

Západočeská univerzita v Plzni

Fakulta aplikovaných věd

Katedra kybernetiky

Bakalářská práce

Analýza přístupů k autonomnímu přistání  
dronu na plošině

7. srpna 2023

Jan Kovář



## Čestné prohlášení

Předkládám tímto k posouzení a obhajobě bakalářskou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni, dne 7. srpna 2023

---

podpis autora

## Abstract

Tato bakalářská práce se zabývá analýzou přístupů k autonomnímu přistání dronů na plošině. Výzkum je zaměřen na bezpilotní letouny a jejich široké spektrum využití v různých oblastech. Hlavním cílem je prozkoumat různé metody detekce bezpečné přistávací plochy včetně využití kamer, LiDARu a jejich kombinace. Dalším cílem je zkoumat autonomní přistání dronů pomocí simulace.

Práce obsahuje teorii bezpilotních letounů, jejich klasifikaci a způsoby ovládání. Dále jsou popsány různé typy přistávacích ploch a metody detekce bezpečné plochy. Pro testování a výzkum je využito simulačního prostředí s použitím ArUco značek pro detekci plochy.

Výsledky práce poskytují cenné poznatky pro další výzkum a zdokonalování autonomních systémů pro přistání dronů na plošině.

## Klíčová slova

bezpilotní letouny, UAV, přistávací plochy, detekce, simulace, autonomní přistání, ArUco značky

## Abstract

This bachelor's thesis deals with the analysis of approaches to autonomous landing of drones on a platform. The research focuses on unmanned aerial vehicles and their wide range of applications in various fields. The main objective is to explore various methods for detecting a safe landing area, including the use of cameras, LiDAR, and their combination. Another goal is to examine autonomous drone landing through simulation.

The thesis includes the theory of unmanned aerial vehicles, their classification, and methods of control. It further describes different types of landing platforms and methods for detecting a safe landing area. For testing and research purposes, a simulation environment is utilized, using ArUco markers for platform detection.

The results of this work provide valuable insights for further research and improvement of autonomous systems for drone landings on platforms.

## **Keywords**

unmanned aerial vehicles (UAVs), landing platforms, detection, simulation, autonomous landing, ArUco markers.

## Poděkování

Chtěl bych poděkovat Ing. Petrovi Neduchalovi, Ph.D., vedoucímu mé bakalářské práce, za odborné vedení, zájem, připomínky a čas, který mi věnoval při konzultačních hodinách.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>4</b>
<b>2</b>	<b>Teorie bezpilotních letounů</b>	<b>5</b>
2.1	Popis bezpilotních letounů . . . . .	5
2.2	Klasifikace bezpilotních letounů . . . . .	6
2.2.1	UAV lehčí než vzduch . . . . .	6
2.2.2	UAV těžší než vzduch . . . . .	6
2.3	Způsob ovládání bezpilotních letounů . . . . .	8
2.3.1	Bezdrátový ovladač . . . . .	8
2.3.2	Mobilní aplikace . . . . .	9
2.3.3	Autonomní ovládání . . . . .	9
2.3.4	Další vývoj . . . . .	11
2.4	Aplikace bezpilotních letounů . . . . .	11
2.4.1	Zabezpečení, monitorování a dohled . . . . .	11
2.4.2	Řízení katastrof . . . . .	12
2.4.3	Dálkový průzkum Země . . . . .	12
2.4.4	Pátrání a záchrana - SAR . . . . .	12
2.4.5	Inspekce staveb a infrastruktury . . . . .	12
2.4.6	Precizní zemědělství . . . . .	13
2.4.7	Monitorování silničního provozu v reálném čase . . . . .	13
2.4.8	Automatizovaná obnova lesa . . . . .	13
2.4.9	Inspekce nadzemního elektrického vedení . . . . .	14
<b>3</b>	<b>Teorie přistávacích ploch</b>	<b>15</b>
3.1	Popis přistávacích ploch . . . . .	15
3.2	Rozřazení přistávacích ploch . . . . .	16
3.2.1	Vnitřní přistávací plochy . . . . .	17
3.2.2	Vnější přistávací plochy . . . . .	17

3.2.3	Známé přistávací plochy . . . . .	18
3.2.4	Neznámé přistávací plochy . . . . .	18
3.3	Detekce bezpečné přistávací plochy . . . . .	19
3.3.1	Na základě kamery . . . . .	20
3.3.2	Na základě LiDARu . . . . .	26
3.3.3	Kombinace LiDARu a kamery . . . . .	27
<b>4</b>	<b>Simulační prostředí a použité technologie</b>	<b>28</b>
4.1	Simulátory . . . . .	28
4.1.1	Výhody . . . . .	28
4.1.2	Nevýhody . . . . .	30
4.1.3	Popis konkrétních simulátorů . . . . .	30
4.2	Podrobnosti použité simulace . . . . .	31
4.2.1	Gazebo . . . . .	32
4.2.2	PX4-Autopilot . . . . .	32
4.2.3	QGroundControl . . . . .	33
4.2.4	MAVLink . . . . .	34
4.2.5	OpenCV . . . . .	34
4.3	ArUco značka . . . . .	35
4.3.1	Tvorba značek . . . . .	36
4.3.2	Detekce značky . . . . .	37
4.3.3	Odhad pozice . . . . .	38
<b>5</b>	<b>Proces přistávání na SLZ</b>	<b>40</b>
5.1	Autonomní plánovač přistání . . . . .	40
5.2	Stroj přistávacího stavu . . . . .	41
5.3	Přistávání v simulaci . . . . .	44
<b>6</b>	<b>Simulace detekce SLZ</b>	<b>45</b>
6.1	Efektivita detekce ArUco . . . . .	45
6.1.1	Popis měření maximální výšky . . . . .	45
6.1.2	Výsledek měření maximální výšky . . . . .	47
6.1.3	Závěr měření maximální výšky . . . . .	48
6.1.4	Popis měření minimální výšky . . . . .	49
6.1.5	Výsledek měření minimální výšky . . . . .	49
6.1.6	Závěr měření minimální výšky . . . . .	51
6.2	Na základě LiDARu . . . . .	52
6.3	Na základě kamery . . . . .	53



6.4	Kombinace kamery a barometru . . . . .	57
<b>7</b>	<b>Závěr</b>	<b>59</b>
	<b>Seznam obrázků</b>	<b>61</b>
	<b>Seznam tabulek</b>	<b>62</b>
	<b>Literatura</b>	<b>63</b>

# Kapitola 1

## Úvod

Bezpilotní letouny se stávají stále důležitějším nástrojem ve světě moderní technologie. Jejich široké spektrum využití zahrnuje mnoho oblastí. Jedním z klíčových aspektů jejich funkcionality je schopnost provést bezpečné a přesné přistání na ploše bez lidského zásahu. Cílem této bakalářské práce je provést analýzu přístupů k autonomnímu přistání drona na plošině.

Práce se nejdříve zaměří na bezpilotní letouny, které se rozřadí do kategorií. Dále prozkoumá různé způsoby jejich ovládání a popíše několik jejich aplikací.

Je věnována zvláštní pozornost přistávacím plochám, které jsou nejprve popsány a následně zařazeny do kategorií. Klíčovým zaměřením je detekce bezpečných přistávacích ploch za pomoci kamery, LiDARu a jejich kombinace.

Simulace jsou použity k testování různých metod detekce přistávacích ploch a autonomního přistání. Klíčovým prvkem detekce přistávacích ploch v této práci jsou ArUco značky.

Dále bude věnována pozornost různým procesům autonomního přistání na plošinách a to hlavně za pomoci kamery a dalších pomocných senzorů.

Poslední část této práce se zabývá simulací detekce přistávací plošiny. V této části je zhodnocena efektivita ArUco značek pro detekci kamerou a je zde testováno několik přístupů k autonomnímu přistání.

Závěry této práce budou sloužit jako cenný zdroj informací a přehled pro vývoj a zdokonalování autonomních systémů pro přistání dronů na plošině. Navrhované přístupy a výsledky simulací budou přínosné pro další výzkum v oblasti bezpilotních letounů a jejich aplikací.

# Kapitola 2

## Teorie bezpilotních letounů

Tato kapitola si klade za cíl poskytnout ucelený pohled na bezpilotní letouny, od jejich základního popisu až po jejich praktické aplikace. Nejprve je prezentován obecný přehled bezpilotních letounů a jejich klíčových vlastností, které je odlišují od tradičních letadel řízených pilotem. Následně se kapitola zaměří na klasifikaci bezpilotních letounů.

### 2.1 Popis bezpilotních letounů

Bezpilotní letoun, neboli Unmanned Aerial Vehicle (UAV), se pohybuje bez posádky na palubě a může být ovládán z pozemní stanice nebo autonomně podle předem daných parametrů. Typické UAV mají malé rozměry a nízkou hmotnost, což jim umožňuje snadné manévrování v prostoru. Mohou být vybaveny různými senzory a kamerami pro sběr dat a jejich aplikace je zmíněna v sekci 2.4.

UAV se dále dělí podle svého účelu, velikosti, pohonu, dosahu, výdrže a dalších faktorů, jejich klasifikace podle typu pohonu a základní stavby je v sekci 2.2. UAV mohou být navrženy pro krátkodobý let v blízkosti pozemní stanice, nebo pro delší lety na velké vzdálenosti. Některé UAV jsou určeny pro vysokorychlostní lety, zatímco jiné jsou navrženy pro pomalé lety s nízkou nadmořskou výškou. Velké UAV mohou mít křídla o rozpětí více než 10 metrů, zatímco malé UAV mohou mít pouze několik centimetrů.

## 2.2 Klasifikace bezpilotních letounů

UAV mohou být rozděleny do dvou základních kategorií na základě jejich struktury a funkčnosti (1): lehčí než vzduch (LTA) a těžší než vzduch (HTA). Každá z těchto kategorií má své specifické fyzikální vlastnosti a způsob pohybu v prostoru. Schéma této klasifikace je znázorněno na Obrázku 2.1.

### 2.2.1 UAV lehčí než vzduch

Tyto UAV jsou založeny na principu vztlaku, který je vytvářen plynem, který je lehčí než vzduch. Tyto UAV se obvykle pohybují pomaleji a jsou stabilnější ve větru, což z nich činí ideální platformy pro pozorování z výšky nebo pro monitoring meteorologických podmínek. Příklady UAV lehčích než vzduch jsou například balóny, vzducholodě, padáky nebo aerostaty.

### 2.2.2 UAV těžší než vzduch

UAV těžší než vzduch jsou konstruovány tak, aby generovaly dostatečný tah a udržely se ve vzduchu. Tyto UAV se obvykle pohybují rychleji a mají větší dolety než UAV lehčí než vzduch. Tyto UAV jsou obvykle navrženy pro specifické účely, jako jsou průzkum, monitorování, bezpečnostní operace a vojenské účely. Příklady UAV těžších než vzduch zahrnují letadla bez pilota (UAV), helikoptéry bez posádky (UH) a námořní drony.

Dále se UAV těžší než vzduch dělí do dvou částí: poháněné (motorové) a nepoháněné (bezmotorové).

#### 2.2.2.1 Bezmotorové UAV

Jedná se o speciální typy UAV, které nevyužívají žádný motor k udržení letu. Tyto UAV jsou navrženy tak, aby využívaly termických proudů a jiných přírodních vzdušných proudů k udržení letu. Mají obvykle větší dolety a jsou mnohem tišší než UAV s motorem. Jejich letové vlastnosti jsou značně ovlivněny okolními podmínkami, jako jsou teplota, vlhkost a rychlost větru. Také jsou obvykle vyráběny z lehkých materiálů, jako je kevlar nebo uhlíkové vlákno, aby minimalizovaly svou hmotnost a maximalizovaly svou schopnost udržet se ve vzduchu. Tento typ UAV se také nazývá větroň nebo plachetnice.

### 2.2.2.2 Motorové UAV

Motorové UAV mají větší nosnost a dolet a jsou obvykle navrženy pro aplikace, kde je potřeba přenášet větší náklady. Obvykle jsou vybaveny výkonnými elektromotory, pístovými či turbínovými spalovacími motory, aby byly schopné vzlétnout a udržet se ve vzduchu. Jsou větší a výkonnější než UAV lehčí než vzduch a mají větší schopnost přenášet náklady a dlouhodobě udržovat let v různých podmínkách.

Motorové UAV dále bývají většinou poháněné elektricky a rozdělují se do tří typů:

1. S pevným křídlem

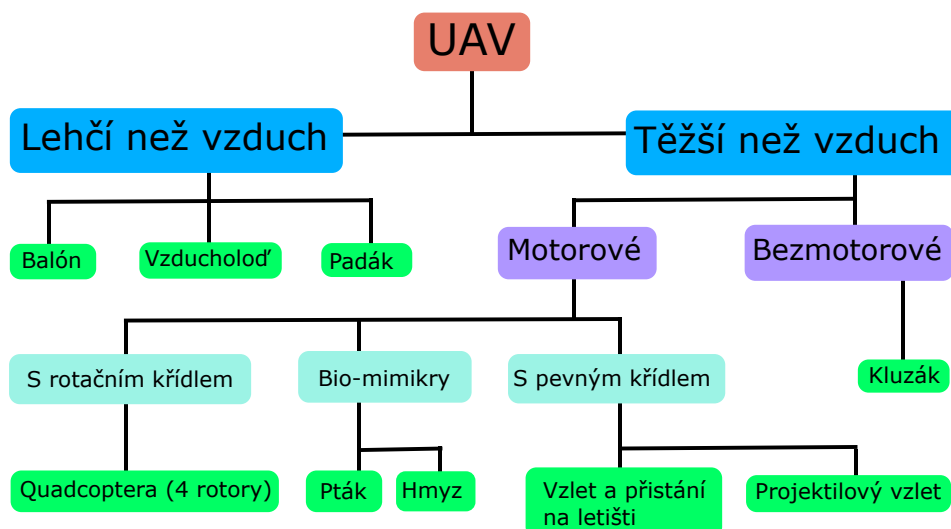
Nejčastěji nabývá podoby letadla a dělí se podle stylu vzletu. Buď vzlétá jako reálné letadlo ze vzletové a přistávací dráhy nebo mu ke vzletu pomáhá odpalovací zařízení.

2. Bio-mimikry

UAV tohoto typu mohou nabývat jakékoliv podoby, jelikož jsou vytvořeny na základě živých organismů.

3. S rotačním křídlem

Tento typ UAV se rozděluje podle počtu rotorů. V této práci bude použit dron z této třídy a to konkrétně Kvadroptéra.



Obrázek 2.1: Schéma klasifikace UAV

## 2.3 Způsob ovládání bezpilotních letounů

V závislosti na konkrétním typu UAV se liší jeho ovládání a způsobu použití. Většina moderních UAV je ovládána pomocí bezdrátového ovladače (dálkového ovládání) nebo pomocí počítačového programu.

