

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

Fakulta elektrotechnická

Katedra radioelektroniky



**Odhad polohy chodce založený  
na detekci kroku z inerciálních měření**

**Pedestrian Positioning from Step  
Tracking Based on Inertial  
Measurements**

DIPLOMOVÁ PRÁCE

Autor:	Bc. David Tupý
Studijní program:	Elektronika a komunikace
Specializace:	Technologie internetu věcí
Vedoucí práce:	Ing. Josef Krška
Rok:	2023



## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Tupý** Jméno: **David** Osobní číslo: **483908**  
Fakulta/ústav: **Fakulta elektrotechnická**  
Zadávací katedra/ústav: **Katedra radioelektroniky**  
Studijní program: **Elektronika a komunikace**  
Specializace: **Technologie internetu věcí**

## II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

**Odhad polohy chodce založený na detekci kroku z inerciálních měření**

Název diplomové práce anglicky:

**Pedestrian Positioning from Step Tracking Based on Inertial Measurements**

Pokyny pro vypracování:

Nalezněte a implementujte vhodné algoritmy pro detekci kroku a odhad jeho délky z dat akcelerometru. Využijte dalších inerciálních měření (například z gyroskopu nebo magnetometru) k odhadu směru kroku. Ověřte zda lze z výše zmíněných dat odhadovat polohu uživatele a opakovatelnost tohoto odhadu. Volitelně se zabývejte možnostmi inicializace odhadování a zobecnění řešení.

Seznam doporučené literatury:

- [1] S. O. H. Madgwick, A. J. L. Harrison and R. Vaidyanathan, "Estimation of IMU and MARG orientation using a gradient descent algorithm", 2011, doi: 10.1109/ICORR.2011.5975346
- [2] Y. Jin, Hong-Song Toh, W. -S. Soh and Wai-Choong Wong, "A robust dead-reckoning pedestrian tracking system with low cost sensors", 2011, doi: 10.1109/PERCOM.2011.5767590
- [3] W. Kang, S. Nam, Y. Han and S. Lee, "Improved heading estimation for smartphone-based indoor positioning systems", 2012, doi: 10.1109/PIMRC.2012.6362768
- [4] P. Aggarwal, N. El-Sheimy, A. Noureldin and Z. Syed, "MEMS-Based Integrated Navigation", Artech, 2010

Jméno a pracoviště vedoucí(ho) diplomové práce:

**Ing. Josef Krška katedra radioelektroniky FEL**

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

Datum zadání diplomové práce: **01.02.2023**

Termín odevzdání diplomové práce: \_\_\_\_\_

Platnost zadání diplomové práce: **22.09.2024**

\_\_\_\_\_  
Ing. Josef Krška  
podpis vedoucí(ho) práce

\_\_\_\_\_  
doc. Ing. Stanislav Vítek, Ph.D.  
podpis vedoucí(ho) ústavu/katedry

\_\_\_\_\_  
prof. Mgr. Petr Páta, Ph.D.  
podpis děkana(ky)

## III. PŘEVZETÍ ZADÁNÍ

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

\_\_\_\_\_  
Datum převzetí zadání

\_\_\_\_\_  
Podpis studenta



### **Prohlášení**

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

V Praze dne 20.5.2023

.....  
autor

## **Poděkování**

Rád bych poděkoval především svému vedoucímu práce Ing. Josefu Krškovi za jeho čas a skvělý přístup při vedení práce, cenné rady a velikou ochotu. Poděkování patří také Ing. Václavu Navrátilovi, Ph.D. za obohacující konzultace a asistenci při měření. Rovněž bych chtěl poděkovat mému okolí za trpělivost a podporu.

David Tupý

## Abstrakt

*Tato práce představuje a implementuje metody detekce kroku a odhadu vzdálenosti, založené na měřeních akcelerometru. Dále popisuje způsoby odhadu směru kroku, ke kterým je využito dalších inerciálních měření z gyroskopu a magnetometru. Spojením všech těchto metod vytváří ucelený odhad polohy chodce. Poté ukazuje algoritmus, který umožňuje zjistit obecnou orientaci zařízení a s touto znalostí získat lineární zrychlení. K ověření funkčnosti implementovaných algoritmů byla provedena měření, která ukazují na očekávané nedokonalosti senzorů při využití samostatného nekompenzovaného gyroskopu nebo magnetometru k odhadu směru. Bylo ověřeno, že systém dokáže být krátkodobě až střednědobě stabilní při fúzi dat kalibrovaného gyroskopu a magnetometru. Pro dlouhodobé využívání není systém vhodné samostatně používat.*

## Klíčová slova

Detekce kroku, odhad délky kroku, odhad směru pohybu, odhad polohy, Kalmanův filtr, odhad orientace, inerciální senzory, inerciální navigace, indoor lokalizace, navigace

## Abstract

*This thesis introduces and implements step detection algorithms and methods for step length estimation based on accelerometer measurements. Next, it describes the heading estimation based on other inertial measurements from a gyroscope and a magnetometer. Combining all these methods creates a comprehensive estimate of the pedestrian's position. Then an algorithm is described that allows us to determine the device's general orientation and obtain linear acceleration from this knowledge. Measurements were taken to verify the functionality of implemented algorithms. They pointed to expected imperfect sensor behavior if an uncalibrated gyroscope and magnetometer were used to estimate position. It has been verified that the system can be stable in the short to medium term when fusing calibrated gyroscope and magnetometer data. It is not suitable to use the system alone for long-term use.*

## Keywords

Step detection, step length estimation, heading estimation, position estimation, Kalman filter, orientation estimation, inertial sensors, inertial navigation system, indoor positioning, navigation





# Obsah

<b>Seznam obrázků</b>	<b>xi</b>
<b>Seznam tabulek</b>	<b>xii</b>
<b>Seznam zkratk</b>	<b>xiii</b>
<b>1 Úvod</b>	<b>1</b>
1.1 Inerciální navigace . . . . .	2
1.2 Inertial Measurement Unit . . . . .	2
1.2.1 Senzory pohybu . . . . .	2
1.3 Pedestrian dead reckoning . . . . .	3
1.4 Navrhovaný systém . . . . .	4
<b>2 Detekce kroku</b>	<b>5</b>
2.1 Zpracování dat . . . . .	5
2.1.1 Zrychlení kolmé k zemi . . . . .	5
2.1.2 Norma zrychlení . . . . .	7
2.2 Metody detekce . . . . .	7
2.2.1 Peak detection . . . . .	7
2.2.2 Zero crossing . . . . .	8
2.2.3 G crossing . . . . .	9
2.2.4 Další metody . . . . .	10
<b>3 Odhad délky kroku</b>	<b>11</b>
3.1 Statické metody . . . . .	11
3.2 Dynamické metody . . . . .	11
3.2.1 Frekvenční modely . . . . .	12
3.2.2 Modely využívající vertikálního zrychlení . . . . .	12
3.3 Kalibrace . . . . .	13
<b>4 Odhad směru kroku</b>	<b>17</b>
4.1 Magnetometr . . . . .	17
4.2 Gyroskop . . . . .	20
4.3 Odhad polohy . . . . .	21
<b>5 Kalmanův filtr</b>	<b>23</b>
5.1 Využití KF . . . . .	25
5.1.1 Odhad polohy z jednoho senzoru . . . . .	26
5.1.2 Fúze měření z více senzorů . . . . .	27

5.2	Rozšířený Kalmanův filtr . . . . .	28
<b>6</b>	<b>Obecná orientace</b>	<b>29</b>
6.1	Souřadné systémy . . . . .	29
6.1.1	East – North – Up . . . . .	29
6.1.2	Lokální a body rámeč . . . . .	30
6.2	Vyjádření orientace . . . . .	31
6.2.1	Eulerovy úhly . . . . .	32
6.2.2	Kvaterniony . . . . .	32
6.3	Odhad orientace . . . . .	34
6.3.1	EKF s kvaterniony . . . . .	34
6.4	Výpočet lineárního zrychlení . . . . .	38
<b>7</b>	<b>Měření</b>	<b>39</b>
7.1	Aplikace – sběr dat . . . . .	39
7.1.1	Android . . . . .	39
7.1.2	Aplikace . . . . .	39
7.1.3	Použité senzory . . . . .	40
7.1.4	Sběr dat . . . . .	40
7.2	Testovací měření . . . . .	41
7.2.1	Zpracování dat . . . . .	41
7.2.2	Interiér . . . . .	41
7.2.3	Exteriér . . . . .	42
7.3	Výsledky . . . . .	43
7.3.1	Interiér . . . . .	44
7.3.2	Exteriér . . . . .	48
7.4	Diskuze . . . . .	50
7.5	Možnosti dalšího směřování . . . . .	51
<b>8</b>	<b>Závěr</b>	<b>53</b>
	<b>Literatura</b>	<b>60</b>
	<b>A Měření v halových laboratořích</b>	<b>61</b>
	<b>B Venkovní měření</b>	<b>62</b>

# Seznam obrázků

1.1	Vývojový diagram zpracování dat . . . . .	4
2.1	Lineární zrychlení ve všech 3 osách . . . . .	6
2.2	Originální a filtrovaný signál v ose $z$ . . . . .	6
2.3	Originální a filtrovaná norma lineárního zrychlení . . . . .	7
2.4	Detekce kroku pomocí <i>peak detection</i> . . . . .	8
2.5	Detekce kroku pomocí <i>zero crossing</i> . . . . .	9
2.6	Detekce kroku pomocí <i>g crossing</i> . . . . .	9
3.1	Maximální a minimální lineární zrychlení pro odhad délky kroku . .	13
3.2	Přesnost odhadu délky kroku . . . . .	14
4.1	Magnetické pole ve 3 osách . . . . .	18
4.2	Magnetická deklinace pro korekci magnetometru [42] . . . . .	18
4.3	Směr pohybu z magnetometru . . . . .	19
4.4	Úhlová rychlost ve 3 osách . . . . .	20
5.1	Princip Kalmanova filtru . . . . .	25
6.1	<i>Body</i> rámeč telefonu . . . . .	30
6.2	Lokální a <i>body</i> rámeč . . . . .	31
7.1	Aplikace pro sběr dat . . . . .	40
7.2	Rozmístění referenčních bodů . . . . .	42
7.3	Venkovní trasa po Technické ulici [74] . . . . .	43
7.4	Venkovní trasa kolem budovy FEL a FS, ČVUT [74] . . . . .	43
7.5	Chůze ve tvaru obdélníku . . . . .	44
7.6	Chůze ve tvaru osmičky . . . . .	45
7.7	Náhodná chůze s ostrým zatočením . . . . .	45
7.8	Náhodná chůze ve tvaru kruhů . . . . .	46
7.9	Čtverec po směru hodinových ručiček . . . . .	46
7.10	Čtverec proti směru hodinových ručiček . . . . .	47
7.11	Schody nahoru . . . . .	47
7.12	Schody dolů . . . . .	48
7.13	Okruh kolem budovy FEL a FS ČVUT . . . . .	49
7.14	3 okruhy kolem Technické ulice . . . . .	49
A.1	Fotografie z měření na chodbě v halových laboratořích . . . . .	61
A.2	Fotografie z měření na chodbě v halových laboratořích . . . . .	61
B.1	Venkovní trasa v Technické ulici z leteckého pohledu [74] . . . . .	62

B.2 Venkovní trasa kolem budovy FEL a FS, ČVUT z leteckého pohledu [74] . . . . .	62
---	----

## Seznam tabulek

3.1 Srovnání reálných a zkalibrovaných délek kroků . . . . .	14
7.1 Porovnání výsledných chyb v odhadu polohy . . . . .	50

# Seznam zkratek

<b>AHRS</b>	Attitude and Heading Reference System; referenční systém polohy a směru
<b>ČVUT</b>	České vysoké učení technické v Praze
<b>DCM</b>	Direction Cosine Matrix; matice rotace
<b>DOF</b>	Degree of Freedom; stupeň volnosti
<b>DR</b>	Dead Reckoning
<b>DTW</b>	Dynamic Time Warping; dynamické zakřívování času
<b>EKF</b>	Extended Kalman Filter; rozšířený Kalmanův filtr
<b>EKG</b>	Electrocardiography; elektrokardiografie
<b>ENU</b>	East-North-Up; lokální kartézský souřadný systém
<b>FEL</b>	Fakulta elektrotechnická
<b>FQA</b>	Factored Quaternion Algorithm
<b>FS</b>	Fakulta strojní
<b>GNSS</b>	Global Navigation Satellite System; globální družicový navigační systém
<b>GPS</b>	Global Positioning System; globální polohový systém
<b>IMU</b>	Inertial Measurement Unit; inerciální měřicí jednotka
<b>INS</b>	Inertial Navigation System; inerciální navigace
<b>KF</b>	Kalman Filter; Kalmanův filtr
<b>MARG</b>	Magnetic, Angular Rate and Gravity; spojení tří typů senzorů
<b>MEMS</b>	Microelectromechanical System; mikroelektromechanický systém
<b>NED</b>	North-East-Down; lokální kartézský souřadný systém
<b>PDR</b>	Pedestrian Dead Reckoning; sledování polohy chodce
<b>QUEST</b>	Quaternion Estimator
<b>TRIAD</b>	Tri-Axial Attitude Determination
<b>UKF</b>	Unscented Kalman Filter
<b>UWB</b>	Ultra-Wide Band; Ultraširokopásmová komunikace
<b>WiFi</b>	Wireless Fidelity; bezdrátová síť dle standardu IEEE 802.11
<b>WLAN</b>	Wireless Local Area Network; lokální bezdrátová síť



# Kapitola 1

## Úvod

Potřebami lokalizace objektů se lidstvo zabývá už dlouho. Požadavky odhadu polohy pohyblivého objektu se vyskytují v řadě oborů, např. v navigaci vozidel, robotů, interakci se stroji a v neposlední řadě také v analýze a sledování lidského pohybu. Nějakou formu navigace dnes již využívá téměř každý. Díky rozšíření chytrých telefonů a nositelné elektroniky se poslední dobou rozmáhá snaha odhadovat polohu chodce.

Metody odhadu polohy osob, které poskytují informace o aktuální pozici určitého objektu nebo lokaci člověka, byly v posledních letech intenzivně vyvíjeny. Konkrétně pak téma navigace uvnitř budov je dnes velmi aktuální a je vhodné se jím zabývat. Přesné sledování lidské pozice může být prospěšné v každodenních aktivitách, jako třeba poskytnutí navigace, ale může i zachránit životy v případě živelné katastrofy nebo během zásahů zdravotních složek. Užitečné mohou být i pro lidi se zdravotním handicapem, například pro zrakově postižené.

Mezi nejrozšířenější navigační systémy patří bezesporu *Global Navigation Satellite System* (GNSS) s nejvyužívanější verzí *Global Positioning System* (GPS), ale ty nejsou vždy plně dostačující. Pro venkovní využití poskytují dobrou přesnost, ale jakmile uživatel zajde do budovy, ztratí přímou viditelnost se satelity a v důsledku přestává být lokalizace přesná nebo úplně dostupná.

Jelikož satelitní signál je uvnitř budov utlumený nebo není vůbec dostupný, jsou pro navigaci uvnitř budov potřeba jiné metody. Mezi ně patří například radiová komunikace na krátkou vzdálenost jako *Wireless Local Area Network* (WLAN) nebo technologie Bluetooth, vše lze nakonec kombinovat i s mapovými podklady [1]. Další způsoby, nezávislé na satelitním signálu, jsou právě založené na měřeních inerciálních senzorů, které dokonce ke svému fungování nepotřebují žádný externí zdroj. Všechny přístupy mají svoje výhody a nevýhody a velice často je nevýhoda jednoho výhodou druhého, a proto je vhodné přístupy různě kombinovat [1].

Cílem této práce je vytvořit ucelený algoritmus, který dokáže s jistotou detekovat krok, odhadovat jeho délku a určit směr, kterým byl krok veden. K tomu využívá inerciální senzory uvnitř chytrého mobilního telefonu, který je držen uživatelem v ruce. Zabývá se také obecnou orientací měřicího zařízení, které se vždy nemusí nacházet v předem definované poloze. Daný systém by mělo jít v budoucnu zkombinovat s dalšími systémy pro lokalizaci uvnitř budov a vytvořit ucelený robustní navigační systém.

V prvních částech se práce nejprve věnuje popisu metod pro detekci kroku. V kapitole 2 jsou detailně uvedeny a vyzkoušeny dvě nejrozšířenější metody *peak*

*detection* a *zero crossing*, které k detekci kroku využívají měření zrychlení z akcelerometru. Na detekci kroku navazuje popis metod pro odhad jeho délky v kapitole 3. Zmíněny jsou metody jak statické, tak i metody dynamické, které využívají převážně frekvenci chůze a nebo také vertikální zrychlení. Je vybrána metoda pracující s minimálním a maximálním lineárním vertikálním zrychlením během kroku a je pro aplikaci nakalibrována. Poté jsou v kapitole 4 uvedeny možnosti, jakými lze odhadovat směr vedeného kroku. K tomu jsou využity další inerciální senzory gyroskop a magnetometr a jsou charakterizovány jejich vlastnosti pro výsledný odhad polohy.

V kapitole 5 je uveden Kalmanův filtr, jakožto univerzální nástroj pro zpracování signálu. V této práci umožňuje fúzi dat několika senzorů a ve výsledku také odhad orientace zařízení. Kapitola 6 se zabývá obecnou orientací. Nejprve popisuje potřebné souřadné systémy a přechod mezi nimi. K tomu jsou využity kvaterniony, které jsou poté odhadovány rozšířenou verzí Kalmanova filtru (EKF). Díky známé orientaci je možné získat lineární zrychlení a správně transformovat měření ze všech senzorů.

Kapitola 7 nejprve popisuje princip, jakým jsou získávány data z mobilního telefonu s operačním systémem Android. Hlavním tématem této kapitoly je výsledné měření a testování robustnosti celého navrhovaného systému. K tomu jsou využita nejdříve měření ve vnitřních prostorách budovy a následně i měření venku pod širým nebem.

Ve zbytku této kapitoly budou uvedeny důležité pojmy týkající se odhadu polohy chodce a také budou zmíněny vhodné senzory. Nakonec bude naznačen koncept navrhovaného systému i se všemi omezeními.

## 1.1 Inerciální navigace

Inerciální navigace neboli INS (*Inertial Navigation System*) je samostatné zařízení skládající se z inerciální jednotky a výpočetní jednotky. Výpočetní část zajišťuje výpočet polohy, případně i rychlosti, a je založena na měřeních právě z inerciální jednotky, která bude popsána dále.

## 1.2 Inertial Measurement Unit

*Inertial measurement unit* (IMU) je elektronické zařízení, ve kterém se typicky nachází senzory pohybu jako je tříosý akcelerometr, tříosý gyroskop a většinou také tříosý magnetometr. Pokud jsou dostupné všechny tři senzory a určuje se pomocí nich vhodným algoritmem orientace, systém se také označuje pojmem referenční systém polohy a směru AHRS (*Attitude and Heading Reference Systems*) [2]. Dalším využívaným názvem pro kombinaci těchto tří senzorů je *Magnetic Angular Rate and Gravity* (MARG) [3]. V těchto případech se ve výsledku jedná o devíti-osé zařízení.

### 1.2.1 Senzory pohybu

Senzory pohybu jsou typem senzorů, které reagují na fyzikální podněty jako zrychlení, úhlovou rychlost nebo magnetické pole. Pro tuto práci jsou nejdůležitěj-



šími akcelerometr, gyroskop a magnetometr.

Dnes je většina gyroskopů, akcelerometrů i magnetometrů založená na technologii mikroelektromechanického systému MEMS, jejichž části jsou malé, lehké, levné a mají minimální energetickou spotřebu. I jejich přesnost se za poslední dobu výrazně zlepšila [4]. Díky těmto vlastnostem jsou velice rozšířené a nachází se také v mobilních telefonech [5]. Navzdory posledním technologickým pokrokům jejich parametry jako přesnost, stabilita nebo např. teplotní závislost stále nejsou ideální [6].

#### **Akcelerometr**

Tento senzor poskytuje měření specifických sil. Dokáže určit zrychlení v  $\text{m s}^{-2}$  v jedné nebo více osách svázaných se zařízením. Akcelerometr měří síly dvojího typu. Nejprve gravitační, které jsou stále přítomné a poté lineární, které je způsobené pohybem. Dvojitou integrací by mělo být možné obdržet polohu, ale tomu zabraňuje nezanedbatelný šum akcelerometru.

#### **Gyroskop**

Tento senzor měří úhlovou rychlost v  $\text{rad s}^{-1}$  v jedné nebo více osách svázaných se zařízením. Jeho integrací lze získat úhel.

#### **Magnetometr**

Tento senzor měří magnetické pole v  $\mu\text{T}$  v jedné nebo více osách svázaných se zařízením. Lze použít jako kompas.

## **1.3 Pedestrian dead reckoning**

*Dead reckoning* (DR) technika a jeho varianta pro chodce je proces odhadu současné polohy ze znalosti minulé polohy a rozdílu mezi nimi [7]. Ten lze zjistit buď známou délkou kroku nebo rychlostí uživatele a znalostí směru pohybu.

