

VĚDECKÉ SPISY VYSOKÉHO UČENÍ TECHNICKÉHO V BRNĚ

Edice PhD Thesis, sv. 483

ISSN 1213-4198

thesis
?
IS

Ing. Tomáš Neužil

**Průběžná lokalizace
a mapování
pomocí mobilního robotu**

Vysoké učení technické v Brně
Fakulta elektrotechniky a komunikačních technologií
Ústav automatizace a měřicí techniky

Ing. Tomáš Nežil

PRŮBĚŽNÁ LOKALIZACE A MAPOVÁNÍ POMOCÍ
MOBILNÍHO ROBOTU

SIMULTANEOUS LOCALIZATION AND MAPPING USING MOBILE ROBOT

Zkrácené znění doktorské práce

Obor: Kybernetika, automatizace a měření
Školitel: prof. Ing. František Šolc, CSc.
Oponenti: prof. Ing. Vladimír Řeřucha, CSc.
prof. Ing. Ladislav Jurišica, Ph.D.
Datum obhajoby: 27.6.2008

Klíčová slova

mobilní robotika, průběžná lokalizace a mapování, SLAM, robot řízený smykem, diferenciální podvozek, Radonova transformace, rozšířený Kalmanův filtr

Key words

mobile robotics, simultaneous localization and mapping, skid steering mobile robot, differential drive, Radon transform, extended Kalman filter

Doktorskou práci lze získat na Vysokém učení technickém v Brně, Fakulta elektrotechniky a komunikačních technologií, Vědecké a zahraniční oddělení, Údolní 53, Brno 602 00, Česká republika.

Obsah

1	Úvod	5
2	Lokalizace a mapování v robotice	5
2.1	Mapování, druhy map	6
2.2	Poloha robotu jako náhodná veličina	8
2.3	Popis polohy robotu pomocí Gaussova rozdělení pravděpodobnosti	9
2.4	Rozšířený Kalmanův filtr	9
3	Model robotu	11
3.1	Kinematický model robotu	12
4	Model snímače, Detekce orientačních bodů	13
4.1	Radonova transformace	15
5	Určení parametrů hledaných přímek	16
5.1	Shlukování nalezených přímek	17
5.2	Určení vzdálenosti mezi jednotlivými objekty	17
5.3	Rozdělení objektů do shluků	18
5.4	Model snímače	19
6	Současná lokalizace a mapování	19
6.1	Inicializace lokalizačně mapovacího algoritmu	20
6.2	Predikce stavového vektoru a hodnot měření	20
6.3	Hledání korespondujících orientačních bodů	21
6.4	Aktualizace stavového vektoru	21
6.5	Aktualizace globální mapy	22
7	Experimentální ověření algoritmu SLAM	23
7.1	Zhodnocení kvality globální mapy	24
8	Shrnutí dosažených cílů	25

1 Úvod

Robotika je obor lidské činnosti, který naplňuje snahu člověka usnadnit si práci. Přestože slovo robot pochází z pera českého spisovatele Karla Čapka (Rossums Universal Robots 1920), snaha vyrobit stroj vykonávající lidskou práci, případně stroj, který se podobá člověku, je v lidské historii zaznamenána mnohem dříve. Za první stroj spadající do kategorie robot jsou označovány vodní hodiny, které sestrojil Ctesibius z Alexandrie v roce 270 př. n. l.

Také pražský Golem, člověk z hlíny, naplňuje myšlenku vytvořit stroj podobný člověku a za člověka pracující. Karel Čapek, spolu se svým bratrem Josefem, byli při vzniku dramatu R.U.R. inspirováni pověstí o hliněném Golemovi a masově se rozvíjející průmyslovou výrobou, která vyžadovala pracovníky vykonávající těžkou, stále se opakující činnost.

V oblasti mobilní robotiky je v současné době kladen vysoký důraz na schopnost autonomního provozu mobilního robotu. Autonomie mobilního robotu je definována jako schopnost robotu vykonávat činnost bez nutnosti zásahu lidské obsluhy v nestrukturovaném prostředí. Pro to, aby mobilní robot bylo možno označit za autonomní, musí mít následující vlastnosti:

- schopnost dlouhodobé samostatné činnosti bez nutnosti lidského zásahu,
- schopnost samostatně se pohybovat pracovním prostředím,
- schopnost vyhnout se situacím, které by mohly vést ke zranění lidské obsluhy nebo zničení robotu,
- schopnost získávat informace o pracovním prostředí.

Základním předpokladem pro splnění výše uvedených podmínek je, aby robot znal v každém okamžiku svoji polohu. Polohu robotu lze získat mnoha způsoby. Disertační práce se zabývá metodou lokalizace mobilního robotu pomocí orientačních bodů v prostoru, které jsou získávány pomocí laserového proximitního snímače umístěném na mobilním robotu s podvozkem řízeným smykem. S lokalizací, jako součástí navigační úlohy, velmi úzce souvisí také vytváření mapy pracovního prostoru robotu.

Pro vytvoření lokalizačně mapovacího algoritmu byl zvolen pravděpodobnostní přístup využívající rozšířeného Kalmanova estimátoru stavů. Tento algoritmus je založen na využití dat získaných měření pomocí planárního laserového snímače. Hlavní výhodou tohoto přístupu k lokalizační úloze je, že není nutný zásah člověka do pracovního prostředí robotu.

2 Lokalizace a mapování v robotice

Na lokalizaci mobilního robotu lze nahlížet jako na problém transformace souřadných systémů. Řešením tohoto problému je nalezení transformace, která umožňuje určení shody mezi částí globální mapy prostředí a lokální mapou získanou měřeními robotu.

- lokální mapa - počátek souřadného systému je pevně spjat s mobilním robotem, např. střed laserového snímače,
- globální mapa - počátek souřadného systému je spjat s prostředím, ve kterém se robot pohybuje, např. roh místnosti, vstup do budovy apod.

Lokalizace pomocí orientačních bodů

Orientační body jsou místa s charakteristickými rysy v pracovní oblasti mobilního robotu, která je robot schopen detekovat pomocí vlastních snímačů. Tyto oblasti mohou mít podobu geometrických útvarů, jako jsou čáry, kruhy, mnohoúhelníky apod., popřípadě mohou být vytvořeny uměle, například formou rádiových vysílačů [1]. Základním předpokladem metody je neměnná poloha orientačních bodů během procesu lokalizace.

přirozené orientační body orientační body, které byly vytvořeny za jiným účelem než je navigace robotu.

Typickým příkladem jsou: rohy místností, dlouhé chodby, okna atd.,

umělé orientační body orientační body, které byly navrženy a vytvořeny pouze za účelem navigace robotu.

Typickým příkladem jsou černobílé obrazce (kamerové navigační systémy), terče s vysokou odrazivostí (optické laserové systémy), aktivní vysílače (rádiové systémy).

Současná lokalizace a mapování, SLAM


Současná lokalizace a mapování (*Simultaneous Localisation and Mapping - SLAM*) - proces, při kterém robot vytváří mapu prostředí, kterou zároveň využívá k určení své pozice. Jedná se o situaci, kdy je robot umístěn do zcela neznámého prostředí a v tomto prostředí má být schopen vyvíjet nějakou, alespoň částečně autonomní činnost. Principem je kontinuální tvorba mapy prostředí při využití dat ze snímačů na robotu umístěných. Shodná vstupní data jsou využívána jak pro tvorbu mapy, tak pro lokalizaci v této mapě.

Při této metodě vytváří robot tzv. *lokální mapu* prostředí, kterou následně porovnává s *globální mapou* uloženou v paměti, a určuje svoji polohu. Kvalita odhadu polohy na základě mapy závisí na schopnosti získat a efektivně využít informace o svém okolí [2, 3].

2.1 Mapování, druhy map

V 80. letech 20. století se problematika mapování v mobilní robotice rozdělila na dva základní způsoby [4]:

Geometrický při tomto způsobu reprezentace je mapa ukládána jako sada geometrických primitiv popisujících prostředí. Zásadním přínosem pro oblast geometrických map bylo




Obrázek 1: Geometrická reprezentace prostředí

využití mřížek obsazenosti. Tento přístup popisuje prostředí jako dostatečně jemnou mřížku, jejíž jednotlivé buňky obsahují informaci, zda je buňka obsazená, či nikoliv [5, 6].

Tento způsob zobrazení prostoru je velmi podobný tomu, jak by danou oblast zobrazil člověk. Porozumění tomuto druhu mapy je proto velmi intuitivní a usnadňuje jak využití výsledků robotického mapování, tak zadávání předem stanovené mapy do navigačního systému robotu.

Topologický - tento přístup popisuje okolní prostředí robotu pomocí vztahů mezi jednotlivými, pro navigaci robotu důležitými, místy. Jednotlivá „význačná místa“ reprezentují uzly grafu. Spojnice mezi těmito uzly pak popisují způsob, kterým se lze mezi body pohybovat. Na obrázku 2 uzly reprezentují jednotlivé místnosti, spojnice pak reprezentují průchody mezi těmito místnostmi.



Obrázek 2: Topologická reprezentace prostředí

K vytvoření mapy prostředí musí být robot vybaven snímači, které mu umožňují získat potřebné informace o prostředí. Nejčastěji používanými senzory pro vytváření robotických map jsou: kamery, laserové dálkoměry (planární nebo 3D), GPS přijímače, radary apod. Výstupy z většiny těchto snímačů jsou omezeny (např. přijímače GPS signálu nefungují uvnitř budov) a výsledky měření jsou zatíženy chybami a šumem. Také pohyb robotu je zatížen šumem, reprezentovaným vlivy okolí robotu, které při řízení jeho pohybu nejsou brány v úvahu, z čehož vyplývá skutečnost, že polohu robotu nelze určit z řídicích signálů, které do robotu vstupují.

V případě, že by oba šumové signály byly na sobě nezávislé, přesnost mapy by bylo možno zvýšit pomocí zvýšení počtu měření a jejich vhodnou statistickou analýzou. V reálných robotických systémech jsou však signály statisticky závislé. Odchyly polohy způsobené řídicím signálem, který je zatížen šumem, rostou v čase a ovlivňují tak polohu, která je určována z měření jednotlivých snímačů. Tyto vypočítané polohy jsou zatíženy systematickou chybou.

