

Bakalářská práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra řídicí techniky

Odhadování sklonu vozovky multisenzorickou fúzí na palubě vozidla

Radek Chládek

Vedoucí: doc. Ing. Zdeněk Hurák, Ph.D.
Obor: Kybernetika a robotika
Květen 2023

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Chládek** Jméno: **Radek** Osobní číslo: **499241**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra řídicí techniky**
Studijní program: **Kybernetika a robotika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Odhadování sklonu vozovky multisenzorickou fúzí na palubě vozidla

Název bakalářské práce anglicky:

Road grade estimation by onboard multisensor fusion

Pokyny pro vypracování:

1. Proveďte důkladnou rešerši stavu poznání v oblasti určování sklonu vozovky (angl. road grade) pomocí měření prováděných na palubách vozidel. Zdokumentujte, jaká všechna měření různé publikované metody využívají, jaké jsou jejich dosažitelné přesnosti, výhody, nevýhody.
2. Po konzultaci s vedoucím a průmyslovými partnery vyberte jednu (a nebo případně i více pro účely srovnání) jednoduchou a v našich podmínkách prakticky realizovatelnou metodu/-y a implementujte v Simulinku (či po dohodě v jiném sw prostředí).
3. Funkčnost implementovaného řešení demonstруйте formou simulací, případně i s využitím dat zaznamenaných měření ze senzorů a digitální mapy.

Seznam doporučené literatury:

- [1] H. S. Bae, J. Ryu, a J. C. Gerdes, „Road Grade and Vehicle Parameter Estimation for Longitudinal Control Using GPS“, in Proceedings of the IEEE Conference on Intelligent Transportation Systems, Oakland, CA, 2001, s. 166–171.
- [2] H. Jansson, E. Kozica, P. Sahlholm, a K. H. Johansson, „Improved road grade estimation using sensor fusion“, in Proceedings of the 12th Reglermöte, Stockholm, Sweden, kvě. 2006. Viděno: 12. červenec 2022. [Online]. Dostupné z: http://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-84522
- [3] N. Kidambi, R. L. Harne, Y. Fujii, G. M. Pietron, a K. W. Wang, „Methods in Vehicle Mass and Road Grade Estimation“, SAE Int. J. Passeng. Cars - Mech. Syst., roč. 7, č. 3, s. 981–991, dub. 2014, doi: [10.4271/2014-01-0111](https://doi.org/10.4271/2014-01-0111).
- [4] P. Sahlholm a K. Henrik Johansson, „Road grade estimation for look-ahead vehicle control using multiple measurement runs“, Control Engineering Practice, roč. 18, č. 11, s. 1328–1341, lis. 2010, doi: [10.1016/j.conengprac.2009.09.007](https://doi.org/10.1016/j.conengprac.2009.09.007).
- [5] P. Sahlholm, H. Jansson, E. Kozica, a K. H. Johansson, „A Sensor and Data Fusion Algorithm for Road Grade Estimation“, IFAC Proceedings Volumes, roč. 40, č. 10, s. 55–62, led. 2007, doi: [10.3182/20070820-3-US-2918.00010](https://doi.org/10.3182/20070820-3-US-2918.00010).
- [6] V. Winstead a I. V. Kolmanovsky, „Estimation of road grade and vehicle mass via model predictive control“, in Proceedings of 2005 IEEE Conference on Control Applications, 2005. CCA 2005., srp. 2005, s. 1588–1593. doi: [10.1109/CCA.2005.1507359](https://doi.org/10.1109/CCA.2005.1507359).

Jméno a pracoviště vedoucí(ho) bakalářské práce:

doc. Ing. Zdeněk Hurák, Ph.D. katedra řídicí techniky FEL

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

Datum zadání bakalářské práce: **17.02.2023**

Termín odevzdání bakalářské práce: **26.05.2023**

Platnost zadání bakalářské práce: **22.09.2024**

doc. Ing. Zdeněk Hurák, Ph.D.
podpis vedoucí(ho) práce

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

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

III. PŘEVZETÍ ZADÁNÍ

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

Datum převzetí zadání

Podpis studenta

Poděkování

Chtěl bych poděkovat své rodině a blízkým za podporu nejen během psaní bakalářské práce, ale během celého studia. Také bych chtěl poděkovat panu doc. Ing. Zdeňku Hurákovi, Ph.D. za cenné připomínky. V neposlední řadě chci poděkovat Ing. Loiovi Do za ochotu odpovědět na jakýkoliv mnou podaný dotaz.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškerou použitou literaturu v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze, 26. května 2023

Abstrakt

Tato bakalářská práce se zaměřuje na odhad sklonu vozovky na základě multisenzorické fúze na palubě kolejového vozidla. Znalost sklonu vozovky se ukazuje být kritickou informací pro vývoj antikolizních systémů, a to zejména pro odhad brzdné dráhy. Dále se tato znalost může využít při plánování energeticky optimálních rychlostních profilů. Práce shrnuje vybrané související texty (články, knihy). Je zde popsán a navržen matematický model podélného pohybu kolejového vozidla. Tento model je v práci využit pro vygenerování syntetických průběhů relevantních veličin. Dále jsou popsány a implementovány tři konkrétní metody, které tyto průběhy využívají pro odhad sklonu vozovky. Jmenovitě Luenbergerův pozorovatel, rozšířený Kalmanův filtr (EKF) a EKF s průměrováním z více průjezdů stejné trasy. Metody jsou naimplementovány v prostředí Matlab a Simulink a mezi sebou porovnány.

Klíčová slova: sklon vozovky, kolejové vozidlo, rozšířený Kalmanův filtr, Luenbergerův pozorovatel

Vedoucí: doc. Ing. Zdeněk Hurák, Ph.D.

Abstract

This bachelor thesis focuses on road grade estimation by multisensor fusion onboard a railway vehicle. The knowledge of road grade proves to be critical information for the development of collision avoidance systems, namely for estimation of braking distance. Furthermore, this knowledge can be used for designing energy-optimal speed profiles. The thesis summarizes methods used today (described in articles or books). A mathematical model of the longitudinal motion of a railway vehicle is described and designed here. The model is then used for generating synthetic measurements of relevant variables. Additionally, three specific methods, that are using the above mentioned variables, are described and implemented in the thesis. Namely the Luenberger observer, the extended Kalman Filter (EKF), and the EKF with averaging from multiple runs over the same route. All of the methods mentioned above are implemented in the Matlab and Simulink environments and compared against each other.

Keywords: road grade, railway vehicle, extended Kalman filter, Luenberger observer

Title translation: Road Grade Estimation By Onboard Multisensor Fusion

Obsah

1 Úvod	1
1.1 Cíl	1
1.2 Motivace	1
1.3 Osnova	2
2 Související práce v oblasti odhadu sklonu vozovky	3
2.1 S GNSS	3
2.2 S barometrem a GNSS	3
2.3 S akcelerometrem a odhadem rychlosti z odometrie	4
2.4 S GNSS a více měření ze stejné trasy	4
2.5 S výškovými údaji z map	5
2.6 Shrnutí nejvýznamějších metod	5
3 Model podélné dynamiky kolejového vozidla	7
3.1 Matematický model kolejového vozidla	7
3.2 Profily dráhy	8
3.3 Model v prostředí <i>Simulink</i>	10
3.4 Identifikace parametrů modelu	10
3.5 Simulační ověření	13
3.6 Přidání nejistot měření	14
4 Použité metody na odhad sklonu	15
4.1 Luenbergerův pozorovatel	15
4.1.1 Linearizace modelu	15
4.1.2 Návrh pozorovatele	16
4.1.3 Výsledky	18
4.2 Diskrétní rozšířený (nelineární) Kalmanův filtr	19
4.2.1 Změna nezávislé jednotky	19
4.2.2 Návrh EKF	20
4.2.3 Výsledky	21
4.3 EKF s průměrováním více dat z jedné trasy	22
4.3.1 Implementace	22
4.3.2 Výsledky	22
5 Závěr	25
5.1 Shrnutí	25
5.2 Budoucí vývoj	26
Bibliografie	29

