



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY

DEPARTMENT OF CONTROL AND INSTRUMENTATION

ROZVĚTVENÉ DYNAMICKÉ MODELY ŘIDIČE

MULTILOOP DYNAMICAL MODELS OF HUMAN DRIVER

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jakub Čelko

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Ondřej

Mihálik

BRNO 2024

Diplomová práce

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

Ústav automatizace a měřicí techniky

Student: Bc. Jakub Čelko

ID: 216785

Ročník: 2

Akademický rok: 2023/24

NÁZEV TÉMATU:

Rozvětvené dynamické modely řidiče

POKYNY PRO VYPRACOVÁNÍ:

Úkolem studenta je vytvoření souboru funkcí a skriptů, které by umožnily automatické zpracování dat ze simulátoru řízení vozidla. Důraz by měl být kladen na úpravu stávajících scénářů, nalezení struktury modelů a na následnou statistickou analýzu.

1. Proveďte rešerši na téma dynamických modelů lidského operátora (řidiče).
2. Seznamte se se simulátorem vozidla na UAMT FEKT a s prostředím Unreal Engine.
3. Vyberte vhodný scénář a rozšiřte ho o nové vstupní poruchové signály (např. vliv větru).
4. Ověřte vhodnost navržených scénářů a modelů člověka na základě měření a vyhodnocení dat.
5. Proveďte měření alespoň 10 různých osob. Data vyhodnoťte statistickými metodami.
6. Diskutujte výsledky a doplňte je grafickými ukázkami.

DOPORUČENÁ LITERATURA:

[1] NASH, C. J. a D. J. COLE. Identification and validation of a driver steering control model incorporating human sensory dynamics. „Vehicle system dynamics“. Abingdon: Taylor & Francis, 2020, roč. 58, č. 4, s. 495–517. ISSN 0042-3114.

[2] NASH, C. J. a D. J. COLE. Identification of a driver model incorporating sensory dynamics, with nonlinear vehicle dynamics and transient disturbances. „Vehicle system dynamics“. Abingdon: Taylor & Francis, 2022, roč. 60, č. 8, s. 2805–2824. ISSN 0042-3114.

Termín zadání: 5.2.2024

Termín odevzdání: 15.5.2024

Vedoucí práce: Ing. Ondrej Mihálik

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

UPOZORNĚNÍ:

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

ABSTRAKT

Práca je zameraná na modelovanie systémov človek-stroj, kde operátor riadi vozidlo. Výsledkom práce je porovnanie kvality modelovania reakcií vodiča vybraných rozvetvených a nerozvetvených modelov. Modely sú aplikované v scenároch, kde okrem budiacej funkcie vo forme žiadaného jazdného pruhu pôsobí aj poruchový signál, ktorý ovplyvňuje smer jazdy vozidla. Identifikácia modelu vodiča prebiehala modelovaním celej uzavretej slučky v diskretnom stavovom popise. V práci je taktiež spísaná rešerš modelov vodiča, predstavený použitý simulátor vozidla a prostredie Unreal Engine 4 použité pre jeho implementáciu. Prezentovaná je aj dokumentácia implementovaných poruchových signálov, ktoré pôsobia ako porucha na vstupe regulovanej sústavy. Výsledky identifikácie modelov na nameraných dátach naznačujú, že nerozvetveným modelom s jedinou prenosovou funkciou sa v scenároch, kde pôsobí poruchový signál, znižuje kvalita predikcie. Rozvetvené modely s rovnakým počtom parametrov dokážu v takých prípadoch modelovať reakcie vodiča kvalitnejšie.

KLÚČOVÉ SLOVÁ

dynamické modely vodiča, ľudský operátor, rozvetvené modely, simulátor vozidla, systémy človek-stroj

ABSTRACT

The thesis is focused on modelling human-machine systems, where a human operator controls a vehicle. The result of the work is a comparison of the prediction capabilities of chosen multiloop and single-loop human driver models. These models are applied in scenarios where, in addition to the lane change forcing function, there is also a disturbance signal that affects the vehicle's motion. The parameters characterising the human dynamics are extracted from the model of the whole loop, defined as a discrete state-space model. The thesis also contains research on driver models, description of the used vehicle simulator and the Unreal Engine 4 environment used for its implementation. Documentation of implemented disturbance signals that act as a fault at the input of the regulated system is also presented. The identification results on the measured data suggest that the models relying on a single transfer function are losing prediction capabilities in scenarios, where the disturbances affect the vehicle. In such cases, the multiloop models with the same number of parameters are able to capture human behaviour more accurately.

KEYWORDS

dynamical driver models, human-machine systems, human operator, multiloop models, vehicle simulator

ČELKO, Jakub. *Rozvětvené dynamické modely řidiče*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2024. Vedúci práce: Ing. Ondrej Mihálik

Vyhlásenie autora o pôvodnosti diela

Meno a priezvisko autora: Bc. Jakub Čelko
VUT ID autora: 216785
Typ práce: Diplomová práca
Akademický rok: 2023/24
Téma závěrečnéj práce: Rozvětvené dynamické modely řidiče

Vyhlasujem, že svoju záverečnú prácu som vypracoval samostatne pod vedením vedúcej/cého záverečnej práce, s využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej záverečnej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto záverečnej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákonníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autora*

*Autor podpisuje iba v tlačenej verzii.

POĎAKOVANIE

Rád by som poďakoval vedúcemu diplomovej práce p. Ing. Ondrejovi Mihálikovi za odborné vedenie, konzultácie, cenné rady a podnetné návrhy k práci.

Obsah

Úvod	12
1 Dynamické modely vodiča	14
1.1 A two-level model of driver steering behaviour	14
1.2 Crossover model	16
1.3 MPC a Bi-LSTM model	17
1.4 Driver steering control model	18
1.5 Fuzzy modely	19
1.6 Model troch úrovní správania	20
2 Simulátor vozidla a prostredie Unreal Engine	22
2.1 Unreal Engine 4	22
2.1.1 Level Editor	22
2.1.2 Programovanie v prostredí Unreal Engine	23
2.2 Simulátor vozidla	24
2.2.1 Pôvodný stav simulátora	25
2.2.2 Inovácie a zmeny	28
2.2.3 Dynamika natáčania kolies modelu auta	31
3 Realizácia poruchového signálu	34
3.1 Generátory poruchového signálu	34
3.1.1 Biely šum	34
3.1.2 Pseudo random binary sequence (PRBS)	35
3.2 Filtre poruchového signálu	36
3.2.1 Implementácia filtrov druhého a štvrtého rádu	37
3.2.2 Príklady filtrovaného poruchového signálu	39
4 Identifikácia modelu vodiča	41
4.1 Postup získavania meraných dát	41
4.2 Identifikačná metóda	42
4.2.1 Vyhodnotenie kvality modelov	45
4.2.2 Porovnanie priamej a nepriamej identifikačnej metódy	46
4.2.3 Vytvorené identifikačné skripty a ich popis	47
4.3 Analyzované modely vodiča	49
4.3.1 Modely s jednou prenosovou funkciou	49
4.3.2 Rozvetvené modely	51

5	Získané výsledky	53
5.1	Úspešnosť jednotlivých modelov na validačných dátach	53
5.2	Identifikované hodnoty parametrov jednotlivých modelov	56
5.2.1	Dongesove modely	57
5.2.2	McRuerove modely	59
5.3	Príklady meraných a modelovaných signálov	62
5.4	Zhrnutie a zhodnotenie výsledkov	68
	Záver	70
	Literatúra	72
	Zoznam symbolov a skratiek	76
	Zoznam príloh	81
	A Dotazník pre testovaných vodičov	82
	B Identifikované hodnoty parametrov jednotlivých modelov	83
	C Priebehy meraných a modelovaných signálov	85
	C.1 Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu	85
	C.2 Statický Dongesov model a McRuerov model 1. rádu	88
	D Obsah elektronickej prílohy	93

Zoznam obrázkov

1.1	Dvojúrovňový model vodiča	15
1.2	Základná signálová schéma regulačného obvodu	16
1.3	MPC model vodiča	17
1.4	Štruktúra modelu vodiča – Driver steering control model	18
1.5	Model vodiča s fuzzy PD regulátorom	20
1.6	Model regulačnej slučky s fuzzy logikou	20
1.7	Tri úrovne správania sa skúseného ľudského operátora	21
2.1	Unreal Engine 4 – Level Editor	22
2.2	Herný volant a pedále Logitech G920	26
2.3	Obrazovka v scenári <i>Step response measurement with noise</i>	29
2.4	Príklad volania C++ funkcie v <i>blueprint</i> skripte	29
2.5	Nastavenie aplikácie z hlavného menu	30
2.6	Reakcia kolies na skokový vstupný signál	32
2.7	Porovnanie požadovanej hodnoty a natočenia kolies	33
3.1	Príklad bieleho šumu a jeho histogram	35
3.2	PRBS Generátor	35
3.3	Príklad PRBS poruchového signálu	36
3.4	Frekvenčná charakteristika filtrov	37
3.5	Realizácia filtra 2. rádu	38
3.6	Realizácia filtra 4. rádu	39
3.7	Filtrovaný PRBS poruchový signál	40
3.8	Filtrovaný biely šum	40
4.1	Základná regulačná slučka	42
4.2	Regulačná slučka s rozkresleným modelom sústavy	42
4.3	Stavový popis systému	43
4.4	Porovnanie priamej a nepriamej identifikačnej metódy	47
4.5	McRuerov model 1. rádu	50
4.6	McRuerov model 2. rádu	51
4.7	Statický Dongesov model	52
4.8	Dongesov model s filtrom 1. rádu	52
5.1	Úspešnosť modelov (ME) na validačných dátach pri predikcii signálu regulačnej odchýlky	54
5.2	Úspešnosť modelov (ME) na validačných dátach pri predikcii akčného zásahu vodiča	55
5.3	Priemerná úspešnosť modelov (ME) na validačných dátach	56
5.4	Identifikované hodnoty parametrov pre Dongesov model s filtrom 1. rádu	58

5.5	Odozva akčného zásahu McRuerových modelov identifikovaných v scenári 4 na skok a impulz žiadanej hodnoty	60
5.6	Identifikované hodnoty parametrov pre McRuerov model 2. rádu . . .	61
5.7	Namerané dáta z celej dĺžky experimentu	63
5.8	Priebehy meraných a modelovaných signálov – scenár 1, vodič 3 . . .	64
5.9	Priebehy meraných a modelovaných signálov – scenár 2, vodič 6 . . .	65
5.10	Priebehy meraných a modelovaných signálov – scenár 3, vodič 3 . . .	66
5.11	Priebehy meraných a modelovaných signálov – scenár 4, vodič 12 . . .	68
B.1	Identifikované hodnoty parametrov pre statický Dongesov model . . .	83
B.2	Identifikované hodnoty parametrov pre McRuerov model 1. rádu . . .	84
C.1	Priebehy meraných a modelovaných signálov – scenár 1, vodič 1 . . .	85
C.2	Priebehy meraných a modelovaných signálov – scenár 1, vodič 9 . . .	86
C.3	Priebehy meraných a modelovaných signálov – scenár 2, vodič 2 . . .	86
C.4	Priebehy meraných a modelovaných signálov – scenár 3, vodič 8 . . .	87
C.5	Priebehy meraných a modelovaných signálov – scenár 4, vodič 8 . . .	87
C.6	Priebehy meraných a modelovaných signálov – scenár 1, vodič 3 . . .	88
C.7	Priebehy meraných a modelovaných signálov – scenár 1, vodič 9 . . .	89
C.8	Priebehy meraných a modelovaných signálov – scenár 2, vodič 6 . . .	89
C.9	Priebehy meraných a modelovaných signálov – scenár 2, vodič 2 . . .	90
C.10	Priebehy meraných a modelovaných signálov – scenár 3, vodič 3 . . .	90
C.11	Priebehy meraných a modelovaných signálov – scenár 3, vodič 8 . . .	91
C.12	Priebehy meraných a modelovaných signálov – scenár 4, vodič 12 . . .	91
C.13	Priebehy meraných a modelovaných signálov – scenár 4, vodič 8 . . .	92

Zoznam tabuliek

1.1	Typická prenosová funkcia človeka riadiaceho vybrané typy sústav . .	16
3.1	Filtre poruchového signálu	37
5.1	Identifikované hodnoty parametrov Dongesovho modelu s filtrom 1. rádu	57
5.2	Identifikované hodnoty parametrov statického Dongesovho modelu . .	59
5.3	Identifikované hodnoty parametrov McRuerovho modelu 2. rádu . . .	61
B.1	Identifikované hodnoty parametrov McRuerovho modelu 1. rádu . . .	84

Úvod

Táto diplomová práca sa zaoberá oblasťou modelovania a identifikácie, konkrétne je zameraná na systémy človek-stroj zahŕňajúce ľudský faktor. Predmetom modelovania a identifikácie sú dynamické modely človeka – vodiča, ktorý riadi automobil v simulátore vozidla.

Cieľom práce je zhrnúť aktuálne používané prístupy k modelovaniu človeka ako regulátora pri vedení vozidla, prípadne ďalšie metódy popisu správania sa pri iných obdobných situáciách. Následne bolo nutné zoznámiť sa so simulátorom vozidla, ktorý je na experimenty používaný na FEKT VUT v Brně. Z už existujúcich scenárov bolo potrebné vybrať vhodných kandidátov na úpravu a implementovať do simulátora úpravy v podobe nových budiacich signálov, ktoré by mohli prispieť ku kvalitnejšej identifikácii modelov vodiča. Nový budiaci signál bol realizovaný ako porucha vstupujúca do regulačnej slučky na vstupe riadenej sústavy. Implementácia nového budiaceho signálu vyžadovala naprogramovanie generátorov a filtrov poruchy, a ich začlenenie do kódu simulátora.

Hlavným výstupom práce je identifikácia a analýza dynamických modelov človeka. Práca porovnáva vybrané modely s jedinou prenosovou funkciou (nerozvetvené modely) s vybranými modelmi so stavovou spätnou väzbou (rozvetvené modely). Zástupcovia oboch skupín boli zvolení tak, aby mali rovnakú komplexnosť – rovnaký počet parametrov. V práci je použitý spôsob identifikácie modelov pomocou funkcie programu MATLAB. Modely boli identifikované nepriamou identifikačnou metódou v diskretnom stavovom popise celej uzavretej slučky. Vyhodnocuje a porovnáva sa kvalita predikcie jednotlivých modelov pri rôznej intenzite pôsobiacej poruchy a prezentujú sa konkrétne hodnoty jednotlivých parametrov modelov. Modely sú identifikované na vzorke dát získaných od 12 vodičov.

Diplomová práca je rozčlenená do piatich základných kapitol. Prvá kapitola predstavuje teoretický úvod do problematiky modelovania vodiča. V kapitole je spísaná rešerš používaných metód a modelov pre identifikáciu človeka v skúmaných systémoch. Druhá kapitola sa venuje popisu simulátora vozidla na FEKT VUT v Brně, popisuje jeho pôvodný stav, ale aj vylepšenia, ktoré do simulátora boli implementované v rámci tejto práce. V časti kapitoly je popísané prostredie Unreal Engine 4, v ktorom je simulátor vozidla vyvinutý. Kapitola 3 dokumentuje nové budiace signály implementované do simulátora. Popisuje spôsob generovania týchto signálov a možnosť ich úpravy pomocou filtrov. Štvrtá kapitola dokumentuje postup získavania meraných dát, rozoberá zvolený spôsob identifikácie modelu vodiča a vyhodnotenia jeho kvality predikcie. Časť kapitoly je venovaná popisu identifikačných skriptov a funkcií vytvorených v prostredí MATLAB. V kapitole je taktiež popísaná štruktúra analyzovaných modelov vodiča. Posledná kapitola prezentuje získané výsledky.

V grafoch je zobrazené konkrétne vyhodnotenie kvality modelov v jednotlivých scenároch, sú tu prezentované konkrétne hodnoty parametrov jednotlivých modelov a príklady nameraných a modelovaných signálov.

Výsledky tejto diplomovej práce boli prijaté k publikácii [1] a k prezentácii na konferencii *18th IFAC Conference on Programmable Devices and Embedded Systems PDeS 2024*.

1 Dynamické modely vodiča

Kapitola popisuje aktuálne prístupy k modelovaniu človeka ako regulátora v systémoch človek-stroj. Je tu uvedené základné rozdelenie modelov a popis niektorých modelov získaných z dostupnej literatúry.

Človek ako regulátor zapojený do systému so spätnou väzbou sa snaží dostať systém do požadovaného stavu, pričom sa dokáže do veľkej miery adaptovať na spôsoby ovládania systému, spôsoby získavania informácií o stave riadeného systému aj na rôzne prípady požadovaného stavu systému. Aby všetky tieto rôznorodé situácie zvládol, musí upravovať svoje vlastnosti a správanie. Dôsledkom tohto procesu je, že kvantitatívny popis človeka ako celku by bol nesmierne komplikovaný. Z tohto dôvodu je nutné rozdeliť analýzu človeka na časti, ktoré bude možné jednoducho modelovať. Tieto časti by mali zaznamenať dominantné účinky, z ktorých bude možné získať dostatočne všeobecné modely človeka popisujúce vybranú oblasť. Vhodnými scenármi pre takúto analýzu sú napríklad situácie, keď človek reguluje systém s konštantnými charakteristikami, na ktorého ovládanie je operátor už zvyknutý a vstupné signály by mali byť náhodné alebo pseudo-náhodné procesy (pre operátora sa ako náhodné budú javiť). [2]

Modelovanie ľudského operátora je v súčasnosti skúmané predovšetkým v oblasti letectva pre popis pilotov a taktiež v oblasti cestnej premávky, kde ľudský operátor riadi vozidlo. V článkoch [3, 4, 5] je možné nájsť rozbor používaných prístupov k modelovaniu človeka a rôzne používané typy modelov. Na základe publikácie [3] je možné zhrnúť aktuálne prístupy modelovania vodiča podľa typu modelov:

- feedback modely s prenosovou funkciou
- preview modely
- fuzzy modely
- MPC modely (model predictive control)
- umelé neurónové siete – prevažne konvolučné siete

V nasledujúcom texte budú postupne uvedené viaceré modely ľudského operátora vychádzajúce z literatúry a vedeckých publikácií.

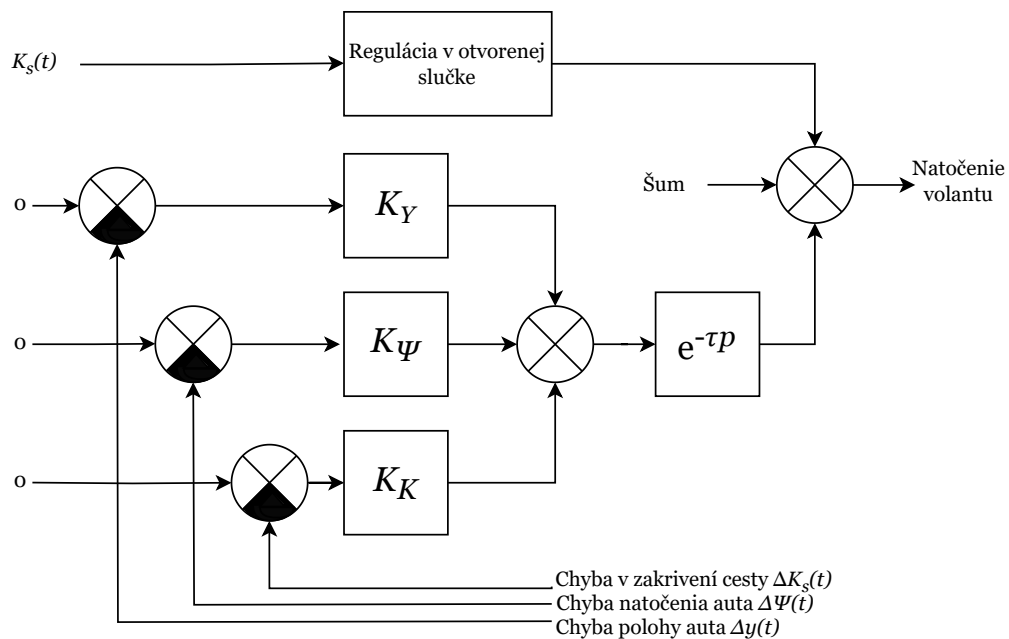
1.1 A two-level model of driver steering behaviour

Text nasledujúcej sekcie vychádza z článku [6], ktorý ako jeden z prvých rieši stavové modely vodiča. V článku bola navrhnutá dvojúrovňová regulačná slučka, ktorá reprezentuje dva druhy vizuálnych vnemov vodiča.

V úrovni *guidance* vodič spracováva informácie o tvare budiacej funkcie (zakrivenie cesty). Pretože vodičovi je zobrazovaná cesta pred vozidlom, je v tomto prípade

okrem aktuálnej požadovanej hodnoty dostupná aj informácia o jej budúcom priebehu. Vodič sa teda môže v predstihu pripraviť na budúcu zmenu žiadanej hodnoty, čo predstavuje *feedforward* reguláciu (reguláciu v otvorenej slučke).

Regulácia v otvorenej slučke musí byť kontrolovaná spätnou väzbou, teda druhou úrovňou nazvanou *stabilization*. Tu vodič sleduje aktuálnu hodnotu budiacej funkcie (zakrivenia cesty), vníma chybu v natočení vozidla a chybu v priečnej vzdialenosti od stredu cesty. Na základe týchto hodnôt určí akčný zásah vo forme natočenia volantu. Takto popísaný model vodiča je schematicky znázornený na obrázku 1.1.



Obr. 1.1: Dvojúrovňový model vodiča [6]

Model regulovanej sústavy (vozidla) bol daný rovnicami

$$\Psi(t) = \int_{t_0}^t v(\theta) [K_i(\theta) - K_s(\theta)] d\theta \quad (1.1)$$


$$y(t) = \int_{t_0}^t v(\theta)\Psi(\theta) d\theta \quad (1.2)$$

kde $K_i(t)$ je aktuálne zakrivenie dráhy, $K_s(t)$ je požadovaný tvar trasy, $\Psi(t)$ je natočenie auta, $y(t)$ je priečna poloha auta na ceste a $v(t)$ je jeho rýchlosť. Model je v podstate zhodný s modelom auta, ktorý bude použitý v experimentoch v tejto práci. Rozdielom je však to, že rýchlosť $v(t)$ sa v experimentoch v [6] menila, zatiaľ čo v tejto práci sa bude pracovať s konštantnou rýchlosťou.

1.2 Crossover model

Popis modelu vychádza z publikácie [2], na základe mena autora sa na tento model v literatúre odkazuje aj ako *McRuerov crossover model* alebo len *McRuerov model*.

