

Diplomová práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra řídicí techniky

Relativní lokalizace duálního efektoru

Kateřina Kuglerová

Vedoucí: Ing. Karel Košnar, Ph.D.

Obor: Kybernetika a robotika

Studijní program: Kybernetika a robotika

Květen 2019

Poděkování

Děkuji vedoucímu práce Karlu Košnarovi za vstřícnost a podporu během celého projektu. Dále Viktorovi Kozákovi za technické tipy a diskuze. A naposled děkuji také své rodině a známým, kteří mě podpořili při mém studiu.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracovala samostatně, a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne 22. května 2019

podpis autora práce

Abstrakt

Cílem práce bylo navrhnout systém pro relativní lokalizaci duálního efektoru vůči uchopovanému objektu s využitím metod pro rekonstrukci povrchu objektu. Přehled známých metod zpracování a filtrování dat z ultrazvukových senzorů je doplněn o metody registrace množiny dat. Podrobněji se práce věnuje algoritmu ICP ("Iterative Closest Point") a jeho úpravám s cílem zlepšit robustnost algoritmu, dále také metodě RANSAC sloužící k detekci odlehlých a extrémních hodnot.

Klíčová slova: relativní lokalizace, sonar, systém senzorů, metoda nejmenších čtverců, filtrování, kalibrace

Vedoucí: Ing. Karel Košnar, Ph.D.

Abstract

The aim of the thesis was to design a system for relative localization of dual effector using method for object's surface reconstruction. An overview of well-known methods of processing and filtering sonar data at the beginning of the work is complemented by methods of point set registration. ICP ("Iterative Closest Point") algorithm and its variants for better robust results are presented in more details, as well as RANSAC method used for the detection of outliers and extreme data.

Keywords: relative localization, sonar, sensor system, least square fitting, filtering, calibration

Title translation: Relative localization of dual effector

Obsah

1 Úvod	1	3.4 Lokalizace	23
1.1 Definice úlohy	2	3.4.1 Lokalizace UOS	24
1.2 Související projekty	3	3.4.2 Lokalizace podstavce	28
1.2.1 Roboti určení pro manipulaci s těžkými předměty	5	4 Experimenty	33
2 Teoretický rozbor úlohy	7	4.1 Použité modely objektů a nastavení senzorů	33
2.1 Princip ultrazvukových senzorů ..	7	4.1.1 Vicon	33
2.2 Zpracování a filtrování dat	11	4.1.2 Umístění senzorů	34
2.3 Registrace množiny dat	14	4.2 Výsledky	34
2.3.1 ICP - Iterative Closest Point	15	5 Vyhodnocení	39
2.3.2 Rozšíření ICP algoritmu	16	6 Závěr	43
2.3.3 Další metody	17	A Literatura	45
3 Implementace	19	B Obsah CD	49
3.1 Senzor SICK UM12	19	C Zadání práce	51
3.1.1 Zapojení senzoru	19		
3.2 Kalibrace senzoru	20		
3.3 Zpracování dat	23		

Obrázky

1.1 Využití manipulátorů pro vykládání přepravních kontejnerů . .	2	3.1 Rozsah snímání senzoru SICK UM12-119 dle výrobce (1 - snímací rozsah senzoru v závislosti na reflexivních vlastnostech, velikosti a orientaci objektu; 2 - limit snímané oblasti u snadno detekovatelných překážek 4; 3 - pracovní oblast, pokud je detekována překážka 5, tyč o průměru 10 mm; [6]	20
1.2 Průřez modely těles a znázornění skenování jejich povrchu ultrazvukovými senzory	3	3.2 Zapojení senzoru SICK UM12 pro převod proudu na napětí 1 až 5 V	21
1.3 Roboti určené pro vyhledávání radioaktivního odpadu	5	3.3 Naměření dat pro kalibraci pomocí referenčního laserového dálkoměru	22
2.1 Analýza tvaru ultrazvukového signálu, [1]	9	3.4 Kalibrační data proložená přímkou	22
2.2 Detekce překážky ultrazvukovým senzorem, [2]	10	3.5 Vygenerovaný model kružnice o poloměru 1048 mm	24
2.3 Detekce rovné zdi a rohu ultrazvukovým senzorem, [2]	11	3.6 Kriteriaální funkce (Huber, Cauchy, Tukey), [7]	26
2.4 Vytvořená mapa okolí robota/mřížka obsazenosti na základě dat z ultrazvukového senzoru	12	3.7 Vygenerovaný model podstavce o šířce 1048 mm	29
2.5 Znázornění vlivu odlehlých hodnot na metodu polyblivého průměru, [3]	13	3.8 Znázornění vzdálenosti mezi naměřenými daty (červeně) a modelem (modře) ve směru os x (čárkovaně) a y (tečkovaně).	30
2.6 Vliv přítomnosti odlehlých, extrémních hodnot na algoritmus "loess", [4]	14	3.9 Znázornění vzdálenosti mezi těžištěm naměřených dat (červeně) a těžištěm modelu (modře).	31
2.7 Typy transformací: (a) identita, (b) euklidovská, (c) afinní, (d) non-rigid, [5]	15	3.10 Znázornění vzdálenosti mezi těžištěm naměřených dat (červeně) a těžištěm modelu (modře).	32

4.1 Umístění modelů objektů a senzoru	34
4.2 Naměřená data reprezentující povrch UOS	35
4.3 Naměřená data (červeně), data bez odlehlých hodnot (zeleně) a aproximace kruhu z vyfiltrovaných dat (modře)	35
4.4 Kruh nalezený algoritmem RANSAC (modře) a metodou nejmenších čtverců (oranžově)	36
4.5 Naměřená data reprezentující povrch podstavce a počáteční odhad t_0 posunu mezi daty (červeně) a modelem (zeleně)	37
4.6 Lokalizace podstavce (černě) s naměřenými daty (červeně) a počátečním odhadem (zeleně)	37
4.7 Lokalizace kruhů (modře) z vybraných dat (zeleně) se všemi naměřenými daty (červeně)	38
4.8 Lokalizace modelu podstavce (černě) z vybraných dat obsahujících méně odlehlých hodnot (červeně) .	38

Tabulky

3.1 Naměřená data použitá pro kalibraci zapojení senzoru	21
5.1 Průměr vypočtených hodnot a směrodatné odchyly $[mm]$	40
5.2 Střední hodnoty vypočtených parametrů a směrodatné odchyly s počátečním odhadem t_0 získaným z těžišť množin bodů $[mm]$	40
5.3 Střední hodnoty vypočtených parametrů a směrodatné odchyly s počátečním odhadem t_0 získaným z analýzy maximálních a minimálních hodnot $[mm]$	40
5.4 Střední hodnoty vypočtených parametrů a směrodatné odchyly po vyřazení odlehlých hodnot metodou RANSAC $[mm]$	41
5.5 Nalezené parametry kruhových výřezů v podstavci $[mm]$	41

Kapitola 1

Úvod

Mezi různými typy úloh robotiky existuje početná skupina, která se zabývá lokalizací a úchopem objektů. S rozvojem automatizace průmyslových linek se rozvíjí i způsoby řešení těchto problémů, ať už s použitím automatizovaných linek bez přítomnosti lidských pracovníků nebo kolaborativních robotů, které jsou schopny pracovat s lidmi. Mezi hlavní důvody toho, že jsou roboty stále více využívané, patří menší náklady na provoz, možnost naprogramování robotu pro opakující se činnost a schopnost manipulace s nebezpečnými nebo těžkými objekty. V současné době, kdy se klade stále větší důraz na přání zákazníka, se navíc přizpůsobují i automatické systémy tak, aby byly schopny vykonávat více činností například na základě stavu svého okolí nebo podle druhu součástek v kontejneru ve výrobní lince.

V projektu [8] je použit manipulátor k vybírání 2 různých typů součástek z kontejneru pomocí systému kamer. Autoři článku předpokládají, že kontejner není umístěn vždy na stejném místě vzhledem k manipulátoru. Proto používají systém kamer (RGB-D) umístěn vně robotu k lokalizaci kontejneru a jednu kameru umístěnou na manipulátoru k detekci a lokalizaci součástek. Zmiňují ve své práci i další podobné projekty, které sice předpokládají pevně umístěný kontejner, ale všechny tyto projekty pracují se systémem kamer. Projekt [9] také využívá RGB-D kamery k lokalizaci objektů, je však více zaměřený na komerční sféru. Jeho cílem je představit systém, který v kontejneru vyhledá objekty z předem dané databáze, určí jejich pozici, natočení a poté je vhodně uchopí a vyloží z kontejneru.



(a) : Manipulátor projektu [8]

(b) : Manipulátor projektu [9]

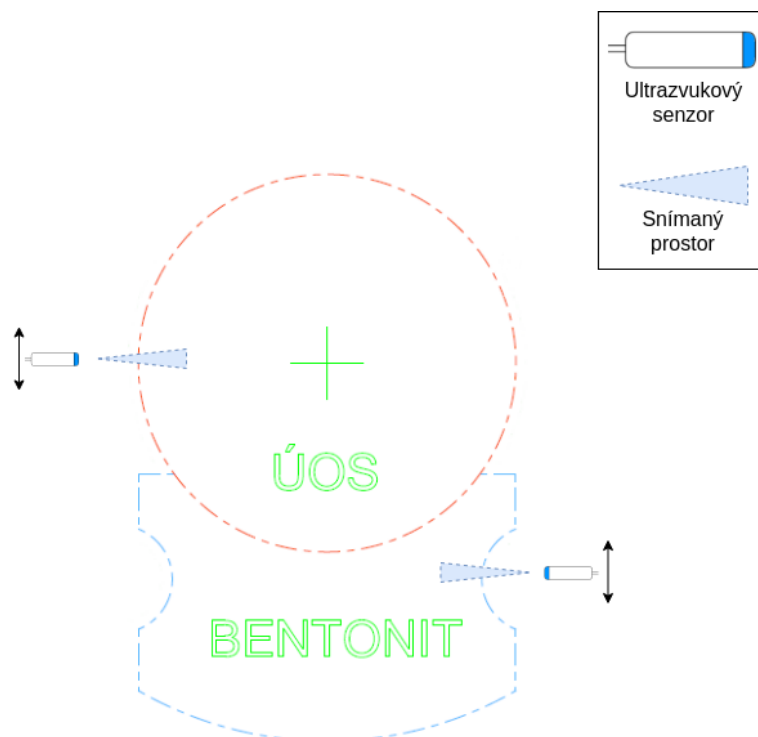
Obrázek 1.1: Využití manipulátorů pro vykládání přepravních kontejnerů

Během manipulace s nebezpečnými, velkými a těžkými objekty se však stále používají manipulátory řízené lidmi. Semi-autonomní a na dálku řízené systémy se také používají v prostředích, které jsou člověku nebezpečné. Tým z Nigérie [10] vyvinul manipulátor připevněný k robotickému vozítku, které je ovládané na dálku lidským operátorem a jeho cílem je vyhledávat a zneškodňovat nevybuchlé bomby a nálože pokládáné na severu země kvůli vzpouře Boko Haram. Na manipulátoru je kvůli tomu účelu připevněna kamera přenášející záznam na bezpečné místo s operátorem. Další projekty ([11], [12]) využívají malé roboty pro průzkum potrubí. Pomocí sonarových a laserových senzorů skenují stěny potrubí a hledají různé praskliny a deformace materiálu, které by mohly vyústit v havárii. Oba tyto roboty jsou ovládané vzdáleně a jsou limitovány dosahem kabelu, kterým jsou spojeny s operátorem.

1.1 Definice úlohy

V diplomové práci se předpokládá manipulace s objektem ve tvaru válce o předem daném průměru, který představuje kontejner na radioaktivní odpad. Válec je umístěn na podstavci přizpůsobeném pro stabilní usazení válcového kontejneru. Tyto dva objekty jsou zachyceny na následujícím obrázku 1.2.

Vzorová situace použití duálního efektoru může vypadat následovně. K duálnímu efektoru je dopraven kontejner na podstavci a s pomocí manipulátoru je kontejner přesunut na přistavený přívěs. Efektor je navržen tak, aby byl schopen chytit a zdvihnout válcový kontejner, podstavec (pokud se na něm kontejner nenachází) nebo oba tyto objekty najednou.



Obrázek 1.2: Průřez modely těles a znázornění skenování jejich povrchu ultrazvukovými senzory

Cílem úlohy je proto navrhnout systém sonarových senzorů, který by umožnil lokalizovat duální efektor vzhledem k požadovanému objektu, aby jej bylo možné přesně navést k objektu a správně ho uchopit.