Obrázky

2.1 Komplementární filtr pro odhad sklonu vozovky	4
2.2 Příklad vizualizace výškových dat z mapy Prahy	5
3.1 Podélné síly působící na kolejové vozidlo	7
3.2 Výškové a úhlové profily pro simulaci dat	9
3.3 Výsledné simulinkové schéma pro podélný pohyb kolejového vozidla .	10
3.4 Simulinkové schéma mechanického systému kolejového vozidla	10
3.5 Experiment prováděný v tramvajové lince 7	11
3.6 Porovnání simulovaného modelu a reálného vozidla	13
3.7 Použitá náhodná procházka	14
4.1 Struktura Luenbergerova pozorovatele	16
4.2 Požadovaná referenční rychlost simulující reálný provoz	18
4.3 Luenbergerův pozorovatel: porovnání odhadu sklonu s reálným sklonem při měření bez šumu	19
4.4 Luenbergerův pozorovatel: porovnání odhadu sklonu s reálným sklonem při měření se šumem	19
4.5 Porovnání odhadu EKF s reálnou odezvou systému s vstupem se šumem	21
4.6 Struktura EKF s průměrováním více dat z jedné trasy	22
4.7 Porovnání odhadu EKF průměrování 1. a 2. profil	23
4.8 RMSE hodnoty závislé na počtu opakování EKF s průměrováním ..	23
5.1 Porovnání všech implementovaných metod	26

Tabulky

2.1 Porovnání studovaných metod v tabulce	6
3.1 Naměřená data z elektrického vlaku 16EV	11
3.2 Parametry pro navržený model .	12
5.1 Porovnání dosažených RMSE hodnot pro implementované metody	26

Kapitola 1

Úvod

1.1 Cíl

Cílem této bakalářské práce je najít a implementovat vhodnou metodu pro odhad sklonu vozovky s využitím palubních měření. Tohoto dosáhnou vhodnou volbou algoritmu pro fúzi dat z dostupných senzorů. Jelikož je práce vypracovávána ve spolupráci se Škoda Digital, tak se bude jednat primárně o tratě a senzory tramvajových vozidel či vlaků (dále označováno jako kolejová vozidla).

1.2 Motivace

Bakalářská práce má dvě hlavní motivace. Primárně se jedná o vývoj anti-kolizních systémů pro tramvaje, kde pro odhad vzdálenosti brzdné dráhy je kritická znalost sklonu tratě. Při modelování tramvaje s hmotností 17000 kg a počáteční rychlostí 15 m/s se ukazuje, že rozdíl brzdné dráhy na rovině se od jízdy z kopce se sklonem 2° liší až o 20 m [1].

Další motivace odhadu sklonu tratě je plánování rychlostních profilů, které by potenciálně vedlo ke snížení spotřeby kolejových vozidel. Jelikož tramvaje či vlaky jezdí stále dokola ty samé cesty, nabízí se ze znalostí sklonů a aktuální dopravy tyto jízdy zoptimalizovat. Touto prací se aktuálně (akademický rok 2022/2023) zabývá Vít Fanta ve své diplomové práci.

Celá práce je součástí velkého projektu, na kterém se podíleli spolužáci ze studijního programu Kybernetika a robotika. Pro odhad sklonu je potřebná znalost aktuální polohy vozidla, na čemž pracuje ve své bakalářské práci Jakub Kašpar. Potřebnou hardwarovou a softwarovou platformu pro měření a následnou fúzi vytváří Matěj Kříž ve své bakalářské práci. Odhad sklonu vozovky se dále může využít v kombinaci s odhadem decelerace kolejového vozidla, což ve své bakalářské práci zpracovává Matouš Vondrášek. Pokud není uvedeno jinak, veškerá odvedená práce v následujícím textu je mým dílem.

■ 1.3 Osnova

Zbytek této práce je organizován následovně. V sekci 2 jsou shrnuty související práce, nastínění jejich výhod/nevýhod a finálně jsou zaneseny v přehledné tabulce. Z těchto metod následně vyberu vhodnou metodu pro můj případ. Model systému pro podélný pohyb kolejového vozidla, který je využit na vygenerování potřebných dat a následně i pro ověření metody odhadující sklon vozovky je k nalezení v sekci 3. V sekci 4 jsou popsány mnou využité a následně naimplementované metody pro odhad sklonu. Konkrétně se jedná o metodu Luenbergerův pozorovatel popsanou v podsekcí 4.1, rozšířený Kalmanův filtr v podsekcí 4.2 a rozšířený Kalmanův filtr s průměrováním více dat z jedné trasy 4.3. Všechny metody jsou srovnány na konci práce v sekci 5.

Kapitola 2

Související práce v oblasti odhadu sklonu vozovky

Na téma odhadu sklonu vozovky a případně s tím spojený odhad dalších parametrů vozidla bylo napsáno mnoho vědeckých článků. V následující kapitole uvedu alespoň některé z nich, a to podle mého subjektivního výběru. Po popsání souvisejících prací provedu jejich následné zhodnocení, abych zjistil, zda jsou vhodné pro dosažení cíle mé bakalářské práce, kterým je odhad sklonu vozovky.

2.1 S GNSS

Jako první zmíním způsob odhadu sklonu pomocí GNSS přijímače a změřeného poměru vertikální a horizontální rychlosti zmíněný v článku [2]. Jsou zde uvedeny dva možné způsoby implementace, kde první je pomocí jedné antény přichycené na střechu vozidla a druhý pomocí dvou antén na střeše vozidla, vzdálené od sebe fixní délkou. První způsob se zdá být obecněji výhodnější. Jedna anténa může být umístěna kamkoliv na střechu vozidla, oproti dvěma anténám, kde existují restriktce. Zadruhé, jedna anténa je robustnější vůči problémům se ztracením signálu a příchodů signálu z více cest, což je způsobeno odrazem a ohybem. Zatřetí, je nutno pořídit pouze jednu anténu, což je levnější možnost. Nakonec, výpočet sklonu z jedné antény zmenší odchylku způsobenou instalací.

Mezi nevýhody této metody patří špatná funkce v oblastech s vysokými budovami, stromy, tunely a obecně velkými objekty. Jelikož průmyslový partner požaduje správnou funkci metody i pro tramvaje, které jezdí městskou zástavbou, tak je toto omezení pro náš případ kritické, a proto bych tuto metodu nedoporučil.

2.2 S barometrem a GNSS

Metoda zmíněna v [3] pro odhad sklonu využívá fúze barometru, GNSS rychlosti, GNSS nadmořské výšky, rychlosti vozidla a točivého momentu motoru. Jelikož se jedná o fúzi již více senzorů, metoda je robustnější vůči

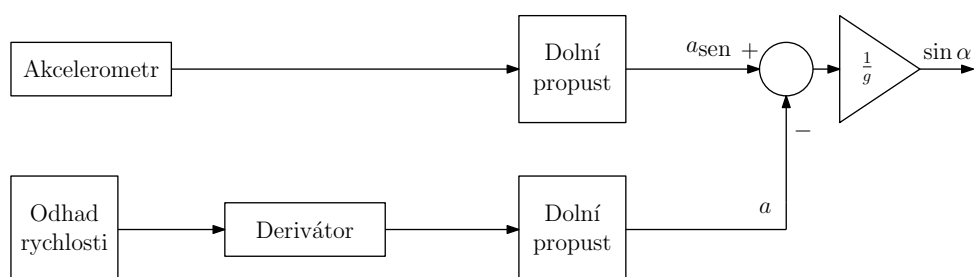
výpadkům měření z kteréhokoliv ze senzorů. Nicméně metoda se stále spoléhá na měření z GNSS, které se ukazuje ve městech jako problémové.

2.3 S akcelerometrem a odhadem rychlosti z odometrie

V článku [4] byly k odhadu sklonu využity výstupy z akcelerometru a odhadu rychlosti z odometrie (dále metoda označována jako [4]a). Následně variací komplementárního filtru, který je znázorněný na obr. 2.1, byly tyto hodnoty sfúzovány. Z naměřených hodnot se následně spočte sklon pomocí vzorce

$$\begin{aligned} a_{\text{sen}} &= a + g \sin \alpha, \\ \alpha &\approx \sin \alpha = \frac{a_{\text{sen}} - a}{g}, \end{aligned} \quad (2.1)$$

kde α je sklon vozovky (tento úhel je malý, a proto byl použit předpoklad, že $\sin(\alpha) \approx \alpha$), a_{sen} je zrychlení naměřené z akcelerometru, a je podélné zrychlení vozidla a g tíhové zrychlení.