Tvorba robotických map je komplikována obtížností určení, zda data naměřená v různých časových okamžicích zobrazují stejná místa v prostoru. Tento problém je v literatuře velmi často zmiňován jako *problém korespondence* měření, nebo jako problém *sdužování dat* [3, 7]. Hlavním důsledkem problému sdužování dat je skutečnost, že s rostoucím časem a počtem měření může celková odchylka polohy překročit mez, která je přijatelná pro lokalizační a mapovací algoritmus. Výpočetní náročnost určení korespondujících bodů měření je proto omezujícím faktorem pro některé algoritmy. Tyto algoritmy dokáží zpracovat pouze omezený počet prvků, čímž je omezena velikost mapy, pro kterou je tato skupina SLAM algoritmů využitelná [8].

Dalším důležitým aspektem při vytváření robotické mapy je dynamika prostředí. Reálné prostředí většinou prochází změnami. Většina současných mapovacích algoritmů předpokládá statické prostředí a všechny dynamické změny v prostředí jsou vyhodnocovány jako šumový signál. Důsledkem tohoto předpokladu je, že lokalizační a mapovací algoritmy jsou funkční v relativně krátkých časových intervalech, ve kterých je prostředí neměnné.

2.2 Poloha robotu jako náhodná veličina

Na polohu robotu, stejně tak jako na polohu orientačních bodů získaných měřeními, lze pohlížet jako na náhodnou veličinu. Poloha mobilního robotu popsaná stavovým vektorem \mathbf{x}_t je závislá na vstupním řídicím signálu \mathbf{u}_t a předchozí hodnotě stavového vektoru \mathbf{x}_{t-1} . Tuto hodnotu lze vyjádřit jako $p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t)$. Takto vyjádřená podmíněná pravděpodobnost je nazývána *pravděpodobností přechodu stavů* a popisuje časový průběh stavového vektoru \mathbf{x}_t [9].

Obdobným způsobem lze popsat také *pravděpodobnost měření*, jako: $p(\mathbf{o}_t | \mathbf{x}_t)$. Z tohoto zápisu je patrné, že hodnota měření je závislá pouze na poloze robotu v prostoru. Tato pravděpodobnost je popisem předpisu, podle něhož jsou generována měření \mathbf{o}_i na základě polohy robotu \mathbf{x}_i .

Jelikož polohu robotického systému nelze stanovit přímo, je nutné tuto polohu odvodit z měřených dat a předpokládaného stavu (polohy) robotu.

Předpokládaný stav robotu je aposteriorní pravděpodobnost vyjadřující hodnotu stavu po provedení akčního zásahu do robotického systému. V tomto případě je pro určení stavu robotu využívána hodnota měření \mathbf{o}_t . Obdobně lze stanovit také hodnotu aposteriorní pravděpodobnosti před započítáním hodnoty pozorování \mathbf{o}_t jako $p(\mathbf{x}_t | \mathbf{o}_{1:t-1}, \mathbf{u}_{1:t})$. Tyto dvě aposteriorní pravděpodobnosti jsou vyjádřením znalosti stavového vektoru mobilního robotu.

- aposteriorní pravděpodobnost nezahrnující hodnotu měření v čase t . Tato pravděpodobnost je nazývána *predikcí stavu* systému:

$$p(\mathbf{x}_t | \mathbf{o}_{1:t-1}, \mathbf{u}_{1:t}) \quad (1)$$

- aposteriorní pravděpodobnost zahrnující hodnotu měření:

$$p(\mathbf{x}_t | \mathbf{o}_{1:t}, \mathbf{u}_{1:t}) \quad (2)$$

Přechod od aposteriorní pravděpodobnosti (1) k aposteriorní pravděpodobnosti (2) se pak nazývá *aktualizací (korekcí) stavu* systému.

Analytické vyjádření a výpočet pravděpodobnosti $p(\mathbf{x}_t | \mathbf{o}_{1:t}, \mathbf{u}_{1:t})$ jsou možné pouze v omezeném počtu případů. Pro reálné robotické systémy, je zapotřebí využít vhodné aproximace této aposteriorní pravděpodobnosti. Pro aproximaci aposteriorní pravděpodobnosti byl zvolen jeden ze základních druhů popisu [9, 10].

2.3 Popis polohy robotu pomocí Gaussova rozdělení pravděpodobnosti

U tohoto způsobu aproximace se k popisu aposteriorní pravděpodobnosti $p(x_t | o_{1:t}, u_{1:t})$ využívá n -rozměrného Gaussova rozdělení a jeho základních charakteristik:

$$p(x) = \det(2\pi\Sigma)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right\} \quad (3)$$

Σ - kovarianční matice. Symetrická, pozitivně definitní matice, jejíž prvky mají hodnotu σ_{ij} .
 μ - vektor středních hodnot. Algoritmy, které využívají tohoto zjednodušeného popisu, jsou nazývány gaussovskými filtry. Mezi nejznámější zástupce této skupiny patří:

Kalmanův filtr - KF pro parametrizaci Gaussova rozdělení je využíváno jeho prvních dvou momentů - *středních hodnot a rozptylů*. Hlavní nevýhodou Kalmanova filtru je, že tento algoritmus je vhodný pouze pro spojité, lineární systémy.

Rozšířený Kalmanův filtr - EKF (*Extended Kalman Filter*). Jelikož funkce pro přechody mezi jednotlivými stavy a závislosti měření většinou nejsou lineární, vyvstává potřeba linearizace přechodové funkce. Algoritmus EKF využívá pro aproximaci nelineární funkce Taylorova rozvoje, ze kterého využívá pouze koeficienty pro první řád [10, 11, 12].

2.4 Rozšířený Kalmanův filtr

Hlavní myšlenkou Kalmanova filtru je spojení algoritmu zpětnovazebního estimátoru pro odhad stavu systému s rekurzivním výpočtem minimalizace odchylky metodou nejmenších čtverců. Algoritmus Kalmanova filtru předpokládá, že model mobilního robotu je popsán stavovými rovnicemi.

Předpokladem této metody je, že model systému je lokálně lineární, hodnoty procesního $\vartheta_{(k)}$ a měřicího $\mathbf{w}_{(k)}$ šumu jsou dostatečně malé a že lze provést odhad stavu systému na základě předchozích výstupů. Stavové rovnice systému a jeho výstupu jsou:

$$\mathbf{x}_{(k+1)} = f(\mathbf{x}_{(k)}, \mathbf{u}_{(k)}, \vartheta_{(k)}) \quad (4)$$

$$\mathbf{y}_{(k)} = h(\mathbf{x}_{(k)}, \mathbf{w}_{(k)}) \quad (5)$$

Pro splnění požadavku na částečně lineární systém je nutné provést linearizaci pomocí Taylorova rozvoje. Linearizované modely systému a snímače lze popsat jako:

$$\mathbf{x}_{(k+1)} = f(\tilde{\mathbf{x}}_{(k|k)}, \mathbf{u}_{(k)}, 0) + \nabla f_x \Delta \mathbf{x}_{(k|k)} + \nabla f_\vartheta \vartheta_{(k)} \quad (6)$$

$$\mathbf{y}_{(k+1)} = h(\tilde{\mathbf{x}}_{(k+1|k)}, 0) + \nabla h_x \Delta \mathbf{x}_{(k+1|k)} + \nabla h_w \mathbf{w}_{(k+1)} \quad (7)$$

kde matice ∇f_x , ∇f_ϑ , ∇h_x , ∇h_w jsou matice Jakobiánů funkcí f_x a f_y , jejichž rozvoj je proveden podle \mathbf{x} respektive ϑ a \mathbf{w} a jejich hodnota je vyjádřena pro $\Delta \mathbf{x}_{(k|k)}$, $\Delta x_{(k+1|k)}$ respektive pro $\vartheta_{(k)}$, $\mathbf{w}_{(k+1)}$.

Rovnice umožňující odhad stavu systému je:

$$\tilde{\mathbf{x}}_{(k+1|k)} = f(\tilde{\mathbf{x}}_{(k|k)}, \mathbf{u}_{(k)}, 0) \doteq E [f(\tilde{\mathbf{x}}_{(k|k)}, \mathbf{u}_{(k)}, 0) + \nabla f_x \Delta \mathbf{x}_{(k|k)} + \nabla f_\vartheta \vartheta_{(k)}] \quad (8)$$

jestliže platí, že hodnoty $\Delta \mathbf{x}_{(k|k)}$ a $\vartheta_{(k)}$ jsou dostatečně malé a mají nulovou střední hodnotu, lze hodnotu odchylky vyjádřit jako:

$$\begin{aligned} \Delta \mathbf{x}_{(k+1|k)} &= \mathbf{x}_{(k+1)} - \tilde{\mathbf{x}}_{(k+1|k)} \\ &= \nabla f_x \Delta \mathbf{x}_{(k|k)} + \nabla f_\vartheta \vartheta_{(k)} \end{aligned}$$

Kovarianční matice odhadu stavového vektoru odpovídá:

$$\begin{aligned} P_{(k+1|k)} &= E [\Delta \mathbf{x}_{(k+1|k)} \Delta \mathbf{x}_{(k+1|k)}^T] \\ &\doteq \nabla f_x P_{(k|k)} \nabla f_x^T + \nabla f_\vartheta Q_{(k)} \nabla f_\vartheta^T \end{aligned} \quad (9)$$

Obdobným způsobem lze určit také vztah pro hodnotu vektoru odhadů výstupních hodnot a inovačního vektoru:

$$\tilde{\mathbf{y}}_{(k+1)} = h(\tilde{\mathbf{x}}_{(k+1|k)}, 0) \quad (10)$$

Člen, vypovídající o kvalitě odhadu stavu, je obsažen v rovnici pro výstupní hodnotu systému, který je:

$$\begin{aligned} \Delta \mathbf{y}_{(k+1)} &= \mathbf{y}_{(k+1)} - \tilde{\mathbf{y}}_{(k+1)} \\ &\doteq \nabla h_x \Delta \mathbf{x}_{(k+1|k)} + \nabla h_w \mathbf{w}_{(k)} \end{aligned} \quad (11)$$

a nazývá se *vektorem inovace*. Tento rozdíl mezi odhadem měření a skutečnou hodnotou

získanou měřením je zaveden pomocí matice L do rovnice pro odhad stavu (8):

$$\begin{aligned}\tilde{\mathbf{x}}_{(k+1|k+1)} &= \tilde{\mathbf{x}}_{(k+1|k)} + L_{(k+1)} \triangle \mathbf{y}_{(k+1)} \\ P_{(k+1|k+1)} &= P_{(k+1|k)} - L_{(k+1)} \chi_{\Delta\Delta(k+1|k)} L_{(k+1)}^T\end{aligned}$$