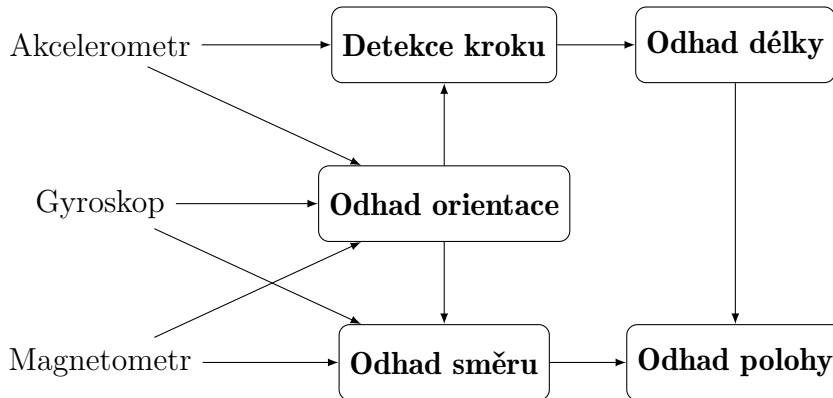
*Pedestrian Dead Reckoning* (PDR) k odhadu polohy využívá převážně inerciální senzory, které délku a směr pohybu dokáží určit. Také je možné k nim přidat barometry, anemometry nebo kamery [8]. Cílem je využívat malé, levné a nositelné senzory často založené na technologii MEMS. Takové senzory však nejsou dokonalé a trpí v čase se akumulujícími chybami, což je největší limitace celého systému, převážně při odhadu směru pohybu. Proto nedokáže dlouhodobě samostatně, bez využití korekčních systémů, fungovat.

Hlavní výhodou PDR je jeho nezávislost na jakémkoliv externí infrastruktuře a systémech. Díky tomu může být využit v jakémkoliv prostředí, typicky právě uvnitř budov. Výstižným příkladem mohou být i zakouřené vnitřní prostory, kterými potřebují projít hasiči [8]. Díky velice rozšířeným chytrým telefonům, které dnes vlastní téměř každý, se dá k DR chodce využít právě telefon.

Samotný DR neposkytuje absolutní řešení, takže je nutná další technika pro získání počáteční polohy [9]. K tomu lze využít externí systémy, které pak při výpadku signálu zastoupí právě PDR a při opětovné dostupnosti mohou korigovat jeho naakumulovanou chybu.

## 1.4 Navrhovaný systém

Celkový systém pro odhad polohy chodce založený na inerciálních senzorech se skládá z několika částí a je uveden na obrázku 1.1. Akcelerometr bude využitý nejprve pro odhad kroku a jeho délky. Gyroskop s magnetometrem pak budou odhadovat výsledný směr pohybu. Následně, kombinací všech zmíněných senzorů bude odhadována orientace měřicího zařízení, aby s touto informací bylo možné správně reprezentovat naměřená data, která jsou využita v blocích Detekce kroku, Odhad délky a Odhad směru. Poté, co proběhnou všechny tyto odhady, je možné s jejich znalostí určit finální odhad polohy chodce.



Obrázek 1.1: Vývojový diagram zpracování dat

Řešení a přístup k odhadu polohy chodce se dělí podle umístění nebo držení měřicího zařízení. Podle [8] je nejvíce studií zaměřeno na připevnění senzorů na kotníku [10] a na držení v ruce [11]. Další studie se také věnují umístění senzorů na hlavě [12], hrudi [13] nebo v oblasti pasu [14]. Tato práce se zabývá umístěním senzorů v podobě mobilního telefonu v ruce chodce.

Důležité je zmínit, že systém má několik omezení. Byly uvažovány pouze kroky dopředu za předpokladu, že se uživatel nepohybuje směrem dozadu nebo úkroky do strany. Dalším předpokladem je, že se chodec pohybuje chůzí pouze ve dvojrozměrném prostoru. Například změna patra v budově, či běh v této práci nebyly řešeny. Nakonec, algoritmy fungují správně pouze pro běžnou chůzi zdravého chodce. Jak je uvedeno v [15], u starších nebo hůře se pohybujících osob výrazně narůstá chyba už v detekci kroku. Jelikož systém zatím není navrhován ve spojení s jiným, je pouze relativní a při zasazení do mapy je mu potřeba určit startovní pozici.

# Kapitola 2

## Detekce kroku

Správné detekování kroku je základním stavebním kamenem pro inerciální navigaci a proto je potřeba se na něj nejvíce zaměřit. Dle Harleho [16] lze krok určit pomocí mnoha druhů senzorů, mezi které patří například optické, tlakové nebo elektromyografické senzory. Dále také senzory inerciální, mezi které spadá především akcelerometr a také gyroskop. Tato kapitola se zabývá detekcí pouze za pomoci akcelerometru.


### 2.1 Zpracování dat

Při úvahách dat akcelerometru jsou v zásadě dvě možnosti jaký použít signál pro detekci kroku. První možností je využít zrychlení kolmé k zemi. Nad tím je možné uvažovat v případě, že je známá orientace zařízení. Pokud se mění, tak je potřeba počítat i s jeho proměnnou orientací v prostoru (natočením) a tedy zakomponovat i údaje z ostatních senzorů. Pak lze data transformovat a pracovat pouze s jednou osou. Druhou možností je použití normy zrychlení, která není závislá na orientaci zařízení.

#### 2.1.1 Zrychlení kolmé k zemi


V případě analýzy zrychlení, které je kolmé k zemi, stačí brát v úvahu pouze jednu osu a to nejčastěji osu  $z$ . Takto to funguje pouze pro zařízení s fixním držením a tedy s neměnicí se orientací – běžně se volí vodorovně se zemí, aby osa  $z$  směřovala kolmo k zemi. Jakmile se telefon i jen trochu nakloní některým směrem, v ose  $z$  přestanou být kroky výrazné a nebude možné je detekovat [17]. Pokud se orientace mění, je nutné s její znalostí zrychlení přepočítat (tím se bude zabývat kapitola 6).

Na obrázku 2.1 je ukázán průběh, jak vypadá zrychlení v  $\text{m s}^{-2}$  bez údaje o gravitaci ve všech 3 osách při provedení deseti kroků. Časový údaj na vodorovné ose je zobrazen v sekundách. Lze pozorovat, že největší dynamika a určitá opakující se sekvence se nachází právě v ose  $z$ .



Obrázek 2.1: Lineární zrychlení ve všech 3 osách

Inerciální senzory se vyrábí v mnoha kvalitativních úrovních, čemuž odpovídají i jejich ceny. V této práci se využívá mobilního telefonu, který takové senzory obsahuje. Bohužel často bývají levné a ne zcela přesné a mohou kvůli tomu trpět problémy. Naměřená data musí být například filtrována, aby se potlačil šum. Filtrací se tedy právě potlačí vysokofrekvenční složky signálu, způsobené např. vibracemi. Vyhlazení signálu pomůže vylepšit kvalitu a přesnost následného zpracování. [18]

Obrázek 2.2: Originální a filtrovaný signál v ose  $z$ 

Signál z obrázku 2.1 je značně zkreslený vlivem šumu senzoru a malých otřesů a bylo by tak problematické ho dále zpracovávat. Frekvence lidské chůze se většinou pohybuje v jednotkách Hz, tudíž je vhodné vyšší frekvence odfiltrovat dolní propustí. Na obrázku 2.2 je vidět originální signál a signál filtrovaný. Je využito

dolní propusti s Butterworthovou aproximací 9. řádu a s mezní frekvencí 3 Hz, podobně jako praktikuje Susi [19].

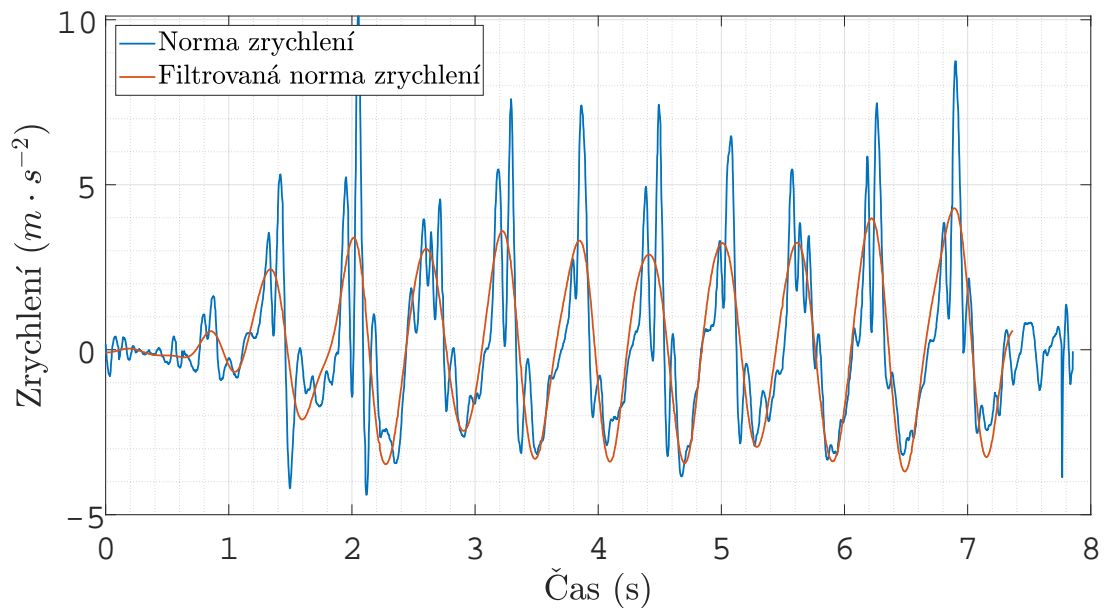
### 2.1.2 Norma zrychlení

Výhodou práce s velikostí zrychlení je její nezávislost na orientaci telefonu, jejíž odhadnutí může být výpočetně náročnější. Kroky se tak objeví pouze v jednom průběhu, do kterého se mohou také víc promítnout náhodné otřesy a manipulace s telefonem.

Rovnice pro normu lineárního zrychlení, která není závislá na náklonu telefonu podle Leppakoski [20] je

$$a(t) = \sqrt{a_x(t)^2 + a_y(t)^2 + a_z(t)^2}, \quad (2.1)$$

kde  $a_x(t)$ ,  $a_y(t)$  a  $a_z(t)$  jsou hodnoty lineárního zrychlení ve třech osách  $x$ ,  $y$  a  $z$ . Stejných 10 kroků jako v předchozí sekci je vidět na následujícím obrázku 2.3. Je zde také nejdříve znázorněn nefiltrovaný a potom filtrovaný průběh stejnou dolní propustí.



Obrázek 2.3: Originální a filtrovaná norma lineárního zrychlení


## 2.2 Metody detekce

Podle [21] se pro detekci kroku, díky charakteristickému průběhu signálu, používají převážně metody *peak detection* a *zero crossing*, které budou vysvětleny dále.

### 2.2.1 Peak detection

Metoda *peak detection* využívá charakteristiku chůze, která vytváří ve vertikálním zrychlení téměř periodický průběh. V tomto tvaru stačí najít dostatečně

vysoké vrcholy, které reprezentují jednotlivé kroky. Zásadním parametrem, který se musí určit předem, je fixní nebo proměnná prahová hodnota, kterou musí vrchol překročit. Vrcholy pod prahovou hodnotou se zamítnou jako falešné detekce způsobené šumem. Průběh 10 kroků lze vidět na obrázku 2.4, kde jsou oranžově označeny vrcholy, které jsou vyhodnoceny jako kroky. [22, 23]



Obrázek 2.4: Detekce kroku pomocí *peak detection*


Zkombinováním [22], [23] a [24] je krok detekován a vyhodnocen v následujících třech krocích:

1. Znaménko vzorku se změní z kladného na záporné  $\text{sgn}(a_z(t) - a_z(t-1)) < \text{sgn}(a_z(t-1) - a_z(t-2))$ , to určí lokální maximum  $a_p$  v čase  $t_p$ .
2. Podezřelý bod s lokálním maximumem musí překročit určený limit  $a_{th}$ , ten může být buď proměnný nebo fixní (na obrázku 2.4 zvoleno  $a_{th} = 2$ ).
3. Přirozená chůze by neměla mít větší frekvenci než 3 Hz. Čas od posledního validního kroku musí být větší než 0,33 s tj.  $(t_{p-1} - t_p) > 0,33$ .

### 2.2.2 Zero crossing


Jak již název napovídá, tato jedna z nejpoužívanějších metod pro detekování kroku využívá průchodu signálu nulou. Samotná detekce začíná, jakmile signál překročí nulu a dostane se ze záporných do kladných hodnot [12]. Za těchto okolností by bylo určeno i mnoho falešných kroků a je proto nutné zvolit fixní nebo dynamicky se měnící práh, kterého musí velikost signálu minimálně dosáhnout, aby se jednalo o validní krok [20]. Detekce jednoho kroku končí buď začátkem dalšího nebo po uplynutí předem daného časového intervalu. Druhá možnost většinou nastává po tom, co uživatel chůzi dokončí.

Průběh signálu pro deset kroků je znázorněn na obrázku 2.5. Modře je vykresleno lineární zrychlení v kolmém směru a červené body poukazují na detekovaný krok.

Obrázek 2.5: Detekce kroku pomocí *zero crossing*

### 2.2.3 G crossing

Při zachování údaje o gravitačním zrychlení se za průchod nulou považuje hodnota  $g$  – jedná se tím pádem o tzv. *g crossing*, který je vidět na obrázku 2.6. Nejčastěji toto nastává, pokud se použije norma zrychlení z celkového zrychlení, které obsahuje lineární i gravitační. Za gravitační zrychlení se typicky považuje hodnota  $g = 9,81 \text{ m s}^{-2}$ . [25]

Obrázek 2.6: Detekce kroku pomocí *g crossing*

### 2.2.4 Další metody

Mezi další méně často využívané algoritmy vyhodnocující krok z dat akcelerometru patří podle Marscholleka [15] např. **Pan-Tomkinsova** metoda, která byla originálně vyvinuta pro zkoumání biologického signálu EKG. Dále také **Dual-Axial** metoda, která kombinuje signál z dvou os zrychlení. Detekovat krok lze i s využitím **autokorelační** metody. Všechny tři postupy však nakonec pracují na bázi hledání vrcholů (*peak detection*) [15].

Dalším významným algoritmem, kterého se občas využívá je **DTW** (*Dynamic Time Warping*) [26]. Touto metodou lze rozšířit základní nejpoužívanější algoritmy a upřesňovat, zda se jedná o validní nebo falešný krok pomocí vzoru, s kterým jsou úseky signálu porovnávány. Když je podobnost podle určeného limitu dostatečná, daný krok se zvaliduje [27].

Všechny tyto metody mají společnou jednu věc. Jsou výpočetně náročnější než metody *peak detection* a *zero crossing* uvedené na začátku sekce. Nejlepších výsledků a přesnosti detekce dosahuje podle [26] zmíněné DTW. Ovšem také za cenu největší výpočetní náročnosti. Zbylé algoritmy lepší výsledky nevykazují. V rámci zachování co největší rychlosti detekování a co nejmenší výpočetní náročnosti jsou v dalších kapitolách využívány metody *peak detection*, *zero crossing* či jejich kombinace.



# Kapitola 3

## Odhad délky kroku

Po tom, co je krok detekován, se může přejít k odhadu jeho délky. Délka kroku se obvykle liší u každého člověka a občas i u každého kroku jednoho člověka. Proto je nutné délky kroků co nejlépe odhadovat, aby výsledná navigace byla co nejpřesnější. Celkovou ušlou vzdálenost lze vypočítat z odhadu délky každého detekovaného kroku. K výslednému odhadu lze přistupovat dvěma způsoby – statickým, kde se uvažuje délka kroku jako konstanta, a dynamickým, kde může být každý krok jinak dlouhý.

### 3.1 Statické metody

Jako první budou popsány statické metody, které jsou oproti dynamickým značně jednodušší. Tyto způsoby nerespektují rozdílné délky jednotlivých kroků a využívají jednu průměrnou hodnotu kroku, která se prohlásí za konstantu. Tou se pouze vynásobí počet kroků a výsledek dá dohromady délku ušlé trasy. Průměrná hodnota může být nastavena na „obyčejnou“ chůzi. Bohužel, kvůli tomu statické modely pro svoji jednoduchost vykazují velkou nepřesnost. [21, 28]

Jednou možností je nechat uživatele zadat délku jako konstantu. Sofistikovaněji lze podle [29] vzdálenost odhadnout jako konstantu, která závisí na pohlaví a výšce každého uživatele. Předpokládá se, že každý validní krok má stejnou délku  $SL$  a ta je modelována rovnicí

$$SL = h \cdot K, \quad (3.1)$$

kde  $h$  je výška člověka a  $K$  je konstanta v závislosti na pohlaví – pro muže je rovna 0,415 a pro ženy 0,413. [30]

V rámci zvyšování přesnosti, která je u inerciální navigace stěžejní je vhodnější implementovat odhady dynamické, které jsou popsány dále.

### 3.2 Dynamické metody

V ideálním případě, jak uvádí [20] by mělo být možné naměřená data z akcelerometru podle základních fyzikálních principů dvakrát zintegrovat a získat pozici

$$x(t) = \int_0^t \left( \int_0^\tau a(s) ds \right) d\tau \quad (3.2)$$

s využitím znalosti zrychlení  $a(s)$ . První integrací se získá rychlost a druhou poté pozice. Bohužel jak ukazuje [31], nejde bez rozsáhlých kompenzací obdržet použitelné výsledky. Signál z akcelerometru je zatížen chybou, která se v čase integrací rychle akumuluje. Poloha je v důsledku stále více zkreslena. Tato chyba je způsobena výskytem šumu v měřeních akcelerometru, nízkou vzorkovací frekvencí, nedostatečnou přesností a také nechtěnými pohyby telefonu, které způsobuje sám uživatel [32].

Základní představa dynamických délek kroku říká, že lidská chůze může být modelována jako obrácené kyvadlo. Délka  $k$ -tého kroku pak odpovídá

$$SL_k = K \cdot \sqrt{2lh - h^2}, \quad (3.3)$$

kde  $K$  je kalibrační konstanta,  $l$  představuje délku nohy a  $h$  představuje vertikální odchylku, kterou lze získat dvojitou integrací vertikálního zrychlení během jednoho kroku. Tato hodnota se musí po každém výpočtu nulovat, aby se nezvětšovala chyba, která takto vzniká. [33]

### 3.2.1 Frekvenční modely

Délka kroku není konstantní přes všechny rychlosti, což zvažuje například Leviho model [22], který dává do vztahu proměnnou délku  $k$ -tého kroku  $SL$  s jeho frekvencí a lze ji určit jako

$$SL_k(f) = S_0 + m \cdot (f - f_0), \quad (3.4)$$

kde  $S_0$  je známá délka kroku a  $f_0$  jeho odpovídající frekvence,  $m$  je sklon kalibrační křivky pro každého uživatele jiný a  $f$  frekvence kroku, u něhož odhadujeme délku.

Tian [29] tvrdí, že zkombinováním ostatních metod získal aproximaci, která využívá frekvenci kroku a výšku člověka v rovnici

$$SL_k(f) = K \cdot h \cdot \sqrt{f}, \quad (3.5)$$

kde  $f$  je frekvence kroku,  $h$  je výška člověka v metrech a  $K$  je konstanta, která se liší v závislosti na pohlaví.

### 3.2.2 Modely využívající vertikálního zrychlení

Rychlost chůze značně ovlivňuje výchyly v amplitudě signálu zrychlení [21]. Jak představil Weinberg [34] ve svém modelu, délku kroku lze odhadovat pomocí maximálního a minimálního zrychlení během kroku. Jeho základní model aproximuje délku  $k$ -tého kroku  $SL$  jako

$$SL_k = \sqrt[4]{a_{max} - a_{min}} \cdot K_1, \quad (3.6)$$

kde  $a_{max}$  a  $a_{min}$  je maximální a minimální vertikální lineární zrychlení v probíhajícímu kroku a  $K_1$  je koeficient, který je potřeba nastavit pro každého uživatele zvlášť. V případě, že konstanta  $K_1$  nedostačuje, lze použít upravený Weinbergův model [23] a přidat k němu konstantu  $K_2$  a odhad kroku vypočítat vztahem

$$SL_k = \sqrt[4]{a_{max} - a_{min}} \cdot K_1 - K_2. \quad (3.7)$$

Kang [23] dále ukazuje, že pro větší délky kroků je vhodné nahradit čtvrtou odmocninu dekadickým logaritmem a spočítat délku  $SL$  pomocí tvaru

$$SL_k = \log(a_{max} - a_{min}) \cdot K_1 - K_2. \quad (3.8)$$

Kim [35] uvádí, že pokud se perioda kroku zkracuje, délka kroku se zvětšuje a s narůstající rychlostí se zvyšuje i vertikální zrychlení. Rovnici pro délku získal experimentálně a dává do vztahu délku a průměrné zrychlení během kroku jako

$$SL_k = K \cdot \sqrt[3]{\frac{\sum_{i=1}^N |a_i|}{N}}, \quad (3.9)$$

kde  $a_i$  je naměřený  $i$ -tý vzorek lineárního zrychlení v daném kroku a  $N$  je daný počet vzorků.  $K$  je opět kalibrační konstanta, tentokrát pro různé umístění senzoru.