Obrázek 2.1: Komplementární filtr pro odhad sklonu vozovky

V tomto článku byl zanedbán odpor jízdy (odpor vzduchu + valivý odpor). Stejný princip výpočtu sklonu vozovky byl použit i v [5], kde byla pouze odlišně odhadována rychlost vozidla. Mezi výhody by mohla patřit jednoduchá implementace metody. Na druhou stranu, metoda využívá veličiny, které se u kolejových vozidel většinou odhadují ze stejného senzoru, a proto by jejich fúze nedávala smysl.

2.4 S GNSS a více měřením ze stejné trasy

V článku [6] je popsána metoda, která využívá více naměřených hodnot ze stejné dráhy, kde je výsledná mapa aktualizována pomocí *distributed data fusion method*. Metoda váhuje data pomocí proměnlivých matic chybových kovariancí v algoritmu rozšířeného Kalmanova filtru. Způsob aktualizace mapy získané novými měřeními je detailně popsán v [7].


Mezi výhody patří snížení chyb z měření vlivem průměrování více dat ze stejné trasy. Samozřejmě nevýhodou je, že tato metoda předpokládá projetí jedné cesty vícekrát.

2.5 S výškovými údaji z map

Tato metoda se spoléhá pouze na GNSS pro měření pozice, aniž by vyžadovala použití dalších senzorů. Pouze se využívá výškový profil map vyfocený z družic s různým vzorkováním (v Praze je údaj uváděn každý 1 m [8]). Z výškového profilu se pomocí numerické derivace vytvoří úhlový profil.

Výhoda metody by spočívala v možnosti celého zpracování profilů tratí bez nutnosti jakéhokoliv měření ve vozidle. Nevýhodou této metody je nicméně fakt, že je nutné mít pro danou oblast výškové údaje ve vysoké kvalitě. Jak bylo zmíněno, úhlový profil se z výškového profilu získá numerickou derivací, čímž ale pro nepřesná data mohou vznikat signifikantní chyby.

Na obr. 2.2 je vizuálně znázorněn segment výškové mapy Prahy. Pro vygenerování mapy v prostředí Matlab jsem použil kód od spolužáka Matěje Kříže.



Obrázek 2.2: Příklad vizualizace výškových dat z mapy Prahy

2.6 Shrnutí nejvýznamějších metod

Hodně metod se spoléhá na GNSS přijímače, které musí být kvalitní, což je následně spojeno s velkou cenou, a i kvalitní přijímače mají problémy ve městě s velkými objekty. Proto se ukazuje velice výhodné zvolit cestu fúze dat měřených z více senzorů.

Mnoho článků mělo velice podobné řešení, proto jsem se rozhodl popsat pouze ta nejpodstatnější. Souhrn všech článků lze vidět v následující ta-

bulce 2.1, kde jsou srovnány esenciální senzory a nutné veličiny ze všech článků.

S ohledem na výše uvedené výhody a nevýhody jednotlivých metod a po zhodnocení dostupných senzorů na palubě vozidla jsem se zaměřil na dvě publikace. První je článek [6] (sekce 2.4) a to kvůli využívání více měření ze stejné trasy, přehlednosti a v neposlední řadě kvůli kladné reputaci autora. Další mnou zvolenou publikací je kniha [5]. Jelikož se jedná o knihu, tak je zde vše pohodlně čitelné.

Senzory:	Akcelerometr	GNSS	Točivý moment motoru	Barometr	Informace o brzdění, přidání rychlosti	Více dat ze stejné trasy	Snímač rychlosti kol
Metody							
[2]	✗	✓	✗	✗	✗	✗	✗
[3]	✗	✓	✓	✓	✓	✗	✗
[6]	✗	✓	✓	✗	✓	✓	✓
[9]	✗	✓	✓	✗	✓	✓	✓
[4]a	✓	✗	✗	✗	✗	✗	✓
[4]b	✗	✗	✓	✗	✓	✗	✓
[5]a	✓	✗	✗	✗	✗	✗	✓
[5]b	✗	✗	✓	✗	✗	✗	✓

Tabulka 2.1: Porovnání studovaných metod v tabulce


Kapitola 3

Model podélné dynamiky kolejového vozidla

Největší problematika odhadu sklonu vozovky je dle mého názoru nedostatek reálných dat, podle kterých by se funkčnost metod následně ověřovala. Proto jsem se rozhodl vytvořit model kolejového vozidla, kterému by byl libovolně uživatelsky zvolený profil zadán. Model by následně data potřebná pro fúzi vygeneroval. Dále bude využit i pro stavový popis, který budou v následující kapitole využívat algoritmy stavových pozorovatelů.

V kapitole nejdříve seznámím čtenáře s fyzikálními vzorci, podle kterých následně vytvořím model v prostředí Simulink. Na konci kapitoly porovnám data vygenerovaná vytvořeným modelem s daty reálného kolejového vozidla.

3.1 Matematický model kolejového vozidla



Obrázek 3.1: Podélné síly působící na kolejové vozidlo

Celý systém můžeme popsat rovnicí, kterou jsem vypočítal s drobnými variacemi ve člancích: [3, 5, 6, 9, 10]. Rovnici jsem zvolil, protože dostatečně popisuje podélnou dynamiku vozidla a také kvůli častým výskytům ve vědeckých člancích. Primárně se budu řídit variací rovnice popsané v [6].

Síly působící na kolejové vozidlo lze vidět na obr. 3.1. Tyto síly jsou popsány rovnicí

$$m\dot{v} = F_{\text{motoru}} - F_{\text{brzdy}} - F_{\text{vzduch}} - F_{\text{odpor}} - F_{\text{naklon}}, \quad (3.1)$$

kde F_{brzdy} je síla velice složitá na výpočet, protože kolejové vozidlo má více vagonů, ve kterých se mohou nacházet odlišné brzdy. V jakém jsou

brzdy stavu se obecně také neví. Tuto sílu také ovlivňuje aktuální teplota spolu s počasím. Z výše uvedených důvodů je síla F_{brzdy} jako taková obecně neznámá. Dále se ukazuje, že v běžném provozním režimu kolejové vozidlo brzdí motorem a využití brzd je uplatněno pouze při nouzovém brždění či těsně před zastavením, kdy se brzdí mechanicky. Pro odhad sklonu jsou tyto režimy brždění nepodstatné a primárně mne zajímá případ klidné jízdy kolejového vozidla, kdy se zrychluje a zpomaluje pomocí motoru. Proto z modelu sílu F_{brzdy} vynechám a její vliv promítnu jako zápornou hodnotu síly F_{motoru} .

Dále síla způsobená náklonem vozovky je

$$F_{\text{naklon}} = mg \sin(\alpha), \quad (3.2)$$

kde α je úhel sklonu vozovky, m je hmotnost vozidla a g je tíhové zrychlení.

Síla motoru se spočte jako

$$F_{\text{motoru}} = \frac{i_t i_f \eta_t \eta_f}{r_w} M, \quad (3.3)$$

kde r_w je poloměr kola tramvaje a i_t , i_f , η_t a η_f jsou konstanty pro převod točivého momentu motoru M na sílu. Jelikož z dodaných dat jsme byli schopni naměřit přímo sílu motoru F_{motoru} , tyto konstanty dále nebudu určovat.

Odpor vzduchu můžeme vyjádřit jako

$$F_{\text{vzduch}} = \frac{1}{2} c_w A_a \rho_a v^2, \quad (3.4)$$

kde c_w je součinitel odporu vzduchu, A_a je obsah přední strany vozidla a ρ_a je hustota vzduchu.

Poslední síla, která působí proti pohybu vozidla, je síla valivého odporu

$$F_{\text{odpor}} = mg c_r \cos(\alpha) \approx mg c_r, \quad (3.5)$$

kde c_r je součinitel valivého odporu. Pro úhly sklonu, které se nachází na silnicích, je vliv $\cos(\alpha)$ podstatně nižší než další odporové vlivy. Úhel α ovlivňuje následující model o mnohem více skrz F_{naklon} . Proto je ve článku [6] vliv $\cos(\alpha)$ zanedbán a rovnice je zjednodušena. Z tohoto předpokladu také vyjdu.

3.2 Profily dráhy


Pro simulaci dat je nutné přidat do simulace výškové a následně úhlové profily dráhy, na kterém namodelované vozidlo pojedí.

