

Model prostředí a lokalizace - obsah

- Model prostředí jako nosič znalosti o prostředí a jeho vlastnosti
 - Geometrická reprezentace
 - Geometrické pravděpodobnostní modely – mřížky obsazenosti, Bayesův přístup
 - Senzory, minimalistický model senzoru (LIDAR)
- Lokalizace v geometrickém modelu prostředí
 - Příznaky prostředí a jejich vlastnosti (invariance), kontinuální lokalizace
 - Dálkoměrné senzory a scan matching techniky
 - Histogram matching
 - Implementace, příklady
- Mapování a navigace z laserového dálkoměru bez geometrické interpretace měření

Modely prostředí – přehled I



- Základní funkční součást klasické architektury inteligentního robotu
- Model prostředí je nosičem informace/znalosti robotu o vlastnostech prostředí (tj. geometrických a jiných omezení)
- Model prostředí může být různé úrovně abstrakce:
 - **Nízkoúrovňové modely,**
 - Bez interpretace významu dat, prosté ukládání sensorických měření (málo používané, neefektivní, často nezvladatelná paměťová náročnost)
 - Provedení jako prosté úložiště dat
 - **Modely se střední úrovní abstrakce**
 - Sensorická data s částečnou interpretací významu (většinou provedení fúze/filtrace měření ke zvýšení věrohodnosti modelu)
 - *Geometrické modely* – tj. forma ukládaných dat postihuje přímo geometrické vlastnosti prostředí (např. pozice překážek a jejich tvar)
 - » Provedení ve formě **mřížkových modelů obsazenosti** (*certainty grids*) - stavebním elementem je pixel, popř. s využitím deskriptorů vyšších řádů (aproximace prostředí jinými deskriptory, např. úsečkami, vrcholy objektů, ap.)
 - » Často používané – snadná implementace, přiměřená paměťová náročnost, umožňuje nízkoúrovňovou fúzi dat, odstranění šumu..)
 - *Topologické modely* – grafová reprezentace prostředí, popis volných a/nebo obsazených oblastí a vztahů mezi nimi

Modely prostředí – přehled II

- **Symbolické modely (nejvyšší úroveň abstrakce)**
 - Interpretace sensorických dat až do formy rozpoznávaných *elementů prostředí a relací* mezi nimi (jména a relace nad nimi/mapou)
 - Nese primárně relační informaci, geometrické vlastnosti prostředí jsou podružné → vhodné pro symbolické postupy využití modelu prostředí (symbolické plánovací postupy, možnost vazby na systémy rozpoznání a generování mluvené řeči, vazba na lidskou entitu...)
 - Symbolická mapa sama o sobě nenese geometrickou informaci a proto je méně vhodná pro plánování/řízení činnosti robotu na fyzické úrovni – generování řídicích příkazů pro aktuátory. Aby ji pro tento účel bylo možné použít, geometrická informace může být připojena.
 - Velmi efektivní a komprimovaná reprezentace, vhodná pro vytváření vazeb k symbolicky orientovaným nadřazeným systémům, náročnější zpráva jejího obsahu na základě získaných sensorických dat (vyžaduje jejich filtraci/fúzi, rozpoznávání objektů a konstrukci relačních vazeb mezi objekty modelu)

Mřížkové modely prostředí

- Akční prostor robotu je rozdělen na diskrétní elementy - pixely, jenž nesou informaci o vlastnostech reprezentované oblasti (*obsazený, volný a neznámý* stav)
- Volba rozměru (obvykle čtvercového) pixelu je kompromisem mezi geom. přesností a paměťovou/výpočetní náročností, *~rozměr robotu*
- Pixel nese pravděpodobnostní vyjádření *obsazení a volnosti* dané lokality
 - Počátení nastavení na hodnotu 0.5 (neznámý stav)
 - S měřenými daty je informace vkládána/obnovována
 - **Pravděpodobnostní (Bayesovské) postupy**
 - Nebayesovské postupy (Dempster-Shaffer)
- Výhody mřížkové reprezentace
 - Jednoduché začleňování nově získané informace
 - Snadná spolupráce s dálkoměrnými senzory
- Nevýhody mřížkové reprezentace
 - Paměťová náročnost pro větší rozlišení/rozlehlejší prostředí
 - Nízká míra abstrakce uchovávané informace → nepřiliš vhodné pro dlouhodobé uchování rozlehlých modelů prostředí (lze obejít dalším zpracováním a přechodem k symbolickým (relačním modelům))