Posledním modelem využívajícím vertikální zrychlení je model Scarlettův [36]. Ten modeluje délku  $k$ -tého kroku  $SL$  jako

$$SL_k = K \cdot \frac{a_{avg} - a_{min}}{a_{max} - a_{min}}, \quad (3.10)$$

kde  $a_{avg}$ ,  $a_{min}$  a  $a_{max}$  je průměrné, minimální a maximální vertikální lineární zrychlení v jednom kroku.

Pratama [30] porovnal 4 uvedené metody (3.1), (3.6), (3.9) a (3.10). Z porovnání nejlépe vychází Scarlettův společně s Weinbergovým modelem.

### 3.3 Kalibrace



Obrázek 3.1: Maximální a minimální lineární zrychlení pro odhad délky kroku

Odhad délky kroku byl nakalibrován rovnicí (3.6), která podle [30] vychází jako jedna z nejpřesnějších. Byly provedeny testovací měření po deseti krocích. Nejprve pro kroky s délkou 35 cm a následně pro další měření vždy o 5 cm delšími kroky

až do délky 100 cm. Všechna měření vždy byla provedena dvakrát. Z nich pak byl pro každou délku vypočten rozdíl  $a_{max} - a_{min}$ , který byl vyprůměrován přes všech 20 měření. Následně byly hodnoty upraveny čtvrtou odmocninou a nakonec bylo potřeba nalézt koeficient  $K_1$ . Vybrané body maximálního a minimálního zrychlení deseti kroků jsou vidět na obrázku 3.1.

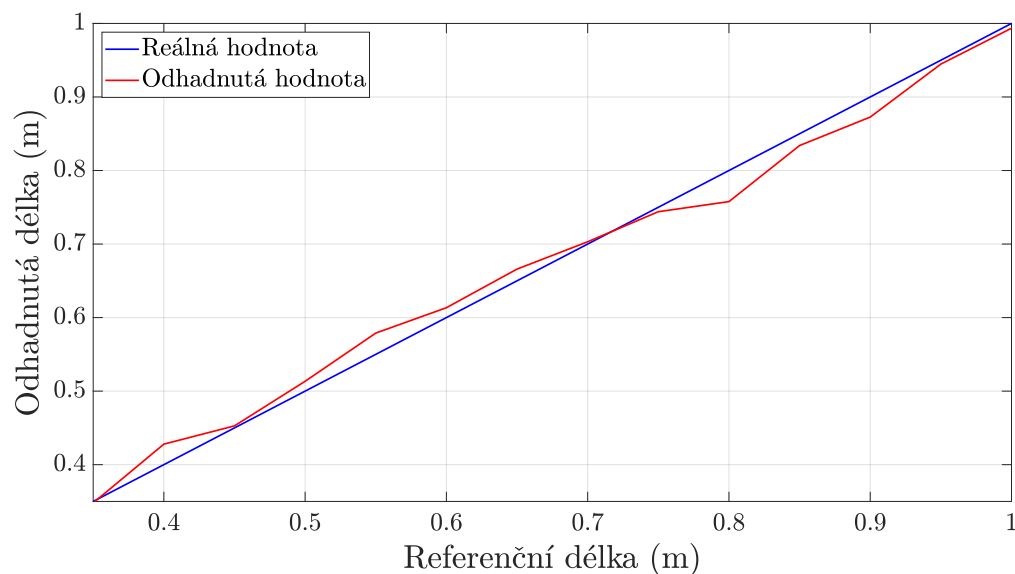
Pro každou délku byl vypočítán ideální koeficient  $K_1$  pro reálnou délku  $SL$  podle

$$K_1 = \sqrt[4]{a_{max} - a_{min}} - SL. \quad (3.11)$$

Tyto hodnoty byly poté vyprůměrovány a ideální koeficient (s celkovou nejmenší chybou) vyšel pro tento případ  $K_1 = 0,828$ . Reálné a vypočítané délky kroků je možno vidět v tabulce 3.1.

Reálná délka (cm)	Vypočítaná délka (cm)
35	35,56
40	43,55
45	46,04
50	52,10
55	58,65
60	62,10
65	67,36
70	71,07
75	75,16
80	76,53
85	84,16
90	88,03
95	95,23
100	100,11

Tabulka 3.1: Srovnání reálných a zkalibrovaných délek kroků



Obrázek 3.2: Přesnost odhadu délky kroku

Průměrná chyba na jeden krok poté vychází rovna 1,66 cm. Nutné podotknout, že se stále jedná pouze o odhad délky kroku a i v rámci jednoho měření deseti stejných kroků se hodnoty lišily. Na kalibraci má velký vliv i použitý filtr. Při jakékoli jeho změně je nutné systém znovu kalibrovat. V kapitole 7 je nakonec ukázáno, že délka je pro potřeby odhadu polohy dostatečně přesná.



# Kapitola 4

## Odhad směru kroku

Poté, co je detekován krok a je známa jeho přibližná délka, je potřeba určit, jakým směrem byl krok veden. Nejběžnějšími senzory pro určení směru (*heading*) jsou ty inerciální – gyroskopy a elektronické magnetické kompasy. Směr pohybu lze také odhadovat speciálními GNSS přijímači, které mají dvě antény [37].


Ani jeden z inerciálních sensorů není bezchybný. Měření z gyroskopu obsahují odchylku (*bias*), kvůli které gyroskop trpí posunem (driftem). Dobře zkalibrovaný elektronický kompas by měl poskytovat relativně dobrý odhad. Je však přirozeně citlivý na zdroje magnetického pole a blízkou přítomnost feromagnetických látek. Takové rušení je pak nejvýraznější ve vnitřních prostorech. [38]

### 4.1 Magnetometr

Magnetometr, neboli elektronický kompas, dokáže na základě měření zemského magnetického pole určit směr pohybu. Pro jeho určení je třeba zajistit měření dvou složek magnetického pole Země, které jsou paralelní k zemskému povrchu a mezi sebou jsou ortogonální [37]. Tomu v běžném natočení zařízení odpovídají osy  $x$  a  $y$  zařízení [23].

Hlavními výhodami magnetometru je schopnost určit absolutní azimut a dlouhodobá stabilita [35]. Jeho chyba se s pohybem a dobou provozu nezvětšuje. Přesto výstup z magnetometru může být zkreslený chybou danou okolním prostředím, která se nedá odstranit ani předvídat [21]. Způsoby rušení jsou podle [39] dvojího typu. Jedním je tzv. *hard iron*, které bývá způsobeno materiály, které vyzařují nechtěné magnetické pole. Jsou způsobeny feromagnetickými materiály poblíž magnetometru [40]. Druhé *soft iron* je způsobeno materiály s vysokou magnetickou permeabilitou, mezi které se může řadit i nošené oblečení a příslušenství osoby, která také drží magnetometr [40]. Celkově je tedy velice citlivý na externí rušení např. od kovových předmětů, které se nejvíce projeví v prostorech budov [35].

Na obrázku 4.1 je možné vidět naměřený průběh magnetického pole ve třech osách pro chůzi 20 kroků ve tvaru čtverce.




Obrázek 4.1: Magnetické pole ve 3 osách

Jelikož magnetický a geografický pól nejsou totožné, tak směřování vypočítané na základě magnetických měření je vztažené k magnetickému pólu a používá se pro něj označení magnetické směřování. K výpočtu skutečného směru, tedy ke geografickému severnímu pólu, musí být při výpočtu odečtena konstanta magnetické deklinace  $h_{\Delta}$ , která je definovaná jako úhel mezi geografickým a magnetickým severem. [28, 37]

Magnetický pól Země se neustále posouvá a jeho zeměpisná poloha se může ročně změnit až o desetiny stupně. Navíc pro každé místo na Zemi, jak je možné se přesvědčit v [41], je hodnota deklinace jiná. Pouze na území České republiky se liší až o  $1,5^{\circ}$ . Pro Prahu v době měření byla vypočtena podle [42] a výsledná deklinace se nachází na obrázku 4.2.

<b>Date</b>	2023-03-14
<b>Latitude</b>	50.1031058° N
<b>Longitude</b>	14.3921378° E
<b>Elevation</b>	0.0 km GPS
<b>Model Used</b>	WMM-2020
<b>Declination</b>	4.82° E changing by 0.16° E per year
<b>Uncertainty</b>	0.38°



Compass shows the magnetic bearing of the magnetic north (MN)

Obrázek 4.2: Magnetická deklinace pro korekci magnetometru [42]



Směr kompasu  $h$  ve stupních pro zařízení paralelní k zemi lze spočítat jako

$$h = \text{atan2}(M_x, M_y) \cdot \frac{180}{\pi}, \quad (4.1)$$

kde  $M_x$  a  $M_y$  jsou magnetická měření v osách  $x$  a  $y$ . Funkce  $\text{atan2}(y, x)$  odpovídá funkci  $\text{atan}\frac{y}{x}$  tam, kde je definována. Rozšiřuje případy, kdy definována není a vrací hodnoty v intervalu  $(-\pi, \pi]$ . Lze jí definovat několika způsoby a mezi jeden patří například tento:


$$\text{atan2}(y, x) = \begin{cases} 2 \tan^{-1} \left( \frac{y}{\sqrt{x^2 + y^2} + x} \right) & \text{pokud } x > 0, \\ 2 \tan^{-1} \left( \frac{\sqrt{x^2 + y^2} + x}{y} \right) & \text{pokud } x \leq 0 \text{ a } y \neq 0, \\ \pi & \text{pokud } x < 0 \text{ a } y = 0, \\ \text{nedefinováno} & \text{pokud } x = 0 \text{ a } y = 0. \end{cases} \quad (4.2)$$

Azimut směřování se pak běžně zapisuje v intervalu  $[0, 360)$  stupňů. Proto je vhodné výstup  $\text{atan2}(x, y)$  namapovat na interval  $[0, 2\pi)$  jednoduchým přičtením  $2\pi$  k záporným hodnotám.

Úhel spočítaný rovnicí (4.1) značí vlastní čtení z kompasu, tj. relativní azimuth od magnetického severu. Pokud je potřeba získat azimuth od geografického severu musí se od vypočteného azimuthu odečíst magnetická deklinace. Směr  $h$  je poté vypočítán následovně

$$h = \left( \text{atan2}(M_x, M_y) - h_{\Delta} \right) \cdot \frac{180}{\pi}, \quad (4.3)$$

kde  $h_{\Delta}$  je rozdíl mezi magnetickým a geografickým severem.



Obrázek 4.3: Směr pohybu z magnetometru


Po použití vztahu (4.1) pro odhad směru je vidět měření z kompasu na obrázku 4.3. Jedná se opět o případ chůze 20 kroků ve tvaru čtverce stejně jako na obrázku 4.1.

## 4.2 Gyroskop

Druhým inerciálním senzorem, kterým se dá určit směr kroku je gyroskop. Ten dokáže ve třech osách měřit úhlovou rychlost. Rotace kolem os  $x$ ,  $y$  a  $z$  se označují úhly  $\Phi$  *roll*,  $\Theta$  *pitch* a  $\Psi$  *yaw*.

Přednosti gyroskopu spočívají v jeho krátkodobé přesnosti a také jeho neovlivnitelnosti externími zdroji rušení. Navzdory stále se zlepšujícím technologiím MEMS, měření sensorů jako je gyroskop jsou stále zatížena nezanedbatelnou chybou (*bias*). Ta se nazývá drift a integrací v čase se rychle akumuluje. Je jí nutné kompenzovat pro každou osu zvlášť. Měření gyroskopu udávají úhlovou rychlost, jejíž integrací lze získat informaci o natočení zařízení. Pokud je v prostoru nutná znalost absolutní orientace, je potřeba nastavit referenci, od které je možné nový směr určit, protože naměřený údaj je sám o sobě relativní. [35, 37]

Na obrázku 4.4 je měření všech 3 os pro 20 kroků ve tvaru čtverce stejně jako pro měření magnetického pole na obrázcích 4.1 a 4.3.



Obrázek 4.4: Úhlová rychlost ve 3 osách

Podle [23] by se pak měl drift gyroskopu korigovat jako

$$\hat{\omega}_i = \omega_i - b_i, \quad i \in x, y, z, \quad (4.4)$$

kde  $\hat{\omega}_i$  je korigovaná úhlová rychlost,  $\omega_i$  je neupravená úhlová rychlost obdržaná z gyroskopu a  $b_i$  je korekce driftu úhlové rychlosti na  $i$ -té ose.

Pro získání úhlu je třeba úhlovou rychlost během kroku zintegrovat, respektive v diskrétním případě použít sumu. Pokud je zařízení drženo ve vodorovné poloze vůči zemi nebo je orientace známá a měření podle ní přepočítané, tak je poté možné pracovat pouze s úhlovou rychlostí v ose  $z$ . Integrace úhlové rychlosti  $\omega_z$  se pak vypočítá vztahem

$$\Theta_z = \int_0^T \omega_z(t) dt, \quad (4.5)$$

kde 0 odpovídá času začátku kroku,  $T$  ukončení kroku a  $\Theta_z$  je změna úhlu.

### 4.3 Odhad polohy

Ve chvíli, kdy je detekován krok, je známá jeho délka a směr, kterým byl veden, se může určit výsledná poloha uživatele. Nová poloha  $x_k$  a  $y_k$  se vypočítá jako

$$\begin{bmatrix} x_k \\ y_k \end{bmatrix} = \begin{bmatrix} x_{k-1} \\ y_{k-1} \end{bmatrix} + SL_k \cdot \begin{bmatrix} \cos(\Theta_k) \\ \sin(\Theta_k) \end{bmatrix}, \quad (4.6)$$

kde  $x_{k-1}$  a  $y_{k-1}$  jsou předešlé polohy,  $\Theta_k$  je úhel směřování kroku  $k$  a  $SL_k$  je jeho příslušná délka.

Úhel  $\Theta_k$  je možné získat z gyroskopu, magnetometru a nebo z jejich kombinace. Tu je možné dosáhnout například fúzí pomocí Kalmanova filtru, který bude uveden v kapitole 5.



# Kapitola 5

## Kalmanův filtr

Kalmanův filtr (KF) [43] je velice univerzální a rozšířený nástroj pro zpracování dat. V této kapitole budou nejprve popsány základní principy filtru s příslušným matematickým popisem. Následně bude ukázáno, jak lze predikovat polohu chodce založenou na měření z jednoho nebo více senzorů a tedy možnosti fúze dat. Nakonec bude popsána jeho rozšířená verze, která umožňuje řešit i nelineární problémy.

Betz [44] udává: „Kalmanův filtr, který umožňuje několik vstupů a výstupů, je rekurzivní lineární digitální filtr.“ Jelikož je rekurzivní, tak záleží pouze na současném a posledním stavu a nemusí si uchovávat celou historii hodnot. Byl představen na začátku éry digitálních počítačů. KF poskytuje optimální estimaci z pohledu minimalizace střední kvadratické chyby pro lineární systémy s Gaussovským šumem [45]. Jeho cílem je odhadovat následující stav v závislosti na aktuálním měření a modelu chování systému v čase. Jeho výhodou je, že stav dokáže odhadovat i bez znalosti měření, pokud není zrovna dostupné. Předpovídá hodnotu odhadovaného stavu a tato predikce je opravována dostupným měřením.

Základem KF jsou dva matematické modely: **dynamický** a **měřicí** [45]. Statické ve vesmíru není prakticky nic, takže téměř vše je dynamické a dá se i dynamicky modelovat [46]. KF tento dynamický stav popisuje na základě náhodného chování s použitím statistických informací [46].

Množina časově závislých charakteristik, které je potřeba odhadnout, se nazývá stavový vektor a značí se  $\mathbf{x}$  [44]. Popis toho, jak se hodnoty stavů mění v čase, se nazývá proces [44]. První základní rovnice, kterou je potřeba popsat, je stavová **dynamická rovnice** (diferenční rovnice procesu) pro odhad stavu v čase  $n$  při znalosti předchozího stavu  $n - 1$  a její tvar je

$$\mathbf{x}_n = \mathbf{F}\mathbf{x}_{n-1} + \mathbf{G}\mathbf{u}_{n-1} + \mathbf{w}_{n-1}, \quad (5.1)$$

kde  $\mathbf{F}$  (často se v literatuře vyskytuje jako matice  $\mathbf{A}$ ) je matice přechodu (*state transition*) z předchozího kroku  $n - 1$  do stavu  $n$ ,  $\mathbf{G}$  (často také značena  $\mathbf{B}$ ) je řídicí matice pro volitelný vstup  $\mathbf{u}$  a  $\mathbf{w}$  reprezentuje procesní šum  $\mathbf{w} \sim \mathcal{N}(0, \mathbf{Q})$  s nulovou střední hodnotou a kovariancí  $\mathbf{Q}$ .

Měřicí model ukazuje vztah mezi stavy a dostupnými měřeními s využitím matice  $\mathbf{H}$  [45]. Pozorovatelné měření  $\mathbf{z}_n$ , které může být zatíženo aditivním Gaussovským bílým šumem  $\mathbf{v}_n$  v **měřicí rovnici**, lze vyjádřit jako

$$\mathbf{z}_n = \mathbf{H}\mathbf{x}_n + \mathbf{v}_n, \quad (5.2)$$

kde  $\mathbf{H}$  je matice transformace mezi stavem a měřením,  $\mathbf{v}_n$  reprezentuje měřicí šum.

Jedná se o vícerozměrný normální šum  $\mathbf{v} \sim \mathcal{N}(0, \mathbf{R})$  s nulovou střední hodnotou a kovariancí  $\mathbf{R}$ .

Výhodou tohoto filtru je, že dokáže kombinovat data z různých přímých, nepřímých a zašuměných měření a tím odhadnout proměnné, které nelze přímo změřit. Stav  $\mathbf{x}_n$  často nebývájí přímo pozorovatelné. Oproti tomu přímo pozorovatelná a změřitelná jsou měření  $\mathbf{z}_n$ , které jsou díky linearitě KF lineární kombinací stavů definovaných měřicím modelem filtru. Typicky je zde také nejistota v měření způsobená zašuměnými pozorováními. Tato nejistota je reprezentovaná aditivním Gaussovským bílým šumem se specifickou kovarianční maticí  $\mathbf{R}$ . [44, 47]

Celý algoritmus po inicializaci úvodními hodnotami probíhá ve dvou stále se opakujících krocích. Ty se nazývají predikce a korekce (aktualizace). Inicializace obsahuje nastavení dvou úvodních hodnot do stavu  $\mathbf{x}_0$  a úvodní hodnotu kovarianční matice  $\mathbf{P}_0$ . Poté, pro každý časový index dělá KF iterativně zmíněné dva kroky.

### Predikce

Po zadání úvodních hodnot  $\mathbf{x}_0$  a  $\mathbf{P}_0$  přichází na řadu nejprve přepočítání stavového vektoru  $\mathbf{x}_n$  a získání jeho odhadu v příštím kroku jako

$$\hat{\mathbf{x}}_n^- = \mathbf{F}\hat{\mathbf{x}}_{n-1} + \mathbf{G}\mathbf{u}_n, \quad (5.3)$$

kde symbol „ $\hat{\cdot}$ “ značí odhadnutou hodnotu a symbol „ $\cdot^-$ “ značí využití *a priori* informace, tedy že veličina byla odhadnuta z předchozí znalosti tj. minulého kroku. Dále se vypočítá odhad kovariance stavového vektoru

$$\mathbf{P}_n^- = \mathbf{F}\mathbf{P}_{n-1}\mathbf{F}^T + \mathbf{Q}, \quad (5.4)$$

kde  $\mathbf{P}_n^-$  je predikovaná kovarianční matice dalšího stavu z kovarianční matice předchozího stavu  $\mathbf{P}_{n-1}$ . Matice  $\mathbf{F}$  je matice přenosu totožná jako v rovnici (5.3) a  $\mathbf{Q}$  je procesní kovarianční matice šumu obsahující nejistotu nebo náhodu v modelu reprezentovanou aditivním Gaussovským bílým šumem [44]. Operátor  $\cdot^T$  značí transponovanou matici. Nejistota v procesním modelu nebo použití redukovaného počtu stavů může být implementována většími hodnotami v procesní kovarianční matici. Následkem je větší chyba v odhadech stavů [44]. Tím je popsána fáze predikování a nyní bude uvedena fáze korigování odhadnutých hodnot.

### Korekce

V tomto kroku se používají naměřená data  $\mathbf{z}_n$  v čase  $n$  ke korekci odhadu jako *a posteriori* informace. Využívá se tedy informace z času  $n$  pro výpočet hodnoty v čase  $n$ . Měření vstupuje do rovnice

$$\mathbf{y}_n = \mathbf{z}_n - \mathbf{H}\hat{\mathbf{x}}_n^-, \quad (5.5)$$

kde  $\mathbf{y}$  se nazývá inovací měření a ukazuje o kolik se měření  $\mathbf{z}_n$  liší od predikovaného měření, které je dané modelem a stavem  $\hat{\mathbf{x}}_n^-$ .

