



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY

DEPARTMENT OF CONTROL AND INSTRUMENTATION

NAVIGAČNÍ SYSTÉM PRO BEZPILOTNÍ LETADLO BEZ GNSS

NAVIGATION SYSTEM FOR UNMANNED AIRCRAFT WITHOUT GNSS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Martin Procházka

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Janoušek, Ph.D.

BRNO 2025

Diplomová práce

magisterský navazující studijní program **Kybernetika, automatizace a měření**

Ústav automatizace a měřicí techniky

Student: Bc. Martin Procházka

ID: 230160

Ročník: 2

Akademický rok: 2024/25

NÁZEV TÉMATU:

Navigační systém pro bezpilotní letadlo bez GNSS

POKYNY PRO VYPRACOVÁNÍ:

1. Seznamte se s problematikou a přístupy navigace UAV systémů v prostředí s částečnou nedostupností globálních navigačních systémů.
2. Navrhněte softwarové navigační řešení založené na fúzi vizuálně-inerciálních senzorů pro UAV systémy fungujících v prostředí s částečnou nedostupností GNSS.
3. Implementujte navigační systém pro přesnou lokalizaci UAV v prostoru do bezpilotního letadla.
4. Navrhněte a implementujte poziční řídicí software pro UAV, který bude možné použít v reálném prostředí.
5. Srovnajte robustnost navigace vytvořeného řešení v různých extrémech venkovního prostředí. Vyhodnoťte a popište dosažené výsledky.

DOPORUČENÁ LITERATURA:

Z. Zuo, B. Yang, Z. Li and T. Zhang, "A GNSS/IMU/Vision Ultra-Tightly Integrated Navigation System for Low Altitude Aircraft," in IEEE Sensors Journal, vol. 22, no. 12, pp. 11857-11864, 15 June 2022, doi: 10.1109/JSEN.2022.3168605

Gallo, Eduardo & Barrientos, Antonio. (2021). Reduction of GNSS-Denied Inertial Navigation Errors for Fixed Wing Autonomous Unmanned Air Vehicles. Aerospace Science and Technology. 120. 107237. 10.1016/j.ast.2021.107237.

Termín zadání: 10.2.2025

Termín odevzdání: 21.5.2025

Vedoucí práce: Ing. Jiří Janoušek, Ph.D.

doc. Ing. Petr Fiedler, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato diplomová práce se zabývá návrhem a realizací navigačního systému pro bezpilotní prostředek schopného operace i při částečné nedostupnosti globálních navigačních systémů. V rámci práce byla provedena rešerše dostupných metod vizuální navigace, přičemž důraz byl kladen na použitelnost ve venkovním prostředí. Tato práce se taktéž věnuje návrhu a realizaci systému v prostředí ROS, které by umožnilo využití dostupných systémů vizuální odometrie. Taktéž je zde věnován prostor dodatečným systémům spojených s vizuální navigací, jako je eliminace driftu a plánování vhodné trasy. Závěrem je provedeno vyhodnocení dostupných systémů vizuální odometrie a nasazení tohoto systému na bezpilotní prostředek.

KLÍČOVÁ SLOVA

UAV, ROS, vizuální odometrie, SLAM, absolutní vizuální lokalizace

ABSTRACT

This thesis focuses on the design and implementation of a navigation system for an unmanned vehicle capable of operating in conditions of partial unavailability of global navigation systems. As part of the work, a review of available visual navigation methods was conducted, with an emphasis on their applicability in outdoor environments. The thesis also addresses the design and implementation of the system within the ROS environment, enabling the use of available visual odometry systems. Additional components related to visual navigation, such as drift elimination and path planning, are also discussed. Finally, the available visual odometry systems are evaluated, and the navigation system is deployed on an unmanned vehicle.

KEYWORDS

UAV, ROS, visual odometry, SLAM, absolute visual localisation

PROCHÁZKA, Martin. *Navigační systém pro bezpilotní letadlo bez GNSS*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2025. Vedoucí práce: Ing. Jiří Janoušek, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Bc. Martin Procházka
VUT ID autora: 230160
Typ práce: Diplomová práce
Akademický rok: 2024/25
Téma závěrečné práce: Navigační systém pro bezpilotní letadlo bez GNSS

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych tímto poděkoval vedoucímu diplomové práce panu Ing. Jiřímu Janouškovi Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Taktéž bych rád poděkoval Ing. Marcovi Pintérovi za asistenci při řešení harwarových problémů s bezpilotním prostředkem a studentskému spolku Drone Research Center za asistenci při provádění testování.

Obsah

Úvod	11
1 Přehled navigace bez GNSS	12
1.1 Přístupy bez mapování	13
1.1.1 Integrované přístupy	13
1.1.2 Přímé přístupy	14
1.1.3 Nepřímé přístupy	15
1.2 Přístupy založené na mapování	16
1.2.1 Přístupy se známým prostředím	16
1.2.2 Mapovací přístupy	17
1.2.3 Plánování trasy	17
2 Vizuální navigace	18
2.1 Požadavky výsledného řešení	18
2.2 Relativní vizuální lokalizace	18
2.2.1 Vizuální odometrie	19
2.2.2 SLAM	20
2.3 Absolutní vizuální lokalizace	21
3 Hardware	23
3.1 Kamery	23
3.1.1 Monokulární kamery	23
3.1.2 Stereo kamery	24
3.1.3 Hloubkové kamery	25
3.2 Výpočetní jednotka	27
3.3 Přehled použité platformy	28
4 ROS	30
4.1 Hlavní součásti systému ROS	30
4.1.1 Node	30
4.1.2 Topic	32
4.1.3 Service	32
5 Dostupná řešení vizuální odometrie	33
5.1 RTAB-Map	33
5.2 ORB-SLAM	34
5.3 OpenVINS	35

6	Metody pro absolutní vizuální lokalizaci	36
6.1	Zdroj podkladů	36
6.1.1	Mapové dlaždice	36
6.2	Nalezení korespondence	38
6.2.1	Template matching	38
6.2.2	Korespondence na základě příznaků	40
6.2.3	Využití strojového učení	44
7	Návrh řešení	46
7.1	Vizuální odometrie	46
7.1.1	Odhad pózy	46
7.1.2	Zpracování pózy	47
7.2	Absolutní vizuální lokalizace	48
7.2.1	Tvorba referenčního podkladu	48
7.2.2	Provedení lokalizace	49
7.3	Plánování trasy	50
7.4	Reprezentace prostředí	50
7.5	Hledání trasy	51
8	Příprava řešení	52
8.1	Kalibrace senzorů	52
8.1.1	Kalibrace kamery	52
8.1.2	Kalibrace IMU	54
8.1.3	Kalibrace vazby IMU-kamera	55
8.2	Konfigurace řídicí jednotky	55
9	Vyhodnocení	58
9.1	Vizuální odometrie	58
9.2	Absolutní vizuální lokalizace	64
9.3	Plánování trasy	67
9.4	Nasazení na bezpilotní prostředek	69
	Závěr	70
	Literatura	72
A	Obsah elektronické přílohy	76

Seznam obrázků

1.1	Ilustrace spoofingu[10]	12
1.2	Dron pro let ve vnitřních prostorech využívající model DroNet[10]	13
1.3	Měření optického toku levé a pravé strany obrazu[5]	14
1.4	Ilustrace odhadu vzdáleností v obraze[8]	15
1.5	Určení pozice vůči QR kódu[12]	16
1.6	Plánování trajektorie v městském prostředí[13]	17
2.1	Vizualizace ze systému vizuálně-inerciální odometrie OpenVINS	19
2.2	Zmapovaná oblast pomocí RTAB-Map	20
2.3	Ilustrace principu absolutní vizuální lokalizace[10]	21
2.4	Využití hledání příznaků pro AVL[10]	22
3.1	Příklad monokulární kamery	23
3.2	Ilustrace efektu typu závěrky[14]	24
3.3	Ilustrace triangulace bodu[16]	25
3.4	Příklad stereo kamery	25
3.5	Hlubkový obraz	26
3.6	Příklad hlubkové kamery	26
3.7	Počítač ASUS NUC	27
3.8	Rám multikoptéry	28
3.9	Letová řídicí jednotka	29
3.10	Moduly kamery RealSense D455	29
4.1	Architektura ROS1	31
4.2	Architektura ROS2	31
4.3	Definice zprávy geometry_msgs/Quaternion.msg	32
5.1	Mapování stejného prostředí napříč světelnými podmínkami[20]	33
5.2	Ilustrace detekce smyčky	34
6.1	Ilustrace struktury mapových dlaždic	36
6.2	Ilustrace válcovité projekce	37
6.3	Příklad úspěšné lokalizace snímku vlevo v mapě vpravo	38
6.4	Příklad neúspěšné lokalizace snímku vlevo v mapě vpravo	39
6.5	Normalizovaná vzájemná korelace v závislosti na posunutí	39
6.6	Ilustrace získání DoG ze scale-space	40
6.7	Ilustrace detekce dominantní orientace pro každý významný bod	41
6.8	Ilustrace procesu popisu významného bodu [26]	42
6.9	Ilustrace zkoumaného okolí algoritmu FAST [27]	43
6.10	Příklady párů k porovnání v rámci algoritmu BRIEF [28]	43
6.11	Ilustrace mechanismů metody LoFTR [29]	45
7.1	Návrh řešení	46

8.1	Kalibrační vzor	52
8.2	Přesnost kalibrace kamery z prostředí Kalibr	53
8.3	Dostupné hardwarové konfigurace systému Ardupilot	56
9.1	Plán trajektorie	58
9.2	Ilustrace transformace souřadnic	59
9.3	Vyhodnocení letové hladiny 5 m	60
9.4	Vyhodnocení letové hladiny 10 m	61
9.5	Vyhodnocení letové hladiny 30 m	62
9.6	Analýza časování dat IMU jednotky	63
9.7	Letová trajektorie	65
9.8	Filtrované korespondence určené algoritmem ORB	65
9.9	Vyhodnocení algoritmů pro AVL	66
9.10	Prostředí pro test plánování s párem vyznačených pozic	67
9.11	Odhad vhodnosti terénu pro vizuální odometrii	68
9.12	Výsledná naplánovaná trasa	68
9.13	Trajektorie reálného testu	69

Úvod

Bezpilotní prostředky zažívají zejména v poslední době velký nárůst oblíbenosti a motivace i snahy k jejich nasazení do různých odvětví každým dnem roste. Jedním z klíčových předpokladů pro jejich bezpečný a autonomní provoz je schopnost přesné lokalizace v prostoru. V současnosti nejrozšířenějším řešením je využití globálních navigačních satelitních systémů, jejichž signál však může být v některých prostředích omezený, zkreslený či zcela nedostupný. V situacích, například při letu v zastavěném městském prostředí, uvnitř budov nebo při záměrném rušení signálu, je nutné hledat jiné přístupy k navigaci. Většina používaných systémů je zcela závislá na satelitních navigačních systémech a při jejich znepřístupnění dochází zcela k přerušení mise, v některých případech až k havárii.

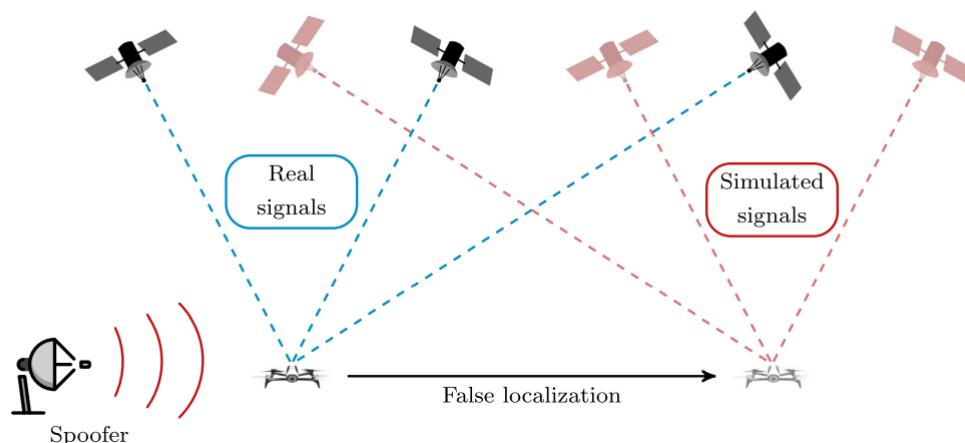
Tato práce se zabývá návrhem, implementací a ověřením navigačního systému pro bezpilotní letadlo, který by byl schopen si s částečnou nedostupností globálních satelitních systémů poradit. Cílem je vytvořit řešení, které by na základě vizuálních dat dokázalo provést lokalizaci v reálném čase na palubě bezpilotního prostředku, a tím výpadek satelitních systémů kompenzovat.

Zpracování a navigace bezpilotních prostředků s využitím vizuálních dat přímo na palubě je umožněna díky značnému polovodičovému vývoji, kdy je možné provádět velice náročné výpočty, které jsou se zpracováním obrazu spojeny. Tyto pokroky přispěly ke zmenšení rozměrů a hlavně energetické náročnosti výpočetních zařízení, což je velice žádané v oblasti bezpilotních prostředků.

1 Přehled navigace bez GNSS

Navigace bezpilotních prostředků bez přístupu ke globálním navigačním systémům je předmětem výzkumu, zejména pak v posledních letech. Tomuto zájmu přispívá velice rychlý rozvoj v oblasti bezpilotních prostředků a taktéž jejich stále častější nasazení do reálného provozu. Následně pak požadavky na jisté autonomní funkce vyžadují ke své funkci znalost polohy daného prostředku v rámci svého okolí.

Navigace je možné docílit mnoha způsoby, které se odvíjí od dostupného hardwarového vybavení, výpočetní kapacity a hlavně od prostředí, do kterého bude daný prostředek nasazen. Nejčastější způsob navigace je zajištěn pomocí globálních navigačních systémů, jelikož je jej možné použít ve vnějším prostředí, kde se většina operací bezpilotních prostředků odehrává, bez nutnosti zajišťovat dodatečnou infrastrukturu z pozice provozovatele bezpilotního prostředku. Stačí pouze daný prostředek opatřit GNSS přijímačem.



Obr. 1.1: Ilustrace spoofingu[10]


Avšak použití globálních navigačních systémů není vždy možné, zejména pak při operacích v uzavřených prostorech. Dalším faktorem je také možnost úmyslného zarušení, případně i podvrhnutí samotných satelitních signálů, jak je ilustrováno na obrázku 1.1. Samotné způsoby navigace je možné rozdělit do hlavních dvou kategorií podle jejich přístupu k této problematice na přístupy založené na mapování a na přístupy bez mapování.[1]

1.1 Přístupy bez mapování

Prvním hlavním přístupem k problematice navigace je navigace bez mapování. Řešení v této kategorii, jak již název napovídá, se neopírají o žádné předchozí informace o prostředí, ve kterém jsou nasazeny a ani nedochází k mapování prostředí při jejich používání. Obecně se tyto přístupy opírají o vyhodnocení sensorových dat, na základě kterých se bezpilotní prostředek řídí. Tyto přístupy se často spoléhají na algoritmy zpracování dat a odhadu polohy prostředku na základě sensorových informací, jako jsou například vzdálenosti od překážek nebo orientace prostředku ve prostoru. Tímto způsobem lze dosáhnout autonomního pohybu bez potřeby přesné znalosti prostředí předem.[1]

1.1.1 Integrované přístupy

Koncepčně nejjednoduššími přístupy jsou integrované přístupy, které mapují sensorická data přímo na povely bezpilotnímu prostředku. Tyto přístupy z velké části využívají strojového učení, kde je vytvořen model, který právě na svém vstupu získává sensorická data, například snímky z kamery, a na svém výstupu produkuje požadované povely.[2]




Obr. 1.2: Dron pro let ve vnitřních prostorech využívající model DroNet[10]

Příkladem takového řešení může být model DroNet, který využívá konvolučních neuronových sítí pro určení požadovaného směru letu a určení pravděpodobnosti kolize s prostředím. Tento model je určen pro městské prostředí a pro použití uvnitř budov. Pro zajištění dostatečného množství tréninkových dat využili autoři data pro autonomní auta, což právě umožňuje navigaci v městském prostředí.[3]

Městské prostředí a kryté prostory jsou příkladem míst, kde je použití globálních navigačních systémů nespolehlivé nebo až přímo nemožné, což vytváří prostor pro použití právě takového modelu, jako je DroNet. Autoři taktéž demonstrovali možnost nasazení tohoto modelu pro malé bezpilotní prostředky s limitovaným výpočetním výkonem pro let uvnitř budov.[4] Tento případ je zobrazen na obrázku 1.2.

1.1.2 Přímé přístupy

Další kategorií navigačních přístupů bez tvorby map jsou přímé přístupy. Tyto přístupy, narozdíl od integrovaných přístupů, se již více zaměřují na porozumění prostředí, ve kterém se bezpilotní prostředek právě nachází. Až na základě porozumění prostředí, například relativní vzdálenosti od sousedních zdí chodby, je potom generován určitý povel bezpilotnímu prostředku pro jeho řízení.[1]



Obr. 1.3: Měření optického toku levé a pravé strany obrazu[5]

Příkladem přímého přístupu může být využití optického toku, kde dochází k porovnání míry pohybu v levé a pravé části obrazu a na základě rozdílu tohoto pohybu mezi příslušnými stranami je pak upraven směr letu. Vychází se zde z toho, že čím blíže je objekt kameře, tím je pohyb mezi snímky kamery signifikantnější.[6] Tato metoda je znázorněna na obrázku 1.3.

1.1.3 Nepřímé přístupy

Posledním přístupem bez tvorby map jsou nepřímé přístupy. Tyto přístupy se vyznačují tím, že různými způsoby získávají vzdálenost k objektům ve svém okolí, na základě které se potom navigují.[1]

Jednou z možných metod je odhad vzdáleností pomocí konvolučních neuronových sítí, které zpracovávají obraz z kamery a vytvářejí hloubkové mapy prostředí a překážek. Tento případ je ilustrován na obrázku 1.4. Další možností odhadu vzdálenosti je za pomoci optického toku, pomocí kterého je možné odhadnout vzdálenosti a relativní rychlosti z pohybu v obraze.[8]



Obr. 1.4: Ilustrace odhadu vzdáleností v obraze[8]

Samotnou vzdálenost lze také měřit přímo pomocí senzorů měřících dobu letu, jako jsou například ultrazvukové či laserové snímače. Zde je pak možné dosáhnout zásadně vyšší přesnosti pomocí fúze dat z více zdrojů za účelem získání přesnějšího odhadu o stavu okolí okolo prostředku.[7]

Velice přínosné může být v určitých prostředích použití LiDARu, který dokáže zmapovat velké množství vzdáleností k okolním překážkám a je tak vhodnou volbou pro navigaci ve stísněných prostorech, nebo i dokonce v temných oblastech, kde není možné použít metody založené na kamerových systémech. Nevýhodou avšak může být nezanedbatelná hmotnost těchto senzorů, což činí jejich nasazení na menších prostředcích obtížné.[9]

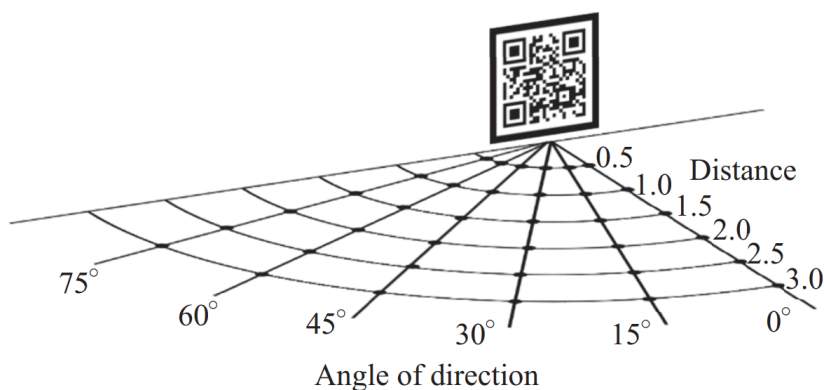
1.2 Přístupy založené na mapování

Druhým hlavním přístupem k problematice navigace je navigace založená na mapování. Zde se pro navigaci využívá předem známé informace o prostředí, nebo se vytváří mapy prostředí v reálném čase během operace. Tento přístup umožňuje efektivní lokalizaci, plánování trasy a vyhýbání se překážkám, což umožňuje plnění náročnějších operací bezpilotními prostředky v prostředích bez dostupnosti globálních navigačních systémů.