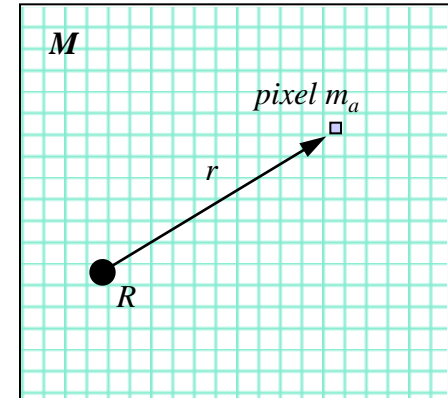


Pravděpodobnostní mřížka - popis

- Mějme:
 - Dálkoměrný senzor R jenž poskytuje jednotlivá měření r
 - Množinu všech možných světů M sestávající z buněk m_a a stavem buňky $s(a)$ (o..obsazeno, v..volno)
 - $P(m|r)$ nechť je pravděpodobnost světa m při uskutečněném měření r

Pravděpodobnost obsazení buňky a za podmínky, že bylo provedeno měření r je:

$$P(s(a) = o | r) = \frac{\sum_{m \in M \wedge s(m_a) = o} P(m | r)}{\sum_{m \in M} P(m | r)}$$



- Problémem je kombinatorická exploze řešení
- Zjednodušující předpoklady:
 - Pravděpodobnostní chování jednotlivých buněk je navzájem nezávislé
 - Komplementarita pravděpodobnostního popisu:

$$P(s(a) = v) = 1 - P(s(a) = o)$$

Pravděpodobnostní mřížka – správa obsahu

- Inicializace mřížky hodnotami pravděpodobnosti $P(s(a)) = 0.5$ (reprezentuje „neznámý stav“ na počátku spuštění mechanismu správy obsahu mřížky)
- Fúze nového měření do existující mřížky užitím Bayesovského postupu:

$$P(s(a) = o | r) = \frac{p(r | s(a) = o).P(s(a) = o)}{p(r | s(a) = o).P(s(a) = o) + p(r | s(a) = v).P(s(a) = v)}$$

Kde:

$P(s(a) = o|r)$ je výsledná hodnota po přidání nového měření r

$p(r|s(a) = o)$ reprezentuje model senzoru (viz. dále)

$P(s(a) = o)$ je předchozí hodnota buňky v mřížce před přidáním nového měření

Pravděpodobnostní mřížka – model senzoru

- K zapracování vlivu chování užitého senzoru je třeba vytvořit jeho pravděpodobnostní model
- Kvantitativní popis modelu senzoru využívá míru významově blízkou pravděpodobnosti (! nespĺňuje normalizační podmínku $\int_m p(x)dx = 1$), se kterou pro zjednodušení pracuje jako se skutečnou pravděpodobností
- Pravděpodobnostní popis senzoru $p(r|s(a) = o)$ tedy uvažujeme:

$$p(r | s(a) = o) = \frac{1 + S_o^r(\alpha, d) - S_v^r(\alpha, d)}{2}$$

Kde:

S_v^r , resp. S_o^r je model senzoru pro *volný*, resp. *obsazený* prostor

(α, d) .. jsou polární souřadnice buňky a v souřadné soustavě senzoru

r .. je naměřená hodnota vzdálenosti

Pravděpodobnostní mřížka – model LIDAR

- Realistický model senzoru:

$$S_v^r(d) = \begin{cases} 1 - \left(\frac{d}{r - \varepsilon}\right)^2, & \text{pro } d \in \langle 0, r - \varepsilon \rangle \\ 0 & \text{jinak} \end{cases} \quad S_o^r(d) = \begin{cases} 1 - \left(\frac{d - r}{\varepsilon}\right)^2, & \text{pro } d \in \langle r - \varepsilon, r + \varepsilon \rangle \wedge r < r_{\max} \\ 0 & \text{jinak} \end{cases}$$

- Zjednodušený model senzoru:

$$S_v^r(d) = \begin{cases} 1 & \text{pro } d \in \langle 0, r - \varepsilon \rangle \\ 0 & \text{jinak} \end{cases} \quad S_o^r(d) = \begin{cases} 1 & \text{pro } d \in \langle r - \varepsilon, r + \varepsilon \rangle \wedge r < r_{\max} \\ 0 & \text{jinak} \end{cases}$$