Rozhodl jsem se použít dva výškové profily, jeden, na kterém naladím parametry metod a druhý na ověření metod. První výškový profil je z trati pražské tramvajové linky číslo 7 ze stanice Depo Hostivař do stanice Radlická (dále označován jako první profil). Výškový profil byl vygenerován pomocí dat získaných z *OpenStreetMap*¹. Profil jsem získal od spolužáka Jakuba Kašpara.


¹OpenStreetMap.[cit.2023-05-21].Dostupné z: <https://www.openstreetmap.org/>

Druhý výškový profil byl také vygenerován pomocí *OpenStreetMap*¹ a je z trati pražské tramvajové linky číslo 20 ze zastávky Sídliště Barrandov do zastávky Divoká Šárka (dále označován jako druhý profil). Profil jsem použil z diplomové práce Petra Hrycha [11].


Vygenerované výškové profily a jejich numerickou derivaci představující sklony lze vidět na obr. 3.2.




(a) : Vyfiltrovaný výškový profil tramvaje číslo 7



(b) : Vyfiltrovaný výškový profil tramvaje číslo 20



(c) : Úhlový profil odpovídající výškovému profilu linky číslo 7

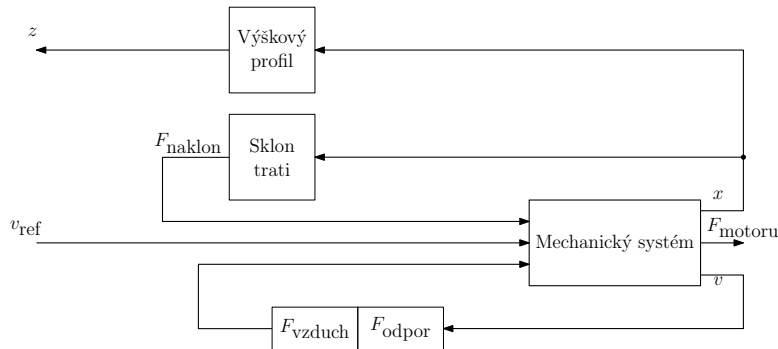


(d) : Úhlový profil odpovídající výškovému profilu linky číslo 20

Obrázek 3.2: Výškové a úhlové profily pro simulaci dat

3.3 Model v prostředí Simulink


Všechny potřebné predispozice pro tvorbu modelu již mám definované, proto se v této kapitole zaměřím na implementaci modelu v prostředí Simulink. Výsledné simulinkové schéma bude mít podobu vyobrazenou na obr. 3.3.



Obrázek 3.3: Výsledné simulinkové schéma pro podélný pohyb kolejového vozidla

Blok mechanického pohybu kolejového vozidla (na obr. 3.3 pod názvem *Mechanický systém*) lze vidět implementovaný na obr. 3.4. Blok obsahuje dva integrátory, protože se jedná o systém 2. řádu, a jako regulovaná veličina je zde síla motoru, která se řídí podle referenční rychlosti v_{ref} . Tato síla bude dále saturovaná podle možností používaného motoru. Regulace síly motoru F_{motoru} je implementovaná zpětnou vazbou s PID regulátorem, který představuje řidiče.

Odporové síly byly implementovány podle rovnice (3.1). Pro sílu odporu F_{odpor} bylo potřeba nastavit znaménko c_r vždy do protipohybu reálného směru jízdy, které je čteno z aktuální rychlosti pomocí bloku *Sign*.



Obrázek 3.4: Simulinkové schéma mechanického systému kolejového vozidla

Vkládání profilů tratě zde řeším pomocí bloku *1-D Lookup Table*, který v závislosti na ujeté vzdálenosti x vrací na výstup předem definovanou výšku a úhel sklonu tratě (ze sekce 3.2 Profily dráhy).

3.4 Identifikace parametrů modelu

V následující kapitole nalezneme potřebné parametry a poté je ověříme s naměřenými daty pro získání realistického modelu podélného pohybu kolejového

vozidla.

Ve spolupráci s průmyslovým partnerem jsme s kolegy z Katedry řídicí techniky Fakulty elektrotechnické ČVUT prováděli experimentální jízdy s tramvají linky číslo 7. Jízda probíhala v Praze ze zastávky Ústřední dílny DP do zastávky Radlická. Bohužel jsme kvůli technickým problémům nebyli schopni nasbírat potřebné hodnoty pro identifikaci parametrů. Konkrétně jsme nebyli schopni zaznamenat, pro práci esenciální, sílu F_{motoru} . Na obr. 3.5 lze vidět konkrétní pracoviště z experimentu a uchycené IMU a GNSS jednotky. S video záznamem pomocí kamery, pro případnou vizuální kontrolu při ukládání dat.



Obrázek 3.5: Experiment prováděný v tramvajové lince 7

Příčinou technických problémů a nemožnosti další replikace experimentu mi byla poskytnuta data z jízdy elektrického vlaku 16Ev. Pro identifikaci mého systému jsem použil data, která jsou znázorněna v tabulce 3.1.

název	Měřené veličiny	Jednotky
odo_acceler.csv	zrychlení	m s^{-2}
odo_speed.csv	reálná rychlost vlaku	m s^{-1}
odo_speedrq.csv	referenční rychlost	m s^{-1}
reg_forcesp.csv	síla motoru	N
reg_slopefor.csv	podélná síla vlaku, způsobená náklonem trati	N

Tabulka 3.1: Naměřená data z elektrického vlaku 16EV

Dodaná data nebyla mnou nijak filtrovaná či měněná a jsou k naleznutí na gitlab stránce tohoto projektu, konkrétně ve složce data ¹.

Z naměřených dat jsem vyzoroval extrémy síly motoru, které byly následně použity na saturaci F_{motoru} v mém modelu. Umístění bloku saturace jde vidět na obr. 3.4. Síla motoru je saturována v konkrétních hodnotách od -1.2966×10^5 do 1.4314×10^5 .

Dostačující hodnoty PID regulátoru jsem odhadnul iteračně jako následující $[k_p, k_i, k_d] = [6 \times 10^6, 0, 10]$.

Po spuštění a porovnávání mnoha simulací s naměřenými daty jsem dospěl k následujícím hodnotám pro parametry, které jsou zapsány v tabulce 3.2.

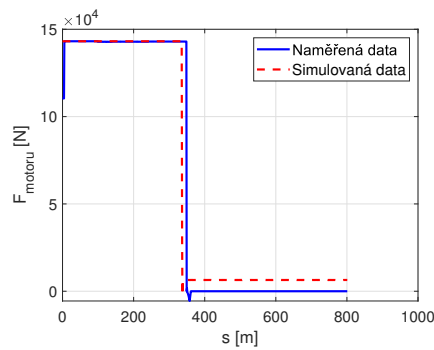
název	měřené veličiny	jednotky
g	9.81	m s^{-2}
m	150000	kg
c_w	1.05	-
A_a	14.484	m^2
c_r	0.00005	-
ρ_a	1.201	kg/m^{-3}

Tabulka 3.2: Parametry pro navržený model

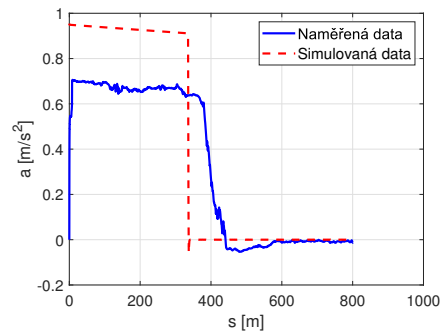
¹<https://gitlab.fel.cvut.cz/aa4cc/ccam/road-grade-estimation/-/tree/main/data>

3.5 Simulační ověření

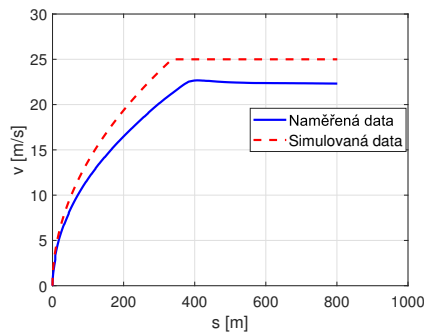
Pro následující simulační ověření bude referenční hodnota konstantních $v_{\text{ref}} = 25 \text{ m/s}$, protože taková byla referenční rychlost v poskytnutých datech. Reálný profil trati, po kterém jel elektrický vlak 16Ev, byl konstantní a blížil se nule. Proto v modelu aproximuji tento profil sklonu nulovou konstantou.