### 2.3.1 Bezdrátový ovladač

Nejčastější způsob ovládání UAV je bezdrátovým ovladačem. Jedná se o zařízení, které umožňuje pilotovi ovládat UAV z bezpečné vzdálenosti, obvykle několik set metrů až jednotek kilometrů.

Bezdrátový ovladač většinou obsahuje několik ovládacích prvků, které slouží k ovládání směru letu, výšky, otáček motorů a dalších funkcí UAV. Tyto ovládací prvky mohou být různého typu a mohou být umístěny na různých místech ovladače v závislosti na konkrétním modelu. Ovladač může být také vybaven i dalšími ovládacími prvky, jako jsou například tlačítka pro start a přistání, ovládací prvky pro kameru nebo senzory a další.

Moderní bezdrátové ovladače také obsahují obrazovky, které zobrazují důležité informace o stavu UAV, jako jsou například výška, rychlost, stav baterií a další. Některé ovladače také umožňují pilotovi zobrazit video nebo snímky

pořízené kamerou na UAV, což umožňuje pilotovi vidět snímání obraz UAV.

Vzhledem k tomu, že bezdrátový ovladač komunikuje s UAV pomocí bezdrátového signálu, je důležité zajistit stabilní a spolehlivý signál, který zajistí bezpečně ovládání UAV. Proto jsou moderní bezdrátové ovladače vybaveny například DSMX, což zajišťuje stabilní a spolehlivou komunikaci mezi ovladačem a UAV.

### 2.3.2 Mobilní aplikace

Tento způsob vyžaduje použití chytrého telefonu nebo tabletu jako ovladače UAV. Mobilní aplikace obvykle umožňuje pilotovi ovládat UAV pomocí dotykového displeje na zařízení a má obvykle podobné ovládací prvky, kterými jsou bezdrátový ovladač, včetně virtuálních páček pro ovládání směru letu a výšky, tlačítka pro start a přistání, ovládací prvky pro ovládání kamer a dalších funkcí.

Mobilní aplikace používá Wi-Fi nebo Bluetooth pro komunikaci s UAV, proto je důležité zajistit stabilní a spolehlivý signál pro bezpečné ovládání UAV stejně jako u bezdrátového ovladače. Na rozdíl od bezdrátových ovladačů samostatná mobilní zařízení nemají k dispozici specializované technologie pro spojení s UAV a proto mají kratší dosah.

Jsou zde také funkce, které jsou specifické pro mobilní zařízení. Například možnosti záznamů videa a fotografií přímo z kamer na UAV, sdílení snímků na sociálních sítích, sledování telemetrických údajů a další.

Výhodami použití mobilní aplikace jako ovladače UAV je velká praktičnost a dostupnost pro piloty, jelikož většina pilotů již má chytrý telefon nebo tablet k dispozici. Mobilní aplikace také umožňuje pilotovi mít přístup k důležitým informacím o UAV a jeho stavu v reálném čase.

Ovládání UAV pomocí mobilní aplikace má také několik nevýhod, kterými jsou menší přesnost a citlivost ovládání, zvláště pro piloty, kteří preferují taktickou odezvu ovladače. Dále mohou být mobilní aplikace náchylné k rušení v bezdrátovém spektru, což může vést k problémům s připojením a narušení signálu.

### 2.3.3 Autonomní ovládání

Za pomoci této možnosti ovládání může UAV letět a vykonávat úkoly bez lidského ovládání nebo dohledu. Toto ovládání se zakládá na předem napro-

gramovaných instrukcích nebo algoritmech, které umožňují UAV letět podle určitých podmínek a vykonávat určité úkoly.

Existuje několik typů autonomního ovládání:

1. Předem naprogramovaná cesta

Pilot předem naprogramuje cestu, kterou UAV má letět. UAV pak sleduje tuto cestu pomocí GPS a senzorů a může například pořizovat fotografie nebo sbírat data na určených místech.

2. Sledování objektu

UAV může být programován k tomu, aby sledoval určitý objekt, například automobil nebo osobu. UAV se snaží udržovat určitou vzdálenost od sledovaného objektu a zachovává požadovaný pohledový úhel.

3. Autonomní rozhodování

UAV může být vybaveno algoritmy, které mu umožňují vyhodnocovat situace a rozhodovat se, co má dělat. Například při zjištění překážky v cestě se UAV může rozhodnout o změně směru nebo o přistání.

4. Autonomní přistání a start

UAV může být programován k tomu, aby automaticky přistával nebo startoval, aniž by byl nutný zásah lidského pilota. Tato funkce je užitečná zejména při použití UAV v obtížně přístupných oblastech a jedná se o hlavní složku této práce.

Výhodou autonomního ovládání je to, že autonomní ovládání umožňuje UAV létat přesně podle naprogramované trasy nebo plnit úkoly bez ovlivnění lidskou chybou. Také je zde několik nevýhod. Je nutné pečlivě naprogramovat UAV, aby se vyhnulo překážkám a bylo schopné vyhodnocovat situace a reagovat na ně. Autonomní ovládání může být náchylné k poruchám a chybám v programování, což může vést k nepožadovanému chování UAV. Návrh a vývoj sofistikovaných algoritmů a senzorových systémů bývá obvykle náročný. Mnoho právních předpisů vyžaduje, aby bylo UAV ovládáno lidským pilotem, což může způsobit problémy v případě, že dojde k nehodě při autonomním letu.

Přesto se autonomní ovládání UAV stává stále důležitější a častější, zejména v průmyslových aplikacích (průzkumy, zemědělství, lesnictví, geologický průzkum a mnoho dalších). Většina moderních UAV je proto vybavena alespoň



nějakou úrovní autonomního ovládání, které může být přizpůsobeno specifickým potřebám a požadavkům uživatele.

### 2.3.4 Další vývoj

V oblasti UAV je vývoj umělé inteligence a strojového učení velmi důležitý, neboť umožňuje UAV provádět složité již zmíněné úkoly. Jedním z největších výzev v této oblasti je vývoj algoritmů, které umožňují UAV provádět tyto úkoly s vysokou přesností a spolehlivostí a to i v nepředvídatelných prostředích. K tomu se používají různé metody strojového učení, jako jsou hluboké neuronové sítě, klasifikační algoritmy, rozhodovací stromy a další.

Další oblastí vývoje je vylepšování sensorových systémů a využití nových technologií, jako jsou LiDAR, radary, termokamery a hyperspektrální kamery, které umožňují UAV získat přesné a komplexní informace o okolním prostředí. Tyto informace se následně používají k optimalizaci rozhodování UAV a zajištění bezpečnosti letu.

Celkově lze říci, že vývoj v oblasti umělé inteligence a strojového učení je klíčový pro další pokrok v oblasti UAV a umožní UAV plnit složité úkoly, které by jinak nebyly možné.

## 2.4 Aplikace bezpilotních letounů

UAV získaly významnou pozornost v různých disciplínách vojenských a civilních služeb kvůli jejich zvýšené stabilitě a odolnosti v několika operacích. Aplikace UAV se výjimečně rozšiřují díky jejich pokročilému využití v internetu věcí (IoT), 5G a B5G. UAV byly v posledním desetiletí používány v různých aplikacích, včetně následujících odstavců(2):

### 2.4.1 Zabezpečení, monitorování a dohled

UAV hrají klíčovou roli ve vojenských sledovacích misích. Několik zemí zařadilo UAV do svých strategických plánů obrany. Tyto letící robotické zařízení slouží k detekci nepřátelských sil, v boji proti pytláctví, ke kontrole hranic a monitorování důležitých námořních tras.

## 2.4.2 Řízení katastrof

V případě, že dojde k přírodním nebo člověkem způsobeným katastrofám, jako jsou teroristické útoky, tsunami nebo záplavy, mohou UAV získat přístup k místům, která jsou pro lidskou činnost příliš nebezpečná. UAV mohou sehrát klíčovou roli při sběru informací, rychlém hledání řešení a navigaci v troskách.

## 2.4.3 Dálkový průzkum Země

V současné době se amatérské drony staly cenným nástrojem pro získávání dat ve vysokém rozlišení z odlehlých oblastí, ostrovů, horských vrcholů a pobřeží. Díky schopnostem těchto bezpilotních průzkumných zařízení lze podporovat sledování kvality vody, monitorování sucha, rovy a zemního plynu, odhady výnosů zemědělství, hydrologické modelování, ochranu biologické rozmanitosti, zkoumání geologických katastrof, průzkum terénu, mapování lesů a monitorování plodin. Tato technologie může být využívána k hromadnému mapování a tvorbě 3D environmentálních map, díky tomu se stává aktivním prvkem archeologie a kartografie.

## 2.4.4 Pátrání a záchrana - SAR

UAV mohou přinést značné úspory pracovních sil, zdrojů a času tím, že poskytnou data a snímky požadované oblasti v reálném čase. Díky tomu může tým záchranářů (SAR) včas zjistit a rozhodnout, kde je nejvíce naléhavě potřeba pomoci. UAV jsou schopna výrazně urychlit operace SAR v katastrofálních situacích, jako jsou hledání pohřešovaných osob, zvládnání lavin, monitorování lesních požárů nebo detekce jedovatých plynů. Například mohou být UAV využity k lokalizaci ztracených horolezců během jakékoli expedice nebo k nalezení lidí ztracených v odlehlých pouštích či lesích.

## 2.4.5 Inspekce staveb a infrastruktury

Mapování skutečného stavu, monitorování stavby a inspekce místa, se staly efektivními, snadnými a rychlými s použitím UAV. Díky nim je sledování stavebních projektů od začátku do konce mnohem snazší, což zajišťuje kvalitní průběh stavebních prací. UAV mohou poskytovat zprávy obsahující snímky, videa a 3D mapy, což je cenné pro potenciálně zainteresované strany. Tato

technologie výrazně přispívá k aplikacím kontroly infrastruktury a stavebních projektů.

#### **2.4.6 Precizní zemědělství**

UAV nacházejí uplatnění v přesném zemědělství, kde zajišťují sběr dat z pozemních senzorů týkajících se například kvality vody, vlastností půdy a vlhkosti. Dále umožňují provádět postřiky pesticidů, detekci chorob, plánování zavlažování, odhalování plevele a sledování a řízení růstu plodin. Integrace UAV do precizního zemědělství se ukazuje jako časově a nákladově efektivní technologie, která může výrazně zvýšit ziskovost, produktivitu a výnosy plodin v rámci zemědělských systémů.

#### **2.4.7 Monitorování silničního provozu v reálném čase**

System monitorování silničního provozu (Road Traffic Monitoring - RTM) je oblast, která projevuje velký zájem o integraci UAV. V rámci RTM je možné dosáhnout plné automatizace dopravního sektoru s pomocí UAV. To zahrnuje automatizaci záchranných týmů, silničních geodetů, dopravní policie a terénních podpůrných týmů. Místní policie může provozovat UAV s cílem získat lepší pohled na dopravní nehody nebo provádět masivní bezpečnostní zásahy proti kriminálním aktivitám na dálnicích, například při krádežích aut.

Další využití UAV v RTM zahrnuje identifikaci vozidel, sledování podezřelých vozidel, pronásledování ozbrojených lupičů a únosců nebo jakýchkoli osob, které porušují pravidla silničního provozu. Díky těmto aplikacím mohou UAV výrazně přispět k zlepšení bezpečnosti a účinnosti silničního provozu.

#### **2.4.8 Automatizovaná obnova lesa**

Využití UAV pro automatizovanou obnovu lesa (Automated Forest Restoration - AFR) je nově vznikající výzkumnou oblastí. UAV mohou být nasazeny k řešení několika klíčových úkolů souvisejících s procesem obnovy lesa. To zahrnuje průzkum lokalit, plánování strategie obnovy, vybudování infrastruktury na místě, dodávku semen, správu lokality (např. hnojení a odplevelení) a průzkum biologické rozmanitosti po dokončení obnovy.

Díky dostupným technologiím, jako jsou polohovací a zobrazovací senzory, jsou UAV schopny vykonávat různé úkoly. Mohou provádět základní

průzkumy místa před zahájením procesu obnovy lesa a následně monitorovat několik aspektů obnovy biologické rozmanitosti. Tímto způsobem UAV přinášejí nový potenciál v oblasti ochrany a obnovy lesních ekosystémů.

#### **2.4.9 Inspekce nadzemního elektrického vedení**

Detekce a prevence poruch elektrického vedení hraje klíčovou roli v zajištění dostupnosti a spolehlivosti dodávek elektřiny. Tradiční techniky kontroly mají své nevýhody, jako je vysoká cena, obtížné nasazení a rizika spojená s manuálními inspekcemi. V této souvislosti se kontroly týkají i bezpečnosti přenosové elektrické sítě.

Jedním z pohodlných přístupů k podpoře těchto kontrolních úkolů je využití UAV vybavených digitální kamerou pro pořizování snímků koridorů elektrického vedení. UAV umožňují sledovat silové stožáry, aby se odhalily případné poruchy, jako jsou poškozené šrouby, koroze, rez a následky úderů blesku. Tímto způsobem UAV přinášejí efektivní a bezpečný způsob kontroly a údržby elektrického vedení, což má pozitivní vliv na spolehlivost a bezpečnost celé elektroenergetické infrastruktury.

# Kapitola 3

## Teorie přistávacích ploch

Tato kapitola se věnuje přistávacím plochám. Nejprve začne s obecným popisem přistávacích ploch, následně popíše jejich klasifikaci a v poslední části popíše způsoby detekce SLZ.

### 3.1 Popis přistávacích ploch

Po dokončení mise UAV musí bezpečně přistát. V dobrém případě UAV nemá problémy najít známé místo přistání (označené) a dokáže bez problémů přistát.

Avšak v případě nepříznivých povětrnostních podmínek nebo technických problémů může UAV potřebovat bezpečné místo pro přistání poblíž aktuální polohy, ať už je to místo známé nebo neznámé. Pokud je UAV vybaveno autonomními funkcemi, může samo najít bezpečné přistávací místo nazývané Save Landing Zone (SLZ) na základě svých vizuálních nebo jiných systémů. Nalezení SLZ je klíčové pro ochranu UAV před pádem nebo jinými nebezpečnými situacemi při přistávání. Tímto způsobem autonomní schopnosti UAV přispívají k jeho bezpečnému provozu a minimalizaci rizika během přistávání.

Aby se plocha mohla považovat za SLZ, musí splňovat několik klíčových vlastností a kritérií, které zajistí bezpečné a úspěšné přistání UAV:

1. Rovina bez překážek

SLZ by měla být rovná, bez výrazných nerovností a překážek, které by mohly narušit přistávací manévr UAV. Tím se minimalizuje riziko poškození UAV při přistání.

## 2. Dostatečná velikost

SLZ by měla být dostatečně velká, aby zajistila dostatečný prostor pro bezpečné přistání a manévrování UAV.

## 3. Stabilita

Plocha by měla být stabilní a pevná, aby poskytovala pevný a spolehlivý podklad pro přistání UAV.

