uvjerenju  $m_M(E, O)$ .
- Jedno mjerjenje kruga sonara (šesnaest sonara), obavi se u vremenskom intervalu trajanja 0.6 sekunde.
- Ova mjerena su prikazana na slici podebljanim linijama koje izlaze iz mobilnog robota.
- Nakon svakog mjerjenja mapa se osvježava prikupljanjem novih podataka pribavljenih od sonara i njihovim kombiniranjem sa ranijim podacima u mapi.



63/81

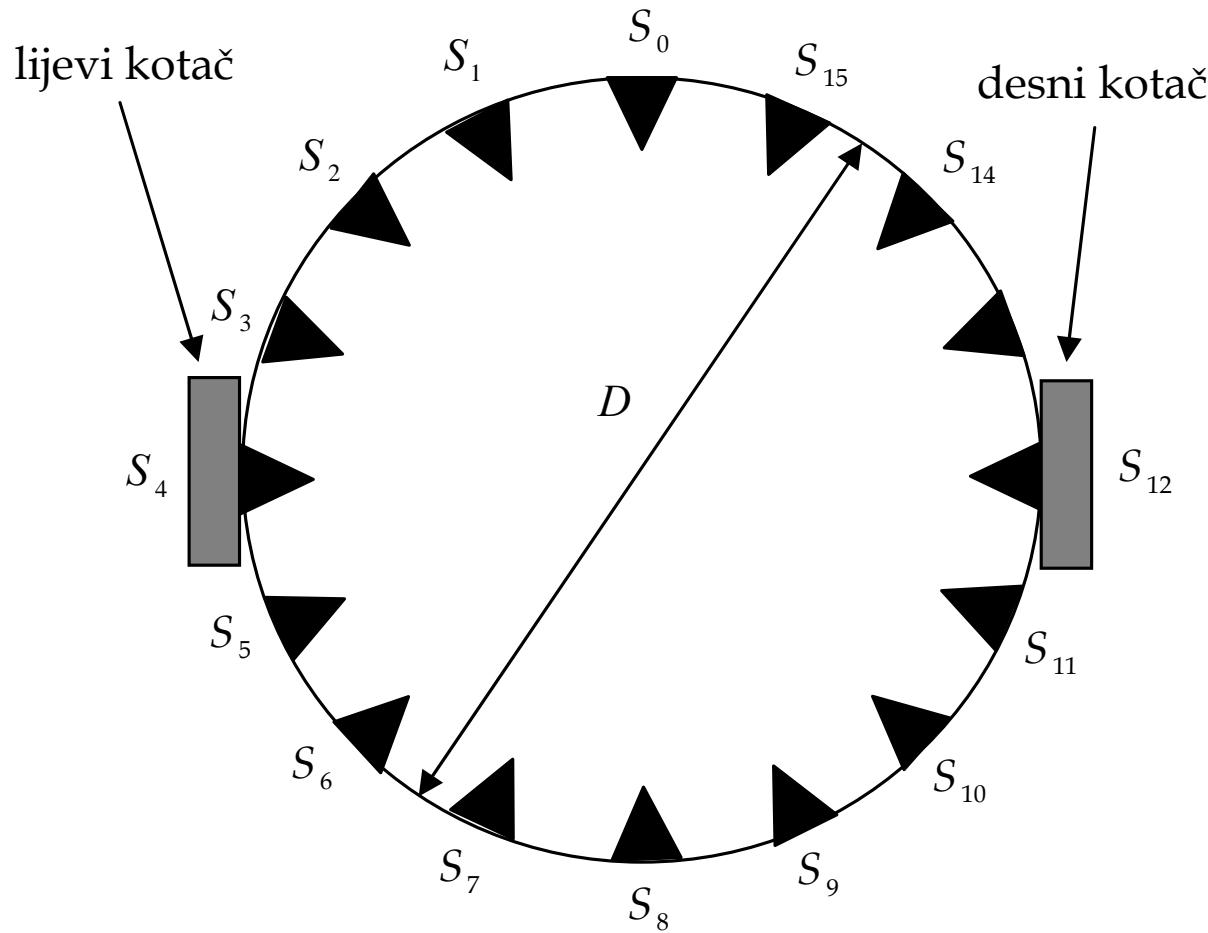
# Gradnja mape D-S teorijom

## Fuzija senzorskih podataka



## Primjer 5.

- Da bi se bolje razumio primjer na sljedećoj slici je prikazana platforma mobilnog robota sa 16 sonara raspoređenih u kružnom prstenu.