Pro získání opraveného odhadu je nejprve potřeba určit Kalmanův zisk  $\mathbf{K}$ , který kombinuje nejistoty stavu a měření a určuje jakou váhu přiřadit měření [45]. Rovnice pro jeho určení se zapisuje ve tvaru

$$\mathbf{K}_n = \mathbf{P}_n^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_n^- \mathbf{H}^T + \mathbf{R}_n)^{-1}, \quad (5.6)$$

kde  $\mathbf{R}_n$  je matice vyjadřující nepřesnosti měřených dat. Rovnice vyjadřuje, že čím je větší nejistota v měření, tím je Kalmanův zisk menší. Menší nejistota v měření dává větší váhu na sledování měření [45].

Se znalostí Kalmanova zesílení je možné korigovat stavový vektor na *a posteriori* odhad jako

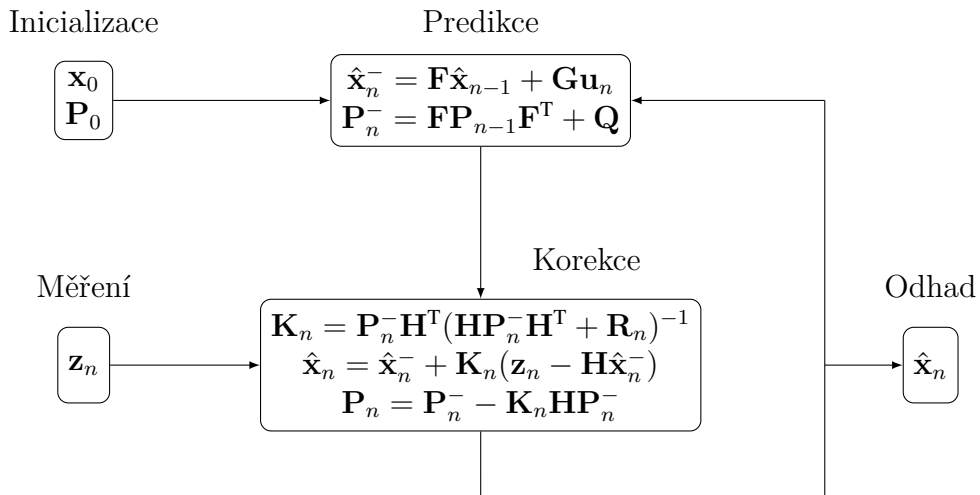
$$\hat{\mathbf{x}}_n = \hat{\mathbf{x}}_n^- + \mathbf{K}_n \mathbf{y}_n, \quad (5.7)$$

ke kterému je využita inovace  $\mathbf{y}_n$ . Nakonec zbývá přepočítat odhad kovarianční matice  $\mathbf{P}_n$  jako

$$\mathbf{P}_n = \mathbf{P}_n^- - \mathbf{K}_n \mathbf{H} \mathbf{P}_n^-. \quad (5.8)$$

Jednotlivé fáze predikce a korekce se neustále opakují. Pro fázi korekce je nutné, aby byl předem k dispozici odhadnutý stav a proběhla predikce. Naopak je možné, aby predikční fáze probíhala několikrát za sebou bez přítomnosti korekce pomocí měření. To může například nastat, pokud se vzorkovací frekvence měření liší od frekvence použití predikovaného stavu. Další možností je, pokud by přestalo být k dispozici měření, tak filtr je dále schopen predikovat hodnoty na základě znalosti stavového popisu a predikční fáze může proběhnout vícekrát za sebou. Nejistota stavu  $\mathbf{P}$  bude narůstat. Ve chvíli, kdy měření bude opět k dispozici, proběhne korekce a vše probíhá dále. [45]

Pro ilustraci je princip fungování Kalmanova filtru znázorněn na obrázku 5.1.



Obrázek 5.1: Princip Kalmanova filtru

## 5.1 Využití KF

Jelikož Kalmanův filtr je optimální estimátor pro celou řadu lineárních problémů je jeho využití opravdu veliké [48]. Tato práce se zaměřuje na určení polohy z měření, kde se Kalmanův filtr může využít. KF tedy bude využit k filtrování polohy vypočtené podle rovnice (4.6) ze směru a délky kroku. Později bude také využit k fúzi měření z gyroskopu, akcelerometru a magnetometru pro odhad orientace. Nejprve budou popsány rovnice pro odhad polohy v případech, kdy je k dispozici pouze jedno měření a následně pokud je dostupných měření více.

### 5.1.1 Odhad polohy z jednoho senzoru

Základem pro aplikaci Kamanova filtru je určení dynamické rovnice. Při odhadu polohy chodce lze vyjít z kinematické rovnice pro určení polohy a rychlosti. Poté lze stavový vektor  $\mathbf{x}_n$  se složkami polohy  $x_n$  a rychlosti  $\dot{x}_n$  zapsat podle [49] jako

$$\hat{\mathbf{x}}_n = \begin{bmatrix} \hat{x}_n \\ \hat{\dot{x}}_n \end{bmatrix} = \begin{bmatrix} \hat{x}_{n-1} + \hat{\dot{x}}_{n-1}\Delta t + \frac{1}{2}\hat{\ddot{x}}_{n-1}\Delta t^2 \\ \hat{\dot{x}}_{n-1} + \hat{\ddot{x}}_{n-1}\Delta t \end{bmatrix}, \quad (5.9)$$

kde  $\Delta t$  je časový interval mezi vzorky  $n-1$  a  $n$ .

Je vhodné předpokládat, že většinu času se chodec pohybuje pouze ve dvojrozměrném prostoru. Poté lze jeho pohyb popsat dvěma kinematickými rovnicemi pro souřadnice  $x$  a  $y$  jako

$$\hat{\mathbf{x}}_n = \begin{bmatrix} \hat{x}_n \\ \hat{y}_n \\ \hat{\dot{x}}_n \\ \hat{\dot{y}}_n \end{bmatrix} = \begin{bmatrix} \hat{x}_{n-1} + \hat{\dot{x}}_{n-1}\Delta t + \frac{1}{2}\hat{\ddot{x}}_{n-1}\Delta t^2 \\ \hat{y}_{n-1} + \hat{\dot{y}}_{n-1}\Delta t + \frac{1}{2}\hat{\ddot{y}}_{n-1}\Delta t^2 \\ \hat{\dot{x}}_{n-1} + \hat{\ddot{x}}_{n-1}\Delta t \\ \hat{\dot{y}}_{n-1} + \hat{\ddot{y}}_{n-1}\Delta t \end{bmatrix}. \quad (5.10)$$

Znalost zrychlení zde není nutná a není třeba ji predikovat, proto pro redukci modelu bude navýšena kovarianční matice. Vztah (5.10) je možné rozepsat s využitím matice  $\mathbf{F}$  do tvaru

$$\hat{\mathbf{x}}_n = \mathbf{F}\hat{\mathbf{x}}_{n-1} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \hat{\mathbf{x}}_{n-1}. \quad (5.11)$$

K dispozici je měření polohy  $x$  a  $y$  podle rovnice (4.6), tomu odpovídá model  $\mathbf{H}$ , který se pro tento případ zapíše jako

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}. \quad (5.12)$$

Kovarianční matice měření  $\mathbf{R}$  je podle [50] rovna

$$\mathbf{R} = \begin{bmatrix} \sigma_x^2 & \sigma_{yx}^2 \\ \sigma_{xy}^2 & \sigma_y^2 \end{bmatrix}, \quad (5.13)$$

kde  $\sigma_x^2$  je rozptyl měření polohy  $x$  a  $\sigma_y^2$  rozptyl měření polohy  $y$ . Rozptyly  $\sigma_{xy}^2$  a  $\sigma_{yx}^2$  jsou společné produkty, pokud jsou na sobě jednotlivá měření závislá. Při předpokladu, že  $x$  a  $y$  jsou nekorelované, je možné prohlásit chybu v měření souřadnic  $x$  jako nezávislou na měření  $y$ . Pro přesnější senzor se vkládají do matice menší hodnoty než pro nepřesný senzor. Poté se může psát

$$\mathbf{R} = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}. \quad (5.14)$$

Dále je potřeba určit počáteční stav kovarianční matice stavu  $\mathbf{P}$ , která se dle [50] určí jako

$$\mathbf{P}_0 = \begin{bmatrix} p_x^2 & 0 & 0 & 0 \\ 0 & p_y^2 & 0 & 0 \\ 0 & 0 & p_{\dot{x}}^2 & 0 \\ 0 & 0 & 0 & p_{\dot{y}}^2 \end{bmatrix}, \quad (5.15)$$



kde prvky na hlavní diagonále matice jsou variance odhadu. Prvek  $p_x$  je variance odhadu souřadnice  $x$ ,  $p_{\dot{x}}$  je variance odhadu rychlosti  $\dot{x}$ ,  $p_y$  je variance odhadu souřadnice  $y$  a  $p_{\dot{y}}$  je variance odhadu rychlosti  $\dot{y}$ . V případě předpokladu, že chyby v  $x$  a  $y$  jsou vzájemně nekorelované, lze jejich kombinace prohlásit za nulové a matice vychází diagonální. Zde opět platí, že čím vyšší hodnota prvku matice, tím se přisuzuje vyšší nejistota. V každé iteraci korekce se matice  $\mathbf{P}$  mění podle toho, jak moc se daný odhad od měření lišil. Výpočet matice  $\mathbf{P}$  také ovlivňují nejistoty. Je tedy potřeba ještě určit kovarianční matici procesního šumu  $\mathbf{Q}$ , která je definovaná vztahem

$$\mathbf{Q} = \begin{bmatrix} \sigma_x^2 & 0 & 0 & 0 \\ 0 & \sigma_y^2 & 0 & 0 \\ 0 & 0 & \sigma_{\dot{x}}^2 & 0 \\ 0 & 0 & 0 & \sigma_{\dot{y}}^2 \end{bmatrix}, \quad (5.16)$$

kde je ideální rozptyly vzdálenosti  $\sigma_x^2$  a  $\sigma_y^2$  určit o jeden řád vyšší než rozptyly rychlostí  $\sigma_{\dot{x}}^2$  a  $\sigma_{\dot{y}}^2$ . Předpokladem je, že procesní šum v ose  $x$  a  $y$  není korelovaný a stejně jako u matice  $\mathbf{P}$  se prvky mohou prohlásit za nulové. Ve výsledku se opět nejčastěji využívá diagonální matice.

### 5.1.2 Fúze měření z více senzorů

Při určení odhadu směru kroku může být vhodné zkombinovat například měření z gyroskopu a magnetometru. Pokud jsou známy polohy vypočítané na bázi obou měření, lze je fúzí zkombinovat. K tomu lze využít většinu rovnic uvedených v předchozí sekci a pouze upravit model měření a kovarianční matici  $\mathbf{R}$ . Pro případ fúzování dat ze dvou senzorů bude matice  $\mathbf{H}$  vypadat jako

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}. \quad (5.17)$$

Rozšířit se musí také kovarianční matice měření  $\mathbf{R}$ . Pro fúzi dvou senzorů lze psát

$$\mathbf{R} = \begin{bmatrix} \mathbf{R}_G & 0 \\ 0 & \mathbf{R}_M \end{bmatrix}, \quad (5.18)$$

kde  $\mathbf{R}_G$  a  $\mathbf{R}_M$  jsou matice  $\mathbf{R}$  z rovnice 5.13 a pro každý senzor se musí nastavit zvlášť. Pro gyroskop je využit index  $\cdot_G$  a pro magnetometr index  $\cdot_M$ . Dohromady se tedy může psát

$$\mathbf{R} = \begin{bmatrix} \sigma_{x_G}^2 & 0 & 0 & 0 \\ 0 & \sigma_{y_G}^2 & 0 & 0 \\ 0 & 0 & \sigma_{x_M}^2 & 0 \\ 0 & 0 & 0 & \sigma_{y_M}^2 \end{bmatrix}, \quad (5.19)$$

kde indexy  $x_G$  a  $y_G$  odpovídají měření polohy s využitím gyroskopu a  $x_M$  a  $y_M$  odpovídají měření polohy s využitím magnetometru.

## 5.2 Rozšířený Kalmanův filtr

Mnohé dynamické systémy nejsou přirozeně lineární, takže tradiční KF nemůže být využit. V takových systémech se může nelinearita vyskytovat v dynamickém modelu, měřicím modelu nebo v obou modelech zároveň [51]. Jakmile funkce přestanou být lineární, je potřeba použít rozšířenou verzi KF zvanou EKF (*Extended Kalman Filter*). Pro tyto nelineární případy je možné systém linearizovat kolem určitého bodu, zde kolem současného odhadu  $\hat{\mathbf{x}}_n$  nebo kolem predikovaného stavu  $\hat{\mathbf{x}}_n^-$  v případě korekce [45].

V případě, kdy je systém vysoce nelineární, přestává dostačovat i EKF. Pro takové případy existuje ještě varianta UKF (*Unscented Kalman Filter*). Ta navíc využívá *unscented* transformaci na převod kovariance, zatímco u EKF se stále předpokládá Gaussovský šum a používá se linearizace. Stejně jako u KF je i u EKF potřeba popsat dva kroky predikce a korekce.

### Predikce

Rovnice dynamických modelů nejsou lineární a tak je nelze zapisovat maticově, protože jsou nelineární funkcí. Proto jsou rovnice pro predikci upraveny a zapisovány ve tvaru

$$\hat{\mathbf{x}}_n^- = \mathbf{f}(\hat{\mathbf{x}}_{n-1}, \mathbf{u}_n), \quad (5.20)$$

$$\hat{\mathbf{P}}_n = \mathbf{F}(\hat{\mathbf{x}}_{n-1}, \mathbf{u}_n) \mathbf{P}_{n-1} \mathbf{F}^T(\hat{\mathbf{x}}_{n-1}, \mathbf{u}_n) + \mathbf{Q}_n, \quad (5.21)$$

kde  $\mathbf{F}$  je Jakobiánem  $\mathbf{f}$  s definicí

$$\mathbf{F}(\hat{\mathbf{x}}_{n-1}, \mathbf{u}_n) = \frac{\partial \mathbf{f}(\hat{\mathbf{x}}_{n-1}, \mathbf{u}_n)}{\partial \mathbf{x}}. \quad (5.22)$$

### Korekce

Zbylé rovnice pro aktualizaci vypadají jako

$$\hat{\mathbf{x}}_n^- = \hat{\mathbf{x}}_n^- + \mathbf{K}_n(\mathbf{z}_n - \mathbf{h}(\hat{\mathbf{x}}_n^-)), \quad (5.23)$$

$$\mathbf{K}_n = \hat{\mathbf{P}}_n \mathbf{H}^T(\hat{\mathbf{x}}_n^-) (\mathbf{H}(\hat{\mathbf{x}}_n^-) \hat{\mathbf{P}}_n \mathbf{H}^T(\hat{\mathbf{x}}_n^-) + \mathbf{R}_n)^{-1}, \quad (5.24)$$

$$\mathbf{P}_n = (\mathbf{I} - \mathbf{K}_n \mathbf{H}(\hat{\mathbf{x}}_n^-)) \hat{\mathbf{P}}_n, \quad (5.25)$$

kde  $\mathbf{I}$  je jednotková matice a  $\mathbf{H}$  je Jakobiánem funkce  $\mathbf{h}$  definován vztahem

$$\mathbf{H}(\hat{\mathbf{x}}_n^-) = \frac{\partial \mathbf{h}(\hat{\mathbf{x}}_n^-)}{\partial \mathbf{x}}. \quad (5.26)$$

# Kapitola 6

## Obecná orientace

Jak již bylo uvedeno v předchozích kapitolách, měřicí zařízení nemusí být vždy v pevně dané a známé poloze. Data je nutné transformovat do takové podoby s pomocí odhadované orientace, aby bylo možné provést definované výpočty. Tato kapitola se primárně zabývá odhadem prostorové orientace zařízení, sloužícího pro odhad polohy. Nejprve jsou definovány souřadné systémy, ve kterých se chodec se zařízením pohybuje. Následně jsou popsány metody, jakými se orientace nejběžněji popisuje. Nakonec je uveden algoritmus, který je pro odhad orientace využit a jak je s touto informací možné obdržet lineární zrychlení.

### 6.1 Souřadné systémy


V závislosti na použitých senzorech je nutné respektovat, že každý obecně měří v jiném souřadném systému. Pro převod mezi nimi je potřeba definovat transformaci, aby bylo možné mezi systémy přecházet a porovnávat jejich data. Běžný ortogonální souřadný systém má 6 stupňů volnosti a to polohu počátku a orientaci os. [52]

Důležité je rozdělení systému na tzv. *strapdown* a *gimbaled*. Ty se liší dle konstrukce senzorů. Pokud je senzor připevněn k platformě a je izolován od externích rotací při změně orientace, má svobodu ve všech třech osách a jedná se o systém typu *gimbaled*. *Strapdown* systémy jsou pevně přichyceny se zařízením a tedy se s ním i otáčejí. Dnes jsou mnohem hojněji využívány, protože je možné je rozměrově vyrobit mnohem menší. Nevýhodou je pouze větší výpočetní náročnost oproti systému *gimbaled*, ale při dnešních výpočetních výkonech zařízení to nečiní sebemenší problém. [53, 54]

V této práci jsou využívány pouze inerciální senzory typu *strapdown* a tak je problém zkrácen pouze na řešení převodu mezi dvěma systémy. Prvním je rámec *body*, který je pevně svázán se zařízením. Druhým je rámec lokální, od kterého se odvíjí poloha a orientace *body* rámce a je uvažován jako referenční.

#### 6.1.1 East – North – Up

Pro účely této práce byly využity senzory v chytrém mobilním telefonu s operačním systémem Android. Senzory v něm využívají systému s rozložením os ENU, které je ukázáno na obrázku 6.1 [55]. Souřadný systém použitých senzorů je tříosý kartézský  $x, y, z$ , kde počátek systému je umístěn uprostřed zařízení [56]. Pokud

Obrázek 6.1: *Body* rámec telefonu

je zařízení v základní poloze, tedy displejem vzhůru, je možné definovat použitý souřadný systém následujícím způsobem. Osa  $x$  míří k východu (*East*), osa  $y$  míří k severu (*North*) a osa  $z$  je doplněna do pravotočivé soustavy a míří vzhůru z displeje (*Up*) [17]. Toto dává dohromady soustavu ENU, která se jmenuje podle směřování os a jejich pořadí, tedy východ – sever – vzhůru (*East – North – Up*). Pokud se vymění osa  $x$  s osou  $y$ , tak doplněním osy  $z$  do pravotočivých souřadnic vznikne souřadný systém NED (*North – East – Down*), který je také často pro inerciální senzory využíván [57]. U něho osa  $x$  směřuje na sever, osa  $y$  na východ a osa  $z$  směrem z displeje dolů.


### 6.1.2 Lokální a body rámec

Nyní je potřeba definovat jediné dva souřadné systémy, které jsou podstatné pro určení orientace zařízení. Lokální rámec má počátek v místě zahájení měření a jeho osy jsou rozloženy podle systému ENU, kde osa  $x$  směřuje ke geografickému východu, osa  $y$  ke geografickému severu a osa  $z$  kolmo vzhůru od země. *Body* rámec je počátkem spojen se středem měřicího zařízení a jeho osy jsou také ve formátu ENU stejně jako na obrázku 6.1. Klíčové je správně odhadnout orientaci a polohu *body* rámce vůči rámci lokálnímu.

Oba systémy jsou ukázány na obrázku 6.2, který zobrazuje referenční osy lokálního rámce  ${}^Lx$ ,  ${}^Ly$ ,  ${}^Lz$  a k nim měnící se polohu a orientaci *body* rámce  ${}^Bx$ ,  ${}^By$ ,  ${}^Bz$ .

Při předpokladu, že inerciální senzory jsou přichyceny k lidskému tělu, reprezentovanému *body* rámcem, který mění orientaci vůči referenčnímu rámci, pak je možné tuto transformaci popsat pomocí matice  ${}^L_B\mathbf{R}$  a vektoru posuvu  ${}^L_B\mathbf{r}$  [58]. Jakýkoliv vektor  $\mathbf{x}$  může být v trojrozměrném prostoru reprezentován relativně vůči referenčnímu systému jako

$${}^L\mathbf{x} = {}^L_B\mathbf{R} {}^B\mathbf{x} + {}^L_B\mathbf{r}, \quad (6.1)$$

Obrázek 6.2: Lokální a *body* rámeček

kde indexy u matice  ${}^L_B\mathbf{R}$  a vektoru posuvu  ${}^L_B\mathbf{r}$  popisují transformaci z *body* rámeček do lokálního a index u  $\mathbf{x}$  značí, v jakém souřadném systému je vektor  $\mathbf{x}$  vyjádřen. [59]

## 6.2 Vyjádření orientace

Jak již bylo uvedeno, např. detekce kroku často probíhá z dat zrychlení v ose kolmé k zemi. Jelikož zařízení může být libovolně natočeno, osa  $z$  zařízení nemusí být vždy stejně natočena jako osa lokálního rámeček. Aby byla data použitelná, je nejprve nutné znát transformaci mezi rámečkami.

Způsobů určení orientace je několik. Některé mohou být založeny na akustických, mechanických nebo optických měřeních, které však nejsou tak populární jako inerciální [59]. Tyto přístupy pro sledování orientace potřebují pro svou funkci externí zdroje – pro optické kameru nebo ultrasonické zařízení pro akustické senzory [6]. Oproti tomu inerciální senzory jsou kompletně soběstačné, protože měří fyzikální veličiny daného rámeček [6].