Základnou myšlienkou tohto modelu je, že človek prispôbovaním svojich vlastností upravuje akčný zásah takým spôsobom, aby v otvorenej slučke vznikol prenos $\omega_r/p \cdot e^{-\tau p}$, kde ω_r je takzvaná frekvencia rezu. V prípade regulácie nestabilnej sústavy a splnení podmienky $\lambda \ll \omega_r$ sa do prenosu otvorenej slučky dostáva aj nestabilný pól sústavy. Základná schéma experimentu je zobrazená na obrázku 1.2, príklady prenosovej funkcie človeka riadiaceho vybrané typy sústav sú vypísané v tabulke 1.1.



Obr. 1.2: Základná signálová schéma regulačného obvodu [2]

Tab. 1.1: Typická prenosová funkcia človeka riadiaceho vybrané typy sústav [2]

Prenos riadenej sústavy $F_S(p)$	Približný prenos operátora $F_R(p)$	Prenos otvorenej slučky $F_0(p)$
K_S	$\frac{K_R}{p} \cdot e^{-\tau p}$	$\frac{\omega_r}{p} \cdot e^{-\tau p}$
$\frac{K_S}{p}$	$K_R \cdot e^{-\tau p}$	
$\frac{K_S}{p(p + \alpha)}$	$K_R(p + \alpha) \cdot e^{-\tau p}$	
$\frac{K_S}{p^2}$	$K_R p \cdot e^{-\tau p}$	$\frac{\omega_r}{p - \lambda} \cdot e^{-\tau p}$
$\frac{K_S}{(p - \lambda)}$	$K_R \cdot e^{-\tau p}$	
$\frac{K_S}{(p + \alpha)(p - \lambda)}$	$K_R(p + \alpha) \cdot e^{-\tau p}$	

Frekvencia rezu ω_r závisí na type regulovanej sústavy aj na maximálnej frekvencii

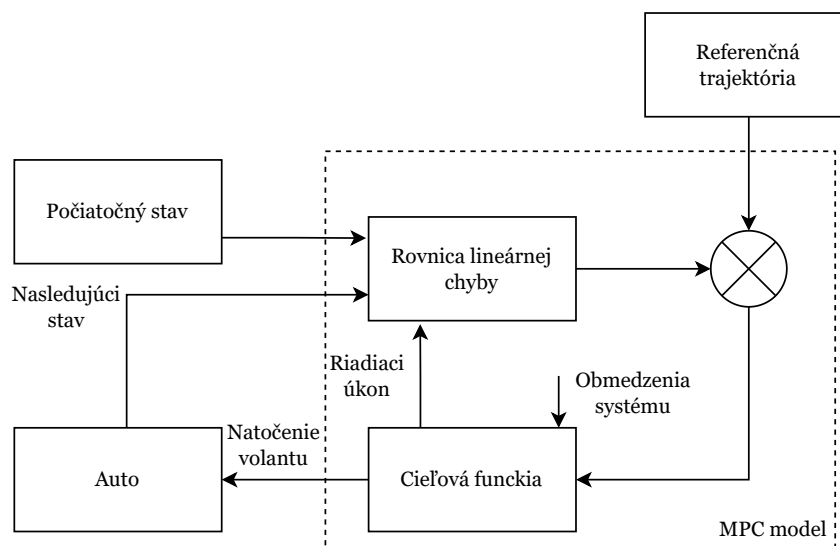
prítomnej v budiacom signále. Slovo *crossover* v názve modelu súvisí s obmedzeným frekvenčným rozsahom, na ktorom je získaný model platný.

Pre zmysluplnú identifikáciu prenosovej funkcie musí byť budiaca funkcia nezadbateľná voči šumu, ktorý sa vyskytuje v uzavretej slučke. V opačnom prípade sa získa operátorový prenos, ktorý je prevrátenou hodnotou operátorového prenosu regulovanej sústavy.

1.3 MPC a Bi-LSTM model

V článku [3] autori porovnávajú MPC model a Bi-LSTM model (typ umelej neurónovej siete) s niekoľkými skúsenými vodičmi. Cieľom bolo nájsť model vodiča, ktorý by pri nasadení ako regulátor v autonómnych vozidlách vykazoval podobné správanie ako ľudskí vodiči, čím by bol pre ostatných účastníkov premávky prijateľnejší. Zaujímavosťou experimentu je to, že skúsení vodiči boli meraní na reálnej ceste a na skutočných autách.

Z identifikácií vyplynulo, že ich zvolený MPC model nedokázal skúseného vodiča dobre popísať, respektíve rozdiel medzi akčným zásahom modelu a akčným zásahom skúseného vodiča bol veľký. Ako ďalšia nevýhoda MPC modelu je uvedený fakt, že daný model potrebuje poznať preddefinovanú referenčnú trajektóriu, zatiaľ čo u človeka nič nenasvedčuje tomu, že si v hlave vytvára požadovanú dráhu, po ktorej by chcel s vozidlom prejsť. MPC model vodiča je schematicky znázornený na obrázku 1.3.



Obr. 1.3: MPC model vodiča [3]

Ako druhý model vodiča je skúmaná umelá neurónová sieť bi-LSTM (bidirectional long short-term memory). Vstupom do modelu je vektor hodnôt

$$\mathbf{X}(t) = (v_t \ d_{yt} \ \delta_t \ \text{label}), \quad (1.3)$$

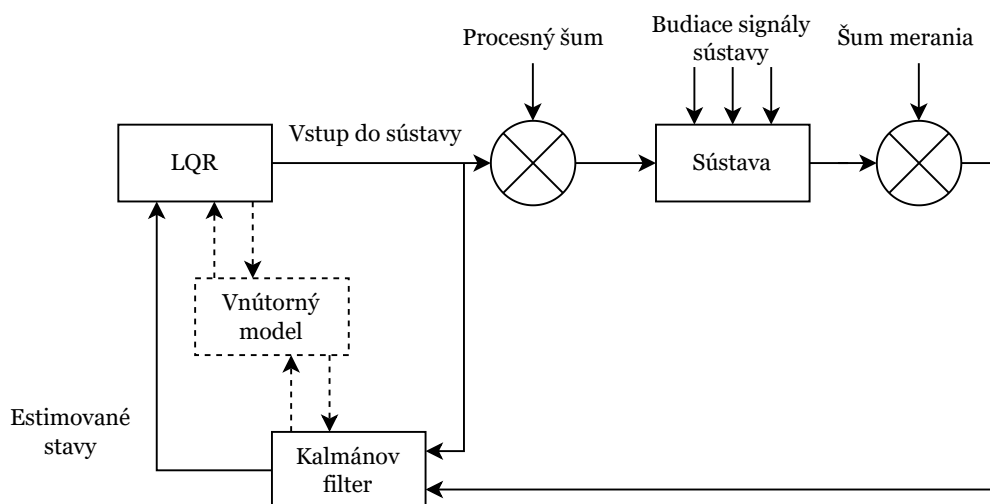
kde v_t je rýchlosť auta v čase t , d_{yt} je priečný offset v čase t , δ_t je natočenie volantu v čase t a label je označenie správania sa vozidla pri zmene jazdného pruhu. Výstupom modelu je hodnota $y(t) = \delta_{t+1}$.

Výsledkom identifikácie je, že predikcie týchto modelov (Bi-LSTM a dvoch ďalších založených na neurónových sieťach) sa do veľkej miery zhodujú s akčným zásahom skutočných vodičov. Zo všetkých testovaných modelov mal najvyššiu presnosť práve model bi-LSTM.

Nevýhodou bi-LSTM je ale to, že výstup siete závisí nielen na minulých hodnotách modelu, ale aj na budúcich výstupoch. V praxi však vo väčšine prípadov nie je možné pozerat sa na nezmerané dáta.

1.4 Driver steering control model

V článku [7], z ktorého vychádza nasledujúca sekcia, vychádzajú zo stavového modelu s *feedforward* a *feedback* väzbami, ktorý bol popísaný v [6], ale navyše uvažujú tri typy pôsobiacich budiacich signálov. *Feedforward* zabezpečuje sledovanie požadovanej dráhy $f_t(t)$, *feedback* kompenzuje náhodne pôsobiace poruchy bočnej $f_v(t)$ a uhlovej $f_w(t)$ rýchlosti auta.



Obr. 1.4: Štruktúra modelu vodiča – Driver steering control model [7]

Človeka v experimente modelujú ako LQR regulátor, pričom ale počítajú s tým, že človek ako regulátor nedokáže vnímať stavy priamo z riadenej sústavy. Z tohto dôvodu do simulácie pridávajú aj stavový rekonštruktor, ktorý navrhli ako Kalmánov filter. Štruktúra modelu je zobrazená na obrázku 1.4.

Žiadaná hodnota $f_t(t)$ bola generovaná tak, že biely šum bol filtrovaný filtrom s prenosom

$$F(p) = \frac{p^2}{(p + 0,1)^2(0,5p + 1)^2}. \quad (1.4)$$

Spektrá poruchových signálov f_v a f_ω boli navrhnuté tak, aby priečna poloha auta mala bez vstupu operátora rovnaké spektrum ako f_t . Kvôli potlačeniu vysokých frekvencií boli ale ešte signály filtrované dolnopriepustným filtrom.

V publikácii [8] je skúmaný podobný model, do ktorého sú ale zakomponované ne-lineárne prvky. Zaujímavým výsledkom článku je porovnanie odoziev vodičov v pohyblivom a nepohyblivom simulátore vozidla. Ak je simulátor nepohyblivý, alebo ak je pohyb simulátora filtrovaný, odozvy vodičov sú horšie. Experimenty so simulátorom s plným alebo škálovaným pohybom mali rýchlejšiu odozvu a lepšie potlačenie poruchy.


1.5 Fuzzy modely

Špecifickým prístupom k modelovaniu ľudských odoziev je využitie fuzzy modelov. Fuzzy modely využívajú fuzzy logiku, kde slovo fuzzy znamená nejasný alebo neurčitý. Táto logika sa snaží napodobniť ľudské uvažovanie a myslenie, ktoré neuvažuje presné číselné hodnoty. Základy tejto oblasti položil L.A. Zadeh v roku 1965 [9]. Podrobnejší popis fuzzy logiky pre účely riadenia a modelovania je možné nájsť napríklad v publikácii [10].


V modelovaní vodiča sa fuzzy systém používa napríklad k spresneniu aproximácie lineárnych modelov. Typicky sa z prenosovej funkcie lineárneho modelu odstráni zložky P a D, ktoré sú nahradené fuzzy PD regulátorom [11]. Takýto model vodiča je schematicky zobrazený na obrázku 1.5. Lineárny model sa môže ponechať aj celý, ale je k nemu pridaná statická fuzzy nelinearita tak, že výsledok tvorí Hammersteinov model [12]. Príklad regulačnej slučky so statickou fuzzy logikou je zobrazený na obrázku 1.6.

Výsledky týchto publikácií naznačujú zlepšenie kvality aproximácie akčného zásahu vodičov, ktorí mali na rovnej diaľnici podľa pokynov prechádzať medzi jazdnými pruhmi. Cenou za zlepšenie kvality predikcie je ale pomerne výrazné navýšenie zložitosti modelu vodiča, pretože fuzzy systémy majú všeobecne veľa parametrov, ktoré

je možné ladiť. V praxi sa potom často pristupuje k zjednodušeniam, napríklad že sú niektoré parametre pevne dané, alebo medzi sebou zviazané.



Obr. 1.5: Model vodiča s fuzzy PD regulátorom [11]



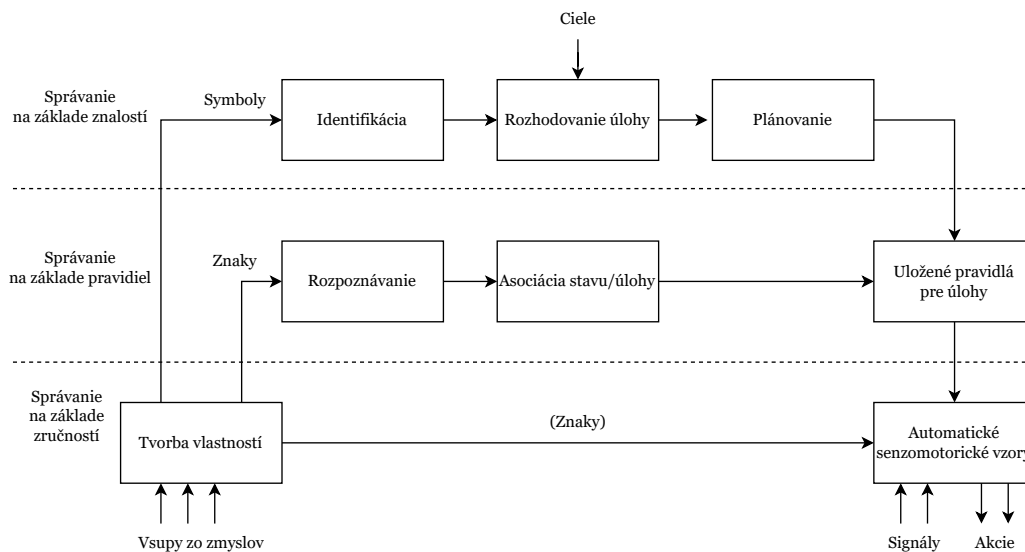
Obr. 1.6: Model regulačnej slučky s fuzzy logikou [12]

Istým nedostatkom by mohlo byť, že v spomenutých publikáciách [11, 12] modely neboli validované, alebo fuzzy a LTI modely neboli trénované na rovnakých dátach. Preto je diskutabilné, nakoľko majú modely s fuzzy logikou lepšiu predikčnú schopnosť než LTI modely.

1.6 Model troch úrovní správania

Úplne odlišný spôsob úvahy nad týmto problémom bol zvolený v publikácii [13], z ktorej vychádza celá nasledujúca sekcia. Namiesto hľadania matematických modelov sa zamýšľajú nad teoretickým modelom ako človek spracováva podnety z okolia. Človeka nemožno považovať za jednoduchý deterministický vstupno-výstupný systém. Je nutné uvažovať, že človek má svoje ciele, ktoré si aktívne vyberá a hľadá k nim relevantné zdroje a informácie. Model človeka bol rozdelený do troch úrovní, ktoré sú: správanie na základe znalostí, správanie na základe pravidiel a správanie na základe zručností. Tri úrovne modelu sú schematicky znázornené na obrázku 1.7.

Správanie na základe zručností používa signály, správanie na základe pravidiel pracuje so znakmi, ktoré riadia proces riadenia. Pri správaní na základe znalostí sa využívajú symboly, ktoré predstavujú vnútornú reprezentáciu súvislostí a uvažovania.



Obr. 1.7: Tri úrovne správania sa skúseného ľudského operátora [13]

Správanie na základe zručností sa vzťahuje na aktivity a situácie, ktoré sa dejú automaticky bez priameho vedomia. Sú to naučené vzory správania a vo väčšine prípadov sa jedná o priame riadenie. Iba zriedka je prítomná jednoduchá spätná väzba, ktorá predstavuje reakciu na odchýlku medzi požadovaným a skutočným stavom.

Správanie na základe pravidiel je zložené zo sledu činností, ktoré riešia známu situáciu na základe uložených pravidiel a procedúr. Tieto pravidlá mohli byť získané empiricky pri riešení predošlých situácií alebo môžu byť predané od inej osoby. V tomto prípade správania sa jedná o *feedforward* riadenie na základe známeho pravidla. Nie je jednoduché rozlíšiť správanie na základe pravidiel a správanie na základe zručností, pretože to do veľkej miery závisí na úrovni naučenia daného problému a na miere pozornosti osoby pri riešení situácie. Vo všeobecnosti je možné tvrdiť, že pri správaní na základe zručností osoba nevie explicitne povedať, na základe čoho sa rozhoduje o procese riadenia, zatiaľ čo v prípade správania na základe pravidiel je tu dané know-how, ktoré postup procesu presne definuje.

Najvyšší stupeň riadenia, správanie na základe znalostí, sa uplatňuje v neznámych situáciách, kde pre riadenie nie sú dostupné žiadne pravidlá alebo predošlé skúsenosti. V tomto prípade je cieľ stanovený na základe analýzy prostredia a vnútorných cieľov osoby. Sú vytvorené viaceré možnosti riešenia, ktorých účinnosť je testovaná metódou pokus-omyl. Prípadne, ak je dostupná znalosť fungovania daného systému alebo prostredia, je možné predpokladať efekt jednotlivých riešení.

2 Simulátor vozidla a prostredie Unreal Engine

Táto kapitola sa venuje simulátoru vozidla na FEKT VUT v Brně, prostrediu Unreal Engine 4, v ktorom je simulátor vyvinutý a popisuje zmeny a zistenia, ktoré boli na simulátore vykonané v rámci tejto práce.

2.1 Unreal Engine 4

V tejto podkapitole je uvedený základný popis a možnosti programovania vo vývojovom prostredí Unreal Engine 4 od spoločnosti Epic Games.

2.1.1 Level Editor

Táto podkapitola vychádza zo zdrojov [14, 15]. Základným prvkom prostredia Unreal Engine je *Level Editor*, ktorý slúži na vytváranie a upravovanie jednotlivých úrovní hry. Pod pojmom *level* sú myslené jednotlivé scény, ktoré vytvárajú herné 3D prostredie. *Level Editor* obsahuje viacero častí, z ktorých bude uvedených niekoľko príkladov.



Obr. 2.1: Unreal Engine 4 – Level Editor

Toolbar (panel nástrojov) zoskupuje niekoľko veľmi často využívaných nástrojov a príkazov. *Viewport* je časť editora zobrazujúca aktuálne upravovaný level. Ponúka viacero možností zobrazenia, napríklad perspektívne (3D) alebo ortogonálne v osiach X, Y a Z. *Details Panel* (panel detailov) zobrazuje informácie a funkcie zvoleného prvku v okne *Viewport*. Je tu možné upravovať polohu, rotáciu a mierku vybraných prvkov (takzvaných *Actors*) a sú tu zhrnuté všetky upravovateľné vlastnosti daného objektu. Ďalšia často využívaná sekcia editora je *Content Browser*, ktorý prehľadne v adresárovej štruktúre zobrazuje všetky súbory daného projektu a zároveň umožňuje tieto súbory spravovať a pristupovať k nim.

Snímok obrazovky editora je zobrazený na obrázku 2.1, kde sú vyznačené aj jednotlivé časti popisované vyššie: 1 – *Toolbar*, 2 – *Viewport*, 3 – *Content Browser* a 4 – *Details Panel*.

2.1.2 Programovanie v prostredí Unreal Engine

Nasledujúci text vychádza zo zdrojov [14, 16, 17]. Unreal Engine ponúka dve možnosti vytvárania a programovania herných prvkov (respektíve objektov), a to prostredníctvom programovacieho jazyka C++ alebo využitím vstavaného systému vizuálneho programovania nazvaného *Blueprint Visual Scripting*. Obidva prístupy je možné používať samostatne, ale v skutočnosti je vhodné a efektívne používať kombináciu oboch prístupov, pretože sa môžu vzájomne dopĺňať. Doporučené prepojenie je používať C++ na vytvorenie funkčných herných blokov a v *blueprint* skriptoch tieto bloky používať k vytvoreniu herného prostredia.

Blueprint Visual Scripting:

Blueprint Visual Scripting je skriptovací systém integrovaný v prostredí Unreal Engine. Systém je založený na vizuálnom programovaní pomocou prepájania jednotlivých blokov. Systém je objektovo orientovaný a na takto vytvorené objekty sa odkazuje názvom *Blueprints*. Existuje niekoľko typov *blueprint* skriptov, každý má svoje špecifické použitie.

Blueprint Class slúži k vytvoreniu nových tried, môžu sa použiť napríklad k programátorsky jednoduchému pridaniu funkcionalít k už existujúcim triedam.

Data-Only Blueprint obsahuje iba kód (vo forme vizuálnych skriptov), premenné a komponenty z rodičovskej triedy. Nie je možné pridať nové prvky, existujúce vlastnosti a parametre sa ale môžu modifikovať.

Level Blueprint je typ globálneho skriptu, ktorý sa uplatňuje pre celú jednu úroveň hry – *level*. Každý *level* má svoj vlastný *level blueprint*. Skript sa používa k riadeniu sekvencií, udalostí a akcií v priebehu daného levelu.

Blueprint Interface je zoznam jednej alebo viacerých funkcií. Sú tu uvedené iba názvy, nie ich implementácia. Tento interface je možné pridať do iných *blueprint* skriptov, u ktorých potom bude garantované, že dané funkcie budú obsahovať. Umožňuje to zdieľanie dát medzi rôznymi typmi *blueprint* skriptov.

Blueprint Macro Library je súbor makier, ktoré môžu byť vložené a použité v ďalších skriptoch. Môžu pozostávať z často používaných sekvencií kódu.

Blueprint Utilities je typ skriptu, ktorý je použiteľný iba v editore na vykonanie rôznych akcií alebo pre rozšírenie možností editora.

Programovanie pomocou C++:

Prvým krokom programovania v C++ v prostredí Unreal Engine je výber rodičovskej triedy. Je možné si vybrať z viacerých preddefinovaných tried. Po výbere triedy a vytvorení názvu triedy prostredie vygeneruje zdrojový súbor `.cpp` a hlavičkový súbor `.h` podľa predpísanej šablóny zvolenej triedy.

Typ rodičovskej triedy môže byť napríklad:

- *None* – prázdna trieda s prednastaveným konštruktorom a deštruktorom
- *Character* – trieda pre objekty ovládané hráčom, ktorá už ale má v sebe zakomponované vlastnosti ako logiku pohybu a kolízie
- *Pawn* – základná trieda pre objekty, ktoré môžu byť ovládané hráčom alebo iným systémom
- *Actor* – základná trieda pre objekt, ktorý môže byť umiestnený v hernom svete
- *Player Camera Manager* – trieda zabezpečujúca pre daného hráča kontrolu kamery
- a veľa ďalších

Pre použitie v rámci tejto práce je najzaujímavejšia možnosť C++ triedy *Blueprint Function Library*. Táto trieda je vhodná na implementáciu sady funkcií, ktoré môžu byť volané z viacerých iných tried alebo z *blueprint* vizuálnych skriptov. Všetky tieto funkcie aj premenné triedy musia byť definované ako statické, pretože hlavným zmyslom tejto triedy je to, že funkcie triedy nie sú viazané na žiadny objekt a teda môžu byť volané bez toho, aby existoval objekt danej triedy. [18]

2.2 Simulátor vozidla

Simulátor vozidla na FEKT VUT v Brně bol pôvodne vytvorený v rámci diplomovej práce [14], neskôr bol však upravený a prepracovaný. Stav simulátora, z ktorého vychádza táto práca, je popísaný v článku [19].