## 4. Vhodná povrchová struktura

Povrch SLZ by měl být vhodný pro přistání UAV, například by neměl poskytovat příliš kluzký nebo nepravidelný povrch, který by mohl ovlivnit řízení UAV.

## 5. Dostatečná viditelnost

SLZ by měla být jasně viditelná z palubní kamery UAV, aby UAV mohlo přesně zaměřit a přistát.

## 6. Vzdálenost od nebezpečných oblastí

Plocha by měla být umístěna dostatečně daleko od nebezpečných oblastí, jako jsou vysoké budovy, silné proudění vzduchu, elektrická vedení nebo terénní nerovnosti.

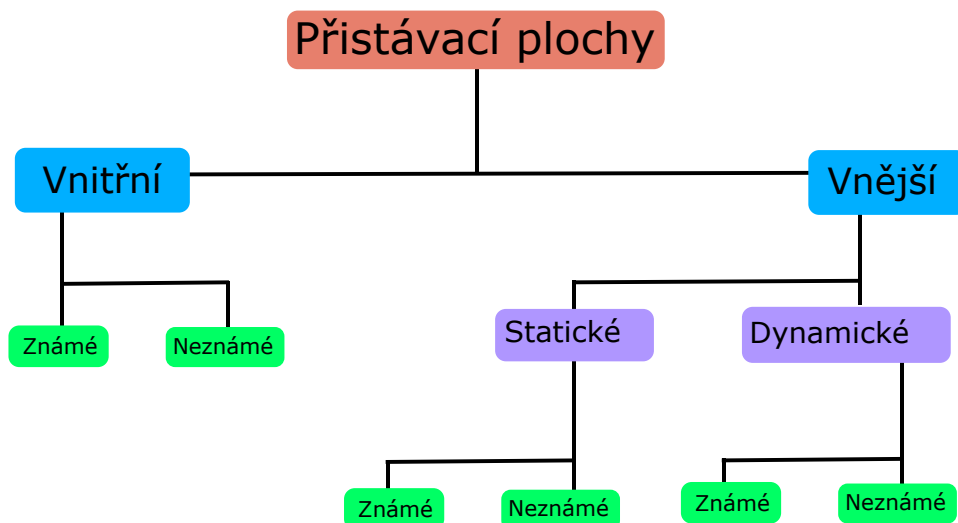
## 7. Bez zákazů a omezení

SLZ by neměla být v zakázané nebo omezené oblasti, která by mohla ovlivnit bezpečnost a legálnost přistání UAV.

## 3.2 Rozřazení přistávacích ploch

SLZ, na kterých UAV může přistát, lze rozdělit do dvou hlavních kategorií, podle toho kde se SLZ vyskytuje (1).

Tato klasifikace je zobrazena na obrázku 3.1. SLZ může v různých úlohách přistání odkazovat na různý typ. V praktické části této práci je SLZ chápáno jako statický a známý droneport zobrazen na obrázku 6.6.



Obrázek 3.1: Schéma klasifikace přistávacích ploch

### 3.2.1 Vnitřní přistávací plochy

Jedná se o SLZ, které jsou uvnitř budov. Jelikož vnitřní prostředí obsahuje různé typy překážek, musí UAV manévrovat opatrně. Vnitřní přistávací plochy jsou většinou statické a horizontální ploché zóny, které jsou bez překážek. Některé z vnitřních SLZ jsou podlahy, stoly a další rovné pevné povrchy rovnoběžné s podlahou. Vnitřní přistávací plochy lze rozdělit na dvě kategorie, kterými jsou známé a neznámé. Rozdělují se podle toho, zda je UAV předem seznámeno s místem pro přistání nebo musí najít bezpečné místo v neznámém prostředí.

### 3.2.2 Vnější přistávací plochy

Tyto SLZ jsou umístěny v otevřeném venkovním prostoru. Venku přistávání přináší několik dodatečných faktorů oproti vnitřnímu přistávání. Patří sem proudění vzduchu, které může ovlivnit stabilitu a řízení UAV během přistávání. Kromě toho jsou zde různé překážky, jako jsou stromy, skály, elektrická vedení a budovy, které zvyšují riziko kolize a vyžadují opatrné manévry UAV.

Venkovní přistávání také čelí výzvám týkajícím se viditelnosti, například mlha, déšť, sníh a písečné bouře, což může omezit viditelnost a ztížit správné

zaměření a řízení UAV během přistávání.

Navíc mohou nastat další technické problémy, které mohou ovlivnit funkci UAV během venkovního přistávání. Celkově venkovní prostředí klade vyšší nároky na řízení a kontrolu UAV a vyžaduje, aby byly UAV vybaveny dostatečnými autonomními funkcemi a senzory pro úspěšné a bezpečné přistávání v těchto náročných podmínkách.

### **3.2.2.1 Statické vnější přistávací plochy**

Jsou to pevně umístěné přistávací plochy, které mají neměnné charakteristiky. Mohou to být přistávací dráhy, dětská hřiště, ploché střechy, heliporty a další pevně označené plochy. Statické přistávací plochy lze rozdělit na známé a neznámé.

### **3.2.2.2 Dynamické vnější přistávací plochy**

Dynamické přistávací zóny jsou pohyblivé plošiny, které mohou být nosičem jedoucího kamionu, lodi, střechy autobusu a dalších pohyblivých plochých ploch. Dynamické přistávací plochy lze rozdělit na známé a neznámé.

### **3.2.3 Známé přistávací plochy**

O těchto plochách je známé, kde se nachází a jak vypadají. Známými statickými zónami jsou například heliport, označené přistávací dráhy nebo označené povrchy. Některé příklady dynamických známých přistávacích ploch jsou letadlová loď a další označené povrchy na lodi, nákladním automobilu nebo jiných pohyblivých se vozidlech s rovným povrchem.

### **3.2.4 Neznámé přistávací plochy**

Tyto plochy mohou být buď zcela neznámé, což znamená, že není přístupná žádná informace o jejich poloze a tvaru, nebo částečně neznámé, kdy je známý vzhled plochy, ale poloha je neznámá. Neznámé statické přistávací plochy jsou většinou rovné a bez překážek, na kterých může UAV bezpečně přistát, jako jsou okraj silnice, pole nebo plochá střecha.

Příklady neznámých dynamických venkovních přistávacích ploch zahrnují různé druhy pohyblivých se vozidel nebo plošin, které nemají přistávací značky a mohou být potenciálně využity pro přistání UAV.



### 3.3 Detekce bezpečné přistávací plochy

Jedná se o proces identifikace a výběru místa, které splňuje potřebné požadavky pro bezpečné a úspěšné přistání dronu. Existuje několik přístupů k řešení tohoto problému, z nichž některé jsou uvedeny níže.

1. Manuální identifikace vhodného místa

Operátor dronu může manuálně vyhledat a identifikovat vhodné místo pro přistání. Tento přístup vyžaduje vysokou úroveň zkušeností a odbornosti, aby bylo zajištěno, že místo splňuje všechny potřebné požadavky.

2. Využití GPS

UAV může být vybaveno GPS systémem, který umožňuje určení polohy a výšky. Při použití GPS může dron sám identifikovat nejvhodnější místo pro přistání na základě kritérií jako jsou dostatečná velikost plochy, absence překážek, stabilní povrch a podobně.

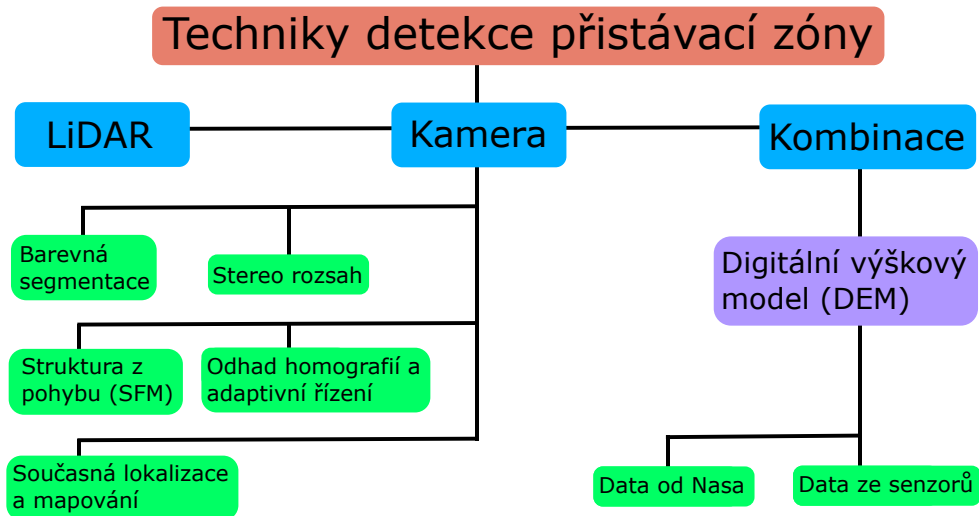
3. Využití senzorů

UAV může být vybaveno různými senzory, jako jsou například ultrazvukové, optické nebo LiDARové senzory, které umožňují získat informace o okolním prostředí. Tyto senzory mohou být použity k identifikaci vhodného místa pro přistání na základě kritérií jako jsou přítomnost stromů, vysoké trávy, překážek a podobně.

4. Využití umělé inteligence

Moderní UAV mohou být vybaveny systémy umělé inteligence, které umožňují identifikovat vhodné místo pro přistání na základě analýzy dat z různých zdrojů. Tyto systémy mohou využívat algoritmy strojového učení, neuronové sítě a další techniky k rozpoznávání vzorů v datech a identifikaci nejlepšího řešení pro přistání.

Většinu existujících technik detekce přistávacích ploch lze rozdělit do tří skupin, které jsou založeny na fotoaparátu, LiDARu nebo jejich kombinaci. Tato klasifikace je ukázána na Obrázku 3.2.



Obrázek 3.2: Schéma detekcí vhodné přistávací plochy

Jeden z konkrétních způsobů hledání SLZ je Gaborova transformace (GB), která zjišťuje frekvence ze snímků pořízené UAV z různých míst. Na základě GB je plochý povrch považován za referenční oblast a ostatní oblasti jsou s ní srovnávány. Jednou nevýhodou této metody je, že může za referenční oblast považovat jiné nežádoucí ploché povrchy, jako je například voda. Za nepříznivých povětrnostních podmínek může UAV pořizovat rozmazané snímky, které mohou vést k falešnému místu přistání. K vyřešení tohoto problému může být nutné použít kombinovaný přístup kamery a LiDAR (1).

### 3.3.1 Na základě kamery

Metody využívající kamery jsou založené na detekci přistávací plochy pomocí snímaných obrazů. Kamera umístěná na palubě UAV zachycuje obraz okolního prostředí a tento obraz může být využit při potřebě přistání. Snímky jsou následně analyzovány algoritmy pro zpracování obrazu, které identifikují nejbližší SLZ.

Techniky detekce přistávacích ploch na základě vizuálního vnímání mohou být aplikovány pro nalezení známých i neznámých ploch jak ve venkovním, tak i vnitřním prostředí. Pokud je potřeba identifikovat neznámou přistávací

plochu, palubní kamera pořizuje snímky země a ty jsou následně analyzovány pomocí algoritmů zpracování obrazu, aby se detekovala vhodná SLZ.

Pro detekci neznámých SLZ není UAV předem trénováno s konkrétní sadou obrazových dat, ale používá známé vlastnosti SLZ, jako jsou například barva, tvar, označení a povrch. Pokud obrazový materiál vyhovuje těmto znakům, povrch pod UAV je označen jako vhodná SLZ pro přistání.

### 3.3.1.1 Stereovize

Jedná se o systém, který je podobný systému lidského vidění. Levé oko a pravé oko zachycuje stejnou scénu, ale v jiném úhlu. Obě scény jsou následně zpracovány lidským mozkiem a je vnímána 3D reprezentace scény.

Podobně se používají dvě kamery na levé i pravé straně UAV. Levá kamera a pravá kamera pořídí stejný snímek v jiném úhlu. Vzhledem k rozdílům v umístění mezi kamerami se na objektech na obou snímcích vyskytují rozdíly v pixelech. Zachycené snímky jsou následně zpracovány různými algoritmy zpracování obrazu a je vnímána hloubka snímku.

Přesné generování profilu terénu z rozdílu pixelů je klíčem pro výběr SLZ. Čím přesnější je profil terénu, tím přesněji může algoritmus najít SLZ. Rozdíl v pixelech se může měnit se změnou výšky UAV.

Přestože se metoda zabývá binokulárním viděním pro určení SLZ, stále potřebuje pomoc od GPS, INS a dalších podsystémů.

### 3.3.1.2 Struktura z pohybu - SfM

Uvedená technika využívaná k rekonstrukci 3D scény a detekci SLZ na základě analýzy pohybu objektů ve scéně. Tato metoda je založena na sledování pohybu jednotlivých bodů v obrazech z kamery, což umožňuje odhadnout jejich prostorovou polohu a vytvořit 3D model scény.

UAV snímá okolní prostředí z různých úhlů a pozic pomocí svých kamer. Software zpracovává snímky a sleduje pohyb jednotlivých bodů mezi jednotlivými snímky. Tím se získávají informace o pohybu objektů ve scéně. Na základě sledování pohybu bodů mezi snímky je možné odhadnout prostorovou polohu těchto bodů a rekonstruovat 3D model scény.

Zatímco Struktura z pohybu (Structure from motion - SfM) se zaměřuje na sledování pohybu a dynamické informace pro rekonstrukci 3D scény, stereovize využívá binokulárního vidění a statických obrazů pro odhad hloubky a 3D struktury. Stereovize pracuje pouze s aktuálními daty neboli právě po-

řízeným snímkem, zatím co SfM nasbírání data (snímky), která následovně vyhodnocuje.

Obě metody mají své výhody a omezení. Mohou být použity v různých situacích a podmínkách. SfM se často používá v situacích, kdy se objekty nebo kamera pohybují, například při sledování pohybu vozidel nebo letadel. Na druhou stranu Stereovize může být výhodná v situacích, kdy je k dispozici statický pohled na scénu z různých úhlů, například při detekci statických objektů ve venkovním prostředí.

### 3.3.1.3 Odhad homografie a adaptivní řízení - HEAC

Tato kombinovaná metoda spojuje odhad homografie a adaptivní řízení, aby identifikovala vhodné místo pro bezpečné přistání v neznámém venkovním prostoru. Pokud je UAV v pohybu, palubní pohyblivá kamera pořizuje sekvenci snímků z různých úhlů pohledu, aby identifikovala SLZ. Tyto snímky mohou mít odlišné perspektivy a zkreslení, které způsobují, že objekty na nich nevypadají stejně. Homografie umožňuje matematicky popsat toto zkreslení a navázat vztah mezi body na obou snímcích.

Pro dva snímky A a B, které zachycují stejný objekt nebo scénu, umožňuje homografie najít matici homografie, která říká, jak se body na obrazu A zobrazují na obrazu B a naopak.