1.2 Související projekty


V radioaktivním prostředí lidé používali roboty již v 60. letech 20. století ([13]). Bylo to dáno přirozenou obavou o zdraví pracovníků, o to víc, když došlo k haváriím v americkém komplexu Three Mile Island (1979), v Černobylu (1986) a ve Fukušimě (2011). V souvislosti s efektivnějším a šetrnějším ukládáním radioaktivního odpadu se rozvíjí projekty na podporu robotů, ať už autonomních nebo dálkově ovládaných, které by byly schopny významně pomáhat při odklizení odpadu nehledě na přítomnou radioaktivitu.

Evropská unie začala v roce 2015 s pětiletou podporou projektu RoMaNS (Robotic Manipulation for Nuclear Sort and Segregation, [14]), který má vyvíjet samostatné a částečně autonomní systémy. Ty by přetřídily nebezpečný odpad podle stupně radioaktivity tak, aby se využily kontejnery s vyšší ochranou proti radioaktivitě na potřebný odpad a méně nebezpečný odpad by se přesunul na jiná úložiště.


Dalšího projektu ([15]), který se v letech 2016-2018 zabýval manipulací radioaktivního odpadu a rozebíráním ozářených objektů, se zúčastnilo 5 evropských institucí s podporou EU. Tým z českých, řeckých, italských a anglických vědců rozšířil projekt dvojramenného manipulátoru ([16]) určeného ke skládání prádla na vyhledávání ozářených předmětů a jejich úchop, přestože robot tyto věci nikdy předtím nespátřil.

Není náhodou, že se Spojené Království účastní výzkumných projektů souvisejících s radioaktivním odpadem. Na pobřeží západní Anglie bylo založeno během Druhé světové války středisko Sellafield pro jaderný výzkum, poté tam byla přistavěna jaderná elektrárna a další objekty zpracovávající jaderné palivo nebo jeho odpad. V roce 1957 vznikl požár v části Windscale Pile, který uvolnil radioaktivní materiál. Ten se sice díky novým filtrům z 95 % nerozšířil, ale celý blok byl v důsledku toho odstaven. V devadesátých letech se začaly rozvíjet plány na odstranění následků, ale čeká se, že to potrvá ještě aspoň 20 let. Mimo to se tam nachází skladovací nádrže a sila, z nichž některá (např. Pile Fuel Cladding Silo z roku 1952 nebo First Generation Magnox Storage Pond z roku 1960) musejí být kompletně rozebrána a odpad bude následně přemístěn do nově vybudovaných skladišť s modernějšími ochranami proti radioaktivitě.

Vzhledem k tomu, že směny lidských pracovníků se musejí střídat v prostoru po krátkých intervalech a jejich zaučení trvá dlouho, vzniklo na podporu vývoje autonomní techniky schopné likvidace jaderného odpadu společné sdružení britských univerzit (National Centre for Nuclear Robotics). Na vývoji robotů se podílí také firma Forth, která nyní pracuje s prototypem robotu schopného detekce odpadu a manipulace s ním ([17]). Robot je vybaven robotickým ramenem, pomocí kterého bude dle předpokladu později shromažďovat odpad do kontejnerů. Firma Qinetiq vyvinula autonomní robotickou jednotku, která je vybavena sonarovými a hmatovými senzory a je schopna nalézt na dně skladovacích nádrží v bahně zdroje radioaktivity ([18]).



(a) : Robot z projektu [18]



(b) : Robot z projektu [17]

Obrázek 1.3: Roboti určené pro vyhledávání radioaktivního odpadu

1.2.1 Roboti určené pro manipulaci s těžkými předměty

Kromě malých průzkumných robotů a robotických manipulátorů v automatických výrobních linkách se používají i velké manipulátory pro manipulaci a přenos velkých (a dost často i těžkých) objektů. Firmy vyrábějící manipulátory (např. ABB, Kuka, Fanuc) na svých webových stránkách uvádějí vedle dostupných typů robotů i příklad jejich využití z praxe. V případě největších dostupných manipulátorů se jedná například o paletizaci sudů [19] a přenášení bloků válců motoru [20]. Firma Kuka je zapojena i do projektu National Nuclear Laboratory pro odstraňování radioaktivního odpadu z oblasti Sellafield, kde už proběhly první zkoušky s roboty v roce 2014, nicméně nešlo o plně autonomní systémy - na každý manipulátor dohlížel tým složený z operátorů [21].

Následující kapitola obsahuje teoretický rozbor úlohy, zabývá se vlastnostmi použitých sonarových senzorů. Dále se věnuje zpracování a filtraci dat. Poslední část druhé kapitoly je věnována registraci množiny dat, rozpoznávání známého objektu v naměřených datech.

V třetí kapitole se věnují již použitému ultrazvukovému senzoru a jeho kalibraci, dále konkrétní implementaci navržených metod filtrace a lokalizace objektů. V navazující kapitole jsou implementace doloženy experimenty s reálnými daty a senzory. Vyhodnocení experimentů se nachází v páté kapitole, celá práce je shrnuta v poslední šesté kapitole.

Kapitola 2

Teoretický rozbor úlohy

V rámci úlohy je definované použití sonarových senzorů. Tyto senzory jsou v poměru k jiným finančně dostupnější a zpracování jimi pořízených dat je výpočetně méně náročné, proto se používají v hojné míře nejen v námořních oblastech, ale také při automatizaci průmyslových linek, navigaci robotů, detekci překážek a vytváření map ([22]). Oproti kamerám mají navíc výhodu při detekci průhledných a průsvitných překážek, také nejsou limitovány přítomností prachu a podobných nečistot.

2.1 Princip ultrazvukových senzorů

Ultrazvukové senzory se v základu dělí na pasivní a aktivní. Pasivní senzory obsahují pouze přijímač, který registruje příchozí zvukové vlny a sám žádné signály nevydává. Toho se s výhodou využívá ve vojenských aplikacích. Zároveň je to i nevýhoda senzoru, protože pomocí samotného senzoru není možné určit vzdálenost ani směr, odkud signál přichází. Proto se pasivní senzory využívají ve skupinách a pozice zdroje signálu se dopočítává trilaterací.

Aktivní ultrazvukový senzor se skládá z vysílače a přijímače. Vysílač produkuje krátký ultrazvukový puls, který se jako vlna šíří podélně ve směru osy vysílače. V případě, že vlna narazí na překážku, odrazí se. V závislosti na reflexivních vlastnostech materiálu a úhlu, pod kterým vlna dopadla na překážku, se nějaká její část odrazí zpět. Přijímač detekuje odraženou vlnu

a vyhodnotí detekci překážky. Přijímače ultrazvukových senzorů mohou být různých typů - pravděpodobně nejjednodušší je přijímač, který má nastavenou hraniční hodnotu intenzity signálu a když přijde první signál s větší intenzitou než je nastavená hranice, všechny ostatní příchozí signály přijímač ignoruje a vyhodnotí vzdálenost k překážce dle času šíření vlny.

Vzdálenost senzoru od překážky je dána dobou, jakou se šířila zvuková vlna k překážce a zpět. Rychlost šíření zvukové vlny závisí na vlastnostech prostředí, ve kterém se zvuková vlna pohybuje. Rychlost zvuku (v ideálním plynu) je dána vztahem

$$c = \sqrt{\gamma \frac{p}{\rho}} = \sqrt{\frac{\gamma RT}{M}} = \sqrt{\frac{\gamma RT_0}{M} \left(1 + \frac{t}{T_0}\right)}, \quad (2.1)$$

kde ρ je hustota, p tlak, T absolutní teplota, T_0 absolutní teplota při 0 stupních Celsia, t teplota ve stupních Celsia, γ Poissonova konstanta, M molární hmotnost plynu a R konstanta plynu [23]. Dosazením konstant pro vzduch lze získat přibližný vztah, kde je jedinou proměnnou pouze teplota vzduchu

$$c_{vzduch} = 331.3 \sqrt{1 + \frac{t}{273.16}}. \quad (2.2)$$


Pomocí tohoto vztahu nebo jeho obdoby a znalosti délky letu t_F odražené vlny se spočítá vzdálenost mezi senzorem a překážkou dle vztahu

$$d = c_{vzduch} \frac{t_F}{2}. \quad (2.3)$$


Nejjednodušším způsobem, jak určit dobu šíření signálu t_F k překážce a zpět pomocí ultrazvukového senzoru, je nastavení hranice detekce signálu τ . Pokud je hodnota přijatého signálu menší než daná hodnota τ , je signál ignorován jako šum. V opačném případě se t_F stanoví jako doba mezi vysláním signálu a časem, kdy byl signál detekován (hodnota signálu byla vyšší než τ). Dalším způsobem, jak změřit dobu šíření signálu t_F , může být analýza přijaté vlny. Barshan a Kuc ([1]) představili metodu, kde využili mikrofon s piezoelektrickým měničem. Měníč je pro vyslání signálu vybuzen šesti cykly čtvercového signálu o frekvenci $f = 40$ kHz a amplitudě 30 V. Amplituda tlaku šířeného signálu je potom definována jako

$$p(r, \theta) \cong \frac{p_0 r_0}{r} e^{-\frac{\theta^2}{2\sigma_T^2}}, r > r_0, \quad (2.4)$$

kde r je radiální vzdálenost od vysílače. θ úhel, p_0 amplituda tlaku šířené vlny ve vzdálenosti r_0 ve směru osy ($\theta = 0^\circ$) a σ_T představuje otevření senzoru. Typický signál vyslaný v čase $t = 0$, poté odražený od překážky a



(a) : Typický tvar zachyceného ultrazvukového signálu



(b) : Proložení první náběžné hrany signálu parabolou

Obrázek 2.1: Analýza tvaru ultrazvukového signálu, [1]

detekovaný senzorem je zobrazen na obrázku 2.1a. Náběžná hrana obálky signálu (čárkovaně) je popsána vztahem

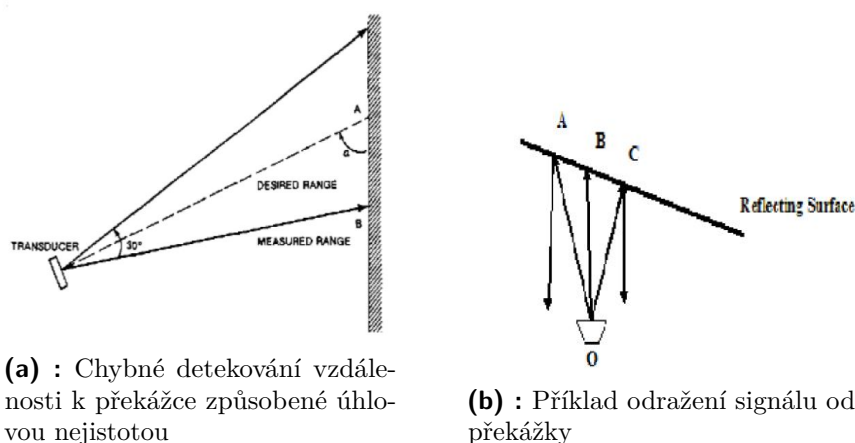
$$x(t - t_F) = a_0 e^{-a_1(t-t_F)}(t - t_F)^2 u(t - t_F), \quad (2.5)$$

kde t_F značí počátek detekovaného signálu, $u(t - t_F)$ jednotkový skok zpožděný o t_F a a_0, a_1 jsou parametry signálu (tvar a amplituda signálu). Tento model obálky je pak použit k proložení dat parabolou $s(t)$ (na obrázku 2.1b)

$$s(t) \cong a_0(t - t_F)^2 + n(t), t \in [t_F, t_F + \frac{1}{2a_1}], \quad (2.6)$$

$n(t)$ reprezentuje šum signálu. Pro minimalizaci odchylek mezi naměřenými daty a modelem autoři využívají gradientní metodu, pomocí které je určena doba šíření signálu a vzdálenost mezi senzorem a překážkou. Autoři v článku dále rozvíjí metodu lokace překážky na základě systému jednoho vysílače a dvou přijímačů, který je inspirovaný navigačním systémem netopýrů.