1.2.1 Přístupy se známým prostředím

Metody založené na mapování lze rozdělit do dvou hlavních kategorií. První kategorií jsou přístupy využívající známé mapy nebo informace o prostředí. Tyto informace mohou být například startovní či cílová pozice, pozice významných bodů, objektů nebo celé mapy.[1]

Jedním z hlavních způsobů navigace v těchto přístupech je vizuální odometrie, která na základě sekvence snímků z kamery odhaduje změnu polohy na základě rozdílů napříč snímky.[10] Dalším způsobem je lokalizace pomocí orientačních bodů, kde specifické značky, například QR kódy, slouží jako pevné referenční body.[12] Tyto orientační body pak mohou obsahovat informace o poloze, což umožňuje prostředku přesně určit svoji pozici a orientaci v prostoru.[11] Určení pozice pomocí QR kódu je ilustrováno na obrázku 1.5.



Obr. 1.5: Určení pozice vůči QR kódu[12]

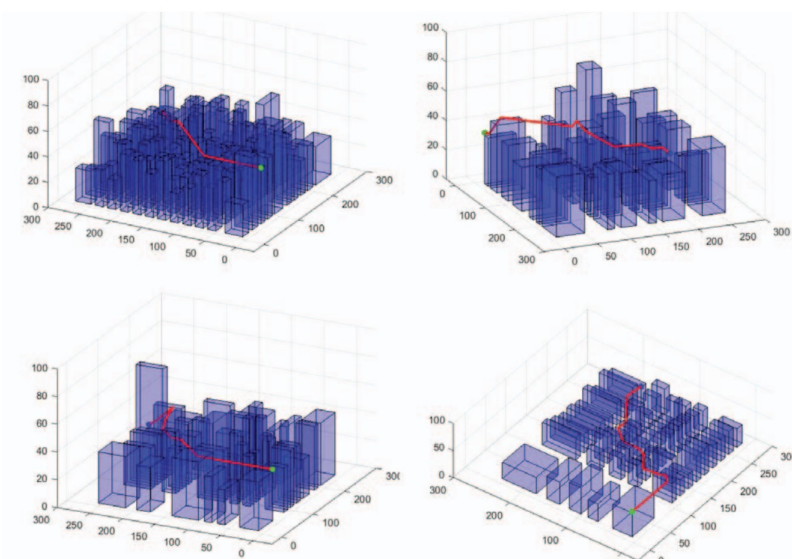
1.2.2 Mapovací přístupy

Druhou kategorií přístupů založených na mapování jsou přístupy využívající mapování v reálném čase. Tyto přístupy umožňují lokalizaci prostředku na základě komplexních dat o okolí. Při svém běhu je prováděno jednak mapování, tak i lokalizace v právě zmapovaném prostředí. Z tohoto důvodu jsou taktéž známé jako Simultaneous Localization and Mapping. Tyto přístupy na základě dat ze senzorů vytváří mapu okolí a zároveň určují pozici a orientaci prostředku v tomto prostředí.

Samotné mapování lze provádět mnoha způsoby, které se odvíjejí od použitých senzorů. Využít lze například jednu či více kamer, kde je pomocí detekce příznaků v jejich obraze možné zrekonstruovat okolní prostředí. Dále je také možné použít LiDAR pro přímé měření vzdálenosti jednotlivých bodů od senzoru. Každý z těchto způsobů přináší svá omezení na možná prostředí, do kterých jsou nasaditelné.

1.2.3 Plánování trasy

Další důležitou součástí přístupů v této kategorii je plánování trasy. Jelikož již máme dostupné komplexní informace o prostředí, můžeme vytvářet požadavky na vyšší úrovni. Tyto požadavky mohou být například automatické zmapování celé oblasti bez zásahu uživatele, případně samostatné nalezení trasy ke specifikovanému bodu. Požadavky se pak odvíjejí od požadovaného úkolu, který má daný prostředek vykonat. Příkladem takového úkolu může být let na konkrétní bod v městském prostředí, jak je ilustrováno na obrázku 1.6.



Obr. 1.6: Plánování trajektorie v městském prostředí[13]

2 Vizuální navigace

Po provedení rešerše dostupných metod pro navigaci bez GNSS je možné usoudit, že zde existuje celá řada způsobů, jak k této problematice přistoupit. Tato práce se tedy zaměřuje na navigaci ve venkovním prostředí, jelikož se jedná o velice běžné prostředí, kde jsou bezpilotní prostředky nasazovány a jsou i tedy nejvíce ohroženy v případě výpadku systému satelitní navigace. Dalším důvodem je i rozvoj autonomních dronů v komerčním sektoru pro logistické účely.

2.1 Požadavky výsledného řešení

Cílem je tedy nalézt takové řešení, které umožní dočasně bezpilotnímu prostředku pokračovat v plnění svého úkolu, a to i v případě výpadku satelitní navigace. Dalším významným požadavkem je, aby dané řešení fungovalo v prostředí, ve kterém se dané prostředky běžně pohybují, tedy vnější prostředí. Posledním, ale neméně důležitým požadavkem je potřeba provádět veškeré výpočty spojené s navigací na palubě bezpilotního prostředku, a to v reálném čase.


Jelikož z povahy úlohy vyplývá požadavek na řízení pozice, nabízí se přístupy založené na mapování, jelikož dokáží pracovat s body se známou pozicí, jakožto je například poslední platná poloha získaná satelitní navigací a pozici cílového bodu, ke kterému prostředek směřuje. Taktéž vzhledem k nasazení ve venkovním prostředí je vhodné využít vizuální data k provádění navigace. Použití LiDARu není vhodné, pokud se nepředpokládá let ve stíněných prostorech, jelikož jinak prostředí neobsahuje dostatečné množství významně členitých objektů, podle kterých by bylo možno provádět navigaci.

2.2 Relativní vizuální lokalizace

Relativní vizuální navigace je přístup, který slouží k určení změny pozice a orientace mezi dvěma nebo více po sobě jdoucími snímky získanými kamerou. Tento přístup využívá pro svou funkci vizuální odometrii a SLAM pro určení pozice a orientace v prostoru. Relativní lokalizace, jak již název napovídá, není přímo navázaná na souřadnice prostředí, ale udává pouze aktuální pózu a její trajektorii relativně vůči počáteční póze. Vizuální odometrie analyzuje pohyb pomocí optického toku nebo sledování příznakových bodů, zatímco SLAM spojuje lokalizaci s průběžnou tvorbou mapy prostředí. Hlavní výhodou RVL je, že nevyžaduje žádné předchozí znalosti o prostředí, ve kterém bude použita.

2.2.1 Vizuální odometrie

Vizuální odometrie odhaduje změnu pózy na základě sledování rozdílů mezi po sobě jdoucími snímky. Proces probíhá pomocí identifikace příznakových bodů, což jsou výrazné vizuální prvky na snímcích, jako jsou rohy, hrany nebo textury. Tyto body jsou následně sledovány napříč po sobě jdoucími snímky. Na základě pohybu jednotlivých bodů v obraze a za předpokladu statické scény je následně proveden odhad posunu a rotace právě mezi dvěma snímky. Vizualizace výsledku takového postupu je pak znázorněna na obrázku 2.1.



Obr. 2.1: Vizualizace ze systému vizuálně-inerciální odometrie OpenVINS


Právě díky pouhému využívání sekvence snímků k určení polohy je možné použít vizuální odometrii v neznámých prostředích a i bez přístupu ke GNSS, avšak hlavní úskalí této metody spočívá v opakovaném odhadu pohybu mezi snímky, kde vzniká problém kumulace chyb, kdy nepřesnosti v odhadu celkové pózy vůči počátku postupně narůstají s časem a vzdáleností.

Jedním ze způsobů, jak projevy tohoto problému zmírnit, je kombinace dat z více nezávislých zdrojů. Příkladem může být využití inerciálních měřících jednotek, které přímo měří zrychlení a úhlovou rychlost ve všech třech osách. Těmto datům pak můžeme přiřadit vyšší význam v případě, že není možné dobře odhadovat polohu ze snímků z kamery, například v důsledku monotónního prostředí bez velkého množství významných bodů. V tomto případě pak mluvíme o vizuálně-inerciální odometrii.

Dalším způsobem minimalizace dopadu kumulace chyb odhadu pózy je využití metody SLAM. Díky této metodě je možné detekovat, že se prostředek nachází na již jednou navštíveném místě, a tím je možné naakumulovanou chybu odstranit.

2.2.2 SLAM

SLAM je zkratka pro Simultaneous Localization and Mapping a představuje proces, při kterém autonomní prostředek současně mapuje neznámé prostředí a určuje svou polohu v tomto prostředí. Tento proces nalézá uplatnění tam, kde je vyžadována autonomní navigace bez předem známé mapy nebo dodatečného navigačního systému, jako je například GNSS.



Obr. 2.2: Zmapovaná oblast pomocí RTAB-Map


Princip SLAM spočívá v měření relativní polohy mezi prostředkem a unikátními významnými body v mapovaném prostředí. Tyto body mohou být buď přirozené, nebo umělé, a slouží jako referenční místa pro lokalizaci a mapování. Proces odhadu polohy prostředku a orientačních bodů využívá algoritmy, jako je Extended Kalman Filter, který odhaduje stav prostředku a bere v potaz nelinearity samotného systému. Výsledkem použití nástrojů SLAM je mimo určení samotné pozice v okolním prostředí i mapa prostředí, ve kterém se prostředek pohyboval, jak je ilustrováno na obrázku 2.2.

Hlavní výhodou této metody je eliminace potřeby předem známých map nebo externí infrastruktury, což umožňuje její nasazení i v předem neznámých prostředích. Jednou z klíčových vlastností SLAM je schopnost opakovaně pozorovat již dříve detekované orientační body, což významně přispívá ke zmírnění kumulativních chyb, které jsou běžné u jiných navigačních metod, jako je například vizuální odometrie.

Avšak použití této metody má i několik limitací. Hlavní omezení představuje především vysoká výpočetní náročnost, která roste s počtem orientačních bodů v prostředí. Tato výpočetní náročnost představuje omezení zejména u bezpilotních prostředků, kde je požadavek, aby tento proces běžel v reálném čase na výpočetních zařízeních, která jsou omezena hmotnostními a napájecími limity. Další omezení je obdobné, jako u vizuální odometrie, a to, že v důsledku monotónního prostředí není možno detekovat dostatečné množství orientačních bodů.[18]

2.3 Absolutní vizuální lokalizace

Absolutní vizuální lokalizace nabízí odlišný přístup k lokalizaci, který se spoléhá na porovnávání aktuálně pořízeného snímku s předem nasbíranými nebo známými referenčními daty, jako jsou satelitní snímky nebo jiné georeferencované snímky. V porovnání s RVL, tento přístup k lokalizaci nenaráží na problém s akumulací chyb, protože každá nová pozice může být odhadována nezávisle na předchozích odhadech. Princip fungování AVL je ilustrován na obrázku 2.3.




Obr. 2.3: Ilustrace principu absolutní vizuální lokalizace[10]

Princip AVL spočívá v porovnávání aktuálních snímků pořízených kamerou se snímky v referenční databázi. Tyto snímky mohou být pořízeny z různých zdrojů, jako jsou satelitní mapy nebo také předešlé lety. Samotné porovnání může být realizováno několika různými způsoby. Jedním ze způsobů je přímé porovnávání snímku vůči mapovým podkladům za pomoci metody zvané template matching, kde je snímek postupně posouván po mapě a pro každé takové posunutí je vypočtena vzájemná korelace. Shoda je určena pro takový posun, kde je odezva korelace nejvyšší. Tato metoda je velice přesná, avšak velice výpočetně náročná, jelikož čím větší je zkoumaná oblast, tím je potřeba provést více porovnání. Dalším úskalím je nutnost mít shodné měřítko právě pořízeného snímku a referenčního snímku.

Avšak existují také způsoby, kde není zapotřebí porovnávat snímek vůči mapě metodou pixel po pixelu. Shody lze také nalézt pomocí hledání podobných příznaků v obou snímcích, kde nejdříve nalezneme v pořízeném snímku významné příznaky, které až pak následně porovnáme s příznaky z referenčního snímku. Navíc je možné si samotné příznaky v referenčních snímcích předpočítat dopředu, což dále snižuje výpočetní náročnost. Příklad hledání shodných příznaků je ilustrován na obrázku 2.4.

Jedním z hlavních problematik AVL je nalezení podobnosti snímku v mapě v případě změn prostředí, jelikož se s denní dobou mění osvětlení, a tudíž i stíny, nebo dokonce může dojít k velice významné změně toho, jak prostředí vypadá v důsledku změny ročního období. Tento problém je možné do jisté míry kompenzovat s využitím strojového učení, jehož použití je v posledních letech stále častější.[10]



Obr. 2.4: Využití hledání příznaků pro AVL[10]

3 Hardware

Tato kapitola se zabývá přehledem možného hardwarového vybavení, které je možno využít pro účely vizuální navigace. Veškeré komponenty sdílejí shodnou potřebu, a to aby je bylo možné využít přímo na palubě bezpilotního prostředku ve vnějším prostředí, jak vyplývá z povahy úlohy vizuální navigace.

3.1 Kamery

První komponentou, potřebnou k realizaci vizuální navigace, je kamera, která je zdrojem informací pro provádění samotné navigace. V rámci vizuální navigace je možné se setkat s různými typy a konfiguracemi kamer, kde každý přístup přináší vylepšení, ale i omezení na provoz.


3.1.1 Monokulární kamery

Monokulární kamery jsou nejběžnějším typem kamery, se kterým se lze potkat. Vzhledem k tomu, že poskytují pouze dvourozměrný obraz, jejich využití pro odhad vzdálenosti objektu je omezené a vyžadují dodatečné zpracování, případně dodatečné předchozí informace. Výhodou těchto kamer je jejich jednoduchost na použití, kompaktní rozměry a cenová dostupnost. Díky těmto vlastnostem jsou snadno použitelné v různých bezpilotních prostředích, od laboratorních podmínek až po reálné aplikace. Vizuální odometrie s monokulárními kamerami často spoléhá na detekci významných bodů napříč snímky k odhadu vzdálenosti v důsledku pohybu prostředku. Zástupce monokulární kamery je ilustrován na obrázku 3.1.



Obr. 3.1: Příklad monokulární kamery

Samotné kamery lze rozdělit do dvou hlavních kategorií dle typu závěrky, konkrétně global shutter a rolling shutter. První kategorie zachycuje veškeré pixely obrazu v jediný moment. Kamery v kategorii rolling shutter zachycují obraz postupně po řádcích. Tento přístup snižuje hardwarové nároky na elektroniku a díky tomu jsou kamery tohoto typu mnohem cenově dostupnější, avšak hlavní nevýhoda plyne z postupného zachytávání obrazu po řádcích, kdy dochází ke zkreslení pořízeného snímku v důsledku pohybu. Tento efekt je ilustrován na obrázku 3.2.




Obr. 3.2: Ilustrace efektu typu závěrky[14]

Tento efekt pak hraje významnou roli v případě vizuální navigace, kde dochází k zásadnímu driftu odhadované pozice v porovnání s global shutter kamerami.[15] Mimo to je zde také možné narazit na komplikace s využitím systému pro detekci smyček, kdy v důsledku pohybu je geometrie objektů zkreslená, a tudíž může dojít k tomu, že již dříve navštívené místo nebude rozpoznáno, což napomáhá další akumulaci odchylky odhadu polohy v čase.

3.1.2 Stereo kamery

Dalším typem kamer, které je možné použít, jsou stereo kamery. Ty jsou tvořeny ze dvou synchronizovaných monokulárních kamer, které jsou navzájem posunuté o definovanou vzdálenost.

Tato konfigurace umožňuje výpočet hloubky scény na základě rozdílu v obraze, způsobeným právě tímto posunem. Zde se pak daný bod promítá s určitým posunem, na základě kterého lze pak odhadnout vzdálenost od kamery. Ilustrace tohoto procesu je zobrazena na obrázku 3.3. Zde ξ představuje vzájemný posun kamer, $c_{1,2}$ ohniska příslušných kamer, f ohniskovou vzdálenost kamer a $p_{1,2}$ projekci bodu P v jednotlivých kamerách.



Obr. 3.3: Ilustrace triangulace bodu[16]

Hlavním přínosem stereo kamer je schopnost odhadovat vzdálenosti bez nutnosti pohybu. Vizuální odometrie s těmito kamerami je přesnější a robustnější, jelikož umožňuje sledování příznaků v prostoru přímým měřením. Zástupce stereo kamery je ilustrován na obrázku 3.4.




Obr. 3.4: Příklad stereo kamery

3.1.3 Hlubkové kamery

Posledním typem kamer jsou hlubkové kamery, které aktivně měří vzdálenost k objektům v prostředí. K dosažení tohoto měření je možné využít dvou přístupů. První z nich je měření doby letu, kdy je vyslán paprsek a je měřena jeho doba letu k objektu a zpět. Druhý přístup využívá projekce známého vzoru do scény a na

základě deformace tohoto obrazce je pak určena samotná vzdálenost jednotlivých bodů. Hloubkové kamery na svém výstupu poskytují hloubkový obraz, kde intenzita každého pixelu reprezentuje informaci o vzdálenosti od kamery. Tuto reprezentaci je možné vidět na obrázku 3.5. [17]



Obr. 3.5: Hloubkový obraz

Nasazení takovýchto kamer ve venkovním prostředí může přinášet svá úskalí, zejména pak kvůli jejich detekčnímu dosahu. Na tuto překážku je možné narazit například v aplikacích využívajících bezpilotní prostředky, kdy je možné se pohybovat ve větších výškách. Tyto kamery nejčastěji nalézají uplatnění v interiérech, například při mapování místností, tak i v průmyslových aplikacích. Příklad takové kamery je ilustrován na obrázku 3.6.