Vhodná volba matice L umožní ovlivnit odhad stavového vektoru tak, aby jeho odchylka od skutečného stavu byla minimální. Algoritmus výpočtu matice L je nazýván Kalmanovým filtrem - estimátorem stavu. Pro hodnotu váhové matice L platí:

$$\begin{aligned}L_{(k+1)} &= P_{(k+1|k)} \nabla h_x^T \chi_{\Delta\Delta(k+1|k)} \\ &= \chi_{x\Delta(k+1|k)} \chi_{\Delta\Delta(k+1|k)}\end{aligned}\tag{12}$$

Jednotlivé kovarianční matice jsou:

$$\begin{aligned}\chi_{\Delta\Delta(k+1|k)} &\doteq \nabla h_x P_{(k+1|k)} \nabla h_x^T + \nabla h_w R_{(k+1)} \nabla h_w^T \\ \chi_{x\Delta(k+1|k)} &\doteq P_{(k+1|k)} \nabla h_x^T\end{aligned}\tag{13}$$

Tímto způsobem výpočtu kovarianční matice inovačního vektoru $\chi_{\Delta\Delta}$ a váhové matice L je zaručeno, že odhad stavového vektoru robotu $\tilde{\mathbf{x}}_R$ je neposunutý. Odhad stavového vektoru $\tilde{\mathbf{x}}_{(i|j)}$ je považován za neposunutý, pokud platí, že matice: $P_{(i|j)} - E \left[\Delta \mathbf{x}_{(i|j)} \Delta \mathbf{x}_{(i|j)}^T \right]$ je semidefinitně pozitivní [13, 14].

Rozšířený Kalmanův filtr (EKF) je v algoritmu průběžné lokalizace a mapování (SLAM) využíván jako estimátor pro stanovení polohy mobilního robotu. Předpokladem je, že v pracovním prostředí robotu se nacházejí orientační body, podle nichž se robot lokalizuje. V navrženém algoritmu SLAM tyto body odpovídají rohům místností.

3 Model robotu

Popsaný algoritmus pro lokalizaci mobilního robotu využívá odhadu polohy robotu a odhadu polohy orientačních bodů, jejichž poloha je měřena snímačem umístěným na mobilním robotu. Aby bylo možno provést tyto odhady, je třeba vytvořit matematický model robotického systému a použitého snímače.

Prostředí, ve kterém se robot pohybuje, je popsáno množinou orientačních bodů \mathbf{m}_N , kde $N \in \mathbb{R}$. Jednotlivé prvky množiny \mathbf{m}_i jsou popsány souřadnicemi x_i a y_i v globálním kartézském systému. Tyto souřadnice jsou zároveň stavovými veličinami popisujícími stav orientačního bodu. Předpokladem je, že stav orientačních bodů je v čase konstantní.

Pro úlohu mapování a lokalizace je využíván robot UTAR, který je vyvíjen na Ústavu


automatizace a měřicí techniky od roku 1999. Jedná se o čtyřkolový mobilní robot, který je poháněn dvěma stejnosměrnými motory. Kola na jsou každé straně robotu spojena řetězem, robot nemá otočnou nápravu, proto při otáčení robotu dochází ke smyku. Hlavní výhodou této konstrukce mobilního podvozku je jeho jednoduchá mechanická konstrukce a velká robustnost, což umožňuje pohyb nejen ve vnitřních prostorách, ale i ve vnějším prostředí.

Pro účely mapovacího algoritmu byl vytvořen jednoduchý matematický model umožňující stanovení stavových veličin. Matematicky lze robot popsat na základě sil na něj působících. Tento způsob popisu vede ke vzniku složitějšího dynamického modelu. Zatímco určení polohy robotu pomocí dynamického modelu je dáno řešením soustavy diferenciálních rovnic, u modelu kinematického se jedná o řešení soustavy goniometrických rovnic.

Při sestavování kinematického modelu jsou pro stanovení průběhu rychlosti pohybu robotu použity pouze rychlosti jednotlivých kol. V takovém případě matematický model robotu nezohledňuje síly, které na něj při pohybu působí. V případě robotu UTAR se jedná zvláště o smykové síly, které působí na kola robotu během zatáčení. Jedním z předpokladů pro sestavení kinematického modelu robotu je, že kola robotu vykonávají čistě rotační pohyb kolem své osy a nedochází k jeho smýkání [15, 16].

3.1 Kinematický model robotu

Idea náhrady jednotlivých robotů je zobrazena na obrázku 3. Požadavkem je, aby se střed



Obrázek 3: Náhrada robotu řízeného smykem robotem řízeným změnou rychlosti kol

otáčení obou robotů nacházet ve stejném bodu. Aby bylo možno provést tuto záměnu obou typů robotických podvozků, je nutné, aby byly splněny následující podmínky:

- podklad, po kterém se robot pohybuje, je homogenní, jeho vlastnosti jsou pod všemi koly shodné (v reálném případě je nutné, aby byl podklad shodný alespoň přibližně),
- kola robotu mají shodné vlastnosti (materiál pneumatik, tlak v pneumatikách, míra opotřebení apod.),

- těžiště smykem řízeného mobilního robotu leží v geometrickém středu robotu.

Pokud jsou splněny uvedené podmínky, lze smykem řízený mobilní robot popsat pomocí kinematického modelu pro robot řízený změnou rychlosti otáčení kol.

Pro dopřednou a úhlovou rychlost robotu lze psát:

$$\Delta v_{(k)} = \frac{v_{L(k)} + v_{P(k)}}{2} \quad (14)$$

$$\Delta \omega_{(k)} = \frac{v_{L(k)} - v_{P(k)}}{r_{diff}} \quad (15)$$

$$r_{diff} = Kr_{smyk} \quad (16)$$

$$\Delta v_{L(k)} = r_r \Delta \omega_{L(k)} \quad (17)$$

$$\Delta v_{P(k)} = r_r \Delta \omega_{P(k)}$$

Jednotlivé stavové veličiny odpovídající poloze robotu lze určit podle:

$$\begin{aligned} \varphi_{(k+1)} &= \varphi_{(k)} + \Delta \omega_{(k)} \\ x_{(k+1)} &= x_{(k)} + \Delta v_{(k)} \sin(\varphi_{(k+1)}) \\ y_{(k+1)} &= y_{(k+1)} + \Delta v_{(k+1)} \cos(\varphi_{(k+1)}) \end{aligned} \quad (18)$$

Tento model lze popsat nelineární přenosovou funkcí v maticovém tvaru jako:

$$\mathbf{x}_{R(k+1)} = f(\mathbf{x}_{R(k)}, \mathbf{u}_{(k)}, \vartheta_{(k)}) = \begin{pmatrix} x_{(k|k)} + \left(\frac{\Delta v_{P(k)} + \Delta v_{L(k)}}{2} + \vartheta_v \right) \cos \left(\varphi_{(k|k)} + \frac{v_{L(k)} - v_{P(k)}}{r_{diff}} + \vartheta_\varphi \right) \\ y_{(k|k)} + \left(\frac{\Delta v_{P(k)} + \Delta v_{L(k)}}{2} + \vartheta_v \right) \sin \left(\varphi_{(k|k)} + \frac{v_{L(k)} - v_{P(k)}}{r_{diff}} + \vartheta_\varphi \right) \\ \varphi_{(k|k)} + \vartheta_\varphi + \left(\frac{v_{L(k)} - v_{Pk}}{r_{diff}} + \vartheta_v \right) \end{pmatrix} \quad (19)$$

kde $\vartheta_{(k)}$ je šumový vektor se složkou ϑ_v odpovídající rychlosti robotu a složkou ϑ_φ , která odpovídá šumu vnášenému do systému odchylkami úhlové rychlosti. Předpokladem je, že šumové složky rychlostí jednotlivých kol ϑ_{vL} a ϑ_{vP} jsou shodné.

4 Model snímače, Detekce orientačních bodů

V současné době se v mobilní robotice rozšiřuje využívání laserových proximitních senzorů. Tyto senzory se vlivem vyvíjející se technologie stávají přístupnější pro robotická pracoviště a svými vlastnostmi doplňují a rozšiřují možnosti stávajících sensorických systémů robotu. Jedná se většinou o senzory, které nejsou primárně určené pro mobilní robotiku, ale pro využití v průmyslových aplikacích, jako jsou zabezpečení nebezpečných provozů, kontrola výroby apod. Mezi významné výrobce této skupiny patří například firma Keyence, Minolta a Sick. Tyto snímače obvykle určují vzdálenost na základě známé rychlosti šíření paprsku a doby letu. Proto je skupina těchto snímačů nazývána (*TOF - Time Of Flight*).

S rozvojem mobilní robotiky se objevují také firmy, které vyvíjejí a vyrábějí laserové snímače přizpůsobené potřebám mobilní robotiky. Jedná se zvláště o přizpůsobení rozměrů a hmotnosti snímače robotickým platformám. Cílem je vyrábět co nejmenší a nejlehčí snímače tak, aby šly využít nejen u robotů pozemních, ale například i u robotů létajících. Mezi nejvyužívanější principy měření u těchto snímačů patří aktivní triangulační metoda a TOF. Vývojem a výrobou těchto snímačů se mimo jiné zabývají firmy Hokuyo a Mesa Imaging AG (3D proximitní kamera). Hmotnost těchto snímačů je většinou snížena na úkor robustnosti a odolnosti proti nepříznivým vlivům prostředí, a proto nejsou určeny pro použití ve vnějším prostředí. Přesto však jsou tyto snímače využívány pro návrhy a testování navigačních algoritmů pro vnější prostředí.

Výstupem z proximitního snímače vzdálenosti je sada měření, která reprezentuje vzdálenost překážek, které se nacházejí v polorovině před snímačem. Každý prvek měření reprezentuje vzdálenost bodu v prostoru, který je popsán souřadnicemi v polárním souřadnicovém systému. Jednotlivé sady měření reprezentují tzv. *lokální mapy*. Lokální mapa představuje vjem robotu v okamžiku měření bez vztahu k počátku globálního souřadnicového systému. Počátek souřadnicového systému lokální mapy je umístěn v ose rotace zrcátka, které rozmítá měřicí laserový paprsek. Na lokální mapu lze pohlížet také jako na binární obraz $O = (\mathbf{b}_1 \dots \mathbf{b}_n)$, jehož každý bod může nabývat hodnoty 1 nebo 0. Buňka binárního obrazu nabývá hodnoty 1 v místě, které odpovídá překážce. V ostatních místech nabývá binární obraz hodnoty 0.