## Primjer 5.

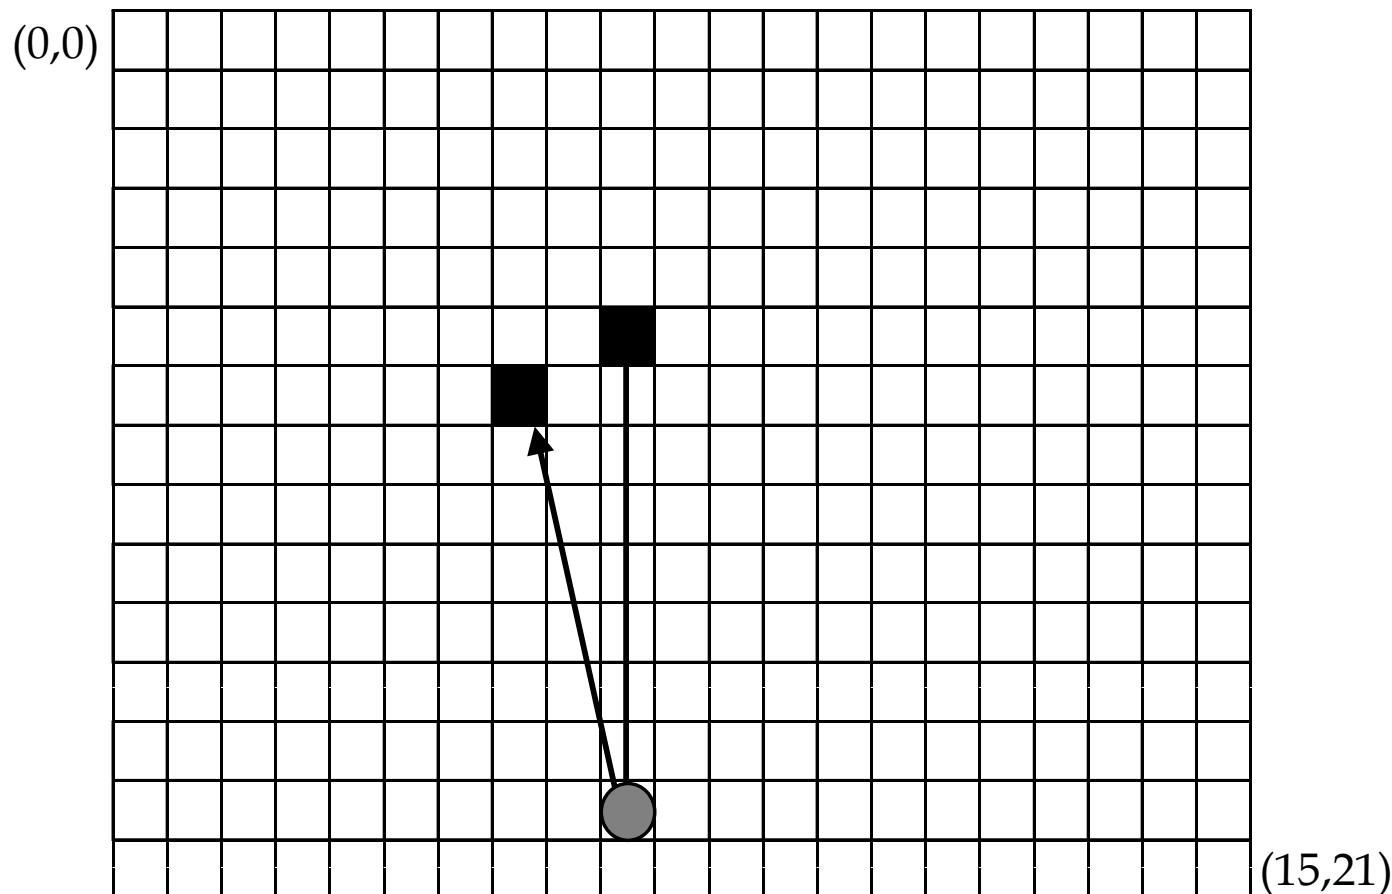
- Neka se robot u početnom trenutku nalazi u ćeliji  $(14,10)$ , odnosno  $C_{14,10}$ .
- Prije početka kretanja sve ćelije imaju osnovne vjerojatnosti (\*\*\*\*\*).
- Nakon starta dobivena su mjerena sonara  $S_0$  i  $S_1$  na udaljenostima  $r_0 = 7$  i  $r_1 = 5$  pod uglovima  $\alpha_0 = 0^\circ$  i  $\alpha_1 = 3^\circ$  (slika ispod) (Velagić, 2005; Velagić, Lačević i Peruničić, 2006).