Obr. 3.6: Příklad hloubkové kamery

3.2 Výpočetní jednotka

Další komponentou je výpočetní jednotka. Ta má za úkol samotné vyhodnocení kamerových dat a na jejich základě určení pozice v prostoru. Při volbě výpočetní jednotky je v tomto případě i nutno brát ohled na to, že bude součástí bezpilotního prostředku, což s sebou nese jisté napájecí, rozměrové a hmotnostní limitace.

První možností je Raspberry Pi 5, což je velice populární jednodeskový počítač. Své uplatnění nalézá zejména u hobby projektů. Jeho hlavní předností jsou malé rozměry a nízká hmotnost. Přes své rozměry ale nabízí dostatečný výkon pro zpracování kamerových dat a až 8 GB operační paměti. Raspberry Pi 5 je velmi cenově dostupné řešení pro výpočetně méně náročné aplikace.

Další možností je platforma NVIDIA Jetson Orin Nano. Jedná se o cenově dostupnou a výkonnou platformu navrženou pro práci s obrazem a umělou inteligencí. Spotřeba energie se pohybuje mezi 7 W a 15 W, což umožňuje jeho nasazení v energeticky omezených prostředích. Jetson Orin Nano je vhodný pro aplikace vyžadující vysoký výpočetní výkon při zachování nízkých nákladů a malé velikosti.



Obr. 3.7: Počítač ASUS NUC

Poslední uvažovanou možností je ASUS NUC, což je řada kompaktních a výkonných mini počítačů navržených pro širokou škálu použití. Tyto systémy nabízejí vysoký výkon v malém formátu, což je činí ideálními pro prostředí s omezeným prostorem. Tento počítač je postaven na platformě Intel a narozdíl od možností uvedených výše se jedná o plnohodnotný počítač. Ilustrace tohoto zařízení je zobrazena na obrázku 3.7. Hlavní předností je velice vysoký výkon a taktéž vysoká softwarová kompatibilita, jelikož nepoužívá procesor založený na architektuře ARM.

3.3 Přehled použité platformy

Po hardwarové stránce byl pro účely praktické části využit rám Hexsoon EDU-450. Jedná se o odolný rám pro multikoptéru, který nabízí velké množství prostoru pro osazení dodatečným vybavením. Tento rám je ilustrován na obrázku 3.8.



Obr. 3.8: Rám multikoptéry


Nadřazený systém pro vyhodnocení dat tvoří počítač ASUS NUC. Ten je zde provozován v konfiguraci s 32GB RAM a procesorem i5 dvanácté generace společně s 1TB NVMe SSD. Tato konfigurace umožňuje provádět výpočetně náročné operace spojené s vizuální navigací přímo na palubě a taktéž díky rychlému úložišti zaznamenávat velké množství dat pro dodatečné vyhodnocení.

Pro nízkoúrovňové řízení bezpilotního prostředku byla použita letová řídicí jednotka CubePilot Cube Orange. Tato jednotka využívá dvojici mikroprocesorů platformy STM32 ke stabilizaci bezpilotního prostředku. Dále také disponuje trojicí IMU jednotek, které jsou aktivně teplotně stabilizovány. Tato řídicí jednotka má taktéž velké množství komunikačních portů, pomocí kterých je možné připojit jednotku k dalším systémům bezpilotního prostředku. Další předností této jednotky je softwarová podpora hlavních autopilotů, konkrétně PX4 a Ardupilot. Tato jednotka je ilustrována na obrázku 3.9.



Obr. 3.9: Letová řídicí jednotka

Pro získávání dat byla použita kamera Intel RealSense D455. Hlavní předností této kamery je, že ji lze provozovat v libovolné potřebné konfiguraci, jako monokulární RGB kamera, stereo kamera anebo hloubková kamera. Veškeré moduly této kamery jsou typu global shutter, což je činí vhodné pro použití k vizuální odometrii. Hloubkové měření je zde zajištěno pomocí infračerveného projektoru vzoru a párem kamer bez filtru infračerveného záření. Rozmístění jednotlivých modulů je ilustrováno na obrázku 3.10.



Obr. 3.10: Moduly kamery RealSense D455

4 ROS

Robot Operating System, zkráceně ROS, představuje velice populární softwarovou platformu pro vývoj a výzkum robotických systémů. Nejedná se o samostatný operační systém, jak by bylo možné si na základě názvu myslet, ale o softwarovou platformu, která umožňuje snadnou tvorbu a propojení programových celků. Jednou z hlavních výzev při tvorbě robotických systémů je opakované tvoření obdobných programových celků a jejich následné propojování. Systém ROS si klade za cíl tuto část co nejvíce zjednodušit tak, aby bylo možné tyto systémy tvořit modulárně. Příkladem může být například výměna kamery pro robotický systém, kde není potřeba přepisovat velké části kódu jen proto, že nová kamera využívá rozdílné rozhraní ke komunikaci, ale stačí pouze využít jiný balíček, který právě s touto novou kamerou bude komunikovat a na svém výstupu bude poskytovat obraz shodným způsobem, jako ta předchozí kamera. Toto umožňuje jednoduše zajišťovat vysokou míru abstrakce, což je v případě vývoje komplexních systémů vídaná vlastnost.

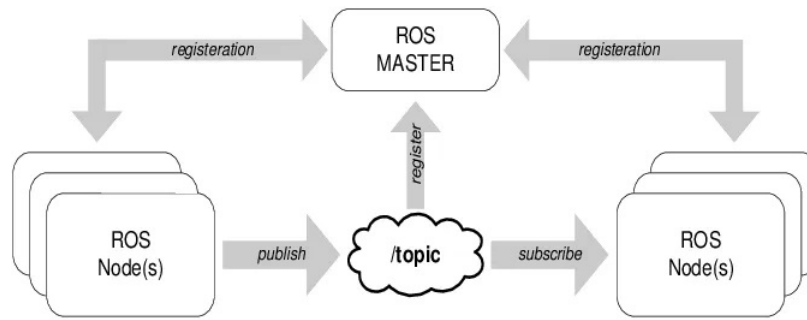
4.1 Hlavní součásti systému ROS

Samotný systém ROS je dlouhodobě vyvíjený projekt, ke kterému aktivně přispívá robotická komunita. Nové funkce a vylepšení jsou vydávány ve formě distribucí, přičemž se první distribuce datuje do roku 2007. Během svého vývoje a rozšíření využití vznikly nové požadavky, které již nebylo možné implementovat v rámci stávající architektury. Z tohoto důvodu došlo v roce 2017 k vydání první distribuce systému ROS2, který s sebou přináší změny v jistých klíčových aspektech.

4.1.1 Node

Hlavním stavebním blokem robotického systému realizovaného v systému ROS je Node. Jedná se o samostatný programový celek plnící specifickou funkci. Příkladem může být získávání dat z kamery, případně třeba provedení plánování trasy v mapě. Tento celek je nezávislý na implementaci zbylého systému. Jedním z dalších přínosů využití systému ROS je možnost implementovat jednotlivé moduly v různých programovacích jazycích, kdy systém ROS dokáže jednoduše tyto celky propojit. Toto nabízí velkou flexibilitu samotného vývoje.

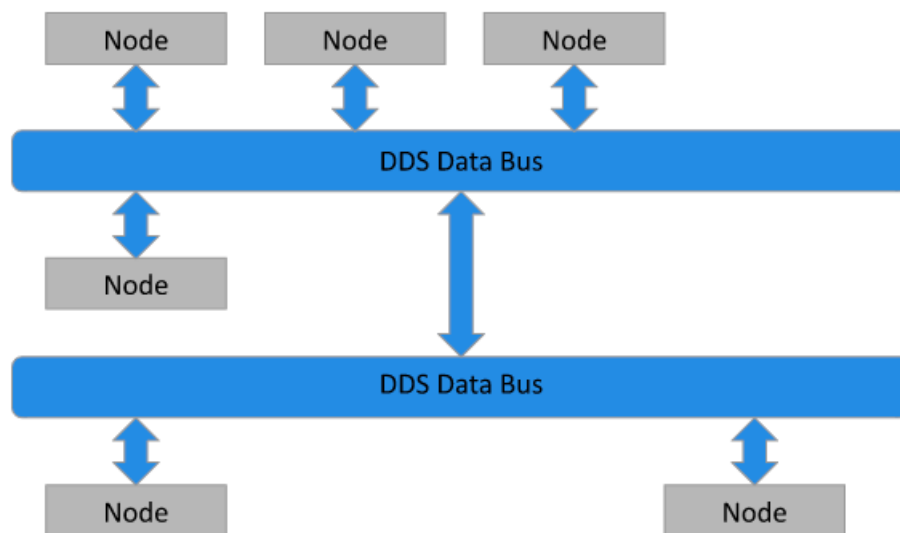
Tato modularita přináší velký přínos společně s velice rozsáhlou robotickou komunitou, která aktivně vytváří moduly pro řešení nejrůznějších úkolů, se kterými je možné se při vývoji robotického systému setkat. Tento fakt značně urychluje vývoj i výzkum, kdy je možné získat již hotová řešení a zabývat se vlastním přínosem.



Obr. 4.1: Architektura ROS1

Způsob, jakým jsou jednotlivé celky propojovány, byl předmětem hlavní změny při přechodu na ROS2. V rámci ROS1 je implementována centralizovaná architektura, kde figuruje jádro systému ve formě ROS Master. Toto jádro zajišťuje registraci všech programových celků a taktéž zajišťuje koordinaci výměny dat mezi nimi. Tato architektura je ilustrována na obrázku 4.1.

V případě ROS2 se jedná o architekturu distribuovaného systému, kdy veškerá komunikace probíhá pomocí komunikační vrstvy zvané Data Distribution Service, zkráceně DDS. Tato vrstva umožňuje propojení nejen samotných celků v rámci jednoho zařízení, ale taktéž propojení všech celků na společné síti napříč mnoha výpočetními zařízeními. Tato vlastnost je ilustrována na obrázku 4.2.



Obr. 4.2: Architektura ROS2

4.1.2 Topic

Komunikace mezi samotnými programovými celky probíhá pomocí definovaných zpráv. Tato komunikace je realizována formou publisher-subscriber, kdy jeden node předává data ostatním celkům, které se přihlásily k získávání těchto dat. Každý jednotlivý Topic představuje právě toto datové propojení. Jeden node může získávat data z několika různých zdrojů a taktéž zároveň nabízet data.

Systém ROS nabízí velké množství definovaných typů zpráv, které jsou relevantní k robotickým systémům, avšak je možné si i vlastní typ v případě potřeby doplnit. Příklad definice natočení je zobrazen na obrázku 4.3.

```
# This represents an orientation in free space in quaternion form.  
  
float64 x  
float64 y  
float64 z  
float64 w
```

Obr. 4.3: Definice zprávy geometry_msgs/Quaternion.msg

4.1.3 Service

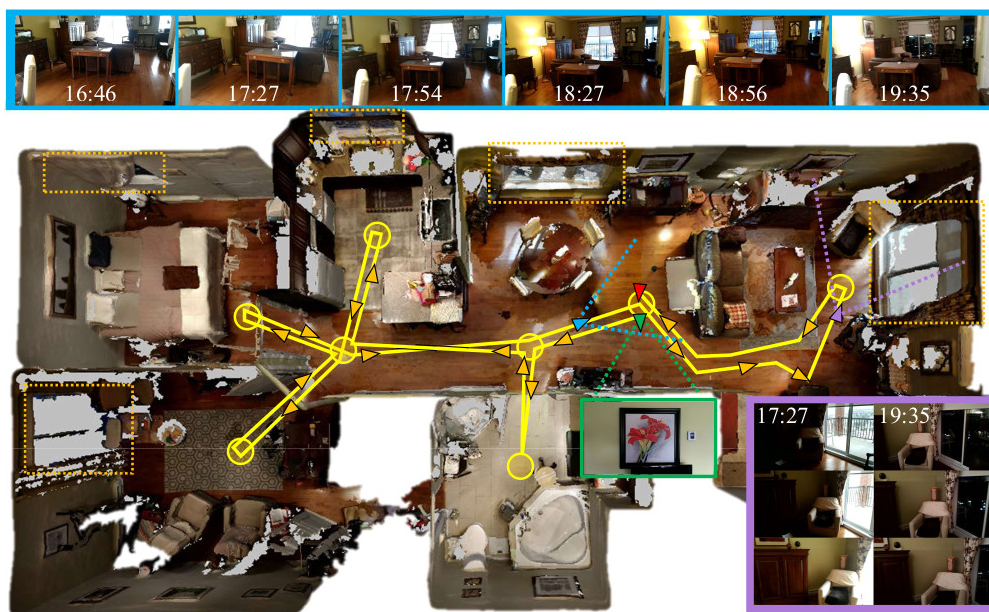
Pro určité úlohy není model publisher-subscriber vhodný, jelikož je uzpůsoben ke kontinuálnímu toku dat. Pro případy, kdy je potřeba provést nepravidelný úkon, systém ROS nabízí realizovat tuto činnost pomocí Service. Jedná se o request-response model, kdy je vyslán požadavek, ten je následně zpracován a závěrem je odeslána odpověď. Příklad využití tohoto modelu je například při konfiguraci systému.

5 Dostupná řešení vizuální odometrie

Problematika vizuální odometrie je dlouholetým předmětem zájmu mnoha výzkumných skupin a tudíž již existují i řešení, která lze použít. V rámci této práce je jedním z cílů provést volbu vhodného systému a sensorové konfigurace pro použití v rámci bezpilotního prostředku ve venkovním prostředí.

5.1 RTAB-Map

Real-Time Appearance-Based Mapping, zkráceně RTAB-Map, je SLAM řešení, které podporuje zpracování jak vizuálních dat, tak i dat z LiDARu. Tento projekt byl založen v roce 2013 a vyvíjen jako open-source za pomoci komunity. RTAB-Map je určen pro autonomní navigaci v reálném čase a snaží se kompenzovat některé nedostatky, které jsou s metodou SLAM spojeny.



Obr. 5.1: Mapování stejného prostředí napříč světelnými podmínkami[20]


Jedním problémem, který je zde adresován, je výpočetní a paměťová náročnost. Ta je značně snížena díky rozdělení paměti na krátkodobou a dlouhodobou, kde jsou starší data přesouvána do dlouhodobé paměti, což umožňuje mapování větších oblastí. Dále je zde snaha minimalizovat dopady akumulace chyby pomocí detekce smyček, pokud prostředek znovu navštíví již předtím zmapovanou oblast, díky čemuž je možno naakumulovanou chybu odstranit. Taktéž je počítáno se změnou osvětlení, ke kterému může během mapování dojít, jak je ilustrováno na obrázku 5.1.

RTAB-Map je možné provozovat v konfiguraci s LiDARem, stereo kamerou anebo s hloubkovou kamerou. Mimo to i nabízí možnost kombinovat tato data s daty z enkodérů v případě pozemních robotů nebo inerciálních jednotek.[19]

5.2 ORB-SLAM

ORB-SLAM je řešení pro vizuální SLAM v reálném čase. Toto řešení prošlo několika iteracemi, kdy nejnovější verze vystupuje pod názvem ORB-SLAM3. ORB-SLAM podporuje velké množství sensorických konfigurací, které lze využít. Tyto konfigurace zahrnují režim monokulární kamery, stereo kamery a taktéž režim hloubkové kamery. Rovněž je zde také možné provést fúzi vizuálních dat s inerciálními daty pro dosažení vizuálně-inerciální navigace.

ORB-SLAM obsahuje řadu funkcí, které usnadňují jeho nasazení do reálného prostředí. Jednou z nich je správa map, kde v případě že systém zaregistruje část trajektorie, kde není možné nalézt dostatečné množství kvalitních příznaků v obraze, spustí mapování znova a doposud vytvořenou mapu uloží. Tento přístup zamezuje vzniku značné chyby v důsledku krátkodobého výpadku vizuálního systému. Pokud se povede prostředku opět nalézt cestu zpět k původně zmapovanému prostředí s kvalitní vizuální informací, systém tyto nezávislé mapy propojí do jednoho celku. Díky této funkci se tato knihovna jeví jako velice vhodná pro venkovní prostředí.



Obr. 5.2: Ilustrace detekce smyčky

Mimo správu map umožňuje tato knihovna efektivní správu paměti, kde ji rozděluje do tří kategorií podle stáří dat na krátkodobou, střednědobou a dlouhodobou. Krátkodobá paměť se zaměřuje na bezprostřední odhad pózy v prostředí. Střednědobá paměť se pak soustředí na spojování nedávných odhadů póz a dlouhodobá paměť se zabývá detekcí smyček, jejíž přínos je ilustrován na obrázku 5.2. Tento přístup značně snižuje paměťovou a výpočetní náročnost a zároveň zvyšuje přesnost lokalizace díky menší akumulaci chyb.[21]

5.3 OpenVINS

OpenVINS je open-source projektem pro výzkum a aplikaci vizuálně-inerciální odometrie. Tento systém byl navržen s důrazem na modularitu a rozšiřitelnost, díky čemuž nalézá uplatnění jednak v akademickém výzkumu, ale i také v praktických aplikacích. Nabízí možnost použití mono kamery nebo stereo kamery v kombinaci s inerciální jednotkou.

OpenVINS implementuje několik technik pro zmírnění dopadů nedostatků spojených s vizuálně-inerciální odometrií. Jednou z nich je detekce stavu, kdy prostředek není v pohybu, což je žádoucí v případě používání mono kamery, jelikož je v tomto režimu odhadována vzdálenost příznaků z pohybu. Tento systém avšak postrádá některé pokročilé funkce SLAM v porovnání s konkurenčními projekty, tudíž je náchylný k akumulaci chyb. Jedním z přínosů absence těchto systémů je ale značně menší výpočetní náročnost, což je příznivá vlastnost v případě nasazení v rámci bezpilotního prostředku.[22]

6 Metody pro absolutní vizuální lokalizaci

Zatímco v případě vizuální odometrie a SLAM je možné se setkat s nemalým množstvím systémů a řešení, které je možno přímo použít, v případě absolutní lokalizace již toto tvrdit nelze. Z tohoto důvodu je taktéž jedním z cílů této práce ověření využitelnosti absolutní vizuální lokalizace pro bezpilotní prostředek.


6.1 Zdroj podkladů

Prvním krokem k realizaci AVL je potřeba volby vhodných referenčních podkladů, ve kterých bude samotná lokalizace probíhat. Cílem je tedy nalézt vhodný referencovaný zdroj dat, vůči kterému bude možné provést vizuální porovnání s kamerovými daty pořízenými na bezpilotním prostředku.

Od zdroje dat je požadována široká dostupnost dat napříč rozsáhlým územím, po kterém se bezpilotní prostředek může pohybovat. Dále je potřeba, aby byly podklady georeferencované. Bez této vlastnosti by potom nebylo možné určit pozici i přes nalezení korespondence. Z těchto důvodů je vhodné využít komerčně dostupné poskytovatele mapových podkladů, jako jsou například společnosti Google, Bing anebo MapTiler. Hlavní výhodou tohoto přístupu je jednotné rozhraní pro přenos dat ve formě mapových dlaždic.