Cílem algoritmu SLAM je nalezení *globální mapy* $M_G = (\mathbf{m}_{G1} \dots \mathbf{m}_{Gn})$ prostředí, která je vztažena ke globálnímu souřadnicovému systému. Pro co nejpřesnější odhad polohy robotu (umožňuje vztažení lokální mapy ke globálnímu souřadnicovému systému) je třeba zajistit, aby byla porovnávána data, která spolu vzájemně korespondují. Jednou z možností, jak dosáhnout tohoto výsledku, je zpracování lokální mapy tak, aby byly nalezeny *význačné rysy* popisující pracovní prostředí robotu $M_L = (\mathbf{m}_{L1} \dots \mathbf{m}_{Ln})$.

- *význačný rys prostředí* - uspořádání částí naměřených hodnot, které charakterizují zkoumané prostředí. Znakem vhodného rysu je skutečnost, že je snadno matematicky popisatelný a je detekovatelný v posloupnosti po sobě jdoucích měřeních [15].

V důsledku skutečnosti, že lokální mapa prostředí odpovídá binárnímu obrazu, lze pro nalezení význačných rysů oblasti použít algoritmy využívané v oblasti počítačového vidění. Mezi význačné rysy, které lze využít jako orientační body při lokalizaci mobilního robotu patří [17, 18, 19]:

- *geometrická primitiva* - přímky, oblouky, části kružnic. Tyto geometrické útvary popisují překážky, které jsou tvořeny rovnými nebo zakřivenými souvislými plochami, odpovídajícími například stěnám místnosti. Hlavním zdrojem chyb při hledání geometrických prvků je šum, kterým jsou zatížena výstupní data ze snímače ¹.

¹Tato skutečnost má za následek, že data reprezentující přímku neleží na ideální přímce, z čehož vyplývá nutnost nalezení vhodné aproximace.

- *rohly místnosti* - tato místa v obrazové funkci jsou vhodná jako orientační body při lokalizaci robotu z toho důvodu, že jsou většinou detekovatelná v sekvenci několika po sobě jdoucích obrazů. V obrazové funkci jsou definována jako místa, v nichž je velké zakřivení hranic zkoumaného prostoru. Detekci rohů místnosti lze převést na hledání průsečíků křivek. Pro hledání průsečíků v obraze získaném laserovým proximitním snímačem nejsou vhodné metody, které jsou založeny na hledání rohu pomocí porovnávání obrazu a předem dané šablony. Důvodem je klesající závislost hustoty bodů na vzdálenosti.
- *Radonova transformace*. Hledání parametrů přímek je převedeno na hledání lokálních maxim v prostoru parametrů přímek $\mathcal{H}(r, \alpha)$. Prostor parametrů přímek je vytvořen na základě normálové rovnice přímek a je popsán parametry r, α , které odpovídají normálové reprezentaci rovnice přímky. Popis přímky tvoří tzv. model, podle něhož jsou určovány hodnoty prvků akumulátoru. Obecná verze obou metod je vhodná nejen k hledání přímek v obraze, ale umožňuje hledání i jiných geometrických primitiv v závislosti na volbě modelu křivky.

Mezi hlavní výhody Radonovy transformace patří skutečnost, že není citlivá na vzdálenost a chybějící body obrazové funkce O .

Oproti předem uvedeným metodám je však tento algoritmus výpočetně náročný a jeho výsledkem jsou rovnice přímek, nikoliv úsečky, které by přímo odpovídaly zdem ohraničujícím prostor. Je tedy nutné metodu doplnit o algoritmus pro nalezení počátku a konců úseček.

Vzhledem k tomu, že s rostoucí vzdáleností měřených objektů roste vzdálenost mezi jednotlivými body obrazu a díky necitlivosti na chybějící body v měření, byla pro získávání geometrického popisu prostředí zvolena metoda Radonovy transformace. Byla navržena modifikace algoritmu, která umožňuje zpracování binárního obrazu z laserového snímače.

4.1 Radonova transformace

Radonova transformace je obdobou algoritmu Houghovy transformace. Pomocí této transformace, která je nejčastěji využívána ke zpracování obrazu v medicínské technice, je možno z binárního obrazu O získaného pomocí laserového proximitního snímače určit skupiny bodů, které náleží k jednotlivým přímkám. Radonova transformace je definována jako:

$$Rf(r, \alpha) = \int \int O(x, y) \delta(r - x \cos(\alpha) + y \sin(\alpha)) dx dy \quad (20)$$

Obrazová funkce $O(x, y)$, kde: $(x, y) \in R^2$, je touto rovnicí transformována na funkci $Rf(r, \alpha)$, kde $r \in R$ a $\alpha \in (0, \pi)$. Rovnice 20 je vyjádřením spojitě Radonovy transformace. Množina bodů naměřených laserovým snímačem je však diskrétní. Pro použitý laserový snímač SICK LMS 200 má krok mezi jednotlivými měřeními (v polárních souřadnicích snímače) velikost $0,25^\circ, 0,5^\circ, 1^\circ$ [20]. Proto bylo využito diskrétní Radonovy transformace, jejíž algoritmus je

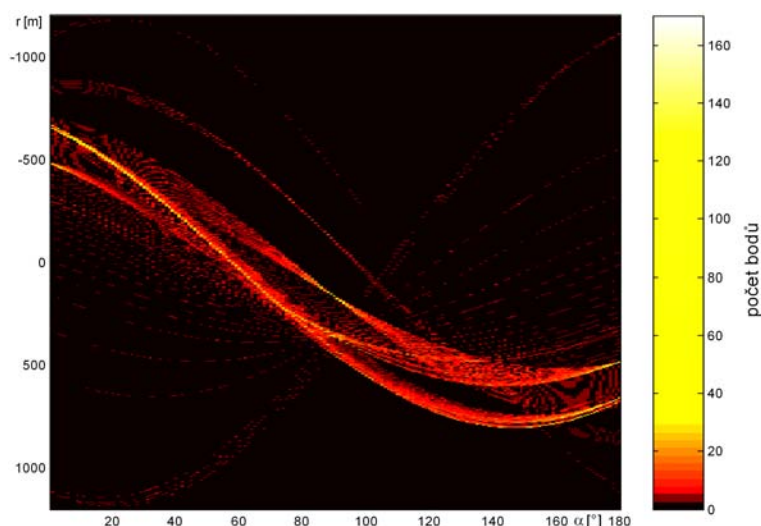
implementován v programu Matlab 6.5 (verze 13) ve funkci `radon.m`. V následujícím textu je uveden jeho princip [21, 22, 23].

V každém kroku je binární obraz pootočen kolem svého středu a je určen počet bodů v každém řádku obrazu. Toto číslo je uloženo do akumulátoru $\mathcal{H}(\alpha, r)$, který má stejnou strukturu jako akumulátor u Houghovy transformace. Pootočení obrazu je prováděno v rozmezí $\alpha \in (0, \pi)$. Velikost pootočení k_α obrazu je nastavitelná, což umožňuje ovlivnit přesnost hledaného parametru α_i a zároveň ovlivňuje rychlost algoritmu.

Při otáčení obrazu O jsou souřadnice každého bodu ($\mathbf{b}_1, \mathbf{b}_2 \dots \mathbf{b}_n$) přepočítány pomocí rotační matice (rovnice 21):

$$\begin{pmatrix} x'_n \\ y'_n \end{pmatrix} = \begin{pmatrix} \cos k_\alpha & -\sin k_\alpha \\ \sin k_\alpha & \cos k_\alpha \end{pmatrix} \begin{pmatrix} x_n \\ y_n \end{pmatrix} \quad (21)$$

Po provedení rotace je určen počet bodů v každém řádku obrazu. Toto číslo je uloženo do akumulátoru $\mathcal{H}(\alpha, r)$. Parametry normálových rovnic hledaných přímek jsou v tomto akumulátoru opět reprezentovány jako lokální maxima [24]. Na obrázku 4 je zobrazen příklad akumulátoru získaného pomocí Radonovy transformace.



Obrázek 4: Akumulátor parametrů přímek pro Radonovu transformaci měření

5 Určení parametrů hledaných přímek

Vzhledem k tomu, že v reálném případě neleží všechny body na jedné přímce, je třeba hodnoty v akumulátoru $\mathcal{H}(\alpha, r)$ zpracovat takovým způsobem, aby nalezené přímky byly nejvhodnější reprezentací pro změřené body.

Při robotickém průzkumu většinou není předem známa struktura prostředí, což znamená, že dopředu nelze určit kolik a jak dlouhé jsou přímky, které prostředí definují. Z tohoto důvodu

není vhodné použít metodu, při níž by se určila prahová hodnota pro hledanou přímku. V takovém případě by byly ze sady nalezených přímek odstraněny přímky, na kterých leží malý počet bodů. Pro hledání přímek byl proto navržen algoritmus na základě shlukové analýzy parametrů přímek v akumulátoru $\mathcal{H}(\alpha, r)$.

5.1 Shlukování nalezených přímek

Základním principem shlukové analýzy je rozdělení objektů (nalezené přímky) do shluků v závislosti na jejich podobnosti, resp. odlišnosti. Objekt je reprezentován svými parametry: $\mathbf{o} = (p_1, p_2)$ kde $p_1 \approx \alpha$ a $p_2 \approx r$. Pro všechny objekty $(\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_n)$ je určena jejich vzájemná vzdálenost d . Na základě této vzdálenosti a nastavené hodnoty prahu T pro rozdělení objektů do jednotlivých shluků jsou potom parametry přímek rozděleny do skupin. Každá skupina parametrů reprezentuje jednu přímku v obraze. Z každé skupiny je pak vybrán objekt odpovídající lokálnímu maximu ve shluku. Takto vybraný objekt odpovídá přímce, na které leží největší počet bodů.

5.2 Určení vzdálenosti mezi jednotlivými objekty

Pro výpočet vzájemných vzdáleností objektů jsou vhodné tyto metody určení vzdálenosti mezi objekty:

Mahalanobisova vzdálenost - tento způsob určení vzdálenosti mezi dvěma objekty je vhodný zejména z toho důvodu, že pomocí váhové matice A v rovnici 22 lze nastavit důležitost koeficientů pro přiřazení do shluku. Vzdálenost mezi dvěma objekty je určena podle:

$$d_M(o_k, o_l) = \sqrt{(o_k - o_l)^T A S^{-1} A (o_k - o_l)}, \quad (22)$$

kde matice A je symetrická matice váhových koeficientů pro jednotlivé parametry a S je matice vzájemných kovariancí mezi jednotlivými parametry.