2.2.1 Pôvodný stav simulátora

Nasledujúca časť práce popisuje vlastnosti a možnosti simulátora, ktoré mal pred zmenami vykonanými v rámci tejto práce. Táto podkapitola vychádza z publikácií o tomto konkrétnom simulátore vozidla [14, 19, 20], ako aj z vlastných pozorovaní pri práci so simulátorom. V kapitole 2.2.2 bude popísaný vlastný prínos práce a zlepšenia vykonané na simulátore.

Model auta (*Vehicle Object*):

Na základe [19] je model auta vytvorený v simulácii základnou časťou simulátora. Komponenta modelu auta v sebe zahŕňa niekoľko funkčných celkov, ktoré spolu vytvárajú pre účastníka experimentu realistický dojem šoférovania vozidla. Súčasťou tejto komponenty podľa [19] je:

- *NVidia PhysX* model, ktorý implementuje fyzikálne vlastnosti auta a definuje jeho pohybové vlastnosti
- 3D model auta
- Zvukové efekty motora a pohybu auta
- *SceneCapture2D*, ktorá zaisťuje obrazy v spätných zrkadlách
- Kamera zabezpečujúca pohľad z prvej alebo z tretej osoby
- Komponenta zaisťujúca ovládanie vozidla prostredníctvom vstupných zariadení – volant, pedále, klávesnica a myš
- Komponenta ukladania meraných dát

HW simulátora:

Simulátor vozidla je spúšťaný pod operačným systémom Windows 10. Hlavným dôvodom, prečo je potrebné sa zaoberať hardvérom simulátora, sú možnosti vzorkovania, ktoré ponúka prostredie Unreal Engine 4. Maximálna vzorkovacia frekvencia je totiž daná počtom snímkov za sekundu. [19]

Vzorkovacia frekvencia je preto do veľkej miery závislá na použitom hardvéri, respektíve na čase, ktorý daný hardvér potrebuje k vykresleniu snímkov. Táto skutočnosť má dopad aj na nerovnomernosť vzorkovania, keďže vykresľovanie rôznych snímkov nemusí trvať rovnaký čas. [19]

Je preto dôležité uviesť na akých komponentoch bol simulátor spustený:

- Procesor: AMD Ryzen 9 3900XT 12-core 3.80 GHz
- Grafická karta: NVidia RTX 2080 Super
- Disk: 1TB NVMe SSD
- Pamäť RAM: 32GB DDR4 3600MHz

S touto konfiguráciou bolo možné dosiahnuť vzorkovaciu frekvenciu vyššiu ako 100 Hz, ktorá je pre meranie ľudských odoziev dostatočne vysoká. V predchádzajúcich experimentoch napríklad v [30] alebo aj vo výsledkoch tejto práce (kapitola 5.2) majú identifikované časové konštanty v modeloch vodiča hodnotu väčšiu ako 0,1 s, čo predstavuje desať násobok vzorkovacej periódy.

Vodič simulátor ovláda pomocou volantu a pedálov Logitech G920 [21] zobrazených na obrázku 2.2. K dispozícii je aj radiaca páka Driving Force Shifter [22], ktorá ale v experimentoch v rámci tejto práce nebola použitá.



Obr. 2.2: Herný volant a pedále Logitech G920 [21]

Herné a realistické prvky simulácie:

Z herných prvkov simulácie je pre experimenty najdôležitejší takzvaný *Heads-up Display*. Sú to informácie, ktoré sa vodičovi priebežne zobrazujú na obrazovke. Jedná sa o rýchlosť auta, zaradený prevodový stupeň a vzdialenosť od stredu požadovaného pruhu. Dôležitejší pre experimenty je však asistent, ktorý ukazuje polohu auta pri výraznom vychýlení z požadovaného jazdného pruhu. *Heads-up Display* je možné vidieť na obrázku 2.3. [19]

Z realistických prvkov je vhodné spomenúť hlavne vykresľovanie obrazu v spätných zrkadlách, čo viacerí účastníci experimentov považovali za nutné ku kvalitnej regulácii vozidla. Ďalej sem patrí napríklad meniaci sa tuhosť volantu v závislosti na povrchu, po ktorom sa auto pohybuje. [19]

To je zaujímavá vlastnosť, ale v experimentoch v rámci tejto práce nebola využitá, pretože sa auto pohybovalo len po jednom povrchu.

Scenáre:

V aplikácii boli vytvorené 3 typy scenárov, každý je zameraný na inú oblasť.

Free ride course

Scenár slúži na zoznámenie sa so simulátorom, správaním sa modelu auta a jeho ovládaním. Neukladajú sa žiadne dáta a vodič má plnú slobodu, nie je od neho požadovaný žiadny konkrétny úkon.

Highway measurement

V tomto scenári má vodič držať vozidlo v strede jazdného pruhu pri jazde po diaľnici. Požadovaný jazdný pruh ostáva stále rovnaký, ale cesta (diaľnica) obsahuje aj zákruty. Vodičovi je pomocou asistenta signalizované, ak sa vychýli z jazdného pruhu. Scenár simuluje dlhú jazdu po diaľnici, kde je pravdepodobné, že dôjde k únave a ospalosti vodiča. [19, 20]

Step response measurement

V tomto scenári má vodič držať vozidlo v strede jazdného pruhu pri jazde po diaľnici, ktorá je rovná, bez zákrut. Počas jazdy sa požadovaný jazdný pruh mení v (pre vodiča) náhodných intervaloch. Zmena požadovaného jazdného pruhu je vodičovi signalizovaná a zároveň vodič pomocou jazdného asistenta vidí, ak sa vozidlo výrazne vychýli z požadovaného pruhu. Kľúčovým zaznamenávaným signálom je vzdialenosť auta od stredu požadovaného jazdného pruhu. Pomocou scenára je možné analyzovať prechodovú charakteristiku vodiča. [19, 20]

Okrem týchto scenárov sú v publikáciách [14, 19, 20] uvedené aj ďalšie, ktoré síce sú vo vývojovom prostredí simulátora vytvorené, ale nie je možné sa k nim dostať z exportovanej aplikácie.

Patrí sem napríklad *Moose test* (losí test), ktorý je vytvorený na základe experimentov s reálnymi vozidlami na určenie ich schopností a dynamiky alebo *Highway: Sudden obstacle scenario*, kde vodič pri jazde po dlhej diaľnici bez zákrut čelí situácii, kedy v náhodných okamžikoch do cesty vstúpi objekt. Vodič sa mu musí vyhnúť. Na rozdiel od scenára *Step response measurement* by mala vzniknúť situácia a zameraný zásah operátora reprezentovať impulznú odozvu.

Ukladanie dát do súboru:

Keďže simulátor vozidla má slúžiť k analýze a modelovaniu vodiča, je nevyhnutné ukladať viaceré signály potrebné pre ďalšiu analýzu. Vybrané dáta sú ukladané do .csv súboru, pred každým scenárom je možné zvoliť existujúci súbor, kde sa nové merania pridajú za už existujúce dáta, alebo vytvoriť súbor nový. Jedná sa predovšetkým o samotné akčné zásahy vodiča. Ukladá sa napríklad časová značka

daného vzorku, vzdialenosť od stredu požadovaného jazdného pruhu, natočenie volantu, rýchlosť auta a pedálový vstup. Ukladanie do .csv súboru zaisťuje C++ trieda `Ucds_logdata_BP_function`. [14]

2.2.2 Inovácie a zmeny

Jedným z dôvodov, prečo boli v simulátore vykonané úpravy, bol pôvodný priebeh experimentu. Celý priebeh prechodového deja je totiž vodičovi známy. Vie dopredu určiť, do ktorého jazdného pruhu sa bude musieť zaradiť, pozná aj amplitúdu skoku žiadanej hodnoty, pretože vzdialenosť medzi jazdnými pruhmi je stále konštantná. Jediné, čo vodič nevie, je čas zmeny žiadanej hodnoty. Experiment je preto potrebné modifikovať tak, aby bola prítomná väčšia náhodnosť v budiacich signáloch. Inšpiráciou pre inovácie boli publikácie od autorov C.J. Nash a D.J. Cole, zhrnuté v podkapitole 1.4.

Z už existujúcich scenárov bol pre úpravu zvolený scenár *Step response measurement*. V scenári už je implementovaný jeden budiaci signál – skoková zmena žiadaného jazdného pruhu, takže pridaním ďalšieho budiaceho signálu, napríklad poruchy, bude systém budený viacerými funkciami. To môže prispieť ku kvalitnejšej identifikácii oproti stavu, kedy by pôsobila iba samotná porucha.

Pridanie nového scenára:

Do aplikácie bol pridaný nový scenár *Step response measurement with noise*, pri ktorom je k akčnému zásahu operátora pripočítavaná zvolená porucha. Scenár je v podstate upravenou kópiou už existujúceho scenára *Step response measurement*.

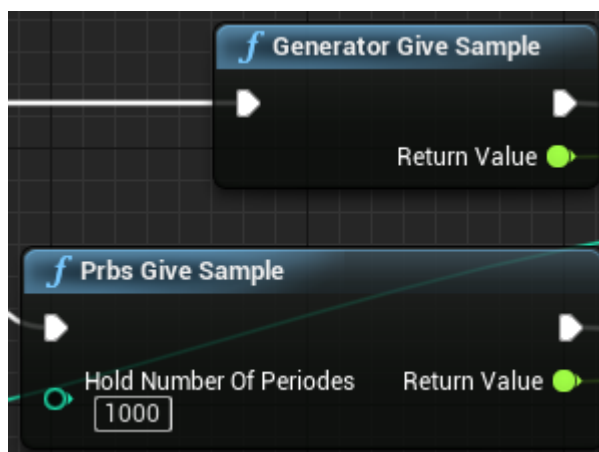
Podstatné zmeny boli vykonané v blueprint *Sedan_Car*, kde bol pridaný generátor poruchového signálu spoločne s filtrom. Pretože tento blueprint je spoločný pre všetky scenáre, musela byť navyše pridaná logika riadiaca generovanie poruchy, ktorá zabezpečí aby sa k akčnému zásahu operátora poruchový signál pripočítaval len v novo vytvorenom scenári. Záber experimentu z tohto scenára je zobrazený na obrázku 2.3.



Obr. 2.3: Obrazovka v scenári *Step response measurement with noise*

Vytvorenie nových C++ tried:

Do projektu boli vytvorené a pridané C++ triedy `UNoiseGenerator` a `UNoiseFilter`, ktorých funkcie sú vytvorené ako `BlueprintCallable`, teda je ich možné volať z *blueprint* v prostredí Unreal Engine.



Obr. 2.4: Príklad volania C++ funkcie v *blueprint* skripte

Trieda `UNoiseGenerator` obsahuje štyri funkcie, ktoré zabezpečujú inicializáciu jednotlivých generátorov poruchy (generátor bieleho šumu a PRBS generátor) a vygenerovanie jednej vzorky použitím daného generátora. Nastavenie generátora

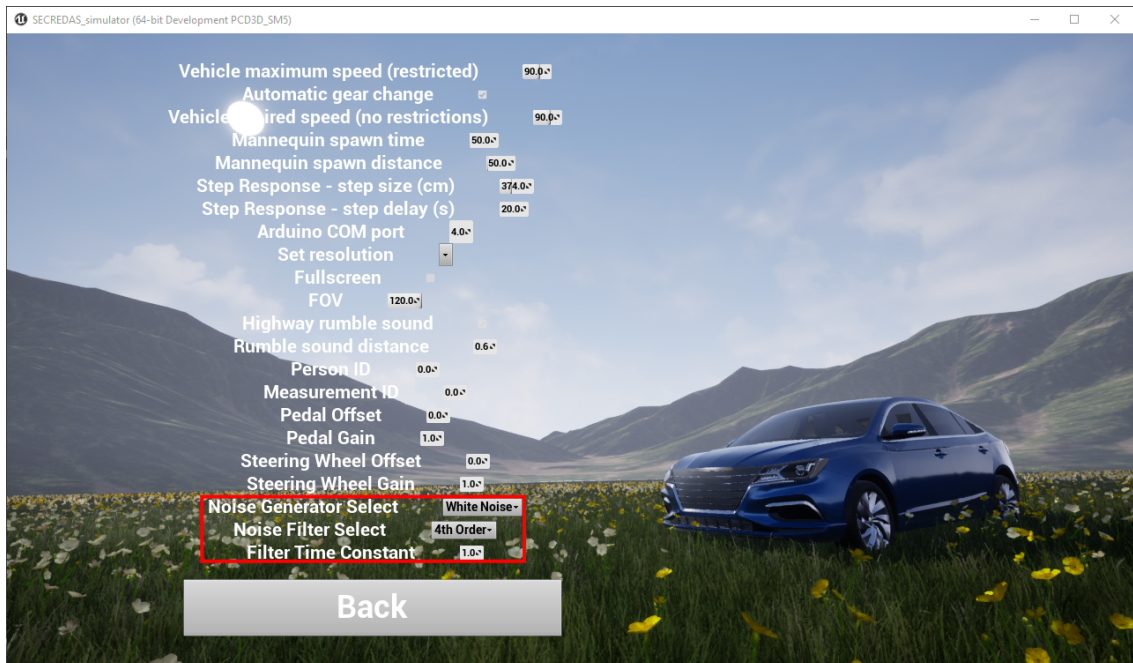
bieleho šumu ako aj uchovanie stavov PRBS generátora prebieha pomocou statických premenných v triede.

Trieda `UNoiseFilter` obsahuje štyri funkcie, ktoré implementujú filtre poruchového signálu a jednu funkciu na inicializáciu filtrov. Jednotlivé stavy filtrov ako aj užívateľom voliteľné parametre filtrov sú uchovávané pomocou statických premenných v triede.

Príklad volania C++ funkcie z programovacieho prostredia Unreal Engine je zobrazený na obrázku 2.4. Podrobný popis obidvoch generátorov poruchy ako aj jednotlivých filtrov je uvedený v kapitole 3.

Nové možnosti nastavenia simulácie:

Do nastavení simulácie, ktoré je možné zobraziť z hlavného menu, ako aj do nastavení, ktoré je možné zobraziť z pozastavenej simulácie, boli pridané nové ovládacie prvky. Aktuálne je možné vybrať zdroj poruchového signálu (biely šum – *White Noise* alebo *PRBS*), filter poruchového signálu (bez filtra – *No Filter*, filter 1., 2. alebo 4. rádu – *1st Order*, *2nd Order*, *4th Order*) a časovú konštantu filtrov T_f v rozsahu od 0,1 do 15 sekúnd. Obrazovka hlavných nastavení aplikácie je zobrazená na obrázku 2.5, kde sú pridané možnosti zvýraznené červenou farbou.



Obr. 2.5: Nastavenie aplikácie z hlavného menu (červenou farbou sú zvýraznené novo pridané možnosti)

Úprava C++ triedy ukladajúcej namerané dáta do súboru:

Aby bolo možné analyzovať vplyv poruchového signálu na vodiča, je nutné tento generovaný signál zaznamenávať a ukladať pre ďalšiu analýzu. Z tohto dôvodu bola do C++ triedy `Ucids_logdata_BP_function` pridaná funkcia, ktorá do súboru `.csv` zapisuje okrem pôvodných signálov navyše aj poruchový signál a natočenie kolies modelu auta. Tieto dva nové signály sa do súboru ukladajú len v scenári *Step response measurement with noise*, v ostatných prípadoch bolo ponechané pôvodné riešenie.

Ďalšie zmeny a vylepšenia:

Spustenie simulácie bolo možné pozastaviť iba stlačením klávesy P a tlačítkom Home na volante. Pri práci so simulátorom a jeho vývoji ale viacerým ľuďom nevyhovovali takéto možnosti. Na pozastavenie simulácie preferovali používať klávesu `Escape`, ktorá je výrazne jednoduchšie a rýchlejšie lokalizovateľná na klávesnici. Z tohto dôvodu bola pridaná aj táto možnosť, zároveň bolo ale zachované aj pôvodné ovládanie.

V simulácii je vykresľovaný virtuálny volant, ktorý sa otáča podľa vstupu vodiča. Pôvodne bol uhol natočenia virtuálneho volantu riadený na základe natočenia kolies modelu auta. V prípade pôsobenia poruchy to malo nežiadúci účinok v tom, že virtuálny volant sa natáčal aj bez vstupu vodiča, pretože reagoval na poruchový signál pôsobiaci na kolesá auta. Výsledok síce nemal priamy vplyv na priebeh experimentu, ale pôsobil veľmi rušivo a neprirodzene. Preto bol blueprint `Sedan_Car` upravený tak, aby bol vstup natočenia virtuálneho volantu ovládaný priamo výstupom z fyzického volantu, čím sa eliminuje vplyv poruchového signálu. Nevýhoda tohto riešenia spočíva v tom, že model auta je možné ovládať aj pomocou kláves A a D. Pri použití týchto kláves sa virtuálny volant okamžite otočí do koncovej polohy bez akéhokoľvek prechodového deja. Ovládanie klávesami A a D je ale pre meranie ľudských odoziev nepoužiteľné, preto táto skutočnosť nepredstavuje pre účastníkov experimentu žiadny problém.


2.2.3 Dynamika natáčania kolies modelu auta

Pri analýze a testovaní dodaného simulátora vozidla si bolo možné všimnúť, že kolesá modelu auta majú svoju dynamiku. Pri skokovom vstupnom signále, ktorý ovláda natočenie kolies, sa kolesá modelu auta nenatočia žiadaným smerom okamžite, ale ich prechod z aktuálnej pozície do žiadanej polohy je postupný. Navyše, z nameraných priebehov sa zistilo, že kolesá sa nenatáčajú zhodne, ale koleso na vnútornej strane zákruty má väčšie natočenie ako to na vonkajšej strane.

Priebehy odozvy obidvoch kolies na skokovú zmenu žiadanej hodnoty sú zobrazené na obrázku 2.6. Pretože vstupom do systému je bezrozmerná požadovaná

hodnota natočenia kolies v rozsahu $\langle -1; 1 \rangle$ ale výstupom je uhol natočenia kolies v rozsahu $\langle -40; 40 \rangle$, je v grafoch v tejto podkapitole výstup natočenia v uhloch vždy vydelený príslušnou konštantou, aby boli tieto dva signály priamo porovnateľné v amplitúde.

Pri analýze dynamiky natáčania kolies bol následne použitý vždy ten väčší uhol natočenia kolesa. To znamená, že pri natočení doprava sa ukladajú údaje o pravom kolese, pri natočení doľava sa berie do úvahy ľavé koleso. Tak je zaistené, že hľadaný systém má rovnaké parametre pri natočení na obidve strany.



Obr. 2.6: Reakcia kolies na skokový vstupný signál

Je nutné poznamenať, že analýza dynamiky kolies bola určená z dát pri rýchlosti auta 90 km/h, teda rýchlosti, pri ktorej boli merané všetky experimenty. Experimentálne bolo totiž zistené, že dynamika natáčania kolies sa mení s rýchlosťou, ktorou sa model auta pohybuje. Dáta boli merané s ľudským vodičom v scenári *Step response measurement with noise*, teda pri jazde po diaľnici s prechodom medzi jednotlivými pruhmi a pôsobiacim šumom. V tomto scenári sú výchylky volantu oveľa menšie ako je maximálny rozsah zobrazený v grafe na obrázku 2.6. Analýzou dát bol zistený nasledujúci prenos popisujúci dynamiku kolies

$$F_w(z) = \frac{b_w z^{-1}}{1 - a_w z^{-1}} = \frac{17,43z^{-1}}{1 - 0,001325z^{-1}} \quad (2.1)$$

Prepočtom na spojitý ekvivalent uvedeného systému, kde parametre a_w a b_w je možné prepočítať na zosilnenie K_w a časovú konštantu T_w podľa rovníc

$$\begin{aligned}
 a_w &= e^{-\frac{T_s}{T_w}} \\
 b_w &= K_w \left(1 - e^{-\frac{T_s}{T_w}}\right)
 \end{aligned}
 \tag{2.2}$$


dostaneme spojitý systém prvého rádu

$$F_w(p) = \frac{K_w}{T_w p + 1} = \frac{17,456}{0,0015p + 1}
 \tag{2.3}$$

Keďže časová konštanta tohto prenosu je o rád menšia ako vzorkovacia perióda simulátora, je možné túto časovú konštantu zanedbať a dynamiku kolies modelovať len oneskorením o jednu vzorku.

$$F_w(z) = b_w z^{-1} = 17,46 z^{-1}
 \tag{2.4}$$

Parameter b_w sa mierne líši od hodnoty identifikovanej v rovnici (2.1), pretože systém bol identifikovaný znovu s novou štruktúrou bez menovateľa v prenose. Z grafu na obrázku 2.7 je zrejmé, že pri malých výchylkách volantu, ktoré nastávajú v prípade scenára zmeny jazdného pruhu na diaľnici, je možné dynamiku kolies popísať zjednodušeným prenosom uvedeným v rovnici (2.4).



Obr. 2.7: Porovnanie požadovanej hodnoty a natočenia kolies

3 Realizácia poruchového signálu

Táto kapitola popisuje jednotlivé generátory poruchového signálu a filtre, ktoré je možné zaradiť za tieto generátory a upravovať tak poruchový signál. Poruchový signál ovplyvňuje smer jazdy vozidla, čím môže simulovať napríklad účinky vetra pôsobiaceho na automobil.

3.1 Generátory poruchového signálu


Zdroj poruchového signálu je možné vybrať z dvoch generátorov. Implementovaný je generátor bieleho šumu a generátor PRBS signálu.

3.1.1 Biely šum

Generátor bieleho šumu bol implementovaný podľa príkladu na stránke [23], kde je uvedený pseudonáhodný generátor s normálnym rozložením definovaný v knižnici `<random>`. Vlastnosti generátora sú stredná hodnota a smerodajná odchýlka. Tieto parametre je ale nutné uviesť už pri jeho definícii, čo by neumožňovalo zmenu vlastností generátora z aplikácie simulátora. Preto bol generátor vytvorený so strednou hodnotou 0 a smerodajnou odchýlkou 1, pričom vzorky generátora $gen(k)$ sú prepočítané na nový výstup $gen_N(k)$ podľa rovnice

$$gen_N(k) = \sigma gen(k) + m, \quad (3.1)$$

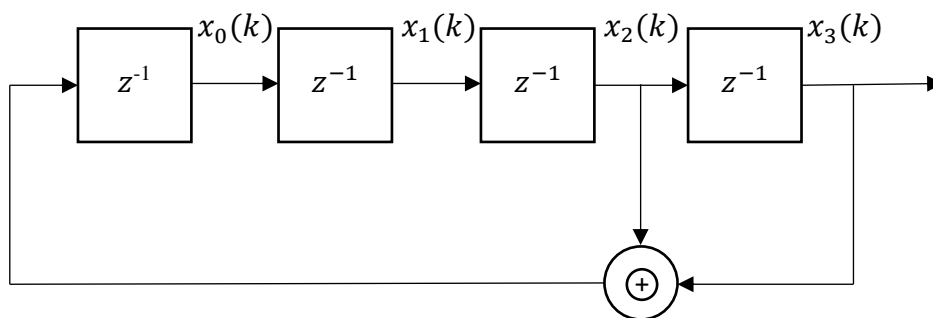
kde parametre σ (smerodajná odchýlka) a m (stredná hodnota) sú definované z prostredia Unreal Engine.