Kde:

S_v^r , resp. S_o^r je model senzoru pro *volný*, resp. *obsazený* prostor

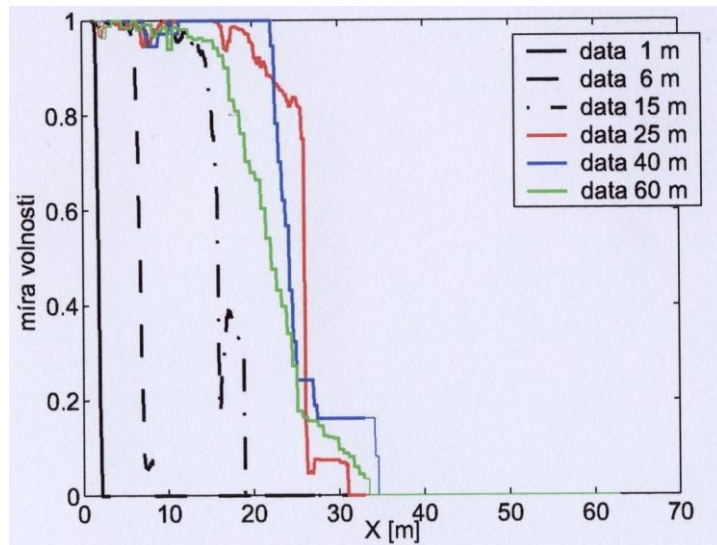
d .. je polární souřadnice (radius) buňky a v souřadné soustavě senzoru

ε .. značí rozlišovací schopnost (přesnost) senzoru


r .. je naměřená hodnota vzdálenosti

r_{\max} .. je stanovený dosah senzoru

Pravděpodobnostní mřížka – chování reálného LIDARU (PLS Sick)




Míra obsazenosti pro laserový dálkoměr




Míra volnosti pro laserový dálkoměr

Pravděpodobnostní mřížka – ilustrace



Surová data ze senzoru (dálkoměr)



Výsledný pravděpodobnostní model prostředí – mřížka (tmavá..volný prostor, světlá..obsazený prostor, šedá..neznámý stav)

- Hranice pevných objektů je „děravá“ → odstranění následným zpracováním
- Informace o vzdálených objektech je nejistá

Určování polohy robotu v prostředí – úloha

Úloha „kde se nacházím“?

- Kvantitativní specifikace polohy robotu (poloha v souřadném systému – absolutním či relativně vzhledem k předchozí poloze, relativní poloha vůči vztažným bodům prostředí, atd.
- Většinou není k dispozici dostatečně přesný/spolehlivý senzorický systém, jenž poskytuje přímá měření požadovaných veličin x, y, φ .
- Typický cílem úlohy lokalizace je:
 - » Rekonstrukce polohy a orientace robotu z nezávislých pozorování prostředí senzory → výpočet požadovaných veličin nepřímo ze získaných pozorování
 - » Zajištění/zvyšování robustnosti zjištěné polohy z důvodů možného selhání, či nepřesnosti senzorů, popř. výpočtu polohy
 - » Permanentní obnovování informace o poloze a orientaci při činnosti/pohybu robotu

Určování polohy robotu v prostředí - problémy

Problémy:

- Šum a selhání senzorů → nepřesnost určení polohy, cílem je udržet přesnost v přijatelných mezích
 - Řešením je nejčastěji časová a vzájemná (napříč odlišnými typy senzorů, popř. jinými instancemi téhož senzoru) filtrace/fúze sensorických dat, která u nekorelovaných poruchových procesů zlepšuje poměr užitečné informace a náhodného šumu

- Proměnlivé se prostředí v němž robot pracuje → problematická rekonstrukce polohy a orientace opírající se o výpočet z extrahovaných příznaků prostředí
 - Např. dříve identifikované deskriptory prostředí nemusí být v následujících situacích vůbec nalezeny
 - Řešením je použití inkrementálního postupu lokalizace (relativně k minulé poloze robotu) s dostatečně malým krokem obnovení polohy a orientace.
 - Zmenšováním kroku, umožní kontrolu největší možné změny scény mezi dvěma lokalizacemi
 - Přijatelné robustnosti lze dosáhnout užitím pouze významných (např. integrálních) příznaků k výpočtu polohy a orientace