6.1.1 Mapové dlaždice

Manipulace s mapovými podklady formou dlaždic umožňuje efektivně přistupovat k požadovaným datům bez nutnosti stahovat celou oblast v celém svém rozsahu a rozlišení.



Obr. 6.1: Ilustrace struktury mapových dlaždic

Tento systém rozděluje celou mapu do čtvercových dlaždic a hustota tohoto rozdělení se odvíjí od požadovaného přiblížení. Díky tomuto jsou načítány jen ty dlaždice, které jsou relevantní pro požadovanou pozici a přiblížení. Dle požadovaného přiblížení se i odvíjí výsledná míra detailů na jednotlivých dlaždicích. Celý systém si lze pak představit jako pyramidu, která je vyobrazena na obrázku 6.1.[23]

Samotné dlaždice potom tvoří mřížku, kde s každým krokem přiblížení zdvojnásobuje počet řádků a sloupců. Souřadnice samotné požadované dlaždice lze získat pomocí následujících vztahů:


$$x = \left\lfloor \frac{\phi + 180}{360} \cdot 2^z \right\rfloor \quad (6.1)$$

$$y = \left\lfloor \frac{1 - \frac{\ln(\tan(\lambda) + \frac{1}{\cos(\lambda)})}{\pi}}{2} \cdot 2^z \right\rfloor \quad (6.2)$$

Kde:

- x - sloupec dlaždice
- y - řádek dlaždice
- ϕ - zeměpisná šířka
- λ - zeměpisná délka
- z - úroveň přiblížení

Důvod tohoto komplexního přepočtu je využití Pseudo-Merkartova zobrazení, které provádí projekci kulovitého zemského povrchu na válcovitou plochu.[24] Tato projekce je ilustrována na obrázku 6.2.



Obr. 6.2: Ilustrace válcovité projekce


6.2 Nalezení korespondence

Jakmile jsou dostupné referenční podklady, je možné začít provádět další krok v rámci AVL, a tím je samotné provedení lokalizace. Cílem je nalézt část mapového podkladu, která se nejvíce podobá aktuálně pořízenému snímku bezpilotním letadlem. Tohoto je možno dosáhnout několika způsoby, kdy každý přináší svá omezení z hlediska své použitelnosti.

6.2.1 Template matching

Jednou z možností nalezení korespondence mezi právě pořízeným snímkem a mapovým podkladem je využití metody template matching. Jedná se o metodu, která se snaží nalézt pozici určitého vzoru v cílovém snímku. V rámci AVL se pak jedná o nalezení části mapového podkladu, která nejvíce odpovídá pořízenému snímku.

Základní princip této metody spočívá v posouvání vzoru po cílovém snímku a výpočtu míry podobnosti mezi právě tímto vzorem a výřezem cílového snímku. Míra podobnosti pak může být určena pomocí několika metrik, jakou jsou suma kvadrátů rozdílů, případně normalizovaná vzájemná korelace jasových hodnot. Pro porovnávání snímků z venkovního prostředí je vhodné využít normalizovanou vzájemnou korelaci díky vyšší robustnosti na rozdíly kontrastu a jasu, se kterými je možné se ve venkovním běžně setkat v důsledku různých světelných podmínek. [25] Příklad úspěšné lokalizace snímku z bezpilotního prostředku pomocí metody template matching je vyobrazena na obrázku 6.3.



Obr. 6.3: Příklad úspěšné lokalizace snímku vlevo v mapě vpravo


Hlavní nevýhodou tohoto přístupu je velká citlivost na změnu měřítka a rotace, což způsobuje značné omezení v rámci bezpilotního prostředku, kdy nepřesné určení výšky a nebo odchylka kompasu může vést k neúspěšnému pokusu o lokalizaci.

[25]Avšak ani správné měřítko a rotace nemusí být zárukou k provedení úspěšné lokalizace. Příkladem tohoto může být situace ilustrovaná na obrázku 6.4, kde byla za vzor zvolena levá polovina původního snímku. I přes to, že je zde stále zachycena unikátní konfigurace chodníků, nejlepší shoda byla nalezena na přilehlé louce.



Obr. 6.4: Příklad neúspěšné lokalizace snímku vlevo v mapě vpravo

Pravděpodobnou příčinou tohoto chování je ta, že na pořízeném snímku nejsou stromy příliš kontrastní vůči okolí v porovnání s mapovým podkladem. Pokud bychom se podívali na odezvu korelace vzoru s mapovým podkladem v závislosti na posunutí, jak je vyobrazeno na obrázku 6.5, tak by bylo možné vidět, že se zde vyskytují oblasti, kde je shoda vysoká i přes to, že na první pohled tomu tak snímek neodpovídá. Tento problém poukazuje na hlavní výzvu AVL, a to je provedení lokalizace i přes drobné změny vnějšího okolí.



Obr. 6.5: Normalizovaná vzájemná korelace v závislosti na posunutí

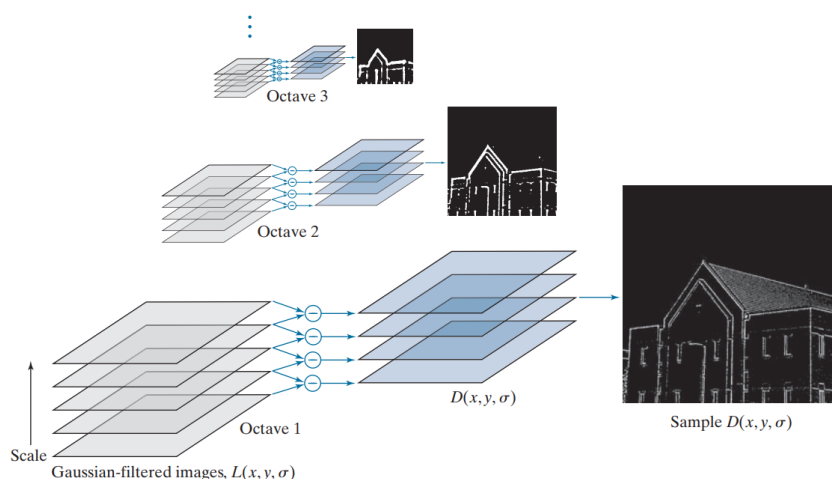
6.2.2 Korespondence na základě příznaků

V porovnání s metodou template matching umožňuje přístup založený na detekci příznaků lépe zvládat náročnější lokalizační situace, jako je změna měřítka, rotace nebo částečná změna referenčního podkladu. Princip těchto metod spočívá v detekci významných bodů jak v referenční mapě, tak i v pořízeném snímku a následném výpočtu deskriptorů, které popisují okolí těchto bodů. Na základě podobnosti těchto právě vypočtených deskriptorů jsou pak vytvořeny korespondence mezi pořízeným snímkem a mapou. Na základě takto získané korespondence je pak možné určit část mapy, která se nejvíce shoduje s pořízeným snímkem, pomocí čehož je možné následně získat i pozici, ze které byl snímek pořízen.

Hlavní výhodou využití detekce příznaků je schopnost nalézt korespondence i při rozdílné orientaci a měřítku nebo při výskytu některých změn ve scéně, které jsou běžné pro venkovní prostředí, jako jsou změny vegetace, stíny, drobné změny infrastruktury. Pro potřeby AVL je důležité nalézt takové metody pro detekci příznaků, které umožňují vysokou opakovatelnost a jsou tedy schopné detekovat stejné body i při různých podmínkách.

SIFT

První metoda pro detekci a popis příznaků se nazývá Scale Invariant Feature Transform. Jedná se o známý robustní algoritmus pro detekci a popis příznaků v obraze. Jak již název napovídá, hlavní předností tohoto algoritmu je jeho nezávislost na měřítku. Ta je docílena díky tomu, že algoritmus pracuje s tzv. scale-space, kde jsou příznaky hledány napříč různými měřítky zvanými oktávami, kdy jsou rozměry obrazu následující oktávy poloviční oproti té předchozí.[26]



Obr. 6.6: Ilustrace získání DoG ze scale-space

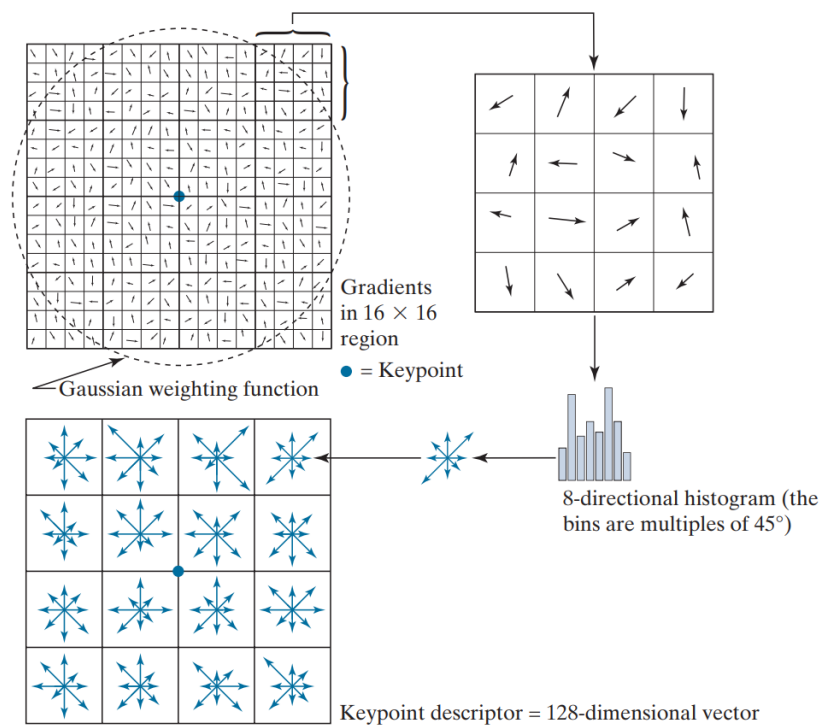
Samotné příznaky hledají v rozdílovém obrazu. Ten vzniká tak, že je obraz postupně stále více rozmazáván pomocí Gaussova filtru. Následně je pak pro každou sousední dvojici vypočten rozdíl těchto obrazů tzv. Difference of Gaussian. Lokální extrémů v tomto DoG obrazu se pak stávají kandidáty na významné body.[26] Proces vzniku DoG ze scale-space je ilustrován na obrázku 6.6.

Pro detekované kandidáty je následně provedena kontrola stability a upřesnění polohy. Dalším krokem je určení rotace samotného významného bodu, aby jej pak následně bylo možné popsat nezávisle na rotaci. To je dosaženo výpočtem velikosti a směru gradientu v určitém okolí významného bodu. Na základě nejvíce zastoupeného úhlu je pak určena dominantní orientace.[26] Detekované orientace pro významné body jsou pak ilustrovány na obrázku 6.7.



Obr. 6.7: Ilustrace detekce dominantní orientace pro každý významný bod

Posledním krokem je vytvoření popisu významného bodu. Tento popis je možné učinit nezávisle na rotaci díky předešlému kroku, kde bylo zjištěno samotné natočení bodu. Samotný výpočet popisu je prováděn v oblasti 16x16 pixelů se středem v místě významného bodu. Tato oblast je rozdělena na 16 shodně velkých podoblastí. Pro každý bod v této podoblasti je vypočten gradient a z těchto gradientů je následně sestaven histogram. Tento postup je proveden pro veškeré příslušné podoblasti. Samotné hodnoty těchto histogramů pak tvoří popis daného významného bodu.[26] Proces popisu je ilustrován na obrázku 6.8.




Obr. 6.8: Ilustrace procesu popisu významného bodu [26]

ORB

Další metoda, pomocí které je možné detekovat a popsat příznaky v obraze, vystupuje pod zkratkou ORB, zkráceně Oriented FAST and Rotated BRIEF. Primární motivace k vývoji této metody byla snaha vyvinout takovou metodu, která by byla srovnatelná s metodou SIFT a její optimalizovanou variantou SURF a která by narozdíl od uvedených nebyla patentově chráněna. Jak již samotný název této metody napovídá, jedná se o spojení dvou metod, kdy jedna slouží k detekci významných bodů a ta druhá k jejich popisu.

Detekce významných bodů je realizována pomocí algoritmu Features from Accelerated Segment Test, zkráceně FAST. Tento algoritmus dokáže detekovat potenciální významné body v obraze s velkou výpočetní efektivitou. Pro vyhodnocení, zda-li se jedná o významný bod, je použito 16 pixelů ležících na kružnici okolo zkoumaného pixelu.[27] Toto okolí je ilustrováno na obrázku 6.9. Aby byl zkoumaný pixel prohlášen za významný bod, musí být intenzita určitého množství těchto pixelů na kružnici společně výrazně odlišná, než je intenzita zkoumaného pixelu. Typický počet pixelů potřebných k určení tohoto bodu je 12.


Metoda ORB dále tento algoritmus detekce příznaků rozšiřuje o další kroky za účelem dosažení lepších výsledků. Obdobně jako u algoritmu SIFT i zde je vstupní



Obr. 6.9: Ilustrace zkoumaného okolí algoritmu FAST [27]

obraz opakovaně zmenšován a i v těchto zmenšených obrazech je následně prováděna detekce významných bodů. Tento krok výrazně zlepšuje odolnost vůči změnám měřítka. Posledním rozšiřujícím krokem je určení orientace významného bodu, díky kterému je možné zajistit nezávislost na rotaci vstupního obrazu. Tato orientace je určena pomocí vektoru vedoucího od významného bodu do těžiště centroidu určitého intenzitou obrazu.[27]

Po provedení samotné detekce významných bodů je vypočten popis pro každý detekovaný významný bod pomocí algoritmu Binary Robust Independent Elementary Features, zkráceně BRIEF. Hlavním principem tohoto algoritmu je provádění série binárních porovnání jasových hodnot pixelů v určitém okolí významného bodu. Výsledkem porovnání je vždy pravdivostní hodnota, zda-li je intenzita jasu prvního pixelu větší než jasová intenzita druhého. Výsledky těchto porovnání potom charakterizují každý významný bod.[28] Možné vzorce párů k porovnání jsou ilustrovány na obrázku 6.10.



Obr. 6.10: Příklady párů k porovnání v rámci algoritmu BRIEF [28]

V základní implementaci je avšak algoritmus BRIEF náchylný na změnu rotace, jelikož jsou páry pixelů k porovnání fixně stanoveny, při změně rotace dojde také ke změně zkoumaných pixelů. Z tohoto důvodu přináší právě metoda ORB modifikaci, kde je testovací vzor pootočen na základě dříve určené rotace významného bodu. Další slabinou společnou pro metody využívající binární porovnání pro popis je náchylnost na šum, který může změnit výsledek porovnání a tím snížit stálost popisu. Z tohoto důvodu v rámci metody ORB nejsou porovnávány jasové hodnoty přímo, ale je porovnávána průměrná jasová hodnota, získaná z okolí porovnávaného pixelu. [27]

6.2.3 Využití strojového učení

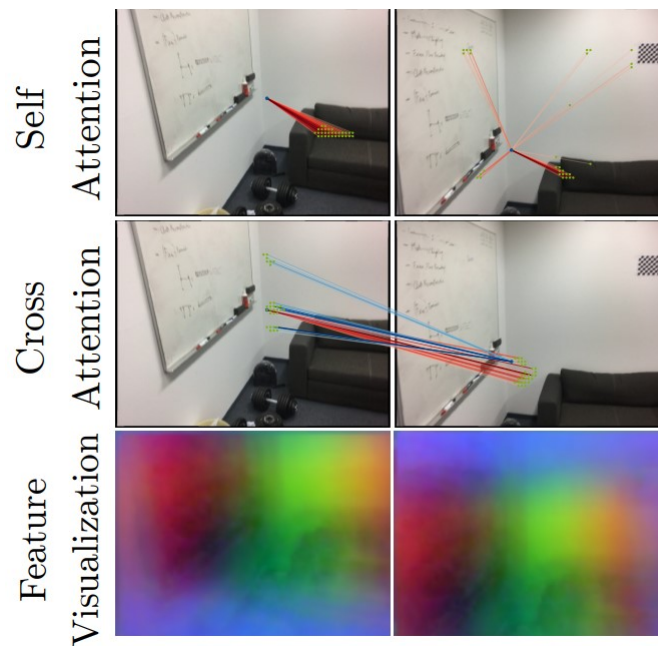
I přes veškeré přínosy, které metody založené na detekci příznaků přináší, jako je nezávislost na měřítku či rotaci, stále se zde objevuje problematika, kdy mapové podklady zcela neodpovídají aktuálnímu stavu vnějšího prostředí. To může být způsobeno aktuální meteorologickou situací, denní dobou, či dokonce ročním obdobím. Z tohoto důvodu může být vhodné využít systém založený na strojovém učení, který by se dokázal adaptovat na tyto variace prostředí a tím i dokázal nalézt podobnost v náročných scénách, ve kterých tradiční přístupy selhávají.

LoFTR

Jednou z metod založených na strojovém učení je metoda s názvem Local Feature Transformer, zkráceně LoFTR. Hlavní myšlenkou této metody je, že pro určení korespondence mezi snímky často není dostatečné analyzovat určité okolí významných bodů, ale je potřeba znát větší kontext jako takový. LoFTR využívá architekturu zvanou transformer, která obzvláště v posledních letech nalézá velké uplatnění při zpracování přirozeného jazyka. Avšak tato architektura nalézá své uplatnění i v oblasti počítačového vidění.

Základní princip LoFTR spočívá v nalezení korespondencí mezi dvěma snímky bez nutnosti přímé detekce významných bodů. Namísto toho pracuje s tzv. dense feature maps, pro které se snaží nalézt souvislost pomocí mechanismu self-attention a cross-attention.[29] Tyto mechanismy jsou ilustrovány na obrázku 6.11. Zásadním rozdílem oproti metodám založených na detekci příznaků je ten, že se zde na vstupu objevují oba snímky, ve kterých je cílem nalézt shodu. Dosavadní přístupy prováděly detekci a popis příznaků nezávisle na sobě. Sjednocením tohoto procesu umožňuje dosáhnout značně lepších výsledků, avšak na úkor jisté flexibility, kterou tradiční přístupy nabízí, jako je například možnost detekce a popisu významných bodů offline v mapových podkladech.