Obr. 3.1: Príklad bieleho šumu a jeho histogram z dĺžky signálu 60 s

3.1.2 Pseudo random binary sequence (PRBS)

Pre generovanie PRBS signálu bol vytvorený diskretný generátor 4. rádu, ktorý generuje sekvenciu jednotiek a núl o maximálnej možnej dĺžke 15. Schematicky je generátor zobrazený na obrázku 3.2.



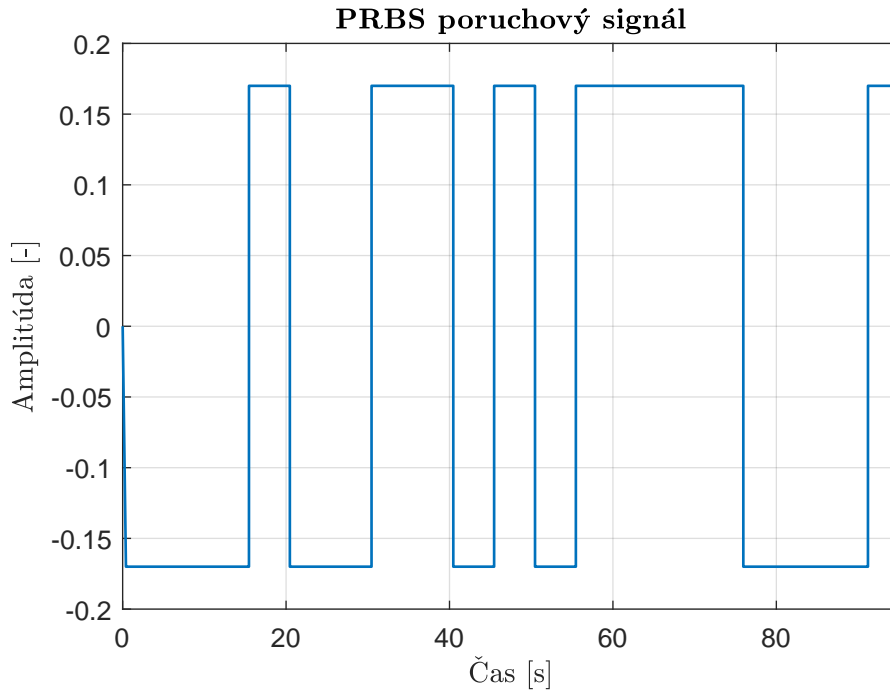
Obr. 3.2: PRBS Generátor – znak \oplus reprezentuje logickú funkciu XOR

Na začiatku simulácie je generátor nastavený počiatočným vektorom

$$\mathbf{x}_0 = (x_0 \ x_1 \ x_2 \ x_3)^T = (1 \ 0 \ 0 \ 0)^T \quad (3.2)$$

Pre účely generovania poruchy ale signál meniaci svoju amplitúdu medzi hodnotami 0 a 1 nebol vhodný. Preto bol skutočný výstup získaný z rovnice (3.3), kedy sa výstup $y(k)$ mení okolo nuly a nadobúda hodnoty -0.17 a 0.17 .

$$y(k) = -0,17 + 0,34x_3(k) \quad (3.3)$$



Obr. 3.3: Príklad PRBS poruchového signálu

Obnovovacia frekvencia PRBS generátora ale nie je zhodná s vzorkovacou frekvenciou simulátora. Períodu obnovy výstupu je možné nastaviť vo vývojovom prostredí Unreal Engine (takzvaný *Blueprint*) ako n -násobok vzorkovacej periódy. Pri všetkých meraniach bola nastavená na 1000-násobok vzorkovacej periódy. Príklad signálu generovaného týmto spôsobom je zobrazený v grafe na obrázku 3.3.

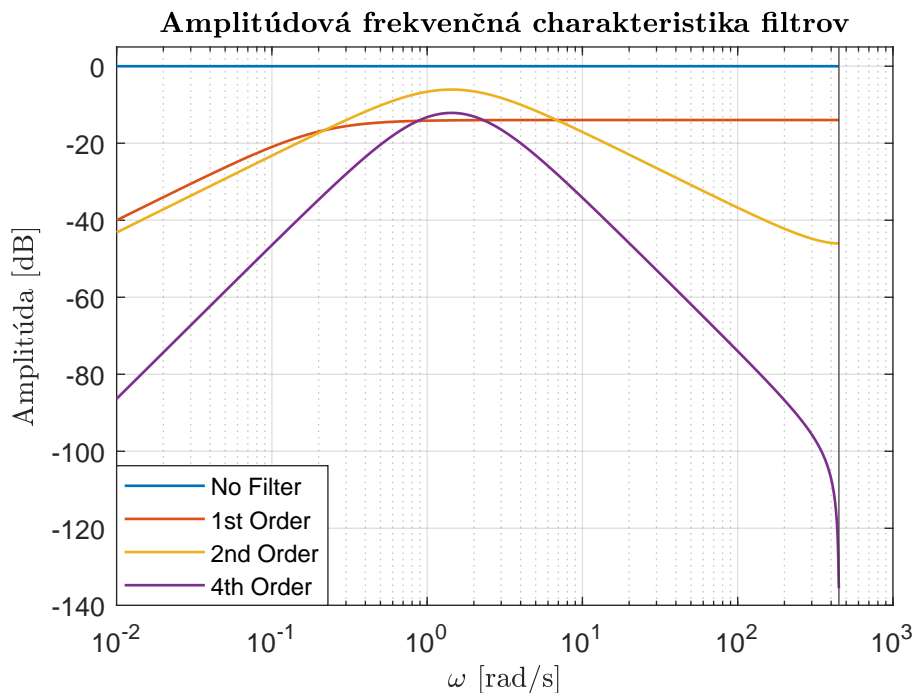
3.2 Filtre poruchového signálu

Za generátor poruchového signálu je možné zaradiť filter, ktorý upraví signál vstupujúci do modelu auta ako porucha. V rámci tejto práce boli vytvorené 4 typy filtrov, medzi ktorými je možné ľubovoľne prepínať. Prenosy filtrov sú uvedené v tabuľke 3.1.

Tab. 3.1: Filtre poruchového signálu

Názov filtra	Spojité prenos $F(p)$	Diskrétny prenos $H(z)$
No Filter	1	1
1st Order	$\frac{p}{T_f p + 1}$	$\frac{1/T_f(1 - z^{-1})}{1 - a_f z^{-1}}$
2nd Order	$\frac{T_f p}{(T_f p + 1)^2}$	$\frac{K_f(1 - z^{-1})}{(1 - a_f z^{-1})^2}$
4th Order	$\frac{(T_f p)^2}{(T_f p + 1)^4}$	$\frac{K_f(1 + b_f z^{-1})(1 - z^{-1})^2}{(1 - a_f z^{-1})^4}$

Všetky filtre boli implementované s voliteľnou časovou konštantou T_f v spojitom ekvivalente prenosu. Amplitúdová frekvenčná charakteristika každého filtra je zobrazená na obrázku 3.4, filter prvého rádu je vykreslený pre časovú konštantu $T_f = 5$ s, filtre druhého a štvrtého rádu sú vykreslené pre časovú konštantu $T_f = 1$ s.



Obr. 3.4: Amplitúdová frekvenčná charakteristika filtrov


3.2.1 Implementácia filtrov druhého a štvrtého rádu

Realizácia filtrov druhého a štvrtého rádu diferenčnou rovnicou, ktorá priamo vyplýva z diskrétného prenosu filtra, prináša negatívne vlastnosti. Príklad takejto rovnice všeobecne pre druhý rád je

$$y(k) = -a_{f1}y(k-1) - a_{f2}y(k-2) + b_{f1}u(k-1) + b_{f2}u(k-2) \quad (3.4)$$

Problémom je, že koeficienty a_{f1} a a_{f2} sú takmer identické, ale s opačným znamienkom. Výsledok diferencie dvoch po sebe nasledujúcich oneskorených výstupov je veľmi malé číslo. Takto realizovaný filter je veľmi citlivý na presnosť týchto koeficientov. Koeficienty museli byť uvádzané v plnej presnosti. Aj malé zmeny (napríklad zaokrúhlenie) viedli k tomu, že celý filter sa mohol stať nestabilným systémom.

Z tohto dôvodu boli filtre vyšších rádoz implementované sériovým programovaním ako niekoľko za sebou zaradených filtrov prvého rádu tak, aby sa výsledok z pohľadu vstup-výstup správal ako prenos uvedený vyššie v tabulke 3.1. Štruktúra filtra druhého rádu je zobrazená na obrázku 3.5.




Obr. 3.5: Realizácia filtra 2. rádu

Uvedený blokový diagram je možné popísať sústavou rovníc (3.6), pričom v tomto prípade boli koeficienty a_f a K_f počítané z periódy vzorkovania a požadovanej časovej konštanty T_f podľa rovníc (3.5).

$$\begin{aligned} a_f &= e^{-\frac{T_s}{T_f}} \approx 1 - \frac{T_s}{T_f} \\ K_f &= \frac{T_s}{T_f} e^{\frac{T_s}{T_f}} \approx \frac{T_s}{T_f} \left(1 + \frac{T_s}{T_f}\right) \end{aligned} \quad (3.5)$$

$$\begin{aligned} x_1(k) &= a_f x_1(k-1) + u(k) - u(k-1) \\ x_2(k) &= a_f x_2(k-1) + K_f x_1(k) \\ y(k) &= x_2(k) \end{aligned} \quad (3.6)$$

Štruktúra filtra štvrtého rádu je zobrazená v blokovom diagrame na obrázku 3.6. Odpovedajúci popis implementácie vo forme diferenčných rovníc je pod obrázkom (sústava rovníc (3.7)).



Obr. 3.6: Realizácia filtra 4. rádu

$$\begin{aligned}
 x_1(k) &= a_f x_1(k-1) + K_f (u(k) - u(k-1)) \\
 x_2(k) &= a_f x_2(k-1) + x_1(k) + b_f x_1(k) \\
 x_3(k) &= a_f x_3(k-1) + x_2(k) - x_2(k-1) \\
 x_4(k) &= a_f x_4(k-1) + x_3(k) \\
 y(k) &= x_4(k)
 \end{aligned} \tag{3.7}$$


Filter bol implementovaný tak, aby bolo možné za behu aplikácie meniť jeho časovú konštantu T_f . Aby parametre nemuseli byť počítané z definície pomocou výpočtetne náročnej exponenciály, bola pre každý parameter nájdená aproximácia pomocou Taylorovho rozvoja, ktorú je možné použiť aj v prípade filtra 2. rádu (rovnice (3.5)). Parametre boli počítané pomocou rovníc

$$\begin{aligned}
 a_f &= e^{-\frac{T_s}{T_f}} \approx 1 - \frac{T_s}{T_f} \\
 b_f &\approx -1 + \frac{4 T_s}{3 T_f} \\
 K_f &= \frac{e^{\frac{T_s}{T_f}}}{6} \left(\frac{T_s}{T_f} \right)^2 \left(3 - \frac{T_s}{T_f} \right) \approx \frac{1}{6} \left(\frac{T_s}{T_f} \right)^2 \left(3 - 4 \frac{T_s}{T_f} \right)
 \end{aligned} \tag{3.8}$$

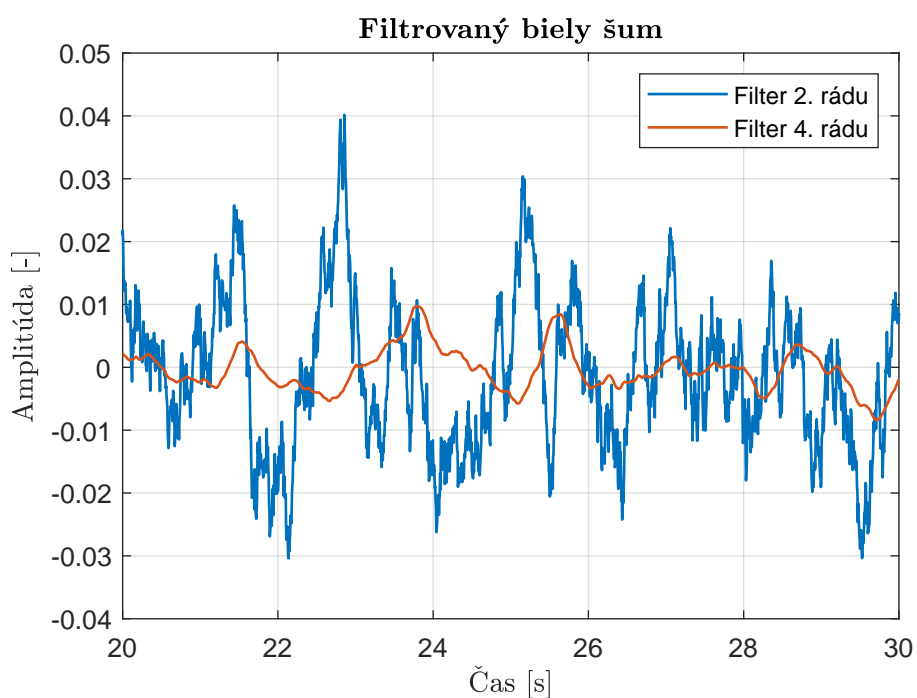
Výsledné správanie filtra sa od toho s hodnotami, ktoré boli vypočítané podľa definície, prakticky nelíši. Nie je teda možné, aby ľudský operátor túto zmenu zaregistroval.

3.2.2 Príklady filtrovaného poruchového signálu

Na nasledujúcich obrázkoch sú uvedené príklady filtrovaných poruchových signálov. Na obrázku 3.7 je príklad PRBS poruchového signálu filtrovaný všetkými implementovanými filtermi – bez filtra, teda pôvodný signál, filter 1. rádu s časovou konštantou $T_f = 5$ s a filtre 2. a 4. rádu s časovou konštantou $T_f = 1$ s.



Obr. 3.7: Filtrovaný PRBS poruchový signál



Obr. 3.8: Filtrovaný biely šum

Na obrázku 3.8 je graf filtrovaného bieleho šumu. Na tomto obrázku sú uvedené iba priebehy po filtrácii filtrom 2. a 4. rádu, obidva s časovou konštantou $T_f = 1$ s. Samotný biely šum ako aj biely šum filtrovaný filtrom prvého rádu by boli na takomto grafe neprehľadné a bez akejkoľvek výpovednej hodnoty.

4 Identifikácia modelu vodiča

Kapitola v prvej časti popisuje priebeh experimentov a postup získavania dát, v druhej časti je uvedený zvolený spôsob identifikácie modelu vodiča, vyhodnotenie kvality vodičov a popis vytvorených identifikačných skriptov v prostredí MATLAB. V poslednej časti sú prezentované analyzované modely vodiča.

4.1 Postup získavania meraných dát

Meranie jedného vodiča pozostávalo z absolvovania 4 jazd, každá jazda predstavovala jeden testovaný scenár. Každý scenár pozostáva približne z 20 zmien žiadaného jazdného pruhu, pričom rozdiel medzi scenármi je v miere a type pôsobiaceho poruchového signálu. Poradie merania scenárov bolo nasledovné:

1. Meranie bez umelo generovaného šumu,
2. Meranie s pôsobiacim bielym šumom filtrovaným filtrom 4. rádu s $T_f = 1$ s,
3. Meranie s pôsobiacim bielym šumom filtrovaným filtrom 2. rádu s $T_f = 1$ s,
4. Meranie s pôsobiacim PRBS signálom filtrovaným filtrom 4. rádu s $T_f = 2$ s.

Poradové čísla scenárov (1 až 4) sa pre zjednodušenie ďalej v texte práce aj v grafoch využívajú k odkazovaniu sa na jednotlivé scenáre.


Každý testovaný vodič vyplnil pred experimentom dotazník dostupný v prílohe A. Odpovede na jednotlivé otázky neboli v rámci tejto práce využité, môžu ale poslúžiť pri ďalšom výskume nad nazbieraným datasetom. Pred samotným meraním bol vodič oboznámený s priebehom experimentu a s ovládacími prvkami simulátora.

Pri identifikácii modelu vodiča bol z nameraných signálov odstránený začiatok a prvé dva skoky žiadanej hodnoty (zmeny žiadaného jazdného pruhu), kedy sa auto rozbieha z nulovej rýchlosti až na konštantnú rýchlosť pri experimente 90 km/h. Pri zmene rýchlosti sa totiž menia vlastnosti (koeficienty diferenciálnych rovníc) regulovanej sústavy (automobilu), čo je v tomto prípade pre identifikáciu modelu vodiča nechcený jav. Na začiatku merania sa taktiež vodič s autom a experimentom zoznamuje a môže reagovať výrazne odlišne od ostatných zmien žiadanej hodnoty.

Z niekoľkých experimentov musel byť odstránený aj koniec meraných signálov, a to v prípadoch, kedy vodič na konci experimentu nezvládol riadenie a vybočil z cesty. Aby sa experiment nemusel opakovať boli použité zvyšné dáta, ale len v prípadoch, keď mali dostatočnú dĺžku (obsahovali dostatočný počet skokov žiadanej hodnoty) pre zmysluplnú identifikáciu. V prípadoch, kedy vodič z cesty vybočil skôr ako tesne pred koncom, muselo byť dané meranie zopakované a celý scenár spustený od začiatku.

4.2 Identifikačná metóda


Na obrázku 4.1 je zobrazená základná bloková schéma experimentu, platná pre jednoduché, nerozvetvené modely vodiča. Signál $w(k)$ je žiadaná hodnota (požadovaný jazdný pruh), $y(k)$ je výstup sústavy (poloha auta na ceste), $e(k)$ je regulačná odchýlka, $x(k)$ je akčný zásah operátora (natočenie volantu) a $v(k)$ je pôsobiaci poruchový signál.



Obr. 4.1: Základná regulačná slučka

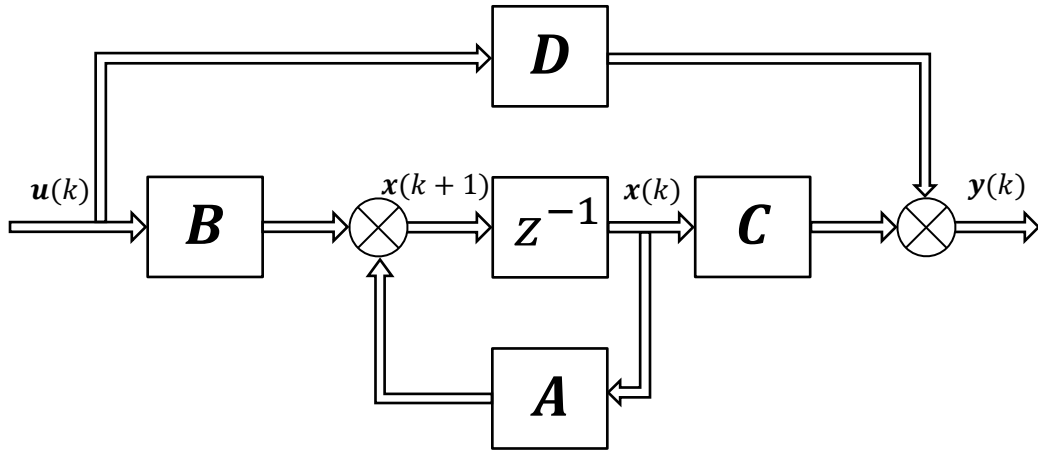
Problém pri identifikácii modelu vodiča priamou identifikačnou metódou, teda iba na základe nameraných signálov $e(k)$ a $x(k)$, môže nastať v prípade, že regulačná odchýlka je na relatívne dlhom úseku blízka nule. Následne model vodiča neprenesie takmer žiadny signál, človek len do systému vnáša svoj nezanedbatelný neuromuskulárny šum. Výsledky takejto identifikácie modelu vodiča môžu byť posunuté smerom k inverznému modelu regulovanej sústavy. [7, 24]

Z tohto dôvodu bol celý systém identifikovaný nepriamou metódou modelovaním celej uzavretej slučky v stavovom popise pomocou funkcie `ssest` v prostredí MATLAB. Všeobecný stavový popis systému je zobrazený na obrázku 4.3, kde $\mathbf{u}(k)$ sú vstupy do systému, $\mathbf{y}(k)$ sú výstupy zo systému a $\mathbf{x}(k)$ sú vnútorné stavy systému. V stavovom popise je možné rozkresliť jednotlivé stavy modelu vodiča a regulovanej sústavy a vzájomne ich prepájať. Na obrázku 4.2 je zobrazená bloková schéma experimentu s rozkresleným modelom sústavy a vyznačenými stavmi, ktoré vstupujú do modelu vodiča.



Obr. 4.2: Regulačná slučka s rozkresleným modelom sústavy a stavovou spätnou väzbou

Funkcii `ssest` sa ako parametre vložia namerané dáta (vstupy a výstupy systému) a štruktúra hľadaného systému (matice **A**, **B**, **C**, **D**), ktorých prvky funkcia upravuje dokiaľ nenájde model vyhovujúci nameraným dátam. Meraným vstupom do systému je požadovaný jazdný pruh a poruchový signál. Meraným výstupom je regulačná odchýlka a akčný zásah operátora. Štruktúra hľadaného systému musí popisovať celú regulačnú slučku tak, ako je zobrazená na obrázku 4.2. To znamená, že musí obsahovať model vodiča a jeho dopravné oneskorenie ale aj model regulovanej sústavy. Vhodným nastavením funkcie je možné označiť, ktoré koeficienty môže funkcia upravovať (hľadaný model vodiča) a ktoré musia ostať nezmenené (regulovaná sústava).