Určování polohy robotu v prostředí - řešení

- Nejčastější způsob výpočtu polohy se opírá o výpočet relativní změny polohy robotu (senzoru) mezi dvěma pozorováními scény
 - Pozorování scény ~ extrakce vhodných příznaků k výpočtu relativní změny
 - K získání absolutní polohy robotu/senzoru může být potřebné metodu kalibrovat vůči globálnímu souřadnému systému. Pokud se ale výpočet opírá o příznaky svázané s prostředím/mapou, dochází k autokalibraci.
 - Porovnávat lze data/příznaky extrahované:
 - Mezi dvěma po sobě jdoucími měřeními (hloubkových scanech)
 - Mezi jednotlivým měřením/scanem a existujícím modelem prostředí ← výhoda autokalibrace, model je obvykle svázan s prostředím
- Jedna z metod je tzv. scan-matching:
 - Zajišťuje kontinuální lokalizaci ve spolupráci s odometrickým systémem robotu
 - Primárním zdrojem x, y, φ je odometrie robotu, jenž trpí kumulativními chybami určení polohy (neznámé poloměry odvalování kol, prokluzu, atd.)
 - Scan-matching periodicky zpřesňuje (kalibruje) odometrii výpočtem z minulého a aktuálního pozorování scény (resp. vhodných deskriptorů) → zajistí omezenou chybu určení polohy a orientace.

Určování polohy robotu v prostředí – histogram-matching

- Vstupem metody je dvojice hloubkových scanů, t.j. vzdálenosti k objektům prostředí změřené užitým dálkoměrem (LIDAR) a/nebo vzdálenosti vyčtené z modelu prostředí (mapy)
- Korekce polohy se provádí ve 2 krocích v daném pořadí:
 - Korekce chyby/rel. změny natočení φ (její oprava je kritická pro úspěšné zjištění relativního posuvu v násl. kroku)
 - Korekce polohy x,y (posunutí)
- Každý z jednotlivých předchozích kroků je reprezentován:
 - Výpočtem příznaků, které jsou invariantní vůči rotaci, resp. translaci
 - Výpočet aktuálního otočení, resp. translace z těchto příznaků užitím korelační funkce
- Krok 1: Výpočet relativního otočení:
 - Konstrukce úhlového histogramu v polárních souřadnicích (histogram směrů jednotlivých segmentů hranice/hloubky scény podél pozorovacího úhlu)

Situace, viz. obr.:




Histogram matching – výpočet otočení

- Histogram úhlů (1D) a původní hloubková data (2D) – viz. obr.
- Vlastnost: Úhlový histogram nemění jednotlivé hodnoty při otáčení → pouze se úhlově posunují (rotují)
- Výpočet relativního otočení (fázového posuvu) j mezi dvěma scany s_1 a s_2 užitím diskretní korelační fce $k(j)$:


$$k(j) = \sum_{i=1}^n s_1(i) s_2(i + j)$$

pro níž hledáme j takové, kdy $\max_j(k(j)) = k(j)$


Kde: i je pořadnice směru
 n je celkový počet směrů



Úhlový histogram



Orig. hloubková data



Dva scany posunuté o 135°

Histogram matching – výpočet posunutí I

- Po výpočtu a korekci vzájemného úhlového otočení obou vstupních scanů je proveden výpočet vzájemného posunutí
- Krok 2: Výpočet relativního posunutí:
 - Výpočet posunutí je prováděn ve dvou, vzájemně kolmých směrech x , y
 - Jedna ze souřadných os x nebo y se volí rovnoběžně s dominantním směrem zjištěným ve směrovém histogramu (přechodí krok).
 - Dominantní směr je směr, který se nejčastěji vyskytuje v odpovídajícím směrovém histogramu (reprezentuje jeho maximum) – reprezentuje „referenční“ objekt, jenž je nejpravděpodobněji stabilní
 - Zvolí se druhý, kolmý směr a pro oba směry jsou vypočteny histogramy hloubky scény v těchto směrech (vzdálenosti k překážkám). Vytvořené histogramy nejsou (na rozdíl od směrových histogramů) periodické funkce.
 - Modifikace histogramů do cyklické formy (periodicita funkce) k umožnění výpočtu korelační funkce. Dosahuje se „zrcadlením“ počátku a konce acyklického histogramu, např aplikací vztahů:

$$h_{1,2}(x) = x \bmod size, \quad h_{1,2}(y) = x \bmod size$$

Kde: $h_{1,2}(x)$ a $h_{1,2}(y)$ jsou příslušné neperiodické histogramy pro scany $s_{1,2}$ a směry x a y
 $size$.. značí rozměr neperiodického histogramu (okna)
 x , y .. periodická pořadnice hodnoty histogramu $h(..)$