Euklidovská vzdálenost - v případě, že váhová a rozptylová matice jsou matice jednotkové, Mahalanobisova vzdálenost přechází ve výpočetně jednodušší euklidovskou vzdálenost. Tento způsob však neumožňuje váhování koeficientů. Pro výpočet euklidovské vzdálenosti platí:

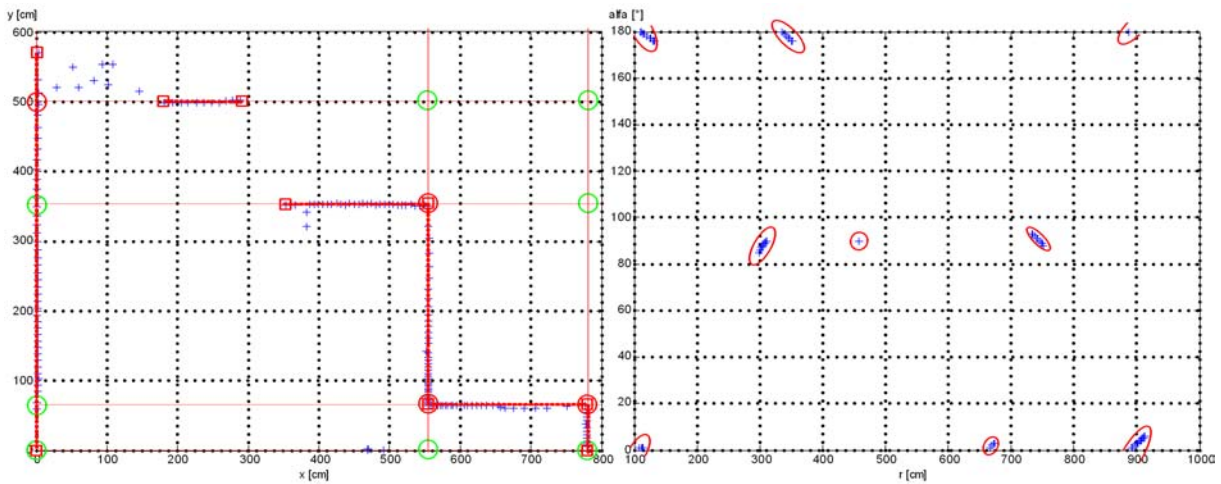
$$d_E(o_k, o_l) = \sqrt{\sum_{i=1}^n (p_{ik} - p_{il})^2} \quad (23)$$

Vzhledem k tomu, že Houghův akumulátor je dvourozměrné pole, kde $n = 2$. V tomto dvourozměrném případě lze nastavení váhy důležitosti jednotlivých parametrů provést změnou měřítka jedné z os v $\mathcal{H}(\alpha, r)$. Tohoto způsobu nastavení citlivosti bylo využito v navrženém a testovaném algoritmu.

5.3 Rozdělení objektů do shluků

Pro rozdělení objektů do shluků je třeba vytvořit matici vzdáleností mezi všemi objekty nalezenými v Houghově akumulátoru $\mathcal{H}(\alpha, r)$. Nastavením prahové hodnoty T pro rozdělení parametrů přímek do jednotlivých shluků je možno nastavit citlivost algoritmu na vzájemnou vzdálenost úseček a rozptyl úhlu jednotlivých úseček reprezentujících stěny a jejich natočení. Pro výpočet matice vzdáleností byla využita základní, euklidovská vzdálenost mezi objekty. Pro přiřazení nebo vyloučení objektu ke shluku bylo použito vzájemné vzdálenosti nejbližších prvků shluků. Tímto nastavením bylo dosaženo výsledku zobrazeného na obrázku 5.

V levé části obrázku 5 je znázorněn výstup z laserového snímače, který byl získán při reálném měření. Také jsou zde zobrazeny nalezené přímky, průsečíky přímek, počátky a konce přímek. Zelenou barvou jsou vyznačeny průsečíky přímek, které neodpovídají rohům místnosti. Platné přímky jsou zobrazeny čárkovaně. Konce a počátky úseček jsou označeny čtvercovou značkou, zatímco průsečíky jsou zobrazeny jako kružnice.



Obrázek 5: Data z laserového proximity snímače, akumulátor se zvýrazněnými shluky

V pravé části obrázku je zobrazen akumulátor $\mathcal{H}(\alpha, r)$, pro toto měření. V $\mathcal{H}(\alpha, r)$ jsou barevně ohraničeny shluky bodů. Každý shluk reprezentuje jednu z přímek nalezených v binárním obraze získaném měřením. V každém shluku je následně nalezen bod reprezentující přímku, na níž leží největší počet bodů (lokální maximum hledané v oblasti shluku). Souřadnice tohoto bodu (α, r) jsou použity pro aproximaci měření.

Nalezené parametry přímek lze přímo využít jako jeden z hledaných znaků popisujících zkoumanou oblast nebo jako vstup do další části algoritmu. Pro určení průsečíků přímek odpovídajícím rohům místností je využíván následující postup.

Jestliže se průsečík nachází v blízkém okolí bodů náležejícím oběma přímkám (vzdálenost je stanovena podle rovnice 23), jedná se o roh místnosti. V opačném případě průsečík přímek neodpovídá reálnému orientačnímu bodu. Také jsou stanoveny hranice úseček (počátek, konec), takto nalezené úsečky reprezentují zdi zkoumané oblasti.

5.4 Model snímače

Pro model snímače, jehož výstupem je poloha orientačních bodů platí:

$$h(\mathbf{x}_{(k)}, \mathbf{w}_{(k)}) = \begin{pmatrix} r_i \\ \varphi_i \end{pmatrix} = \begin{pmatrix} \sqrt{(x_{R(k)} - x_{Li})^2 - (y_{R(k)} - y_{Li})^2} \\ \tan\left(\frac{y_{R(k)} - y_{Li}}{x_{R(k)} - x_{Li}}\right) - \varphi_R \end{pmatrix} + \begin{pmatrix} w_{r(k)} \\ w_{\varphi(k)} \end{pmatrix} \quad (24)$$

Jedná se o model snímače, který definuje polohu orientačních bodů v polárních souřadnicích. Tento model byl zvolen z důvodu snazšího zohlednění šumového signálu $\mathbf{w}_{(k)}$. Složky šumového signálu jsou v práci považovány za nezávislé na čase. Funkce $h(\mathbf{x}_{(k)}, \mathbf{w}_{(k)})$ je převodním vztahem mezi souřadným systémem globální mapy M_G a lokálním souřadným systémem robotu, který je použit pro reprezentaci nalezených orientačních bodů. Vzhledem k tomu, že snímač je nedílnou součástí robotu, lze střed souřadného systému snímače snadno odvodit ze známých rozměrů robotu a snímače.

6 Současná lokalizace a mapování

Výhodou tohoto přístupu k mapování a lokalizaci v mobilní robotice je skutečnost, že mobilní robot je schopen pohybu v předem neznámém prostředí. Pro orientaci v prostředí nepotřebuje zásah člověka a vytvoření umělých orientačních bodů. Pro určení polohy jsou využívána měření ze snímačů, tato data jsou současně využívána i pro vytváření mapy, ve které se robot lokalizuje, což činí mobilní robot autonomním (ve smyslu schopnosti samostatného pohybu prostorem) [25]. Navržený algoritmus náleží k online algoritmům pro SLAM.

- *Online SLAM* - algoritmus, při němž jsou pro určení polohy robotu a orientačních bodů využívány pouze proměnné (poloha, poloha překážek, ...), které jsou aktuální v prováděném kroku k . Po té, co jsou tyto proměnné zpracovány, nejsou ukládány v paměti robotu. Tento algoritmus je inkrementální a umožňuje vytvoření mapy prostředí o téměř libovolné velikosti. Data lze do mapy přidávat do mapy v libovolném počtu kroků. Jelikož je však výpočetní náročnost online SLAMu kvadraticky závislá na počtu orientačních bodů, je velikost globální mapy omezena výpočetním výkonem. Nevýhodou tohoto algoritmu je potřeba velmi robustního procesu o vzájemné korespondenci orientačních bodů mapy $\mathbf{m}_G = \{\mathbf{m}_{G1}, \dots, \mathbf{m}_{Gn}\}$ odpovídá orientační bod \mathbf{m}_{Lm} . Při řešení online SLAMu se jedná o hledání aposteriorní pravděpodobnosti: $p(\mathbf{x}_k, \mathbf{m} \mid \mathbf{o}_{1:k}, \mathbf{u}_{1:k})$.

Pro odhad polohy robotu a vytváření mapy je využito rozšířeného Kalmanova estimátoru stavů. Matematické modely robotu a laserového snímače jsou uvedeny v předchozích kapitolách. Popis těchto prvků byl uveden s ohledem na jejich využití pro algoritmus SLAM.

6.1 Inicializace lokalizačně mapovacího algoritmu

V prvním kroku algoritmu SLAM je střed globálního souřadnicového systému nastaven do bodu, kde se nachází robot $\mathbf{x}_0 = [0, 0, 0]^T$. Ve stejném časovém okamžiku jsou také nastaveny hodnoty všech kovariančních matic. Hodnota matice Q reprezentuje šumový signál, který vstupuje do systému, čímž ovlivňuje polohu mobilního robotu. Matice R zohledňuje šum měření. Hodnoty těchto matic byly nastaveny na základě experimentů, které jsou popsány v kapitole 3.

V této poloze je provedeno první měření prostředí a segmentace naměřených dat pomocí přímek a jejich průsečíků. Tyto význačné rysy jsou uloženy do matice $\mathbf{m}_G = (\mathbf{m}_1, \dots, \mathbf{m}_n)$, čímž je vytvořena *globální mapa* pro $k = 1$.