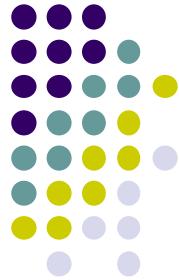


66/81

## Primjer 5.

- Neka se robot u početnom trenutku nalazi u ćeliji  $(14, 10)$ , odnosno  $C_{14, 10}$ .





## Primjer 5.

- Uvjerjenja da su ćelije (7,8) i (10,6) zauzete su:

$$m_{7,8}^{S_0(7)}(O) = \frac{\left(\frac{15-0}{15}\right)^2 + \left(\frac{1.5 - |8-7|}{1.5}\right)^2}{2} \cdot 0.98 = 0.54488$$

$$m_{7,8}^{S_0(7)}(E) = 0$$

$$m_{7,8}^{S_0(7)}(\{E, O\}) = 1 - m_{7,8}^{S_0(7)}(O) = 0.45512$$

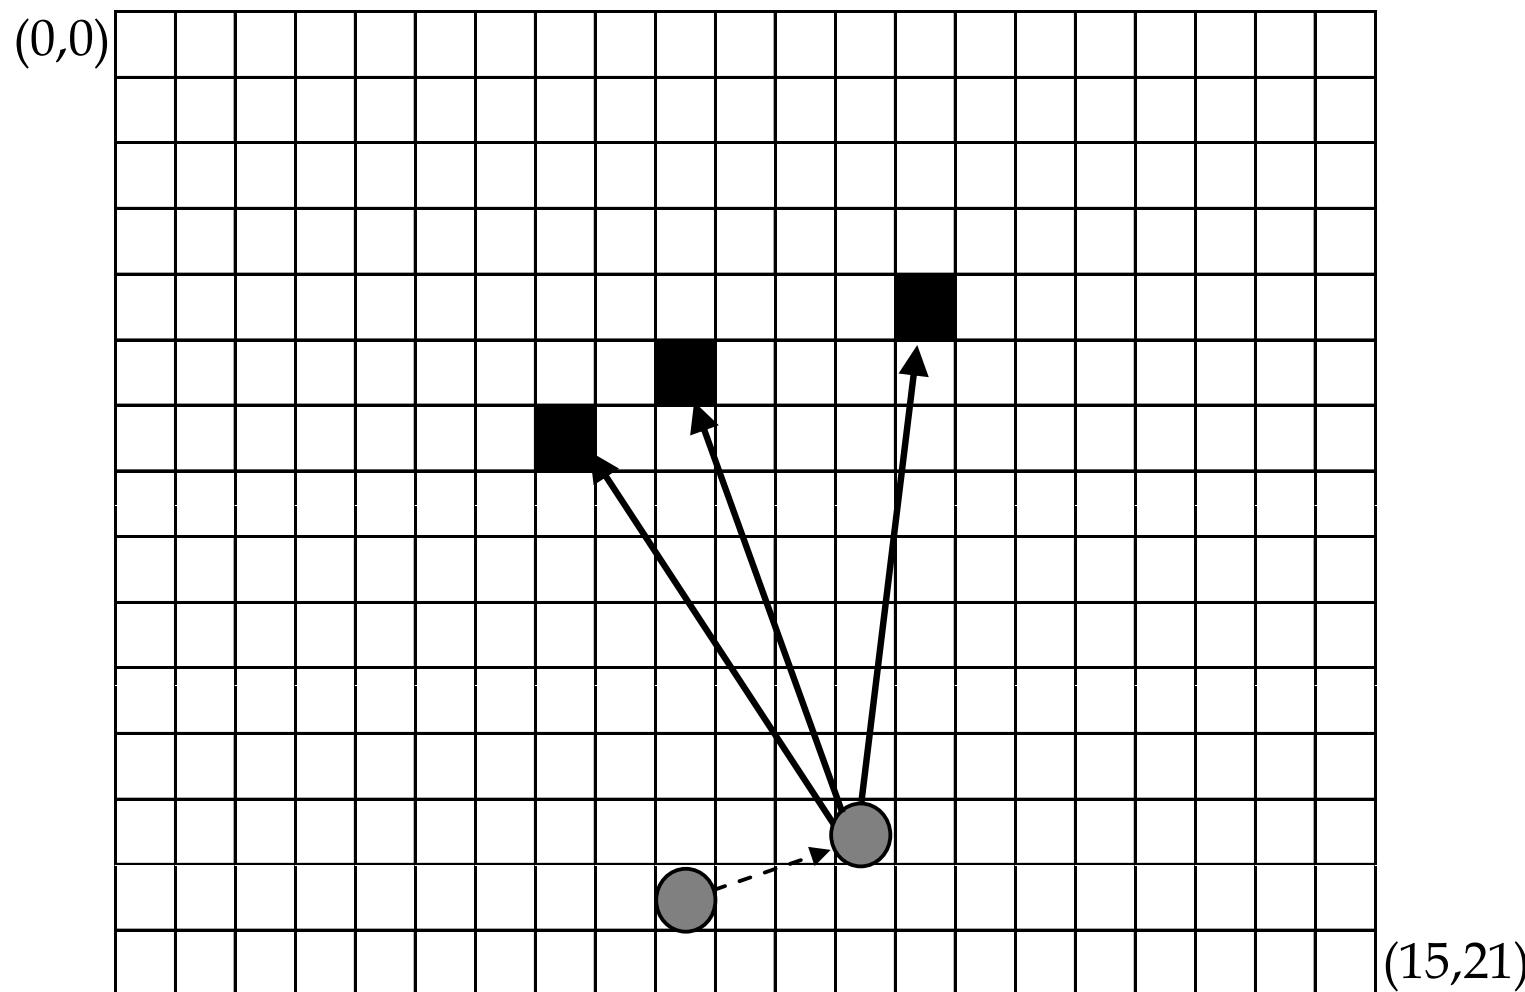
$$m_{6,10}^{S_1(5)}(O) = 0$$

$$m_{6,10}^{S_1(5)}(E) = \frac{\left(\frac{15-3}{15}\right)^2 + \left(\frac{8-1.5-5}{10-1.5}\right)^2}{2} = 0.336$$

$$m_{6,10}^{S_1(5)}(\{E, O\}) = 1 - m_{10,6}^{S_1(5)} = 0.664$$

## Primjer 5.

- U sljedećem trenutku se robot pomjerio u pravcu označenom isprekidanom linijom na slici



## Primjer 5.

- Uvjerenja da su ćelije  $(7,8)$ ,  $(6,10)$  i  $(5,14)$  zauzete na temelju mjerenja sonara  $S_0$ ,  $S_1$  i  $S_{15}$  ( $r_0 = 6.5$ ,  $r_1 = 7$ ,  $r_{15} = 7.5$ ,  $\alpha_0 = 2$ ,  $\alpha_1 = 5$  i  $\alpha_{15} = 4$ ) su:

$$m_{7,8}^{S_0(6.5)}(O) = \frac{\left(\frac{15-2}{15}\right)^2 + \left(\frac{1.5 - |8-6.5|}{1.5}\right)^2}{2} \cdot 0.98 = 0.36848$$

$$m_{7,8}^{S_0(6.5)}(E) = 0$$

$$m_{7,8}^{S_0(6.5)}(\{E, O\}) = 1 - m_{7,8}^{S_0(6.5)}(O) = 0.63152$$

$$m_{6,10}^{S_1(7)}(O) = \frac{\left(\frac{15-5}{15}\right)^2 + \left(\frac{1.5 - |8-7|}{1.5}\right)^2}{2} \cdot 0.98 = 0.27244$$

$$m_{6,10}^{S_1(7)}(E) = 0$$

$$m_{6,10}^{S_1(7)}(\{E, O\}) = 1 - m_{6,10}^{S_1(7)} = 0.72756$$



70/81

## Primjer 5.

$$m_{5,14}^{S_{15}(7.5)}(O) = \frac{\left(\frac{15-4}{15}\right)^2 + \left(\frac{1.5 - |8-7.5|}{1.5}\right)^2}{2} \cdot 0.98 = 0.48118$$

$$m_{5,14}^{S_{15}(7.5)}(E) = 0$$

$$m_{5,14}^{S_{15}(7.5)}(\{E, O\}) = 1 - m_{5,14}^{S_{15}(7.5)} = 0.51882$$

## Primjer 5.

- Kombiniranjem prethodnih i trenutnih mjerenja za ćelije (7,8) i (6,10) pomoću Dempsterovih pravila zaključivanja dobiva se:

$$m_{7,8}^t(E) = m_{7,8}^{t-1} \oplus m_{7,8}^t(E) = \frac{0 \cdot 0 + 0 \cdot 0.63152 + 0.45512 \cdot 0}{1 - 0 \cdot 0.36848 - 0.5488 \cdot 0} = 0$$

$$m_{7,8}^t(O) = m_{7,8}^{t-1} \oplus m_{7,8}^t(O) = \frac{0.5488 \cdot 0.36848 + 0.5488 \cdot 0.63152 + 0.45512 \cdot 0.36848}{1 - 0 \cdot 0.36848 - 0.5488 \cdot 0} = 0.7151$$

$$m_{7,8}^t(\{E, O\}) = 1 - 0.7151 = 0.2849$$



## Primjer 5.

$$m_{6,10}^t(E) = m_{6,10}^{t-1} \oplus m_{6,10}^t(E) = \frac{0 \cdot 0 + 0 \cdot 0.72756 + 0.664 \cdot 0}{1 - 0 \cdot 0.27244 - 0.336 \cdot 0} = 0$$

$$m_{6,10}^t(O) = m_{6,10}^{t-1} \oplus m_{6,10}^t(O) = \frac{0.336 \cdot 0.27244 + 0.336 \cdot 0.72756 + 0.664 \cdot 0.27244}{1 - 0 \cdot 0.27244 - 0.336 \cdot 0} = 0.5169$$

$$m_{6,10}^t(\{E, O\}) = 1 - 0.5169 = 0.4831$$

$$m_{5,14}^t(O) = 0.48118$$

$$m_{5,14}^t(E) = 0$$

$$m_{5,14}^t(\{E, O\}) = 0.51882$$

Na temelju novog skeniranja povećalo se uvjerenje o zauzeću ćelija (7,8) i (6,10). Ovaj proces se dalje nastavlja dok robot ne dođe do cilja.



## Primjer 5.

- Primjer mape zauzeća generirane Dempster-Shafereovom teorije uvjerenja prikazan je na slici (Murphy, 2000).



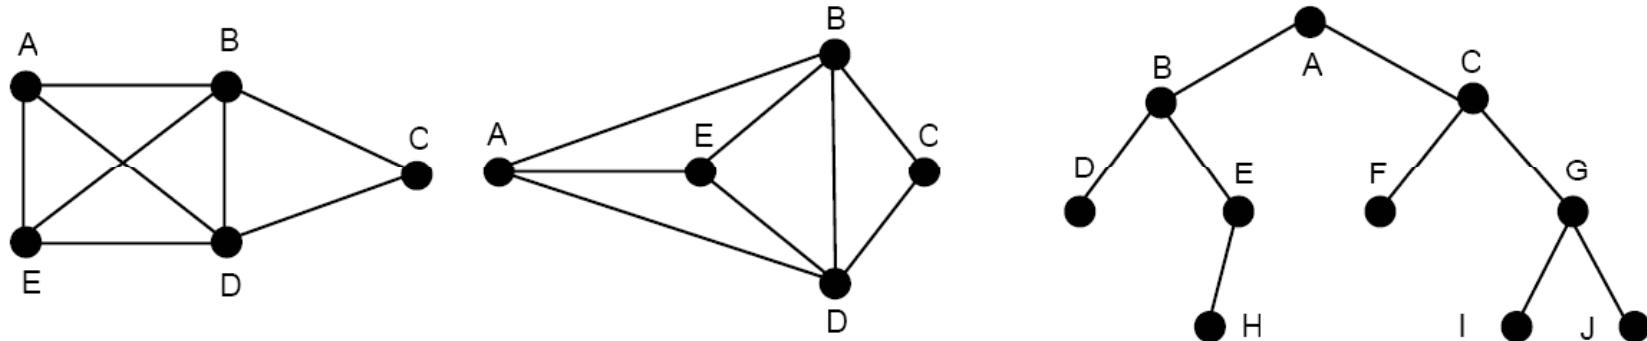


### 10.3. Topološke mape

- Da bi se izbjegle poteškoće u održavanju velikih metričkih mapa robotske okoline alternativno se koriste prikazi okoline u obliku grafova.
- Topološki prikaz okoline zaobilazi zahtjev za potencijalno velikim memorijskim prostorom za pohranu podataka o elementima mape koji je povezan sa metričkim mapama.
- Topološke mape opisuju okolinu pomoću grafa koji spaja specifične lokacije u stvarnom svijetu (geometrijske značajke prostora).
- Graf se sastoji od vrhova (čvorovi) i ivica (linija) koje povezuju vrhove. Također se može grafu pridružiti još jedan parametar koji izražava težinu odgovarajuće ivice.