Histogram matching – výpočet posunutí II

- Korelační funkce užitá pro výpočet korelace směrových histogramů je vhodná pouze pro určení fázového posuvu pro nejlepší korelaci. Kvantitativně nemá vypovídací hodnotu.
- Řešení spočívá v užití tzv. *korelačního koeficientu* $c(j)$ (normalizovaná korelační fce):

$$c(j) = \frac{\sum_{i=1}^n (h_1(i) - \bar{h}_1) \cdot (h_2(i+j) - \bar{h}_2)}{\sqrt{\sum_{i=1}^n (h_1(i) - \bar{h}_1)^2 \cdot \sum_{i=1}^n (h_2(i+j) - \bar{h}_2)^2}}$$


Kde: $c(j) \in \langle -1, +1 \rangle$
 \bar{h}_1, \bar{h}_2 ..jsou střední hodnoty hist.

Kde funkční hodnota: 0 .. nekorelované histogramy
 1 .. plně korelované histogramy


Poznámky:

- Výpočetní složitost algoritmu scan/histogram matching je $O(n^3)$.
- *Ke zvýšení robustnosti je možné porovnávat histogramy vytvářené nad částečně segmentovanými scénami (např. histogramy úseček aproximující hranice objektů – zvláště vhodné pro ortogonální/polygonální prostředí)*
- *Kombinace metody s odometrií je možné odometrii použít jako metodu pro hrubý odhad polohy (podpora a vyšší spolehlivost určení korelačních extrémů)*


Histogram matching – posunutí a otočení (ilustrace) I




Orig. dvojice hloubkových scanů, $\Delta\varphi=43^\circ$, $\Delta x=0.14m$,
 $\Delta y=0.96m$
 pozice senzoru (0,0)



Úhlový histogram dvojice scanů




Vzájemná korelace úhlových histogramů
 maximum @ 43°




Hloubkové scany otočené o 43°

($+24^\circ$, -19°) – související volba dominantních směrů


Histogram matching – posunutí a otočení (ilustrace) II



Korelace ve směru x, maximum @ -0.35m (koreluje s maximem v otočeném scanu @ -0.14m)



Korelace ve směru y, maximum @ +0.90m (koreluje s maximem v otočeném scanu @ +0.98m)



Výsledná korekce: translace ve směru x o +0.14m, ve směru y o -0.98m

Od určení polohy a orientace v mapě prostředí I

- Pro každou lokalitu prostředí existuje určitý úhlový histogram a histogramy pro směry x , y
- Výše uvedený popis užitím histogramů je pro sousední lokality vzájemně odlišný (především se liší v hodnotách histogramů pro směry)
- Histogramový popis je časově stabilní (předpoklad)

Z výše uvedeného vyplývá vysoká míra jednoznačnosti zobrazení:

pozice ve scéně → úhlový a směrové histogramy

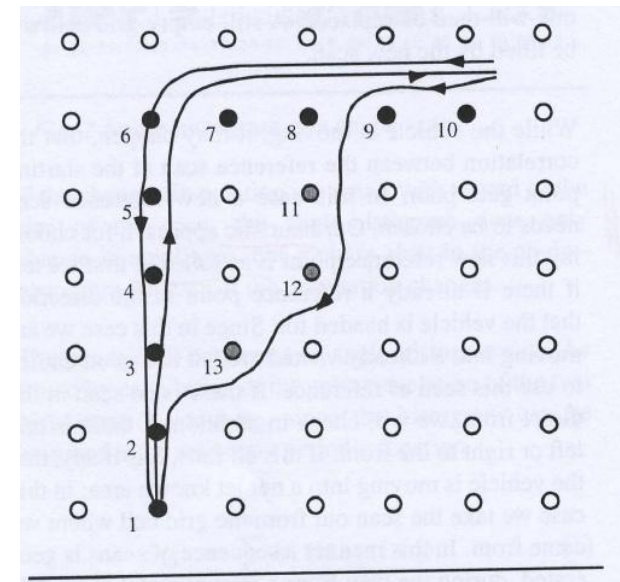
v daném bodě prostředí a jeho blízkém okolí → uložením jednotlivých místně příslušných popisů je možné vytvořit **mapu prostředí** bez potřeby sensorová data jakoliv složitě interpretovat...