Nejjednodušším řešením získání orientace z inerciálních měření by bylo využití úhlové rychlosti z gyroskopu a tu v čase integrovat. Bohužel, jak již bylo řečeno v předchozí kapitole 4, by také toto řešení trpělo v čase driftem a velice rychle by se odchylovalo od reality. Aby bylo možné předejít driftu, je potřeba přidat i další inerciální senzory a tuto chybu opravovat a případně i odhadovat. Na druhou stranu, gyroskopy mohou pomoci v dosažení přesnosti odhadu pro systémy s vysokou dynamikou. [59, 60]

Vhodné je využít tříosý akcelerometr, který zaznamenává akceleraci, která je na něj působením gravitačního pole aplikována. Díky tomu dokáže udávat informace o orientaci v horizontální rovině. Tříosý magnetometr poskytuje informaci o natočení kolem vertikální osy a udává informace o magnetickém poli Země. [60]

Pro vyjádření orientace se v zásadě používají dvě formy popisu. První popis pomocí Eulerových úhlů a druhý s využitím kvaternionů. Obě reprezentace jsou uvedeny v následujících sekcích.

### 6.2.1 Eulerovy úhly

Nejběžnější a nejjednodušší forma pro popsání prostorové orientace/rotace je pomocí Eulerových úhlů, které se také nazývají Tait-Bryantovy úhly. Vzájemnou orientaci dvou souřadných systémů lze popsat pomocí tří úhlů. Tyto tři úhly představující rotaci kolem jednotlivých os se nazývají a označují  $\Phi$  *roll* pro osu  $x$ ,  $\Theta$  *pitch* pro osu  $y$  a  $\Psi$  *yaw* pro osu  $z$ . Výsledná rotace pak je popsána pomocí  $3 \times 3$  matice. [61]

Se znalostí měření akcelerometru lze určit rotaci kolem os  $x$  a  $y$  neboli *roll* a *pitch*. Jelikož tato transformace mezi systémy je závislá na pořadí, tak se podle toho liší výsledné transformační rovnice [57]. Pro příklad rotace z referenčního systému do nového, kde se nejprve rotuje kolem osy  $x$ , poté  $y$  a nakonec  $z$  jsou podle [62] rovnice ve tvaru

$$\Phi = \text{atan2}(a_y, a_z), \quad (6.2)$$

$$\Theta = \text{atan2}(-a_x, \sqrt{a_y^2 + a_z^2}), \quad (6.3)$$

kde  $a_x$ ,  $a_y$  a  $a_z$  jsou gravitační zrychlení naměřená v osách  $x$ ,  $y$  a  $z$ . Úhel  $\Psi$  pak může být získán z úhlové rychlosti a nebo se dá využít měření magnetometru [63]. Se znalostí vypočítaných úhlů *roll* a *pitch* z akcelerometru, pokud se uvažuje pořadí rotace  $xyz$ , lze podle [24] transformovat měření magnetometru jako

$$\hat{M}_y = M_x \cos(\Theta) + M_y \sin(\Theta) \sin(\Phi) + M_z \sin(\Theta) \cos(\Phi), \quad (6.4)$$

$$\hat{M}_x = M_y \cos(\Phi) - M_z \sin(\Phi), \quad (6.5)$$

kde  $\hat{M}_y$  a  $\hat{M}_x$  jsou transformované údaje magnetického pole z naměřených hodnot  $M_x$ ,  $M_y$  a  $M_z$ . S touto znalostí pak lze úhel *yaw* určit jako

$$\Psi = \text{atan2}(\hat{M}_y, \hat{M}_x). \quad (6.6)$$

Výpočet orientace Eulerovými úhly není ideální. Při rotaci zařízení se může snadno stát, že nastane tzv. *gimbal lock*, který značí ztrátu jednoho nebo více stupňů volnosti. Z tří os, podél kterých se systém otáčí, se minimálně dvě osy spojí. Další nevýhodou je, že rovnice jsou odvozeny pro určité pořadí rotací. Těmto nevýhodám se může předejít výpočtem orientace pomocí kvaternionů. [61]

### 6.2.2 Kvaterniony

Kvaterniony (*quaternions*) zobecňují komplexní čísla a rozšiřují je. Lze s nimi reprezentovat orientaci tělesa v trojrozměrném prostoru a jsou více kompaktní než maticový zápis. Jsou udávány jako uspořádaná čtveřice

$$\mathbf{q} = q_0 + \mathbf{i}q_1 + \mathbf{j}q_2 + \mathbf{k}q_3, \quad (6.7)$$

kde  $q_0$ ,  $q_1$ ,  $q_2$  a  $q_3$  jsou reálná čísla a  $\mathbf{i}$ ,  $\mathbf{j}$ ,  $\mathbf{k}$  jsou vzájemně ortogonální imaginární složky, pro něž platí  $\mathbf{i}^2 = \mathbf{j}^2 = \mathbf{k}^2 = \mathbf{ijk} = -1$ ,  $\mathbf{ij} = -\mathbf{ji} = \mathbf{k}$ ,  $\mathbf{jk} = -\mathbf{kj} = \mathbf{i}$  a  $\mathbf{ki} = -\mathbf{ik} = \mathbf{j}$  [64]. Běžně se zapisují v praktičtější vektorové formě

$$\mathbf{q} = [q_0 \quad q_1 \quad q_2 \quad q_3]^T. \quad (6.8)$$

Složku  $q_0$  je možné vnímat jako reálnou a zbylé složky jako imaginární.

Speciální operací, kterou je potřeba uvést, je součin kvaternionů. Definice pro kvaterniony  $\mathbf{a} = a_0 + \mathbf{i}a_1 + \mathbf{j}a_2 + \mathbf{k}a_3$  a  $\mathbf{b} = b_0 + \mathbf{i}b_1 + \mathbf{j}b_2 + \mathbf{k}b_3$  vypadá jako

$$\begin{aligned} \mathbf{ab} &= (a_0b_0 - a_1b_1 - a_2b_2 - a_3b_3) \\ &+ \mathbf{i}(a_0b_1 + a_1b_0 + a_2b_3 - a_3b_2) \\ &+ \mathbf{j}(a_0b_2 - a_1b_3 + a_2b_0 + a_3b_1) \\ &+ \mathbf{k}(a_0b_3 + a_1b_2 - a_2b_1 + a_3b_0). \end{aligned} \quad (6.9)$$

Kvaterniony se dají dobře využít pro rotaci v 3D prostoru. Toho lze docílit pomocí následující rovnice, ve které je vektor  $\mathbf{a}$  rotován na  $\mathbf{a}'$  jako

$$\mathbf{a}' = \mathbf{qaq}^{-1}, \quad (6.10)$$

kde  $\mathbf{q} = (q_0, q_1, q_2, q_3)$ ,  $\mathbf{a} = (0, x, y, z)$  a  $\mathbf{q}^{-1}$  je inverze  $\mathbf{q}$ . Souřadnice, které je potřeba transformovat mají reálnou složku nulovou a imaginární nenulové složky.

Pro komfortní výpočet je potřeba najít matici rotace  $\mathbf{R}_{(A)}^{(B)\mathbf{q}}$ , která tuto transformaci provede stejně jako v rovnici (6.1) a je ve tvaru

$${}^B\mathbf{a} = \mathbf{R}_{(A)}^{(B)\mathbf{q}}\mathbf{a}, \quad (6.11)$$

kde  ${}^A\mathbf{a}$  jsou původní souřadnice a  ${}^B\mathbf{a}$  jsou souřadnice nové. Indexy u  $\mathbf{q}$  značí orientaci A framu vzhledem k framu B.

Matice  $\mathbf{R}_{(A)}^{(B)\mathbf{q}}$  se označuje jako DCM (*Direction Cosine Matrix*) a je definovaná vztahem

$$\mathbf{R}_{(A)}^{(B)\mathbf{q}} = \begin{bmatrix} 1 - 2q_2^2 - 2q_3^2 & 2(q_1q_2 - q_0q_3) & 2(q_1q_3 + q_0q_2) \\ 2(q_0q_3 + q_1q_2) & 1 - 2q_1^2 - 2q_3^2 & 2(q_2q_3 - q_0q_1) \\ 2(q_1q_3 - q_0q_2) & 2(q_0q_1 + q_2q_3) & 1 - 2q_1^2 - 2q_3^2 \end{bmatrix}. \quad (6.12)$$

Pro určení kvaternionu orientace se využívá jednotková velikost podle

$$|\mathbf{q}|^2 = q_0^2 + q_1^2 + q_2^2 + q_3^2 = 1. \quad (6.13)$$

Pokud by se stalo, že rovnice (6.13) neplatí a kvaternion není jednotkový, je nutné kvaternion nejdříve normovat na jednotkovou velikost, protože je to pro vyjádření orientace v podobě kvaternionů vyžadováno [64]. Díky tomu poté také platí

$$\mathbf{q}^{-1} = \mathbf{q}^*. \quad (6.14)$$

Operaci transformace mezi souřadnicemi je možné provést i zpět (opačným směrem) a je možné k tomu využít právě komplexního sdružení kvaternionu. Pokud  ${}^A_B\mathbf{q}$  udává orientaci rámce B vzhledem k A, tak použití komplexního sdružení značí přechod opačným směrem a pro přechod z A do B a opačně platí

$${}^B_A\mathbf{q}^* = {}^A_B\mathbf{q} = [q_0 \quad -q_1 \quad -q_2 \quad -q_3]^T. \quad (6.15)$$

Při znalosti kvaternionů orientace je možné vypočítat podle Madgwicka [65] zpětně Eulerovy úhly *roll*, *pitch* a *yaw* jako

$$\Phi = \text{atan2}(2q_3q_4 - 2q_1q_2, 2q_1^2 + 2q_4^2 - 1), \quad (6.16)$$

$$\Theta = -\arcsin(2q_2q_4 + 2q_1q_3), \quad (6.17)$$

$$\Psi = \text{atan2}(2q_2q_3 - 2q_1q_4, 2q_1^2 + 2q_2^2 - 1). \quad (6.18)$$

## 6.3 Odhad orientace

Jelikož Eulerovy úhly nejsou pro své problémy v této práci dobře využitelné, je potřeba odhadovat orientaci pomocí kvaternionů. Ty jsou dokonce méně výpočetně náročné a obsahují méně parametrů. Většina z dnes používaných fúzovacích algoritmů jsou na tomto principu založena. K tomu slouží dvě skupiny přístupů k odhadu orientace – deterministické a stochastické. Mezi deterministické patří např. algoritmy TRIAD (*Tri-Axial Attitude Determination*), QUEST (*Quaternion Estimator*), FQA (*Factored Quaternion Algorithm*) a GN (*Gauss-Newton*) optimalizace. Ty odhadují natočení bez využití gyroskopu. Stochastický přístup používá model pro odhad chování časových aspektů systému (dynamický model) a model senzorů měření (měřicí model), aby produkoval co nejpřesnější odhady. Ze stochastických algoritmů je nejpoužívanější Kalmanův filtr a poskytuje také nejlepší přesnost. [3, 6, 66]

K určení odhadu orientace je potřeba měření z akcelerometru a magnetometru fúzovat a přidat k nim úhlovou rychlost z gyroskopu. Cílem následujícího algoritmu je zkombinovat dohromady celkem 9 měření během jedné iterace a získat orientaci v podobě kvaternionu a odhadu *biasu* gyroskopu. Díky znalosti orientace je poté možné vypočítat z akcelerometru lineární zrychlení, které je využito pro odhad kroku a jeho délky.

### 6.3.1 EKF s kvaterniony

Dle [67] byl zvolen algoritmus využívající EKF, protože je jeden z mála, který umožňuje fúzi všech 3 inerciálních senzorů – gyroskopu, akcelerometru a magnetometru. Celý algoritmus je pak inspirovaný [68] a [69].

Aby bylo možné Kalmanův filtr použít, je potřeba nejprve určit stavový a řídicí vektor. Jelikož úhlová rychlost se získává z gyroskopu, lze použít kinematickou rovnici pro získání stavu orientace [6]. Je tedy vhodné pracovat s daty z gyroskopu jako s externími vstupy v řídicím vektoru než jako s měřeními. Díky tomu je možné zredukovat dimenzi pro stavový vektor a docílit nižší výpočetní náročnosti [6]. Data z gyroskopu tedy budou využita pro predikci a data z akcelerometru a magnetometru pak budou využita jako měření během korekčního kroku. Výpočty s kvaterniony jsou nelineární, což vede k výpočtu Jakobiánu u přenosové i měřicí matice, jak bude ukázáno dále. Z toho důvodu je nutné používat EKF.

Stavový vektor  $\mathbf{x}$  a řídicí vektor  $\mathbf{u}$  budou definovány jako

$$\mathbf{x} \triangleq [\mathbf{q}^T \ \mathbf{b}^T]^T = [q_0 \ q_1 \ q_2 \ q_3 \ b_x \ b_y \ b_z]^T, \quad (6.19)$$

$$\mathbf{u} \triangleq \boldsymbol{\omega} = [\omega_x \ \omega_y \ \omega_z]^T, \quad (6.20)$$

kde  $\mathbf{q}$  značí kvaternion orientace,  $\mathbf{b}$  bias úhlové rychlosti gyroskopu a  $\boldsymbol{\omega}$  úhlovou rychlost gyroskopu, která je reprezentovaná kvaternionem s nulovou reálnou složkou.

#### Predikce

Dynamický model systému rotace lze dle [40] popsat rovnicí

$$\dot{\mathbf{q}} = \frac{1}{2}\mathbf{S}(\boldsymbol{\omega})\mathbf{q} = \frac{1}{2}\mathbf{S}(\mathbf{q})\boldsymbol{\omega}, \quad (6.21)$$



kde  $\dot{\mathbf{q}}$  značí časovou derivaci kvaternionu  $\mathbf{q}$  a  $\mathbf{S}(\boldsymbol{\omega})$  se dá zapsat jako

$$\mathbf{S}(\boldsymbol{\omega}) = \begin{bmatrix} 0 & -\boldsymbol{\omega}^T \\ \boldsymbol{\omega} & [\boldsymbol{\omega}]_{\times} \end{bmatrix} = \begin{bmatrix} 0 & -\omega_x & -\omega_y & -\omega_z \\ \omega_x & 0 & \omega_z & -\omega_y \\ \omega_y & -\omega_z & 0 & \omega_x \\ \omega_z & \omega_y & -\omega_x & 0 \end{bmatrix}, \quad (6.22)$$

kde  $[\boldsymbol{\omega}]_{\times}$  rozšiřuje vektor  $\boldsymbol{\omega}$  do antisymetrické  $3 \times 3$  matice.  $\mathbf{S}(\mathbf{q})$  je matice

$$\mathbf{S}(\mathbf{q}) = \begin{bmatrix} -q_1 & -q_2 & -q_3 \\ q_0 & -q_3 & q_2 \\ q_3 & q_0 & -q_1 \\ -q_2 & q_1 & q_0 \end{bmatrix}. \quad (6.23)$$

Pro odhadování driftu gyroskopu, je nutné rovnici (6.21) upravit a úhlovou rychlost  $\boldsymbol{\omega}$  kompenzovat *biasem*  $\mathbf{b}$  vztahem

$$\dot{\mathbf{q}} = \frac{1}{2}\mathbf{S}(\boldsymbol{\omega} - \mathbf{b})\mathbf{q} = \frac{1}{2}\mathbf{S}(\mathbf{q})(\boldsymbol{\omega} - \mathbf{b}) = \frac{1}{2}\mathbf{S}(\mathbf{q})\boldsymbol{\omega} - \frac{1}{2}\mathbf{S}(\mathbf{q})\mathbf{b}. \quad (6.24)$$

Pokud se uvažuje definice  $\hat{\mathbf{q}}$  podle rovnice (6.24), pak lze využít vztah pro predikovaný stav  $\mathbf{x}_n$  z [70], kde se ponechá pouze první derivace a ostatní se zanedbá. Pak predikce stavu má tvar

$$\hat{\mathbf{q}}_n = \hat{\mathbf{q}}_{n-1} + \frac{\Delta t}{2} \left( \mathbf{S}(\hat{\mathbf{q}}_{n-1})\boldsymbol{\omega}_n - \mathbf{S}(\hat{\mathbf{q}}_{n-1})\hat{\mathbf{b}}_{n-1} \right), \quad (6.25)$$

kde  $\Delta t$  je čas mezi jednotlivými vzorky gyroskopu. Výsledná predikce stavového vektoru se poté rovná

$$\hat{\mathbf{x}}_n = \begin{bmatrix} \hat{\mathbf{q}} \\ \hat{\mathbf{b}} \end{bmatrix}_n = \begin{bmatrix} \mathbf{I}_4 & -\frac{\Delta t}{2}\mathbf{S}(\mathbf{q}) \\ \mathbf{0}_{3 \times 4} & \mathbf{I}_3 \end{bmatrix} \begin{bmatrix} \hat{\mathbf{q}} \\ \hat{\mathbf{b}} \end{bmatrix}_{n-1} + \begin{bmatrix} \frac{\Delta t}{2}\mathbf{S}(\mathbf{q}) \\ \mathbf{0}_3 \end{bmatrix} \boldsymbol{\omega}_n, \quad (6.26)$$

kde  $\mathbf{I}_4$  je jednotková matice velikosti  $4 \times 4$ ,  $\mathbf{I}_3$  je jednotková matice o rozměrech  $3 \times 3$ ,  $\mathbf{0}_{3 \times 4}$  je nulová matice velikosti  $3 \times 4$  a  $\mathbf{0}_3$  je nulová matice velikosti  $3 \times 3$ . Rovnici (6.26) je možné rozepsat do tvaru

$$\begin{bmatrix} q_0 \\ q_1 \\ q_2 \\ q_3 \\ b_x \\ b_y \\ b_z \end{bmatrix}_n = \begin{bmatrix} 1 & 0 & 0 & 0 & \frac{\Delta t}{2}q_1 & \frac{\Delta t}{2}q_2 & \frac{\Delta t}{2}q_3 \\ 0 & 1 & 0 & 0 & -\frac{\Delta t}{2}q_0 & \frac{\Delta t}{2}q_3 & -\frac{\Delta t}{2}q_2 \\ 0 & 0 & 1 & 0 & -\frac{\Delta t}{2}q_3 & -\frac{\Delta t}{2}q_0 & \frac{\Delta t}{2}q_1 \\ 0 & 0 & 0 & 1 & \frac{\Delta t}{2}q_2 & -\frac{\Delta t}{2}q_1 & -\frac{\Delta t}{2}q_0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} q_0 \\ q_1 \\ q_2 \\ q_3 \\ b_x \\ b_y \\ b_z \end{bmatrix}_{n-1} + \frac{\Delta t}{2} \begin{bmatrix} -q_1 & -q_2 & -q_3 \\ q_0 & -q_3 & q_2 \\ q_3 & q_0 & -q_1 \\ -q_2 & q_1 & q_0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \omega_x \\ \omega_y \\ \omega_z \end{bmatrix}_n. \quad (6.27)$$

Dle definice EKF je potřeba získat funkci přechodu stavů  $\mathbf{f}$ . Rovnice (6.25),

(6.26) a (6.27) lze rozepsat a získat tak tuto funkci pro odhad stavu jako

$$\begin{aligned} \hat{\mathbf{x}}_n &= \mathbf{f}(\hat{\mathbf{x}}_{n-1}, \boldsymbol{\omega}_n) \\ &= \begin{bmatrix} q_0 - \frac{\Delta t}{2}\omega_x q_1 - \frac{\Delta t}{2}\omega_y q_2 - \frac{\Delta t}{2}\omega_z q_3 + \frac{\Delta t}{2}b_x q_1 + \frac{\Delta t}{2}b_y q_2 + \frac{\Delta t}{2}b_z q_3 \\ q_1 + \frac{\Delta t}{2}\omega_x q_0 - \frac{\Delta t}{2}\omega_y q_3 + \frac{\Delta t}{2}\omega_z q_2 - \frac{\Delta t}{2}b_x q_0 + \frac{\Delta t}{2}b_y q_3 - \frac{\Delta t}{2}b_z q_2 \\ q_2 + \frac{\Delta t}{2}\omega_x q_3 + \frac{\Delta t}{2}\omega_y q_0 - \frac{\Delta t}{2}\omega_z q_1 - \frac{\Delta t}{2}b_x q_3 - \frac{\Delta t}{2}b_y q_0 + \frac{\Delta t}{2}b_z q_1 \\ q_3 - \frac{\Delta t}{2}\omega_x q_2 + \frac{\Delta t}{2}\omega_y q_1 + \frac{\Delta t}{2}\omega_z q_0 + \frac{\Delta t}{2}b_x q_2 - \frac{\Delta t}{2}b_y q_1 - \frac{\Delta t}{2}b_z q_0 \\ b_x \\ b_y \\ b_z \end{bmatrix}. \end{aligned} \quad (6.28)$$

Matice  $\mathbf{F}$  se vypočítá jako Jakobián rovnice (6.28) a vypadá jako

$$\mathbf{F}(\hat{\mathbf{x}}_{n-1}, \boldsymbol{\omega}_n) = \frac{\partial \mathbf{f}(\mathbf{x}, \boldsymbol{\omega}_n)}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{n-1}} = \begin{bmatrix} 1 & -\frac{\Delta t}{2}\omega_x + \frac{\Delta t}{2}b_x & -\frac{\Delta t}{2}\omega_y + \frac{\Delta t}{2}b_y & -\frac{\Delta t}{2}\omega_z + \frac{\Delta t}{2}b_z & \frac{\Delta t}{2}q_1 & \frac{\Delta t}{2}q_2 & \frac{\Delta t}{2}q_3 \\ \frac{\Delta t}{2}\omega_x - \frac{\Delta t}{2}b_x & 1 & \frac{\Delta t}{2}\omega_z - \frac{\Delta t}{2}b_z & -\frac{\Delta t}{2}\omega_y + \frac{\Delta t}{2}b_y & -\frac{\Delta t}{2}q_0 & \frac{\Delta t}{2}q_3 & -\frac{\Delta t}{2}q_2 \\ \frac{\Delta t}{2}\omega_y - \frac{\Delta t}{2}b_y & -\frac{\Delta t}{2}\omega_z + \frac{\Delta t}{2}b_z & 1 & \frac{\Delta t}{2}\omega_x - \frac{\Delta t}{2}b_x & -\frac{\Delta t}{2}q_3 & -\frac{\Delta t}{2}q_0 & \frac{\Delta t}{2}q_1 \\ \frac{\Delta t}{2}\omega_z - \frac{\Delta t}{2}b_z & \frac{\Delta t}{2}\omega_y - \frac{\Delta t}{2}b_y & -\frac{\Delta t}{2}\omega_x + \frac{\Delta t}{2}b_x & 1 & \frac{\Delta t}{2}q_2 & -\frac{\Delta t}{2}q_1 & -\frac{\Delta t}{2}q_0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}. \quad (6.29)$$

## Korekce

Měření z gyroskopu byla použita pro predikci kvaternionu. Nyní je třeba rozhodnout, jak bude zacházeno s měřeními akcelerometru a magnetometru. Pro měřicí model existuje několik variant. Můžou být zfúzovány přímo pomocí deterministického odhadu (TRIAD, QUEST, FQA, GN estimátor). Preferovanou metodou je transformování orientace z *body* rámce do lokálních souřadnic a korigovat jí predikci. [6]

Vektor měření obsahuje údaje z akcelerometru a magnetometru a je definován jako

$$\mathbf{z}_n = \begin{bmatrix} \mathbf{a}_n \\ \mathbf{m}_n \end{bmatrix} = \begin{bmatrix} a_x \\ a_y \\ a_z \\ m_x \\ m_y \\ m_z \end{bmatrix}_n, \quad (6.30)$$

kde  $\mathbf{a}_n$  a  $\mathbf{m}_n$  jsou měření z akcelerometru, respektive magnetometru v čase  $n$ .