Matice homografie obsahuje 9 prvků, ale je definována pouze do zřetězení (homogenního násobku), takže je reprezentována 8 volnými parametry. Tyto parametry jsou získávány pomocí různých algoritmů, jako je RANSAC (Random Sample Consensus) nebo Least Squares metoda, na základě bodů, které jsou na obou snímcích společné. Tímto způsobem lze dosáhnout korespondence mezi body na obou snímcích a znát geometrický vztah mezi nimi.

Odhad homografie je důležitý pro zjištění opravy obrazu a registrace obrazu. Může být také použit pro výpočet pohybu kamery mezi dvěma snímky. Jakmile je pohyb kamery vypočítán z odhadované homogenní matice, mohou být tyto informace užitečné pro opětovné vytvoření 3D informací původní scény. Pro přesný odhad homografie se dodržují následující kroky:

1. První snímek se považuje za referenční snímek.
2. Pro každý nově pořízený snímek se spustí algoritmus pro shodu bodů, aby se zkontrolovaly společné rysy odpovídající horizontální rovině.

3. Pokud se zjistí, že nový snímek sdílí stejnou horizontálu rovina a překrývá se s referenčním snímkem s pevnou prahovou hodnotou, pak je tento nový snímek je registrován a korelován s referenčním snímkem.
4. Poslední registrovaný snímek je pořízen jako nový referenční.
5. Celý proces se opakuje.

Základní myšlenkou adaptivního řízení je, že systém se sám "učí" nebo se přizpůsobuje prostředí na základě získaných dat a zpětné vazby. To znamená, že systém nevyužívá pouze předem stanovených pevných parametrů nebo pravidel, ale dokáže se přizpůsobit novým situacím a optimalizovat své chování v reálném čase. V rámci detekce SLZ UAV aktivně vyhledává a sleduje potenciální plochy pro přistání na základě dat z kamery a dalších senzorů. Pokud je nalezena vhodná SLZ, adaptivní řízení umožní letadlu provést bezpečné přistání na této pozici.

Nasazení metody HEAC pro nalezení SLZ v nerovinných oblastech může být složité, protože jsou kamery v pohybu a UAV si neustále vybírá nový referenční snímek. Je obtížné rozpoznat SLZ, jakmile UAV projde registrovaným referenčním snímkem. K vyřešení tohoto problému lze nainstalovat vícehledové kamery, které dokáží registrovat více referenčních snímků dohromady.

#### **3.3.1.4 Barevná segmentace**

Tato metoda identifikace SLZ využívá palubní kameru UAV, která pořizuje barevné snímky země, když potřebuje přistát. Barevná segmentace se zaměřuje na rozdělení pořízených snímků do různých segmentů na základě podobnosti v barvě. Princip této metody spočívá v použití vhodného barevného modelu (např. RGB, HSV nebo LAB) a v následném rozdělení obrazu na oblasti, kde jsou pixely s podobnými barevnými hodnotami přiřazeny do stejného segmentu.

Při použití barevného modelu RGB (červená, zelená a modrá) jsou snímky rozděleny do tří hlavních barev RGB a poté se často každému barevnému pixelu RGB přiřadí hodnota šedé stupnice od 0 do 255. Každý pixel v šedotónovém obrázku má svůj jasový (šedotónový) stupeň, který určuje, jak světlý nebo tmavý je daný bod na obrázku. Šedotónový obrázek se skládá z různých odstínů šedi, kde černá odpovídá nejnižšímu jasů a bílá nejvyššímu

jasu. Prostřední odstíny šedi pak představují různé úrovně jasu mezi černou a bílou.

Pro dosažení segmentace mohou být použity různé přístupy, jako je prahování, kdy jsou definovány prahové hodnoty pro každou barvu, nebo klastrování, které seskupuje pixely do shluků na základě jejich podobnosti v barvě. Výsledkem je obraz rozdělený do barevných oblastí, které představují různé objekty nebo části scény. Při segmentaci šedotónového obrázku dochází ke značnému zjednodušení, jelikož se volí prahy pouze v jedné stupnici.

Pokud jsou známy některé charakteristiky SLZ, jako je specifická barva, textura nebo geometrický tvar, může být barevná segmentace použita k vyhledání podobných oblastí v obraze. Tímto způsobem může být určeno, zda se v okolí UAV nachází potenciální plochy pro přistání.

Dalším způsobem, jak barevná segmentace pomáhá při hledání SLZ, je odhalení překážek na ploše, které by mohly ovlivnit bezpečnost přistání. Tyto překážky se mohou lišit od okolního prostředí ve své barvě nebo textuře, což umožňuje detekci a vymezení jejich polohy pomocí segmentace.

### **3.3.1.5 Simultánní lokalizace a mapování - SLAM**

Pomocí této techniky dokáže UAV současně vytvářet mapu svého okolí a určovat svou vlastní polohu v této mapě. SLAM (Simultaneous Localization and Mapping) se skládá ze dvou základních úloh - konstrukce mapy okolního prostředí a lokalizace, tedy určování polohy a orientace robota nebo UAV v této mapě.

#### **1. Konstrukce mapy okolního prostředí**

Fungování SLAM začíná snímáním okolí pomocí senzorů, jako jsou kamery, laserové skenery, ultrazvukové senzory nebo GPS, které získávají data o okolním prostředí. Pomocí těchto snímků SLAM generuje 3D mapu prostředí a odhaduje jeho polohu. Tato 3D mapa se také používá pro rozpoznání SLZ pro UAV.

Celý proces je vícestupňový a zahrnuje zarovnání dat senzorů pomocí různých algoritmů. SLAM se obvykle používá v neznámém prostředí, kde chybí známé orientační body, které by pomohly UAV navigovat ke stanoveným SLZ.

#### **2. Lokalizace**

Na základě získaných rysů a dat ze sensorů se postupně konstruuje mapa okolního prostředí. Robot nebo letadlo "učí" tvar a charakteristiky prostředí a ukládá je do své mapy.

Zároveň robot nebo letadlo analyzuje data ze sensorů a snaží se určit svou aktuální polohu a orientaci v mapě, tedy provádí lokalizaci. SLAM je iterativní proces, který neustále aktualizuje mapu a polohu robota nebo letadla na základě nových dat ze sensorů. Robot nebo letadlo postupně zlepšuje své vnitřní odhady, přesnost mapy a lokalizace.

Během procesu SLAM identifikuje potenciální plochy, které by mohly být vhodné pro přistání (SLZ). To může zahrnovat otevřené oblasti, pole, rovné střechy budov nebo jiné vhodné povrchy.

Jakmile je identifikováno potenciální SLZ, UAV může vyhodnotit tyto oblasti a zvolit nejvhodnější místo pro přistání. Zároveň si UAV udržuje informace o okolním prostředí a mapu, což mu umožňuje přistát bezpečně a efektivně, i když toto místo není předem známé.

SLAM je složitá a náročná technika, která vyžaduje sofistikované algoritmy a výpočetní sílu. Přesto má široké využití v autonomní robotice, umožňuje robotům a letadlům pohybovat se v neznámém prostředí, plnit úkoly a zároveň si vytvářet a udržovat přesnou mapu tohoto prostředí. Díky SLAM mohou autonomní systémy efektivně a spolehlivě operovat v různých prostředích a zvládat komplexní úkoly, jako je průzkum, vyhledávání nebo navigace.

### 3.3.1.6 Optický tok

Jedná se o techniku, která slouží k analýze pohybu objektů v obraze na základě jejich změn v jasů a intenzitě pixelů mezi dvěma po sobě jdoucími snímky. Princip fungování této metody spočívá v určení směru a rychlosti pohybu objektů na základě výpočtu optického toku, což jsou posuny bodů v obraze mezi dvěma snímky.

Postup začíná získáním dvou po sobě jdoucích snímků (nebo více) zachycujících scénu v krátkém časovém intervalu. Následně se vypočítá gradient obrazu neboli identifikace oblasti, kde se intenzita pixelů rychle mění. Tyto změny indikují pohyb objektů v obraze.

Dále následuje výpočet optického toku, což je proces sledování pohybu objektů mezi dvěma snímky. Algoritmy pro detekci optického toku určují korespondující body mezi snímky a vypočítávají jejich posun. Tím je získána informace o směru a rychlosti pohybu objektů.

Výsledky optického toku mohou být využity v různých aplikacích. Patří sem sledování objektů, stabilizace obrazu, detekce kolizí nebo navigace autonomních vozidel a UAV. Avšak metoda optického toku může být náchylná na chyby, zejména při velkých změnách jasu nebo pokud dochází ke změnám scény mezi snímky. Je proto důležité používat adekvátní algoritmy a techniky, aby byly dosaženy spolehlivé výsledky detekce.

Optický tok může být využit pro sledování pohybu překážek a identifikaci rovných, bezpečných ploch pro přistání. To by mohlo pomoci UAV při autonomním hledání a vyhodnocování vhodných SLZ, a tím zvýšit bezpečnost a spolehlivost jeho operací.

### 3.3.2 Na základě LiDARu

Metoda Laserového dálkoměru (Light Detection and Ranging – LiDAR) se používá k odhadu vzdálenosti mezi dvěma objekty. LiDAR se skládá z pulzního laseru a skeneru, pro přesnější a spolehlivější detekci se používají společně s Global Positioning System (GPS) a Inertial Measurement Unit (IMU) (3).

UAV vybavené LiDARem vysílá pulzní laserové paprsky do cílové oblasti na zemi. Tyto paprsky světla se odráží od oblasti, na kterou narazí a následně senzor změří změnu odraženého pulzního signálu ve srovnání s vysílaným signálem pro výpočet vzdálenosti mezi UAV a cílem. Když je dosah laseru kombinován s daty o poloze a orientaci generovanými ze systémů GPS a IMU, úhlem skenování a kalibrací ze skeneru, je generováno mračno bodů. Každé mračno bodů má trojrozměrné souřadnice, které odpovídají konkrétnímu bodu na zemském povrchu, od kterého se laserový puls odrážel. Tato mračna bodů se používají ke generování nového digitálního výškového modelu (DEM), ze kterého lze generovat 3D reprezentaci cíle. V případě známé přistávací plochy je UAV trénováno s datovou sadou obsahující snímky potenciálních SLZ. Při potřebě přistání UAV začne porovnávat pořízené snímky s dříve natrénovanými snímky a pokud se ve snímku zdá některá plocha totožná s natrénovanými plochami, je tato plocha klasifikována jako SLZ.

LiDARy využívají pokročilé senzory, které používají laserové paprsky pro měření vzdálenosti a mapování prostoru. Tyto senzory jsou obvykle složitější a dražší na výrobu než kamery, které fungují na principu zachytávání obrazů pomocí světla.



### 3.3.3 Kombinace LiDARu a kamery

Kombinovaný přístup využívá jak kameru, tak LiDAR k detekci potenciálních přistávacích ploch. LiDAR je příliš drahý na to, aby se dal použít v hromadné výrobě (3). Generuje přesné 3D mračno bodů pronikající hustými oblastmi pokrytými vegetací nebo lesy. Implementace algoritmu hledání SLZ může detekovat nejlepší místa pro přistání UAV.

#### 3.3.3.1 Digitální výškový model (Digital Elevation Model - DEM)

Jedná se o 3D reprezentaci povrchu terénu generovaná z údajů o nadmořské výšce terénu, která je běžně známá jako výška povrchu terénu ve srovnání s referenčním bodem. UAV může generovat DEM pomocí svých palubních senzorů: kamera a LiDAR.

LiDAR vysílá laserový paprsek a měří čas, než se paprsek vrátí odražený od povrchu objektu. Poté zaznamenává údaje o vzdálenosti a také o úhlu, pod kterým je paprsek odražen. Tyto údaje se pak používají k vytvoření trojrozměrného modelu scény.

Je také možné použít předem stanovený DEM, například od Národního úřadu pro letectví a vesmír (National Aeronautics and Space Administration - NASA), který má vlastní datovou sadu DEM. Pokud lze UAV během mise připojit k DEM konkrétního terénu, UAV může snadno najít SLZ.

Pro generování DEM je třeba připravit datovou sadu z mračna bodů LiDARu po předběžném zpracování místních odlehlých hodnot LiDARu. Pomocí připravené datové sady jsou pozemní a nepozemní body odděleny pomocí různých metod. Jakmile jsou uzemňovací body odděleny, DEM je generován interpolací zemních bodů. Jedním z náročných úkolů při generování DEM pomocí LiDARu je provedení pozemního filtrování na základě prvního nebo posledního návratu dat LiDAR. Někteří výzkumníci dávají přednost použití posledního návratu pro pozemní filtrování, protože laserové paprsky pronikají hlouběji do vegetačních oblastí. To poskytuje přesný soubor dat pro generování DEM, ze kterého lze snadno určit SLZ.

# Kapitola 4

## Simulační prostředí a použité technologie

Tato kapitola je zaměřena na simulační prostředí, které sloužilo jako klíčový nástroj pro provedení zkoumání detekce SLZ. Jsou zde popsány obecné simulátory a konkrétní použité technologie, které umožnily simulovat a analyzovat detekci SLZ v kontrolovaném a reprodukovatelném prostředí.

### 4.1 Simulátory

Simulátor je programový nástroj, který vytváří virtuální prostředí, ve kterém lze simulovat různé procesy, situace nebo události, jako například let letadla, jízdu vlaku, chování robotů, atd. Simulátor umožňuje uživatelům testovat různé scénáře a parametry bez potřeby fyzické implementace v reálném světě (4).

Simulátor může být buďto v podobě softwaru běžícího na počítači, nebo v podobě hardwaru, který umožňuje uživatelům interakci s virtuálním prostředím. Výběr simulátoru závisí na konkrétním účelu a aplikaci, pro kterou je použit.

#### 4.1.1 Výhody

1. Snížení nákladů

Pokud je třeba testovat nový robotický systém v reálném světě, je zapotřebí koupit nejen samotný hardware, ale také nákladnou výbavu na

snímání dat a testování. Simulace například v simulačním programu Gazebo umožňuje vytvořit virtuální model robota a prostředí, ve kterém se bude pohybovat, bez nutnosti investovat velké množství peněz do fyzického hardware.

## 2. Flexibilita

V simulátoru lze snadno měnit prostředí a scénáře, což je u fyzického testování mnohem obtížnější. Například je možné jednoduše změnit osvětlení nebo povrch, na kterém se robot pohybuje, či vytvořit naprosto nové prostředí pro testování robota.

## 3. Bezpečnost

Testování robotických systémů v simulátoru umožňuje vývojářům testovat systémy v bezpečném prostředí, bez rizika poškození hardware nebo způsobení úrazu.

## 4. Rychlost

Testování v simulátoru může být rychlejší než v reálném světě, protože simulace mohou být spuštěny rychleji a snadněji než fyzické testování. To znamená, že vývojáři mohou rychleji testovat a iterovat hardware a algoritmy.

## 5. Opakovatelnost

Simulace umožňují opakovat testy vícekrát, což je u fyzického testování obtížné, zejména pokud testování vyžaduje specifické podmínky. Pokud je například potřeba testovat robot v různých podmínkách počasí, simulace umožní jednoduše změnit podmínky v simulaci a opakovat testy.