Samotné nalezení souvislosti se odehrává v několika krocích. První krok spočívá v extrakci lokálních příznaků s využitím konvoluční neuronové sítě v obou snímcích. Takto získané příznaky jsou následně zpracovány pomocí mechanismu self-attention, který umožňuje každému detekovanému bodu určit návaznost na ostatní detekované body v rámci daného obrázku. Tímto mechanismem mohou jednotlivé příznaky získat globální kontext, což umožňuje lépe nalézt souvislost mezi snímky. Dalším krokem je nalezení potenciálních korespondencí mezi příznaky obou snímků pomocí mechanismu cross-attention. Závěrem je pak pozice jednotlivých významných bodů upřesněna tak, aby bylo dosaženo vyšší přesnosti.[29]



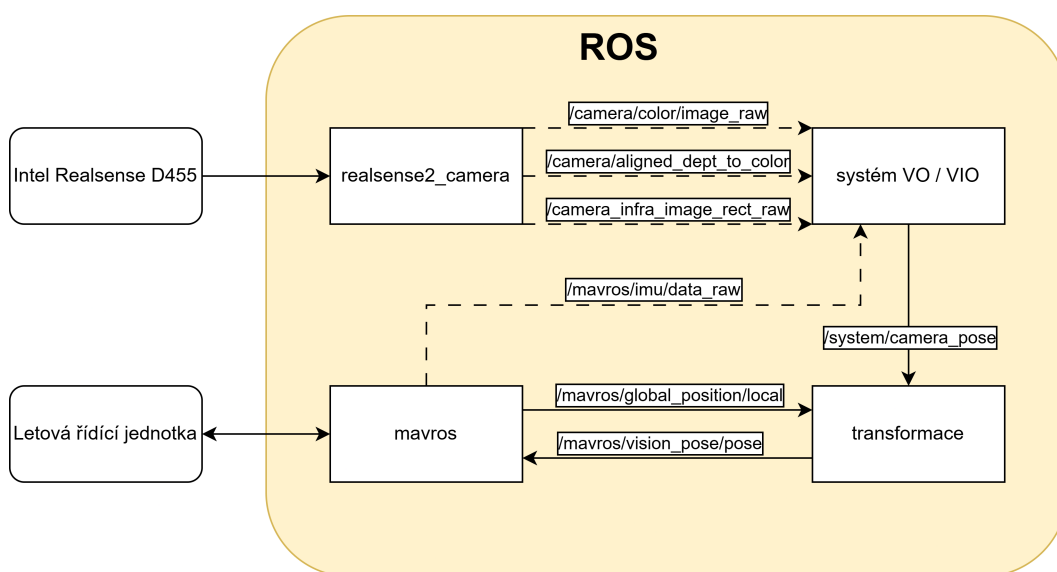
Obr. 6.11: Ilustrace mechanismů metody LoFTR [29]

7 Návrh řešení

Samostatný návrh řešení je tvořen z několika částí. První část se zabývá vizuální odometrií a jejím využitím v reálném čase na palubě bezpilotního prostředku. Předmětem druhé části je vyhodnocení využitelnosti absolutní vizuální lokalizace ve venkovním prostředí.

7.1 Vizuální odometrie

Celkové řešení pro vizuální odometrii je navrženo v několika samostatných modulech, plnících definovanou funkci. Cílem je realizovat řešení pomocí systému ROS 1, který umožňuje značnou modularitu celé realizace, kde jsou jednotlivé moduly realizovány pomocí jednoho či více ROS node. Výsledné řešení má za úkol získávat data z kamery, která je připojena k výpočetní jednotce, tato data zpracovat a vyhodnotit z nich pozici a orientaci v prostoru a tuto informaci předat řídicí jednotce bezpilotního prostředku, která je rovněž připojena k výpočetní jednotce. Blokové schéma tohoto návrhu je vyobrazeno na obrázku 7.1.



Obr. 7.1: Návrh řešení

7.1.1 Odhad pózy

První modul zajišťuje propojení mezi kamerou a prostředím ROS. Díky rozšířenosti zvolené kamery je zde možné využít nástroje výrobce, který spravuje balíček realsense2_camera, pomocí kterého je možné právě zmíněné propojení realizovat. Tento

balíček zajišťuje mimo jiné převod senzorických dat z kamery na standardní formát zpráv, které lze pak dále využívat napříč různými řešeními vizuální odometrie. Výstupem této části může být hloubkový obraz, RGB obraz, či případně dvojice obrazů ze stereo kamer, které jsou na modulu umístěny.

Druhým a nejvíce klíčovým modulem v rámci této části je modul vizuální odometrie. Při návrhu tohoto řešení bylo dbáno na to, aby bylo možné jednoduše jednotlivé navigační systémy zaměnit mezi sebou. Tato možnost je právě umožněna díky modularitě systému ROS, kdy každé testované řešení vystupuje jako samostatný ROS node. V závislosti na zamýšleném režimu použití je každý systém spuštěn se svou příslušnou konfigurací, kde jsou mimo kalibračních hodnot a parametrů specifických pro daný systém taktéž uvedeny názvy pro každý příslušný ROS topic, ze kterého mají být brána data. Výstupem každého systému je pak aktuální odhad pózy prostředku, který je následně zpracováván.

7.1.2 Zpracování pózy

Samotná potřeba pro dodatečné zpracování plyne z toho, že systém vizuální odometrie nemá z počátku pevně určenou výchozí orientaci, s výjimkou systémů využívajících fúzi vizuálních a inerciálních dat. Další překážkou, se kterou je možné se při nasazení těchto systémů setkat, je rozdílné měřítko. Na tento problém jsou zejména náchylné systémy, které nemají referenci ve formě odhadu rozměrů. S rozměrovou referencí pracují systémy operující v režimu hloubkové kamery, případně stereo kamery.

Z těchto důvodů je třeba implementovat systém, který dokáže provést korekci transformací souřadnicového systému s odhadem pozice prostředku do skutečného souřadnicového systému. Aby bylo možno tuto operaci realizovat, je potřeba nejdříve provést sběr párů pozic mezi souřadnicovým systémem odhadu pozice a referenčním souřadnicovým systémem prostředku. Jako referenční souřadnicový systém se nejlépe nabízí systém souřadnic, ve kterém je interně v rámci autopilotního systému reprezentována pozice bezpilotního prostředku. Tento souřadnicový systém vystupuje pod názvem NED, který je odvozen od os north, east, down. Počátek tohoto systému je umístěn v místě startu prostředku.

V základní konfiguraci je pozice v tomto systému určována pomocí fúze pozice ze satelitní navigace s dalšími senzorickými daty na palubě prostředku. Pro provedení příslušné transformace mezi souřadnicovými systémy je tedy potřeba provést krátký sběr pozičních dat při pohybu prostředku, na základě kterých bude tato transformace určena. Tento krok umožňuje následně jednoduché přepnutí zdroje pozičních dat pro bezpilotní prostředek a umožňuje následný provoz již bez přístupu k satelitní navigaci.

Závěrem je potřeba zprostředkovat komunikaci mezi prostředím ROS a samotnou řídicí letovou jednotkou. K tomuto účelu je možné použít balíček mavros. Jedná se o komunitně vyvíjený projekt, který umožňuje velice jednoduchou integraci bezpilotních prostředků se systémem ROS. Samotná komunikace s řídicí jednotkou bezpilotního prostředku probíhá pomocí protokolu MAVLink, který je využíván nejpožívanějšími autopilotními systémy, jako jsou Ardupilot a PX4.

7.2 Absolutní vizuální lokalizace

Cílem absolutní vizuální lokalizace je provedení korekce odhadované pozice bezpilotního prostředku, který využívá relativní vizuální odometrii, a tím zamezení akumulace driftu v rámci svého pohybu. Tato korekce se skládá z hlavních dvou kroků, kde je potřeba nejdříve získat adekvátní referenční podklad a následně v tomto podkladu provést lokalizaci.

7.2.1 Tvorba referenčního podkladu

Hlavní výzvou absolutní vizuální lokalizace je nalezení korespondence mezi aktuálním snímkem z bezpilotního prostředku a mapovým podkladem. Je tudíž příhodné zajistit vhodné podmínky k provedení tohoto kroku. Jedním z úskalí tohoto kroku je nalezení korespondence přes rozdílnou úroveň detailů v pořízeném snímku a mapovém podkladu. Z tohoto důvodu je vhodné předzpracovat referenční podklad před provedením samotného porovnání tak, aby si tedy výsledná úroveň detailů byla navzájem podobná. Míra detailu lze určit podle toho, jaké délce v reálném světě odpovídá jeden pixel. Pro snímek pořízený bezpilotním prostředkem je úroveň detailu závislá jednak na konstantních parametrech kamery, jako je zorné pole a rozlišení pořízeného snímku, tak i na proměnlivém parametru, čímž je výška nad terénem. Výpočet požadované úrovně detailu je možné provést pomocí následujícího vztahu:

$$r = \frac{2h \tan\left(\frac{\phi}{2}\right)}{w} \quad (7.1)$$

Kde:

- h - výška nad terénem [m]
- ϕ - zorné pole kamery [deg]
- w - šířka snímku [px]

Jakmile je vypočtena požadovaná úroveň detailu, je zapotřebí vytvořit samotný referenční podklad. K tomuto je zapotřebí ještě znalost jedné informace, a to přibližná pozice bezpilotního prostředku, pomocí které je možné vytvořit oblast zájmu, ve které bude samotná lokalizace prováděna. Jednou z aplikací absolutní vizuální

lokalizace je její možnost využití k eliminaci akumulace driftu relativní vizuální odometrie, kde je tedy samotná přibližná pozice odhadnuta relativní vizuální odometrií a následně upřesněna pomocí absolutní vizuální lokalizace. Avšak tento odhad nemusí zcela odpovídat skutečné pozici prostředku. Z tohoto důvodu je vhodné získat referenční podklad pod tuto odhadnutou pozici, ale také pro její okolí.

Vytváření referenčního podkladu je značně usnadněno pomocí faktu, že jsou mapové podklady tvořeny mapovými dlaždicemi. Za pomoci mapových dlaždic je možné sestavit mapový podklad pouze v požadované oblasti. Díky tomuto je možné operovat pouze s relevantními daty, což snižuje výpočetní a paměťovou náročnost. Samotný proces vytvoření podkladu je uskutečněn v několika krocích. První krok spočívá v určení výchozí dlaždice, na které se nachází odhadovaná pozice. Souřadnice této dlaždice je možné získat pomocí přepočtu válcovité projekce. Následným krokem je zjištění potřebného počtu dlaždic. Samotné dlaždice tvoří společně čtverec, i přestože je vstupní obraz obdélníkového tvaru. Toto je důsledek toho, že pořízený snímek z bezpilotního prostředku po většinu času může být natočen.

Závěrem jsou vyžádány relevantní dlaždice, které jsou spojeny do jednoho celku. Následně je provedeno škálování tak, aby byla dodržena požadovaná úroveň detailu.

7.2.2 Provedení lokalizace

Po získání požadovaného referenčního podkladu je možné provést samotnou lokalizaci. Proces provedení lokalizace se odvíjí od použité metody, kdy každá má své určité požadavky, které plynou z jednotlivých principů použitých metod. V případě použití metody template matching je nejdříve potřeba provést odpovídající rotaci referenčního podkladu, jelikož tato metoda není invariantní vůči rotaci. Jako zdroj potřebného natočení je možné využít kompasu, který je součástí samotného bezpilotního prostředku. Následně je pak pomocí samotné metody určeno místo, kde se pořízený snímek nejlépe shoduje s referencí.

Pro případ použití jedné z metod, které na svém výstupu poskytují nalezené shodné páry významných bodů v pořízeném snímku a referenčním podkladu, je proces lokalizace odlišný. Pomocí samotné množiny párů bodů nelze přímo určit pozici prostředku, která odpovídá pozici středu pořízeného snímku. Z tohoto důvodu je nejprve potřeba nalézt odpovídající transformaci pro body z pořízeného snímku do referenčního podkladu. Na základě této transformace lze pak následně transformovat střed snímku, a tím získat výslednou pozici. Samotná transformace odpovídá neúplné afinní transformaci, kdy je cílem zjistit rotaci, translaci a měřítko. Odhadovaná matice transformace následně vypadá následovně:

$$\begin{bmatrix} \cos(\theta) \cdot s & \sin(\theta) \cdot s & t_x \\ -\sin(\theta) \cdot s & \cos(\theta) \cdot s & t_y \end{bmatrix}$$

7.3 Plánování trasy

Využití vizuální odometrie ve venkovním prostředí přináší jistá omezení na oblasti, ve kterých je možné se pohybovat. Toto omezení vzniká v důsledku toho, že tyto systémy ke své funkci využívají detekci významných bodů ve snímaném obraze, pomocí kterých následně odhadují samotný pohyb prostředku. Z tohoto důvodu je vhodné, aby se bezpilotní prostředek při svém letu vyhýbal oblastem, ve kterých není právě možné velké množství významných bodů detekovat. Toho lze dosáhnout pomocí plánovače trajektorie, který dokáže využít informaci o předpokládané náročnosti daného prostředí pro systémy vizuální odometrie.

7.4 Re prezentace prostředí

Před začátkem plánování je nejprve třeba převést prostředí do reprezentace, ve které je samotné vyhledávání možné provést. Pro účel algoritmu, který hledá nejkratší cestu, je vhodné problém reprezentovat ve formě grafu, kde v tomto případě vrcholy tvoří jednotlivé pozice prostředku a hrany reprezentují náročnost přechodu do daného vrcholu. Pro účely této úlohy je uvažována konstantní relativní výška nad terénem, tudíž lze tento problém řešit ve dvou prostorových dimenzích. Pro samotné zvažované pozice jsou rozmístěny ve čtvercové mřížce, kde velikost jednoho pole odpovídá odhadované ploše, která by byla viditelná kamerou v kolmém směru k povrchu. Díky nástrojům pro tvorbu podkladu k absolutní vizuální lokalizaci je možné takto vygenerovat podklad, který bude mít podobnou úroveň detailu, tudíž bude i správně reflektován vliv výšky na viditelnost detailů.

Pro vyhodnocení každého pole je potřeba určit jistý index, který by odrážel množství klíčových bodů v obraze. Dále je potřeba, aby byl výpočet tohoto indexu velice rychlý, jelikož obzvláště u delších trajektorií je potřeba vyhodnotit značnou plochu. K tomuto úkolu se nabízí algoritmus FAST, který dokáže detekovat významné body s malou výpočetní náročností. Mimo tuto příznivou vlastnost je taktéž využíván jako první krok při detekci významných bodů v rámci metody ORB, na které jsou systémy vizuální odometrie založeny. Samotnou váhu hrany lze vypočítat následným vztahem:

$$w = 1 + k \cdot \left(1 - \frac{N}{N_{max}}\right) \quad (7.2)$$

Kde:

- N - počet detekovaných významných bodů
- N_{max} - maximální počet detekovaných významných bodů
- k - volitelné zesílení vlivu počtu bodů

7.5 Hledání trasy

Jakmile je reprezentace vytvořena, je možné provést vyhledávání pomocí ustálených algoritmů. Vhodným algoritmem k této úloze je algoritmus zvaný A*, díky kterému je možné nalézt efektivně nejkratší cestu mezi dvěma vrcholy.[30] Efektivita tohoto algoritmu spočívá ve vhodné volbě prohledávaných vrcholů, které jsou ohodnocovány dle následující funkce:

$$f(v) = g(v) + h(v) \quad (7.3)$$

Kde:

- $g(v)$ představuje skutečnou hodnotu trasy od startovního vrcholu k vrcholu v
- $h(v)$ je heuristický odhad hodnoty trasy z vrcholu v do cílového vrcholu

Jakožto heuristickou funkci je možné využít Euklidovskou vzdálenost mezi zkoumaným vrcholem a cílovým vrcholem dle následujícího vztahu:

$$h(v) = \sqrt{(v_x - e_x)^2 + (v_y - e_y)^2} \quad (7.4)$$

Kde:

- $v_{x,y}$ představují souřadnice zkoumaného vrcholu v
- $e_{x,y}$ představují souřadnice cílového vrcholu e

Algoritmus pak následně iterativně prohledává sousední uzly již prozkoumaných vrcholů, kdy vždy vybírá vrchol s nejnižší hodnotou ohodnocovací funkce.[30]

8 Příprava řešení


Před použitím samotných systémů vizuální odometrie je zapotřebí provést kalibraci a konfiguraci použité hardwarové platformy.

8.1 Kalibrace senzorů

První krok při realizaci navrženého řešení je kalibrace senzorů, které budou využity pro navigaci. Konkrétně se jedná o kameru a inerciální jednotku. Pro provedení kalibrace parametrů byl zvolen projekt Kalibr, který obsahuje sadu nástrojů, potřebných pro kalibraci senzorů pro použití ve vizuálně-inerciální odometrii. Další výhodou tohoto projektu je export změřených parametrů ve formátu, který je možné jednoduše použít při konfiguraci běžně používaných systémů pro vizuálně-inerciální odometrii.

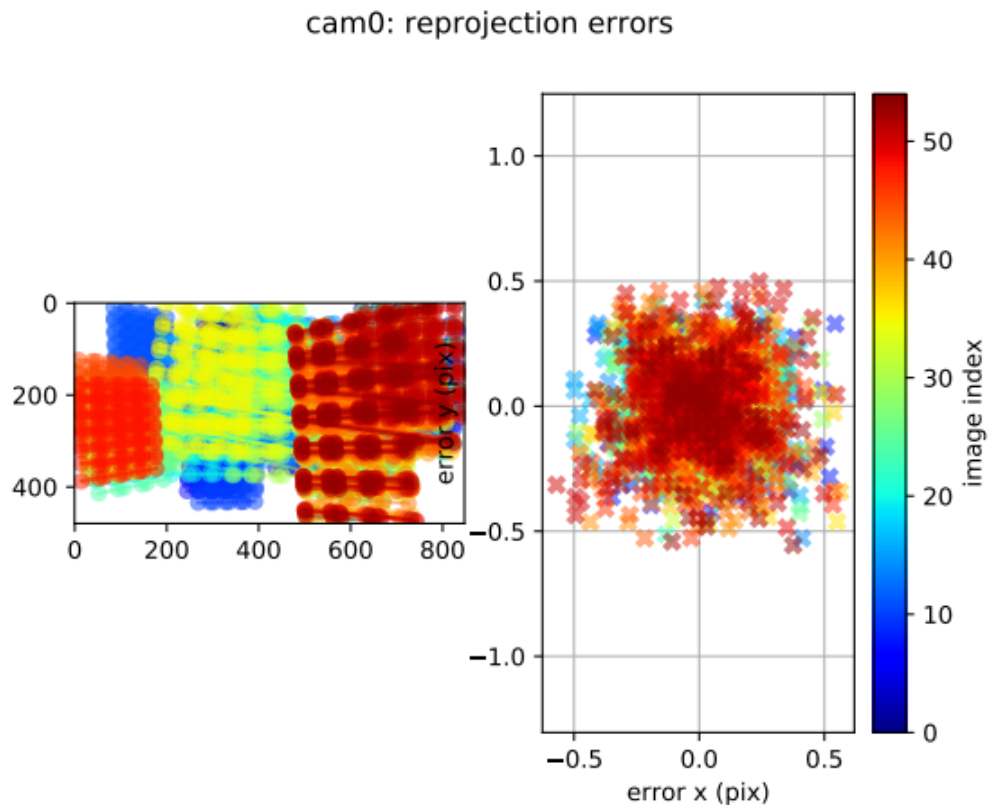
8.1.1 Kalibrace kamery

V případě kamery je zapotřebí určit ohniskovou vzdálenost a optický střed. Bez provedení kalibrace by totiž pak nebylo možné přesně určit pozici významných bodů v prostředí, a tím by docházelo ke vzniku chyby při odhadu pozice.