Senzory poskytují měření v *body* rámci, ale očekávaná měření akcelerometru a magnetometru jsou v lokálních souřadnicích. Z predikčního kroku je tedy známý

odhadnutý kvaternion  $\hat{\mathbf{q}}_n$ , který už popisuje orientaci vzhledem k lokálním souřadnicím, a proto je možné ho využít k rotaci měření zbylých senzorů. Jak bylo ukázáno v předchozí sekci, lze měření transformovat s využitím rovnice (6.12). Magnetometr poskytuje vektor, který směřuje k magnetickému severu. Jak bylo uvedeno v kapitole 4, tak se tento vektor s různou polohou na Zemi mění.

Měřené hodnoty akcelerometru a magnetometru jsou v této práci zaznamenány v ENU souřadném systému *body* rámce. Gravitační zrychlení v lokální soustavě se dá zapsat jako  ${}^L\mathbf{g} = [0 \ 0 \ 9,81]^\top$  v  $\text{m s}^{-2}$ . Gravitační zrychlení v lokálním rámci se totiž nachází pouze v ose  $z$ .

Zemské magnetické pole se dá také popsat 3D vektorem jako  $\mathbf{p} = [p_x \ p_y \ p_z]^\top$ . V ideálním případě, pokud by se neuvažovala magnetická deklinace, by se dalo napsat  ${}^L\mathbf{p} = [0 \ p_y \ 0]^\top$ . V kapitole 4 bylo uvedeno, že magnetický a pravý severní pól nesměřuje stejným směrem. Proto je tato zjednodušená varianta neakceptovatelná. Magnetický vektor je pak možné spočítat pomocí vztahu  ${}^L\mathbf{p} = [0 \ \cos(h_\Delta) \ -\sin(h_\Delta)]^\top$ , kde  $h_\Delta$  je magnetická deklinace pro danou oblast.

Orientace je udávána normalizovaným kvaternionem, a proto je nutné před dalšími kroky gravitační a magnetický vektor normovat následujícím způsobem jako

$${}^L\mathbf{g} = [0 \ 0 \ 1]^\top, \quad (6.31)$$

$${}^L\mathbf{p} = \frac{1}{\sqrt{\cos^2(h_\Delta) + \sin^2(h_\Delta)}} [0 \ \cos(h_\Delta) \ -\sin(h_\Delta)]^\top. \quad (6.32)$$

Aby výsledný kvaternion měl jednotkovou velikost, je potřeba také normovat měření ze senzorů jako

$${}^B\mathbf{a} = \frac{1}{\sqrt{a_x^2 + a_y^2 + a_z^2}} [a_x \ a_y \ a_z]^\top, \quad (6.33)$$

$${}^B\mathbf{m} = \frac{1}{\sqrt{m_x^2 + m_y^2 + m_z^2}} [m_x \ m_y \ m_z]^\top. \quad (6.34)$$

Uvedené gravitační zrychlení  $\mathbf{g}$  a magnetické pole  $\mathbf{p}$  je nutné transformovat z lokálního do *body* rámce. K tomu je možné využít predikovaný kvaternion ve tvaru

$${}^B\hat{\mathbf{a}} = \mathbf{R}_{(L)}^{(B)}(\hat{\mathbf{q}})^\top ({}^L\mathbf{g}), \quad (6.35)$$

$${}^B\hat{\mathbf{m}} = \mathbf{R}_{(L)}^{(B)}(\hat{\mathbf{q}})^\top ({}^L\mathbf{p}), \quad (6.36)$$

kde  $\mathbf{R}_{(L)}^{(B)}(\hat{\mathbf{q}})$  je matice ze vztahu (6.12).

Z předchozích rovnic lze definovat model měření jako

$$\mathbf{h}(\hat{\mathbf{q}}_n) = \begin{bmatrix} \hat{\mathbf{a}} \\ \hat{\mathbf{m}} \end{bmatrix} = 2 \begin{bmatrix} g_x(\frac{1}{2} - q_2^2 - q_3^2) + g_y(q_0q_3 + q_1q_2) + g_z(q_1q_3 - q_0q_2) \\ g_x(q_1q_2 - q_0q_3) + g_y(\frac{1}{2} - q_1^2 - q_3^2) + g_z(q_0q_1 + q_2q_3) \\ g_x(q_0q_2 + q_1q_3) + g_y(q_2q_3 - q_0q_1) + g_z(\frac{1}{2} - q_1^2 - q_2^2) \\ p_x(\frac{1}{2} - q_2^2 - q_3^2) + p_y(q_0q_3 + q_1q_2) + p_z(q_1q_3 - q_0q_2) \\ p_x(q_1q_2 - q_0q_3) + p_y(\frac{1}{2} - q_1^2 - q_3^2) + p_z(q_0q_1 + q_2q_3) \\ p_x(q_0q_2 + q_1q_3) + p_y(q_2q_3 - q_0q_1) + p_z(\frac{1}{2} - q_1^2 - q_2^2) \end{bmatrix}. \quad (6.37)$$

Jeho Jakobián je poté vypočítán jako

$$\mathbf{H}(\hat{\mathbf{q}}_n) = \frac{\partial \mathbf{h}(\hat{\mathbf{q}}_n)}{\partial \mathbf{q}} = \begin{matrix} 2 & \begin{bmatrix} g_y q_3 - g_z q_2 & g_y q_2 + g_z q_3 & -2g_x q_2 + g_y q_1 - g_z q_0 & -2g_x q_3 + g_y q_0 + g_z q_1 & 0 & 0 & 0 \\ -g_x q_3 + g_z q_1 & g_x q_2 - 2g_y q_1 + g_z q_0 & g_x q_1 + g_z q_3 & -g_x q_0 - 2g_y q_3 + g_z q_2 & 0 & 0 & 0 \\ g_x q_2 - g_y q_1 & g_x q_3 - g_y q_0 - 2g_z q_1 & g_x q_0 + g_y q_3 - 2g_z q_2 & g_x q_1 + g_y q_2 & 0 & 0 & 0 \\ p_y q_3 - p_z q_2 & p_y q_2 + p_z q_3 & -2p_x q_2 + p_y q_1 - p_z q_0 & -2p_x q_3 + p_y q_0 + p_z q_1 & 0 & 0 & 0 \\ -p_x q_3 + p_z q_1 & p_x q_2 - 2p_y q_1 + p_z q_0 & p_x q_1 + p_z q_3 & -p_x q_0 - 2p_y q_3 + p_z q_2 & 0 & 0 & 0 \\ p_x q_2 - p_y q_1 & p_x q_3 - p_y q_0 - 2p_z q_1 & p_x q_0 + p_y q_3 - 2p_z q_2 & p_x q_1 + p_y q_2 & 0 & 0 & 0 \end{bmatrix} \end{matrix} \quad (6.38)$$

Šum ze senzorů je uvažován jako nekorelovaný a izotropický. Matice  $\mathbf{R}$  se spočítá vztahem

$$\mathbf{R} = \begin{bmatrix} \sigma_a^2 \mathbf{I}_3 & \mathbf{0}_3 \\ \mathbf{0}_3 & \sigma_m^2 \mathbf{I}_3 \end{bmatrix}, \quad (6.39)$$

kde  $\sigma_a^2$  a  $\sigma_m^2$  jsou rozptyly akcelerometru a magnetometru,  $\mathbf{I}_3$  je jednotková matice velikosti  $3 \times 3$  a  $\mathbf{0}_3$  je nulová matice  $3 \times 3$ .

S ohledem na vzorkovací frekvence senzorů je možné provádět korekci buď pro každý senzor samostatně, nebo pro oba senzory současně v závislosti na časové značce vzorku. Problémem je, že většinou je orientace řešena pro statický objekt. Pro pohybující objekt se musí využít lehce modifikovaný algoritmus jako je využit v [71] a korekci z měření akcelerometru aplikovat pouze, pokud se chodec nachází v klidu. Tato práce se zabývá pohybem chodce, takže je nutné uvažovat orientaci pohyblivého objektu. Jelikož v tomto řešení se během chůze ve zrychlení vyskytuje i zrychlení lineární, tak pokud by se kvaternion opravoval v každém měření zrychlení, bude výsledek zkreslený touto nepřesností. Proto je vhodné aktivovat korekční krok pouze, když je uživatel v klidu. To nastává na konci každého kroku, kdy se ve vektoru zrychlení vyskytují pouze gravitační údaje a lineární zrychlení je minimální. Za konec kroku je možné označit chvíli, kdy chodec dopadne nohou na zem a ještě neudělá pohyb druhou nohou. Naopak, ve chvílích pohybu je nutné se spoléhat pouze na měření gyroskopu a magnetometru.

## 6.4 Výpočet lineárního zrychlení

Ve chvíli, kdy je známá orientace zařízení, je možné přejít k výpočtu lineárního zrychlení. To je možné oddělit z měření akcelerometru díky znalosti zrychlení gravitačního.

Na sledovaný systém působí gravitační vektor  ${}^L \mathbf{g} = [0 \ 0 \ 9,81]^T$  v  $\text{m}^2 \text{s}^{-1}$ . Podle [72], pak s využitím znalosti transformační matice  $\mathbf{R}({}^L_B \hat{\mathbf{q}})$  (6.12), lze gravitační zrychlení převést do *body* rámce jako

$${}^B \mathbf{g} = \mathbf{R}({}^L_B \hat{\mathbf{q}}) {}^L \mathbf{g}, \quad (6.40)$$

kde  ${}^B \mathbf{g}$  je přepočítaná gravitace. Pak pouze stačí od celkového zrychlení odečíst vypočítané gravitační zrychlení postupně pro všechny osy a získat výsledné lineární zrychlení  $\mathbf{a}$  v *body* rámci jako

$${}^B \mathbf{a} = {}^B \mathbf{ag} - {}^B \mathbf{g}, \quad (6.41)$$

kde  $\mathbf{g}$  je gravitační zrychlení a  $\mathbf{ag}$  je původní naměřený vektor obsahující lineární i gravitační zrychlení.

# Kapitola 7

## Měření

Tato kapitola se nejprve zabývá popisem metody sběru dat ze senzorů mobilního telefonu s operačním systémem Android. Získaná data mohou být zpracována metodami popsanými v předchozích částech práce. Zbytek kapitoly prezentuje zpracovaná data v podobě naměřených průběhů tras, z kterých je vyhodnocena použitelnost a robustnost celého systému.

### 7.1 Aplikace – sběr dat

Cílem této práce je sledovat pohyb chodce. U těch je jedno z nejrozšířenějších zařízení jednoznačně telefon. Proto je vhodné senzory takového chytrého telefonu využít. Pro co nejsnadnější získávání dat ze senzorů a případně další funkčnosti byl zvolen telefon s operačním systémem Android. Výsledná aplikace pro sběr dat byla vyvinuta v prostředí Android Studio.

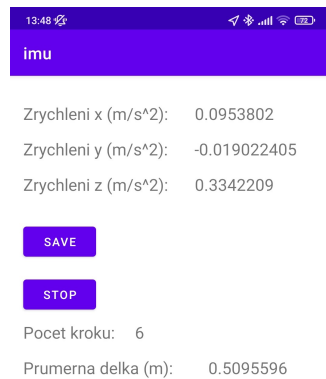
#### 7.1.1 Android

Operační systém Android poskytuje tři typy senzorů: Senzory pohybu (*motion*), senzory prostředí (*environment*) a senzory pozice (*position*). Programové rozhraní pro Android umožňuje přístup k několika typům senzorů. Primárně se rozlišují hardwarové a softwarové. Hardwarové senzory vychází z fyzických senzorů zařízení. Typicky se jedná právě o senzory jako akcelerometr, gyroskop nebo magnetometr. Softwarové senzory nejsou fyzicky přítomny v telefonu, ale zpracovávají už naměřené hodnoty ze senzorů hardwarových. Příkladem takových senzorů mohou být senzory orientace nebo lineárního zrychlení. [55]

#### 7.1.2 Aplikace

Základem pro správné fungování celého systému inerciální navigace je získání dat, která se dále zpracovávají. Pro tyto účely byla vytvořena aplikace, jejíž hlavní obrazovku je možno vidět na obrázku 7.1. K dispozici byl telefon Xiaomi Mi 9 s operačním systémem Android 11. K vývoji se díky tomu vybízelo použít prostředí Android Studio. Výhodou je, že většina moderních telefonů obsahuje MEMS senzory, které lze využít a zaznamenávat z nich potřebné informace o pohybu.

Aplikace zde zastává dvě role. První je záznam dat z akcelerometru, gyroskopu a magnetometru do samostatného souboru, které je možné dále využít pro následné



Obrázek 7.1: Aplikace pro sběr dat

zpracování v externím programu. Druhou rolí je detekce kroků a odhad jejich vzdáleností přímo za běhu v reálném čase. Druhá funkce nebyla použita pro měření a tato práce se jí nebude zabývat.

### 7.1.3 Použité senzory

Na použitém telefonu Xiaomi Mi 9 se nacházejí konkrétně tyto senzory:

- Akcelerometr společně s gyroskopem v jednom pouzdře 6 DOF: ST Microelectronics LSM6DS3C se vzorkovací frekvencí 400 Hz
- Magnetometr: AKM AK0991X se vzorkovací frekvencí 100 Hz.

### 7.1.4 Sběr dat

Základem pro tuto práci jsou tři inerciální senzory. Smyslem bylo využít čistá data, která nebyla systémem Android upravena. Pro sběr dat je potřeba přistupovat k jednotlivým typům senzorů. Data z akcelerometru obsahující gravitační i lineární zrychlení se nachází v senzoru `TYPE_ACCELEROMETER` v jednotkách  $\text{m s}^{-2}$ . Nekalibrované hodnoty úhlové rychlosti z gyroskopu jsou pak uloženy v `TYPE_GYROSCOPE` v jednotkách  $\text{rad s}^{-1}$  a data obsahující informace o magnetickém poli jsou obsaženy v `TYPE_MAGNETIC_FIELD` v jednotkách  $\mu\text{T}$ . Hodnoty pro všechny senzory, postupně v osách  $x$ ,  $y$  a  $z$  jsou uloženy vždy v proměnných `SensorEvent.values[0]`, `SensorEvent.values[1]` a nakonec v `SensorEvent.values[2]` aktuálně zaznamenaného senzoru.

Pro porovnání s daty softwarových senzorů androidu byly také pozorována data ze senzorů `TYPE_LINEAR_ACCELERATION`, který poskytuje lineární zrychlení

a z `TYPE_ROTATION_VECTOR`, ve kterém se nachází kvaternion rotace. Ten má jako jediný z uvedených senzorů 4 složky.

Aplikace si při spuštění záznamu vytvoří textový soubor, který uloží do vnitřního úložiště dokumentů. Textový soubor obsahuje středníkem oddělené hodnoty z požadovaných senzorů vždy ve 3 osách a záznam času v ms, ve kterém byly pořízeny.

## 7.2 Testovací měření

Měření, která měla ověřit celkové fungování navrhovaného systému probíhala dne 25.4.2023. První část měření probíhala v prostorech halových laboratoří v budově FEL, ČVUT v Dejvicích. Druhou částí bylo měření v exteriéru konkrétně v okolí budovy FEL a FS, ČVUT.

### 7.2.1 Zpracování dat

Výsledný algoritmus detekoval kroky metodou *zero crossing* a *peak detection* a délku odhadoval nakalibrovaným Weinbergovým modelem. K výpočtu polohy bylo využito nejprve samostatných dat z magnetometru a poté samostatných neupravených dat z gyroskopu. Jelikož gyroskop trpí driftem, jak bylo popsáno v kapitole 4, tak následně byla poloha počítána i z kalibrovaných dat gyroskopu. K odhadu jeho zkreslení bylo využito několik prvních sekund po začátku měření, kdy se telefon nehýbal a byl v klidu. V tomto okamžiku byla odečtena průměrná hodnota úhlové rychlosti zvlášť pro každou osu, kterou bylo možné měření z gyroskopu kompenzovat podle rovnice (4.4). Pak bylo možné využít Kalmanův filtr podle kapitoly 5 a fúzovat dohromady data z kalibrovaného gyroskopu a magnetometru. Větší váha zde byla kladena měřením gyroskopu než magnetometru s konkrétními konstantními maticemi

$$\mathbf{R} = \begin{bmatrix} 0,1 & 0 & 0 & 0 \\ 0 & 0,1 & 0 & 0 \\ 0 & 0 & 0,01 & 0 \\ 0 & 0 & 0 & 0,01 \end{bmatrix}, \quad (7.1)$$


$$\mathbf{Q} = \begin{bmatrix} 0,1 & 0 & 0 & 0 \\ 0 & 0,1 & 0 & 0 \\ 0 & 0 & 0,01 & 0 \\ 0 & 0 & 0 & 0,01 \end{bmatrix}. \quad (7.2)$$

Pomocí EKF z kapitoly 6 byla nakonec odhadována pouze počáteční orientace zařízení. S touto informací pak bylo měřicí zařízení zafixováno a byly transformovány zbylé vzorky měření.

### 7.2.2 Interiér

Měření v interiéru byla rozložena do tří odlišných částí. V první části bylo měřeno na široké chodbě a proběhlo zde nejvíce měření. Trasa chodce se zde srovnávala s referenčními body a systémem UWB podle [73]. Proto bylo potřeba nastavit a zaměřit referenční body k definování trasy, které jsou vykresleny na obrázku 7.2

a ohraničují prostor výskytu chodce. Body byly zaměřeny pomocí přesného zařízení 3D laserového dálkoměru Leica Disto S910. V tomto uskupení pak proběhlo více sad měření i s měřením systému UWB. Trasa se šla s mobilním telefonem v ruce a navíc bylo vedle telefonu nesené i UWB uživatelské zařízení.