Měření vzdálenosti senzoru od překážky však závisí ještě na tvaru a materiálu překážky. V případě, že je překážka z měkkého materiálu nebo takového, od kterého se vlna nemůže s dostatečnou intenzitou odrazit, nemusí přijímač signál (a překážku) vůbec detekovat - senzor přime signál s malou intenzitou a vyhodnotí ho jako šum. Podobný případ může nastat, pokud vyslaný signál dopadá na překážku tak, že se odrazí jiným směrem, než kde se nachází přijímač, tzn. vyslaná vlna dopadá na překážku pod jiným než kolmým úhlem. Pokud se naopak v okolí senzoru nachází překážek více, může se vyslaná vlna odrazit v různých místech a přijímač pak zachytí několik různých signálů a



(a) : Chybné detekování vzdálenosti k překážce způsobené úhlovou nejistotou

(b) : Příklad odražení signálu od překážky

Obrázek 2.2: Detekce překážky ultrazvukovým senzorem, [2]

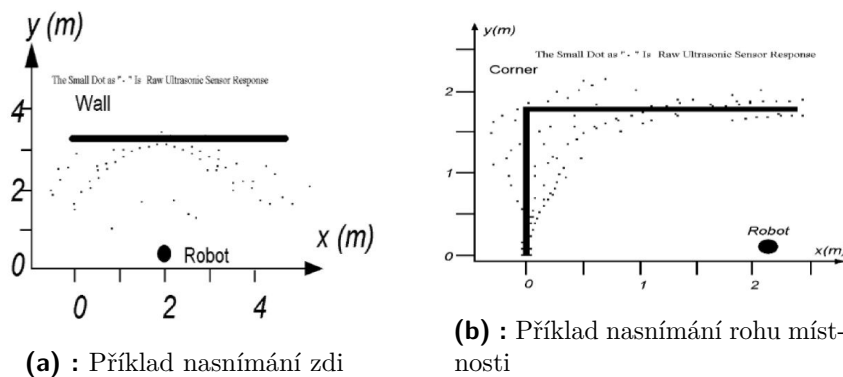
vyvodit z toho mylnou vzdálenost. V závislosti na naprogramování senzoru například zachytí pouze ten první signál a všechny další ignoruje až do doby, kdy vygeneruje vysílač další vlnu. Pak může nastat také situace, kdy senzor vyšle první vlnu, zachytí odražený signál, poté vyšle druhou vlnu, ale zde zachytí odražený signál vygenerovaný stále ještě první vlnou.

Vzhledem k tomu, že vyslaný signál se šíří prostředím v podobě vlny, vzniká okolo osy senzoru kuželovitá oblast otevření senzoru (tzv. "opening" senzoru), ve které je možné detekovat překážky. Oblast, ve které se pohybuje signál s vysokou intenzitou, se nazývá hlavní lalok ("main lobe"). V jejím okolí je možné odražený signál také zachytit, ale již s menší intenzitou, takové oblasti se nazývají vedlejší laloky. U jednoduchého senzoru s jedním přijímačem pak není možné jednoznačně určit, z jakého místa na průřezu kuželu ve zjištěné vzdálenosti se překážka nachází - takovému jevu se říká úhlová nejistota [2]. Situace, kdy vznikají chybné detekce vzdálenosti mezi senzorem a překážkou, jsou zachyceny na obrázku 2.2.

Existuje více typů modelu ultrazvukového senzoru, kde se každý model liší podle toho, jak (a jestli) se snaží minimalizovat chyby a nejistoty způsobené konstrukcí a principy fungování ultrazvukového senzoru. V nejjednodušším modelu senzoru [24] se předpokládá, že detekovaná překážka se nachází přímo před senzorem a detekovaná vzdálenost je měřena v ose vysílání senzoru. Takový model přirozeně určí chybné vzdálenosti od překážek nacházejících se mimo osu senzoru nebo nakloněných tak, že se vyslaný signál odrazí jinam než do přijímače senzoru. Autoři článku [25] předpokládali nezávislost úhlové a osově složky měření a namodelovali obě dvě složky měření s normálním a rovnoměrným rozdělením pro vytváření mřížky obsazenosti.


2.2 Zpracování a filtrování dat

Naměřená data z ultrazvukového senzoru mívají hlavní společné rysy. Především, kvůli principu fungování senzoru a situacím popsaných v předešlé části, obsahují šum. Ten vzniká příjmem signálu odražených vln od různých překážek nebo od překážek, které nejsou kolmé na směr šíření vlny. Na obrázku 2.3a je zachycena situace, kdy je robot umístěn na jednom místě před zdí, otáčí se a ultrazvukovým senzorem měří vzdálenost ke zdi. Z naměřených dat v obrázku je patrné, že jako vzdálenost mezi senzorem a robotem v každém bodě natočení robotu je vyhodnocena vždy ta nejkratší vzdálenost detekovaná v hlavním laloku senzoru. Pokud by se z takto získaných dat namodelovala překážka, měla by tvar oblouku místo rovné zdi. Podobná situace je znázorněna na obrázku 2.3b, který zobrazuje nasnímání rohu místnosti robotem stojícím na jednom místě.



Obrázek 2.3: Detekce rovné zdi a rohu ultrazvukovým senzorem, [2]

Sonarové senzory jsou pravděpodobně nejznámější pro své využití při skenování dna vodních nádrží a moří, uplatňují se však i v robotice. V této oblasti se ultrazvukové senzory používají převážně při mapování okolí robota a vyhýbání se překážkám. Pro svoji nepřesnost a nejistotu detekování překážek se současně s ultrazvukovými senzory nejčastěji využívá při vytváření mapy okolí robota mřížka obsazenosti. Každá buňka mřížky obsahuje hodnotu (nebo hodnoty), která reprezentuje obsazenost/volnost prostoru, který buňka představuje. Nejčastější přístup vytváření mřížky obsazenosti je pravděpodobnostní přístup. Pokud uvažujeme buňku m_{ij} , pak pravděpodobnost $p(m_{ij})$ značí pravděpodobnost obsazenosti uvažované buňky. Použití Bayesova filtru poté umožňuje pro každou novou množinu naměřených hodnot aktualizovat dosavadní pravděpodobnosti obsazenosti buněk. Pomocí opakovaných měření se pak šance na správné rozpoznání překážky zvětšují a naopak šance na mylnou detekci klesají.



(a) : [26]

(b) : [27]

Obrázek 2.4: Vytvořená mapa okolí robota/mřížka obsazenosti na základě dat z ultrazvukového senzoru


Na obrázcích 2.4 z vytváření mapy pomocí mřížky obsazenosti lze vidět, jak data obsahují šum. Po převedení analogových dat na digitální se tedy data z ultrazvukových senzorů nejprve zpracovávají. První krok při zpracování sonarových dat může být odstranění maximálních a minimálních hodnot, které se v měření objevují, pokud přijímač nezachytí žádný odražený signál nebo respektive pokud zachytí odražený signál ze vzdálenosti bližší, než dovoluje konstrukce a fyzikální vlastnosti senzoru. Dalším krokem bývají filtry (např. FIR nebo IIR filtry) a vyhlazování, které mají odstranit nežádoucí aspekty zachyceného signálu, především šum, nebo zvýraznit vlastnosti známého signálu jako je například frekvence. Ideální překážky by měly hladké a rovné povrchy, které by odrážely 2 po sobě jdoucí signály se stejnou intenzitou a stejným úhlem. To však s reálnými překážkami s členitým povrchem není možné, a proto se i 2 po sobě jdoucí signály mohou lišit ve vypočtené vzdálenosti mezi senzorem a překážkou. Díky velkému množství měření tak vznikají členité průběhy skenovaného povrchu, které ovšem lze vyhladit pomocí určitých metod, získat tak hladký sken povrchu překážky a vyzdvihnout hlavní rysy získaných dat. Také lze pomocí vyhlazení zmenšit objem dat i při zachování jejich klíčových vlastností a trendů.

Jedním z nejpoužívanějších a nejjednodušších algoritmů pro vyhlazování je metoda pohyblivého průměru (jednoduchá, nevážená). Při ní se každý výsledný bod x_{si} spočítá jako průměr n bodů před a za bodem x_i z původního setu dat:

$$x_{si} = \frac{1}{2n + 1} (x_{i-n} + \dots x_{i-1} + x_i + x_{i+1} + \dots x_{i+n}) \quad (2.7)$$


Tato metoda odstraňuje z dat malé místní (vysokofrekvenční) odchylky a tím spadá pod filtry dolní propusti. Nevýhodou této metody je, že neeliminuje

odlehle hodnoty (outliers) a jejich výrazně jiná hodnota pak velmi ovlivňuje výsledná vyhlazená data, viz 2.5.



Obrázek 2.5: Znázornění vlivu odlehle hodnot na metodu pohyblivého průměru, [3]

Další metodou je lokální polynomiální regrese, neboli "loess, lowess" (= locally (weighted) estimated scatterplot smoothing, [4]). Tato metoda zobecňuje metodu pohyblivého průměru a kombinuje ji s polynomiální regresí - proložením dat polynomem daného nebo libovolného stupně. Při prokládání dat polynomem se hledají metodou nejmenších čtverců takové parametry polynomu určitého stupně, aby součet druhých mocnin odchylek dat od polynomu byl co nejmenší. Naměřená data jsou rozdělena na menší úseky a v každém se algoritmus snaží najít polynom daného řádu metodou nejmenších čtverců. Pokud je při prokládání dat použit polynom nultého stupně, stává se z algoritmu již dříve popsaná metoda pohyblivého průměru. Podobně jako jiné postupy vyhlazování, které využívají metody nejmenších čtverců, je metoda lokální regrese bez dalšího ošetření náchylná na chyby vzniklé přítomností odlehle hodnot (2.6). Metoda lokální regrese je podrobně rozebrána v článku [28], kde se autoři věnují jednak základnímu algoritmu, dále ale zkoumají i různé možnosti obměny algoritmu. Uvádí, že adaptivní prokládání dat polynomy různého řádu a adaptivní šířka okolí bodu, ve kterém se prokládají data polynomem, mohou výrazně napomoci v případě dat s radikálními změnami průběhu dat.




Obrázek 2.6: Vliv přítomnosti odlehlých, extrémních hodnot na algoritmus "loess", [4]

Nevýhodu velkého vlivu odlehlých hodnot odstraňuje také Kolmogorovův-Zurbenkův filtr ([29]), který rozšiřuje metodu pohyblivého průměru o počet iterací, kolikrát se metoda pohyblivého průměru opakuje. Filtr je pokládán za robustní a téměř optimální. Vzhledem k tomu, že jeho základem je výpočetně jednoduchá a nenáročná metoda, je takový i filtr s rozšířením o opakování.

2.3 Registrace množiny dat

Registrace množiny dat ("Point set registration, point matching") je proces, pomocí kterého lze zjistit vzájemný vztah dvou množin bodů. Tento proces se využívá v počítačovém vidění a rozpoznávání objektů, ať už ve 2D nebo 3D prostoru. Aplikováním získaného vztahu mezi množinami dat je možné data sloučit, získat informace o jejich poloze nebo rekonstruovat povrch objektu pomocí známého modelu. Také se registrace množiny dat využívá ve zdravotnictví, kdy se přiřazují data a části obrazů lebky získané z magnetické rezonance k obrazu celé lebky.

Registrace množiny dat se dělí na 2 typy, při prvním ("rigid", Euklidovská transformace) se v každém páru bodů z jednoho a druhého setu zachovává vzdálenost a výsledkem procesu je pouze rotace a posun. V druhém typu se vzdálenost mezi korespondujícími body nemusí zachovávat a kromě rotace a posunu jsou dalšími výstupy registrace množiny dat i afinní transformace jako je škálování. V případě registrace množiny dat s Euklidovskou transformací se tedy jedná o jednodušší problém pouze s neznámou rotací a posunem (3 neznámé x, y, θ pro 2D systém, 6 neznámých $x, y, z, \varphi, \theta, \phi$ pro 3D systém).



Obrázek 2.7: Typy transformací: (a) identita, (b) euklidovská, (c) afinní, (d) non-rigid, [5]

Hledání parametrů afinních transformací je oproti tomu složitější, nicméně má i širší a zajímavější použití - od rozpoznávání ručně psaných znaků přes mapování 3D objektů z různých úhlů až po již zmíněnou registraci lékařských skenů. Rozdíl mezi typy transformací je patrný z obrázku 2.7.

Vzhledem k tomu, že využití registrace množiny dat je rozsáhlé a problém přiřazování dat k modelu se vyskytuje více jak 30 let, vznikly za tu dobu různé algoritmy a metody. Všechny mají své výhody a nevýhody podle toho, jaký byl jejich zamýšlený účel a použití. Některé algoritmy jsou například jednoduché na pochopení a nenáročné na výpočet, zato však jsou nepřesné v případě výskytu šumu nebo odlehlých hodnot. Naopak složité algoritmy, které jsou robustní a imunní k šumu, mívají znatelně větší výpočetní náročnost.

2.3.1 ICP - Iterative Closest Point

Pravděpodobně jeden z nejpoužívanějších algoritmů pro registraci množiny dat byl představen na začátku 90. let minulého století ([30]). Předpoklad, ze kterého algoritmus získal název, říká, že pár korespondujících bodů ve dvou množinách dat je u sebe nejbližší a podle toho také tvoří páry. Pro dvě množiny dat se poté algoritmus metodou nejmenších čtverců snaží najít takovou transformaci, aby se vzdálenost mezi body v párech minimalizovala. Postup algoritmu je následující (vstup algoritmu jsou body modelu M a body X , výstupy jsou transformace R a t):

- Pro každý bod z množiny bodů X se nalezne nejbližší bod z množiny bodů M .
- Pomocí metody nejmenších čtverců se určí taková rotační matice R a vektor posunu t , aby vzdálenost mezi body v páru určeném v předchozím kroku byla minimální.