Obr. 8.1: Kalibrační vzor

Pro provedení kalibrace je nejdříve potřeba vytvořit kalibrační vzor. Tento již vygenerovaný vzor je možné si stáhnout z repozitáře projektu kalibr, popřípadě si vygenerovat nový dle vlastních požadavků. Výsledný vzor je vyobrazen na obrázku 8.1. Následně je potřeba tento vzor nasnímat kamerou z různých úhlů a v různých orientacích. Toho lze jednoduše dosáhnout pomocí nástroje rosbag, který dokáže vytvořit požadovaný záznam ze sensorických dat a taktéž je tento formát podporován samotnými nástroji v rámci projektu Kalibr. Závěrem je provedena kalibrace pomocí zmíněného záznamu a pomocí parametrů kalibračního vzoru.



Obr. 8.2: Přesnost kalibrace kamery z prostředí Kalibr

Po provedení kalibrace je mimo změřených parametrů taktéž vytvořena zpráva, kde je možné si správnost kalibrace ověřit. Nejlépe k tomu poslouží graf na obrázku 8.2, kde je možné vidět, že chyba zpětné projekce odhadnutých bodů kalibračního vzoru je nejvýše v okolí poloviny pixelu.

Společně s vnitřními parametry kamery je také určeno zkreslení kamery. Výsledek této kalibrace je zobrazen na výpisu 8.1.

```
cam0:
  cam_overlaps: []
  camera_model: pinhole
  distortion_coeffs: [0.2899, 0.0856, 0.2332, -0.0244]
  distortion_model: equidistant
  intrinsics: [421.4026, 423.6488, 417.0046, 235.1531]
  resolution: [848, 480]
  rostopic: /d455/color/image_raw
```

Výpis 8.1: Výsledek měření vlastností kamery

8.1.2 Kalibrace IMU

S úspěšnou kalibrací kamery je nyní možné se posunout na kalibraci inerciální jednotky. Zde je potřeba změřit míru šumu akcelerometru a gyroskopu ve všech osách. Pro změření této charakteristiky je zapotřebí získat dostatečně dlouhý záznam měření tak, aby bylo možné tyto charakteristiky určit s vysokou mírou přesnosti.

Samotné měření probíhalo po dobu jednoho dne v době, kdy se poblíž prostředku nikdo nepohyboval, tak aby nedošlo ke zkreslení výsledků v důsledku vibrací z pohybu osob. Data z IMU jednotky, která je součástí řídicí jednotky bezpilotního prostředku, byla přenášena do prostředí ROS pomocí balíčku mavros a zaznamenávána pomocí nástroje rosbag. Zaznamenávána byla nezpracovaná data, aby bylo možné provést požadovanou analýzu.

Výsledná analýza byla provedena pomocí nástroje Kalibr, jejímž výstupem jsou šumové charakteristiky gyroskopu a akcelerometru. Výstupní formát je zobrazen na výpisu 8.2.

```
#Accelerometer
accelerometer_noise_density: 0.018599691924157194
accelerometer_random_walk: 6.831626921231633e-04

#Gyroscope
gyroscope_noise_density: 5.560880116994105e-05
gyroscope_random_walk: 1.114968684480172e-06

rostopic: '/mavros/imu/data_raw'
update_rate: 200.0
```

Výpis 8.2: Výsledek měření vlastností IMU

8.1.3 Kalibrace vazby IMU-kamera

Posledním krokem kalibrace sensorického vybavení bylo provedení kalibrace vztahu mezi IMU a kamerou. Konkrétně je hlavním cílem zjistit vzájemnou transformaci mezi souřadnicovými systémy těchto dvou komponent. Mimo to je také cílem změřit časový posun mezi měřením IMU jednotky a pořízením snímku kamerou. Průběh této kalibrace je obdobný procesu kamery, kdy je potřeba provést sérii pohybů, kde kamera snímá kalibrační vzor. Tentokrát jsou zaznamenávána i data z IMU jednotky mimo samotných snímků z kamery.

Provedení této kalibrace je rovněž umožněno nástrojem Kalibr, kde je mimo samotné transformace a časového zpoždění také ověřována platnost kalibrace šumových vlastností IMU jednotky. Výsledek kalibrace je zobrazen na výpisu 8.3.

```
cam0:
  T_cam_imu:
  - [0.0250, -0.9997, 0.0045, 0.0522]
  - [-0.8263, -0.0231, -0.5628, -0.0760]
  - [0.5627, 0.0104, -0.8266, 0.0414]
  - [0.0, 0.0, 0.0, 1.0]
  cam_overlaps: []
  camera_model: pinhole
  distortion_coeffs: [0.2899, 0.0856, 0.2332, -0.0244]
  distortion_model: equidistant
  intrinsics: [421.4026, 423.6488, 417.0046, 235.1531]
  resolution: [848, 480]
  rostopic: /d455/color/image_raw
  timeshift_cam_imu: 0.0062
```


Výpis 8.3: Výsledek kalibrace vazby IMU-kamera

8.2 Konfigurace řídicí jednotky

Poslední krok k realizaci navigačního řešení se týká samotné řídicí jednotky bezpilotního prostředku. Před samotnou konfigurací je zde potřeba zvolit řídicí systém pro řízení celého prostředku, který zajišťuje stabilizaci a veškeré funkce spojené se samotným letem.

Řídicí systém lze volit ze dvou možností. První možností je systém PX4, který nabízí řadu pokročilých funkcí pro autonomní létání. Jedná se o open-source systém vyvíjený rozsáhlou komunitou vývojářů. PX4 podporuje velké množství hardwarových platforem a nabízí možnost použití od multikoptér až po letouny. Okolo tohoto systému existuje také velké množství nástrojů pro simulaci.

Druhou možností je systém Ardupilot, který je taktéž vyvíjen komunitou v režimu open-source. Tento systém je možné použít nejen na létající prostředky, ale také na pozemní vozidla a dokonce i ponorky. Přehled možných konfigurací je vyobrazen na obrázku 8.3. V porovnání s PX4 avšak okolo tohoto systému není takové množství doprovodných nástrojů.



Obr. 8.3: Dostupné hardwarové konfigurace systému Ardupilot

Oba systémy podporují protokol MAVLink, pomocí kterého lze s řídicí jednotkou jednoduše komunikovat a vyčítat z ní relevantní informace. Hlavní výhodou systému Ardupilot oproti PX4, která je relevantní pro tuto práci, je větší možnost konfigurace systému bez nutnosti měnit zdrojový kód a sestavovat systém manuálně.

Systém Ardupilot umožňuje manuální konfiguraci zdrojů dat pro stavový estimátor, díky čemuž je možné jednoduše nakonfigurovat řídicí jednotku tak, aby využívala data, která se jí posílají z výpočetní jednotky. Pro správnou konfiguraci je potřeba zvolit estimátor, který podporuje externí vstup, nastavením parametrů dle tabulky 8.1.

Parametr	Hodnota	Vysvětlení
EK3_ENABLE	1	Aktivace EKF3
EK2_ENABLE	0	Deaktivace EKF2
AHRS_EKF_TYPE	3	Zvolení použití EKF3
EK3_SRC_OPTIONS	0	Umožnění přepínání zdroje dat automaticky
VISO_TYPE	1	Přenos pozice pomocí MAVLink
RC8_OPTION	90	Přepínání zdroje EKF pomocí RC8

Tab. 8.1: Obecné parametry systému Arducopter

Následně je jen potřeba zvolit požadované primární a záložní datové zdroje. Zde konkrétně se primárně používá GPS a v případě výpadku je použit externí zdroj,

tedy vizuální navigace. Mezi těmito zdroji lze také manuálně přepínat pomocí definovaného kanálu na vysílače. Příslušné parametry jsou uvedeny v tabulce 8.2.

Parametr	Hodnota	Vysvětlení
EK3_SRC1_POSXY	3	Pozice z GPS
EK3_SRC1_VELXY	3	Rychlost z GPS
EK3_SRC1_POSZ	1	Výška z barometru
EK3_SRC1_VELZ	3	Rychlost z GPS
EK3_SRC1_YAW	1	Azimut z kompasu
EK3_SRC2_POSXY	6	Pozice z externího zdroje
EK3_SRC2_VELXY	0	Externí zdroj neposkytuje informaci o rychlosti
EK3_SRC2_POSZ	6	Výška z externího zdroje
EK3_SRC2_VELZ	0	Externí zdroj neposkytuje informaci o rychlosti
EK3_SRC2_YAW	1	Azimut z kompasu


Tab. 8.2: Nastavení vstupů EKF

9 Vyhodnocení

V rámci této kapitoly je provedeno vyhodnocení jednotlivých dílčích testů, které byly provedeny na základě nasnímaných sensorických dat.

9.1 Vizuální odometrie


Prvním cílem testování bylo vyhodnocení a porovnání systémů vizuální odometrie ve venkovních podmínkách. Za tímto účelem byla bezpilotnímu prostředku naplánována trajektorie, kterou má sledovat. Tento plán a dodatečné sledování telemetrických údajů bylo dosaženo za pomoci programu Mission Planner. Samotná trajektorie je ve tvaru smyčky pro vyhodnocení akumulace driftu pozičního odhadu. Zobrazení této trajektorie je možné nalézt na obrázku 9.1.



Obr. 9.1: Plán trajektorie

Jedním z cílů testování bylo provedení vyhodnocení vlivu výšky nad povrchem na kvalitu odhadu pozice. Za tímto účelem byly zvoleny tři letové hladiny 5 m, 10 m a 30 m. Během letu byl prováděn záznam veškerých sensorických dat a telemetrických dat ze samotného prostředku pomocí nástroje rosbag. Díky tomuto je možné následně zpětně přehrát data systému vizuální odometrie a provést takto vyhodnocení až po dokončení letu. Hlavním přínosem tohoto přístupu je možnost porovnání všech systémů za naprosto shodných podmínek. Jako referenční pozice je použit vnitřní odhad pozice bezpilotního prostředku, který je založen na fúzi dat ze satelitní navigace a IMU jednotky. Tento odhad je možné získat v tzv. lokálním referenčním systému. Tento systém využívá kartézských souřadnic s počátkem v bodě vzletu, tudíž není potřeba dodatečných převodů souřadnicového systému.

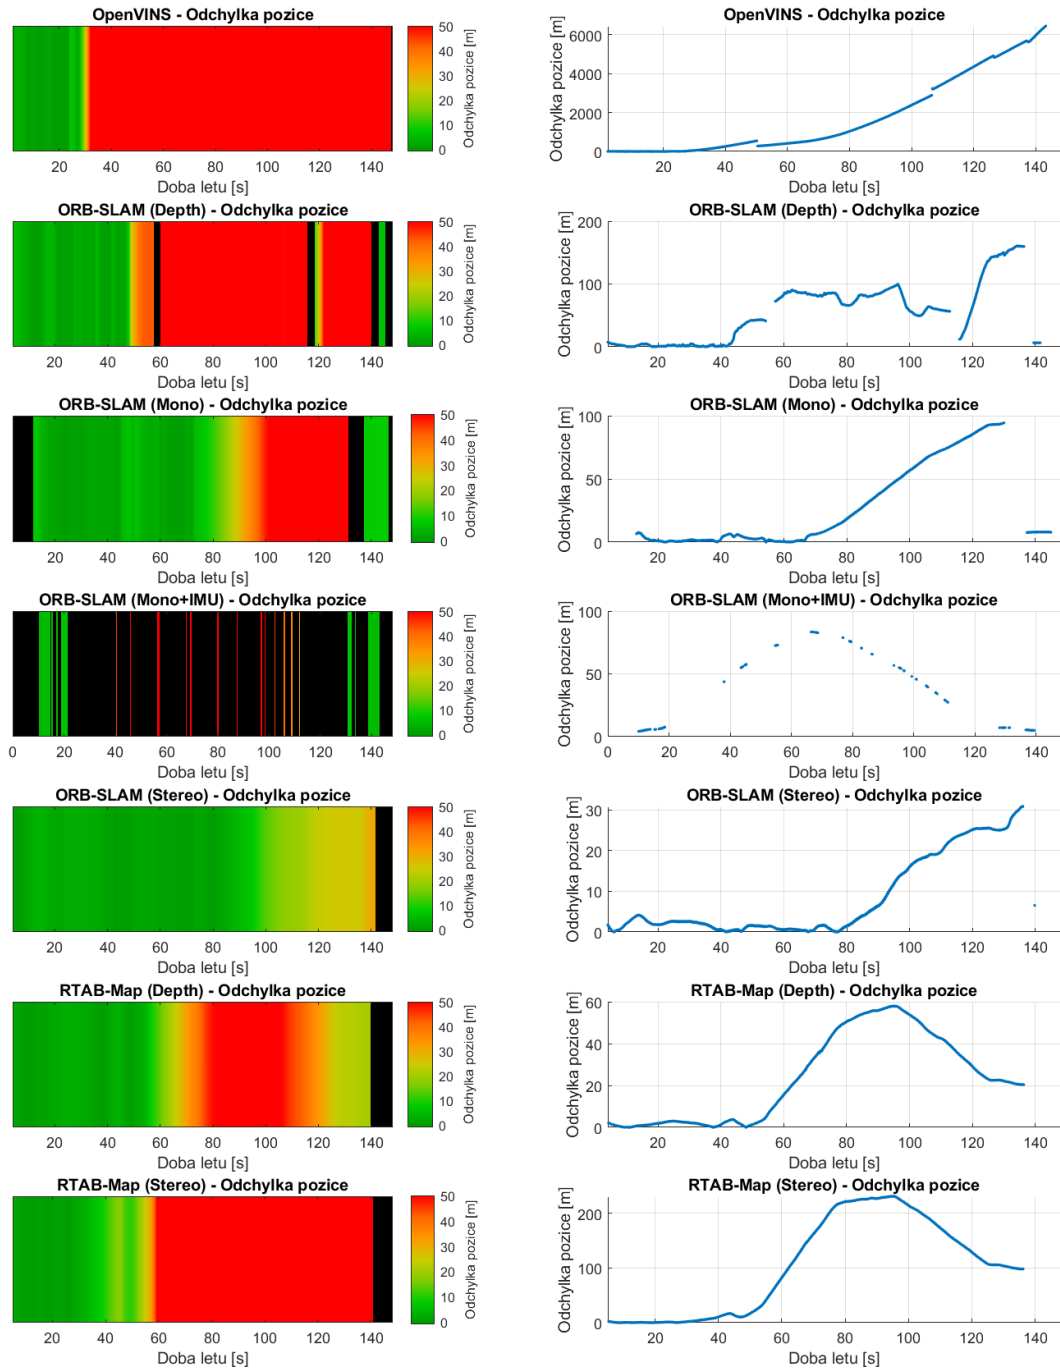
Metrika pro určení přesnosti sledování trajektorie je Euklidovská vzdálenost mezi odhadovanou pozicí a referenční pozicí. Avšak před provedením tohoto vyhodnocení je potřeba provést synchronizaci souřadnicových systémů, které využívají jednotlivé systémy vizuální odometry, s referenčním systémem. Z tohoto důvodu je využita část počátku trajektorie k určení nejvhodnější transformace. Nepříznivým vlivem této transformace je ten, že část dat, která byla použita k odhadu transformace, nelze použít k vyhodnocení přesnosti, jelikož jsou odchylky minimalizovány během provádění odhadu. Aby byl tento nepříznivý vliv minimalizován, tak je využita pouze malá část počátku trajektorie, kde je proveden pohyb alespoň ve dvou osách, aby byla transformace jednoznačná. Ilustrace výsledku tohoto procesu je na obrázku 9.2.



Obr. 9.2: Ilustrace transformace souřadnic

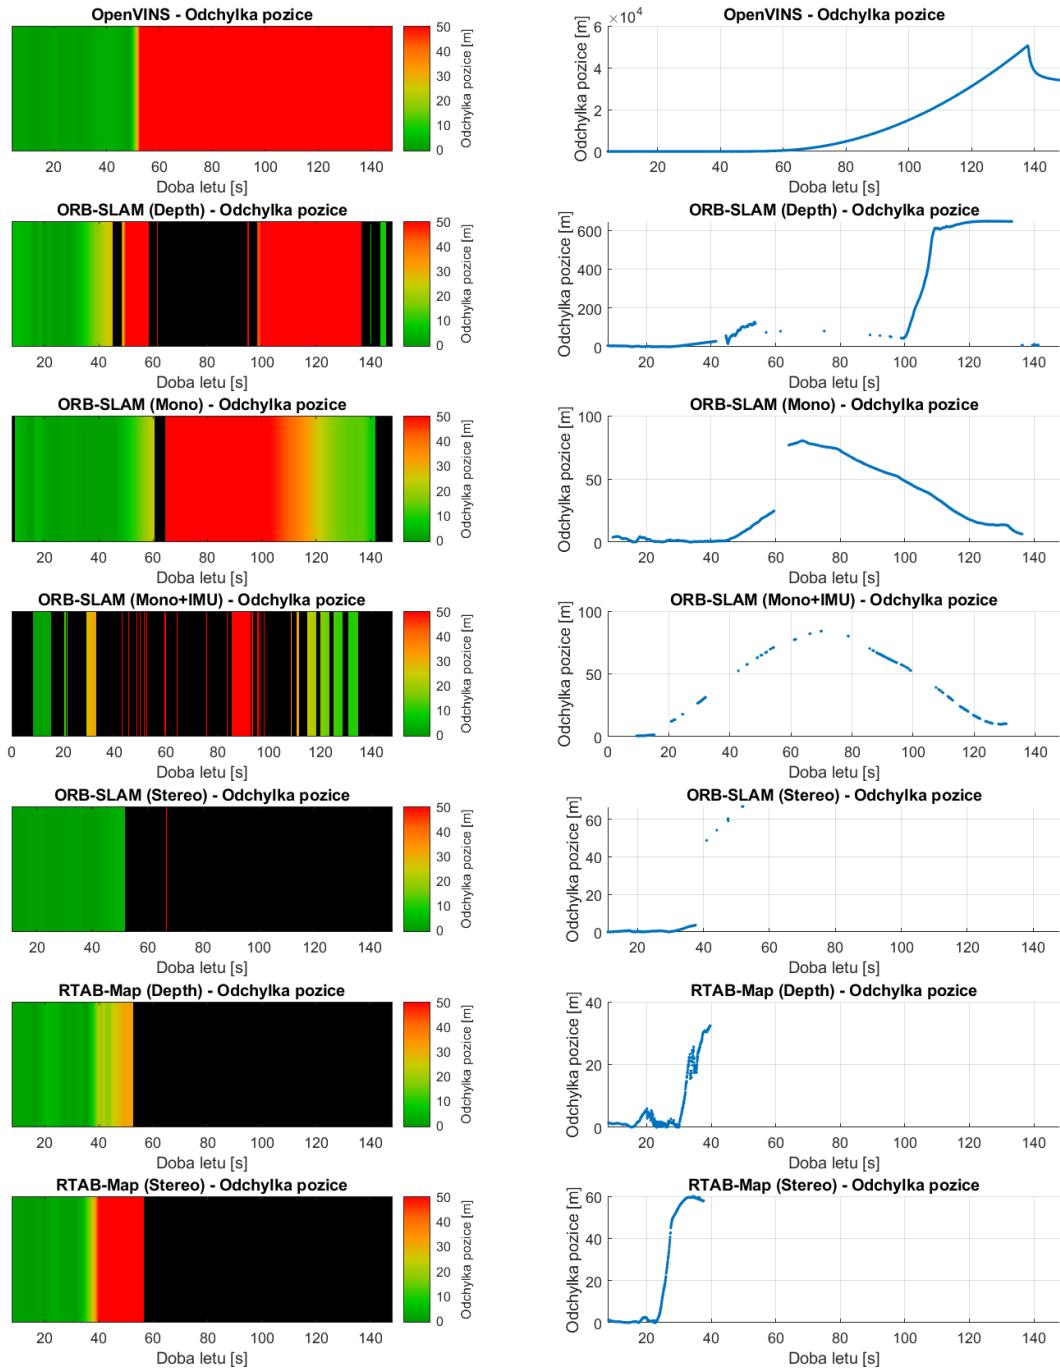
Samotný let byl proveden ve třech zvolených letových výškách v rámci jednoho dne v odpoledních hodinách. Během letu byla přítomna mírná oblačnost a poryvy větru nepřesahovaly 2 m/s. Po nasnímání byla data následně vyhodnocena. Samotné vyhodnocení probíhalo přímo na výpočetní jednotce, která je přítomna na prostředku, tudíž byla výpočetní kapacita shodná s podmínkami, které by nastaly, pokud by byl odhad pozice prováděn za letu v reálném čase.