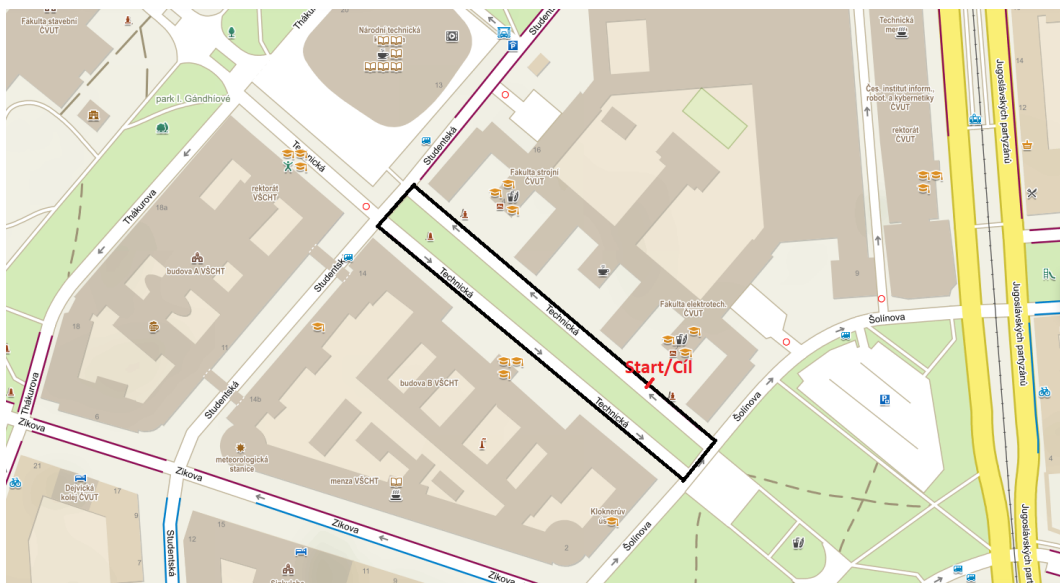
Obrázek 7.2: Rozmístění referenčních bodů

Následně, stále v prostorech školy, byla provedena měření v přiléhajících chodbách od prvního měření. Byl obcházen blok přibližně ve tvaru čtverce. Nejprve po směru hodinových ručiček a následně proti směru hodinových ručiček. Posledním pokusem v budově školy bylo otestováno, jak bude navrhovaný algoritmus fungovat, pokud se chodec pohybuje po schodech.

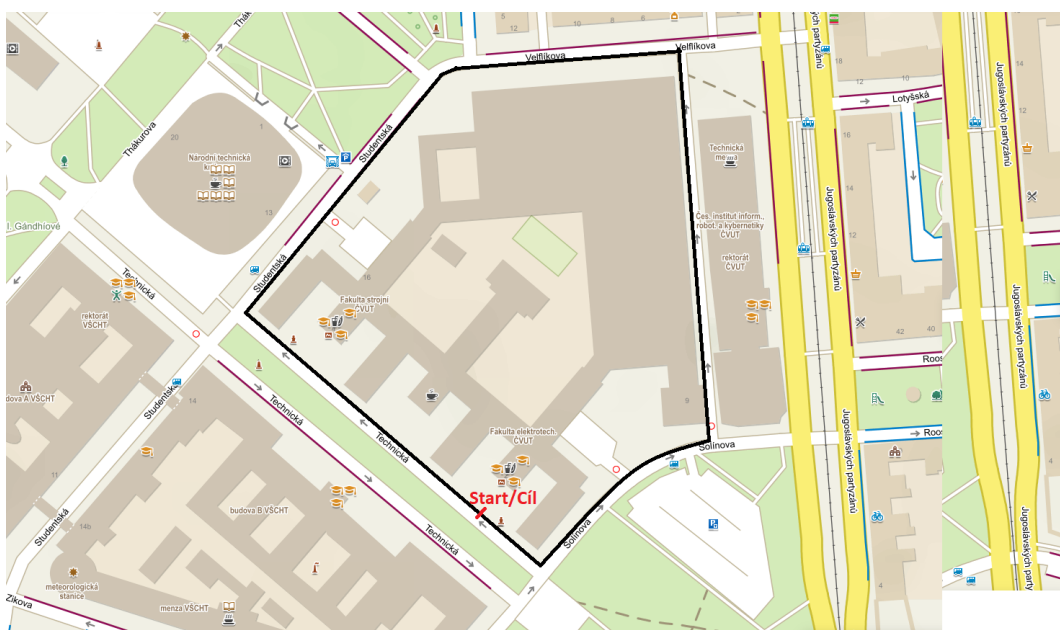
### 7.2.3 Exteriér

Venkovní trasy měření začínaly a končily před vstupem do budovy FEL, ČVUT v Dejvicích. Byly naměřeny postupně dvě trasy. Nejdříve tři stejné okruhy v kuse kolem Technické ulice po trase, která je znázorněna na obrázku 7.3. Následně kolečko kolem celé budovy FEL a FS ČVUT, jak je zobrazeno na obrázku 7.4.





Obrázek 7.3: Venkovní trasa po Technické ulici [74]



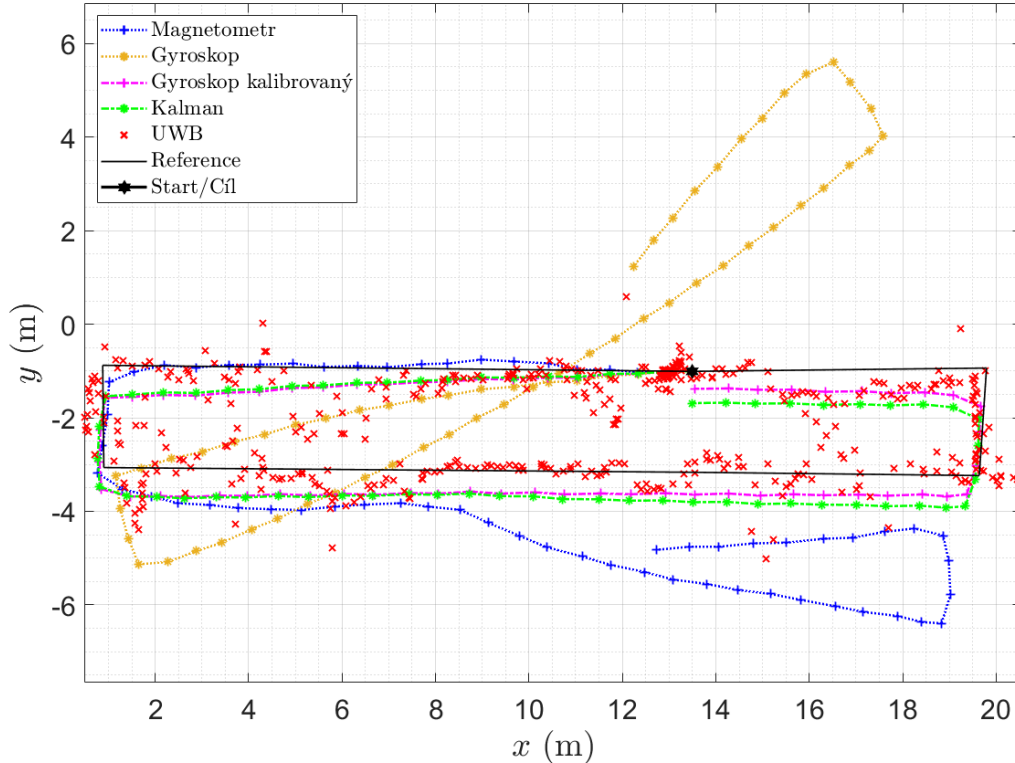
Obrázek 7.4: Venkovní trasa kolem budovy FEL a FS, ČVUT [74]

## 7.3 Výsledky

Výsledky z provedeného měření jsou opět rozděleny do dvou sekcí. V první jsou uvedeny cesty, které byly zaznamenány uvnitř budovy školy v prostorech halových laboratoří. Ty měly otestovat především přesnost lokalizace a krátkodobou až střednědobou stabilitu. V druhé sekci jsou vyobrazeny cesty, které byly naměřeny venku v okolí fakulty. Jejich cílem bylo zaznamenat delší cesty a vyhodnotit dlouhodobou stabilitu.

### 7.3.1 Interiér

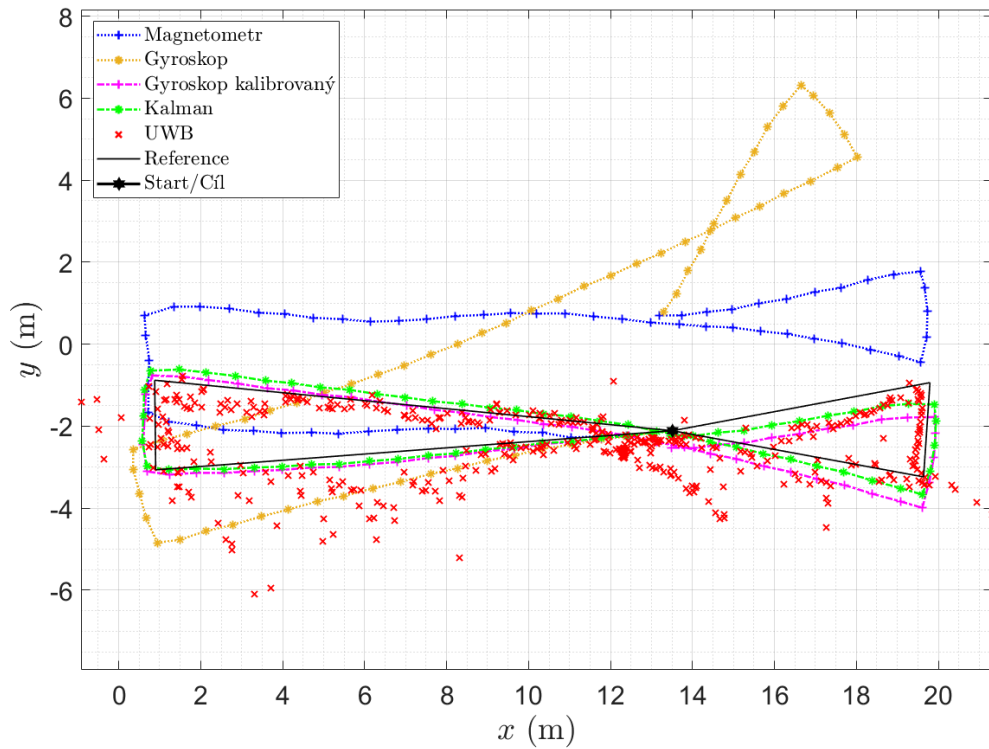
První část měření ve vnitřních prostorech probíhala přes vyznačené referenční body z obrázku 7.2. Záznamy z těchto cest se pohybovaly v přibližné délce 40–50 m za dobu 40–50 s. Na obrázku 7.5 je vidět první ušlá trasa ve tvaru obdélníku.




Obrázek 7.5: Chůze ve tvaru obdélníku

Barevné značení průběhů je stejné ve všech obrázcích této kapitoly a je následovné. Modrou barvou je ukázána trasa, která byla vypočtena z naměřených dat magnetometru. Oproti tomu žlutou barvou je vyznačena trasa z dat gyroskopu. Růžovou barvou je poté znázorněna trasa z kalibrovaných dat gyroskopu. Zelenou barvou je následně ukázána trasa, která byla získána fúzí dat z kalibrovaného gyroskopu a magnetometru Kalmanovým filtrem. Červeně jsou nakonec vyznačeny body zaznamenané systémem UWB. Černě je značena referenční trasa procházející vyměřenými body.

Další trajektorie měla tvar čísla osm s ostrými hranami a procházela krajními referenčními body, aby šlo měření s referencí porovnat. Zobrazena je na obrázku 7.6.




Obrázek 7.6: Chůze ve tvaru osmičky



Obrázek 7.7: Náhodná chůze s ostrým zatočením


Následovala náhodná cesta mezi referenčními body na obrázku 7.7. Na závěr tohoto typu měření se šlo kruhovým pohybem po úplně náhodné trase, pro kterou není zaznamenána trasa referenční. Je jí tedy možné porovnat pouze s daty z UWB.

Tato trasa je vykreslena na obrázku 7.8.



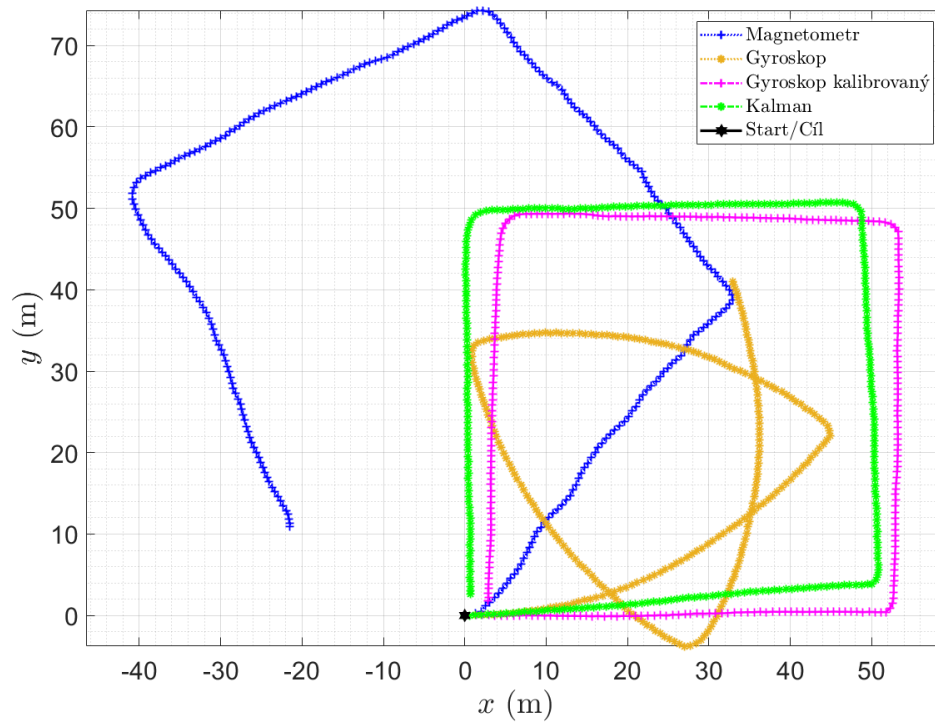
Obrázek 7.8: Náhodná chůze ve tvaru kruhů

Následují dvě trasy z chodeb v halových laboratořích, kde je vyobrazen čtverec nejprve po směru hodinových ručiček na obrázku 7.9 a následně proti směru hodinových ručiček na obrázku 7.10. Tyto trasy už byly delší než ty předchozí




Obrázek 7.9: Čtverec po směru hodinových ručiček

a neobsahují měření z UWB ani referenční trasu. Jejich přesnost je možné posoudit podle startovního a cílového bodu, které by se měly shodovat. Tyto trasy byly přibližné délky 200 m za čas 150 s.



Obrázek 7.10: Čtverec proti směru hodinových ručiček


Posledním typem měření v interiéru byl pokus, jak bude celý systém reagovat pokud by se chodec vydal po schodech. Průběh lineárního zrychlení pro chůzi deseti schodů nahoru je vykreslen na obrázku 7.11 a cesta po schodech dolů na obrázku 7.12.



Obrázek 7.11: Schody nahoru

Jak je vidět, kroky jsou detekovány správně, ale vůbec realitě neodpovídá


délka kroků. Průměrná naměřená délka kroku pro chůzi po schodech nahoru byla 0,8019 m, kdežto reálně krok měřil 0,28 m. To samé platilo pro chůzi ze schodů. Tam byla naměřena průměrná délka kroku 0,7645 m oproti reálným 0,28 m.




Obrázek 7.12: Schody dolů

### 7.3.2 Exteriér

Při venkovním měření byly naměřeny dohromady dvě dlouhé trasy, opět s absencí systému UWB a bez referenčních bodů, pro získání představy o dlouhodobé stabilitě systému. První je naměřená trasa na obrázku 7.13, která vedla kolem celé budovy FEL a FS ČVUT. Podle mapových podkladů [74] měří celá trasa 841 m a aplikací bylo naměřeno 846,5 m za čas 570 s.



Obrázek 7.13: Okruh kolem budovy FEL a FS ČVUT



Obrázek 7.14: 3 okruhy kolem Technické ulice

Druhou trasou byl okruh kolem Technické ulice na obrázku 7.14, který byl obejit celkem třikrát v rámci jednoho měření. Podle mapových podkladů [74] měří

jedno kolečko trasy 448 m, čili celá trasa je dlouhá 1344 m a naměřeno bylo celkem 1331,9 m za 930 s.

Výsledné chyby odhadu polohy měřených tras jsou shrnuty v tabulce 7.1, která je podle jednotlivých typů rozdělena na tři části.

Typ měření	Chyba výsledné polohy (m)
Interiér – krátké trasy	
Obdélník	0,6759
Osmička	0,1316
Náhodné ostré	0,4047
Náhodné kruhy	0,4981
Interiér – středně dlouhé trasy	
Čtverec po směru	12,7153
Čtverec proti směru	2,7194
Exteriér – dlouhé trasy	
Kolem ČVUT	32,5383
3 okruhy	72,3769

Tabulka 7.1: Porovnání výsledných chyb v odhadu polohy

## 7.4 Diskuze

Na všech změřených cestách lze pozorovat nedokonalosti inerciálních senzorů. Magnetometr uvnitř i vně budovy vždy zachytí externí rušení a odklání se od reality. Na neupravených datech z gyroskopu je zase možné pozorovat, jak se již po několika sekundách projeví jeho *bias* a trasa se začne viditelně odklánět. Naštěstí lze měření gyroskopu korigovat kalibrací a tím jeho projev zdokonalit. Takové výsledky už se jeví jako použitelnější. Výhodné může být oba senzory zkombinovat Kalmanovým filtrem, v kterém je větší váha nastavena kalibrovanému gyroskopu. Zde pak takto většina tras vycházela nejpřesněji. Kompenzace dat gyroskopu probíhala pouze statickou hodnotou odečtenou na začátku měření. Hodnoty z orientačního filtru nakonec kvůli své nepřesnosti nebyly využity.

Jako velmi věrohodný lze vyhodnotit použitý Weinbergův model pro odhad vzdálenosti. Na kratších trasách přímé porovnání délky není dostupné, ale při venkovních měřeních se naměřená a reálná celková délka liší pouze v řádech desetin procent.

Průběhy z obrázků 7.5, 7.6, 7.7 a 7.8 ukazují, že pro krátkou dobu je možné systém inerciální navigace využít samostatně a vyhodnocená cesta se od reálné téměř nebude lišit. U průběhů z obrázků 7.9 a 7.10 se začíná dokládat, že při střednědobých odhadech polohy nemusí být výsledek vždy dostatečně přesný. Pro dlouhodobé odhady z obrázků 7.13 a 7.14 se ukázalo, že samostatné využití inerciální navigace se od reality odklání výrazně.

Odhadnutou polohu je potřeba ještě porovnat se samostatným systémem UWB. Z velké části si jsou trasy podobné, ale v některých místech se od sebe odchyľují



a někdy se i výrazně liší. Při pohledu na referenční trasy se jim víc podobají cesty naměřené inerciální navigací než UWB. Jeho nepřesnost zde může být způsobena nevhodným umístěním antény nebo útlumem překážek v chodbě.

V případě využití inerciální navigace v dlouhodobějším horizontu se jeví jako vhodné vypočtenou polohu opravit z externího systému. Tím by se vymazala naakumulovaná chyba a navigace se výrazně zlepšila. V interiérech je možno využít systémy jako WiFi [75], mapové podklady [9] a nebo právě UWB. Případně je možné zkombinovat WLAN a mapové podklady jako v [1]. Při chůzi venku je možné využití kombinace s GNSS a vytvořit komplexní navigaci jak popisuje Groves [52].

## 7.5 Možnosti dalšího směřování

Oblast směřování této práce je široká a je možné ji rozšířit mnoha směry. Mezi jeden takový může patřit řešení chůze po schodech a změny patra. Jak uvádí v [24], tak je možné při použití barometru sledovat změnu patra buď po schodech a nebo výtahem. Rozdílu tlaku pak využívají v [76] a snaží se změny výšky sledovat. Ovšem jak v předchozí části této práce bylo zjištěno, odhad délky kroku při chůzi po schodech nelze dobře využít.

Dále se nabízí možnost vyzkoušet a otestovat, jak se celý systém bude chovat pokud se chodec rozeběhne. Je možné, že tento stav bude potřeba rozpoznat (jako například zde [77]) a minimálně modifikovat odhad délky kroku.

Díky dostupnosti záznamu měření, které kromě inerciálních dat obsahuje i data UWB se jako další možností jeví udělat fúzi těchto dvou systémů. Případně by bylo vhodné udělat další měření a zjistit, jak spolu dané systémy budou spolupracovat.

Nakonec bylo zjištěno, že při použití pouze mobilního telefonu nebo jakéhokoliv zařízení, které je drženo v ruce, nelze bez použití dalších senzorů, které by byly přítomny na těle chodce, vyhodnocovat obecnou orientaci zařízení. Nelze totiž rozlišit pokud se například zařízením pouze pohnulo a nebo se změnil azimut směřování. Azimut by tedy musely zajišťovat senzory umístěné někde na těle chodce. V této práci tedy bylo možné pouze určit počáteční orientaci, tu zafixovat a podle toho transformovat zbylá měření. K tomu byl využit filtr orientace z kapitoly 6. Nebylo tedy možné měnit orientaci měřícího zařízení během chůze. Dále by bylo možné filtr orientace vylepšit a využít ho ke kompenzaci dat gyroskopu, případně i k sledování směru kroku.



# Kapitola 8

## Závěr

Cílem této práce bylo odhadovat polohu chodce pomocí detekce kroku s využitím inerciálních měření. Teto cíl byl splněn, neboť byl udělán algoritmus detekující krok, ale i odhadující jeho délku a směr. Kombinací těchto zjištění pak algoritmus odhadoval polohu uživatele. K tomu byly využity inerciální senzory z chytrého mobilního telefonu.