- Získaná transformace složená z rotační matice R a vektoru posunu t se aplikuje na množinu bodů X .
- S novou množinou se celý postup opakuje, dokud není dosaženo maximálního počtu kroků nebo dokud není součet odchylek mezi body v páru dostatečně malý.

Výhodou algoritmu ICP je, že nepotřebuje žádné body se zvláštními vlastnostmi, podle kterých by se hledaly mezi dvěma sety odpovídající dvojice bodů. Zároveň je to velká nevýhoda algoritmu, protože spoléhá na přesný odhad výchozího stavu a v případě, že není takový odhad k dispozici, může algoritmus selhat. To znamená, že algoritmus ICP sice najde lokální minimum, ovšem nemusí být schopný najít minimum globální a nalezené minimum se může od optimálního řešení lišit.

Kromě těchto nevýhod existují i další, a proto se v minulosti objevily různé úpravy ICP algoritmu za účelem jeho zlepšení. Autoři článku [31] se zaměřili na shrnutí dosavadních výzkumů v oblastech, ve kterých by mohlo dojít k posunu ICP algoritmu - vybírání a filtrování důležitých, užitečných bodů, určení ideálního okolí bodu pro vyhledávání globálních tendencí, spojování relevantních korespondujících bodů, váhování nalezených dvojic a odstraňování nesmyslných dat v podobě odlehlých, extrémních hodnot.

■ 2.3.2 Rozšíření ICP algoritmu

EM-ICP ([32]) obohacuje ICP algoritmus o princip maximalizace-očekávání (expectation-maximization). Tato metoda předpokládá, že neznámé parametry (v případě registrace setu dat je to transformace mezi nimi) závisí ještě na nepozorovatelných proměnných. V každé iteraci algoritmu se nejprve provede fáze E, která vytvoří funkci předvídání věrohodnosti a dosadí do ní současné odhady parametrů. Poté následuje fáze M, která spočítá parametry maximalizací očekávané věrohodnosti nalezené v předchozí fázi. Tyto parametry jsou pak v dalším cyklu opět použité ve fázi E.

Zatímco algoritmus ICP minimalizuje rozdíl mezi oběma množinami dat ve dvou krocích (hledání nejbližších korespondujících bodů a transformace minimalizující vzdálenost mezi nimi), článek [33] představil robustnější postup, ve kterém se minimalizuje rozdíl mezi modelem a druhou množinou dat pomocí

nelineární minimalizace Levenberg-Marquardtova algoritmu. Skutečně má dle závěru článku LM-ICP algoritmus s méně přesným počátečním odhadem lepší výsledky než ICP.

■ 2.3.3 Další metody

KC (Kernel Correlation) algoritmus rozšiřuje techniky korelace. V základním algoritmu ICP se dvojice korespondujících bodů tvoří z bodů, které mají mezi sebou nejmenší Euklidovskou vzdálenost. V tomto případě se ale každý bod z jednoho setu spojí s každým bodem z druhého setu, proto bývá tento algoritmus označován také jako vícenásobně-propojený (multiple-linked) ICP algoritmus. Pomocí zvolené jádrové funkce (kernel function) se stanoví pravděpodobnostní funkce, hustoty pravděpodobnosti a kritériální funkce ceny, která se posléze optimalizuje gradientní metodou. Tsing a Kanade [34] zdůraznili závislost dobrého výsledku algoritmu na vhodně zvolené jádrové funkci. Tato metoda dosahuje oproti ICP lepších výsledků se zašuměnými daty, opět ale může být ovlivněna nežádoucími body.

GMM (Gaussian Mixture Models) metoda využívá toho, že v KC algoritmu lze nahradit součet Gaussiánů ve výpočtu jádrových odhadů hustot právě pomocí GMM. Pro obě množiny dat se získají GMM a rozdíl mezi nimi se minimalizuje. Dle [35] se tato metoda používá hlavně ze 3 důvodů - reálné problémy mohou být často popsány pomocí kombinace Gaussiánů, metoda sama je jednoduchá na pochopení a implementaci a v malých dimenzích je výpočetně efektivní.

Kapitola 3

Implementace

3.1 Senzor SICK UM12

Pro zadanou úlohu byly použity ultrazvukové senzory SICK UM12-119 [6]. Tyto senzory fungují na principu první přijaté vlny, vzdálenost k překážce je pak vypočtena pomocí doby od vyslání vlny po zachycení signálu ze vzorce uvedeném v minulé kapitole. Výstupem senzoru je tedy pouze 1 hodnota, a to v rozmezí od 4 do 20 mA v závislosti na vzdálenosti mezi senzorem a detekovanou překážkou. Později přijaté vlny a odrazy senzor ignoruje až do vyslání další vlny vysílačem.

Uváděný rozsah měření vzdálenosti senzoru je dle výrobce 40 až 240 mm, s limitem až do 350 mm v ideálních podmínkách (např. dokonale odrážející povrch překážek). Osa, podél které se šíří vyslaný signál, je shodná s osou senzoru. Senzor UM12 pracuje typicky na frekvenci 500 kHz s udávaným rozlišením $\pm 1\%$ a zabudovanou teplotní kompenzací.


Rozsah snímání senzoru je znázorněn na obrázku 3.1.

3.1.1 Zapojení senzoru

Při práci bylo využito již hotové zapojení senzoru. Senzor je napájený 24 V a jeho výstup je přiveden na odpor o velikosti 250 Ω tak, aby bylo možné měřit výsledné napětí v rozmezí přibližně 1 až 5 V. Zapojení je k dispozici na obrázku 3.2.

UM12-119

Detection area in mm (inch)

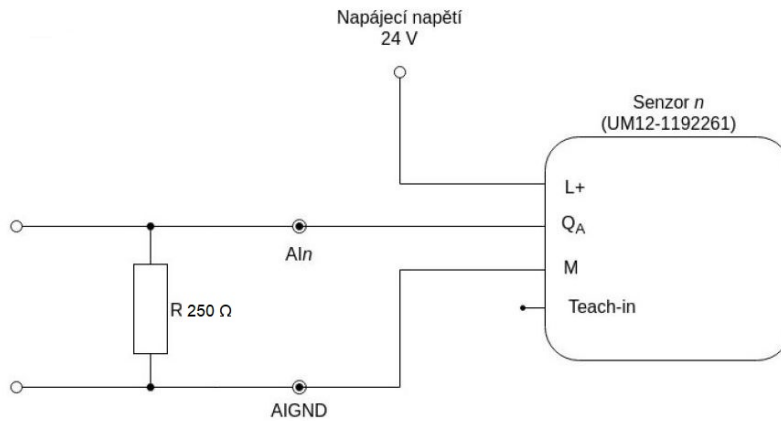


Obrázek 3.1: Rozsah snímání senzoru SICK UM12-119 dle výrobce (1 - snímací rozsah senzoru v závislosti na reflexivních vlastnostech, velikosti a orientaci objektu; 2 - limit snímané oblasti u snadno detekovatelných překážek 4; 3 - pracovní oblast, pokud je detekována překážka 5, tyč o průměru 10 mm; [6])

Při použití takového zapojení potom odpovídá 1 V vzdálenosti 40 mm mezi překážkou a senzorem a 5 V odpovídá vzdálenosti 240 mm.

3.2 Kalibrace senzoru

Mezi naměřenými daty ze senzoru a výslednými daty, které jsou zpracovávány programem, je několik mezičlánků a celý řetězec prvků a převodníků může dohromady vykazovat chyby a nejistoty. Proto bylo rozhodnuto, že se



Obrázek 3.2: Zapojení senzoru SICK UM12 pro převod proudu na napětí 1 až 5 V

proměří vztah naměřených a výsledných dat s kompletním zapojením senzoru.

Výsledná data by měla vykazovat přibližnou lineární závislost na měření vzdálenosti, proto by mělo být dostačující změření několika vzdáleností (nikoli v limitních oblastech senzoru) a jejich následná aproximace přímkou. Tím se získá požadovaný vztah mezi vzdáleností senzoru od překážky a daty

$$x_c = k_1 x_m + k_2, \quad (3.1)$$

kde x_m představují naměřená data (analogové hodnoty z AD převodníku), x_c zkalibrovaná data a k_1, k_2 parametry přímky získané proložení dat metodou nejmenších čtverců. Tento vztah potom může být dále použit v reálných měřeních pro kalibraci dat [36]. Referenční data x_{ref} byla naměřena pomocí laserového dálkoměru Bosch PLR 50C.

Data použitá pro kalibraci jsou uvedena v tabulce 3.1, x_{ref} představují referenční hodnoty.

x_{ref} [mm]	50	69	89	119	138	162	232
x_m	2498	2647	2783	3001	3141	3318	3829

Tabulka 3.1: Naměřená data použitá pro kalibraci zapojení senzoru

K proložení dat přímkou byla použita funkce MATLABu `polyfit`, celý postup pak lze nalézt ve skriptu `calib.m` a parametry přímky v souboru

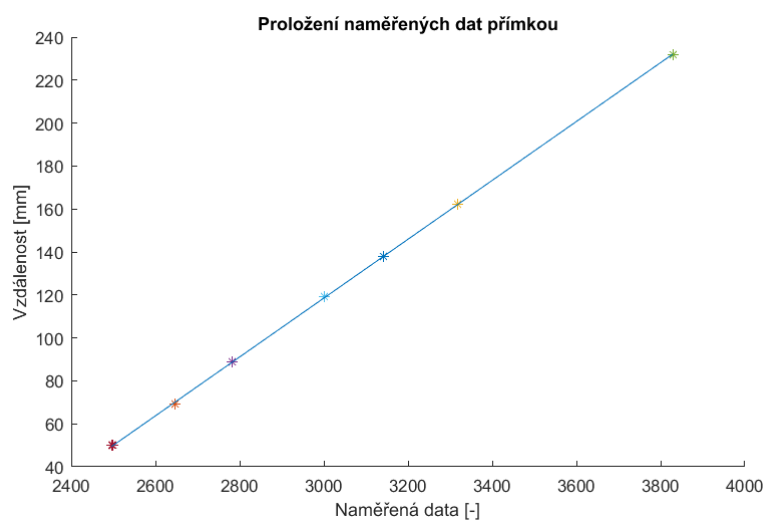


Obrázek 3.3: Naměření dat pro kalibraci pomocí referenčního laserového dálkoměru

calib-polyfit.mat. Výsledná rovnice aproximační přímky má tvar

$$x_c = 0,137x_m - 292,5339, \quad (3.2)$$

náhled přímky i s naměřenými daty je k dispozici na obrázku 3.4. Z obrázku je patrné, že naměřená data mají lineární průběh, a to i v obou hraničních oblastech rozsahu měření senzoru.



Obrázek 3.4: Kalibrační data proložená přímkou

3.3 Zpracování dat

Skripty `fit_uos.m` a `fit_podstavec.m` obsahují příkazy k lokalizaci UOS, respektive podstavci. Nejprve se jedná o načtení naměřených a kalibračních dat z externích souborů a načtení modelu lokalizovaného objektu. Načtená data ze souborů jsou následně zpracována takto (v uvedeném pořadí):

- Filtrování - z načtených dat jsou odstraněna všechna, která mají hodnotu větší než 3960. Takové hodnoty náležejí měřením, kdy jsou překážky od senzoru příliš daleko nebo příliš blízko, tzn. není možné určit vzdálenost.
- Převod - zbývající data jsou převedena pomocí načtené kalibrace na jednotky milimetrů pomocí vztahu uvedeného v předešlé sekci **Kalibrace senzoru**, a poté ještě násobené 0,001 pro převod na metry [m]. Po převedení dat je ještě jednou zkontrolováno, jestli data obsahují pouze hodnoty v rozsahu senzoru, tj. od 0,05 m do 0,3 m.
- Transformace - z naměřené vzdálenosti mezi senzorem a překážkou x_c a známé pozice senzoru v prostoru X_s jsou vypočítané body povrchu X lokalizovaného objektu pomocí vztahu

$$X = X_s + s[R^{-1}(x_c \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix})], \quad (3.3)$$

kde R je rotační matice udávající natočení senzoru v prostoru a s slouží k určení toho, ze které strany je objekt skenovaný. Pokud data o natočení senzoru v prostoru (matice R) nejsou k dispozici, pouze se přičte vzdálenost mezi senzorem a překážkou k pozici senzoru ve směru osy skenování.

- Vyhlazování - data jsou vyhlazena pomocí metody pohyblivého průměru, popsaného rovnicí v sekci **Zpracování a filtrování dat** pro $n = 2$, tzn. počítá se aritmetický průměr celkem z pěti bodů. Pro metodu pohyblivého průměru byla vytvořena funkce `smooth_mv_avg.m`.