6.2 Predikce stavového vektoru a hodnot měření

Na základě řídicího signálu $\mathbf{u}_k = (v_{Lk}, v_{Pk})$ se robot přemístí do polohy $\mathbf{x}_{R(k+1)} = (x_{(k+1)}, y_{(k+1)}, \varphi_{(k+1)})$. Odhad polohy robotu $\tilde{\mathbf{x}}_{R(k+1)}$ je určen z matematického modelu robotu, který byl definován v kapitole 3. Rovnice 25 popisuje přenosovou funkci $f(\mathbf{x}_{(k)}, \mathbf{u}_{(k)}, 0)$

$$\tilde{\mathbf{x}}_{R(k+1|k)} = \begin{pmatrix} \tilde{x}_{(k+1|k)} \\ \tilde{y}_{(k+1|k)} \\ \tilde{\varphi}_{(k+1|k)} \end{pmatrix} = \begin{pmatrix} \tilde{x}_{(k|k)} \\ \tilde{y}_{(k|k)} \\ \tilde{\varphi}_{(k|k)} \end{pmatrix} + \begin{pmatrix} \left(\frac{\Delta v_{Pk} + \Delta v_{Lk}}{2} \right) \cos(\tilde{\varphi}_{(k+1|k)}) \\ \left(\frac{\Delta v_{Pk} + \Delta v_{Lk}}{2} \right) \sin(\tilde{\varphi}_{(k+1|k)}) \\ \left(\frac{v_{Lk} - v_{Pk}}{\text{diff}} \right) \end{pmatrix} \quad (25)$$

Vzhledem k tomu, že se jedná o nelineární přechodovou funkci, je pro výpočet kovariančních matic a Kalmanovy váhové matice potřeba určit jakobiány této funkce a vyjádřit jejich příslušné hodnoty. Jakobián ∇f_x funkce f vyjádřený pro stav systému \mathbf{x} je definován rovnicí:

$$\nabla f_x = \begin{pmatrix} 1 & 0 & -\left(\frac{v_{Pk} + v_{Lk}}{2}\right) \sin(\varphi_k) \\ 0 & 1 & \left(\frac{v_{Pk} + v_{Lk}}{2}\right) \cos(\varphi_k) \\ 0 & 0 & 1 \end{pmatrix}_{\tilde{\mathbf{x}}_{R(k+1|k)}} \quad (26)$$

Pro jakobián ∇f_ϑ funkce f vyjádřený podle šumového vektoru ϑ platí:

$$\nabla f_\vartheta = \begin{pmatrix} \cos(\varphi_k) - \left(\frac{v_{PK} + v_{LK}}{2}\right) \sin(\varphi_k) & -\left(\frac{v_{PK} + v_{LK}}{2}\right) \sin(\varphi_k) \\ \sin(\varphi_k) + \left(\frac{v_{PK} + v_{LK}}{2}\right) \cos(\varphi_k) & \left(\frac{v_{PK} + v_{LK}}{2}\right) \cos(\varphi_k) \\ 1 & 1 \end{pmatrix}_{\mathbf{u}_{(k)}} \quad (27)$$

Na základě odhadu polohy robotu $\tilde{\mathbf{x}}_{R(k+1|k)}$ je z globální mapy \mathbf{m}_G určen odhad měření pro krok $k + 1$. Odhad polohy vychází z modelu definovaného v kapitole 3. Převod souřadnic je prováděn podle rovnice 24.

V poloze $\mathbf{x}_{R(k+1)}$ je laserovým snímačem získáno měření \mathbf{y}_R . Metodou Radonovy transformace jsou z obrazu extrahovány přímky a orientační body. Orientační body tvoří lokální mapu $\mathbf{m}_{L(k+1)} = (\mathbf{x}_{L1(k+1)}, \dots, \mathbf{x}_{Lm(k+1)})$. Počet prvků m lokální mapy nemusí být nutně shodný s

počtem prvků n globální mapy.

6.3 Hledání korespondujících orientačních bodů

V okamžiku, kdy je na základě modelu systému a snímače určena předpokládaná poloha orientačních bodů v prostoru, je nutné nalézt dvojice vzájemně si odpovídajících orientačních bodů z globální a lokální mapy. Pro každou kombinaci prvků \mathbf{x}_{Lj} a \mathbf{x}_{Gk} je určena jejich vzájemná euklidovská vzdálenost (viz rovnice 23). Dvojice odpovídajících si bodů je vybrána na základě:

$$d_{tE} > \min_{j \in \{1 \dots m\}, k \in \{1 \dots n\}} \left| \sqrt{(x_{Lj} - x_{Gk})^2 + (y_{Lj} - y_{Gk})^2} \right| \quad (28)$$

Kde hodnota d_{tE} je prahová hodnota pro stanovení příslušnosti bodů. Tato hodnota je odhadnuta na základě kovariančních matic systému a snímače.

6.4 Aktualizace stavového vektoru

Dvojice navzájem si příslušejících bodů jsou v kroku aktualizace stavu využity pro vytvoření inovačního vektoru $\Delta y_{(k+1)}$ (viz rovnice 11). Pro vytvoření inovačního vektoru je využito příslušných jakobiánů výstupní přenosové funkce $h(x_{(k)}, w_{(k)})$ (viz rovnice 24) vyjádřených podle stavu systému \mathbf{x} a šumového signálu w .

$$\nabla h_x = \begin{pmatrix} 2(x_R - x_L) \left[(x_R - x_L)^2 - (y_R - y_L)^2 \right]^{-\frac{1}{2}} & 2(x_R - x_L) \left[(x_R - x_L)^2 - (y_R - y_L)^2 \right]^{-\frac{1}{2}} & 0 \\ \frac{1}{\cos^2 \frac{y_R - y_L}{x_R - x_L}} \frac{-(y_R - y_L)}{(x_R - x_L)} & \frac{1}{\cos^2 \frac{y_R - y_L}{x_R - x_L}} \frac{(x_R - x_L)}{(y_R - y_L)} & 0 \\ 0 & 0 & 0 \end{pmatrix} \tilde{\mathbf{x}}_{R(k+1|k)} \quad (29)$$

$$\nabla h_w = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \quad (30)$$

Pomocí těchto jakobiánů je z rovnice 12 určena aktualizovaná hodnota kovarianční matice stavového vektoru $P_{(k+1|k+1)}$ a následně i aktualizovaný stavový vektor $\mathbf{x}_{R(k+1|k+1)}$. Popsaný krok aktualizace zpracovává polohy jednotlivých orientačních bodů postupně. V každém kroku je pro určení polohy robotu využít pouze jeden orientační bod. Tento způsob se nazývá *sekvenčním krokem aktualizace* (sequential update step). Výhodou tohoto přístupu je jeho snadnější implementace a možnost nastavit váhy jednotlivých orientačních bodů.

Další možností je tzv. *aktualizace po dávkách* (batch update step), při níž jsou jakobiány pro všechny orientační body sloučeny do jedné matice. Této matici je pak vhodně přizpůsobena také kovarianční matice stavu robotu a krok aktualizace je proveden ze všech poloh orientačních bodů zároveň. Tento způsob aktualizací kroku umožňuje využití stavových veličin pro rozšíření globální mapy. V tomto případě by se globální mapa robotu skládala nejen z orientačních bodů, případně rysů charakterizujících prostředí, ale mohla by obsahovat

vat také hodnoty stavového vektoru v jednotlivých krocích. Využití rozšířené globální mapy umožňuje například slučování jednotlivých map v systémech s větším počtem robotů [26].

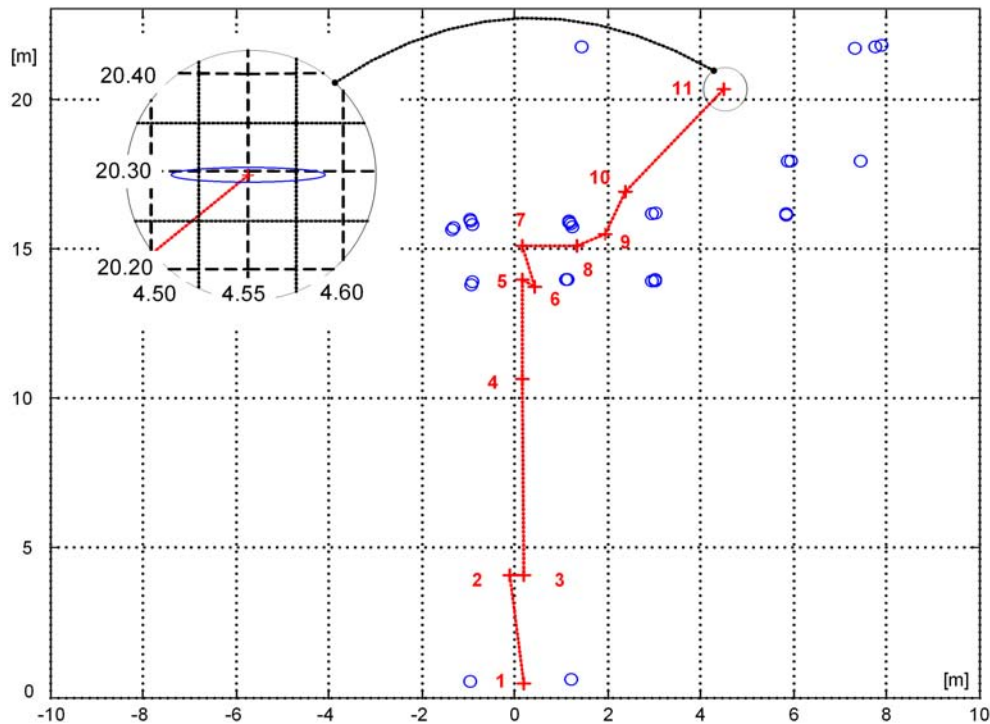
6.5 Aktualizace globální mapy

V posledním kroku SLAM algoritmu je poloha orientačních bodů z lokální mapy \mathbf{m}_L , které nebyly využity pro úlohu lokalizace, přepočítána podle rovnic 31 a 32 na základě aktualizovaného odhadu polohy robotu do globálních souřadnic. Tyto body jsou přidány do globální mapy \mathbf{m}_G .

$$x_{iG} = r_i \cos(\varphi_i - \varphi_{R(k+1|k+1)}) + x_{R(k+1|k+1)} \quad (31)$$

$$y_{iG} = r_i \sin(\varphi_i - \varphi_{R(k+1|k+1)}) + y_{R(k+1|k+1)} \quad (32)$$

Krokem aktualizace globální mapy je smyčka algoritmu SLAM uzavřena a lze pokračovat zpracováním měření v nové poloze robotu. Globální mapa prostředí je tvořena polohami jednotlivých orientačních bodů.