(a) : Porovnání nasimulované a reálné používané síle motoru



(b) : Porovnání simulovaného a reálného zrychlení vozidla



(c) : Porovnání nasimulované a reálné rychlosti vozidla



(d) : Odporové síly působící na model kolejového vozidla

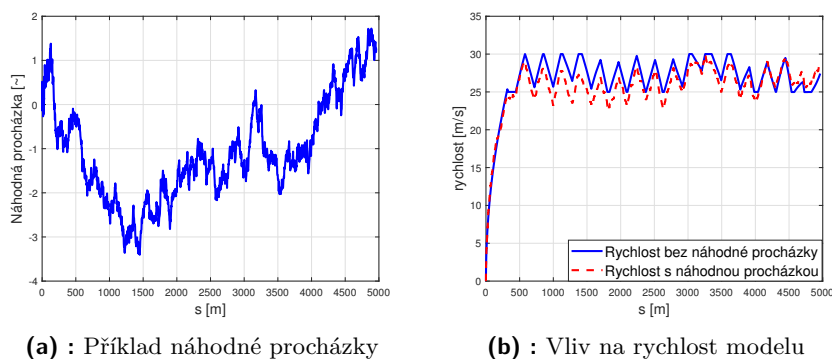
Obrázek 3.6: Porovnání simulovaného modelu a reálného vozidla

Cílem kapitoly nebylo přesně naladit model na reálná data, jelikož v praxi nejsou všechny vozy stejné a nalezené konstanty by se všude lišily. Proto jsem se snažil model naladit, aby alespoň řádově odpovídal realitě. Na obr. 3.6a, 3.6b a 3.6c můžeme vidět, že data simulovaná a naměřená se řádově shodují a pro vygenerování dat pro následnou filtraci se jedná o dostatečnou shodu. Dále na obr. 3.6d lze vidět součet odporových sil $F_{\text{odporove}} = F_{\text{odpor}} + F_{\text{vzduch}}$, působících proti směru pohybu.

3.6 Přidání nejistot měření

Pro otestování robustnosti odhadovacích metod, které budou popsány v kapitole 4, je nutné přidat k vygenerovaným datům určitou nejistotu měření. Proto jsem se rozhodl přidat k simulovaným datům rušení. K měření rychlosti jsem přidal rušení *Náhodná procházka* (z angl. *Random walk*). Jedná se o náhodný proces, kde každá následující náhodná hodnota závisí na předešlé hodnotě. V praxi je *Náhodná procházka* implementována pomocí integrace bílého šumu. Na obr. 3.7 můžeme vidět příklad náhodné procházky a jejího vlivu na rychlost.

K měření nadmořské výšky z jako nejistotu měření použiji bílý šum, který jsem v Simulinku implementoval pomocí bloku *Band-Limited White Noise* se spektrální hustotou výkonu (parametr *noise power*) 0.1. Simulinkový blok je použit pro metodu ze sekce 4.1. Pro metody ze sekcí 4.2 a 4.3 je použita funkce *randn* pro vygenerování pseudonáhodných čísel.



Obrázek 3.7: Použitá náhodná procházka

Kapitola 4

Použité metody na odhad sklonu

Pro odhad sklonu vozovky jsem si vybral 3 metody. První je založená na Luenbergerovu pozorovateli, druhá na diskretním rozšířeném Kalmanovu filtru (EKF) a poslední využívá EKF s průměrováním dat z více projetí stejné trasy.

Luenbergerův pozorovatel je lehký na implementaci, ale dokáže pracovat pouze s lineárním modelem, což model popsany rovnicí 3.1 není. Proto je zapotřebí rovnici zlinearizovat, a to může vést k chybám. Pro správnou funkci této metody s daty, které obsahují nejistoty měření, je zapotřebí najít ideální místo pólů pozorovatele, což může být složité.

EKF oproti Luenbergerovu pozorovateli linearizuje model v každém iteračním kroku okolo aktuálního bodu. Proto předpokládám menší chyby způsobené linearizací. Dále nalezení potřebných matic, které určují nejistoty měření a parametrizují EKF, vidím jako snazší.

Jako poslední naimplementovanou metodu ukáži EKF s průměrováním dat z více projetí, což by mělo dále zpřesnit odhad sklonu vozovky díky snížení statistické nejistoty měření.

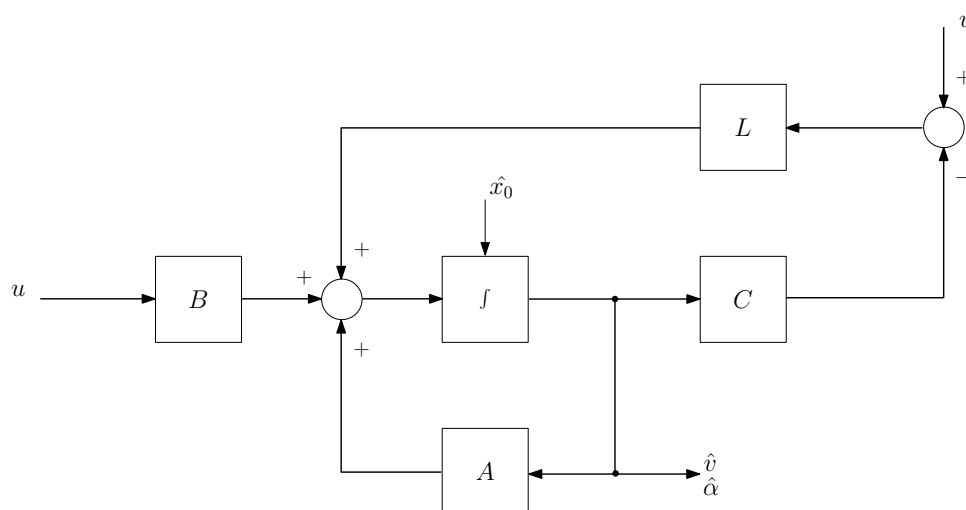
4.1 Luenbergerův pozorovatel

Jako první metodu jsem zvolil implementaci metody popsané v [5], která využívá pro odhad sklonu Luenbergerova pozorovatele. Pozorovatel bude implementován pomocí schématu zobrazeného na obr. 4.1. Měřený stav je rychlost vozidla v . Dále je využita síla motoru F_{motoru} .

4.1.1 Linearizace modelu

Pro implementaci stavového pozorovatele je potřeba model (3.1) zlinearizovat, proto jsem zavedl dva předpoklady:

- Jelikož koleje tramvají se nachází na silnicích s malými sklony budu předpokládat, že $\sin(\alpha) \approx \alpha$.
- Pro eliminaci mocniny v odporu vzduchu si vytvořím novou proměnnou a to sice F_v , kde $F_v = F_{\text{motoru}} - F_{\text{vzduch}} - F_{\text{odpor}}$. Celá tato výsledná síla bude použita jako vstup do modelu.



Obrázek 4.1: Struktura Luenbergerova pozorovatele

Výsledkem linearizace je zjednodušení formy rovnice (3.1) na tvar

$$m\dot{v} = F_v - mg\alpha . \quad (4.1)$$

Stavový vektor x bude obsahovat rychlost vozidla v a sklon tratě α . Vektor vstupu u bude obsahovat výslednou sílu F_v a 0. Druhý vstup je do modelu přidán, aby bylo možné přidat injekci z výstupu (termín vysvětlen v rovnici (4.6)) i do druhého odhadu stavu $\hat{\alpha}$.

$$x = \begin{bmatrix} v \\ \alpha \end{bmatrix}, \quad u = \begin{bmatrix} F_v \\ 0 \end{bmatrix} . \quad (4.2)$$

Výsledný lineární model ve tvaru

$$\begin{aligned} \dot{x} &= Ax + Bu , \\ y &= Cx , \end{aligned} \quad (4.3)$$

bude vyčíslen následovně

$$\begin{aligned} \begin{bmatrix} \dot{v} \\ \dot{\alpha} \end{bmatrix} &= \begin{bmatrix} 0 & -g \\ 0 & 0 \end{bmatrix} \begin{bmatrix} v \\ \alpha \end{bmatrix} + \begin{bmatrix} \frac{1}{m} & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} F_v \\ 0 \end{bmatrix} , \\ y &= \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} v \\ \alpha \end{bmatrix} . \end{aligned} \quad (4.4)$$

4.1.2 Návrh pozorovatele

Pro možnost návržení pozorovatele je zapotřebí, aby systém (4.4) byl pozorovatelný. Tento předpoklad zjistím pomocí matice pozorovatelnosti, která bude v našem případě

$$\mathcal{O} = \begin{bmatrix} C \\ C A \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -g \end{bmatrix} , \quad (4.5)$$

kde hodnost matice \mathcal{O} je 2. To pro systém 2. řádu včetně mého znamená, že je plně pozorovatelný a návrh pozorovatele je proto možný.