## 6. Vzdělávání

Simulace mohou být použity k výuce a výzkumu v oblasti robotiky a automatizace. Studenti mohou v simulaci zkoumat a experimentovat s různými robotickými systémy a vytvářet nové algoritmy a řídicí strategie.

## 7. Testování systémů v raném stádiu vývoje

To umožňuje vývojářům rychleji a efektivněji vyvinout a testovat nové technologie, což může vést k výraznému zlepšení robotických systémů v budoucnosti.

## 4.1.2 Nevýhody

### 1. Složitost

Simulační modely mohou být složité a jejich vývoj a provoz vyžadují specializované znalosti a školení. To může ztížit efektivní využití simulace pro ty, kteří nemají potřebné odborné znalosti.

### 2. Omezený rozsah

Simulace je omezena rozsahem vyvíjeného modelu. Modely nemusí být schopny zohlednit všechny proměnné a faktory, které mohou ovlivnit reálný systém nebo proces, což vede k neúplným nebo nepřesným výsledkům.

### 3. Určitá nepřesnost

Nemusí vždy přesně reprezentovat modelovaný systém nebo proces v reálném světě. To může vést k nepřesným předpovědím a falešnému pocitu důvěry ve výsledky. Vyskytuje se zde jistá aproximace reality neboli nesrovnalosti ve výsledcích simulace a výsledcích v realitě.

## 4.1.3 Popis konkrétních simulátorů

Simulace umožňují vytváření realistických scénářů pro testování robotických systémů v různých situacích. To je užitečné pro výuku a výzkum v oblastech jako je autonomní řízení, robotická manipulace a navigace. Konkrétní simulátory, které je možné použít pro kování detekce SLZ, jsou Gazebo a Airsim.

### 4.1.3.1 Gazebo

Jedná se o open-source simulátor robotů a UAV (5), který umožňuje uživatelům testovat, ladit a optimalizovat ovládání UAV v simulovaném prostředí. Gazebo nabízí široké spektrum funkcí, jako jsou 3D vizualizace, fyzikální simulace, podpora různých typů senzorů, podpora vývoje autonomního ovládání a mnoho dalších.

Jednou z výhod Gazebo je, že umožňuje uživatelům testovat a ladit ovládání UAV bez nutnosti vlastního fyzického UAV. To umožňuje úsporu nákladů a zrychlení vývoje nových algoritmů a aplikací. Gazebo také umožňuje

uživatelům vytvářet a sdílet vlastní modely UAV a prostředí, což zvyšuje flexibilitu a přizpůsobivost simulátoru.

Vývojové týmy mohou Gazebo využít pro testování různých scénářů, včetně testování bezpečnosti letu, odolnosti proti poruchám a simulace různých povětrnostních podmínek. Tento simulátor také umožňuje testovat nové algoritmy autonomního ovládání, včetně detekce a sledování cílů, navigace v prostoru a mnoho dalších.

Gazebo je velmi užitečný nástroj pro vývoj a testování UAV a umožňuje vývojářům a týmům snadno a efektivně testovat své nápady a řešení v bezpečném a simulovaném prostředí.

#### 4.1.3.2 Airsim

Je to open-source simulátor pro UAV, vyvinutý společností Microsoft (6). Jeho hlavním účelem je poskytnout vývojářům a výzkumníkům bezpečné a efektivní prostředí pro testování nových algoritmů a aplikací v oblasti autonomního ovládání UAV.

AirSim je postaven na platformě Unreal Engine a nabízí mnoho funkcí, jako jsou realistické 3D vizualizace, fyzikální simulace, podpora různých typů senzorů, včetně kamer, LiDARů, radarů a GPS. Tento simulátor také umožňuje vývojářům a výzkumníkům testovat své algoritmy v různých prostředích, včetně městských a venkovských oblastí. Simulátor umožňuje uživatelům vytvářet a upravovat prostředí a objekty v simulovaném světě. Tento simulátor také podporuje vývoj autonomního ovládání UAV, včetně plánování trasy, detekce a vyhýbání se překážkám a mnoho dalších.


AirSim je vyvinut primárně pro výzkumné účely a je k dispozici zdarma pro osobní a komerční použití. Tento simulátor je velmi populární v komunitě vývojářů a výzkumníků UAV díky vysokému výkonu a širokému spektru funkcí, které poskytuje.

## 4.2 Podrobnosti použité simulace

Tato sekce shrnuje všechny programy a knihovny, které jsou použity pro sestavení a spuštění simulace.

## 4.2.1 Gazebo

Simulace jsou provedeny v Gazebu kvůli již zmíněným výhodám 4.1.3.1. Hlavními důvody použití Gazeba je jeho rozšiřitelnost, což znamená, že je velké množství přístupných materiálů od různých uživatelů. Dalším důvodem je, že základy simulace, které se v práci budou potřebovat, jsou již postaveny. Předností Gazeba je analýza, která z něj dělá preferovanou možnost nad jinými simulátory.



Obrázek 4.1: Ukázka načtené simulace

## 4.2.2 PX4-Autopilot

Je open-source autopilotní systém dostupný na [px4.io](http://px4.io), který je navržen pro autonomní řízení letadel, vrtulníků, vírníků a dalších bezpilotních prostředků. Jedná se o populární platformu v komunitě bezpilotních letadel a je známá pro svou spolehlivost, flexibilitu a širokou škálu funkcí.

PX4 je vysoce modulární a rozšiřitelný jak z hlediska hardwaru, tak softwaru. Využívá architekturu založenou na portech, což znamená, že když vý-

vojáři přidají komponenty, rozšířený systém neztrácí robustnost ani výkon. Knihovna je navržena tak, aby byla propojena s vestavěným počítačovým viděním pro autonomní schopnosti, což snižuje vstupní bariéru pro vývojáře pracující na algoritmech lokalizace a detekce překážek. Všechny moduly jsou samostatné a lze je snadno vyměnit za jiný modul bez úpravy jádra. Funkce se snadno nasazují a překonfigurují.

PX4 je součástí Dronecode, což je nezisková organizace spravovaná Linux Foundation za účelem podpory používání open source softwaru na létajících vozidlech. Dronecode také hostí QGroundControl, MAVLink a MAVSDK, které budou popsány dále.

### 4.2.3 QGroundControl

Jedná se o open-source softwarovou platformu, která slouží k řízení a vizualizaci UAV a je k dispozici na webové stránce [qgroundcontrol.com](http://qgroundcontrol.com). Tato platforma je vyvinuta jako součást projektu PX4 Autopilot. QGroundControl je dostupný pro různé operační systémy, včetně Windows, macOS a Linux.

QGroundControl poskytuje uživatelům snadno ovladatelné rozhraní pro konfiguraci autopilota a jeho senzorů. Umožňuje nastavit parametry letu, kalibrovat senzory a provádět aktualizace firmwaru. Software také nabízí možnost plánování letových misí pomocí interaktivní mapy. Uživatelé mohou vytvářet cílové body, trasovat letové trasy, nastavit rychlosti a výšky a provádět další pokročilá nastavení.

Dále QGroundControl zobrazuje telemetrická data v reálném čase. Tato data zahrnují informace o poloze letadla, stavu baterie, výšce, rychlosti, teplotě senzorů a dalších důležitých údajů. Software umožňuje ovládání letadla prostřednictvím virtuálních ovladačů nebo fyzických RC ovladačů. Lze tak ovládat letadlo manuálně, přepnout do autonomního režimu nebo provádět další specifické úkoly.

QGroundControl také dokáže zaznamenávat letová data, včetně telemetrie, polohy, akcí operátora a dalších informací. Tyto záznamy lze následně analyzovat a vyhodnocovat pro účely ladění, výzkumu a zlepšování letového výkonu. Celkově je QGroundControl užitečným a všestranným nástrojem pro řízení a sledování bezpilotních letadel s mnoha funkcemi pro pokročilé i začátečnické uživatele.

#### 4.2.4 MAVLink

MAVLink (Micro Air Vehicle Communication Protocol) je binární a open-source protokol komunikace určený pro UAV, který je dostupný na [mavlink.io](http://mavlink.io). Je navržen tak, aby umožnil spolehlivou a efektivní výměnu dat mezi řídicím systémem letounu (autopilotem) a pohonným systémem (například letovým řídicím střediskem) nebo jinými externími zařízeními, jako jsou pozemní stanice, mobilní aplikace nebo senzory.

MAVLink je široce využíván v různých aplikacích UAV a MAV, včetně průmyslového zemědělství, průzkumu a mapování, záchranářských operací, vědeckého výzkumu a dalších. Díky své jednoduchosti, spolehlivosti a široké podpoře se stal jedním z klíčových nástrojů pro komunikaci a řízení bezpilotních letadel a dronů.

#### 4.2.5 OpenCV

Jedná se o open-source knihovnu vyvinutou především pro zpracování obrazu a počítačové vidění, která je k dispozici na webové stránce [opencv.org](http://opencv.org). Tato knihovna je považována za jednu z nejvýznamnějších a nejrozšířenějších v oblasti práce s obrazem a zpracování videa.

OpenCV poskytuje uživatelům širokou paletu nástrojů, funkcí a algoritmů pro práci s obrazovými daty a jejich analýzu. Hlavním jazykem, ve kterém je knihovna napsána, je C++. Také nabízí rozhraní pro další programovací jazyky, včetně Pythonu. Mezi základní funkce, které knihovna obsahuje, patří manipulace s obrazy, jako je načítání a ukládání obrazových souborů, změna velikosti, převod mezi barevnými prostory, aplikace filtrů, detekce hran, práce s histogramy a další.

OpenCV rovněž nabízí pokročilejší algoritmy pro rozpoznávání obličejů, sledování objektů, extrakci rysů, kalibraci kamer, šablonové porovnávání, stereo vidění a další pokročilé funkce. Díky své rozmanitosti a výkonným algoritmům je tato knihovna široce využívána v oblasti vědeckého výzkumu, průmyslu a vývoje aplikací, které vyžadují zpracování obrazu a analýzu. Má široké uplatnění například v počítačovém vidění, robotice, rozpoznávání vzorů, autonomních vozidlech, medicíně, bezpečnostních systémech, interakce člověk-počítač a mnoha dalších oblastech.



## 4.3 ArUco značka

Jedná se o umělou čtvercovou značku, která je tvořena širokým černým okrajem a vnitřní binární maticí, která nese svůj identifikátor (ID) (7). Klíčovým prvkem těchto značek je to, že jedna značka poskytuje dostatečný počet referenčních bodů (čtyři rohy), které umožňují určení pozice kamery. Černý okraj usnadňuje rychlou detekci značky na obraze, zatímco vnitřní binární kód ji činí odolnou vůči chybám a umožňuje použití technik detekce a opravy chyb.

Velikost značky určuje velikost vnitřní binární matice. Například značky o velikosti 4x4 obsahují 16 bitů. Pokud je značka nalezena v obraze v různě natočeném úhlu, je nutné určit její původní orientaci, aby bylo možné jednoznačně identifikovat každý roh. Tento proces se provádí na základě binárního kódu, který nese informace o její orientaci.

Pro určení binárního kódu jsou klíčové následující prvky:


1. Slovník značek (Dictionary)

Je tvořen ze sady značek, které jsou brány v úvahu v konkrétní aplikaci. Jedná se o sadu binárních kodifikací každé značky. Hlavní vlastnosti slovníku jsou velikost slovníku (počet značek, které tvoří slovník) a velikost značky (velikost těchto značek - počet bitů).

2. ID značky

Jedná se o její index ve slovníku, do kterého patří.

Modul ArUco zahrnuje detekci těchto typů značek a nástroje pro jejich použití pro odhad pozice a kalibraci kamery. Funkce ChArUco kombinují ArUco markery s tradičními šachovnicemi, což umožňuje snadnou a všestrannou detekci rohů. Modul také obsahuje funkce pro detekci rohů ChArUco a jejich použití pro odhad pozice a kalibraci kamery.



Obrázek 4.2: Ukázka ArUco značek (8)

### 4.3.1 Tvorba značek

Před jejich detekcí je potřeba značky vytisknout a poté umístit do prostředí. Obrázky značek lze generovat pomocí funkce "generateImageMarker(dictionary, id, sidePixels, img, borderBits)". Parametry této funkce jsou:

1. dictionary - dříve vytvořený objekt dictionary
2. id - ID požadované značky
3. sidePixels - velikost obrázku výstupní značky zadáno v pixelech
4. img - výstupní obrázek

5. borderBits - volitelný parametr k určení šířky černého okraje značky (výchozí hodnota je 1)

### 4.3.2 Detekce značky

Pokud obrázek obsahuje značky ArUco, musí proces detekce vrátit seznam detekovaných značek. Každá detekovaná značka obsahuje polohu jeho čtyř rohů na obrázku (v původním pořadí) a ID značky.


Proces detekce značek se skládá ze dvou kroků:

1. Detekce potencionálních značek

V obrázku se hledají čtvercové útvary, které jsou kandidáty na označení. Začne se adaptivním prahováním pro segmentaci značek, poté jsou z prahovaného obrazu extrahovány kontury (linie) a ty, které nejsou konvexní nebo se nepřibližují čtvercovému tvaru, jsou vyřazeny. Je také použito dodatečné filtrování.

2. Určení, zda se jedná o skutečné značky analýzou jejich vnitřní kodifikace

Tento krok zahrnuje postup extrakce bitů z každé značky. Nejprve se aplikuje perspektivní transformace, aby se značka převedla do své standardní podoby. Poté je tento standardní obraz prahován pomocí metody Otsu, což je automatická technika prahování obrazu, a to za účelem oddělení bílých a černých bitů. Značka je potom rozdělena do různých buněk podle její velikosti a okraje. V každé buňce se spočítá počet bílých a černých pixelů, což umožní určit, zda odpovídají bílým nebo černým bitům. Poté jsou bity analyzovány, aby se zjistilo, zda značka odpovídá specifickému slovníku. Pokud je to potřeba, jsou použity techniky opravy chyb, aby se zajistila správná interpretace značky.



Obrázek 4.3: Ukázka detekce značek (9)


### 4.3.3 Odhad pozice

Pro určení polohy kamery je důležité mít k dispozici parametry kalibrace kamery, což zahrnuje kamerovou matici a koeficienty zkreslení. Tato kalibrace je obvykle prováděna jednou a platí, pokud nejsou provedeny žádné zásadní změny v optice kamery, jako je změna zaostření.

Výsledkem kalibrace je matice kamery o rozměrech  $3 \times 3$  obsahující ohniskovou vzdálenost a souřadnice středu kamery, což jsou tzv. vnitřní parametry. Dále jsou získány koeficienty zkreslení, které jsou reprezentovány vektorem obsahujícím 5 nebo více prvků a slouží k modelování zkreslení způsobeného kamerou.