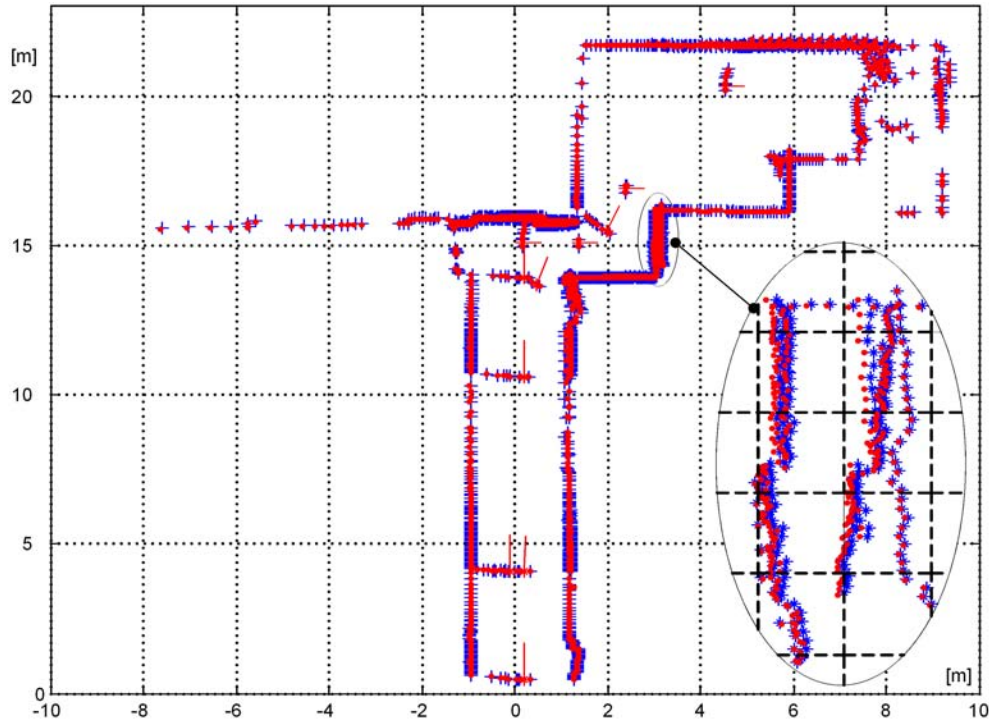


Obrázek 6: Globální mapa prostředí

Na obrázku 6 je zobrazena globální mapa prostředí, která je výsledkem realizovaného algoritmu SLAM. Modrou barvou jsou v mapě zobrazeny orientační body. Červenou čarou je vynesena trajektorie robotu a body, ve kterých bylo provedeno měření. V levém horním rohu obrázku je zobrazena elipsa, která odpovídá rozptylu hustoty pravděpodobnosti odhadnuté polohy mobilního robotu na konci mapování.

7 Experimentální ověření algoritmu SLAM

Navržený algoritmus byl experimentálně otestován v prostředí budovy VUT v Brně. Pro dané prostředí byl vytvořen příslušný model robotu. Materiál podlahy byl tvořen keramickými dlaždicemi. Vzhledem k tomu, že se jednalo o vnitřní prostory budovy, byl splněn i předpoklad rovných zdí, které bylo možno nahradit přímkami. Prostředí bylo snímáno z různých poloh pod různými úhly. Na obrázku 7 jsou naznačena místa a natočení robotu, při kterém byla prováděna měření. Na základě matematického modelu robotu byl proveden odhad polohy robotu, který byl následně aktualizován informací získané Radonovou transformací z měření.



Obrázek 7: Lokální sensorické mapy

Na obrázku 7 jsou zobrazeny lokální sensorické mapy získané při jednotlivých měřeních. Poloha jednotlivých bodů měření je přepočítána do globálního souřadného systému. Modrou barvou je vyneseno měření v polohách $\mathbf{x}_{R(1...k)}$, které byly zjištěny přesným měřením. Tyto polohy nebyly využity pro konstruování mapy, ale pouze pro kontrolu přesnosti algoritmu SLAM. Červené body jsou lokální sensorické mapy přepočítané na základě odhadu polohy robotu $\tilde{\mathbf{x}}_{R(1...k)}$. V levém horním rohu obrázku 6 je zobrazena elipsa, která odpovídá rozptylu hustoty pravděpodobnosti odhadu polohy mobilního robotu po ukončení experimentu. Rozptylu odhadu polohy $\tilde{\mathbf{x}}_{R(1...k)}$ odpovídá přibližně 1% z rozměru globální mapy.

7.1 Zhodnocení kvality globální mapy

Kvalitu získané globální mapy lze vyhodnotit pomocí posunutí odhadu stavového vektoru (odhad stavového vektoru - polohy robotu - je prováděn na základě globální mapy).

Shoda odhadu stavového vektoru (odhad není posunutý) je definována podmínkou [27]:

$$\begin{aligned} E[\mathbf{x}_{Rk} - \tilde{\mathbf{x}}_{Rk}] &= 0 \\ E[(\mathbf{x}_{Rk} - \tilde{\mathbf{x}}_{Rk})(\mathbf{x}_{Rk} - \tilde{\mathbf{x}}_{Rk})^T] &= P_k \end{aligned} \quad (33)$$

Tato podmínka je však splněna pouze v případě lineárních systémů. Přestože je váhová matice v každém kroku určena tak, aby odhad stavového vektoru nebyl posunutý (viz rovnice 12), je možné, že linearizace pomocí Taylorova rozvoje prvního řádu nepopisuje aproximované funkce f a h dostatečně přesně.

Přestože není známa hustota pravděpodobnosti popisující hodnotu stavového vektoru \mathbf{x}_{Rk} , lze provést vyhodnocení kvality jeho odhadu. Vzhledem k tomu, že při experimentu byla zaznamenávána i data odpovídající skutečné poloze a natočení robotu, lze kvalitu odhadu posoudit pomocí kritéria NEES (normalizovaný kvadrát odchylek odhadu), které je definované jako:

$$\epsilon_k = (\mathbf{x}_{Rk} - \tilde{\mathbf{x}}_{R(k|k)}) P_{(k|k)}^{-1} (\mathbf{x}_{Rk} - \tilde{\mathbf{x}}_{R(k|k)})^T \quad (34)$$

a její průměrné hodnoty pro všech N kroků algoritmu SLAM:

$$\bar{\epsilon} = \frac{1}{N} \sum_{i=1}^N \epsilon_i \quad (35)$$

Odhad stavového vektoru je neposunutý, pokud se hodnota $\bar{\epsilon}_k$ pro N jdoucích se blíží rozměru stavového vektoru [28].

Hodnota koeficientu $\bar{\epsilon}$ pro $N = 11$ (mapa prostředí je uvedena na obrázku 6) je: $\bar{\epsilon} = 3,76$, což odpovídá 92. percentilu. Tato hodnota vyjadřuje, že navržený Kalmanův estimátor je optimistický (nesplňuje podmínku definovanou 33) [28]. Důsledek této skutečnosti může při mapování rozlehlých prostor vést k nedostatečné přesnosti odhadu polohy a selhání algoritmu.

Nárůstu kvadratické chyby odhadu lze zabránit zvýšením počtu orientačních bodů, čehož lze docílit vhodným nastavením segmentačního algoritmu tak, aby byly detekovány i krátké úsečky, které se nacházejí v těsné blízkosti (odpovídající např. zárubním dveřím). Druhou možností je provádět aktualizaci odhadu stavového vektoru pomocí dávkového algoritmu (batch update). Nevýhodou tohoto postupu je však nutnost výpočtu inverzních matic s mnoha prvky, což při globálních mapách rozlehlých prostředí může být neúměrně výpočetně náročné.

8 Shrnutí dosažených cílů

V práci je řešena problematika současné lokalizace a mapování v oblasti mobilní robotiky. Jedním z možných případů je průběžná lokalizace a mapování (SLAM), při níž jsou shodná data využívána jak pro tvorbu robotické mapy, tak i pro určení polohy mobilního robotu v prostředí.

Omezujícím faktorem pro návrh algoritmu je předpoklad, že lze využívat pouze data získaná ze snímačů umístěných na robotu. Z tohoto důvodu byl zvolen pravděpodobnostní přístup zpracování informací ze sensorů a matematického modelu robotu. Tento způsob, založený na principu podmíněné pravděpodobnosti, umožňuje sloučení těchto dvou zdrojů informací. V práci jsou také prezentovány možné způsoby řešení lokalizační úlohy s ohledem na popis polohy robotu a orientačních bodů pomocí Gaussova rozložení pravděpodobnosti.

Pro řešení algoritmu SLAM byl zvolen rozšířený Kalmanův filtr (EKF). Pomocí tohoto algoritmu je na základě matematického modelu robotu a snímače určen odhad polohy robotu. Za účelem odhadu polohy mobilního robotu byl vytvořen matematický model umožňující náhradu smykem řízeného robotického podvozku za diferenciální podvozek. Byly stanoveny podmínky, za kterých je možné tuto záměnu provést. Pro ověření správnosti předpokladu bylo provedeno experimentální ověření. Výsledky experimentů byly využity nejen pro ověření vhodnosti navrženého modelu, ale také pro stanovení parametrů potřebných pro algoritmus EKF.

Navržený algoritmus SLAM patří do skupiny algoritmů, které pro svoji funkci využívají zjišťování polohy orientačních bodů. V doktorské práci je navržen vlastní způsob segmentace naměřených dat využívající Radonovy transformace. tento způsob segmentace umožňuje získání parametrů geometrických prvků využívaných pro popis prostředí.

Pracovní prostředí robotu je snímáno pomocí laserového planárního snímače. Výstupem segmentačního algoritmu je poloha orientačních bodů v lokálním souřadnicovém systému robotu. Polohy těchto bodů jsou v mapovací části navrženého algoritmu interpretovány jako informace o zkoumaném prostředí.

V práci je dále uveden podrobný popis jednoho kroku navrženého algoritmu, ve kterém je určen odhad polohy a doplněny nové orientační body do globální mapy. Navržený algoritmus SLAM byl experimentálně ověřen v reálném prostředí a výsledky experimentu byly vyhodnoceny. Výsledkem experimentu je globální mapa zkoumaného prostředí.

Možná rozšíření navržené metody

Výsledkem práce je funkční algoritmus SLAM, přesto je pro další výzkum v oblasti lokalizace a mapování množství dalších dílčích úloh, které s problematikou souvisí, ale v práci nebyly řešeny.

Přesnost a robustnost navrženého algoritmu je možné zvýšit zvláště využitím všech dosažitelných parametrů popisujících zkoumané prostředí (statistický popis prostředí, využití všech ge-

ometrických informací o prostředí,...). Implementace těchto informací získaných z měření by umožnila využití algoritmu pro mapování rozlehlých prostor, kde počet měření nabývá řádově větších hodnot.