Luenbergerův pozorovatel se zapisuje jako

$$\begin{aligned}\dot{\hat{x}} &= A\hat{x} + Bu + \underbrace{L(y - \hat{y})}_{\text{injekce z výstupu}} , \\ \hat{y} &= C\hat{x} .\end{aligned}\tag{4.6}$$

K chybě pozorovatele se dostaneme následujícími úpravami rovnic (4.4) a (4.6)

$$\begin{aligned}e &= x - \hat{x} , \\ \dot{e} &= \dot{x} - \dot{\hat{x}} , \\ \dot{e} &= (Ax + Bu) - (A\hat{x} + Bu + L(y - \hat{y})) , \\ \dot{e} &= (A - LC)e .\end{aligned}\tag{4.7}$$

Vlastní čísla matice $(A - LC)$ nastavím pomocí matice L , která bude mít dvě hodnoty. Po transpozici dostaneme $(A^T - C^T L^T)$. Nyní lze využít duální úlohu k umístování pólů matice $(A - BK)$ pro kterou lze využít funkce *place* v Matlabu¹.

Pro umístění pólů se podívám na póly svého systému, které dostanu jako vlastní čísla matice A jako

$$\text{eig}(A) = \begin{bmatrix} 0 \\ 0 \end{bmatrix} ,\tag{4.8}$$


póly jsem umístil o 0.6 a 0.7 v záporném směru reálné osy. Výsledná matice

$$L = \begin{bmatrix} 1.3 \\ -0.0428 \end{bmatrix} .\tag{4.9}$$


¹Place: Pole placement design [online]. [cit. 2023-05-21].
Dostupné z: <https://www.mathworks.com/help/control/ref/place.html>

4.1.3 Výsledky


Referenční rychlost budu v jednotlivých metodách implementovat jako součet konstanty 25 m s^{-1} a obdélníkového signálu s amplitudou $A = 5 \text{ m s}^{-1}$ a periodou $T = 10 \text{ s}$. Na grafech 4.2 je ukázána referenční rychlost, reálná rychlost vozidla a nakonec rychlost zatížená nejistotou měření. Tento způsob je zaveden kvůli přiblížení se reálné jízdě vozidla, kdy se řidič (v mém případě PID regulátor) musí podřídit aktuální jízdě situaci a nikdy nebude požadovaná rychlost konstantních 25 m s^{-1} .




(a) : Požadovaná referenční rychlost pro 1. profil



(b) : Požadovaná referenční rychlost pro 2. profil



(c) : Rychlost modelu s/bez nejistoty měření pro 1. profil



(d) : Rychlost modelu s/bez nejistoty měření pro 2. profil


Obrázek 4.2: Požadovaná referenční rychlost simulující reálný provoz

Na obr. 4.3 lze vidět, že navržený pozorovatel při ideálním čtení rychlosti (tj. rychlost bez šumu) kopíruje profil tratě zadaný modelu s relativně malou odchylkou.


Dále na obr. 4.4 lze vidět případ, kdy k rychlosti vygenerované z modelu byla přičtena nejistota popsána v sekci 3.6. Když se podíváme na odhad sklonu, tak vidíme, že pozorovatel sleduje profil s poměrně znatelnou odchylkou.

Z výše uvedených poznatků vidíme, že tímto způsobem navržený Luenbergerův pozorovatel je vhodný pouze pro případy, kdy bychom měli bezchybné čtení ze senzorů bez šumových vlastností, což v reálném případě není prakticky možné.

Pro 1. profil dosáhl Luenbergův pozorovatel hodnoty $\text{RMSE} = 0.79$ a pro 2. profil $\text{RMSE} = 0.75$.




(a) : Odhad Luenbergerova pozorovatele 1. profil bez nejistoty měření rychlosti




(b) : Odhad Luenbergerova pozorovatele 2. profil bez nejistoty měření rychlosti

Obrázek 4.3: Luenbergerův pozorovatel: porovnání odhadu sklonu s reálným sklonem při měření bez šumu



(a) : Odhad Luenbergerova pozorovatele 1. profil s nejistotou měření rychlosti



(b) : Odhad Luenbergerova pozorovatele 2. profil s nejistotou měření rychlosti

Obrázek 4.4: Luenbergerův pozorovatel: porovnání odhadu sklonu s reálným sklonem při měření se šumem

4.2 Diskrétní rozšířený (nelineární) Kalmanův filtr

Metodu jsem implementoval ze vzoru v článku [6]. Měřené stavy jsou rychlost vozidla v a aktuální nadmořská výška z . Dále je z modelu využita informace o velikosti síly motoru F_{motoru} .

4.2.1 Změna nezávislé jednotky

S motivací využití více dat ze stejné trasy pro odhad sklonu je potřeba přestat uvádět úhly v závislosti na čase, protože řidič každou trasu ujede za odlišný čas. V důsledku čehož by se nám tvořily pro stejnou dráhu zcela odlišné profily. Proto potřebuji změnit nezávislou proměnnou z času t na pozici s .

Využijí rovnic z článku [12]

$$\begin{aligned}\frac{dt}{ds} &= \frac{1}{v}, \\ \frac{dv}{dt} &= \frac{dv}{ds} \frac{ds}{dt}, \\ \frac{dv}{ds} &= \frac{dt}{ds} \frac{dv}{dt} = \frac{1}{v} \frac{dv}{dt},\end{aligned}\tag{4.10}$$

kde $\frac{dv}{dt}$ použijí z rovnice (3.1). Výsledný tvar rychlosti vztahované k pozici vypadá jako

$$\frac{dv}{ds} = \frac{F_{\text{motoru}}}{mv} - \frac{c_w A_a \rho_a}{2m} v - \frac{g}{v} (c_r + \sin \alpha).\tag{4.11}$$

Kvůli přidané nelinearitě $\frac{1}{v}$ způsobené přeparametrizováním není možné využít zlinealizovaného modelu popsaného rovnicí (4.1). Proto ze vzoru v článku [6] využijí EKF.

4.2.2 Návrh EKF

V EKF je nelineární model linearizován v každém kroku okolo aktuálního stavu, což by mělo vyprodukovat přesnější výsledky. Se získanou maticí F_k je následně rekurzivně zacházeno jako ve standardním lineárním Kalmanovu filtru.

Rekurze se skládá ze dvou kroků: předpověď (rovnice (4.12)) a korekce (rovnice (4.13)). Předpověď nám předpovídá následující stav podle modelu a korekce následnou předpověď opraví podle naměřených dat [13].

Předpověď:

$$\begin{aligned}x_{k|k-1} &= f(x_{k-1|k-1}, u_k), \\ P_{k|k-1} &= F_k P_{k-1|k-1} F_k^T + F_k Q F_k^T, \\ y_k &= h(x_k).\end{aligned}\tag{4.12}$$

Korekce:

$$\begin{aligned}S_k &= H_k P_{k|k-1} H_k^T + H_k R H_k^T, \\ K_k &= P_{k|k-1} H_k^T S_k^{-1}, \\ x_{k|k} &= x_{k|k-1} + K_k (y_k - y_{k|k-1}), \\ P_{k|k} &= P_{k|k-1} - K_k S_k K_k^T, \\ y_k &= h(x_k).\end{aligned}\tag{4.13}$$

Dolní indexy korespondují se sousledností naměřených hodnot. k značí aktuální krok a $k - 1$ minulý krok. Matice K_k je Kalmanovo zesílení, Q a R jsou matice chybové kovariance, podle kterých volíme, jak moc věříme modelu oproti měřeným datům.