Při odhadu polohy značek ArUco je možné odhadnout polohu každé značky zvlášť. Pozice kamery, vzhledem k značce, je pak určena pomocí 3D transformace, která převádí souřadnicový systém značky do souřadnicového systému kamery. Toto zahrnuje vektory rotace a translace, které popisují

pozici a orientaci kamery v prostoru vzhledem k značce.



Obrázek 4.4: Ukázka odhadu pozice (10)

# Kapitola 5

## Proces přistávání na SLZ

Důležitou třídou UAV jsou kvadrokoptéry, které jsou díky svým vynikajícím vlastnostem (vysoká manévrovatelnost, spolehlivost, různorodá použitelnost a hospodárnost) často používané (11).

Při návrhu přistání kvadrokoptéry je důležité zvážit přítomnost přízemního efektu a vnějšího rušení, které jsou známé jako hlavní faktory snižující výkonnost kvadrokoptér při letu v malých výškách.

Přestože bylo prozkoumáno mnoho řídicích technik, návrh vysoce výkonných řídicích jednotek pro kvadrokoptéry zůstává náročný a ve vědecké komunitě je široce používán. Algoritmy pro přistání na pevných platformách nemohou splnit požadavky na výkonnost při přistání, když jsou platformy uvedeny do pohybu.

Zatížení kvadrokoptéry omezuje kapacitu baterie, kterou může nést. Kvadrokoptéra proto potřebuje často přistávat kvůli výměně nebo dobíjení baterie po krátké době provozu.

Následující metody uvádějí příklady autonomního rozhodování při přistání.

### 5.1 Autonomní plánovač přistání

V článku (11) se řeší algoritmus autonomního přistání kvadrokoptéry, který umožňuje UAV robustně a přesně přistát na zvedací plošině. Kromě toho je zde navržen postup přistání, který zajišťuje bezpečné a spolehlivé splnění úkolu přistání (Autonomní plánovač přistání).

Jakmile je spuštěna úloha přistání, plánovač zajistí, aby UAV dodrželo

postup přistání, který se skládá z pěti fází:

1. Přiblížení k oblasti obsahující SLZ

V této fázi je UAV řízeno tak, aby dosáhlo přistávací plochy horizontálně při zachování své výšky.

2. Horizontální přiblížení k SLZ

Jakmile je SLZ detekováno kamerou, plánovač nasměruje kvadrokoptéru tak, aby se k cíli přiblížila horizontálně, dokud vodorovná vzdálenost mezi vozidlem a cílem nesplní danou podmínku.

3. Sestup nad přistávací cíl

Když je kvadrokoptéra horizontálně dostatečně blízko k cíli, začne klesat, přičemž si udržuje horizontální vzdálenost k cíli. Pokud během Fáze 2 a Fáze 3 není SLZ detekováno (po určitou dobu), tak bude plánovač považovat cíl za dočasně ztracený a manipuluje s vozidlem tak, aby vystoupalo do předem definované výšky k vyhledání cíle.

4. Konečný přístup

Když je kvadrokoptéra vertikálně blízko k SLZ, plánovač provede fázi konečného přiblížení včetně snížení plynu vozidla a deaktivace stabilizovaného řízení.

5. Přistání dokončeno

Jakmile UAV stojí na přistávací plošině, plánovač jej odzbrojí a úkol přistání je dokončen.

Pokud je SLZ ztraceno na určitou dobu a je vyčerpán určitý počet pokusů jeho vyhledání, tak UAV přistane na aktuální pozici.

## 5.2 Stroj přistávacího stavu

Tento dokument (12) se zabývá vnímáním, ovládáním a plánováním trajektorie pro identifikaci a přistání na jedoucím autě rychlostí 15km/h. Používá se zde UAV typu Hexakoptéra, která je vybavena palubními senzory a počítačem. UAV detekuje vůz pomocí monokulární kamery a předpovídá budoucí pohyb vozu pomocí nelineárního modelu pohybu. Při sledování vozu přistane

UAV na střeše a připevní se pomocí magnetických nohou. Navržený systém je plně autonomní od vzletu až po přistání.

UAV je řízeno strojem přistávacího stavu (LANDING STATE MACHINE - LSM) od vzletu až po přistání. LSM převezme kontrolu nad UAV poté, co operátor vydá signál nebo po uplynutí určitého času od spuštění. Po vzletu přepne UAV do stavu "Let do čekacího bodu", což přesune UAV do výšky 8m nad křižovátku dvou silnic, kde se LSM přepne do stavu "Čekání na SLZ", dokud se v zorném poli neobjeví vůz se SLZ.

Když je cíl poprvé spatřen, LSM se přepne do stavu "Zarovnání horizontální polohy se SLZ" a začne UAV vyrovnávat svou horizontální polohu s vozem, přičemž si udržuje 8m výšku.

Poté, co je UAV vyrovnán s vozem vodorovně do 1,5m, LSM se přepne do stavu "klesání". V tomto stavu se výška UAV snižuje na 4m, což je nejnižší výška, ve které je stále možné sledovat vůz s ohledem na konkrétní konfiguraci UAV a kamery.

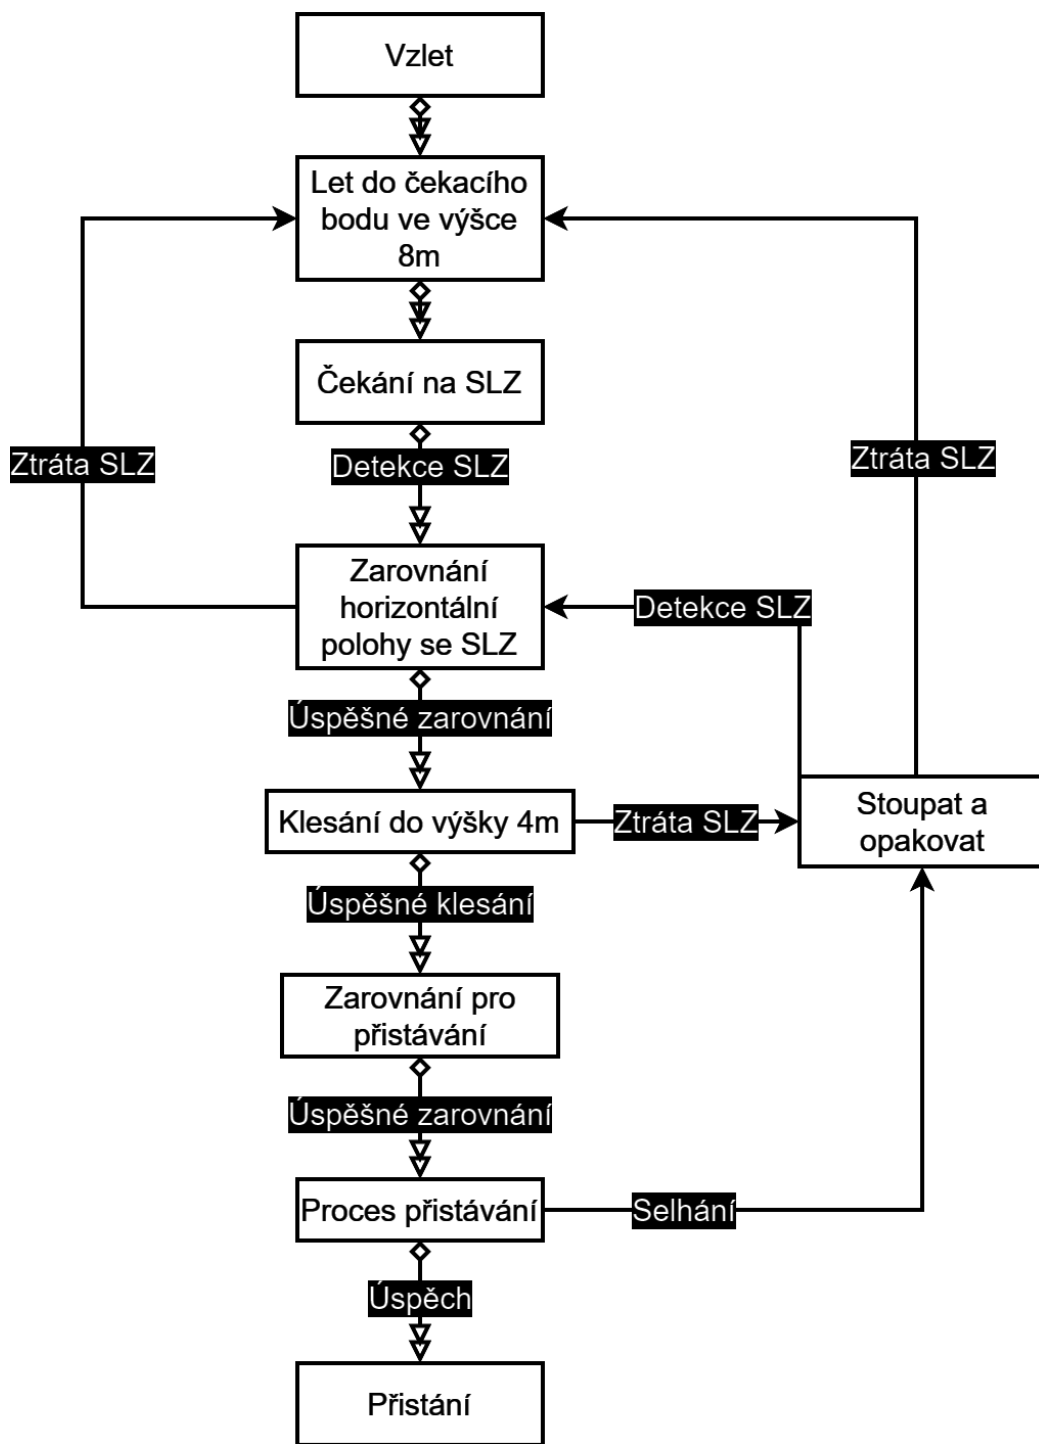
Jakmile je dosaženo výšky 4m, LSM přejde do stavu "Zarovnání pro přistávání", kde čeká na splnění dvou podmínek pro zahájení konečného přistání na jedoucím voze.

1. Vyrovnání polohy UAV vodorovně do 0,3m od středu SLZ
2. Přejednutí do pozemního stavu je povoleno pouze nad příjímými částmi trati (rovná cesta)

Po splnění podmínek je proveden přistávací manévr, při kterém se provede rychlý sestup na střechu vozu. Během přistání jsou motory přerušeny signálem z laserového dálkoměru směřujícího dolů nebo je celé přistání přerušeno kvůli překročení nízkého výškového prahu (1,5m nad zemí).

Pokud se SLZ ztratí z dohledu během některé z výše zmíněných fází přistání, LSM přejde do stavu "Stoupat a opakovat". Pokud není SLZ znovu detekován, LSM přejde zpět do stavu "Letu do čekacího bodu". Pokud je vůz detekován ve stavu "Stoupat a opakovat", proces "Zarovnání horizontální polohy se SLZ" se opakuje.





Obrázek 5.1: Schéma rozhodování při přistávání s použitím LSM

## 5.3 Přistávání v simulaci

Jednotlivé metody rozhodování jsou popsány v následující kapitole u konkrétních přístupů k detekci SLZ. Postup přistání při použití kamery pro detekci SLZ je popsán v sekci 6.3 a při použití kombinace kamery a LiDARU je popsán v sekci 6.4.

# Kapitola 6

## Simulace detekce SLZ

Kapitola se zabývá zhodnocením efektivity detekce ArUco značek z malé i velké výšky a následné simulování a zhodnocení několika metod detekce SLZ a následovného přistání.

Parametry použité kamery v simulaci jsou: zorné pole - 60 stupňů, šířka záběru - 1024 pixelů, výška záběru - 768 pixelů a snímků za sekundu - 30.

Veškerý kód použitý v této práci je dostupný na platformě github Jan1Kovar/UAV\_landing\_BP (13).


### 6.1 Efektivita detekce ArUco

Při použití ArUco značek patří k důležitým rozhodnutím velikost značky a počet čtverců, ze kterých se bude skládat. Oba parametry rozhodují o tom, z jaké maximální a minimální výšky je možné ArUco značku rozpoznat. Tato sekce se věnuje zjištění závislosti mezi uvedenými parametry a maximální a minimální výškou detekce.

#### 6.1.1 Popis měření maximální výšky


Měření je provedeno v simulaci, jejíž prostředím je rovná plocha s texturou podobné trávě. ArUco značka je umístěna na šedé rovné ploše do středu simulace. Po načtení modelů drona a ArUco značky, dron zahájí svůj let a přesune se nad značku do zvolené výšky, kde se značku pokusí rozpoznat a při úspěšném rozpoznání začne stoupat. Ve stoupání pokračuje pokud značku

detekuje. Při ztrátě značky se stoupání zastaví a poslední záznam o aktuální výšce je zaznamenán jako instance maximální výšky při daném pokusu.



Obrázek 6.1: Ukázka simulace měření dat v simulaci

Pro testování jsou vybrány čtyři ArUco značky ukázané na obrázku 6.2. Každá značka je označena AXA-B-C, kde AXA označuje počet čtverců, ze kterých se skládá, B označuje počet značek se stejným AXA ve slovníku a C označuje ID značky, neboli její pozici ve slovníku. Značky jsou vytvořeny pomocí funkce popsané v sekci 4.3.1.




Obrázek 6.2: Použité ArUco značky

### 6.1.2 Výsledek měření maximální výšky

Maximální výška detekce ArUco značky je naměřena pro všechny kombinace počtu čtverců a velikosti značky. Měření je provedeno pětkrát a výsledný průměr v metrech je uveden v následující tabulce 6.1 a obrázek grafu 6.3.

		Velikost strany značky [m]					
		0,1	0,2	0,3	0,4	0,5	0,6
Počet čtverců	4x4	5,519	10,570	16,719	21,537	24,836	27,927
	5x5	4,784	9,169	15,191	17,568	22,818	26,687
	6x6	4,696	8,595	13,829	16,501	21,596	25,059
	7x7	4,330	7,634	12,210	15,215	19,981	23,576

Tabulka 6.1: Tabulka výsledků měření maximální výšky



Obrázek 6.3: Graf maximálních výšek detekce

Naměřená data ukázaly, že nejvyšší možné výšky rozpoznání značky při jakémkoliv rozměru je dosaženo s nejmenším počtem čtverců 4x4. Důvodem tohoto výsledku je, že čím menší je počet čtverců, ze kterých se značka skládá, tím zabírají větší plochu, a proto se snáze rozpoznávají z větších vzdáleností. Rozdíl rozměru čtverců je možné vidět v obrázku 6.2.

Značky s vyšším počtem čtverců poskytují větší přesnost, spolehlivost, robustnost rozpoznávání a větší počet unikátních identifikátorů. To umožňuje přesnější a spolehlivější rozpoznávání značek i v situacích, kdy jsou značky v prostředí s vyšším stupněm zkreslení, odstínů, odrazů a šumu nebo se vyskytuje více značek v blízké oblasti. Značky jsou navrženy tak, aby byly odolnější vůči chybám detekce a rozpoznání. Pokud je část značky zakryta, poškozena nebo zkreslena, systém stále dokáže spolehlivě identifikovat značku díky redundanci informací z více čtverců.