Vyhodnocení letu 5m



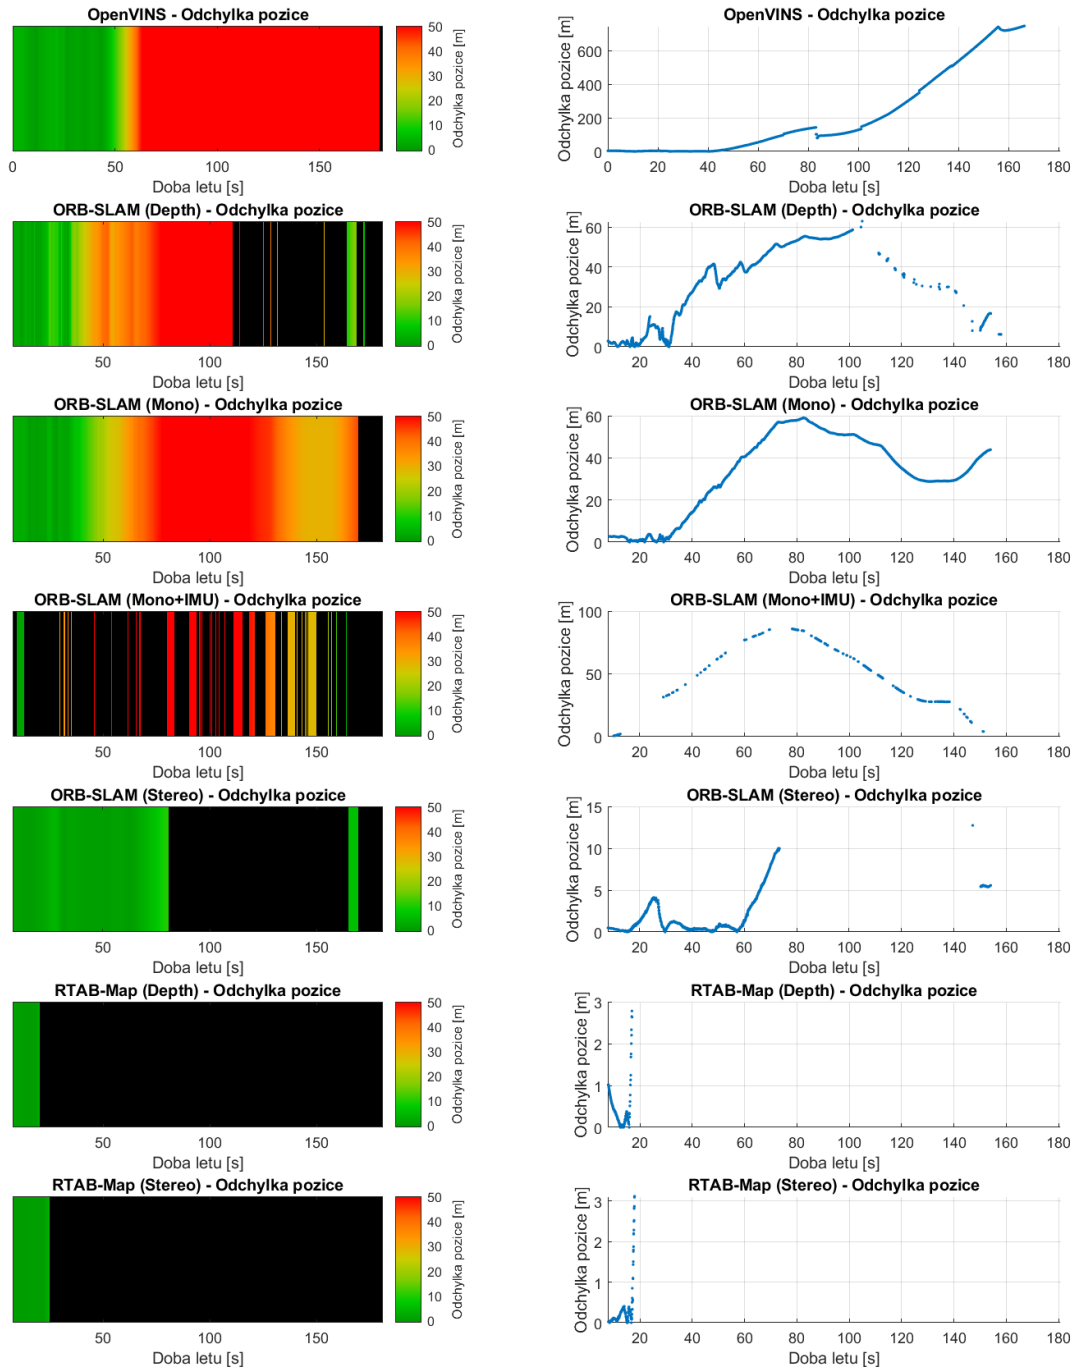
Obr. 9.3: Vyhodnocení letové hladiny 5 m

Vyhodnocení letu 10m



Obr. 9.4: Vyhodnocení letové hladiny 10 m

Vyhodnocení letu 30m

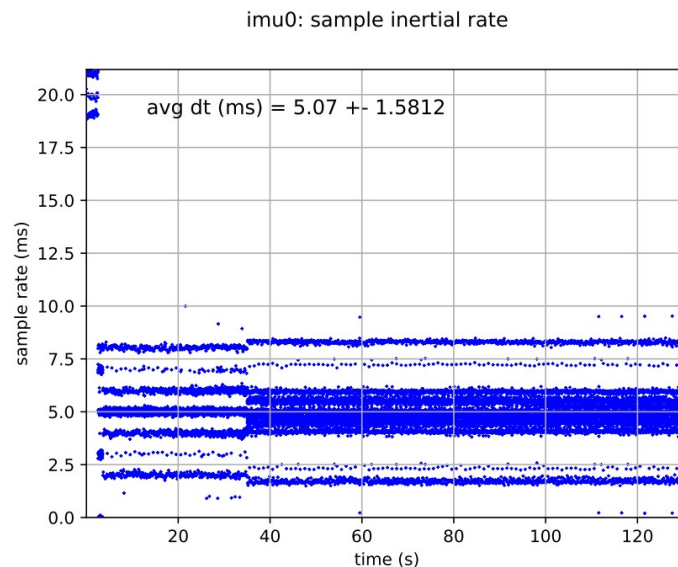


Obr. 9.5: Vyhodnocení letové hladiny 30 m

Výsledky provedených testů jsou zobrazeny na obrázcích 9.3, 9.4 a 9.5, kde každý přísluší jednomu letu v dané letové hladině. Pro jednodušší orientaci a přehlednost je odchylka od referenční pozice reprezentována jednak pomocí barevné škály, tak také pomocí běžného grafu pro odečtení hodnot. V rámci barevné škály je taktéž reprezentováno černou barvou období, kdy byl odhad pozice ztracen. Toto se projevilo tak, že daný systém vizuální odometrie určil pozici v počátku souřadnic. Výjimkou tohoto chování je systém OpenVINS, u kterého dochází k selhání ve formě přiřazení velkého významu měřením z IMU jednotky, kdy následně dojde k potlačení významu vizuálních dat a odhad pozice se stává zcela neplatným.

Na první pohled je možné vyvodit, že výška nad terénem značně negativně ovlivňuje samotný odhad pozice napříč různými systémy. Zatímco v letové hladině 5 m většina systémů i přes značně chybný odhad stále provádí svou činnost, v případě vyšších letových hladin pak již systémy z větší části selhávají. K selhání dochází konkrétně u systémů, které využívají stereo kameru. Toto platí i pro systémy využívající hloubkový obraz, jelikož ten je vnitřně taktéž vytvářen pomocí páru kamer. Toto chování je očekávatelné, kdy dochází k tomu, že jsou významné body příliš daleko od samotné kamery a vzdálenost kamer v rámci stereo páru není dostatečná k jejich přesné triangulaci.

Tímto problémem netrpí systém ORB-SLAM v režimu mono kamery, kdy je pozice významných bodů odhadována z pohybu, a tudíž dokáže produkovat odhad během celého letu napříč letovými hladinami. Avšak tento odhad je značně nepřesný a pro řízení bezpilotního prostředku jej nelze použít.



Obr. 9.6: Analýza časování dat IMU jednotky

Z dat je taktéž patrné, že systém ORB-SLAM ve vizuálně inerciálním režimu nebyl schopen provést odhad pozice nezávisle na výšce v kontrastu se systémem OpenVINS, který taktéž operuje ve vizuálně inerciálním režimu a který byl alespoň z části schopen sledování poziční reference. Pro hlubší analýzu byl využit nástroj Kalibr, pomocí kterého bylo možné analyzovat data z IMU jednotky během letu. Pomocí tohoto nástroje bylo možné analyzovat časování zpráv a výsledek této analýzy je zobrazen na obrázku 9.6. Z tohoto grafu je možné pozorovat značné nekonzistentní časování měření, které může být příčinou selhání. Taktéž je možné se na základě těchto dat domnívat, že je systém OpenVINS robustnější vůči této formě chyby.

Příčina tohoto problému s časováním pravděpodobně leží v samotném přenosu dat z řídicí jednotky do systému ROS. Jelikož řídicí jednotka obsahuje tři IMU jednotky, které jsou využívány k aktivní stabilizaci letu, je důvodné se domnívat, že při samotném měření dat k problému nedochází.

Z veškerých kombinací systémů a letových hladin pouze jeden systém byl schopen provádět platný odhad pozice po celou dobu letu. Tímto systémem je ORB-SLAM v režimu stereo kamery při výšce 5 m. Z tohoto důvodu byl zvolen jako nejvhodnější kandidát pro nasazení s limitací letové výšky.

9.2 Absolutní vizuální lokalizace

Druhým cílem testování bylo vyhodnocení využitelnosti absolutní vizuální lokalizace ve vnějším prostředí. Aby bylo možné toto vyhodnocení provést, bylo potřeba nasbírat data vhodná k tomuto účelu. Konkrétně se jedná o záznam z kamery, která je namířena kolmo k povrchu. K tomuto sběru nebylo vhodné použít platformy, jako v případě vizuální odometrie, jelikož je zde kamera pevně umístěna a náklony prostředku by vnášely do procesu lokalizace chyby v důsledku zkreslení. Z tohoto důvodu byla využita multikoptéra DJI Mini 3 Pro. Tento prostředek disponuje stabilizovanou kamerou pomocí gimbálu, tudíž je možné provádět záznam bez větších vlivů v důsledku náklonu prostředku.

Aby bylo možné absolutní lokalizaci provádět, je zapotřebí mít snímek, který zabírá co největší plochu, což zvyšuje šanci na provedení úspěšné lokalizace vůči mapovému podkladu. Toho lze dosáhnout letem ve vyšší výšce. Z tohoto důvodu bylo cílem provést let ve 100 m nad terénem pro zajištění dostatečného množství unikátních příznaků pro provedení lokalizace. Dále bylo žádoucí, aby nasnímaná trajektorie zahrnovala oblasti s rozdílným množstvím významných bodů, aby bylo možné vyhodnotit úspěšnost napříč rozmanitým prostředím. Z tohoto důvodu trasa obsahuje ze začátku křížovanku s částečnou zástavbou, která představuje prostředí vhodné pro lokalizaci. Dále následuje část s malou mírou významných bodů, ve které

je očekáváno selhání lokalizace a závěrem se v záběru objevuje zatáčka cyklostezky, pomocí které by mělo být možné lokalizaci provést. Lokace provádění tohoto letu bylo letiště Čebín. Samotná provedená letová trajektorie je zobrazena na obrázku 9.7.



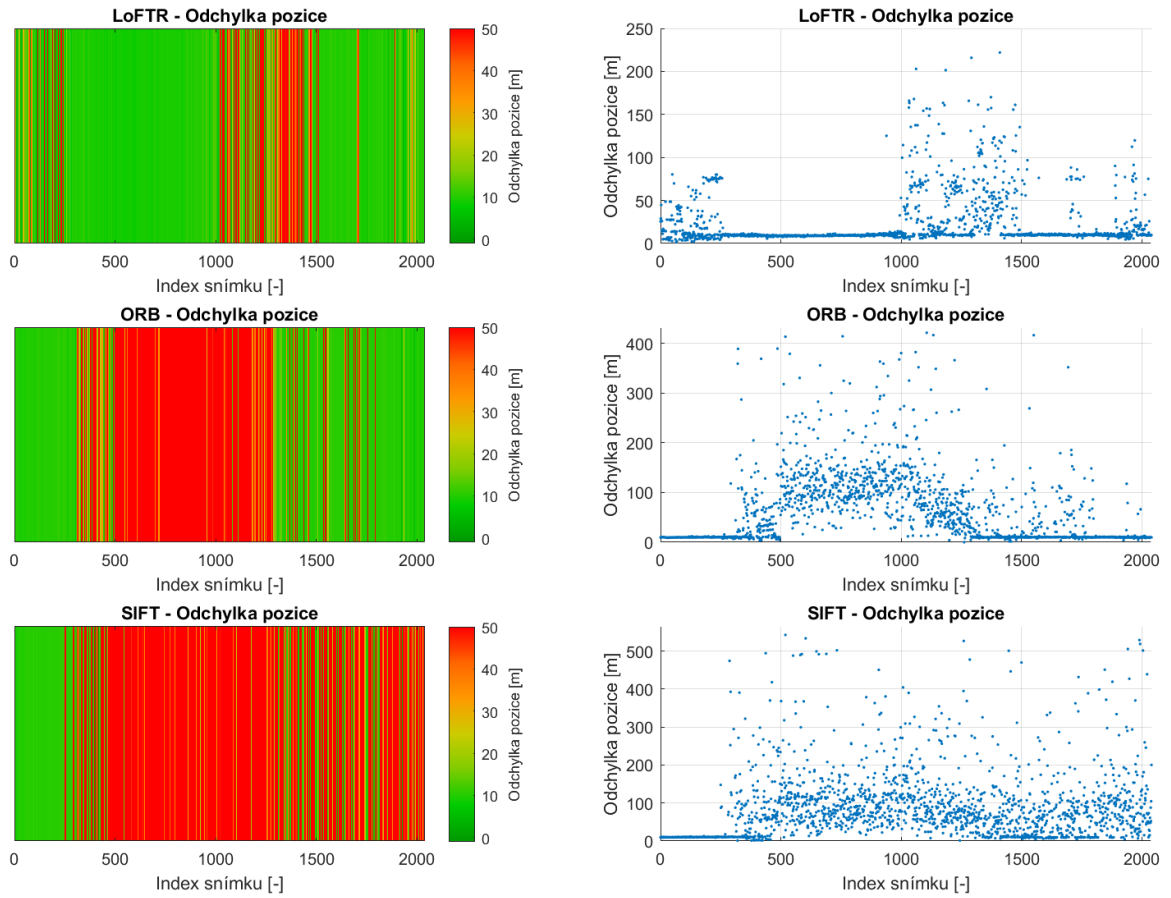
Obr. 9.7: Letová trajektorie

Výstupem provedeného letu byl videozáznam z palubní kamery společně se souborem, který v sobě obsahoval metadata k jednotlivým snímkům záznamu, která mimo jiné obsahovala i souřadnice pořízení. Následně byl pro každý snímek vytvořen mapový podklad a byl proveden pokus o lokalizaci pomocí algoritmů relevantních pro AVL s výjimkou metody template matching, jelikož není možné určit azimut bezpilotního prostředku, tudíž není také možné provést patřičnou rotaci, bez které není možné získat touto metodou relevantní data. Ilustraci z tohoto procesu s algoritmem ORB je možné nalézt na obrázku 9.8.



Obr. 9.8: Filtrované korespondence určené algoritmem ORB

Vyhodnocení algoritmů AVL



Obr. 9.9: Vyhodnocení algoritmů pro AVL

Výsledná úspěšnost lokalizace jednotlivých algoritmů je zobrazena na obrázku 9.9. Z výsledků je patrné, že jednotlivé algoritmy dosahovaly rozdílných úspěšností. V případě algoritmu SIFT byla úspěšně provedena lokalizace v počátku záznamu, kde bylo možné nalézt dostatečné množství významných bodů, avšak v následujících oblastech obsahující převážně travnatý povrch a pole již k úspěšné lokalizaci nedošlo, a to ani v závěru, kde je v záběru přítomna zatáčka cyklostezky. Algoritmus ORB dosahoval obdobných výsledků, jako algoritmus SIFT s tím rozdílem, že dokázal provést úspěšnou lokalizaci i v závěru trasy. Nejlepších výsledků dosahoval algoritmus LoFTR, který dokázal úspěšně provést lokalizaci po značnou část cesty, a to i v oblastech, kde tradiční algoritmy selhávaly. Z tohoto důvodu se jeví jako velice vhodný kandidát pro absolutní vizuální lokalizaci.


9.3 Plánování trasy

Dalším předmětem vyhodnocení bylo plánování trasy pro bezpilotní prostředek, který ke své navigaci využívá vizuální odometrii. K tomuto testu nebylo potřeba provést sběr sensorických dat, jelikož se tato část opírá čistě o mapové podklady. K ověření funkčnosti bylo zapotřebí zvolit prostředí, ve kterém se nachází značné oblasti s nedostatkem významných bodů. Tuto charakteristiku vykazují vodní plochy, kterým je i z praktických důvodů vhodné se vyhnout. Na základě této úvahy byl pro ověření funkčnosti zvolen přelet přes část Brněnské přehrady. Samotné prostředí a místa, mezi kterými je trasa hledána, jsou zobrazeny na obrázku 9.10.