Obr. 4.3: Stavový popis systému [25]

Realizovaný experiment je možné popísať stavovými maticami uvedenými v rovniciach (4.1), ktoré tvoria systém s dvomi vstupmi a dvomi výstupmi tak, ako bol popísaný vyššie.

$$\mathbf{A} = \begin{pmatrix} \mathbf{A}_{11} & \mathbf{0} & \mathbf{0} & \mathbf{A}_{14} \\ \mathbf{0} & \mathbf{A}_{22} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{A}_{33} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{A}_{44} \end{pmatrix} \quad \mathbf{B} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \\ \vdots & \vdots \\ 0 & 1 \\ 0 & 0 \\ \vdots & \vdots \\ 0 & 0 \end{pmatrix} \quad (4.1)$$

$$\mathbf{C} = \begin{pmatrix} 0 & \cdots & 0 & 0 & \cdots & -1 \\ 0 & \cdots & 1 & 0 & \cdots & 0 \end{pmatrix} \quad \mathbf{D} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$$

Jednotlivé submatice v matici \mathbf{A} označujú dielčie časti modelu. Matica \mathbf{A}_{11} popisuje model vodiča bez dopravného oneskorenia, matica \mathbf{A}_{22} popisuje dopravné oneskorenie vodiča, matica \mathbf{A}_{33} popisuje dopravné oneskorenie sústavy, matica \mathbf{A}_{44} modeluje dynamiku regulovanej sústavy a matica \mathbf{A}_{14} popisuje spätné väzby zo stavov sústavy do modelu vodiča. Je nutné podotknúť, že zobrazenie matice \mathbf{A} v rovniciach (4.1) je značne zjednodušené a jednotlivé submatice na hlavnej diagonále sa v skutočnosti v rohoch čiastočne prekrývajú.

Stavový popis regulovanej sústavy popisuje model auta schematicky zakreslený na obrázku 4.2 – dvojitý integrátor s prenosom

$$F_S(z) = K_C T_S^2 \frac{z^{-2}}{(1 + z^{-1})^2} z^{-d}, \quad (4.2)$$

ktorému odpovedá spojitý prenos

$$F_S(p) = \frac{K_S}{p^2} e^{-\tau p}. \quad (4.3)$$

Model sústavy bez dopravného oneskorenia síce má v čitateli z^{-2} , čiže oneskoruje o 2 vzorky oproti spojitému ekvivalentu, no je možné to vykompenzovať menším počtom oneskorení d . Experimentálne zistené hodnoty parametrov sústavy boli $K_C = 73$ a $d = 40$. Dopravné oneskorenie sústavy je dané implementáciou daného simulátora vozidla.

Identifikácia dopravného oneskorenia vodiča:

Použitá identifikačná funkcia `ssest` nedovoľuje identifikovať dopravné oneskorenie modelu priamo ako vstupný parameter. Oneskorenie musí byť v diskretnom stavovom popise modelované ako rad za sebou zapojených jednokrokových oneskorení z^{-1} , definovaných v štruktúre systému maticou \mathbf{A} , respektíve jej submaticou \mathbf{A}_{22} .

Pre každé jedno meranie a každý identifikovaný model vodiča bolo analyzovaných niekoľko modelov s rovnakou dynamikou, ale s rôznym dopravným oneskorením. Identifikovalo sa 20 modelov s dopravným oneskorením od $d = 4$ po $d = 80$ s krokom 4. Uvedené diskkrétne oneskorenia odpovedajú rozsahu približne 0,04 až 0,8 s, podľa aktuálne zvolenej vzorkovacej periódy.

Z týchto modelov bol následne vybraný ten, ktorého výstup mal najlepšiu zhodu s meranými dátami. Keďže ale všetky analyzované modely majú dva výstupy, bolo kritériom výberu priemer zhody obidvoch výstupných signálov. Podrobný popis kritéria kvality modelov sa nachádza v kapitole 4.2.1.

Voľba vzorkovacej periódy:

Je nutné pripomenúť, že namerané dáta zo simulátora nemajú ekvidistantné vzorkovanie. Vo väčšine prípadov je rozdiel medzi dvoma nasledujúcimi vzorkami 7 ms, ale existujú aj dvojice po sebe idúcich vzoriek s časovým rozdielom od 6 do 10 ms. Identifikácia systémov pomocou funkcie `ssest` ale vyžaduje rovnomerné vzorkovanie. Jednotná vzorkovacia perióda T_S bola vypočítaná podľa vzorca (4.4) (N je celkový počet vzoriek a $t(i)$ je časová značka i -tého vzorku v milisekundách) a všetky vzorky boli uvažované tak, ako by boli zmerané s touto hodnotou vzorkovacej periódy.

$$T_S = \frac{1}{N} \sum_{i=1}^{N-1} [t(i+1) - t(i)] \quad (4.4)$$

Táto zmena v signáloch spôsobí chybu v amplitúde Δy , ktorú je možné aproximovať rovnicami (4.5).

$$\begin{aligned} \Delta y &= f(k + \Delta t) - f(k) \\ \frac{\Delta y}{\Delta t} &= \frac{f(k + \Delta t) - f(k)}{\Delta t} \\ \frac{\Delta y}{\Delta t} &\approx f'(k) \\ \Delta y &\approx \Delta t f'(k) \end{aligned} \quad (4.5)$$

Vzhľadom ale na jemnosť vzorkovania (Δt je malá hodnota) a na pomalosť signálov generovaných človekom ($f'(k)$ je tiež malá hodnota) by mala byť výsledná chyba v amplitúde zanedbateľná.

4.2.1 Vyhodnotenie kvality modelov

Kvantifikácia kvality identifikovaného modelu (úspešnosť alebo vierohodnosť modelu do akej miery sa jeho predikcia zhoduje s nameranými dátami, v skratke ME – *Model Efficiency*) je počítaná podľa rovnice

$$ME_{\text{train}} = 1 - \frac{\sum_{k=0}^{N-1} [\hat{f}(k) - f(k)]^2}{\sum_{k=0}^{N-1} [f(k) - \bar{f}]^2}, \quad (4.6)$$

kde $f(k)$ reprezentuje tréningové dáta, \bar{f} je ich stredná hodnota a $\hat{f}(k)$ označuje predikciu modelu. Prostredie MATLAB vyjadruje kvalitu modelu ako *FitPercent*, ktorá sa počíta ako $100(1 - \text{NRMSE})$, kde NRMSE je normalizovaná kvadratická chyba (*normalized root mean squared error*) [26, 27]. ME je možné na základe *FitPercent* vypočítať z rovnice $ME_{\text{train}} = 100 [1 - (1 - \text{FitPercent}/100)^2]$.

Keďže modely vodiča sú identifikované v uzavretej slučke ako systém s dvomi výstupmi, hodnota ME_{train} je počítaná pre dva predikované signály. Pre výber najlepšieho modelu bola preto použitá stredná hodnota obidvoch ME.

Za účelom vyhodnotenia prediktívnych schopností identifikovaných modelov vodičov bola použitá metóda štandardnej krížovej validácie (angl. *crossvalidation*), ktorá delí namerané dáta na K podmnožín. Metóda je popísaná napríklad v publikácii [28] a v oblasti strojového učenia je dobre známa.

V tejto práci sú použité $K = 2$ podmnožiny: $f_1(k)$ a $f_2(k)$. Odstránenie začiatku signálov, prvých dvoch skokov žiadanej hodnoty, bolo prevedené ešte pred tvorbou jednotlivých podmnožín. Následne sa po vytvorení podmnožín identifikujú dva modely tak, aby sa kvalita modelu posudzovala na iných ako tréningových dátach.

1. Prvý model je tréňovaný na podmnožine $f_1(k)$ a validovaný na podmnožine $f_2(k)$,
2. Druhý model je tréňovaný na podmnožine $f_2(k)$ a validovaný na podmnožine $f_1(k)$

Kvantifikácia kvality identifikovaného modelu na validačných dátach je počítaná podľa rovnice

$$ME_{\text{val}} = 1 - \frac{\sum_{k=0}^{N-1} [\hat{f}_m(k) - f_m(k)]^2}{\sum_{k=0}^{N-1} [f_m(k) - \bar{f}_m]^2}, \quad m = 1, 2, \quad (4.7)$$

kde $f_m(k)$ predstavuje validačné dáta a $\hat{f}_m(k)$ signál predikovaný modelom. Vyššie hodnoty parametru ME predstavujú lepšiu úspešnosť predikcie modelu. Ideálna hodnota $ME = 1$ je prirodzene dosiahnutá iba v prípade, ak je predikcia modelu zhodná s validačnými dátami.


4.2.2 Porovnanie priamej a nepriamej identifikačnej metódy

Predchádzajúce publikácie (napríklad [19, 30]), ktoré analyzovali vodičov na simulátore vozidla použitého aj v tejto práci, používali k identifikácii priamu metódu pomocou funkcie `tfest` v prostredí MATLAB. Priama metóda identifikuje parametre modelu iba na základe nameraných signálov vstupu a výstupu modelu vodiča. V prípade McRuerovho modelu 2. rádu (detailne popísaný v kapitole 4.3.1) je to signál regulačnej odchýlky a akčný zásah.

Ako už ale bolo spomenuté v predchádzajúcej podkapitole 4.2, nepriama metóda by mala byť vhodnejšia. Podrobné odvodenie je možné nájsť v [24]. V grafoch na obrázku 4.4 je porovnanie ME McRuerovho modelu 2. rádu pre priamu (`tfest`) a nepriamu (`ssest`) identifikačnú metódu.

V priemere vychádza ME pre regulačnú odchýlku nižšie pre priamu metódu ako pre metódu nepriamu. ME pre akčný zásah je buď približne rovnaké pre obidve

funkcie, alebo je pre priamu metódu mierne vyššie. Problém u priamej metódy ale je, že v niektorých prípadoch v scenároch s veľkou intenzitou poruchy bol identifikovaný nestabilný model vodiča. Na druhej strane, nepriamou metódou bolo na tých istých dátach nájdené stabilné riešenie.



Obr. 4.4: Porovnanie priamej a nepriamej identifikačnej metódy na validačných dátach pre McRuerov model 2. rádu, plné stĺpce reprezentujú ME regulačnej odchýlky, čiarkované stĺpce reprezentujú ME akčného zásahu

4.2.3 Vytvorené identifikačné skripty a ich popis

Keďže neoddeliteľnou súčasťou tejto diplomovej práce sú aj skripty vytvorené v prostredí MATLAB, ktoré boli používané pri spracovaní dát a analýze modelov a ktorých výstupy sú v práci prezentované, je v tejto časti práce uvedený stručný popis tých najdôležitejších skriptov. Všetky vytvorené skripty sú dostupné v elektronickej prílohe, ktorej obsah je popísaný v prílohe D.

Identifikačné skripty:

systIdent.m

Skript pre zvolených vodičov a zvolené scenáre identifikuje všetky modely vodiča na celých nameraných dátach. Identifikované modely sú ukladané pre každého vodiča a každý scenár samostatne do `.mat` súboru.

crossvalidation.m

Skript slúži na identifikáciu modelov za účelom získania ich presnosti. Využíva metódu krížovej validácie pričom merané dáta delí na dve skupiny. Pre zvolených

vodičov a zvolené scenáre identifikuje vždy dva modely, obidva modely aj ich úspešnosť na tréningových aj validačných dátach je uložená do `.mat` súboru. Tento skript umožňuje v jednom čase identifikovať iba jeden typ modelu.

Funkcie:

ssest1.p a **ssest2.p**

Funkcie slúžia k identifikácii zvoleného modelu v stavovom popise. Vstupnými parametrami sú identifikačné dáta (namerané vstupné a výstupné signály), typ identifikovaného modelu (označené číslom 0, 1 a 2), prípadne dopravné oneskorenie modelu. Ak dopravné oneskorenie nie je špecifikované, funkcia otestuje modely s dopravným oneskorením od $d = 4$ po $d = 80$ s krokom 4 a vyberie najlepší model. Funkcia `ssest1.p` slúži na identifikáciu McRuerových modelov 1. a 2. rádu, funkcia `ssest2.p` slúži na identifikáciu Dongesovho modelu statického a Dongesovho modelu s filtrom 1. rádu.

loadData.p

Funkcia slúži na načítanie a predspracovanie identifikačných dát uložených v súbore `.csv`, ktorý je výstupom meraní v simulátore. Vstupnými parametrami je číslo vodiča, číslo scenára, voliteľné parametre sú identifikačný účel a číslo testovanej podmnožiny. Funkcia načíta požadovaný súbor a z meraných dát vypočíta budiaci signál, ktorý nebol meraný. Odstráni prvé 2 skoky žiadanej hodnoty a podľa identifikačného účelu vyberie signály, ktoré v definovanej štruktúre tvoria návratovú hodnotu funkcie. Identifikačný účel môže byť: `'loop'` – identifikácia uzavretej slučky z celých dát, `'plant'` – identifikácia regulovanej sústavy, `'loop-fold'` – rovnaké výstupné signály ako v `'loop'` ale posledný vstupný parameter funkcie (číslo testovanej podmnožiny) určí, ktorá časť dát bude použitá.

compareError.p

Jedná sa o podpornú funkciu pre skript `plotAllTrainingMEs.mat`, ktorá realizuje načítanie a vykresľovanie úspešnosti modelov pre jeden daný scenár a zvolené typy modelov.

globalPlant.p

Viacere vytvorené skripty používajú konštanty `'KC'` pre zosilnenie sústavy, `'d'` pre dopravné oneskorenie sústavy alebo `'maxd'` pre vopred definovaný maximálny počet oneskorení pri identifikácii modelu vodiča. Aby bolo možné ich meniť iba na jednom mieste, táto funkcia slúži na definíciu týchto konštánt. Funkcia vráti pri volaní hodnotu požadovaného parametra regulovanej sústavy na základe vstupného parametra. Prípustné hodnoty sú: `'KC'`, `'d'` a `'maxd'`.

Skripty na vykresľovanie grafov:

plotModelVsData.m

Skript pre zvoleného vodiča, scenár a časové okno vykreslí 3 grafy. Priebeh žiadanej hodnoty a skutočného výstupu sústavy, porovnanie nameranej a modelovanej

regulačnej odchýlky pre všetky modely, priebeh nameraného a modelovaného akčného zásahu pre všetky modely. Predikcia modelov je realizovaná na validačných dátach.

plotModelParameters.m

Skript pre zvolený typ modelu, zvolený rozsah vodičov a scenárov extrahuje z diskretného stavového modelu jednotlivé parametre modelu človeka. Parametre sú prepočítané na spojité ekvivalenty a vykreslené do grafu. Priemerné hodnoty parametrov sú spolu s intervalom hodnôt, kde sa daný parameter nachádza s pravdepodobnosťou 95 % vypísané do konzoly.

plotAllCrossValMEs.m

Skript slúži na vykreslenie úspešnosti modelov na validačných dátach. Pre každý scenár je vykreslená ME regulačnej odchýlky a ME akčného zásahu modelov pre každého vodiča. Do posledného grafu sú vykreslené priemerné ME naprieč všetkými vodičmi, zvlášť pre oba modelované signály aj celková ME daného modelu, ktorá vznikne priemerom ME obidvoch modelovaných signálov.

plotFilterGraphs.m

Skript vykreslí príklad filtrovaných poruchových signálov (bieleho šumu aj PRBS) a zobrazí amplitúdovú frekvenčnú charakteristiku implementovaných filtrov poruchového signálu.

plotAllTrainingMEs.m

Skript pre všetky scenáre vykreslí úspešnosť všetkých modelov na tréningových dátach. Plné stĺpce odpovedajú ME regulačnej odchýlky, čiarkované stĺpce odpovedajú ME akčného zásahu.

V skriptoch je pri vykresľovaní používaná aj prebratá funkcia `hatch.m`, ktorá je dostupná na stránke [29].

4.3 Analyzované modely vodiča

Nasledujúca podkapitola popisuje skúmané modely vodiča aplikované na namerané dáta. Práca porovnáva dva prístupy k modelovaniu vodiča: SISO modely s jedinou prenosovou funkciou a rozvetvené modely s viacerými vstupmi a jedným výstupom.

4.3.1 Modely s jednou prenosovou funkciou

Tieto modely sú založené na teórii McRuerových crossover modelov [2], kedy operátor prispôsobuje svoje vlastnosti tak, aby v otvorenej slučke vznikol optimálny prenos $\omega_r/p \cdot e^{-\tau p}$. Tieto modely majú iba jeden vstup, ktorým je regulačná odchýlka $e(k)$.

V rámci tejto skupiny modelov boli analyzované dve štruktúry: McRuerov model 1. rádu a McRuerov model 2. rádu.


McRuerov model 1. rádu:

McRuerov model 1. rádu bol pri identifikácii v stavovom popise implementovaný štruktúrou zobrazenou na obrázku 4.5. Model predstavuje filter 1. rádu nasledovaného diferenciou a dopravným oneskorením. Uvedenú blokovú schému je možné vyjadriť vo forme diskkrétnej prenosovej funkcie

$$F_R(z) = \frac{b_1(1 - z^{-1})}{1 - a_1z^{-1}}z^{-d}, \quad (4.8)$$

ktorú je možné za použitia tvarovača nultého rádu previesť na jej spojité ekvivalent (4.9).

$$F_R(p) = \frac{K_{Rp}}{T_R p + 1} e^{-\tau p} \quad (4.9)$$



Obr. 4.5: McRuerov model 1. rádu

Spojité ekvivalenty jednotlivých prenosov a filtrov sú použité pre lepšiu čitateľnosť prezentovaných výsledkov.


McRuerov model 2. rádu:

Na obrázku 4.6 je zobrazená použitá štruktúra McRueorovho modelu 2. rádu. Model je tvorený filtrom 2. rádu nasledovaný diferenciou a dopravným oneskorením. Uvedenú štruktúru modelu je možné vyjadriť vo forme diskkrétnej prenosovej funkcie

$$F_R(z) = \frac{b_1(1 - z^{-1})}{1 - a_1z^{-1} - a_2z^{-2}}z^{-d}, \quad (4.10)$$

ktorú je možné za použitia tvarovača nultého rádu previesť na jej spojité ekvivalent (4.11).

$$F_R(p) = \frac{K_{Rp}}{T_R^2 p^2 + 2\xi T_R p + 1} e^{-\tau p} \quad (4.11)$$



Obr. 4.6: McRuerov model 2. rádu

Tento tvar prenosu sa v minulosti ukazoval ako vhodný pre popis ľudského operátora regulujúceho tento typ sústavy na základe viacerých experimentov analyzovaných na FEKT (napríklad [19, 30]).


4.3.2 Rozvetvené modely

Analyzované rozvetvené modely vodiča vychádzajú z teórie popísanej v [6]. Na rozdiel od ich modelu vodiča popísaného v kapitole 1.1 je v tejto práci použitý mierne upravený model. V realizovanom experimente pri jazde po rovnej diaľnici nie je prítomný signál, ktorý by reprezentoval zakrivenie cesty, preto bola táto regulačná slučka odstránená. Vodič sa taktiež nemá držať iba v jednom jazdnom pruhu, ale má prechádzať z pruhu do pruhu podľa pokynov, ktoré predstavujú žiadanú hodnotu. Táto žiadaná hodnota vstupuje do rozdielového člena, kde je od nej odčítaná aktuálna poloha auta.

Hlavným znakom modelu je, že vstupom sú obidva stavy regulovanej sústavy (vozidla). Jedná sa o aktuálnu polohu vozidla na ceste $y(k)$ a jeho aktuálne natočenie $\Psi(k)$. Identifikované boli dve varianty modelu: Statický Dongesov model a Dongesov model s filtrom 1. rádu.

Statický Dongesov model:

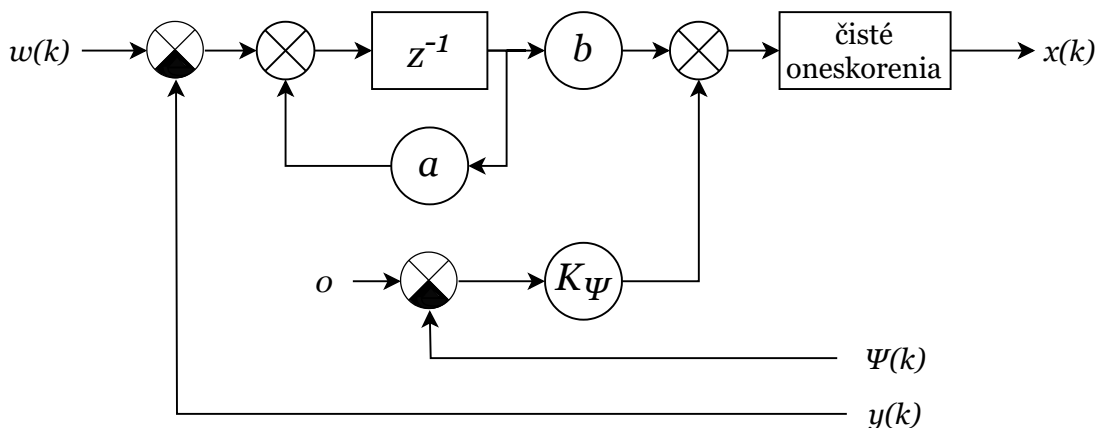
Bloková schéma statického Dongesovho modelu je zobrazená na obrázku 4.7. Model tvoria dve statické zosilnenia: K_Y , ktoré násobí chybu v polohe a K_Ψ , ktoré násobí chybu v natočení. Tieto signály sa sčítajú a po prirátaní dopravného oneskorenia tvoria akčný zásah operátora. Model teda neobsahuje žiadnu ďalšiu dynamiku.



Obr. 4.7: Statický Dongesov model

Dongesov model s filtrom 1. rádu:

Štruktúra Dongesovho modelu s filtrom 1. rádu je zobrazená na obrázku 4.8. Na rozdiel od statického Dongesovho modelu má regulačná slučka so spätnou väzbou od polohy za rozdielovým členom zaradený filter 1. rádu. Signál je po filtrovaní násobený diskretným zosilnením b a sčítaný s príspevkom od regulačnej slučky natočenia auta, ktorá ostala nezmenená. Výsledok po prirátaní dopravného oneskorenia tvorí výsledný akčný zásah vodiča.



Obr. 4.8: Dongesov model s filtrom 1. rádu

Pre lepšiu čitateľnosť prezentovaných výsledkov je diskretný filter 1. rádu prepočítaný pri uvažovaní tvarovača nultého rádu na jeho spojitý ekvivalent podľa rovnice (4.12).

$$F_d(z) = \frac{b}{z - a} \iff F_c(p) = \frac{K_Y}{Tp + 1}. \quad (4.12)$$

5 Získané výsledky


Kapitola prezentuje získané výsledky identifikácie zvolených modelov vodiča na nameraných dátach. V prvej časti je uvedená úspešnosť jednotlivých modelov na validačných dátach, následne sú prezentované konkrétne hodnoty parametrov analyzovaných modelov a príklady modelovaných signálov v porovnaní s nameranými dátami z experimentov. V závere kapitoly sa nachádza zhrnutie a zhodnotenie dosiahnutých výsledkov.

5.1 Úspešnosť jednotlivých modelov na validačných dátach

Grafy na obrázkoch 5.1, 5.2 a 5.3 prezentujú úspešnosť jednotlivých modelov na validačných dátach. Úspešnosť pre každého vodiča je počítaná ako priemer úspešnosti dvoch natrénovaných modelov (ktoré vznikli na základe metódy krížovej validácie s dvomi podmnožinami).