Nejprve byly nalezeny, popsány a implementovány algoritmy vhodné pro detekci kroku a odhadu jeho délky z dat akcelerometru. Odhad délky kroku byl nakalibrován a výsledná průměrná chyba odhadu vycházela rovna 1,66 cm. Následně byla přidána měření z dalších inerciálních sensorů, gyroskopu a magnetometru, ze kterých bylo možné odhadovat směr pohybu chodce.

V další části byl představen univerzální nástroj v podobě Kalmanova filtru, který umožnil fúzovat měření z více sensorů nebo odhadovat orientaci zařízení. Pro analýzu obecné orientace bylo nutné definovat potřebné souřadné systémy a přechod mezi nimi. Ukázalo se, že pro danou transformaci nedostačují Eulerovy úhly a je nutné využít popis pomocí kvaternionů. S jejich popisem pak byl představen filtr na bázi EKF, který orientaci v podobě kvaternionů odhadoval. Navíc také odhadoval *bias* gyroskopu. Zde se narazilo na limit v podobě nerozlišitelnosti změny orientace od změny směru pohybu, takže orientace byla odhadnuta na začátku měření, zafixována a pomocí ní byly transformované zbylé vzorky měření.

V poslední kapitole byl popsán způsob sběru dat z mobilního telefonu s operačním systémem Android. Hlavní náplní však bylo ověřit funkčnost všech implementovaných metod. K tomu bylo provedeno několik měření, jak uvnitř budov, tak i vně. V naměřených průbězích bylo vidět, že využití samostatného nekompensovaného gyroskopu nebo magnetometru není pro odhad polohy dostatečné. Bylo ukázáno, že systém může být krátkodobě až střednědobě dobře využitelný, pokud se pro odhad směru použije kombinace kompenzovaného gyroskopu s magnetometrem. Pouze v exteriéru se dlouhodobá stabilita nepotvrdila. Ovšem jako zcela dostatečný se projevil algoritmus pro odhad délky kroku. Největší problém činilo správně určit směr pohybu.

Uvedený systém měl několik limitací a nedokonalostí. Dal by se využít jako základ pro další rozšiřování, mezi které může patřit například fúze s dalším systémem, který by data ze systému opravoval. Dále se také nabízí přidat barometr a rozšířit funkčnost i na změnu patra v budově.



# Literatura

1. H. Leppakoski, J. Collin a J. Takala, „Pedestrian navigation based on inertial sensors, indoor map, and WLAN signals“, in *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2012-03. DOI: 10.1109/icassp.2012.6288192.
2. SBG systems. „AHRS – Attitude and Heading Reference Ssstems“, Dostupné z: <https://www.sbg-systems.com/attitude-heading-reference-systems-ahrs/> (cit. 2023-05-16).
3. R. G. Valenti, I. Dryanovski a J. Xiao, „A Linear Kalman Filter for MARG Orientation Estimation Using the Algebraic Quaternion Algorithm“, *IEEE Transactions on Instrumentation and Measurement*, roč. 65, č. 2, s. 467–481, 2016-02. DOI: 10.1109/tim.2015.2498998.
4. M. Kok, J. D. Hol a T. B. Schön, „Using Inertial Sensors for Position and Orientation Estimation“, *Foundations and Trends® in Signal Processing*, roč. 11, č. 1-2, s. 1–153, 2017. DOI: 10.1561/20000000094.
5. W. Lu, F. Wu, H. Zhu a Y. Zhang, „A Step Length Estimation Model of Coefficient Self-Determined Based on Peak-Valley Detection“, *Journal of Sensors*, roč. 2020, R. Morales, ed., s. 1–14, 2020-11. DOI: 10.1155/2020/8818130.
6. A. M. Sabatini, „Estimating Three-Dimensional Orientation of Human Body Parts by Inertial/Magnetic Sensing“, *Sensors*, roč. 11, č. 2, s. 1489–1525, 2011-01. DOI: 10.3390/s110201489.
7. Z. Sun, X. Mao, W. Tian a X. Zhang, „Activity classification and dead reckoning for pedestrian navigation with wearable sensors“, *Measurement Science and Technology*, roč. 20, č. 1, s. 015 203, 2008-11. DOI: 10.1088/0957-0233/20/1/015203.
8. X. Hou a J. Bergmann, „Pedestrian Dead Reckoning With Wearable Sensors: A Systematic Review“, *IEEE Sensors Journal*, roč. 21, č. 1, s. 143–152, 2021-01. DOI: 10.1109/jsen.2020.3014955.
9. H. Bao a W.-C. Wong, „An indoor dead-reckoning algorithm with map matching“, in *2013 9th International Wireless Communications and Mobile Computing Conference (IWCMC)*, IEEE, 2013-07. DOI: 10.1109/iwcmc.2013.6583784.
10. L.-F. Shi, Y.-L. Zhao, G.-X. Liu et al., „A Robust Pedestrian Dead Reckoning System Using Low-Cost Magnetic and Inertial Sensors“, *IEEE Transactions on Instrumentation and Measurement*, roč. 68, č. 8, s. 2996–3003, 2019-08. DOI: 10.1109/tim.2018.2869262.
11. B. Shin, C. Kim, J. Kim et al., „Motion Recognition based 3D Pedestrian Navigation System using Smartphone“, *IEEE Sensors Journal*, s. 1–1, 2016. DOI: 10.1109/jsen.2016.2585655.

12. S. Beauregard, „A helmet-mounted pedestrian dead reckoning system“, in *3rd International Forum on Applied Wearable Computing 2006*, VDE, 2006, s. 1–11.
13. N. Choe, H. Zhao, S. Qiu a Y. So, „A sensor-to-segment calibration method for motion capture system based on low cost MIMU“, *Measurement*, roč. 131, s. 490–500, 2019-01. DOI: 10.1016/j.measurement.2018.07.078.
14. J. Park, Y. Kim a J. Lee, „Waist mounted Pedestrian Dead-Reckoning system“, in *2012 9th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, IEEE, 2012-11. DOI: 10.1109/urai.2012.6463008.
15. M. Marschollek, M. Goevercin, K.-H. Wolf et al., „A performance comparison of accelerometry based step detection algorithms on a large, non-laboratory sample of healthy and mobility-impaired persons“, in *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, IEEE, 2008-08, s. 1319–1322. DOI: 10.1109/iembs.2008.4649407.
16. R. Harle, „A survey of indoor inertial positioning systems for pedestrians“, *IEEE Communications Surveys & Tutorials*, roč. 15, č. 3, s. 1281–1293, 2013. DOI: 10.1109/surv.2012.121912.00075.
17. S. Verma, R. Omanwar, V. Sreejith a G. S. Meera, „A smartphone based indoor navigation system“, in *2016 28th International Conference on Microelectronics (ICM)*, IEEE, 2016-12. DOI: 10.1109/icm.2016.7847886.
18. A. Abadleh, E. Al-Hawari, E. Alkafaween a H. Al-Sawalqah, „Step detection algorithm for accurate distance estimation using dynamic step length“, in *2017 18th IEEE international conference on mobile data management (MDM)*, IEEE, IEEE, 2017-05, s. 324–327. DOI: 10.1109/mdm.2017.52.
19. M. Susi, V. Renaudin a G. Lachapelle, „Motion Mode Recognition and Step Detection Algorithms for Mobile Phone Users“, *Sensors*, roč. 13, č. 2, s. 1539–1562, 2013-01. DOI: 10.3390/s130201539.
20. H. Leppäkoski, J. Collin a J. Takala, „Pedestrian navigation based on inertial sensors, indoor map, and WLAN signals“, *Journal of Signal Processing Systems*, roč. 71, s. 287–296, 2013.
21. W. Kang, S. Nam, Y. Han a S. Lee, „Improved heading estimation for smartphone-based indoor positioning systems“, in *2012 IEEE 23rd International Symposium on Personal, Indoor and Mobile Radio Communications-(PIMRC)*, IEEE, IEEE, 2012-09, s. 2449–2453. DOI: 10.1109/pimrc.2012.6362768.
22. R. W. Levi a T. Judd, *Dead reckoning navigational system using accelerometer to measure foot impacts*, US Patent 5,583,776, 1996.
23. W. Kang a Y. Han, „SmartPDR: Smartphone-based pedestrian dead reckoning for indoor localization“, *IEEE Sensors Journal*, roč. 15, č. 5, s. 2906–2916, 2015-05. DOI: 10.1109/jsen.2014.2382568.
24. L. Fang, P. J. Antsaklis, L. A. Montestruque et al., „Design of a wireless assisted pedestrian dead reckoning system-the NavMote experience“, *IEEE Transactions on Instrumentation and Measurement*, roč. 54, č. 6, s. 2342–2358, 2005-12. DOI: 10.1109/tim.2005.858557.
25. A. Perttula, H. Leppäkoski, M. Kirkko-Jaakkola et al., „Distributed indoor positioning system with inertial measurements and map matching“, *IEEE Transactions on Instrumentation and Measurement*, roč. 63, č. 11, s. 2682–2695, 2014-11. DOI: 10.1109/tim.2014.2313951.

26. A. Brajdic a R. Harle, „Walk detection and step counting on unconstrained smartphones“, in *Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing*, ACM, 2013-09, s. 225–234. DOI: 10.1145/2493432.2493449.
27. F. Li, C. Zhao, G. Ding et al., „A reliable and accurate indoor localization method using phone inertial sensors“, in *Proceedings of the 2012 ACM conference on ubiquitous computing*, ACM, 2012-09, s. 421–430. DOI: 10.1145/2370216.2370280.
28. J. Liu, R. Chen, L. Pei, R. Guinness a H. Kuusniemi, „A hybrid smartphone indoor positioning solution for mobile LBS“, *Sensors*, roč. 12, č. 12, s. 17208–17233, 2012-12. DOI: 10.3390/s121217208.
29. Q. Tian, Z. Salcic, K. I.-K. Wang a Y. Pan, „A Multi-Mode Dead Reckoning System for Pedestrian Tracking Using Smartphones“, *IEEE Sensors Journal*, roč. 16, č. 7, s. 2079–2093, 2016. DOI: 10.1109/jsen.2015.2510364.
30. A. R. Pratama, Widyawan a R. Hidayat, „Smartphone-based Pedestrian Dead Reckoning as an indoor positioning system“, in *2012 International Conference on System Engineering and Technology (ICSET)*, IEEE, 2012-09. DOI: 10.1109/icsengt.2012.6339316.
31. P. Neto, J. N. Pires a A. P. Moreira, „3-D position estimation from inertial sensing: Minimizing the error from the process of double integration of accelerations“, in *IECON 2013-39th Annual Conference of the IEEE Industrial Electronics Society*, IEEE, IEEE, 2013-11, s. 4026–4031. DOI: 10.1109/iecon.2013.6699780.
32. H. Wang, S. Sen, A. Elgohary et al., „No need to war-drive: Unsupervised indoor localization“, in *Proceedings of the 10th international conference on Mobile systems, applications, and services*, ACM, 2012-06, s. 197–210. DOI: 10.1145/2307636.2307655.
33. D. Alvarez, R. C. González, A. López a J. C. Alvarez, „Comparison of step length estimators from wearable accelerometer devices“, in *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, IEEE, 2006-08, s. 5964–5967. DOI: 10.1109/iembs.2006.259593.
34. H. Weinberg, „Using the ADXL202 in pedometer and personal navigation applications“, *Analog Devices AN-602 application note*, roč. 2, č. 2, s. 1–6, 2002.
35. J. W. Kim, H. J. Jang, D.-H. Hwang a C. Park, „A step, stride and heading determination for the pedestrian navigation system“, *Journal of Global Positioning Systems*, roč. 3, č. 1-2, s. 273–279, 2004-12. DOI: 10.5081/jgps.3.1.273.
36. J. Scarlett, „Enhancing the performance of pedometers using a single accelerometer“, *Application Note, Analog Devices*, roč. 41, 2007.
37. P. Kaniewski a J. Kazubek, „Integrated System for Heading Determination“, *Acta Physica Polonica A*, roč. 116, č. 3, 2009-09. DOI: 10.12693/aphyspola.116.325.
38. P. Goyal, V. J. Ribeiro, H. Saran a A. Kumar, „Strap-down pedestrian dead-reckoning system“, in *2011 international conference on indoor positioning and indoor navigation*, IEEE, IEEE, 2011-09, s. 1–7. DOI: 10.1109/ipin.2011.6071935.
39. Y. Tawil. „Magnetometer Soft Iron and Hard Iron Calibration: Why and How“, Dostupné z: <https://atadiat.com/en/e-magnetometer-soft-iron-and-hard-iron-calibration-why-how/> (cit. 2023-04-18).

40. A. Sabatini, „Quaternion-Based Extended Kalman Filter for Determining Orientation by Inertial and Magnetic Sensing“, *IEEE Transactions on Biomedical Engineering*, roč. 53, č. 7, s. 1346–1356, 2006-07. DOI: 10.1109/tbme.2006.875664.
41. Magnetic-Declination.com. „Find the magnetic declination at your location“, Dostupné z: <https://www.magnetic-declination.com/> (cit. 2023-04-18).
42. National Centers for Environmental Information. „Magnetic Field Calculators, Magnetic Declination Estimated Value“, Dostupné z: <https://www.ngdc.noaa.gov/geomag/calculators/magcalc.shtml#declination> (cit. 2023-03-23).
43. R. E. Kalman, „A new approach to linear filtering and prediction problems“, 1960.
44. J. W. Betz, *Engineering Satellite-Based Navigation and Timing : Global Navigation Satellite Systems, Signals, and Receivers, Global Navigation Satellite Systems, Signals, and Receivers*. Wiley-Interscience, 2016, s. 672, ISBN: 9781118615973.
45. P. Aggarwal, *MEMS-based integrated navigation*. Artech House, 2010, s. 197, ISBN: 9781608070435.
46. M. S. Grewal a A. Andrews, *Kalman filtering theory and practice using MATLAB, theory and practice using MATLAB*. John Wiley & Sons Inc., 2015, s. 617, ISBN: 9781118851210.
47. E. Foxlin, „Inertial head-tracker sensor fusion by a complementary separate-bias Kalman filter“, in *Proceedings of the IEEE 1996 Virtual Reality Annual International Symposium*, IEEE, 1996. DOI: 10.1109/vrais.1996.490527.
48. G. Bishop, G. Welch et al., „An introduction to the kalman filter“, *Proc of SIGGRAPH, Course*, roč. 8, č. 27599-23175, s. 41, 2001.
49. R. Sadli. „Object Tracking: 2-D Object Tracking using Kalman Filter in Python“, Dostupné z: <https://machinelearning.space.com/2d-object-tracking-using-kalman-filter/> (cit. 2023-04-16).
50. A. Becker. „Kalman filter: Introduction to Kalman filter“, Dostupné z: <https://www.kalmanfilter.net/default.aspx> (cit. 2023-04-16).
51. J. Hartikainen, A. Solin a S. Särkkä, „Optimal filtering with Kalman filters and smoothers—a Manual for Matlab toolbox EKF/UKF“, 2011-09.
52. P. D. Groves, *Principles of GNSS, inertial, and multisensor integrated navigation systems*. Artech House, 2008, s. 518, ISBN: 9781580532556.
53. O. J. Woodman, „An introduction to inertial navigation“, University of Cambridge, Computer Laboratory, tech. zpr., 2007.
54. A. Bose, K. N. Bhat a T. Kurian, *Fundamentals of Navigation and Inertial Sensors*. Prentice Hall India Pvt., Limited, 2014, ISBN: 9788120348592.
55. „Android for Developers“, Dostupné z: <https://developer.android.com/> (cit. 2023-03-15).
56. „Accelerometer“, Dostupné z: <https://www.w3.org/TR/accelerometer/> (cit. 2023-03-27).
57. A. Noureldin, T. B. Karamat a J. Georgy, *Fundamentals of Inertial Navigation, Satellite-based Positioning and their Integration*. Springer Berlin Heidelberg, 2013. DOI: 10.1007/978-3-642-30466-8.



58. J. K. Lee a E. J. Park, „A Fast Quaternion-Based Orientation Optimizer via Virtual Rotation for Human Motion Tracking“, *IEEE Transactions on Biomedical Engineering*, roč. 56, č. 5, s. 1574–1582, 2009-05. DOI: 10.1109/tbme.2008.2001285.
59. A. M. Sabatini, „Kalman-Filter-Based Orientation Determination Using Inertial / Magnetic Sensors: Observability Analysis and Performance Evaluation“, *Sensors*, roč. 11, č. 10, s. 9182–9206, 2011-09. DOI: 10.3390/s111009182.
60. X. Yun a E. R. Bachmann, „Design, Implementation, and Experimental Results of a Quaternion-Based Kalman Filter for Human Body Motion Tracking“, *IEEE Transactions on Robotics*, roč. 22, č. 6, s. 1216–1227, 2006-12. DOI: 10.1109/tro.2006.886270.
61. M. Pettersson, „Extended Kalman Filter for Robust UAV Attitude Estimation“, dipl. pr., Linköping University, Automatic Control, 2015, s. 86.
62. M. Pedley, „Tilt sensing using a three-axis accelerometer“, *Freescale semiconductor application note*, roč. 1, s. 2012–2013, 2013.
63. B.-S. Cho, W.-s. Moon, W.-J. Seo a K.-R. Baek, „A dead reckoning localization system for mobile robots using inertial sensors and wheel revolution encoding“, *Journal of Mechanical Science and Technology*, roč. 25, č. 11, s. 2907–2917, 2011-11. DOI: 10.1007/s12206-011-0805-1.
64. J. Solà, *Quaternion kinematics for the error-state KF*, 2015. DOI: 10.48550/ARXIV.1711.02508.
65. S. O. H. Madgwick, A. J. L. Harrison a R. Vaidyanathan, „Estimation of IMU and MARG orientation using a gradient descent algorithm“, in *2011 IEEE International Conference on Rehabilitation Robotics*, IEEE, 2011-06. DOI: 10.1109/icorr.2011.5975346.
66. Z. Chu, C. Chen, Y. Liu, Y. Wang a X. Lin, „Magnetic orientation system based on magnetometer, accelerometer and gyroscope“, *CAAI Transactions on Intelligence Technology*, roč. 2, č. 4, s. 166–172, 2017-12. DOI: 10.1049/trit.2017.0024.
67. M. Garcia. „Attitude and Heading Reference Systems“, Dostupné z: <https://ahrs.readthedocs.io/en/latest/filters.html> (cit. 2023-04-04).
68. M. Garcia. „Attitude Estimators: Extended Kalman Filter“, Dostupné z: <https://ahrs.readthedocs.io/en/latest/filters/ekf.html> (cit. 2023-04-04).
69. ThePoorEngineer. „Attitude Determination with Quaternion Using Extended Kalman Filter“, Dostupné z: <https://thepoorengineer.com/en/ekf-impl/> (cit. 2023-04-04).
70. J. R. Wertz, *Spacecraft Attitude Determination and Control*. Springer, 1978, s. 876, ISBN: 9789027709592.
71. E. M. Foxlin, M. Harrington a Y. Altshuler, „Miniature six-DOF inertial system for tracking HMDs“, in *SPIE Proceedings*, R. J. Lewandowski, L. A. Haworth a H. J. Girolamo, ed., SPIE, 1998-08. DOI: 10.1117/12.317434.
72. S. Sharma a A. Hoover, „A Study on Linear Acceleration of the Wrist During Free-Living“, in *2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, IEEE, 2019-11. DOI: 10.1109/bibm47256.2019.8983383.

- 
73. V. Navratil, J. Krska a F. Vejrazka, „Concurrent Bidirectional TDoA Positioning in UWB Network With Free-Running Clocks“, *IEEE Transactions on Aerospace and Electronic Systems*, roč. 58, č. 5, s. 4434–4450, 2022-10. DOI: 10.1109/taes.2022.3161895.
  74. Seznam.cz. „Mapy.cz“, Dostupné z: <https://mapy.cz/zakladni?x=14.3938845&y=50.1022876&z=17> (cit. 2023-04-28).
  75. F. Evennou a F. Marx, „Advanced Integration of WiFi and Inertial Navigation Systems for Indoor Mobile Positioning“, *EURASIP Journal on Advances in Signal Processing*, roč. 2006, č. 1, 2006-04. DOI: 10.1155/asp/2006/86706.
  76. F. J. Romero, E. M. Diaz a D. B. Ahmed, „Smartphone-Based Localization for Passengers Commuting in Traffic Hubs“, *Sensors*, roč. 22, č. 19, s. 7199, 2022-09. DOI: 10.3390/s22197199.
  77. J. R. Kwapisz, G. M. Weiss a S. A. Moore, „Activity recognition using cell phone accelerometers“, *ACM SIGKDD Explorations Newsletter*, roč. 12, č. 2, s. 74–82, 2011-03. DOI: 10.1145/1964897.1964918.

## Příloha A

### Měření v halových laboratořích



Obrázek A.1: Fotografie z měření na chodbě v halových laboratořích



Obrázek A.2: Fotografie z měření na chodbě v halových laboratořích

# Příloha B

## Venkovní měření



Obrázek B.1: Venkovní trasa v Technické ulici z leteckého pohledu [74]



Obrázek B.2: Venkovní trasa kolem budovy FEL a FS, ČVUT z leteckého pohledu [74]