3.4 Lokalizace

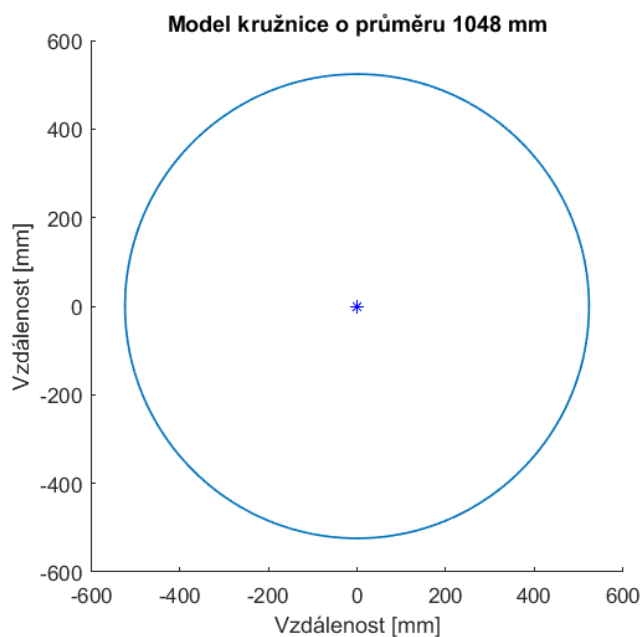
Předpokládá se, že ve výsledné realizaci manipulátoru budou senzory umístěné na konci ramene, přímo na kleštích uchopujících požadovaný objekt. Mohou být připevněné vodorovně se zemí nebo natočené vůči zemi. Pozice

umístění senzorů, stejně jako jejich natočení v prostoru, je známé a k dispozici.

3.4.1 Lokalizace UOS

Úloha lokalizace UOS (= úložný obalový soubor) byla řešena několika způsoby. Objekt UOS lze pro zjednodušení modelovat jako ležící válec o průměru 1048 mm. Protože se předpokládá skenování objektu kolmo na osu válce procházející středem podstav válce, znamená to, že se úloha převede ze tří dimenzí do dvou dimenzí na lokalizaci kruhu. V tomto případě spadá úloha pod oblast registrace množiny dat, kdy se jako neznámé proměnné uvažují pouze rotace a translace (tzv. Euklidovská transformace), tj. relativní pozice kruhu vůči kleštím manipulátoru.

Nejprve byl vytvořen model kružnice o průměru 1048 mm, který bude později použit jako vstup do algoritmů registrace množiny bodů. Tento model obsahuje 201 bodů, které jsou rovnoměrně rozprostřeny po kružnici s odstupem $\pi/100$. Celý skript `circle_gen.m` obsahuje vygenerování bodů na kružnici s daným poloměrem, jejich uložení do souboru `circle.mat` a vykreslení kružnice.



Obrázek 3.5: Vygenerovaný model kružnice o poloměru 1048 mm

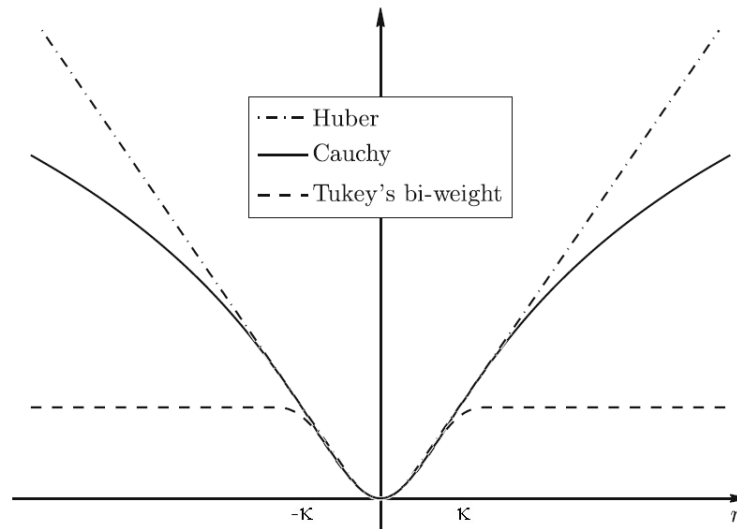
Vzhledem ke známému modelu kružnice jsem se rozhodla použít k lokalizaci kruhu registrační algoritmus ICP. Bergström implementoval ICP algoritmus ve volně dostupném souboru `icp.m` [37]. Kromě standardního ICP algoritmu [30], který používá k výpočtu odchylek metodu nejmenších čtverců, přidal autor do funkce několik robustních kritériálních funkcí. Robustní algoritmus ICP využívající váhovaný výpočet odchylek v metodě nejmenších čtverců je popsán v publikaci [38]. Dle slov autorů je tento upravený ICP algoritmus schopen snížit vliv odlehlých hodnot.

Autoři se dále odkazují na projekty, které využívají váhování dat pro robustní zlepšení algoritmů. Po vytvoření korespondujících dvojic nejbližších bodů se každému páru přiřadí váha, která určuje, zda je daná dvojice bodů pravděpodobně správná (větší hodnoty váhy) či špatná (menší hodnoty váhy). Tak se sníží vliv odlehlých hodnot v následujícím kroku, kdy se počítají odchylky mezi sety dat metodou nejmenších čtverců. Extrémním případem takovéto metody je přiřazení váhy s nulovou hodnotou dvojicím, které jsou ohodnoceny jak nežádoucí odlehlé hodnoty. Protože se poté odchylka mezi dvěma body v páru násobí jejich váhou, takto ohodnocené dvojice získávají nulovou hodnotu a nemají další vliv v metodě nejmenších čtverců. Zjevnou nevýhodou tohoto typu váhování je, že mohou být omylem vyloučeny i "správné" hodnoty.

Přístup autorů je podobný jako v případě váhování hodnot. Představují verzi ICP algoritmu, která v každém cyklu znovu ohodnotí a přiřadí nové váhy dvojicím bodů a s takto nově váženými odchylkami vypočítá transformaci mezi sety dat metodou nejmenších čtverců ("IRLS, iterative re-weighted least squares"). Jednotlivé váhy se získávají z M kritérií, odhadů využívajících extrémních vlastností typů metod maximální věrohodnosti. Metoda maximální věrohodnosti, podle které získala tato skupina název, je speciální případ M odhadů [7]. Nabízejí k ohodnocení párů bodů 3 kritériální funkce - Huberovu, Cauchyovu a Tukeyho. Pro všechny tři funkce platí, že pokud absolutní hodnota r (odchylka mezi body v páru) nepřekročí danou hranici κ , přiřazená váha sleduje podobný průběh. Pokud je porovnávána absolutní hodnota r větší než κ , funkce přiřazují odlišné váhy a jejich průběh je zachycen na obrázku 3.6.

Autoři IRLS-ICP algoritmu dále předkládají teorém a jeho důkaz, že jimi upravený ICP algoritmus se zmíněnými kritériálními funkcemi konverguje k lokálnímu extrému funkce f

$$f(R, t) = \sum_{i=1}^N \rho(d(Rp_i + t, X)), \quad (3.4)$$



Obrázek 3.6: Kriteriační funkce (Huber, Cauchy, Tukey), [7]

kde R a t jsou hledaná rotace a translace, ρ použitá kriteriační funkce, d vzdálenost mezi body páru a $p_{i=1}^N$ představují data, která jsou transformována, aby odpovídala datům modelu X . V teorému se jedná pouze o lokální extrém, a nikoliv globální. Sami autoři uznávají, že mohou nastat situace, kdy algoritmus sice úspěšně nalezne lokální extrém nebo sedlový bod, ale nebude schopen dosáhnout lepšího výsledku v podobě globálního extrému. Jako příklady uvádějí situace, kdy je orientace dat velmi rozdílná (data otočena např. o 180°), když jsou k sobě nesprávně přiřazené body v páru nebo když mají příliš mnoho podobných rysů. Nicméně pokud je inicializační odhad proměnných R, t zvolen vhodně, předpokládá se, že dosažený lokální extrém je současně ten globální.

Pro lokalizaci kružnice o známém průměru jsem se rozhodla implementovat ještě algoritmus využívající metodu RANSAC (RANdom SAMple Consensus, [39]). Je to metoda, která se využívá ke stanovení parametrů nějakého matematického modelu tak, aby model odpovídal poskytnutým datům co nejlépe. Tato metoda ovšem narozdíl od metody nejmenších čtverců rozlišuje data na vhodná data a odlehlé hodnoty tak, aby odlehlé, extrémní hodnoty neměly vliv na stanovení hodnot hledaných parametrů. Je proto také známá jako metoda pro detekování odlehlých hodnot.

Metoda RANSAC v každém kroku iterace vybere náhodnou množinu potřebnou ke zkonstruování matematického modelu. Poté jsou všechna data otestována, jestli patří k modelu na základě vybrané funkce, a jsou rozdělena na vhodná data a odlehlé, extrémní hodnoty. Pokud je podíl vhodných dat

vůči všem datům dostatečný, je model uznán jako přijatelný a jeho parametry jsou uloženy. V dalších iteracích se provádí stejný postup a vždy, když se povede získat další přijatelný model, porovná se počet bodů, které jsou součástí modelů, a uloží se parametry modelu s větším počtem vhodných dat. Cyklus algoritmu se opakuje tolikrát, kolik je předem daný maximální limit. Tím, že jsou data ke konstrukci modelu vybírána náhodně, nelze říct, jestli je po určitém počtu kroků dosaženo nejlepšího možného výsledku. Pouze se zvyšujícím počtem iterací roste zároveň pravděpodobnost, že se nejlepšího výsledku podaří dosáhnout.

Kružnice je jednoznačně definována 3 body, proto se nejprve v každé iteraci implementované funkce náhodně vyberou 3 body A, B, C a zkontroluje se, jestli nejsou některé dva body vybrané shodné. Pokud ano, vzorek se zamítne a pokračuje se další iterací. Tři body náhodného vzorku tvoří trojúhelník a střed S kružnice jemu opsané se spočítá pomocí dle následujících vztahů [40]:

$$\begin{aligned} S_x &= \frac{1}{D} [(A_x^2 + A_y^2)(B_y - C_y) + (B_x^2 + B_y^2)(C_y - A_y) + (C_x^2 + C_y^2)(A_y - B_y)] \\ S_y &= \frac{1}{D} [(A_x^2 + A_y^2)(C_x - B_x) + (B_x^2 + B_y^2)(A_x - C_x) + (C_x^2 + C_y^2)(B_x - A_x)] \\ D &= 2[A_x(B_y - C_y) + B_x(C_y - A_y) + C_x(A_y - B_y)] \end{aligned}$$

Tyto vzorce vyjadřují vztah mezi středem kružnice S a dvěma úsečkami tvořenými body A, B a B, C . Kolmice na úsečky v jejich střezech se protínají právě ve středu kružnice opsané. Poloměr kružnice r se pak snadno dopočte jako Euklidovská vzdálenost od středu kružnice S k libovolnému ze tří bodů ze vzorku jako

$$r = \sqrt{(S_x - A_x)^2 + (S_y - A_y)^2}. \quad (3.5)$$

Pokud je dopředu znám průměr, respektive poloměr kružnice, je v tomto bodě algoritmu porovnán vypočtený poloměr kružnice se zadaným poloměrem. V případě, že se navzájem liší o více jak 10 % délky zadaného poloměru, je tento vzorek vynechán a algoritmus pokračuje další iterací. Implementovaná funkce v případě absence známého rozměru kružnice tento krok vynechá a ve vstupních datech se snaží nalézt vyhovující kružnici o libovolném poloměru.

V dalším kroku se vypočítá vzdálenost každého bodu od středu kružnice. Výsledek se poté porovná s vypočteným poloměrem kružnice a všechny body, které mají rozdíl vzdálenosti od středu kružnice a jejího poloměru menší než κ , jsou klasifikovány jako vhodné a zbytek je považován za příliš odlehlé hodnoty a není již dále zahrnutý do výpočtů. Hodnota κ je definována buď jako 5 % zadaného, nebo vypočítaného poloměru podle toho, jestli byl poloměr kružnice předán jako vstupní parametr funkce.

Pokud je počet všech nalezených bodů kružnice vyšší než dosavadní nejlepší výsledek, je tento model zaevidován jako nový nejlepší a jeho parametry (střed kružnice S , poloměr kružnice r a nalezené body kružnice) jsou uloženy do výstupních proměnných funkce. Celá implementace lokalizace kružnice pomocí metody RANSAC se nalézá v souboru `circle_ransac.m`.

Metoda RANSAC se také díky filtrování odlehlých hodnot může použít ke zpracování dat ještě předtím, než jsou data použita v algoritmu ICP a jemu podobných. Tím se zamezí nežádoucímu vlivu odlehlých hodnot na výsledky algoritmu, které odlehlé hodnoty neumí nebo nemohou zanedbat.