Pro získání potřebných matic na implementaci EKF je nutné model nejprve zdiskretizovat použitím kroku délky Δs . V implementaci kódu použijí tento

krok o konkrétní délce $\Delta s = 2.5\text{m}$. Diskretizovaný model 4.11 s přidáním dvěma stavy z_k a α_k je

$$\underbrace{\begin{bmatrix} v_k \\ z_k \\ \alpha_k \end{bmatrix}}_{x_k} = \underbrace{\begin{bmatrix} v_{k-1} \Delta s \frac{F_{\text{motoru}}}{mv} - \frac{c_w A_a \rho_a}{2m} v - \frac{g}{v} (c_r + \sin \alpha) \\ z_{k-1} \Delta s \sin \alpha \\ \alpha_{k-1} \end{bmatrix}}_{f(x_{k|k}, u_k)} + \underbrace{\begin{bmatrix} w_k^v \\ w_k^z \\ w_k^\alpha \end{bmatrix}}_{w_k}, \quad (4.14)$$

kde w_k je procesní šum, který zahrnuje poruchy ovlivňující dynamiku systému. Funkci $h(x_k)$ definuji jako

$$y_k = \underbrace{\begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}}_{h(x_k)} \begin{bmatrix} v_k \\ z_k \\ \alpha_k \end{bmatrix} + \underbrace{\begin{bmatrix} e_k^v \\ e_k^z \\ e_k^\alpha \end{bmatrix}}_{e_k}, \quad (4.15)$$

kde e_k je šum měření.


4.2.3 Výsledky

Přidání nejistot měření k rychlosti v a nadmořské výšce z provádím stejně jako v případě Luenbergerova pozorovatele (popáno v sekci 3.6).


Po odsimulovaných jízdách vozidla jsem našel chybové matice kovariancí jako

$$Q = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, R = \begin{bmatrix} 1500000 & 0 \\ 0 & 900000 \end{bmatrix}. \quad (4.16)$$

Na obr. 4.5 lze vidět funkci implementovaného EKF. Pro první profil dosáhl hodnoty RMSE = 0.010 a pro druhý RMSE = 0.0058.



(a) : Odhad EKF 1. profil s nejistotou měření rychlosti a nadmořské výšky



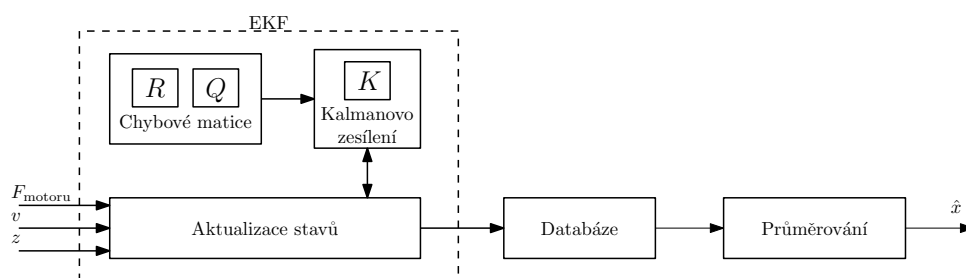
(b) : Odhad EKF 2. profil s nejistotou měření rychlosti a nadmořské výšky

Obrázek 4.5: Porovnání odhadu EKF s reálnou odezvou systému s vstupem se šumem

Na základě RMSE a porovnání grafů 4.4 a 4.5 vidíme, že si EKF vede znatelně lépe pro zašuměná data než Luenbergův pozorovatel.

4.3 EKF s průměrováním více dat z jedné trasy

Tato metoda je motivována reálnou situací, kdy kolejová vozidla jezdí po zadané trase vícekrát za den po celý rok. Proto by mělo být k dispozici velké množství měření z jedné trasy. Při využití těchto dat by se měla jak chyba procesu, tak chyba měření statisticky zmenšovat. Výsledný princip funkce metody je znázorněn na obr. 4.6.



Obrázek 4.6: Struktura EKF s průměrováním více dat z jedné trasy

4.3.1 Implementace

Oproti obyčejnému EKF zmenším hodnoty v maticích chybových kovariancí. S maticemi 4.16 nebral algoritmus měřená data dostatečně v potaz, protože jim nevěřil, čímž byl následně způsoben horší výsledek s průměrováním. Výsledný signál by se pomocí průměrování měl vyhladit dostatečně, proto si můžeme dovolit věřit měření více než v případě obyčejného EKF. Použité matice jsou


$$Q = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, R = \begin{bmatrix} 15000 & 0 \\ 0 & 9000 \end{bmatrix}. \quad (4.17)$$

4.3.2 Výsledky


Abych pro každou iteraci vygeneroval odlišný rychlostní profil, rozhodl jsem se referenční rychlost generovat oproti ostatním metodám s proměnnou amplitudou a periodou u obdélníkového signálu. Hodnoty jsem volil náhodně v rozmezích: Amplituda $\in \langle 0,10 \rangle$ a perioda $\in \langle 0,1,20 \rangle$. Jelikož měněním referenční rychlosti se všechny jízdy nemusí dostat do stejné vzdálenosti, najdu si minima ujetých vzdáleností a omezím jimi graf. Pro první profil jsem ujetou dráhu omezil na 3400 m. Druhý profil jsem omezil na ujetou dráhu 20000 m.

Na obr. 4.7 vidíme, že hodnoty RMSE se podle předpokladu zmenšují a v průměrovací iteraci $i = 300$ dosahují lepších hodnot, než v nejlépe naladěném EKF. Pro první profil dostáváme hodnotu $RMSE = 0.0040$ a pro druhý profil $RMSE = 0.0050$. Jedná se o nejlepší testovanou metodu.

Vývoj hodnot RMSE obou profilů v závislosti na počtu iterací lze vidět na obr. 4.8.



(a) : Odhad EKF s průměrováním z 300 iterací prvního profilu s nejistotou měření rychlosti a nadmořské výšky




(b) : Odhad EKF s průměrováním z 300 iterací druhého profilu s nejistotou měření rychlosti a nadmořské výšky

Obrázek 4.7: Porovnání odhadu EKF průměrování 1. a 2. profil

Vidíme, že hodnota RMSE se podle očekávání zlepšuje s každou iterací. Prvních 100 iterací je změna markantnější. Další iterace se již zdá, že RMSE hodnota se ustálila víceméně na konstantních hodnotách.

Mohlo by se zdát, že počet dostačujících iterací pro nejlepší funkci této metody bude obecně 100. Dle mého názoru se hodnota RMSE ustálila na konstantě pro iterace od 100. dále z důvodu nedostatečně se měnících dat (tj. málo se měnící referenční rychlosti). V případě jízdy reálného kolejového vozidla, pro ilustraci tramvaje, bude variabilita dat mnohem větší, a proto předpokládám znatelné posunutí počtu dostačujících iterací.



Obrázek 4.8: RMSE hodnoty závislé na počtu opakování EKF s průměrováním

Kapitola 5

Závěr

5.1 Shrnutí

V práci jsem nejdříve shrnul již vyvinuté práce v oblasti odhadu sklonu vozovky a následně srovnával jejich funkčnost a požadavky pro zvolení implementovaných metod.

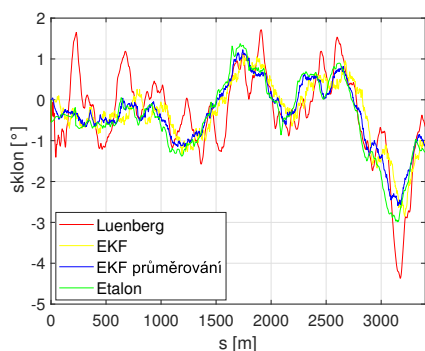
Dále jsem navrhnul model podélného pohybu kolejového vozidla. Model byl využit jak pro vygenerování dat, která jsem následně fúzoval, tak pro možnost zadání mnou libovolně zvolených profilů sklonu tratě, abych mohl metody následně porovnat a zjistit jejich funkčnost. V této sekci byla zapotřebí práce s reálnými daty z jízdy kolejového vozidla, která byla dodána od průmyslového partnera. Data byla využita pro identifikaci chybějících parametrů v modelu. Model byl v závěru srovnán s reálnými daty. U modelu jsem dosahoval řádové shody.