Graf na obrázku 5.1 ukazuje dosiahnutú ME modelov pre jednotlivých vodičov pri modelovaní signálu regulačnej odchýlky. V tomto prípade vykazujú všetky analyzované modely vysokú ME pri prvých dvoch scenároch. V scenári 1 sú všetky modely prakticky zhodné, v 2. scenári je ale viditeľný pokles ME u obidvoch McRuerových modelov. Pre scenáre 3 a 4 klesá ME ako aj u Dongesových modelov, tak aj u McRuerových modelov. Prepad u McRuerových modelov je ale oveľa výraznejší, v poslednom scenári je model regulačnej odchýlky už nepoužiteľný, zatiaľ čo Dongesove modely dosahujú stále relatívne vysoké hodnoty ME.


Graf na obrázku 5.2 ukazuje dosiahnutú ME modelov pre jednotlivých vodičov pri modelovaní signálu akčného zásahu vodiča. V tomto prípade je ME všeobecne nižšia ako pri modelovaní regulačnej odchýlky. Ukazuje sa, že McRuerov model 2. rádu je na tento účel použiteľný iba pri scenári bez pôsobiaceho šumu, s horšou presnosťou aj pre scenár číslo 2. V ostatných scenároch modelovanie zlyháva, McRuerov model 1. rádu nebol schopný aproximovať merané dáta akčného zásahu ani v jednom scenári. Na druhej strane, Dongesov model vykazuje relatívne dobrú ME vo všetkých testovaných scenároch. Dongesov model s filtrom 1. rádu má vo väčšine prípadov lepšiu ME ako statický Dongesov model, v scenároch s pôsobiacim šumom má dokonca vyššiu ME ako v scenári bez šumu.




Obr. 5.1: Úspešnosť modelov (ME) na validačných dátach pri predikcii signálu regulačnej odchýlky

Na obrázku 5.3 sú zobrazené priemerné ME pre regulačnú odchýlku a akčný zásah, ktoré boli spočítané ako aritmetický priemer z úspešností modelov jednotlivých vodičov. Je tu vykreslená aj celková ME daného modelu, ktorá vznikne priemerom ME regulačnej odchýlky a ME akčného zásahu. Výsledky ukazujú, že Dongesove modely majú približne rovnakú úspešnosť pre prvé 3 scenáre, v poslednom scenári je ME nižšia. Úspešnosť McRuerových modelov však s narastajúcim pôsobiacim šu-

mom veľmi rýchlo klesá. Dongesov model 1. rádu prekonáva statický Dongesov model vo všetkých scenároch. Zaujímavé ale je, že statický Dongesov model má v scenároch 2 až 4 lepšiu ME ako McRuerov model 2. rádu, ale pritom je jednoduchší (má menej parametrov).



Obr. 5.2: Úspešnosť modelov (ME) na validačných dátach pri predikcii akčného zásahu vodiča



Obr. 5.3: Priemerná úspešnosť modelov (ME) na validačných dátach

5.2 Identifikované hodnoty parametrov jednotlivých modelov

V nasledujúcej podkapitole je diskusia k identifikovaným hodnotám parametrov jednotlivých modelov a grafy hodnôt parametrov v závislosti na testovaných vodičoch a scenároch. Prezentované parametre boli extrahované zo stavového modelu, ktorý bol trénovaný na celých nameraných dátach. Diskrétné parametre modelov sú pre jednoduchšiu interpretáciu prepočítané na ich spojité ekvivalenty.

V texte sú prezentované výsledky parametrov jednak pre každého vodiča zvlášť, ako aj výsledné priemerné hodnoty naprieč všetkými vodičmi. Pre každý parameter je uvedený interval hodnôt, kde sa identifikovaná veličina nachádza s pravdepodobnosťou 95 %. Napríklad pre parameter K_Y Dongesovho modelu [31]:

$$K_Y = \overline{K_Y} \pm U(K_Y) \quad (5.1)$$

kde

$$\overline{K_Y} = \frac{1}{N} \sum_{i=1}^N K_{Yi} \quad (5.2)$$

$$U(K_Y) = 2 \cdot u_A(K_Y) = 2 \cdot \sqrt{\frac{1}{N(N-1)} \sum_{i=1}^N (K_{Yi} - \overline{K_Y})^2} \quad (5.3)$$

Interval spoľahlivosti sa počíta iba na základe štandardnej neistoty typu A, štandardná neistota typu B sa zanedbáva, pretože ju nie je možné spoľahlivo určiť.

5.2.1 Dongesove modely

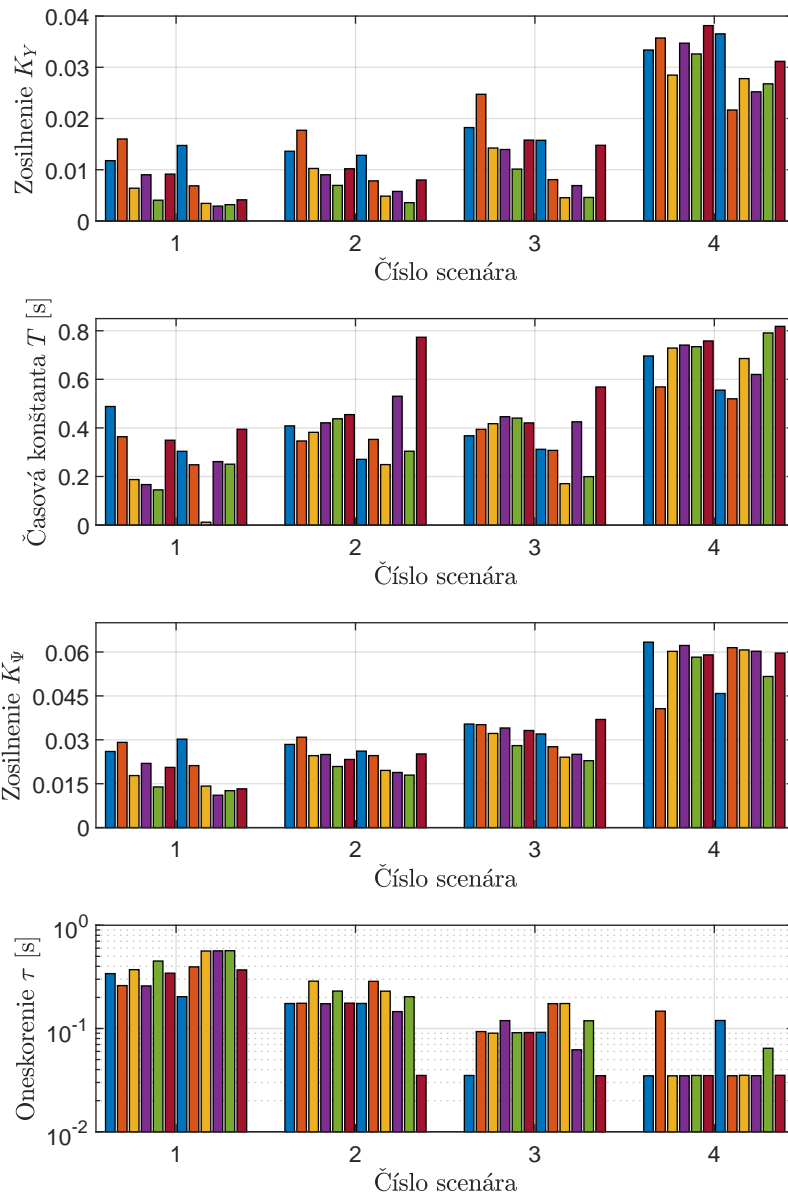
Identifikované parametre Dongesovho modelu s filtrom 1. rádu pre každého vodiča sú zobrazené v grafe na obrázku 5.4, v tabuľke 5.1 sú vypísané priemerné hodnoty parametrov pre jednotlivé scenáre. Pre jednoduchšiu interpretáciu výsledkov bol diskretný filter 1. rádu s koeficientom a a zosilnením b prepočítaný na jeho spojité ekvivalent s časovou konštantou T a zosilnením K_Y .

Tab. 5.1: Identifikované hodnoty parametrov Dongesovho modelu s filtrom 1. rádu

Číslo scenára	K_Y	T [s]	K_Ψ	τ [s]
1	$0,0076 \pm 0,0026$	$0,26 \pm 0,08$	$0,019 \pm 0,004$	$0,39 \pm 0,08$
2	$0,0092 \pm 0,0023$	$0,41 \pm 0,09$	$0,0238 \pm 0,0023$	$0,19 \pm 0,04$
3	$0,013 \pm 0,004$	$0,37 \pm 0,07$	$0,0305 \pm 0,0028$	$0,098 \pm 0,026$
4	$0,0310 \pm 0,0029$	$0,68 \pm 0,06$	$0,057 \pm 0,005$	$0,054 \pm 0,023$

Výsledky naznačujú, že zosilnenia K_Y a K_Ψ sa zvyšujú s narastajúcou intenzitou poruchového signálu. Toto zistenie je v súlade s výsledkami publikovanými v [32], kde bol realizovaný odlišný experiment s pôsobiacou poruchou. Príčinou by mohlo byť, že vodič zrejme potrebuje väčší akčný zásah pre vykompenzovanie pôsobiacej poruchy. Časová konštanta filtra T ostáva približne na rovnakých hodnotách v prvých troch scenároch, avšak v poslednom scenári jej hodnota viditeľne vzrastie. Táto skutočnosť môže súvisieť s typom poruchového signálu, náhodná porucha vzniknutá filtráciou bieleho šumu v scenároch 2 a 3 neovplyvňuje tento parameter do takej miery ako filtrovaný PRBS signál v scenári 4, ktorý je do veľkej miery predikovatelný a preto sa naň vodič môže adaptovať.

Identifikované parametre pre Dongesov model 1. rádu



Obr. 5.4: Identifikované hodnoty parametrov pre Dongesov model s filtrom 1. rádu

Dopravné oneskorenie vodiča τ relatívne výrazne klesá s narastajúcim poruchovým signálom. Nastýkajú sa dve možné vysvetlenia: 1) Vodič sa v scenároch, kde sa po dlhú dobu od neho neočakáva žiadna reakcia, unaví alebo nudí, čo má za následok pomalšie reakcie pri požiadavku na zmenu jazdného pruhu. 2) Pri silnejšej pôsobiacej poruche musí vodič neustále reagovať volantom, akčný zásah teda nemá ustálené obdobie pred zmenou jazdného pruhu ako je tomu v scenári 1. Vtedy môže byť ťažké rozlíšiť medzi čistým oneskorením vodiča a jeho dynamikou, a tak by napríklad menšie oneskorenie τ mohlo byť kompenzované väčšou časovou konštantou T alebo zosilnením. V grafe na obrázku 5.4 je možné si všimnúť, že tam kde je

identifikované dopravné oneskorenie τ väčšie, bola odpovedajúca časová konštanta T nižšia a naopak.

Identifikované hodnoty parametrov pre každého vodiča pre statický Dongesov model sú v prílohe B na obrázku B.1. V tabuľke 5.2 sú uvedené priemerné hodnoty parametrov pre jednotlivé scenáre.

Zmeny jednotlivých parametrov medzi scenármi kopírujú trendy z Dongesovho modelu s filtrom 1. rádu. Zosilnenia K_Y a K_Ψ sa zvyšujú s intenzitou poruchového signálu, dopravné oneskorenie τ sa s narastajúcou intenzitou poruchy znižuje.

Opäť je ale možné pozorovať istú tendenciu nejednoznačnosti parametrov, hlavne v poslednom scenári, kedy sa výrazné navýšenie dopravného oneskorenia τ prejaví znížením zosilnenia K_Ψ u daného vodiča.

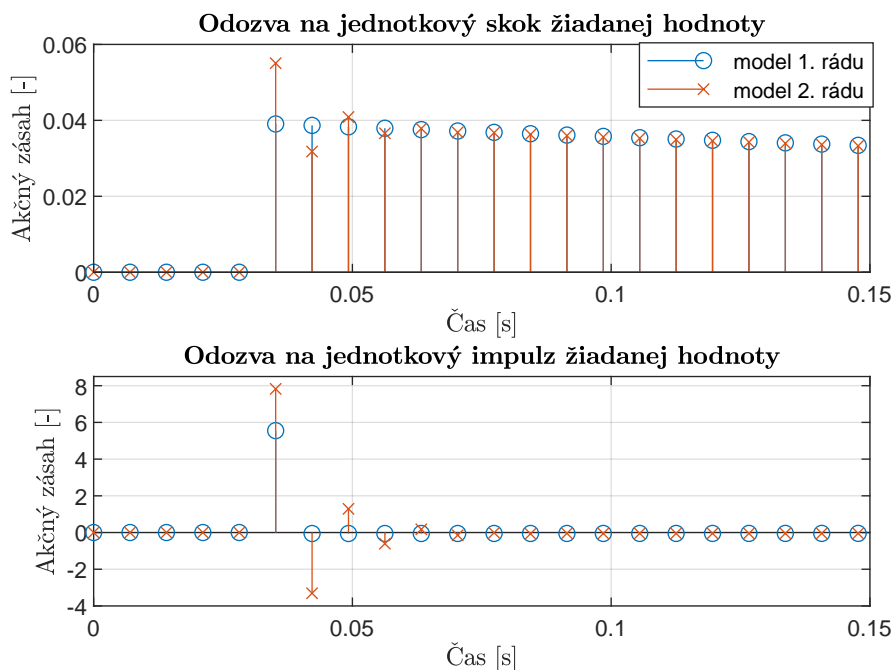
Tab. 5.2: Identifikované hodnoty parametrov statického Dongesovho modelu

Číslo scenára	K_Y	K_Ψ	τ [s]
1	$0,0057 \pm 0,0016$	$0,0155 \pm 0,0024$	$0,46 \pm 0,07$
2	$0,0065 \pm 0,0015$	$0,0177 \pm 0,0015$	$0,23 \pm 0,05$
3	$0,0096 \pm 0,0021$	$0,0256 \pm 0,0013$	$0,089 \pm 0,025$
4	$0,0183 \pm 0,0021$	$0,047 \pm 0,006$	$0,061 \pm 0,027$

5.2.2 McRuerove modely

Na obrázku 5.6 sú v grafoch vykreslené identifikované hodnoty parametrov McRuerovho modelu 2. rádu pre každého vodiča, v tabuľke 5.3 sú uvedené priemerné hodnoty pre jednotlivé scenáre. Parametre pre 4. scenár tu nie sú uvedené, pretože model degradoval na diskretný systém bez spojitého ekvivalentu nasledovaný systémom 1. rádu.

Na obrázku 5.5 je príklad odozvy akčného zásahu McRuerových modelov v scenári 4 na jednotkový skok a jednotkový impulz žiadanej hodnoty. Vykreslený je len detail na začiatku prechodového deja, pretože na zvyšnej časti prechodovej charakteristiky sú priebehy oboch modelov prakticky zhodné. U modelu 2. rádu sú vidno kmity, ktoré s každou vzorkou menia polaritu pri porovnaní s modelom 1. rádu. Po odznení tohto prechodového javu, ktorý trvá približne 5 vzorkovacích periód, sú už výstupy modelov totožné.



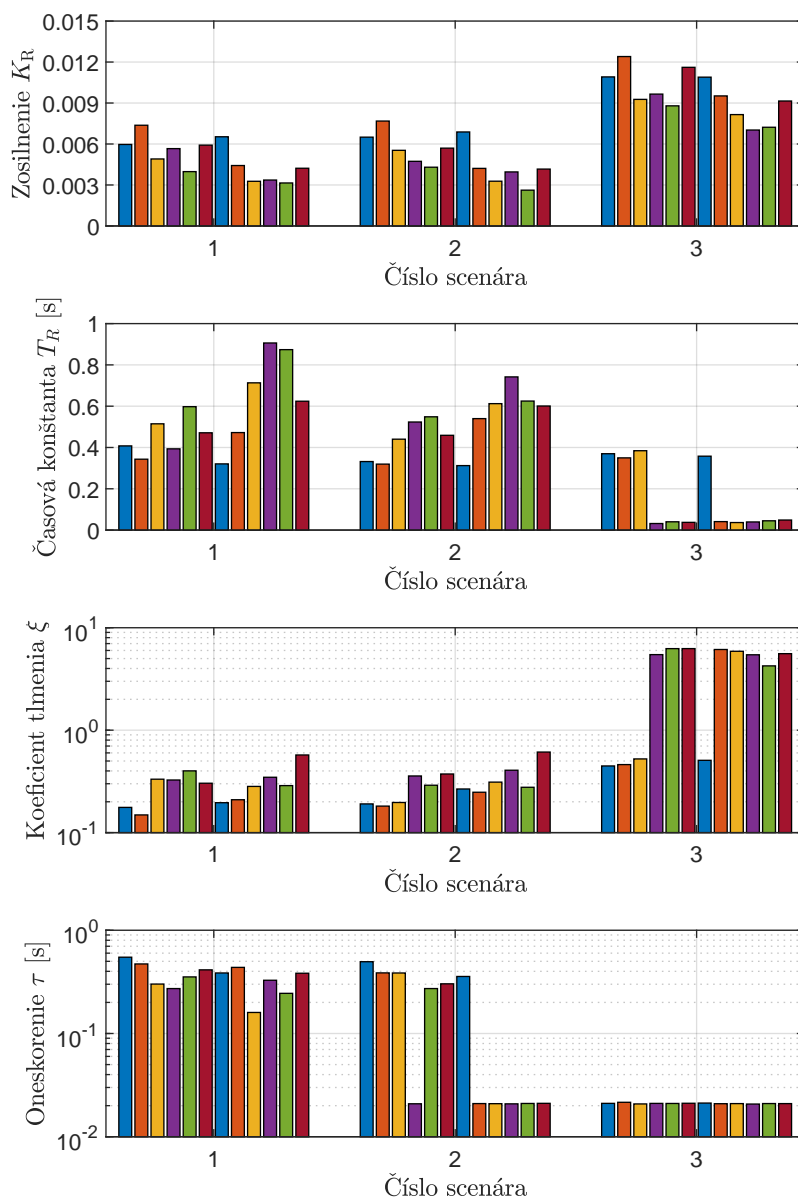
Obr. 5.5: Odozva akčného zásahu McRuerových modelov identifikovaných v scenári 4 na skok a impulz žiadanej hodnoty

Tu je vhodné spomenúť, že ak bol model v scenári 3 identifikovaný na celých nameraných dátach, tak výsledok bolo možné transformovať na spojitý ekvivalent pre všetkých vodičov. V prípade modelov identifikovaných pomocou krížovej validácie pri rozdelení dát na dve podmnožiny ale niektoré identifikované modely nebolo možné previesť do spojitaj oblasti, tak ako to nastalo v scenári 4.

Tento model má v prvých dvoch scenároch takmer rovnaké hodnoty identifikovaných parametrov zosilnenia K_R , časovej konštanty T_R a koeficientu tlmenia ξ . Môže to byť spôsobené tým, že tento model je necitlivý na vstupujúcu poruchu a preto je výsledok v podstate rovnaký. Vstupujúca porucha v scenári 2 nie je veľmi výrazná, preto sa necitlivosť modelu výrazne neprejavila v jeho hodnotení kvality ME (obrázky 5.1, 5.2 a 5.3). Výnimkou je dopravné oneskorenie τ , ktoré bolo v scenári 2 v polovici prípadov identifikované približne o rád menšie ako v scenári 1.

Diskutabilný je význam hodnôt parametrov v scenári 3, keďže tu už model nebol schopný modelovať reakcie ľudského vodiča. Minimálne je zaujímavé podotknúť, že opäť došlo pri identifikácii k istej zámennosti alebo zviazanosti jednotlivých parametrov. Všimnime si hodnoty časovej konštanty T_R a koeficientu tlmenia ξ . Výrazné navýšenie jedného parametra je kompenzované prudkým poklesom druhého a naopak. Naznačuje to, že tieto parametre nemusia byť za daných okolností úplne nezávislé a k tomu istému výsledku je možné sa dopracovať viacerými spôsobmi.

Identifikované parametre pre McRuerov model 2. rádu



Obr. 5.6: Identifikované hodnoty parametrov pre McRuerov model 2. rádu

Tab. 5.3: Identifikované hodnoty parametrov McRuerovho modelu 2. rádu

Číslo scenára	K_R	T_R [s]	ξ	τ [s]
1	$0,0049 \pm 0,0008$	$0,55 \pm 0,12$	$0,30 \pm 0,07$	$0,36 \pm 0,07$
2	$0,0050 \pm 0,0009$	$0,50 \pm 0,08$	$0,31 \pm 0,07$	$0,19 \pm 0,11$
3	$0,0096 \pm 0,0011$	$0,1 \pm 0,1$	$3,9 \pm 1,5$	$0,0210 \pm 0,0001$

Pre kompletnosť prezentovaných výsledkov sú v prílohe B v tabulke B.1 a na ob-

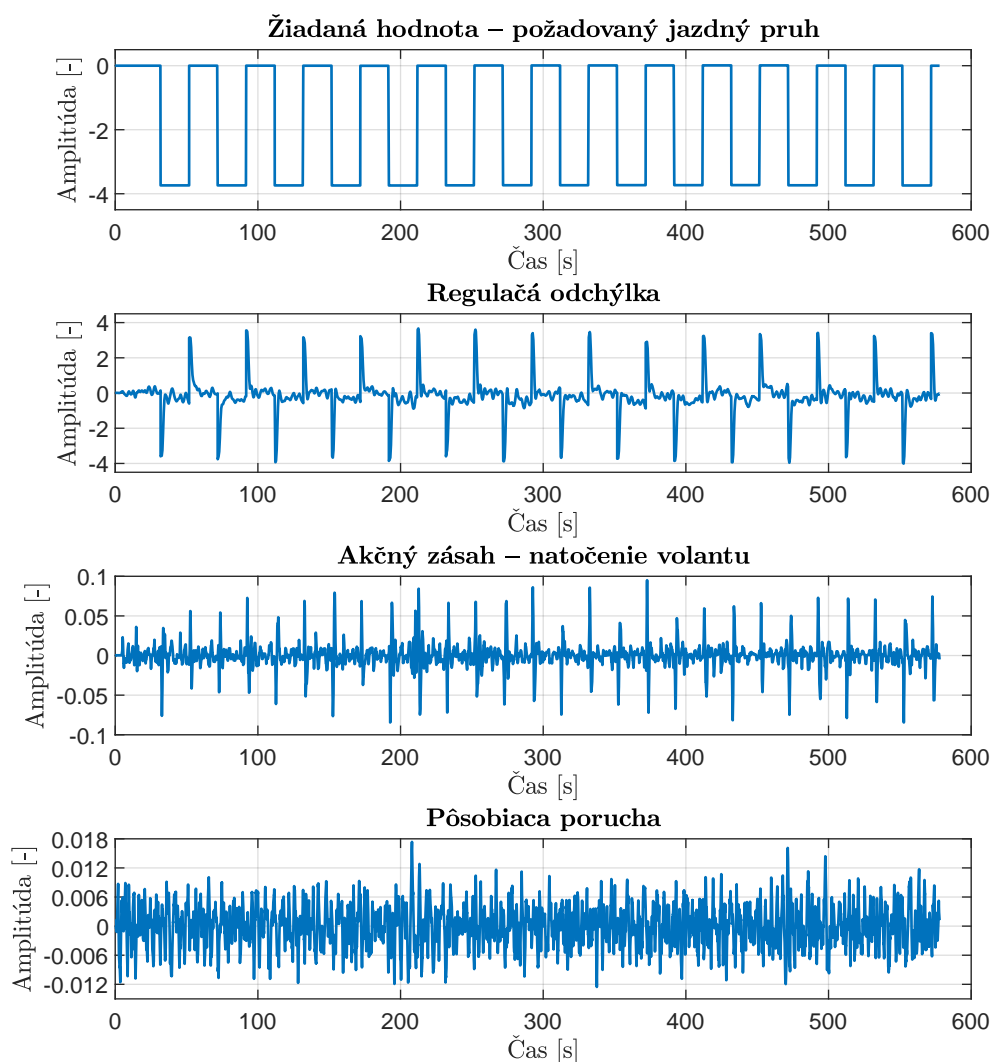
rázku B.2 v grafoch prezentované identifikované parametre McRuerovho modelu 1. rádu. Diskusia o zmenách parametrov medzi jednotlivými scenármi však nebude uvedená, pretože tento model je na základe krížovej validácie (obrázok 5.3) použiteľný iba pre scenár bez pôsobiaceho šumu. Navyše aj v tomto scenári výrazne zaostáva za zvyšnými analyzovanými modelmi. V ostatných scenároch tento model akcie ľudského vodiča nedokáže vystihnúť, preto je aj analýza identifikovaných parametrov v týchto scenároch bezpredmetná. Zaujímavé by mohli byť parametre identifikované vo 4. scenári, pretože McRuerov model 2. rádu pri identifikácii prakticky degradoval na McRuerov model 1. rádu, odozvy týchto dvoch modelov v scenári 4. boli prakticky totožné.