Kromě algoritmu ICP jsem se rozhodla ještě otestovat funkci `fitcircle.m` od Richarda Browna [41]. Ten implementoval dvě varianty funkce pro aproximaci kruhu ve 2D prostoru. V první variantě se využívá lineární metody minimalizující algebraickou odchylku kvadratické funkce $f(x)$ popisující kruh

$$f(x) = ax^T x + b^T x + c = 0, \quad (3.6)$$

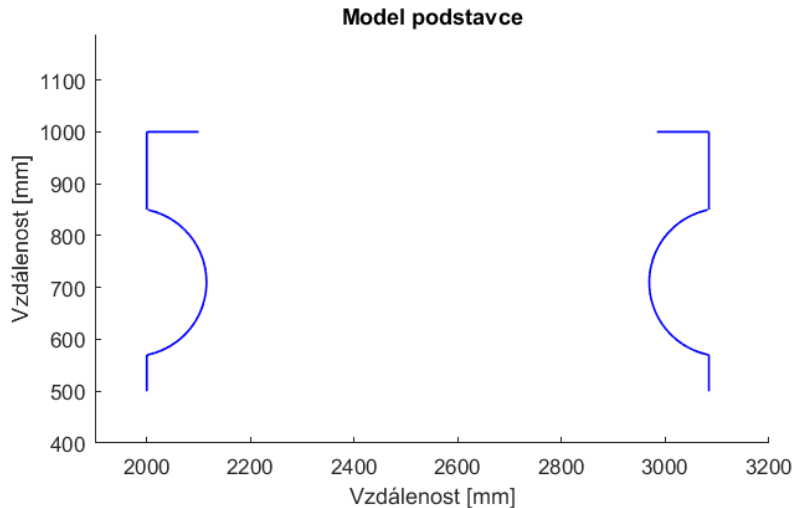
kde a, b, c jsou parametry rovnice a x naměřené body kruhu.

Druhá varianta se zaměřuje na minimalizaci geometrické odchylky, což vede na nelineární metodu nejmenších čtverců. Ta využívá k získání parametrů kruhu Gaussovu-Newtonovu metodu, která převádí nelineární problém na sekvenci lineárních rovnic používající metodu nejmenších čtverců. Celá funkce je podrobně rozepsaná v práci [42], ze které autor implementované funkce vycházel.

■ 3.4.2 Lokalizace podstavce

Podobně jako u lokalizace UOS, byl i tady vytvořen model podstavce, který dále poslouží jako vstup do registračního algoritmu ICP. Šířka podstavce je

shodná s průměrem kružnice, tedy 1048 mm. Boční strana podstavce má kulatý výřez umožňující uchopení podstavce manipulátorem, který začíná 150 mm pod horním okrajem a končí 430 mm pod horním okrajem. Kruhový výřez zasahuje v nejširším místě přibližně 115 mm do podstavce a délka takto vzniklého oblouku je 355 mm.

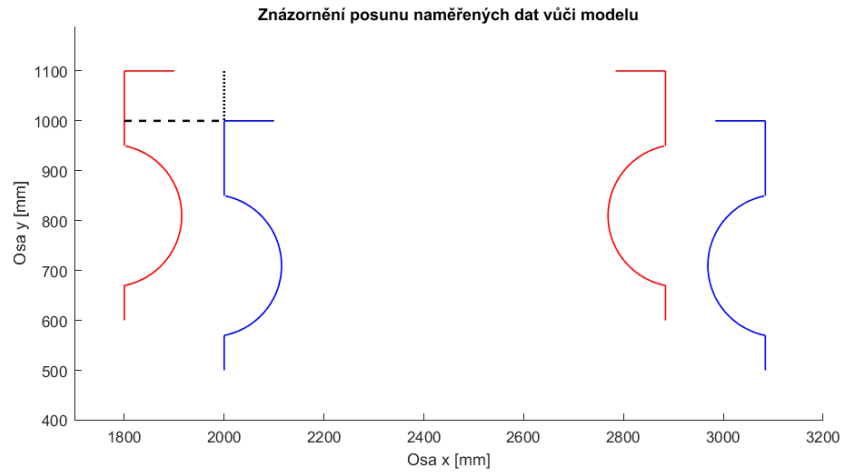


Obrázek 3.7: Vygenerovaný model podstavce o šířce 1048 mm

Skript `bentonit_gen.m` obsahuje vygenerování bodů na obou stranách podstavce, jejich uložení do souboru `base.mat` a vykreslení bodů podstavce.

Lokalizace podstavce může být s vygenerovaným modelem provedena pomocí ICP algoritmu. Pro ten je velmi důležitý prvotní odhad hledaných parametrů, tj. rotační matice R_0 a vektor posunu t_0 . Lze předpokládat, že podstavec bude natočený z čelního pohledu stále stejně, proto je zvolena jako výchozí odhad jednotková matice $R_0 = I^{2 \times 2}$. Vektor posunu se v případě dvourozměrného problému skládá z posunu ve směru dvou os a je znázorněn na obrázku 3.8.

Pro stanovení základního odhadu vektoru t_0 může posloužit analýza naměřených dat. Určí se maximální (nebo minimální) hodnoty naměřených dat ve směru os x a y , poté se od těchto hodnot odečtou maximální (nebo minimální) hodnoty modelu ve směru os x a y . Rozdíly δ_x a δ_y poslouží jako počáteční



Obrázek 3.8: Znázornění vzdálenosti mezi naměřenými daty (červeně) a modelem (modře) ve směru os x (čárkovaně) a y (tečkovaně).

odhad t_0 .

$$R_0 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (3.7)$$

$$t_0 = \begin{bmatrix} \delta_x \\ \delta_y \end{bmatrix} \quad (3.8)$$

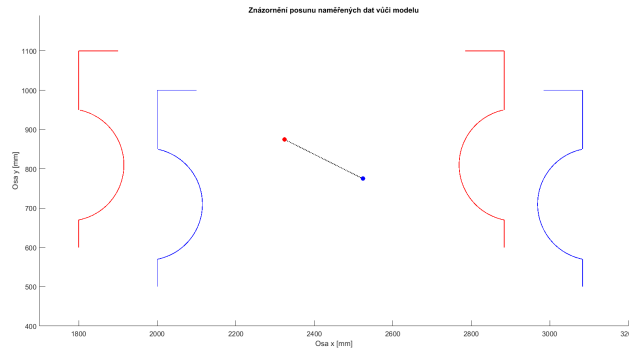
Přesto, že byla data ještě před tímto krokem filtrována, může se stát, že maximální (nebo minimální) naměřené hodnoty obsahují nevhodné body, které neleží na povrchu uchopovaného objektu. Další možností je proto nalezení těžiště naměřených bodů M_x a těžiště modelu M_m (3.9). Vzdálenost mezi těmito dvěma těžišti ve směru os x a y utvoří prvotní odhad t_0 podobně jako v předchozím případě δ_x a δ_y .

$$M_x = \frac{1}{N_x} \sum_i^{N_x} X_i \quad (3.9)$$

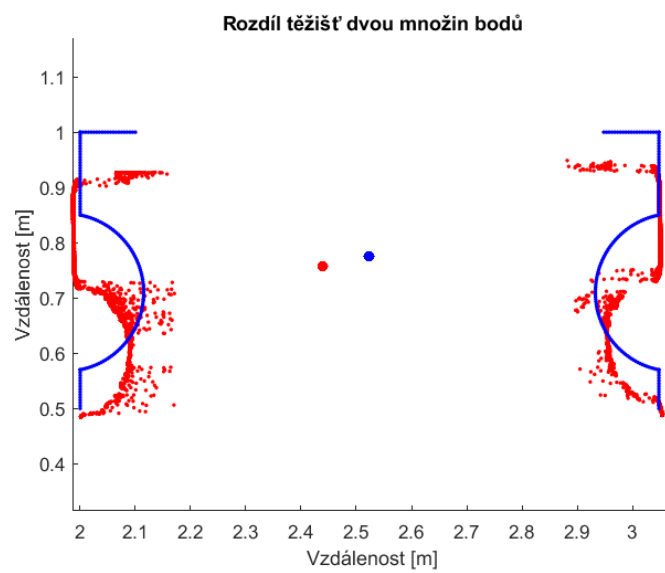
$$M_m = \frac{1}{N_m} \sum_j^{N_m} X m_j \quad (3.10)$$

$$t_0 = \begin{bmatrix} \delta_x \\ \delta_y \end{bmatrix} = \begin{bmatrix} M_{xx} - M_{mx} \\ M_{xy} - M_{my} \end{bmatrix} \quad (3.11)$$

Odhad posunu t_0 , který je vytvořený pomocí rozdílu těžišť dvou množin bodů, bude více odpovídat skutečnosti, pokud jsou data rozložena v obou množinách rovnoměrně nebo pokud mají v podobných oblastech podobné množství dat. Ideální odhad takto vznikne u 2 totožných množin dat (3.9), naopak v případě, že u jedné množiny chybí podstatná část bodů, nemusí vzniklý odhad t_0 vůbec odpovídat. Tato situace je zachycena na obrázku 3.10, kde je zřejmé, že rozdíl přibližně 10 cm mezi těžišti ve směru osy x neodpovídá zarovnání dvou množin dat.



Obrázek 3.9: Znárodnění vzdálenosti mezi těžištěm naměřených dat (červeně) a těžištěm modelu (modře).



Obrázek 3.10: Znáznornění vzdálenosti mezi těžištěm naměřených dat (červeně) a těžištěm modelu (modře).

Kapitola 4

Experimenty

Se všemi implementovanými částmi procesu lokalizace obou dvou objektů byly provedeny experimenty. Nejprve byla testována lokalizace UOS, poté i lokalizace podstavce.

4.1 Použité modely objektů a nastavení senzorů

Na obrázku 4.1a jsou zobrazené modely lokalizovaných objektů použité v experimentech. Jejich rozměry se shodují s těmi uvedenými v části práce popisující implementaci, tj. průměr válce je roven 1048 mm, stejně tak jako šířka podstavce.

4.1.1 Vicon

Během experimentů byl pro lokalizaci senzorů použit lokalizační systém Vicon [43]. Ten se sestává z kamer, které jsou umístěny do čtverce tak, aby se jejich zorná pole překrývala. To umožňuje přesnější lokalizaci hledaného objektu. Těmi jsou speciální značky vytvořené z reflexních kuliček umístěných na destičce.

4.1.2 Umístění senzorů

Vzhledem k tomu, že pohyb s modelovými čelistmi manipulátoru by byl náročný, byly ultrazvukové senzory UM12 během experimentů připevněny na stativech pomocí speciálních plastových úchytů 4.1b. Na úchyt senzoru byla vždy připevněna značka pro lokalizaci systémem Vicon, bylo tak možné během experimentů zapisovat údaje o pozici senzoru. Hýbáním senzoru pomocí mechanismu stavivu bylo nasimulováno snímání povrchu manipulátorem.



(a) : Modely lokalizovaných objektů pro praktické experimenty



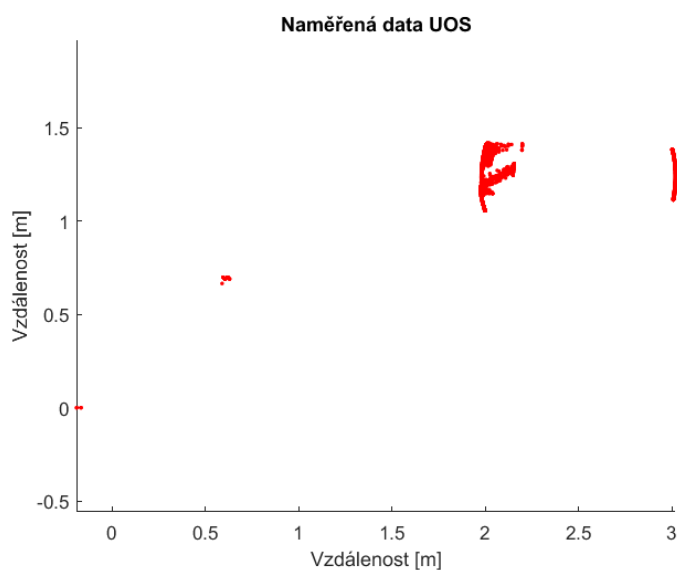
(b) : Umístění senzoru UM12 a lokalizační značky Vicon

Obrázek 4.1: Umístění modelů objektů a senzoru

4.2 Výsledky

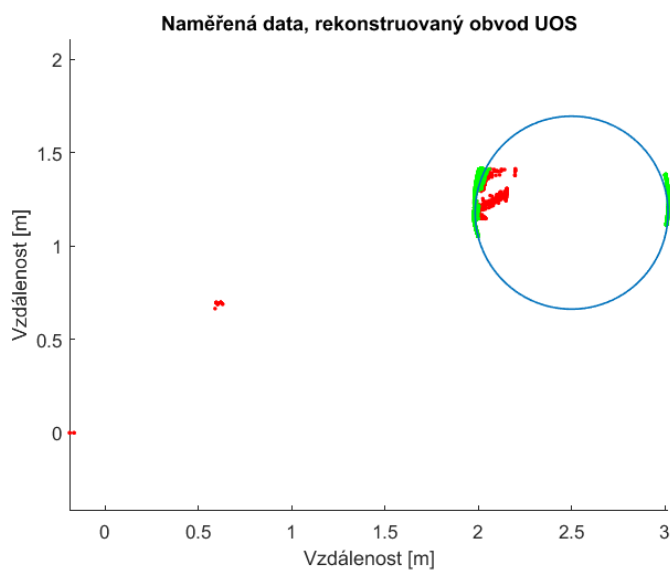
Všechna měření povrchu UOS jsou znázorněna na obrázku 4.2. Celkem data obsahují 13417 bodů z 16 měření. Měření byla prováděna jak se senzorem ve vodorovné poloze vůči zemi, tak i s nakloněným senzorem. Na uvedeném obrázku lze vidět, že data obsahují odhlehle a extrémní hodnoty.