75/81



- Primjeri različitih grafova
- Mapa robotske okoline predstavljena grafom može se opisati skupom  $N$  čvorova  $V$  i  $M$  linija povezivanja  $E$ :

$$G = (V, E)$$



## Topološke mape

- Čvorovi grafa i linije povezivanja su definirani na sljedeći način:

$$V = (v_1, v_2, \dots, v_N)$$

$$E = (e_1, e_2, \dots, e_M)$$

- gdje su linije povezivanja dane sa:

$$e = (v_i, v_j)$$

- Skupovi  $V$  i  $E$  za graf sa prve slike na prethodnom slajdu su:

$$V = (A, B, C, D, E)$$

$$E = (AB, AD, AE, BC, BD, CD, DE)$$



## Topološke mape

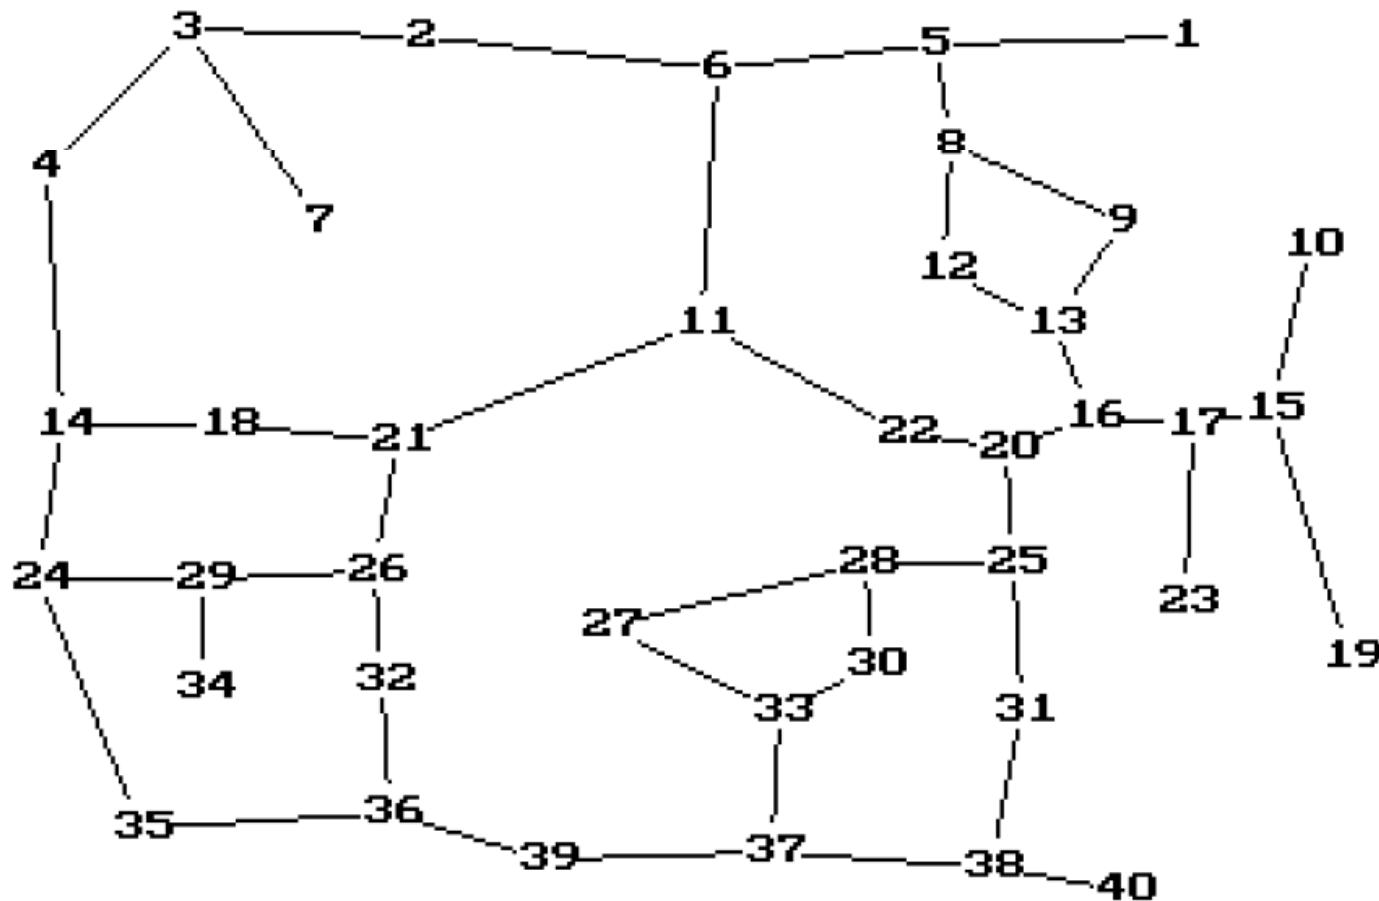
- U robotskoj okolini čvorovima se označavaju uočljive situacije, mjesta ili orijentiri (kao što su otvori u zidu, prolazi, čoškovi prostorija, itd.).
- Ovi čvorovi se povezuju linijama ako postoji direktna staza između njih.
- U praksi se topološki prikazi koriste za kontinuirane okoline zasnovane na orijentirima ili drugim značajkama.
- Rezultati ekstrakcije topološke mape (grafa) iz mrežaste mape sa slike na slajdu 63. prikazani su na sljedećoj slici.