Literatúra získané výsledky potvrdzuje, keďže sa už minimálne od roku 1961 [33] používa pre obdobné prípady prenosová funkcia minimálne 2. rádu. Na takúto prenosovú funkciu sa odkazujú aj v [34] alebo [19, 35].

5.3 Príklady meraných a modelovaných signálov

V nasledujúcej časti práce sú prezentované príklady nameraných signálov z experimentov a ich porovnanie s predikciou jednotlivých modelov vodiča. Porovnanie meraných a modelovaných signálov bolo realizované na validačných dátach s modelmi, ktoré boli trénované pomocou metódy krížovej validácie. Prezentovaný model je trénovaný na 1. podmnožine a porovnávaný na dátach z 2. podmnožiny.

V grafoch na obrázku 5.7 sú znázornené priebehy meraných signálov v celej dĺžke jedného experimentu. Pretože experiment je relatívne dlhý (každá jazda má necelých 10 minút), budú pre lepšiu prehľadnosť v nasledujúcich grafoch zobrazené prevažne časové výseky signálov. V rámci textu práce sú v grafoch porovnávané iba modely so štyrmi parametrami, konkrétne sa jedná o Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu. V prílohe C sú dostupné priebehy pre statický Dongesov model a McRuerov model 1. rádu, ako aj ďalšie príklady priebehov pre Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu.



Obr. 5.7: Namerané dáta z celej dĺžky experimentu – experiment s pôsobiacim bieleym šumom filtrovaným filtrom 4. rádu


Scenár bez pôsobiacej poruchy:

V grafoch na obrázkoch 5.8, C.1, C.2, C.6 a C.7 je zobrazený časový výrez z nameraných signálov pri experimente bez pôsobiaceho šumu. Spoločne s meraným priebehom je tu zobrazený aj modelovaný priebeh generovaný daným modelom vodiča.

V tomto prípade sú výstupy Dongesovho modelu s filtrom 1. rádu aj McRuerovho modelu 2. rádu takmer identické a dosahujú relatívne vysokú zhodu s meranými dátami. Vo väčšine prípadov v scenári 1 je teda možné vodiča modelovať aj Dongesovým modelom s filtrom 1. rádu aj McRuerovým modelom s prenosovou funkciou 2. rádu.

Veľmi dobrú aproximáciu dosahuje aj statický Dongesov model. Jeho nedostatok ale nastáva pri skokovej zmene žiadanej hodnoty, kedy sa v akčnom zásahu taktiež objaví skoková zmena, ktorá u reálneho vodiča nenastáva. Uvedený záver je logický, keďže model neobsahuje žiadnu dynamiku, ktorá by skok v signáli filtrovala.

Najmenej kvalitnú aproximáciu dosahuje McRuerov model 1. rádu. Nedokáže vhodne popísať akčný zásah vodiča, pri skokovej zmene žiadanej hodnoty sa v signáli navyše objavuje veľmi výrazný skok spôsobený deriváciou v čitateli prenosovej funkcie, ktorá nie je kompenzovaná dostatočne vysokým rádom menovateľa.



Obr. 5.8: Priebehy meraných a modelovaných signálov – scenár 1, vodič 3

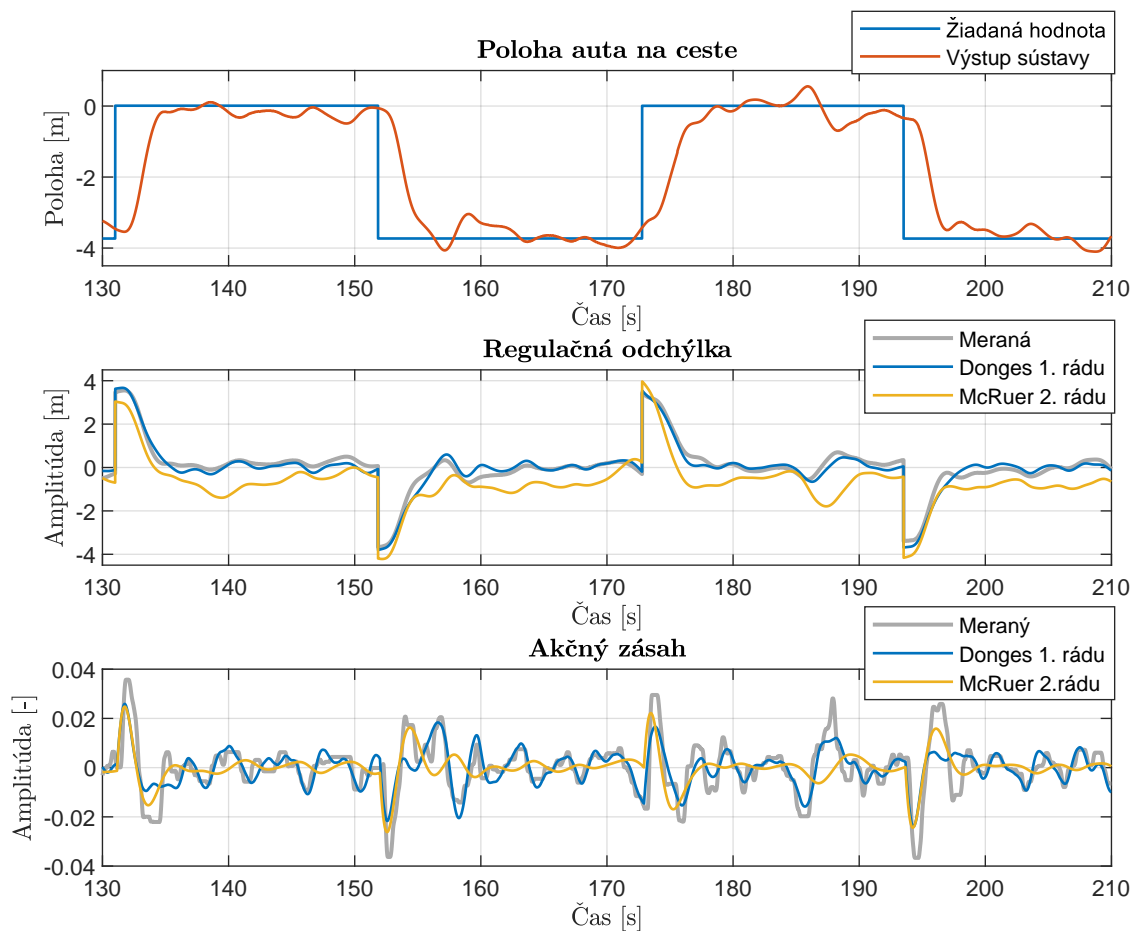
Je nutné spomenúť, že nastali aj prípady, kde ani jeden z analyzovaných modelov nebol schopný akcie vodiča aproximovať. Takáto situácia nastala napríklad pri vodičovi 9 a 10, z priebehov signálov (obrázky C.2 a C.7) je zjavná malá zhoda s meraným akčným zásahom, ktorá sa ukázala už pri hodnotení kvality modelov ME (obrázok 5.2). Výsledok je zrejme daný veľmi bohatým akčným zásahom, ktorý je viac podobný na akčný zásah pri pôsobiacej poruche, čo môže byť dané spôsobom

riadenia vozidla a taktiež neschopnosťou týchto vodičov navyknúť si na simulátor a v ňom implementovaný model vozidla.

Scenár s pôsobiacim bielym šumom filtrovaným filtrom 4. rádu:

Priebehy modelovaných signálov pre Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu sú zobrazené na obrázkoch 5.9 a C.3, statický Dongesov model a McRuerov model 1. rádu je zobrazený na obrázkoch C.8 a C.9.

McRuerov model 2. rádu aj v tomto scenári dosahuje vysokú zhodu s meranými dátami, ale z grafov na obrázkoch 5.9 a C.3 je vidno, že akčný zásah nevystihuje reakciu vodiča na poruchu, ale skôr jeho strednú hodnotu. Keďže v tomto scenári nie je porucha veľmi výrazná, tak výsledok nemá až taký dopad na celkovú ME modelu. Navyše, už pri nízkej intenzite poruchy sa začína rozchádzať meraná a modelovaná regulačná odchýlka. Odozvy McRuerovho modelu 1. rádu sú prakticky rovnaké ako v scenári 1, charakterizované prudkým skokom pri zmene žiadanej hodnoty a bez vystihnutia reakcie vodiča.

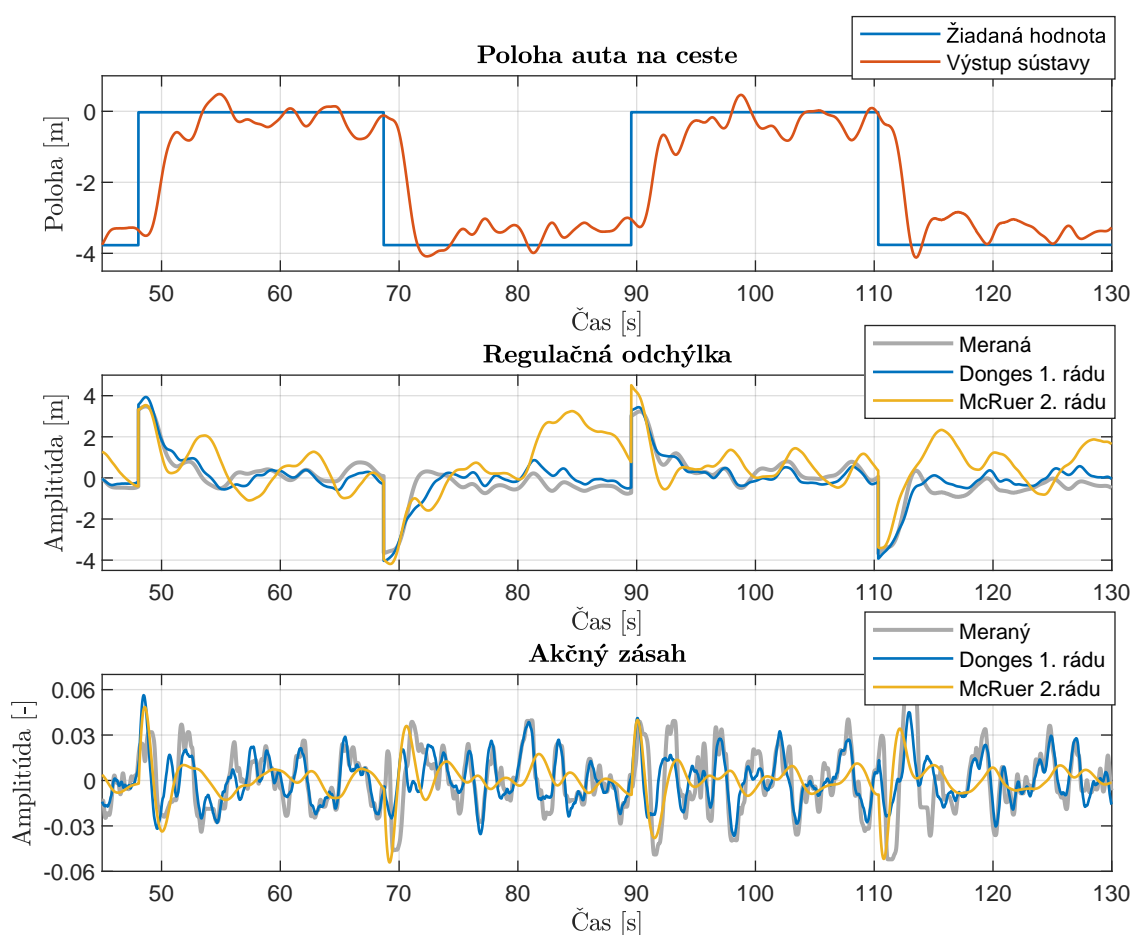


Obr. 5.9: Priebehy meraných a modelovaných signálov – scenár 2, vodič 6

Už v tomto scenári s miernou poruchou prekonávajú obidva Dongesove modely oba McRuerove modely. Dokážu veľmi presne vystihnúť aj reakcie človeka na pôsobiacu poruchu. V prípade Dongesovho modelu s filtrom 1. rádu je odozva na skok žiadanej hodnoty porovnateľná s McRuerovým modelom 2. rádu. Obdobne sa správa aj statický Dongesov model, ale s mierne nižšou zhodnosťou s meranými dátami. Znovu nastáva problém so skokovou zmenou akčného zásahu pri skokovej zmene žiadanej hodnoty.

Scenár s pôsobiacim bielym šumom filtrovaným filtrom 2. rádu:

Priebehy modelovaných signálov v scenári 3 pre Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu sú zobrazené na obrázkoch 5.10 a C.4, statický Dongesov model a McRuerov model 1. rádu je zobrazený na obrázkoch C.10 a C.11.



Obr. 5.10: Priebehy meraných a modelovaných signálov – scenár 3, vodič 3

Predikcia Dongesovho modelu s filtrom 1. rádu je aj v tomto scenári s vysokou intenzitou pôsobiaceho šumu veľmi kvalitná. Model dokáže verne kopírovať reakcie

vodiča na pôsobiacu poruchu, pričom si zachováva aj hodnovernú aproximáciu reakcie na zmenu jazdného pruhu. Predikcia signálu regulačnej odchýlky je aj v tomto prípade dostatočne kvalitná.

Podobne je na tom aj statický Dongesov model, ktorý dokáže presne modelovať reakcie vodiča na pôsobiaci poruchový signál. Taktiež vystihuje aj regulačnú odchýlku takmer s rovnakou kvalitou ako Dongesov model s filtrom 1. rádu. Nedostatok modelu je horšia aproximácia reakcie vodiča na zmenu požadovaného jazdného pruhu.

Na druhej strane McRuerove modely už pri poruche s väčšou intenzitou zlyhávajú. McRuerov model 2. rádu dokáže v akčnom zásahu aproximuje iba reakciu na zmenu jazdného pruhu, kompenzáciu poruchy takmer vôbec nevystihuje. Značne nekvalitná je aj aproximácia regulačnej odchýlky, ktorá sa už výrazne vzďaľuje od nameraných priebehov. McRuerov model 1. rádu nedokáže vhodne popísať v akčnom zásahu ani reakciu na zmenu žiadaného pruhu, pri regulačnej odchýlke je jeho predikcia približne rovnaká ako McRuerovho modelu 2. rádu.


Scenár s pôsobiacim PRBS signálom filtrovaným filtrom 4. rádu:

Príklady nameraných a modelovaných signálov v scenári 4 pre Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu sú zobrazené na obrázkoch 5.11 a C.5, statický Dongesov model a McRuerov model 1. rádu je zobrazený na obrázkoch C.12 a C.13.

Výstupy oboch McRuerových modelov sú prakticky totožné. Rozdiely nastanú iba v akčnom zásahu pri zmene žiadaného jazdného pruhu, kde sú u modelu 2. rádu prítomné zákmity spôsobené diskretnou prenosovou funkciou bez spojitého ekvivalentu, zatiaľ čo u modelu 1. rádu zákmity nenastávajú. Výsledok identifikácie modelu 2. rádu je teda prakticky to isté ako výsledok identifikácie modelu 1. rádu.

McRuerove modely v tomto scenári nedokážu vystihnúť akčný zásah vodiča, obsahujú pre človeka netypický skok v akčnom zásahu pri skokovej zmene žiadanej hodnoty. Na pôsobiaci filtrovaný PRBS signál modely reagujú značnými kmitmi, ktoré sa v meraných dátach nevyškytujú. Predikcia signálu regulačnej odchýlky sa s meranými dátami nezhoduje vôbec.

Dongesove modely dosahujú v scenári 4 taktiež značne nižšiu kvalitu predikcie v porovnaní s predchádzajúcimi scenármi. Oba modely vo väčšine prípadov nedokážu vystihnúť namerané rýchle kmity v akčnom zásahu, aj napriek tomu však akcie vodiča aproximujú relatívne kvalitne. Oproti McRuerovým modelom lepšie prezentujú aspoň strednú hodnotu akčného zásahu. Predikcia signálu regulačnej odchýlky Dongesových modelov dosahuje tiež horších výsledkov ako v scenároch 1 až 3, stále však neporovnateľne kvalitnejšia oproti McRuerovým modelom.



Obr. 5.11: Priebehy meraných a modelovaných signálov – scenár 4, vodič 12

5.4 Zhrnutie a zhodnotenie výsledkov

Analyzované boli 4 modely vodiča, identifikované na nameraných dátach v štyroch scenároch s rôznou intenzitou a typom poruchového signálu. V kapitole sa vyhodnocovala úspešnosť modelov pomocou krížovej validácie, prezentovali sa získané hodnoty parametrov a boli prezentované príklady nameraných a modelovaných signálov.

Dongesov model s filtrom 1. rádu prekováva oba McRuerove modely vo všetkých scenároch s pôsobiacou poruchou. V scenári bez umelo generovaného šumu dosiahol prakticky rovnakú úroveň kvality predikcie ako McRuerov model 2. rádu. Statický Dongesov model dosahuje mierne nižšiu kvalitu predikcie ako Dongesov model s filtrom 1. rádu, nedokáže napríklad až tak verne vystihnúť reakciu na skokovú zmenu jazdného pruhu.

McRuerov model 2. rádu nebol schopný modelovať reakcie na poruchu vstupujúcu do regulačnej slučky. Čím bola intenzita poruchového signálu väčšia, tým bola predikcia tohto modelu horšia. V scenároch s najväčšou intenzitou poruchy (scenáre

3 a 4) už nebol schopný predikovať reakcie vodiča. Model sa zdá byť vhodný len pre scenár 1 – bez akéhokoľvek poruchového signálu. McRuerov model 1. rádu na základe výsledkov aj dostupnej literatúry nie je vhodný pre popis reakcií vodiča ani v jednom z testovaných scenárov.

Zosilnenie modelov má tendenciu rásť so zvyšujúcou sa intenzitou poruchového signálu. V prípade Dongesovho modelu má rastúcu tendenciu aj časová konštanta filtra. Naopak, dopravné oneskorenie vodiča sa so zvyšujúcou intenzitou poruchy znižuje. Niektoré z vypočítaných trendov v identifikovaných parametroch naprieč jednotlivými scenármi potvrdzujú výsledky z literatúry.

Záver

V rámci tejto diplomovej práce bol najskôr spísaný prehľad aktuálne používaných prístupov k modelovaniu človeka v systémoch človek-stroj, so zameraním na modelovanie človeka ako regulátora pri vedení vozidla. V práci je ďalej popísané prostredie Unreal Engine 4 použité pre implementáciu simulátora vozidla, ako aj popis samotného simulátora a vykonaných zmien.

Do simulátora bol implementovaný nový scenár, ktorý vznikol úpravou existujúceho scenára jazdy po diaľnici. V novom scenári boli naprogramované dva nové budiace signály, ktoré pôsobia ako porucha na vstupe do riadenej sústavy. Jedná sa o biely šum a PRBS signál. Za generátory týchto signálov je možné pre ich úpravu zaradiť filter. Do simulátora boli implementované 4 typy filtrov. Filtre 1., 2. a 4. rádu boli naprogramované tak, že je možné užívateľom voľiť ich časovú konštantu a ďalej tak upravovať výsledný signál. Jednotlivé generátory poruchového signálu ako aj filtre je možné ľubovoľne meniť užívateľom v rámci bežiackej aplikácie simulátora, aj v rámci bežiaceho experimentu pomocou nastavení simulácie.

V práci sú porovnávané 4 vybrané modely človeka, rozvetvené modely so stavovou spätnou väzbou (statický Dongesov model a Dongesov model s filtrom 1. rádu) sú porovnávané s modelmi s jedinou prenosovou funkciou (McRuerov model 1. a 2. rádu). Modely boli identifikované v uzatvorenej slučke v diskretnom stavovom popise celého systému pomocou funkcie `ssest` v prostredí MATLAB. Úspešnosť vybraných modelov vodiča bola skúmaná v štyroch scenároch, ktoré sa líšili intenzitou a typom pôsobiaceho poruchového signálu. Identifikačné dáta boli nazbierané z experimentov od 12 rôznych vodičov.

Dáta boli vyhodnotené štatistickými metódami, kvalita predikcie modelov bola realizovaná pomocou metódy krížovej validácie, z identifikovaných hodnôt parametrov bol pre každý model a scenár počítaný priemer a interval, v ktorom sa daný parameter nachádza s pravdepodobnosťou 95 %.