Na obrázku 4.3 lze vidět výsledky algoritmu RANSAC, pomocí kterého byly z bodů vyfiltrovány odhlehle hodnoty. Na zbylých 12948 bodech (zeleně) byl nalezen pomocí stejného algoritmu kruh (modře) s průměrem 1033 mm a



Obrázek 4.2: Naměřená data reprezentující povrch UOS

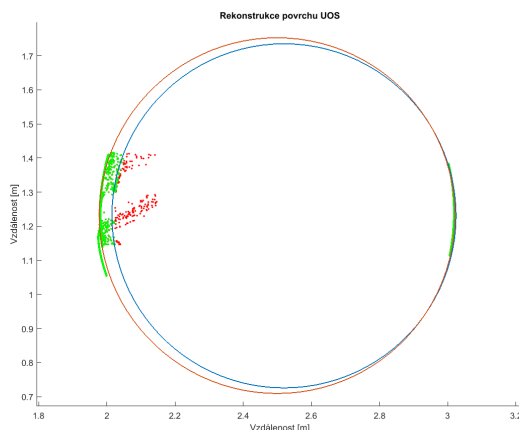
se středem v bodě [2499; 1178].



Obrázek 4.3: Naměřená data (červeně), data bez odlehlých hodnot (zeleně) a aproximace kruhu z vyfiltrovaných dat (modře)

Rozdíl v průměru kruhu tedy činí 14,9 mm. Střed skutečného modelu byl určen jako [2515; 1206]. Střed kruhu ve směru osy x byl tedy stanoven s přesností pod 20 mm, ale odchylka ve směru osy y činí 27,3 mm. Ta je pravděpodobně způsobena především dvěma důvody. Prvním je, že metoda RANSAC sice vyřadí odlehlé hodnoty, ale model kruhu generuje z náhodně

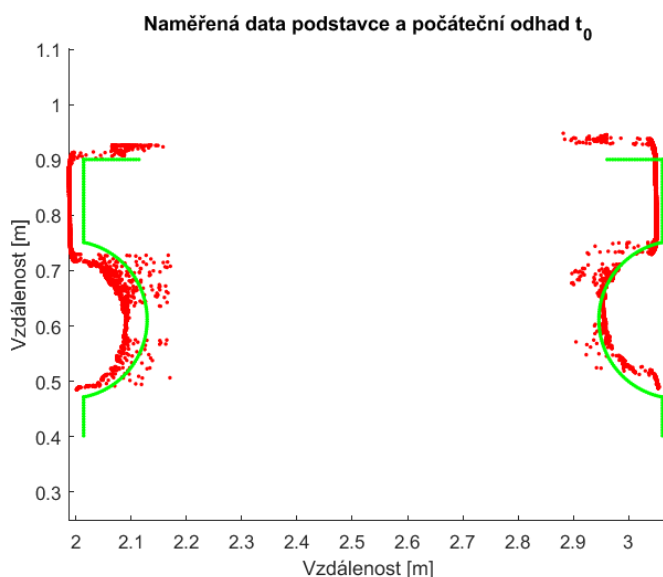
vybraných dat, tzn. nevyužívá všechny body ke stanovení nejlepších parametrů kruhu. Druhým důvodem může být chyba měření způsobená úhlovou nejistotou. Tato chyba je nejmenší při takovém snímání objektu, kdy je osa senzoru kolmá na tečnu kruhu v bodě odrazu. To znamená, že pokud je senzor ve vodorovné poloze se zemí, tato chyba se vůbec neprojevuje v místě, kde je model nejširší, a čím dále se od tohoto místa měří, tím větší je chyba. Naměřená data tedy odpovídají kruhu s větším poloměrem, než ve skutečnosti je.



Obrázek 4.4: Kruh nalezený algoritmem RANSAC (modře) a metodou nejmenších čtverců (oranžově)

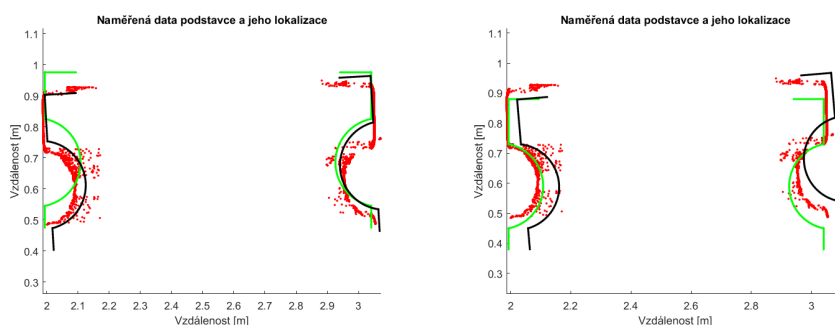
Na obrázku 4.4 je znázorněn další krok, kdy byla data odpovídající kruhu nalezenému algoritmem RANSAC použita jako vstup do algoritmu, který hledá parametry kruhu na základě metody nejmenších čtverců. Průměr takto nalezeného kruhu činí 1043,4 mm, tj. odchylka od modelu je v tomto případě rovna pouze 0,6 mm. Střed nalezeného kruhu je nyní [2519, 6; 1230, 5]. Vyhodnocení všech měření a lokalizací kruhu je k dispozici v následující kapitole.

Všechna měření podstavce jsou znázorněna na obrázku 4.5. Celkem data obsahují 9203 bodů ze 13 měření. Opět je vidět, že naměřená data obsahují odhlehlelé a extrémní hodnoty, především v části oblouku, kde se signál více odráží. Přítomnost odlehlých hodnot se projevila především lokalizace podstavce pomocí ICP algoritmu. Bylo vyzkoušeno více počátečních odhadů, ale jak je vidět na obrázcích 4.6a a 4.6b ICP algoritmus nebyl schopný uspokojivě lokalizovat podstavec. Protože ICP algoritmus nejprve hledá nejbližší sousedící prvky mezi oběma množinami dat, mají na výsledek algoritmu velký vliv odlehlé hodnoty. Navíc se zde opět nachází nepřesnosti v naměřených datech způsobených úhlovou nejistotou. Například rovná svislá část nad obloukem měří na modelu 150 mm, ale na naměřených datech je výrazně delší - přibližně 190 mm. Jde o 20 mm z každé strany, což dle výrobce odpovídá otevření



Obrázek 4.5: Naměřená data reprezentující povrch podstavce a počáteční odhad t_0 posunu mezi daty (červeně) a modelem (zeleně)

senzoru při vzdálenosti 150 mm od překážky. To znamená, že přestože již byla osa senzoru při snímání nad/pod hranou, část rovné svislé části ještě zasahovala do oblasti snímání senzoru.



(a) : Lokalizace podstavce ICP algoritmem

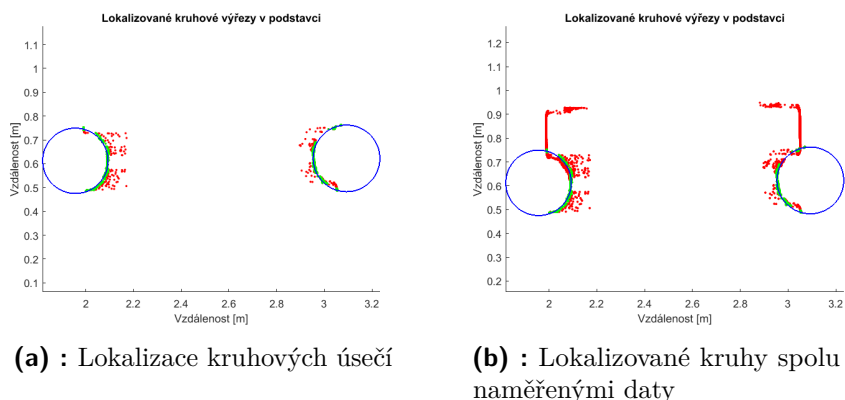
(b) : Lokalizace podstavce ICP algoritmem

Obrázek 4.6: Lokalizace podstavce (černě) s naměřenými daty (červeně) a počátečním odhadem (zeleně)

Další experiment byl proto proveden s daty, která byla naměřena v okolí kruhových výřezů v podstavci. Pomocí algoritmu RANSAC byly odstraněny odlehlé hodnoty z naměřených dat a ve zbylých datech byly nalezeny kruhy o přibližném průměru 280 mm (na obrázku 4.7). Metoda našla kruhy s průměrem 274 mm a 280 mm, se středy v bodech [1955, 8; 612, 2] a [3093, 3; 622, 4].

Následující experiment využil filtrovaná data bez odlehlých hodnot v oblasti kruhových výřezů spolu s daty horní části podstavce. Tato data byla sloučena

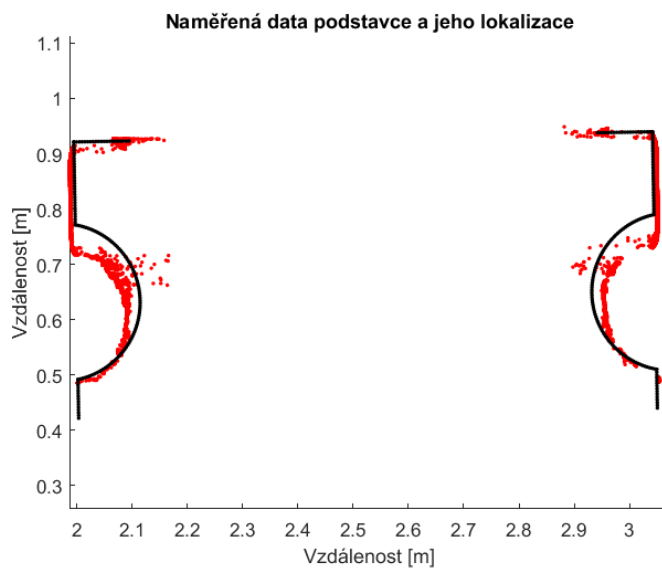
4. Experimenty



Obrázek 4.7: Lokalizace kruhů (modře) z vybraných dat (zeleně) se všemi naměřenými daty (červeně)

a použita jako vstup do ICP algoritmu, který v tomto případě úspěšněji lokalizoval model podstavce vůči vstupním datům. Na obrázku 4.8 lze vidět, že ve směru osy x model odpovídá naměřeným datům, ve směru osy y se nalezená pozice liší přibližně o 30 mm.

Vyhodnocení všech měření a lokalizací podstavce je k dispozici v následující kapitole.



Obrázek 4.8: Lokalizace modelu podstavce (černě) z vybraných dat obsahujících méně odlehlých hodnot (červeně)

Kapitola 5

Vyhodnocení

Rekonstrukce povrchu uchopovaných objektů (válce UOS a podstavce) využívá u obou objektů vlastností metody RANSAC k tomu, aby omezila vliv odlehlých hodnot na algoritmy registrace množiny dat využívající metody nejmenších čtverců. U obou objektů je metoda RANSAC využita k detekci kruhu o známém průměru, což umožňuje roztrždit data na data náležející povrchu kruhu a na odlehlé hodnoty. Dle výsledků experimentů bylo použití metody RANSAC v obou případech přínosné a pomohlo zpřesnit lokalizaci objektů.

V případě válce UOS jsou filtrovaná data dále použita ve funkci, která pomocí metody nejmenších čtverců a rozkladu na singulární hodnoty hledá optimální parametry kruhu. Kombinace těchto dvou metod se ukázala jako vhodná k rekonstrukci povrchu UOS a lokalizaci středu válce s přesností do 40 mm. Menší přesnost byla dosažena v ose y , která byla pravděpodobně způsobena úhlovou nejistotou měření. Průměr válce pak bylo možné určit dokonce s přesností pod 10 mm. V tabulce 5.1 lze vidět střední hodnoty $E(X)$ parametrů kruhu získané z 8 měření (metoda RANSAC a její kombinace s metodou nejmenších čtverců LS) spolu se směrodatnými odchylkami σ a absolutní rozdíly Δ průměrných a referenčních hodnot (střed kruhu [2515; 1206], průměr 1048 mm).