Funkčnost navrženého algoritmu je omezena na vnitřní prostředí budov. Pro využití algoritmu ve venkovním prostředí je nutné robotický systém doplnit o možnost měření nerovnosti povrchu, po kterém se robot pohybuje. Také segmentační metoda založená na Radonově transformaci není vhodná pro nestructurované vnější prostředí a musela by být nahrazena (doplněna) metodou jinou (například orientační body definované pomocí GPS souřadnic).

Reference

- [1] BORENSTEIN, J., EVERETT, H. R., FENG, L., „*Where am I?*” *Sensors and Methods for Mobile robot Positioning*, University of Michigan, 1996
- [2] DURRANT-WHYTE, H., BAILEY, T., *Simultaneous Localisation and Mapping: Part I*, IEEE Robotics & Automation Magazine, June 2006
- [3] DURRANT-WHYTE, H., BAILEY, T., *Simultaneous Localisation and Mapping: Part II*, IEEE Robotics & Automation Magazine, September 2006
- [4] THRUN, S., *Robotic Mapping: A Survey, Exploring artificial intelligence in the new millennium*, Morgan Kaufman Publishers Inc., 2003, ISBN: 1-55860-811-7
- [5] ELFES, A., *Using Occupancy Grids for Mobile Robot Perception and Navigation*, 1989, IEEE Computer, Vol. 22, Issue 6, ISSN 0018-9162
- [6] MARTIN, C. M., MORAVEC, P. H., *Robot Evidence Grids*, Carnegie Mellon University Pittsburgh, CMU-RI-TR-96-06
- [7] NIETO, J., *Detailed Environment Representation for the SLAM Problem*, Ph.D. Thesis, University of Sydney, 2005
- [8] LOSADA, R., D., MATIA, F., GALAN, R., *Building geometric feature based maps for indoor service robots*, Robotics and Autonomous Systems 54, 2006, <www.sciencedirect.com> [cit. 1.9.2007]
- [9] THRUN, S., BURGARD, W., FOX, D., *Probabilistic robotics*, The MIT Press, 2005, ISBN 0-262-20162-3
- [10] JULIER, S.S., UHLMANN, J.K., *A New Extension of the Kalman Filter to Nonlinear Systems*, SPIE AeroSense Symposium, April 21-24, 1997. <www.cs.unc.edu/~welch/kalman> [cit. 18.6.2007]

- [11] FRANKLIN, G., F., POWELL, J., D., WORKMAN, M., L., *Digital Control of Dynamic Systems*, Addison-Wesley Publishing Company, Inc., 1990, ISBN: 0-201-51884-8
- [12] WELCH, G., BISHOP, G., *An Introduction to the Kalman Filter*, Department of Computer Science, University of North Carolina at Chapel Hill, <www.cs.unc.edu/~welch/kalman> [cit. 3.8.2007]
- [13] CSORBA, M., *Simultaneous Localisation and Mapping*, Ph.D. thesis, Oxford, 1997
- [14] MODRLÁK, O., *Základy analýzy a syntézy ve stavovém prostoru*, studijní materiály, Katedra řídicí techniky Technická Univerzita v Liberci, 2004, <www.fm.vslib.cz/~krt/krt_cz/krt_om.htm> [cit. 29.8.2007]
- [15] SIEGWART, R., NOURBAKSH, I., R., *Introduction to Autonomous Mobile Robots*, A Bradford Book, MIT Press, 2004, ISBN 0-262-19502-X
- [16] PAZDERSKI, D., KOZLOWSKI, K., DIXON, W. E., *Tracking and Regulation Control of a Skid Steering Vehicle*, ANS International Conference on Robotics and Remote Systems for Hazardous Environments, 2004, pp. 369-376
- [17] LEI, B. J., HENDRIKS, E. A., REINDERS, M. J. T., *On Feature Extracion from Images*, Research Review of MCCWS project, Information and Communication Theory Group, TU Delft, 1999, <<https://doc.telin.nl/dsweb/Get/Document-10236/>> [cit. 10.12.2007]
- [18] ALEMPIJEVIC, A., *High Speed Feature Extraction in Sensor Coordinates for Laser Rangefinders*, Australasian Conference on Robotics & Automation, 2004, <www.araa.asn.au/acra/acra2004> [cit. 1.12.2007]
- [19] NGUYE, V. MARTINELLI, A., TOMATIS, N., SIEGWART, R., *A Comparison of Line Extraction Algorithms using 2D Laser Rangefinder for Idoor Mobile Robotics*, IROS'2005, ISBN 0-7803-891-3, 2005
- [20] <www.sick.com> [cit. 14.9.2007]
- [21] <www.mathworks.com> [cit. 15.12.2007]
- [22] NEUŽIL, T., *Simultaneous Mapping and Navigation for Skid Steered Mobile Robot*, Advanced Topics on Signal Processing, Robotics and Automation, WSEAS Press, 2008, ISBN 978-960-6766-442
- [23] NEUŽIL, T., JEŽ O., *Data processing for mapping in mobile robotics*, IETA 2007, Springer – Verlag, 2007, (Currently in press)
- [24] AVERBUCH, A., COIFMAN, R. R., DONOHO, D. L., ISRAELI, M., WALDÉN, J., *Fast Slant Stack: A notion of Radon Transform in a Cartesian Grid which*

is Rapidly Computible, Algebraically Exact, Geometrically Faithfull and Invertible,
<www.stat.stanford.edu/~donoho/Reports> [cit. 1.12.2007]

- [25] DISSANAYAKE, G. M. W. M., NEWMAN, P., CLARK, S., DURRANT-WHYTE, H. F., CSORBA, M., *A Solution to the Simultaneous Localisation and Map Building (SLAM) Problem*, IEEE transactions on Robotics and Automation, vol. 17, No. 3, 2001, <www.robots.ox.ac.uk/~pnewman> [cit. 15.12.2007]
- [26] RIKOSKI, R. J., LEONARD, J. J., NEWMAN, P. M., *Stochastic Mapping Frameworks*, Proceedings of the 2002 IEEE International Conference on Robotics and Automation, May 2002, pp. 426-433, <www.robots.ox.ac.uk/~pnewman> [cit. 1.1.2008]
- [27] CASTELLANOS, J., A., NEIRA, J., TARDÓS, J., D., *Limits to the Consistency of EKF Based SLAM*, IFAC Symposium on Intelligent Autonomous Vehicles, 2004, <web-diis.unizar.es/~jdtardos> [cit. 10.1.2008]
- [28] BAILEY, T., NIETO, J., GUIVANT, J., STEVENS, M., NEBOT, E., *Consistency of the EKF-SLAM Algorithm*, IEEE/RSJ, 2006, <www-personal.acfr.usyd.edu.au/tbailey> [cit. 10.1.2008]

Životopis autora

Jméno: Tomáš Neužil
Datum narození: 24.5.1977
Email: neuzil@feec.vutbr.cz

Dosažené vzdělání:

2000-2008 Fakulta elektrotechniky a komunikačních technologií VUT v Brně.
Doktorský studijní program - kybernetika a automatizace.
2000 Université Joseph Fourier, Grenoble, Francie. Diplomová práce: High resolution 3D ultrasonic position localisation system for three sensors simultaneously.
1995 – 2000 Fakulta elektrotechniky a informatiky, VUT v Brně.
1991 – 1995 Střední průmyslová škola elektrotechnická, Brno, obor automatizace.
Praxe:
2000 – 2008 Centrum aplikované kybernetiky - vývoj a výzkum v oblasti mobilní robotiky. Člen týmu, který získal první místo na Robotic Rescue Word Cup. Vývoj a výroba sensorických subsystémů pro mobilní roboty.

Vybrané publikace

NEUŽIL, T., *Simultaneous Mapping and Navigation for Skid Steered Mobile Robot*, Advanced Topics on Signal Processing, Robotics and Automation, WSEAS Press, 2008, ISBN 978-960-6766-442

NEUŽIL, T., *Simultaneous Mapping and Navigation for Skid Steered Mobile Robot*, WSEAS Applied Informatics & Communications, 2008, ISSN 1790-5117

NEUŽIL, T., JEŽ, O., *Data processing for mapping in mobile robotics*, IETA 2007

NEUŽIL, T., *Scanner data processing for mapping in mobile robotics*, Modern Trends in Control, 2006, ISBN 80-969224-6-7

NEUŽIL, T., *3D kamerový scanner*, AT&P journal PLUS 5 2004, ISSN 1336-5010

NEUŽIL, T., *Camera Based Laser Proximity Sensor*, ISBN 80-86059-41-3

NEUŽIL, T., *3D Camera Based Laser Proximity Sensor*, EEICT 2004, ISBN 80-214-2636-5

NEUŽIL, T., *CCD Camera Proximity Scanner*, The 6th International Scientific Conference, ISBN 80-7194-662-1

NEUŽIL, T., *CCD Laser Proximity Scanner*, RAAD 2004, , ISBN 80-7204-341-2

NEUŽIL, T., *Laser Proximity Scanner for Mobile Robotics*, DAAAM 2004, ISBN 3-901509-42-9

NEUŽIL, T., *Kamerový proximitní skener*, Radešín 2003, ISBN 80-214-2479-6

Abstrakt:

V práci je uveden rozbor průběžné lokalizace a mapování (SLAM) v oblasti mobilní robotiky. Na základě tohoto rozboru je navržen algoritmus využívající rozšířeného Kalmanova estimátoru stavu pro odhad polohy robotu. Je uveden popis matematického modelu robotu a snímače, který je využíván pro úlohu SLAM. Lokalizační metoda využívá informace o pracovním prostředí mobilního robotu, které jsou získávány pomocí laserového snímače. Orientační body pro určení odhadu stavového vektoru (polohy robotu) jsou z naměřených dat získány pomocí Radonovy transformace. Navržená metoda SLAM byla otestována na datech získaných pomocí mobilního robotu s podvozkem řízeným smykem. V závěru práce je uvedeno zhodnocení dosažených výsledků a možnosti rozšíření navržených algoritmů.

Abstract:

This work presents an overview of the simultaneous localisation and mapping (SLAM) problem in mobile robotics. Extended Kalman filter (EKF) based algorithm for localisation and mapping is proposed. For EKF algorithm the models of the skid steering mobile robot and the laser scanner are presented. The EKF algorithm is a feature based algorithm, therefore a method for landmark position determination was developed. This segmentation method is based on clustering of the Radon transform space. Proposed SLAM algorithm was tested with real data measured using UTAR mobile platform. Achievements of the work are summarized in the conclusion of the proposed work and possible improvements of the components are suggested.