78/81

## Topološke mape

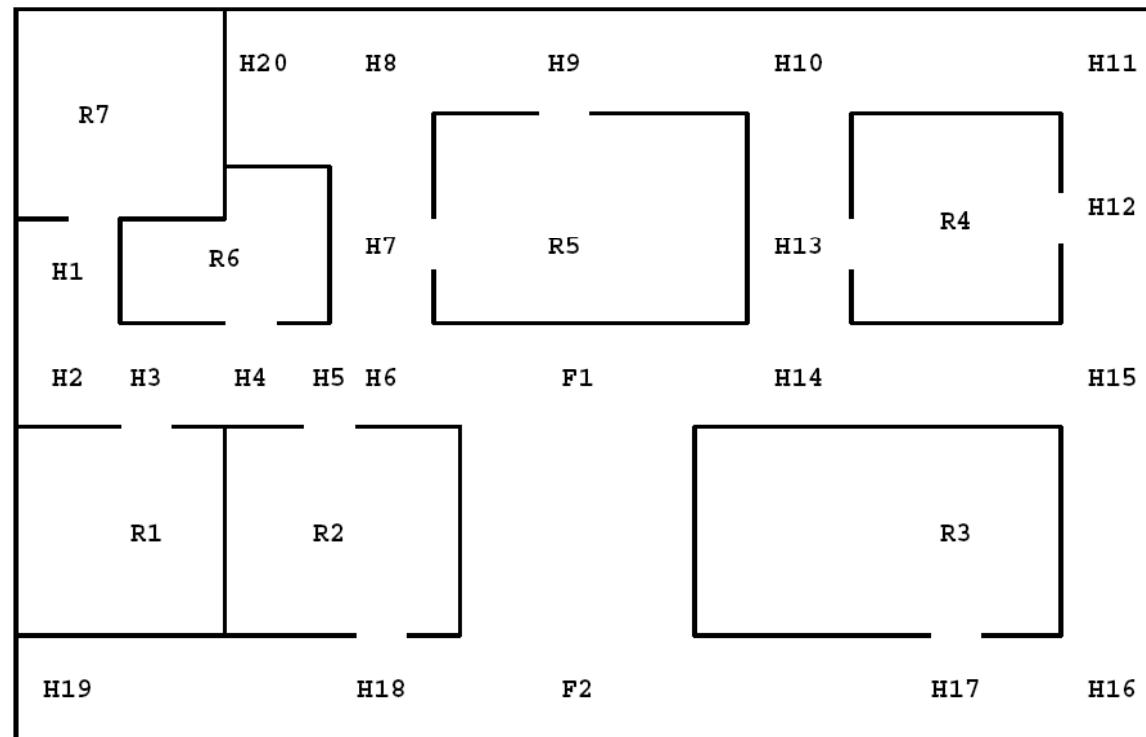
- ## ■ Topološki graf





## Topološke mape

- Na sljedećoj slici prikazana je metrička mapa prikaza jednog kata zgrade.
- Prostorije su označene oznakom R, a hodnici sa H.
- Prikaz istog kata zgrade pomoću grafa, odnosno topološke mape predviđen je slikom na sljedećem slajdu.