### 6.1.3 Závěr měření maximální výšky

Volba počtu čtverců značek závisí na konkrétních potřebách aplikace a na podmínkách, ve kterých se budou značky používat. Pro simulaci v této práci

stačí počet čtverců 4x4, jelikož se jedná o statický a známý dronport v rovinném prostření s homogenní texturou.

#### 6.1.4 Popis měření minimální výšky


Měření je provedeno ve stejné simulaci, která byla použita v minulém měření. Po načtení modelů drona a ArUco značky, dron zahájí svůj let a přesune se nad značku do zvolené výšky, kde se značku pokusí rozpoznat a při úspěšném rozpoznání začne klesat. V klesání pokračuje, dokud je značku schopný rozpoznat nebo dokud se kousek značky nedostane mimo kameru. Při ztrátě značky se zastaví a jeho poslední záznam o aktuální výšce je zaznamenán jako instance minimální výšky při daném pokusu.

Jelikož se v této simulaci nedají využít výhody značek s větším počtem čtverců, tak hlavní rozdíl mezi typy značek je maximální výška detekce. V minulém pokusu se ukázaly značky typu 4x4 jako nejvíce efektivní. Značky tohoto typu se budou používat v dalších simulacích.

#### 6.1.5 Výsledek měření minimální výšky

Minimální výška detekce ArUco značky je naměřena pro značky s počtem čtverců 4x4 a stejné velikosti, jako při měření maximální výšky detekce. Měření je provedeno pětkrát a výsledný průměr v metrech je uveden v následující tabulce 6.2 společně s teoretickými výsledky a dále jsou porovnány v obrázku 6.5.

Je možné vypočítat teoretickou minimální výšku detekce neboli minimální výšku, při které se značka přesně vejde do záběru kamery. Kamera zabírá obraz pod úhlem  $60^\circ$  a za předpokladu, že je kamera natočena kolmo ke značce, svírají zbylé úhly  $60^\circ$ . Dále za použití délky strany značky je možné sestavit následující trojúhelník, který je zobrazený na obrázku 6.4 a je vytvořený za pomoci aplikace Geogebra. Parametry trojúhelníku se vypočítají z následujících rovnic.



Obrázek 6.4: Teoretický trojúhelník

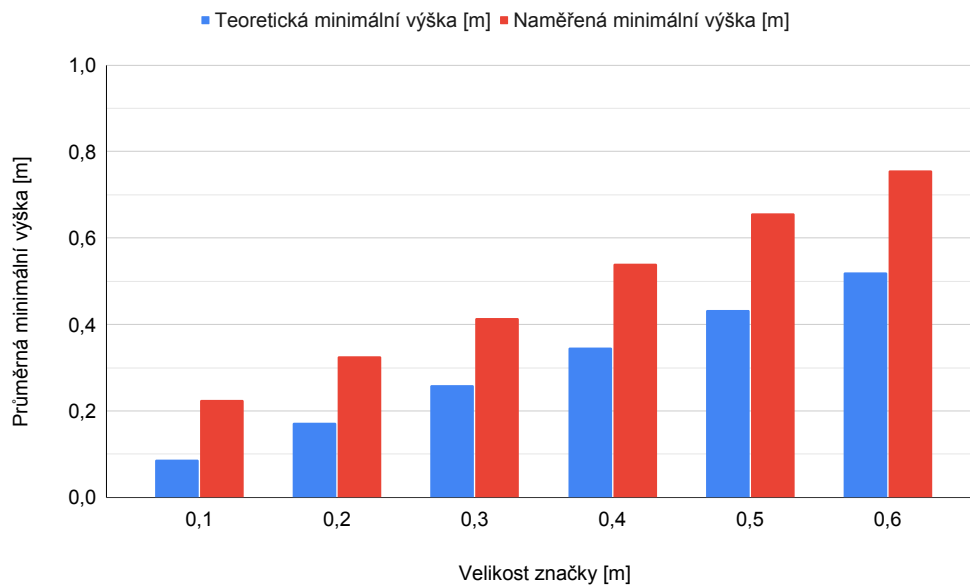
$$\text{min výška} = \sqrt{\frac{2 * a^2 + 2 * b^2 - c^2}{4}} \quad (6.1)$$

$$a = b = c = \text{Výška značky} = \text{Výška záběru 768 pixelů} \quad (6.2)$$

	Velikost strany značky [m]					
	0,1	0,2	0,3	0,4	0,5	0,6
Naměřená minimální výška [m]	0,226	0,325	0,415	0,541	0,657	0,755
Teoretická minimální výška [m]	0,087	0,173	0,26	0,346	0,433	0,52

Tabulka 6.2: Tabulka výsledků měření minimální výšky






Obrázek 6.5: Graf minimálních výšek detekce

### 6.1.6 Závěr měření minimální výšky

Na samotný dronport jsou umístěny dvě ArUco značky. Obě značky mají vnitřní počet čtverců 4x4. První značka má velikost strany 0,1m a ID je 1. Jejím účelem je zvýšit přesnost přistání na požadovaném místě. Druhá značka má velikost strany 0,2m a ID je 2, jejím účelem je zvýšit maximální výšku detekce. Také se v prostředí simulace nevyskytuje žádná překážka, která by mohla značku překrýt.



Obrázek 6.6: Ukázka dronportu

## 6.2 Na základě LiDARu

Při detekci SLZ pomocí LiDARu je UAV vybaveno LiDAREm, který vysílá laserové paprsky směrem dolů na zem a následně zachytává odražené paprsky. Tímto způsobem je možné získat výšková data a informace o povrchu terénu pod UAV. LiDAR je schopen poskytovat velmi přesné vzdálenostní a prostorové informace o okolí s vysokou rychlostí a přesností.

Detekce přistávací plochy pomocí LiDARu se obvykle provádí následujícími kroky:

1. Skenování terénu

LiDAR vysílá laserové paprsky směrem dolů a zachytává odražené signály. Tímto způsobem se získají data o terénu pod UAV. LiDAR po-

skytuje informace o vzdálenostech, intenzitě odrazu a dalších charakteristikách povrchu.

## 2. Segmentace přistávací plochy

Na základě získaných dat se provádí analýza a segmentace terénu. Přistávací plocha je identifikována na základě určitých kritérií, jako je například konzistence výškových dat, textura povrchu nebo odrazivost.

## 3. Filtrace a vyhodnocení

Filtrační algoritmy se používají k odstranění šumu a nežádoucích objektů, což umožňuje lepší identifikaci přistávací plochy.

## 4. Přistání

Po úspěšné detekci přistávací plochy použije UAV předešlé informace k přistání. LiDAR poskytuje přesné vzdálenostní informace, které mohou být využity pro výpočet trajektorie a správné přistání na přistávací ploše.

Pro simulaci v této práci je detekce SLZ pouze za pomoci LiDARu nepraktická a neefektivní. Jelikož je prostředí simulace rovina, tak LiDAR může detekovat pouze samotný dronport.

Z těchto důvodů detekce SLZ na základě LiDARu nebude simulována.

## 6.3 Na základě kamery

V rámci simulace je UAV vybaveno kamerou a dále GPS, což reprezentuje ovládání letu UAV pomocí zadaných souřadnic. To umožňuje UAV znát svojí horizontální polohu a pro zjednodušení přibližnou vertikální polohu. Jelikož je SLZ v této simulaci reprezentováno známým dronportem, u kterého je známa pozice, a ARUCO značkami, které se na něm vyskytují, je nalezení dronportu jednoduché.


Po zahájení letu se UAV přesune na stejné horizontální souřadnice, jako má dronport. Vertikální souřadnice UAV jsou vybrány náhodně v rozmezí 4m až 8m nad zemí simulace. Tato akce je pojmenována "Pohyb nad dronport" a jedná se o výchozí bod, do kterého se UAV vrací, pokud dojde k selhání v některé sekci. Jelikož je výška vybrána z náhodného rozsahu, lze tuto akci považovat za změnu pohledu na dronport, která může některé problémy vyřešit.

Po dosažení výchozího bodu se zahájí proces přistávání, který začíná snímáním obrazu kamerou. Pokud z nějakého důvodu snímání není zahájeno opakuje se akce "Pohyb nad dronport".

Při úspěšném zahájení snímání obrazu se zkontroluje, zda je obraz dostupný a pokud není, opakuje se akce "Pohyb nad dronport".

Nyní je z dostupného obrazu možné detekovat ArUco značky na dronportu. V případě, kdy není detekována žádná značka, opakuje se akce "Pohyb nad dronport".

Když dojde k detekci alespoň jedné značky, UAV začne snižovat svou vertikální výšku a přibližuje se k dronportu. Zároveň se snaží mít značku v prostředku snímaného obrazu a také se snaží mít stejnou orientaci jako značka. Informace o orientaci značky je získána z detekovaného levého horního rohu značky a díky detekci středu značky stačí, aby v prostředku obrázku byl jeden bod. Detekce těchto bodů je ukázána na obrázku 6.7. Pokud jsou detekovány obě značky, je k orientaci upřednostněna menší značka oproti větší značce.

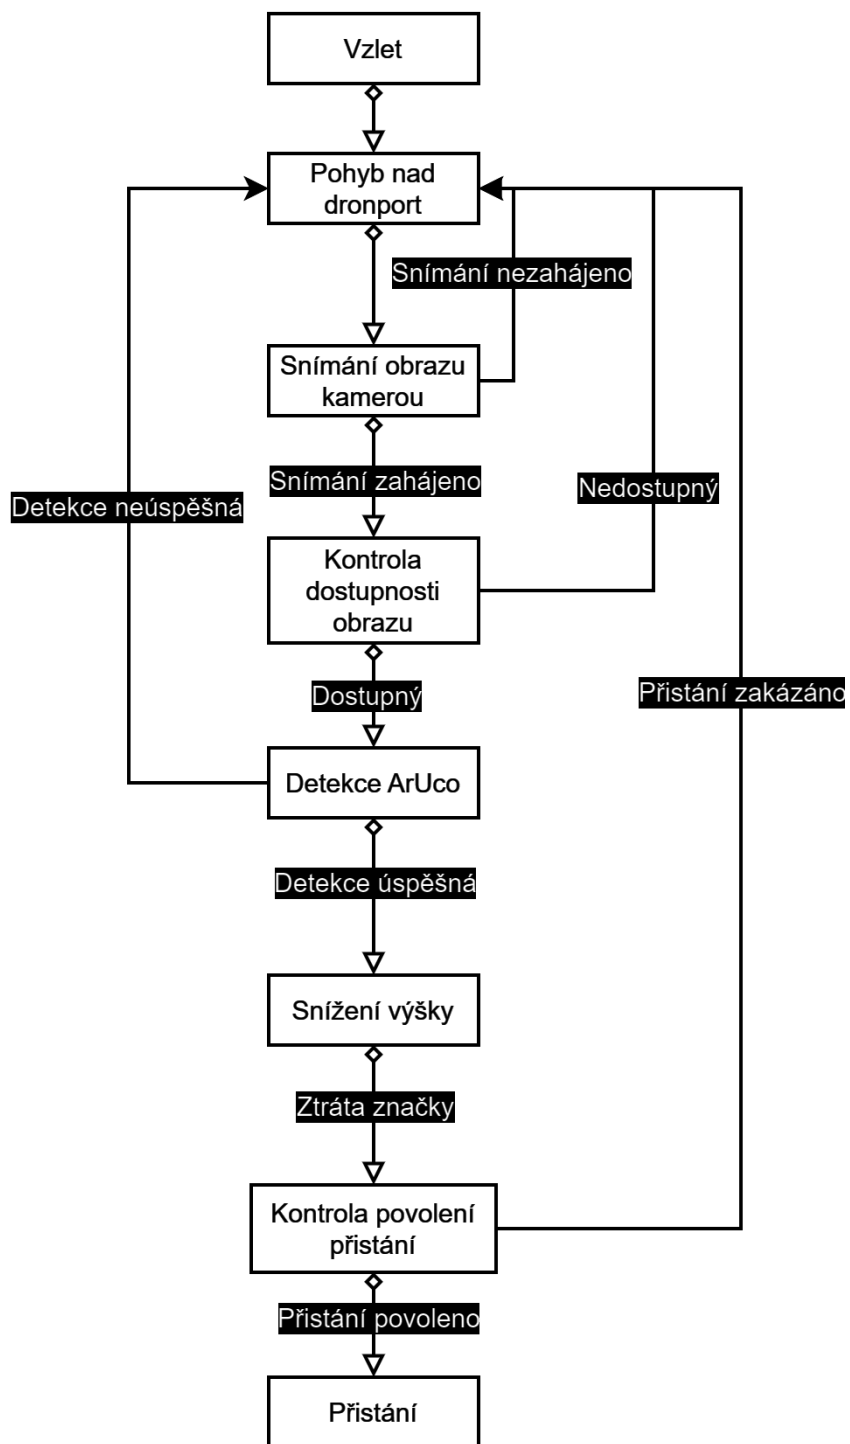


Obrázek 6.7: Ukázka záznamu kamery drona

V této části je nutné zmínit, že se v žádné části přistávání kromě akce "Pohyb nad dronport" nepoužívá informace o vertikální výšce. Z toho důvodu se zde vyskytuje problém při ztrátě všech ArUco značek. Při zjišťování

efektivitu detekce ArUco značek, je zjištěna průměrná minimální výška detekce značky, která má hodnotu 0,226m pro menší značku. Po klesnutí pod tuto hranici jsou všechny značky ztraceny a je nutné rozlišit dva případy, kdy dojde ke ztrátě všech značek. První případ je chyba při klesání a je nutné opakovat akci "Pohyb nad dronport". Druhý případ nastane právě při klesnutí pod zmíněnou minimální hranici, což znamená, že je možné přistát.

Tento problém lze řešit odhadem vzdálenosti pomocí ArUco značky, k čemuž je zapotřebí kalibrace kamery a samotné funkce, které jsou k tomu potřebné, nejsou kompatibilní s verzí OpenCV, která je v simulaci využívána. Další řešení, které je v simulaci implementováno, je, že pokud je detekována pouze malá značka, je přistávání povoleno. To způsobí, že po překročení minimální hranice a ztrátě všech značek, UAV přistane. Pro omezení předčasného povolení přistávání, při chybě v detekci velké značky v oblasti, ve které má být stále detekovatelná, je přistávání zamítnuto, pokud jsou detekovány obě značky. Toto řešení má problém v malé výškové oblasti, kde je přesažena minimální výška detekce velké značky 0,325m a nastává detekce pouze malé značky, což způsobuje povolení přistání. Pokud je v této části přistávání UAV vytlačeno z dronportu, nemá možnost opravit horizontální výšku a přistane mimo dronport. K tomuto případu může dojít například při silném větru nebo srážce s jiným tělesem. V simulaci se žádné tyto případy neuvažují a tím pádem lze tuto metodu pokládat za dostačující.