	RANSAC				LS			
X	x	y	r	d	x	y	r	d
$E(X)$	2503,13	1241,63	519,34	1038,68	2499	1236,63	521,4	1042,8
σ	7,27	20,42	6,02	12,04	0	7,22	0,58	1,16
Δ	11,88	35,63	4,66	9,33	16	30,63	2,6	5,2

Tabulka 5.1: Průměr vypočtených hodnot a směrodatné odchylky [mm]

Rekonstrukce povrchu podstavce a jeho následná lokalizace se ukázala být náročnější kvůli většímu zastoupení odlehlých hodnot a větší členitosti povrchu. Při použití samotné metody ICP byly výsledky neuspokojivé i s použitím implementovaného váhování hodnot. Střední hodnoty a směrodatné odchylky posunu T mezi pozicí modelu a jeho aproximací naměřenými daty jsou v tabulkách 5.2 a 5.3. Absolutní rozdíly Δ mezi středními hodnotami $E(T)$ a referenčními hodnotami $T_r = [-5; -100]$ mm se pohybují mezi 30 a 50 mm.

X	T_x	T_x
$E(X)$	26,7	-130,87
σ	13,31	29,09
Δ	31,7	30,87

Tabulka 5.2: Střední hodnoty vypočtených parametrů a směrodatné odchylky s počátečním odhadem t_0 získaným z těžišť množin bodů [mm]

X	T_x	T_x
$E(X)$	39,87	-146,93
σ	37,95	77,7
Δ	44,86	46,93

Tabulka 5.3: Střední hodnoty vypočtených parametrů a směrodatné odchylky s počátečním odhadem t_0 získaným z analýzy maximálních a minimálních hodnot [mm]

K dosažení větší přesnosti byla proto opět použita metoda RANSAC k detekování odlehlých hodnot v okolí kruhového výřezu a jejich vyloučení z dalšího zpracování dat. K lokalizaci podstavce je také možné použít samotné lokalizování dvou kruhů, které jsou na konci kleští manipulátoru a slouží pro pevný úchop objektu. Jsou tedy pro relativní lokalizaci manipulátoru vůči uchopovanému objektu důležité. Střední hodnoty parametrů kruhů a jejich směrodatné odchylky jsou k dispozici v tabulce 5.5. Po odfiltrování odlehlých hodnot je možné zbylá data opět použít v ICP algoritmu, v tomto případě je dosažený výsledek přesnější. Ve směru obou os x a y bylo dosaženo řádově lepších výsledků než při použití samotného algoritmu ICP. Střední hodnoty, směrodatné odchylky a rozdíly středních a referenčních hodnot T jsou v tabulce 5.4.

X	T_x	T_x
$E(X)$	4,57	-108,1
σ	3,72	7,49
Δ	9,57	8,1

Tabulka 5.4: Střední hodnoty vypočtených parametrů a směrodatné odchylky po vyřazení odlehlých hodnot metodou RANSAC [mm]

X	x_1	y_1	r_1	x_2	y_2	r_2
$E(X)$	1954,63	613,4	135,93	3091,17	626,6	135,37
σ	1,59	1,14	1,67	0,4	0,49	0,17

Tabulka 5.5: Nalezené parametry kruhových výřezů v podstavci [mm]

Pokud je hlavním cílem rekonstrukce povrchu podstavce, pak lze použít ICP algoritmus k nalezení pozice modelu podstavce. Na druhé straně pokud je důležitější lokalizace podstavce vzhledem k manipulátoru, zdá se vhodnější použití pouze RANSAC algoritmu. Ten se soustředí výhradně na lokalizaci kruhových výřezů, jejichž relativní pozice vzhledem ke kleštím manipulátoru je klíčová pro vhodný úchop objektů.

Kapitola 6

Závěr

Cílem této práce bylo seznámit se využitím ultrazvukových senzorů a jejich vlastnostmi, možnostmi filtrování a použití v úloze rekonstrukce povrchu skenovaného objektu a relativní lokalizace.

Dále byly prostudovány různé metody registrace množin bodů pro lokalizaci objektu a rekonstrukci jeho povrchu. Podrobněji byl nastudován algoritmus ICP ("Iterative Closest Point") a jeho úpravy s cílem zvýšit robustnost algoritmu. Při rekonstrukci povrchů uchopovaných objektů bylo s výhodou využito známých rozměrů a motivů kruhu v průřezu skenovaných těles. Tyto motivy kruhů jsou lokalizovány pomocí metody RANSAC ("RANdom SAMple Consensus"), zároveň jsou pomocí této metody vyloučeny odlehle hodnoty v okolí kruhů. Toho se s výhodou používá v následujících krocích lokalizace, kde by měly přítomné odlehle metody významný vliv na počítání odchylek mezi body pomocí metody nejmenších čtverců.

Byly provedeny příslušné experimenty s reálnými daty naměřenými na modelech uchopovaných objektů se senzory SICK UM12-119. U obou detekovaných objektů bylo možné s přesností do 3 cm určit jejich polohu, průměr válce UOS bylo možné určit s přesností do 1 cm.

Skripty a funkce, zdrojové soubory s naměřenými daty, průvodní fotografie a výsledky jsou k dispozici na přiloženém CD.

Příloha A

Literatura

- [1] B. Barshan and R. Kuc, “A bat-like sonar system for obstacle localization,” *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 22, pp. 636 – 646, 08 1992.
- [2] L. Chandrashekar, “Characteristics of sonar sensors for short range measurement,” 11 2014.
- [3] “Data smoothing and outlier detection.” https://www.mathworks.com/help/matlab/data_analysis/data-smoothing-and-outlier-detection.html. Citováno 20.5.2019.
- [4] A. Bezerra and P. Motta Pires, “An approach to outlier detection and smoothing applied to a trajectography radar data,” *Journal of Aerospace Technology and Management*, vol. 6, pp. 237–248, 09 2014.
- [5] D. Rueckert, “Non-rigid registration : Concepts , algorithms and applications,”
- [6] “Ultrazvukový snímač um12-119.” <https://www.sick.com/cz/cs/snimace-mereni-vzdalenosti/ultrazvukove-snimace/um12/um12-1192261/p/p358150>. Citováno 20.5.2019.
- [7] P. Huber, “Robust statistics,” *International Encyclopedia of Statistical Science*, pp. 1248–1251, 01 1981.
- [8] D. Holz and S. Behnke, “Fast edge-based detection and localization of transport boxes and pallets in rgb-d images for mobile robot bin picking,” 2016.
- [9] N. Vaskevicius, C. A. Mueller, M. Bonilla, V. Tincani, T. Stoyanov, G. Fantoni, K. Pathak, A. Lilienthal, A. Bicchi, and A. Birk, “Object

- [21] “Kuka: Robotické systémy pro bezpečnou demontáž jaderných zařízení.” <https://www.kuka.com/cs-cz/odv%C4%9Btv%C3%AD/energetick%C3%BD-pr%C5%AFmysl/odst%C3%A1vka-jadern%C3%BDch-za%C5%99%C3%ADzen%C3%AD>. Citováno 20.5.2019.
- [22] “Ultrasonic sensor applications.” <https://www.maxbotix.com/articles/ultrasonic-sensor-applications.htm>. Citováno 20.5.2019.
- [23] “Speed of sound.” https://en.wikipedia.org/wiki/Speed_of_sound. Citováno 20.5.2019.
- [24] H. P. Moravec and A. Elfes, “High resolution maps from wide angle sonar,” vol. 2, pp. 116 – 121, 04 1985.
- [25] E. Ivanjko, I. Petrović, and D. Miklić, “An implementation of the triangulation based fusion mapping algorithm,” in *Proceedings of 13th International Conference on Electrical Drives and Power Electronics EDPE 2005*, 2005.
- [26] E. A. Shvets, D. A. Shepelev, and D. P. Nikolaev, “Occupancy grid mapping with the use of a forward sonar model by gradient descent,” *Journal of Communications Technology and Electronics*, vol. 61, pp. 1474–1480, Dec 2016.
- [27] A. K. Pandey, M. Krishna, and M. Nath, “Feature based occupancy grid maps for sonar based safe-mapping,,” pp. 2172–, 01 2007.
- [28] W. S. Cleveland and C. Loader, “Smoothing by local regression: Principles and methods,” *Statistical theory and computational aspects of smoothing*, vol. 1049, 06 1996.
- [29] W. Yang and I. Zurlenko, “Kolmogorov–zurlenko filters,” *Wiley Interdisciplinary Reviews: Computational Statistics*, vol. 2, pp. 340 – 351, 05 2010.
- [30] P. Besl and H. McKay, “A method for registration of 3-d shapes. iee trans pattern anal mach intell,” *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 14, pp. 239–256, 03 1992.
- [31] S. Rusinkiewicz and M. Levoy, “Efficient variants of the icp algorithm,” in *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*, pp. 145–152, May 2001.
- [32] S. Granger and X. Pennec, “Multi-scale em-icp: A fast and robust approach for surface registration,” vol. 2353, pp. 418–432, 05 2002.
- [33] A. Fitzgibbon, “Robust registration of 2d and 3d point sets,” *Image and Vision Computing*, vol. 21, pp. 1145–1153, 04 2002.
- [34] Y. Tsin and T. Kanade, “A correlation-based approach to robust point set registration,” vol. 3, pp. 558–569, 01 2004.

- [35] B. Maiseli, Y. Gu, and H. Gao, “Recent developments and trends in point set registration methods,” *Journal of Visual Communication and Image Representation*, vol. 46, pp. 95–106, 03 2017.
- [36] I. Paunovic, D. Todorovic, M. Bozic, and G. Djordjevic, “Calibration of ultrasonic sensors of a mobile robot,” *Serbian Journal of Electrical Engineering*, vol. 6, pp. 427–437, 01 2009.
- [37] P. Bergström, “File exchange: Iterative closest point method.” <https://www.mathworks.com/matlabcentral/fileexchange/12627-iterative-closest-point-method>, 2016. Citováno 20.5.2019.
- [38] P. Bergström and O. Edlund, “Robust registration of point sets using iteratively reweighted least squares,” *Computational Optimization and Applications*, vol. 58, 07 2014.
- [39] M. A. Fischler and R. C. Bolles, “Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography,” *Communications of the ACM*, vol. 24, pp. 381–395, 06 1981.
- [40] J. Vanžura and J. Švrček, *Geometrie trojúhelníka*. SNTL - Státní nakladatelství technické literatury, 1988.
- [41] R. Brown, “File exchange: fircircle.m.” <https://www.mathworks.com/matlabcentral/fileexchange/15060-fitcircle-m>, 2007. Citováno 20.5.2019.
- [42] W. Gander, G. H. Golub, and R. Strebler, “Least squares fitting of circles and ellipses,” 1994.
- [43] “Vicon | motion capture systems.” <https://www.vicon.com/>. Citováno 20.5.2019.



Příloha B

Obsah CD

Příložené CD obsahuje elektronickou verzi tohoto dokumentu a následující složky:

- samples - složka s naměřenými daty pro experimenty
- files - složka se skripty a funkcemi programu MATLAB
- results - složka s výslednými grafy a vyhodnocenými experimenty

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Kuglerová** Jméno: **Kateřina** Osobní číslo: **434815**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra řídicí techniky**
Studijní program: **Kybernetika a robotika**
Studijní obor: **Kybernetika a robotika**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Relativní lokalizace duálního efektoru

Název diplomové práce anglicky:

Relative localization of dual effector

Pokyny pro vypracování:

1. Seznamte se s metodami zpracování a filtrování sonarových dat
2. Seznamte se s metodami registrace množin bodů
3. Navrhněte metodu pro rekonstrukci povrchu uchopovaného objektu
4. Navrhněte a implementujte metodu pro lokalizaci čelistí duálního efektoru vůči uchopovanému objektu
5. Vyhodnoťte vlastnosti navržené metody

Seznam doporučené literatury:

1. A template matching procedure for automatic target recognition in synthetic aperture sonar imagery. Myers, Vincent, and John Fawcett. IEEE Signal Processing Letters 17.7 (2010)
2. Localization and navigation of a mobile robot using natural point landmarks extracted from sonar data. Wijk, Olle, and Henrik I. Christensen. Robotics and Autonomous Systems 31.1-2 (2000)
3. Surface profile determination from multiple sonar data using morphological processing Baskent, Deniz, and Billur Barshan. "The International Journal of Robotics Research 18.8 (1999)

Jméno a pracoviště vedoucí(ho) diplomové práce:

Ing. Karel Košnar, Ph.D., inteligentní a mobilní robotika CIIRC

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **14.02.2019**

Termín odevzdání diplomové práce: **24.05.2019**

Platnost zadání diplomové práce: **20.09.2020**

Ing. Karel Košnar, Ph.D.
podpis vedoucí(ho) práce

prof. Ing. Michael Šebek, DrSc.
podpis vedoucí(ho) ústavu/katedry

prof. Ing. Pavel Ripka, CSc.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomantka bere na vědomí, že je povinna vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studentky