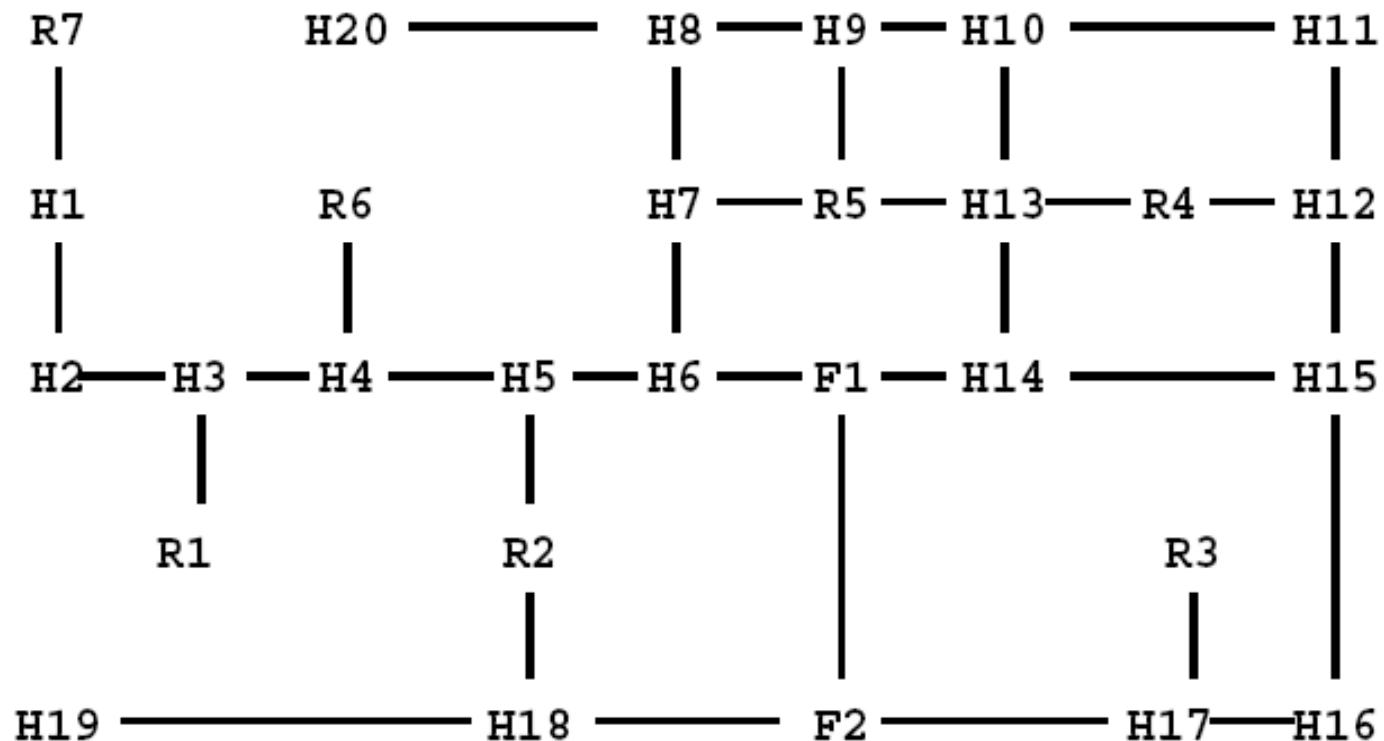




80/81

# Topološke mape

- Topološki prikaz kata zgrade sa prethodnog slajda





## Topološke mape

- Na temelju topoloških grafova razvijene su brojne metode planiranja kretanja, kao što su **grafovi vidljivih vrhova** i **Voronoijevi grafovi**, koji će se detaljno razmatrati u jednom od sljedećih predavanja.
- Također je važan i problem kretanja po topološkim mapama i pronalaženje optimalnih puteva kroz topološke grafove.
- Za ove potrebe se najviše koriste Dijkstra, Bellman-Ford i Bug algoritmi, koji će se također razmatrati u jednom od sljedećih predavanja.