Obr. 9.10: Prostředí pro test plánování s párem vyznačených pozic

Samotné plánování určuje vhodnost prostředí podle množství detekovaných významných bodů algoritmem FAST, jež je součástí algoritmu ORB, se kterým je možné se v rámci vizuální odometrie setkat. Samotné vyhodnocování probíhá jen dle potřeby, jak je mapa prohledávána, avšak pro ilustrační účely bylo provedeno vyhodnocení celé oblasti. To je vyobrazeno na obrázku 9.11, kde vyšší úroveň červeného zbarvení určuje menší vhodnost terénu k navigaci pomocí systémů vizuální odometrie.



Obr. 9.11: Odhad vhodnosti terénu pro vizuální odometrii

Výsledná trasa je vyznačená na obrázku 9.12. Je patrné, že se výsledná trasa vyhýbá hlavní nepříznivé oblasti, která je tvořena vodní plochou. Tato trasa je delší oproti přímé trase, která by spojila tyto dva body přímkou, avšak pro potřeby vizuální navigace a taktéž praktické potřeby provozu bezpilotního prostředku je naplánovaná trasa vhodnější.



Obr. 9.12: Výsledná naplánovaná trasa

9.4 Nasazení na bezpilotní prostředek

Poslední test spočíval v ověření správnosti propojení systému vizuální odometrie se samostatným bezpilotním prostředkem. Cílem bylo uskutečnit pohyb bezpilotního prostředku bez využití satelitní navigace, kdy je pozice dodávána zvoleným systémem vizuální odometrie. Na základě předešlého testování byl zvolen systém ORB-SLAM v režimu stereo, který vykazoval nejslibnější výsledky.

Testování probíhalo za ztížených podmínek, kdy byly přítomny značné nárazy větru, které samotné testování ztěžovaly. Samotný test započal nejdříve sérií pohybů, aby bylo následně možné provést synchronizaci souřadnic systému vizuální odometrie a referenční pozice prostředku. Tento krok byl ztěžován právě zmíněnými poryvy větru, kdy nebylo možné měnit pozici prostředku hladce. Po provedení série pohybů byla provedena synchronizace a následná změna vstupu pozice do řídicí jednotky prostředku pomocí vysílačky. Následně byl proveden pohyb vpřed, kdy jednotka využívala pouze dodávaná poziční data. Koncem tohoto pohybu docházelo k nepřesnosti odhadu výšky nad terénem. Z tohoto důvodu byl pokus následně ukončen. Výsledná trajektorie je zobrazena na obrázku 9.13.



Obr. 9.13: Trajektorie reálného testu

Tento test i přes nastalé komplikace ověřil možnost přepínání mezi satelitní pozicí a vizuální odometrií při zachování veškerých funkcí bezpilotního prostředku.

Závěr

Cílem této diplomové práce bylo navrhnout a realizovat navigační systém pro bezpilotní letadlo, který bude schopen operovat i s částečnou nedostupností globálních navigačních systémů. V rámci této práce byla nejdříve provedena rešerše současných přístupů k navigaci bez využití satelitních systémů, přičemž největší důraz byl kladen na vizuální odometrii a absolutní vizuální lokalizaci, které se jeví jako nejvíce vhodná řešení pro nasazení ve venkovním prostředí. Následně byl proveden přehled hardwarového vybavení, pomocí kterého by bylo možné nalezených přístupů využít.

Následně byla provedena rešerše dostupných systémů, které se problematikou vizuální navigace zabývají. Na základě této rešerše byly zvoleny tři systémy pro vizuální odometrii, kde každý systém nabízel různé možnosti. Konkrétně se jednalo o systém OpenVINS, RTAB-Map a ORB-SLAM. Aby bylo možné těchto systémů využít, byl proveden návrh řešení v rámci prostředí ROS, které umožňuje propojení jednotlivých testovaných systémů s příslušnými senzorickými daty a také se samotnou řídicí jednotkou bezpilotního prostředku. Významnou součástí tohoto řešení byl návrh systému pro synchronizaci souřadnicových systémů bezpilotního prostředku a systémů vizuální odometrie, který na základě množiny pozičních párů byl schopen odhadnout vhodnou transformaci mezi těmito souřadnicovými systémy.

Mimo samotné použití systémů vizuální odometrie byla věnována pozornost problematice absolutní vizuální lokalizace. Cílem tohoto úsilí bylo provedení ověření, zda-li je možné tento systém realizovat a využít jej k kompenzaci akumulovaného driftu, který během provozu vizuální odometrie nevyhnutelně vzniká. Za tímto účelem byl realizován systém, který na základě mapových podkladů a snímku z bezpilotního prostředku provede lokalizaci v dané mapě a pokusí se tak určit pozici samotného prostředku, a tím eliminovat naakumulovaný drift.

Poslední navrženou součástí je plánovací systém, jehož cílem je plánování tras pro bezpilotní prostředky s ohledem na požadavky a omezení plynoucí z používání systémů vizuální odometrie. Konkrétně se jedná o množství významných bodů, které se v prostředí nachází, kdy je žádoucí, aby se prostředek vyhýbal oblastem, kde těchto významných bodů s vysokou pravděpodobností mnoho nebude. Příkladem takového prostředí je pohyb nad vodními plochami.

Po provedení návrhu byla provedena kalibrace senzorického vybavení prostředku, konkrétně se jednalo o zjištění parametrů kamerového systému a IMU jednotky bezpilotního prostředku tak, aby bylo možné vhodně nakonfigurovat jednotlivé systémy vizuální odometrie. Následně pak byla provedena konfigurace samotné letové řídicí jednotky za účelem umožnění příjmu pozičních dat z nadřazeného systému, kterým bylo navržené řešení v prostředí ROS.

Závěrem práce bylo provedeno testování navrženého systému ve venkovním prostředí. První část testování se zaměřila na využitelnost zvolených systémů vizuální odometrie. Toto testování bylo prováděno napříč několika letovými hladinami, aby bylo možné zjistit, jakou roli hraje letová výška nad terénem. Výsledky tohoto testování ukázaly, že je použití systémů vizuální odometrie v rámci bezpilotního prostředku ve vnějším prostředí značně omezené, kdy pouze jeden systém byl schopen sledovat celou trajektorii, kterou prostředek uletěl. Konkrétně se jednalo o systém ORB-SLAM v režimu stereo.

Druhá část si kladla za cíl nalézt vhodný algoritmus pro provádění absolutní vizuální lokalizace. Za tímto účelem byl proveden let v dostatečné výšce, aby tato lokalizace byla umožněna. Vyhodnocovány byly dva algoritmy založené na detekci a popisu příznaků, konkrétně algoritmus SIFT a ORB. Mimo to byl také vyhodnocován jeden algoritmus založený na strojovém učení zvaný LoFTR. Po provedení vyhodnocení bylo usouzeno, že nejvhodnějším algoritmem pro provádění absolutní vizuální lokalizace je právě algoritmus LoFTR. Tímto bylo ověřeno, že provádění absolutní vizuální lokalizace za účelem snížení je na palubě bezpilotního prostředku možné. Mimo samotnou vizuální lokalizaci byla ověřena funkčnost plánovacího řešení, které našlo vhodnou trasu v prostředí, kde se vyskytují oblasti nepříznivé pro provoz vizuální odometrie.

V rámci poslední části testování navrženého systému byl proveden test přímo na samotné palubě bezpilotního prostředku, kde bylo cílem ověřit možnost přepínání mezi zdroji pozičních dat. V důsledku nepříznivých povětrnostních podmínek bylo toto testování omezené, avšak i přes tento nepříznivý vliv bylo možné ověřit použitelnost systému vizuální odometrie v reálném čase v rámci bezpilotního prostředku.

Literatura

- [1] Chang, Y., Cheng, Y., Manzoor, U., Murray, J. (2023). *A review of UAV autonomous navigation in GPS-denied environments*. Robotics and Autonomous Systems, 104533. Dostupné z: <https://doi.org/10.1016/j.robot.2023.104533>. [cit. 2024-11-20].
- [2] Carrio, A., Sampedro, C., Rodriguez-Ramos, A., Campoy, P. (2017). *A Review of Deep Learning Methods and Applications for Unmanned Aerial Vehicles*. Journal of Sensors, 2017, 1–13. Dostupné z: <https://doi.org/10.1155/2017/3296874>. [cit. 2024-11-20].
- [3] LOQUERCIO, Antonio; MAQUEDA, Ana I.; DEL-BLANCO, Carlos R. a SCARAMUZZA, Davide. *DroNet: Learning to Fly by Driving*. IEEE Robotics and Automation Letters. 2018, roč. 3, č. 2, s. 1088-1095. ISSN 2377-3766. Dostupné z: <https://doi.org/10.1109/LRA.2018.2795643>. [cit. 2024-11-21].
- [4] PALOSSO, Daniele; CONTI, Francesco a BENINI, Luca. *An Open Source and Open Hardware Deep Learning-Powered Visual Navigation Engine for Autonomous Nano-UAVs*. 15th International Conference on Distributed Computing in Sensor Systems (DCOSS). IEEE, 2019, s. 604-611. ISBN 978-1-7281-0570-3. Dostupné z: <https://doi.org/10.1109/DCOSS.2019.00111>. [cit. 2024-11-21].
- [5] TEMIZER, Selim. *Optical flow based robot navigation*. Dostupné z: https://people.csail.mit.edu/lpk/mars/temizer_2001/Optical_Flow/. [cit. 2024-11-23].
- [6] Yoo, Dong-Wan, Dae-Yeon Won a Min-Jea Tahk. *Optical Flow Based Collision Avoidance of Multi-Rotor UAVs in Urban Environments*. International Journal of Aeronautical and Space Sciences, vol. 12, no. 3. The Korean Society for Aeronautical & Space Sciences, pp. 252–259, 2011 Dostupné z: <https://doi.org/10.5139/IJASS.2011.12.3.252>. [cit. 2024-11-23].
- [7] MENG GUANGLEI a PAN HAIBING. *The application of ultrasonic sensor in the obstacle avoidance of quad-rotor UAV*. IEEE Chinese Guidance, Navigation and Control Conference (CGNCC). IEEE, 2016, s. 976-981. ISBN 978-1-4673-8318-9. Dostupné z: <https://doi.org/10.1109/CGNCC.2016.7828918>. [cit. 2024-11-26].
- [8] KOURIS, Alexandros a BOUGANIS, Christos-Savvas. *Learning to Fly by My-Self: A Self-Supervised CNN-Based Approach for Autonomous Navigation*. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).

- IEEE, 2018, s. 1-9. ISBN 978-1-5386-8094-0. Dostupné z: <https://doi.org/10.1109/IRoS.2018.8594204>. [cit. 2024-11-26].
- [9] MOFFATT, Andrew; PLATT, Eric; MONDRAGON, Brandon; KWOK, Aaron; URYEU, Dennis et al. *Obstacle Detection and Avoidance System for Small UAVs using a LiDAR*. 2020 International Conference on Unmanned Aircraft Systems (ICUAS). IEEE, 2020, s. 633-640. ISBN 978-1-7281-4278-4. Dostupné z: <https://doi.org/10.1109/ICUAS48674.2020.9213897>. [cit. 2024-11-29].
- [10] Couturier, A. a Akhloufi, M. A. *A review on absolute visual localization for UAV*. Robotics and Autonomous Systems, 135, 103666. Dostupné z: <https://doi.org/10.1016/j.robot.2020.103666>. [cit. 2024-11-29].
- [11] Dawadee, A., Chahl, J. a Nandagopal, D. *An Algorithm for Autonomous Aerial Navigation Using Landmarks*. Journal of Aerospace Engineering, 29(3), 04015072. Dostupné z: [https://doi.org/10.1061/\(asce\)as.1943-5525.0000554](https://doi.org/10.1061/(asce)as.1943-5525.0000554). [cit. 2024-11-29].
- [12] Ukida, H. *Indoor Unmanned Aerial Vehicle Navigation System Using LED Panels and QR Codes*. Journal of Robotics and Mechatronics, 33(2), 242–253. Dostupné z: <https://doi.org/10.20965/jrm.2021.p0242>. [cit. 2024-11-29].
- [13] ZHOU, Qiang a LIU, Guangcai. *UAV Path Planning Based on the Combination of A-star Algorithm and RRT-star Algorithm*. 2022 IEEE International Conference on Unmanned Systems (ICUS). IEEE, 2022, s. 146-151. ISBN 978-1-6654-8456-5 Dostupné z: <https://doi.org/10.1109/ICUS55513.2022.9986703>. [cit. 2024-11-29].
- [14] *Rolling Shutter vs Global Shutter sCMOS Camera Mode- Oxford Instruments*. Oxford Instruments Dostupné z: <https://andor.oxinst.com/learning/view/article/rolling-and-global-shutter>. [cit. 2024-11-29].
- [15] Palm N. *Rolling shutter in feature-based Visual-SLAM: Robustness through rectification in a wearable and monocular context* Uppsala University Dostupné z: <https://urn.kb.se/resolve?urn=urn%3Anbn%3Ase%3Auu%3Adiva-504784>. [cit. 2024-11-29].
- [16] Woo, Ami, Fidan, Baris, Melek, W.W., Buehrer, R. *Localization for Autonomous Driving* Localization for Autonomous Driving. 1051-1087 Dostupné z: [10.1002/9781119434610.ch29](https://doi.org/10.1002/9781119434610.ch29).. [cit. 2024-11-29].

- [17] *Beginner's guide to depth.* Intel® RealSense™ Depth and Tracking Cameras. Dostupné z: <https://www.intelrealsense.com/beginners-guide-to-depth/>. [cit. 2024-11-29].
- [18] Dissanayake, M. W. M. G., Newman, P., Clark, S., Durrant-Whyte, H. F., a Csorba, M. *A solution to the simultaneous localization and map building (SLAM) problem.* IEEE Transactions on Robotics and Automation, 17(3), 229–241. Dostupné z: <https://doi.org/10.1109/70.938381>. [cit. 2024-12-7].
- [19] Labbé, M., a Michaud, F. *RTAB-Map as an open-source lidar and visual simultaneous localization and mapping library for large-scale and long-term on-line operation.* Journal of Field Robotics, 36(2), 416–446. Dostupné z: <https://doi.org/10.1002/rob.21831>. [cit. 2024-12-7].
- [20] *RTAB-Map* Dostupné z: <https://introlab.github.io/rtabmap/>. [cit. 2024-12-7].
- [21] Campos, C., Elvira, R., Rodriguez, J. J. G., M. Montiel, J. M., a D. Tardos, J. *ORB-SLAM3: An Accurate Open-Source Library for Visual, Visual-Inertial, and Multimap SLAM.* IEEE Transactions on Robotics, 1–17. Dostupné z: <https://doi.org/10.1109/tro.2021.3075644>. [cit. 2024-12-7].
- [22] Geneva P., Eckenhoff K., Lee W., Yang Y. a Huang G. *OpenVINS: A Research Platform for Visual-Inertial Estimation* IEEE International Conference on Robotics and Automation Dostupné z: https://github.com/rpng/open_vins. [cit. 2024-12-7].
- [23] Ricardo García, Juan Pablo de Castro, Elena Verdú, María Jesús Verdú and Luisa María Regueras *Web Map Tile Services for Spatial Data Infrastructures: Management and Optimization* Cartography - A Tool for Spatial Analysis Dostupné z: <https://www.intechopen.com/chapters/38302>. [cit. 2024-12-7].
- [24] Sturm, Thomas F. *Template Matching Advances and Applications in Image Analysis* Universität der Bundeswehr München. Institut für Mathematik und Informatik Dostupné z: DOI:10.18726/2020_3. [cit. 2024-12-7].
- [25] Nazanin H, Roya A., Atieh G., Parastoo F. *Some Principles of Web Mercator Maps and their Computation* Dostupné z: <https://doi.org/10.48550/arXiv.1610.07231>. [cit. 2025-3-7].
- [26] Lindeberg, T. *Scale Invariant Feature Transform.* Scholarpedia Dostupné z: [10.4249/scholarpedia.10491](https://doi.org/10.4249/scholarpedia.10491). [cit. 2025-3-7].

- [27] E. Rublee, V. Rabaud, K. Konolige and G. Bradski *ORB: An efficient alternative to SIFT or SURF* 2011 International Conference on Computer Vision, Barcelona, Spain, 2011, pp. 2564-2571 Dostupné z: DOI:10.1109/ICCV.2011.6126544. [cit. 2025-3-7].
- [28] Calonder, M., Lepetit, V., Strecha, C., Fua, P. *BRIEF: Binary Robust Independent Elementary Features* ECCV 2010. Lecture Notes in Computer Science, vol 6314. Springer, Berlin, Heidelberg. Dostupné z: https://doi.org/10.1007/978-3-642-15561-1_56. [cit. 2025-3-7].
- [29] Sun, Jiaming and Shen, Zehong and Wang, Yuang and Bao, Hujun and Zhou, Xiaowei *LoFTR: Detector-Free Local Feature Matching with Transformers* Dostupné z: <https://doi.org/10.48550/arXiv.2104.00680>. [cit. 2025-3-7].
- [30] František Duchoň, Andrej Babinec, Martin Kajan, Peter Beňo, Martin Florek, Tomáš Fico, Ladislav Jurišica *Path Planning with Modified a Star Algorithm for a Mobile Robot* Procedia Engineering 96, 2014, 59-69, ISSN 1877-7058, Dostupné z: <https://doi.org/10.1016/j.proeng.2014.12.098>. [cit. 2025-3-7].

A Obsah elektronické přílohy

```
/.....kořenový adresář
├── VO_logs ..... výstupy systémů vizuální odometrie
│   ├── OPENVINS_05m_position_data.csv
│   ├── OPENVINS_10m_position_data.csv
│   ├── OPENVINS_30m_position_data.csv
│   ├── ORBSLAM_DEPTH_05m_position_data.csv
│   ├── ORBSLAM_DEPTH_10m_position_data.csv
│   ├── ORBSLAM_DEPTH_30m_position_data.csv
│   ├── ORBSLAM_MONO_05m_position_data.csv
│   ├── ORBSLAM_MONO_10m_position_data.csv
│   ├── ORBSLAM_MONO_30m_position_data.csv
│   ├── ORBSLAM_MONO_INS_05m_position_data.csv
│   ├── ORBSLAM_MONO_INS_10m_position_data.csv
│   ├── ORBSLAM_MONO_INS_30m_position_data.csv
│   ├── ORBSLAM_STEREO_05m_position_data.csv
│   ├── ORBSLAM_STEREO_10m_position_data.csv
│   ├── ORBSLAM_STEREO_30m_position_data.csv
│   ├── POS_ROSBAG_05m_position_data.csv
│   ├── POS_ROSBAG_10m_position_data.csv
│   ├── POS_ROSBAG_30m_position_data.csv
│   ├── RTABMAP_DEPTH_05m_position_data.csv
│   ├── RTABMAP_DEPTH_10m_position_data.csv
│   ├── RTABMAP_DEPTH_30m_position_data.csv
│   ├── RTABMAP_STEREO_05m_position_data.csv
│   ├── RTABMAP_STEREO_10m_position_data.csv
│   └── RTABMAP_STEREO_30m_position_data.csv
├── AVL_logs.....výstupy AVL
│   ├── AVL_LOFTR.csv
│   ├── AVL_ORB.csv
│   └── AVL_SIFT.csv
```