Obrázek 6.8: Schéma rozhodování při přistávání s použitím pouze kamery

## 6.4 Kombinace kamery a barometru

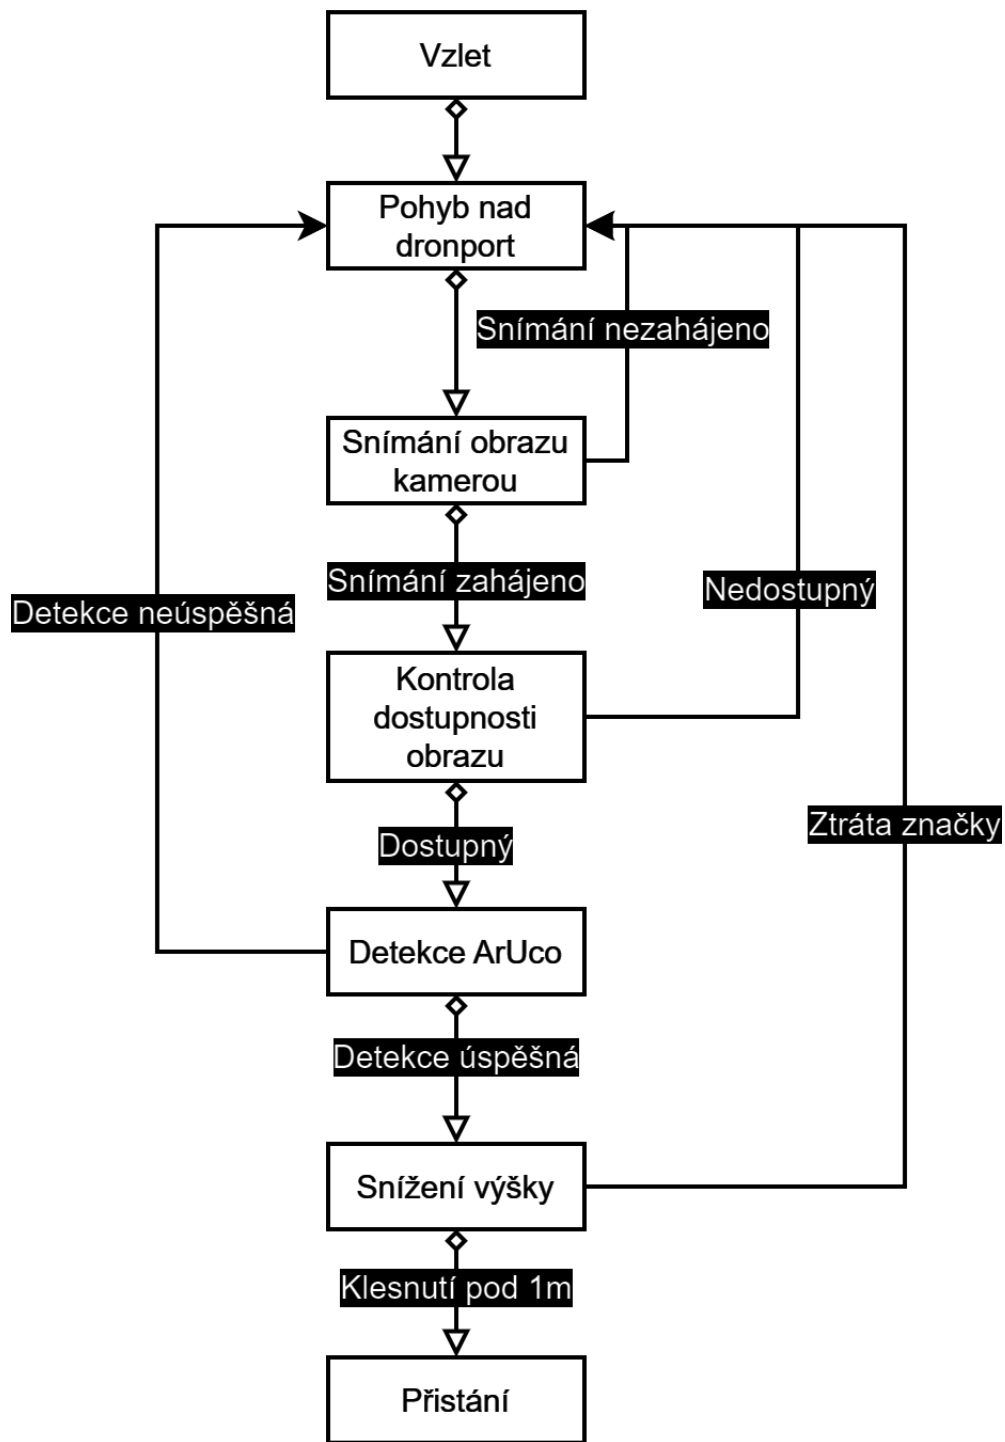
UAV v této simulaci je vybaveno kamerou a GPS jako v předešlé simulaci a navíc obsahuje barometr, který měří tlak, jenž na UAV působí. Jelikož je prostředí simulace rovná plocha, tak pro přibližné měření výšky UAV je možné využít barometr, protože úroveň změny tlaku v závislosti na výšce je konstantní. Na rovné ploše bez vlivu větru se atmosférický tlak mění s výškou v přibližně konstantním tempu. Pomocí barometru je měřena hodnota tlaku před vzletem a během letu a z rozdílu těchto hodnot je možné přibližně odhadnout aktuální výšku UAV.

V této konkrétní simulaci je tedy možné použít barometr místo LiDARu na odhad výšky. Barometr je používán pro zjištění výšky UAV ve všech předešlých úlohách. UAV musí startovat z nejnižšího místa v simulaci, což je zde samotná zem, jinak při výpočtu výšky může dosáhnout záporných hodnot, když se přesune do místa, které je položené níže než start. Pokud by v simulaci bylo zahrnuto mnoho aspektů, nebyla by tato náhrada možná. Příklady těchto aspektů jsou například vliv větru a velké pozemní nerovnosti.

Simulace probíhá velice podobně jako v předešlé sekci, ale je zde informace o aktuální výšce UAV. To velice usnadňuje mnoho procesů při přistávání. Akce "Pohyb nad dronport" se liší tím, že nyní se UAV přesune vždy do výšky 6m. Tato akce stále slouží jako výchozí bod, do kterého se UAV vrací, pokud dojde k selhání v některé sekci.

Průběh simulace je stejný až do sekce, kdy je potřeba přistát. Díky informaci o výšce je problém z minulé sekce, o rozhodnutí, zda ztráta všech značek je způsobena poruchou a nebo se UAV nachází nad dronportem, vyřešen. Nyní se neuděluje povolení přistání, ale UAV přistane pokud klesne pod 1m a zároveň detekuje malou značku. Když dojde ke ztrátě všech značek je zahájena akce "Pohyb nad dronport". Tato metoda je mnohem spolehlivější než řešení v minulé sekci.

LiDAR je zde nahrazen barometrem a metoda funguje jen za velice omezených podmínek. V simulaci je dostačující, ale kdekoliv jinde je třeba pro efektivní měření výšky použít LiDAR. Metoda detekce pouze za použití kamery je dostačující, ale dodatečná informace o výšce velice usnadňuje automatizaci procesu přistání. Kombinace LiDARu a kamery umožňuje při detekci přistávacích ploch dosáhnout lepšího výkonu za různých podmínek, a to i za snížené viditelnosti nebo v prostředí s různorodými překážkami.



Obrázek 6.9: Schéma rozhodování při přistávání s použitím kamery a barometru/LiDARu



# Kapitola 7

## Závěr

V této práci je věnována pozornost simulačnímu prostředí, které poskytuje prostor pro testování různých přístupů k detekci přistávacích ploch a autonomnímu přistání. Klíčovou součástí detekce přistávacích ploch v simulaci jsou ArUco značky, které poskytly spolehlivou a efektivní metodu detekce.

Jsou provedeny experimenty, které zkoumaly efektivitu ArUco značek při detekci a to zejména maximální a minimální výška detekce. Maximální a minimální výšku detekce ovlivňuje velikost značky a počet čtverců, které značku tvoří. Tyto experimenty ukázaly, že největší efektivitu detekce poskytují značky s počtem čtverců 4x4, ale se sníženou spolehlivostí a to hlavně v různorodém prostředí.

Jsou zkoumány různé procesy autonomního přistání na plošinách, zejména za využití kamery a dalších senzorů. Detekce SLZ s použitím pouze LiDARu je poněkud složitá a pro simulaci, která je použita v práci, je neefektivní. Detekce SLZ s použitím pouze kamery je mnohem jednodušší za použití již zmíněných ArUco značek, ale pro zvýšení efektivitu je potřeba informace o výšce. Konkrétně v tomto typu simulace je možné použít barometr pro výpočet výšky UAV, což zlepšuje efektivitu jak při navigaci, tak při přistávání. Výsledky ukázaly, že autonomní přistání na plošinách pomocí navrhovaných metod dosahují dostačujících a spolehlivých výsledků.

Závěrem je třeba konstatovat, že analýza přístupů k autonomnímu přistání dronu na plošině je důležitým krokem v rozvoji bezpilotních letounů a jejich aplikací. Navrhované přístupy a výsledky simulací nabízejí cenný zdroj informací a přehled pro další výzkum v této oblasti. Cílem je dosáhnout ještě vyšší úrovně bezpečnosti, přesnosti a spolehlivosti autonomního přistání dronu na plošině.

Výsledky této práce by se daly rozšířit především různým prostředím simulace, která je velice zjednodušená a nepodobá se prostředí v realitě. Pro metody vytvořené v této práci by rozšíření simulace mohlo představovat zásadní problém a metody by bylo nutné upravit. Aby se simulace podobala více realitě, je nutné přidat výškovou a texturovou rozmanitost.

Další možností rozšíření je přidání více senzorů, kterými jsou například LiDAR, ultrazvukové senzory, infračervené senzory, sonar a radar. Každý z těchto senzorů přináší nové metody detekce přistávacích ploch, které lze vhodně kombinovat a dosáhnout tak nejvyšší možné efektivity v daném prostředí a pro konkrétní mise, ve kterých je UAV využíváno. Při rozhodování o přidání senzorů je důležité zvážit, které senzory poskytnou relevantní informace pro danou úlohu a zároveň je nutné zhodnotit, zda je implementace finančně výhodná. Náležitě zvolená kombinace senzorů může přinést vyšší přesnost detekce, ale je nutné najít kompromis mezi touto přesností a celkovými náklady, neboť každá úloha může vyžadovat jinou prioritu mezi těmito faktory.

# Seznam obrázků

2.1	Schéma klasifikace UAV . . . . .	8
3.1	Schéma klasifikace přistávacích ploch . . . . .	17
3.2	Schéma detekcí vhodné přistávací plochy . . . . .	20
4.1	Ukázka načtené simulace . . . . .	32
4.2	Ukázka ArUco značek (8) . . . . .	36
4.3	Ukázka detekce značek (9) . . . . .	38
4.4	Ukázka odhadu pozice (10) . . . . .	39
5.1	Schéma rozhodování při přistávání s použitím LSM . . . . .	43
6.1	Ukázka simulace měření dat v simulaci . . . . .	46
6.2	Použité ArUco značky . . . . .	47
6.3	Graf maximálních výšek detekce . . . . .	48
6.4	Teoretický trojúhelník . . . . .	50
6.5	Graf minimálních výšek detekce . . . . .	51
6.6	Ukázka dronportu . . . . .	52
6.7	Ukázka záznamu kamery drona . . . . .	54
6.8	Schéma rozhodování při přistávání s použitím pouze kamery . . . . .	56
6.9	Schéma rozhodování při přistávání s použitím kamery a barometru/LiDARu . . . . .	58

# Seznam tabulek

6.1	Tabulka výsledků měření maximální výšky . . . . .	47
6.2	Tabulka výsledků měření minimální výšky . . . . .	50

# Literatura

- [1] M. S. Alam and J. Oluoch, “A survey of safe landing zone detection techniques for autonomous unmanned aerial vehicles (uavs),” *Expert Systems with Applications*, vol. 179, p. 115091, 2021.
- [2] Mohsan, S. A. Hassnain, M. A. Khan, F. Noor, I. Ullah, and M. H. Alsharif, “Towards the unmanned aerial vehicles (uavs): A comprehensive review,” *Drones*, vol. 6, no. 6, 2022. [Online]. Available: <https://www.mdpi.com/2504-446X/6/6/147>
- [3] P. Wang, “Research on comparison of lidar and camera in autonomous driving,” in *Journal of Physics: Conference Series*, vol. 2093, no. 1. IOP Publishing, 2021, p. 012032.
- [4] L. Žlajpah, “Simulation in robotics,” *Mathematics and Computers in Simulation*, vol. 79, no. 4, pp. 879–897, 2008.
- [5] N. Koenig and A. Howard, “Design and use paradigms for gazebo, an open-source multi-robot simulator,” in *IEEE/RSJ International Conference on Intelligent Robots and Systems*, Sendai, Japan, Sep 2004, pp. 2149–2154.
- [6] S. Shah, D. Dey, C. Lovett, and A. Kapoor, “Airsim: High-fidelity visual and physical simulation for autonomous vehicles,” in *Field and Service Robotics*, 2017. [Online]. Available: <https://microsoft.github.io/AirSim/paper/main.pdf>
- [7] S. N. Sergio Garrido. Basic detection and pose estimation from single aruco markers. [Online]. Available: [https://docs.opencv.org/4.x/d5/dae/tutorial\\_aruco\\_detection.html](https://docs.opencv.org/4.x/d5/dae/tutorial_aruco_detection.html)

- [8] ——. Basic detection and pose estimation from single aruco markers. [Online]. Available: <https://docs.opencv.org/4.x/markers.jpg>
- [9] ——. Basic detection and pose estimation from single aruco markers. [Online]. Available: <https://docs.opencv.org/4.x/singlemarkersdetection.jpg>
- [10] ——. Basic detection and pose estimation from single aruco markers. [Online]. Available: <https://docs.opencv.org/4.x/singlemarkersaxes.jpg>
- [11] Baca, Tomas, P. Stepan, V. Spurny, D. Hert, R. Penicka, M. Saska, J. Thomas, G. Loianno, and V. Kumar, “Autonomous landing on a moving vehicle with an unmanned aerial vehicle,” *Journal of Field Robotics*, vol. 36, no. 5, pp. 874–891, 2019.
- [12] N. Xuan-Mung, S. K. Hong, N. P. Nguyen, T.-L. Le *et al.*, “Autonomous quadcopter precision landing onto a heaving platform: New method and experiment,” *IEEE Access*, vol. 8, pp. 167 192–167 202, 2020.
- [13] J. Kovář. Jan1kovar/uav\_landing\_bp. Datum přístupu: 6.8.2023. [Online]. Available: [https://github.com/Jan1Kovar/UAV\\_landing\\_BP](https://github.com/Jan1Kovar/UAV_landing_BP)