Rozhodl jsem se naimplementovat tři metody. První byla založená na Luenbergerově pozorovateli. U syntetických dat pro fúzi jsem se rozhodl přidat nejistotu měření, abych simuloval měření z reálných senzorů.

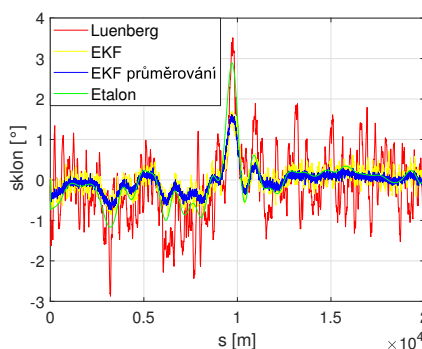
Druhá metoda, kterou jsem navrhl, byl EKF. Metoda pro oba profily fungovala lépe než Luenbergerův pozorovatel.

Na závěr jsem naimplementoval EKF s průměrováním více dat z jedné trasy. Metoda byla zvolená hlavně kvůli reálné situaci, kdy vozy hromadné dopravy jezdí stejné trasy stále dokola. Proto se metoda s využitím více měření nabízí. Metoda byla ze všech použitých nejlepší, a to pro oba profily. Ukázalo se, že po určité iteraci projetí se výstup metody již nezlepšoval a držel se na konstantní hodnotě. Tento fenomén předpokládám i v reálném případě, ale pořadové číslo této iterace bude dle mého názoru mnohem větší než v mém případě.

Všechny metody jsem pro přehlednost vykreslil do jednoho grafu 5.1. V grafu je také pravý profil tratě, který měly metody sledovat. V práci se povedlo splnit nastavené cíle.



(a) : Porovnání všech implementovaných metod na 1. profilu



(b) : Porovnání všech implementovaných metod na 2. profilu

Obrázek 5.1: Porovnání všech implementovaných metod

Pro úplnost jsem se rozhodl srovnat RMSE hodnoty pro metody popsané v jednotlivých sekcích. Toto porovnání můžeme vidět v tab. 5.1.

Metoda ze sekce	RMSE první profil	RMSE druhý profil
4.1	0.7900	0.7500
4.2	0.0100	0.0058
4.3	0.0040	0.0050

Tabulka 5.1: Porovnání dosažených RMSE hodnot pro implementované metody

5.2 Budoucí vývoj

Navazujícím cílem je zvolit vhodnou reprezentaci odhadnutých sklonů. Reprezentace může být implementována do podoby již existujících webových rozhraní jako *OpenStreet maps*¹, *OpenRail map*² nebo do vlastní vyhledávací tabulky. Tento cíl jsem neměl zadán, a proto jsem ho ani nedosahoval.

V metodě popsané v sekci 4.3 jsem se řídil podle článku [6]. V tomto článku byla místo průměrování použita metoda popsaná v knížce [7]. Metoda je složitější a vzhledem k dostupnému času pro vypracování bakalářské práce nebylo možno zkusit ji naimplementovat. V budoucím vývoji bych chtěl metodu implementovat a s již provedenými metodami porovnat.

Pro budoucí pokračování v oblasti vývoje odhadu sklonu vozovky je na místě ověření metod pomocí dat naměřených z reálných kolejových vozidel.

Z každé metody byla použita rychlost v a síla motoru F_{motoru} . Tyto veličiny by měly být dostupné přímo na palubní sběrnici kolejových vozidel. Dále u metody s EKF byla využita také nadmořská výška z . Pro měření této veličiny se nabízejí tři řešení. V první řadě lze tuto veličinu měřit pomocí GNSS. Avšak toto může být ve městě s vysokými budovami a obecně objekty problémové,

¹OpenStreetMap.[cit.2023-05-21].Dostupné z: <https://www.openstreetmap.org/>

²OpenRailwayMap.[cit.2023-05-21].Dostupné z: <https://www.openrailwaymap.org/>

protože GNSS má znatelné výpadky způsobené odrazy od velkých objektů. Dále jsem objevil v článku [3] použití nadmořské výšky korigované s využitím barometru. Barometr použitý v článku nebyl příliš přesný a s jeho pomocí byla prováděna pouze korekce dat. Pro použití barometru jako primárního zdroje informace o nadmořské výšce by bylo zapotřebí použít velice kvalitní senzor, který na trzích v České republice není příliš dostupný. V poslední řadě by šlo použít výškové údaje z map. Tyto údaje nejsou moc přesné, ale fúzí s ostatními veličinami by bylo možné je vylepšit. Pro tuto metodu bude potřeba přesně určovat aktuální pozici.



Bibliografie

- [1] Loi Do, Ivo Herman a Zdeněk Hurák. “Onboard Model-based Prediction of Tram Braking Distance”. en. In: *IFAC-PapersOnLine* 53.2 (2020), s. 15047–15052. ISSN: 24058963. DOI: 10.1016/j.ifacol.2020.12.2006.
- [2] Hong S Bae, Jihan Ryu a J Christian Gerdes. “Road Grade and Vehicle Parameter Estimation for Longitudinal Control Using GPS”. en. In: *IEEE Transactions on Intelligent Transportation Systems - TITS* (led. 2001).
- [3] Henrik Jansson et al. “Improved road grade estimation using sensor fusion”. In: *Proceedings of the 12th Reglermöte. Stockholm, Sweden* (led. 2006). URL: https://www.researchgate.net/publication/228901131_Improved_road_grade_estimation_using_sensor_fusion.
- [4] Hiroshi Ohnishi et al. “A study on road slope estimation for automatic transmission control”. en. In: *JSAE Review* 21.2 (dub. 2000), s. 235–240. ISSN: 03894304. DOI: 10.1016/S0389-4304(99)00097-1.
- [5] U. Kiencke a Lars Nielsen. *Automotive control systems: for engine, driveline, and vehicle*. en. 2nd ed. OCLC: ocm59615521. Berlin: Springer, 2005. ISBN: 978-3-540-23139-4.
- [6] Per Sahlholm a Karl Henrik Johansson. “Road grade estimation for look-ahead vehicle control using multiple measurement runs”. en. In: *Control Engineering Practice* 18.11 (lis. 2010), s. 1328–1341. ISSN: 09670661. DOI: 10.1016/j.conengprac.2009.09.007.
- [7] Fredrik Gustafsson. *Adaptive Filtering and Change Detection*. English. 1st edition. Chichester New York: Wiley, zář. 2000. ISBN: 978-0-471-49287-0.
- [8] *Digitální model povrchu - 1m*. Praha. URL: <https://www.geoportalpraha.cz/cs/data/otevrena-data/1164EC41-5008-4824-B15B-3D033FED9DD1> (cit. 21.05.2023).

- [9] Per Sahlholm et al. “A SENSOR AND DATA FUSION ALGORITHM FOR ROAD GRADE ESTIMATION”. en. In: *IFAC Proceedings Volumes* 40.10 (2007), s. 55–62. ISSN: 14746670. DOI: 10.3182/20070820-3-US-2918.00010.
- [10] Narayanan Kidambi et al. “Methods in Vehicle Mass and Road Grade Estimation”. en. In: *SAE International Journal of Passenger Cars - Mechanical Systems* 7.3 (dub. 2014), s. 981–991. ISSN: 1946-4002. DOI: 10.4271/2014-01-0111. URL: <https://www.sae.org/content/2014-01-0111/>.
- [11] Petr Hrych. “Real-time estimation of some physical parameters of trams relevant for onboard prediction of braking distance”. Masters thesis. Prague: CZECH TECHNICAL UNIVERSITY IN PRAGUE Faculty of Electrical Engineering Department of Control Engineering, 2020. URL: <https://dspace.cvut.cz/handle/10467/88068>.
- [12] Amie Albrecht et al. “The key principles of optimal train control—Part 1: Formulation of the model, strategies of optimal type, evolutionary lines, location of optimal switching points”. en. In: *Transportation Research Part B: Methodological* 94 (pros. 2016), s. 482–508. ISSN: 01912615. DOI: 10.1016/j.trb.2015.07.023.
- [13] Dan Simon. *Optimal State Estimation: Kalman, H Infinity, and Nonlinear Approaches*. English. 1st edition. Hoboken, N.J: Wiley-Interscience, čvn. 2006. ISBN: 978-0-471-70858-2.