- Vzniklá mapa obsahuje veškeré dosud projeté lokality, pro něž byly určeny a uloženy příslušné histogramy

Od určení polohy a orientace k mapě prostředí III

Algoritmus inkrementální stavby modelu sveta (naznačení):

- Zvolím aktuální referenční bod pro výpočet hist.-matching lokalizace
- Postupuji prostředím (systematicky rastrem nebo podél zadané trajektorie), polohu určuji průběžně podle aktuálního referenčního bodu.
- Test úspěšnosti lokalizace. Provedu kvantitativní hodnocení (např. výpočtem korelačního koeficientu). S
 - hledám-li nadprahovou nejistotu určení polohy a orientace, zvolím v tomto místě nový (aktuální) referenční bod.
 - Existuje-li někde v blízkosti již nějaký referenční bod, vztáhnou další lokalizaci vzhledem k němu.
- Tímto postupem dospějí k cíli cesty (a nebo systematicky zmapují celé prostředí).
- Vykonáním předchozího mechanismu spolu s uložením histogramových popisů scény v platných vytažných bodech získávám mapu prostředí.



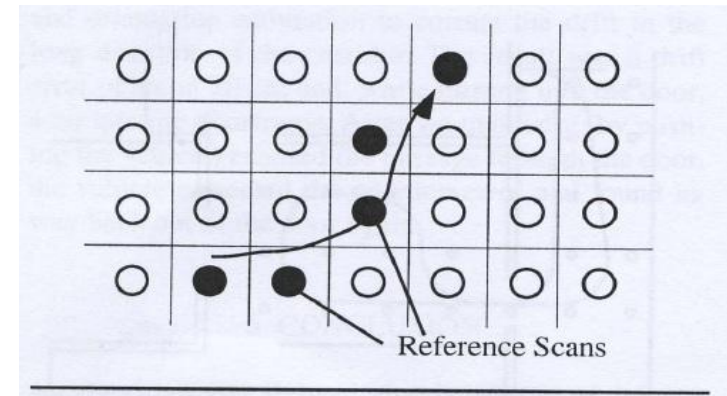
Příklad vzniku a použití mapy prostředí bez interpretace dat s užitím histogram-matching lokalizace.

Vlastnosti:

- Mapa je typu „record and play“
- Reprezentace prostředí nevyžaduje žádnou hlubší interpretaci sensorových dat
- Hustčí síť referenčních bodů → vzájemné zpřesnění jejich popisů

Od určení polohy a orientace k mapě prostředí II

- Příklad popisu prostředí mapováním v diskrétních bodech, resp. podél projetych trajektorií - viz obr.
 - Dostatečně husté umístění referenčních lokalit pokryje „spojitě“ celý prostor
 - Metoda je funkční i pro řídká pokrytí prostoru podél spojitých trajektorií
- Identický postup slouží:
 - Jak k počátečnímu naplnění mapy hodnotami pro dané prostředí,
 - Tak ke zpřesnění již existujících hodnoty popisu jednotlivé lokality



Uložení spojitě trajektorie mapováním v přilehlých (referenčních) bodech

Reference:

- Weiss G., Wetzler Ch., Putkammer E.: *Keeping Track of Position and Orientation of Moving Indoor Systems by Correlation of Range-Finder Scans*, Dpt. For Computer Science, University of Kaiserslautern, Germany, Paper ref. E047, 1994,7pp
- Gutmann J.S., Schlegel Ch.: *AMOS: Comparison of Scan matching Approaches for Self-Localization in Indoor Environments*, Research Institute for Applied Knowledge Processing (FAW), Ulm, Germany, 1996,7pp
- Mázl R.: *Aktualizace modelů 2D prostředí mobilního robotu*, dipl. práce, FEL ČVUT Praha, kat. kybernetiky, 1999, 77pp