Výsledky ukazujú, že Dongesove modely so stavovou spätnou väzbou dokážu aproximovať reakcie ľudského vodiča v prvých troch scenároch veľmi dobre. Dongesov model s filtrom 1. rádu prekonáva statický Dongesov model, ktorý nemá takú kvalitnú aproximáciu reakcie na zmenu jazdného pruhu. V poslednom scenári je kvalita predikcie oboch modelov horšia, stále však neporovnateľne lepšia oproti McRuerovým modelom. V prvom scenári dosahuje Dongesov model s filtrom 1. rádu prakticky rovnakú kvalitu predikcie ako McRuerov model 2. rádu.

Z McRuerových modelov je vhodný iba model 2. rádu, aj ten iba pre scenár bez pôsobiacej poruchy. V prípade, že do regulačnej slučky vstupuje poruchový signál, schopnosť predikcie týchto modelov s jedinou prenosovou funkciou klesá. Čím je intenzita poruchy väčšia, tým je zhoda s nameranými dátami horšia. Tieto modely

nedokázali vystihnúť reakcie človeka kompenzujúceho poruchový signál.

Pre Dongesov model s filtrom 1. rádu nadobúdalo zosilnenie K_Y hodnoty 0,0076 pre scenár bez pôsobiacej poruchy až 0,031 pre scenár s najväčšou intenzitou poruchového signálu, časová konštanta T hodnoty 0,26 s až 0,68 s, zosilnenie K_Ψ hodnoty 0,019 až 0,057. Dopravné oneskorenie τ klesalo od 0,39 s pre scenár bez poruchy až k 0,054 s pre scenár s najväčšou intenzitou poruchového signálu. Parametre statického Dongesovho modelu nadobúdali podobné hodnoty, zosilnenie K_Y však bolo mierne nižšie.

U McRureovho modelu 2. rádu v prvých dvoch scenároch nadobúdalo zosilnenie K_R hodnotu okolo 0,005, časová konštanta T_R hodnotu približne 0,5 s a hodnota tlmenia ξ bola 0,3. Dopravné oneskorenie τ malo v scenári bez poruchy hodnotu 0,36, v druhom scenári hodnotu 0,19.

Z výsledkov vyplýva, že navrhnutý a otestovaný rozvetvený model vodiča má v experimentoch bez pôsobiacej poruchy porovnateľnú kvalitu predikcie ako nerozvetvený model rovnakej zložitosti. V scenároch s pôsobiacim poruchovým signálom ale tento rozvetvený model prekonáva model nerozvetvený.

Výsledky tejto diplomovej práce boli prijaté k publikácii [1] a k prezentácii na konferencii *18th IFAC Conference on Programmable Devices and Embedded Systems PDeS 2024*.

Na základe získaných výsledkov je vhodné sa v budúcom výskume primárne venovať rozvetveným modelom so stavovou spätnou väzbou, nakoľko tieto modely vykazujú kvalitnú predikciu reakcií vodiča v realistickejších scenároch, kedy do regulačnej slučky vstupuje aj poruchový signál. Možným návrhom na pokračovanie práce môže byť analýza ďalších štruktúr rozvetvených modelov, ktoré využívajú stavovú spätnú väzbu.

Literatúra

- [1] ČELKO, Jakub; MIHÁLIK, Ondrej; HUSÁK, Michal; BRADÁČ, Zdeněk. A Simple State-Space Model of Human Driver Applicable to Windy Conditions. In *18th IFAC Conference on Programmable Devices and Embedded Systems PDeS 2024*. IFAC-PapersOnLine (ELSEVIER). 2024. ISSN: 2405-8963.
- [2] MCRUER, Duane T. a KRENDEL, Ezra S. *Mathematical Models of Human Pilot Behaviour*. Online. Agard, 1974. Dostupné z: <https://www.sto.nato.int/publications/AGARD/AGARD-AG-188/AGARD-AG-188.pdf>. [cit. 2023-12-30].
- [3] CAI, Junyu; JIANG, Haobin a WANG, Junyan, PANCIONI, Luca (ed.). Implementation of the Human-Like Lane Changing Driver Model Based on Bi-LSTM. Online. *Discrete Dynamics in Nature and Society*. 2022, roč. 2022, s. 1-17. ISSN 1607-887X. Dostupné z: <https://doi.org/10.1155/2022/9934292>. [cit. 2023-12-14].
- [4] XU, Shuting; TAN, Wenqian; EFREMOV, Alexander V.; SUN, Liguo a QU, Xiangju. Review of control models for human pilot behavior. Online. *Annual Reviews in Control*. 2017, vol. 44, s. 274-291. ISSN 13675788. Dostupné z: <https://doi.org/10.1016/j.arcontrol.2017.09.009>. [cit. 2023-12-14].
- [5] NOUBISSIE TIENTCHEU, Simplicie Igor; DU, Shengzhi a DJOUANI, Karim. Review on Haptic Assistive Driving Systems Based on Drivers' Steering-Wheel Operating Behaviour. Online. *Electronics*. 2022, roč. 11, č. 13. ISSN 2079-9292. Dostupné z: <https://doi.org/10.3390/electronics11132102>. [cit. 2023-12-14].
- [6] DONGES, Edmund. A Two-Level Model of Driver Steering Behaviour. *Human Factors*. 1978, roč. 20, č. 6, s. 691-707.
- [7] NASH, C. J. a COLE, D. J. Identification and validation of a driver steering control model incorporating human sensory dynamics. Online. *Vehicle System Dynamics*. 2020, roč. 58, č. 4, s. 495-517. ISSN 0042-3114. Dostupné z: <https://doi.org/10.1080/00423114.2019.1589536>. [cit. 2023-12-28].
- [8] NASH, C. J. a COLE, D. J. Identification of a driver model incorporating sensory dynamics, with nonlinear vehicle dynamics and transient disturbances. Online. *Vehicle System Dynamics*. 2022, roč. 60, č. 8, s. 2805-2824. ISSN 0042-3114. Dostupné z: <https://doi.org/10.1080/00423114.2021.1931696>. [cit. 2023-12-28].

- [9] ZADEH, L.A. Fuzzy sets. Online. *Information and Control*. 1965, roč. 8, č. 3, s. 338-353. ISSN 00199958. Dostupné z: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X). [cit. 2024-04-06].
- [10] JURA, Pavel. *Základy fuzzy logiky pro řízení a modelování*. Brno: Vysoké učení technické v Brně, Nakladatelství VUTIUM, 2003. ISBN 80-214-2261-0.
- [11] FIŠER, Michal. *Fuzzy modely chování řidiče*. Online, Diplomová práce, vedoucí Miroslav Jirgl. Brno: Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií, 2023. Dostupné z: https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=253839. [cit. 2024-04-06].
- [12] MIHÁLIK, Ondrej a FIEDLER, Petr. Means of Obtaining Mamdani Fuzzy Model of Car Driver's Dynamics. Online. In: *Proceedings II of the 28st Conference STUDENT EEICT 2022: Selected papers*. Brno: Fakulta elektrotechniky a komunikacnich technologii VUT v Brne, 2022, s. 243-247. ISBN 978-80-214-6030-0. Dostupné z: <https://doi.org/10.13164/eeict.2022.243>. [cit. 2024-04-06].
- [13] RASMUSSEN, Jens. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. Online. *IEEE Transactions on Systems, Man, and Cybernetics*. 1983, roč. SMC-13, č. 3, s. 257-266. ISSN 0018-9472. Dostupné z: <https://doi.org/10.1109/TSMC.1983.6313160>. [cit. 2023-12-14].
- [14] MICHALÍK, David. *Simulátor řízení vozidla*. Online, Diplomová práce, vedoucí Ing. Miroslav Jirgl, Ph.D. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2019. Dostupné z: https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=189346. [cit. 2023-11-10].
- [15] EPIC GAMES. *Unreal Engine 4 Documentation: Level Editor*. Online. © 2004-2023. Dostupné z: <https://docs.unrealengine.com/4.27/en-US/BuildingWorlds/LevelEditor/>. [cit. 2023-11-26].
- [16] EPIC GAMES. *Unreal Engine 4 Documentation: Blueprint Overview*. Online. © 2004-2023. Dostupné z: <https://docs.unrealengine.com/4.27/en-US/ProgrammingAndScripting/Blueprints/Overview/>. [cit. 2023-12-20].
- [17] EPIC GAMES. *Unreal Engine 4 Documentation: Introduction to C++ Programming in UE4*. Online. © 2004-2023. Dostupné z: <https://docs.unrealengine.com/4.27/en-US/ProgrammingAndScripting/ProgrammingWithCPP/IntroductionToCPP/>. [cit. 2023-12-20].

- [18] EPIC GAMES. *Unreal Engine 4 Documentation: Blueprint Function Libraries*. Online. © 2004-2023. Dostupné z: <https://docs.unrealengine.com/4.27/en-US/ProgrammingAndScripting/ProgrammingWithCPP/BlueprintFunctionLibraries/>. [cit. 2023-12-20].
- [19] MICHALÍK, David; JIRGL, Miroslav; ARM, Jakub a FIEDLER, Petr. Developing an Unreal Engine 4-Based Vehicle Driving Simulator Applicable in Driver Behavior Analysis—A Technical Perspective. Online. *Safety*. 2021, roč. 7, č. 2, s. 1-17. ISSN 2313-576X. Dostupné z: <https://doi.org/10.3390/safety7020025>. [cit. 2023-11-10].
- [20] MICHALIK, D.; MIHALIK, O.; JIRGL, M. a FIEDLER, P. Driver Behaviour Modeling With Vehicle Driving Simulator. Online. In *16th IFAC Conference on Programmable Devices and Embedded Systems PDeS 2019*. IFAC-PapersOnLine (ELSEVIER). 2019, roč. 52, č. 27, s. 180-185. ISSN 24058963. Dostupné z: <https://doi.org/10.1016/j.ifacol.2019.12.753>. [cit. 2024-04-09].
- [21] LOGITECH. *Závodní volant Driving Force*. Online. © 2023. Dostupné z: <https://www.logitechg.com/cs-cz/products/driving/driving-force-racing-wheel.941-000123.html>. [cit. 2023-11-19].
- [22] LOGITECH. *Driving Force Shifter*. Online. © 2023. Dostupné z: <https://www.logitechg.com/cs-cz/products/driving/driving-force-shifter.941-000130.html>. [cit. 2023-11-22].
- [23] CPPREFERENCE.COM. *Std::normal_distribution*. Online. 2023. Dostupné z: https://en.cppreference.com/w/cpp/numeric/random/normal_distribution. [cit. 2023-11-10].
- [24] LJUNG, Lennart. *System Identification: Theory for the User*. 2nd ed. Upper Saddle River, NJ: Prentice Hall PTR, ©1999. ISBN 0-13-656695-2.
- [25] VAVŘÍN, Petr. *Teorie dynamických systémů*. Skriptum. Brno: Vysoké učení technické v Brně, 1989.
- [26] THE MATHWORKS, INC. *GoodnessOfFit*. Online. Help Center. 2024. Dostupné z: <https://www.mathworks.com/help/ident/ref/goodnessoffit.html>. [cit. 2024-04-06].
- [27] LJUNG, Lennart. *System Identification Toolbox: Reference*. Online. THE MATHWORKS, INC. MATLAB Help Center. 2023. Dostupné z: https://www.mathworks.com/help/pdf_doc/ident/ident_ref.pdf. [cit. 2024-03-02].

- [28] HASTIE, Trevor; TIBSHIRANI, Robert a FRIEDMAN, Jerome. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed. Springer Series in Statistics. New York: Springer, ©2009. ISBN 978-0-387-84857-0.
- [29] WEINSTEIN, Iram. Hatch.m. Online. In: MATLAB Central File Exchange. 2024. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/2075-hatch-m>. [cit. 2024-03-05].
- [30] ČELKO, Jakub. *Modelování systémů člověk-stroj pomocí McRuerových modelů*. Online, Bakalářská práce, vedoucí Ing. Ondřej Mihálik. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace, 2022. Dostupné z: https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=238941. [cit. 2023-12-30].
- [31] BEJČEK, Ludvík; ČEJKA, Miloslav; REZ, Jiří; GESCHIEDTOVÁ, Eva a STEIBAUER, Miloslav. *Měření v elektrotechnice*. Online, Skriptum. [Brno]: Vysoké učení technické v Brně, 2002. Dostupné z: https://www.researchgate.net/profile/Miloslav-Steinbauer/publication/39856619_Mereni_v_elektrotechnice/links/54a51f0b0cf256bf8bb351c4/Mereni-v-elektrotechnice.pdf?_tp=eyJjb250ZXh0Ijp7ImZpcnNOUGFnZSI6InB1YmxpY2F0aW9uIiwicGFnZSI6InB1YmxpY2F0aW9uIn19. [cit. 2024-04-06].
- [32] NASH, C. J. a COLE, D. J. A Simulation Study of Human Sensory Dynamics and Driver–Vehicle Response. Online. *Journal of Dynamic Systems, Measurement, and Control*. 2022, roč. 144, č. 6. ISSN 0022-0434. Dostupné z: <https://doi.org/10.1115/1.4053865>. [cit. 2024-03-19].
- [33] ORNSTEIN, G. N. The automatic analog determination of human transfer function coefficients. Online. *Medical Electronics & Biological Engineering*. 1963, roč. 1, č. 3, s. 377-387. ISSN 0368-9271. Dostupné z: <https://doi.org/10.1007/BF02474421>. [cit. 2024-03-19].
- [34] MACADAM, Charles C. Understanding and Modeling the Human Driver. Online. *Vehicle System Dynamics*. 2003, roč. 40, č. 1-3, s. 101-134. ISSN 0042-3114. Dostupné z: <https://doi.org/10.1076/vesd.40.1.101.15875>. [cit. 2024-03-19].
- [35] JIRGL, Miroslav; BORIL, Jan a JALOVECKY, Rudolf. Statistical Evaluation of Pilot’s Behavior Models Parameters Connected to Military Flight Training. Online. *Energies*. 2020, roč. 13, č. 17, s. 4452. ISSN 1996-1073. Dostupné z: <https://doi.org/10.3390/en13174452>. [cit. 2024-03-19].

Zoznam symbolov a skratiek

a, b	koeficienty diskretných modelov vodiča
a_f, b_f	koeficienty v diskretnom prenose filtra
a_w, b_w	koeficienty v diskretnom prenose dynamiky kolies
\mathbf{A}	matica spätných väzieb
\mathbf{A}_{11}	matica \mathbf{A} stavového modelu vodiča
\mathbf{A}_{14}	matica spätných väzieb zo stavov sústavy do modelu vodiča
\mathbf{A}_{22}	matica \mathbf{A} dopravného oneskorenia vodiča
\mathbf{A}_{33}	matica \mathbf{A} dopravného oneskorenia sústavy
\mathbf{A}_{44}	matica \mathbf{A} stavového modelu regulovanej sústavy
\mathbf{B}	matica väzieb systému na vstupy
Bi-LSTM	bidirectional long short term memory
\mathbf{C}	matica väzieb výstupov na stavy
d	dopravné oneskorenie systému v krokoch
d_{yt}	priečny offset v čase t
\mathbf{D}	derivačná zložka regulátora
\mathbf{D}	matica priamych väzieb vstupov na výstup
$e(t)$	regulačná odchýlka v čase t
$e(k)$	regulačná odchýlka v kroku k
$f(k)$	namerané dáta v kroku k
$\hat{f}(k)$	predikcia modelu v kroku k
\bar{f}	stredná hodnota nameraných dát
$f_m(k)$	m -tá podmnožina krížovej validácie v kroku k
f_t	žiadaná trajektória cesty
f_v	porucha bočnej rýchlosti

f_ω	porucha uhlovej rýchlosti
$F(p)$	spojitý prenos systému
$F(z)$	diskrétny prenos systému
$F_0(p)$	spojitý prenos otvorenej slučky
$F_c(p)$	spojitý prenos filtra Dongesovho modelu
$F_d(z)$	diskrétny prenos filtra Dongesovho modelu
$F_w(p)$	spojitý prenos dynamiky kolies
$F_w(z)$	diskrétny prenos dynamiky kolies
$F_R(p)$	spojitý prenos modelu vodiča
$F_R(z)$	diskrétny prenos modelu vodiča
$F_S(p)$	spojitý prenos modelu sústavy
$F_S(z)$	diskrétny prenos modelu sústavy
FEKT	Fakulta elektrotechniky a komunikačných technológií
$gen(k)$	vzorka generátora v kroku k
$H(z)$	diskrétny prenos filtra poruchového signálu
k	časová vzorka signálu
K	počet podmnožín krížovej validácie
K_c	zosilnenie diskretného modelu vozidla
K_f	zosilnenie v prenose filtra poruchového signálu
$K_i(t)$	aktuálny tvar trasy
K_K	zosilnenie chyby v zakrivení
K_R	zosilnenie v prenose vodiča
$K_s(t)$	požadovaný tvar trasy
K_S	zosilnenie v prenose sústavy
K_Y	zosilnenie chyby polohy

K_w	zosilnenie v prenose dynamiky kolies
K_ψ	zosilnenie chyby natočenia
LQR	Linear-Quadratic regulator
LTI	angl. <i>linear time-invariant</i> – lineárny časovo invariantný
m	stredná hodnota
M_e	normalizačný koeficient pre regulačnú odchýlku
$M_{\Delta e}$	normalizačný koeficient pre diferenciu regulačnej odchýlky
M_x	normalizačný koeficient pre výstup fuzzy systému
ME, ME _{val}	Úspešnosť modelu na validačných dátach, angl. <i>Model Efficiency</i>
ME _{train}	Úspešnosť modelu na tréningových dátach, angl. <i>Model Efficiency</i>
MPC	Model predictive control
N	celkový počet vzoriek
NRMSE	normalizovaná kvadratická chyba
p	Laplaceov operátor
P	proporcionálna zložka regulátora
PD	proporcionálna a derivačná zložka regulátora
PRBS	pseudo random binary sequence
R	regulátor, model vodiča
S	model sústavy
SISO	model s jedným vstupom a jedným výstupom
t	čas
T	časová konštanta Dongesovho modelu s filtrom 1. rádu
T_f	časová konštanta filtra poruchového signálu
T_R	časová konštanta McRuerovho modelu
T_S	vzorkovacia perióda

T_w	časová konštanta dynamiky kolies
$u(k)$	vstup do systému v kroku k
$\mathbf{u}(k)$	vstupy do systému v stavovom popise v kroku k
u_A	štandardná neistota typu A
U	rozšírená neistota
$v(k)$	poruchový signál v kroku k
$v(t)$	rýchlosť auta
VUT	Vysoké učení technické
$w(k)$	požadovaná hodnota v kroku k
$w(t)$	požadovaná hodnota v čase t
$x(k)$	akčný zásah operátora v kroku k
$x(t)$	akčný zásah operátora v čase t
$\mathbf{x}(k)$	stavy systému v kroku k
\mathbf{x}_0	počiatočný vektor hodnôt stavov
$x_i(k)$	i -ty stav systému v kroku k
$y(t)$	priečna poloha auta, výstup modelu v čase t
$\mathbf{y}(k)$	výstupy do systému v stavovom popise v kroku k
z	operátor Z transformácie
α, λ	koeficienty prenosu sústavy, $\alpha > 0, \lambda > 0$
$\delta(t)$	natočenie volantú
Δ	diferencia veličiny
ξ	koeficient tlmenia
σ	smerodajná odchýlka
τ	časové oneskorenie
τ_d	časové oneskorenie displeja

$\Psi(t)$	natočenie auta
ω	uhlová frekvencia
ω_r	uhlová frekvencia rezu
\oplus	logická funkcia XOR
\ll	veľičina na ľavej strane je výrazne menšia ako veľičina na pravej strane

Zoznam príloh

A	Dotazník pre testovaných vodičov	82
B	Identifikované hodnoty parametrov jednotlivých modelov	83
C	Priebehy meraných a modelovaných signálov	85
C.1	Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu	85
C.2	Statický Dongesov model a McRuerov model 1. rádu	88
D	Obsah elektronickej prílohy	93

A Dotazník pro testovaných vodičů



Dotazník k měření na simulátoru CDS

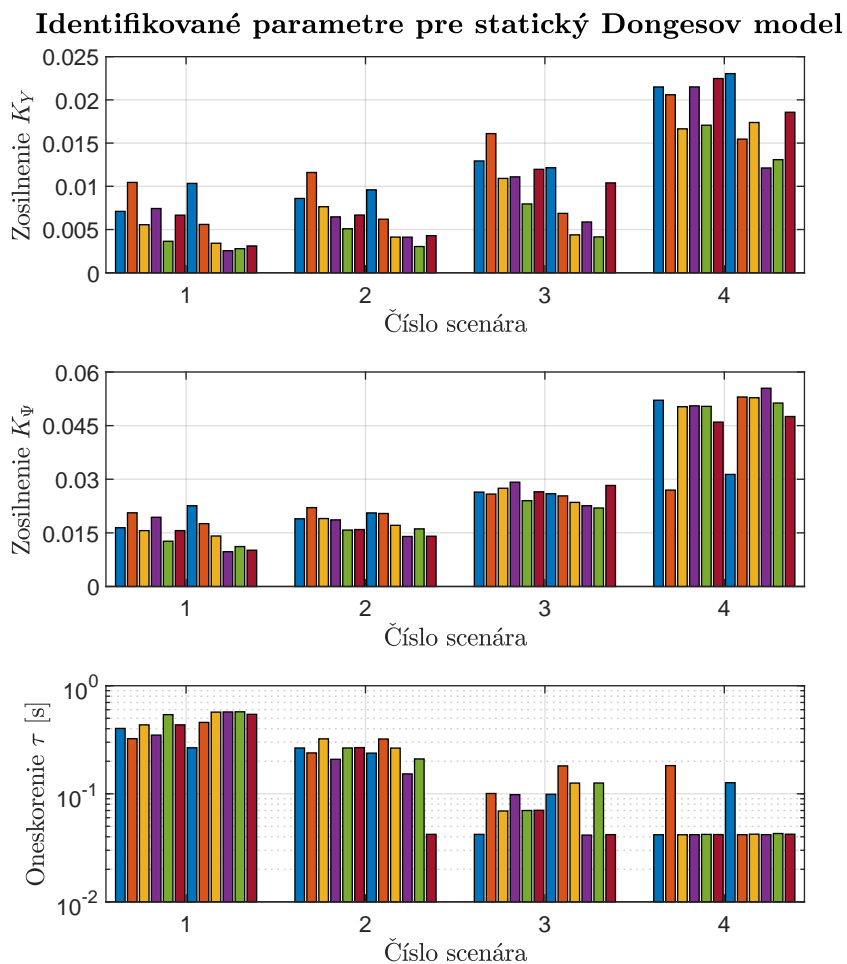
Měření je prováděno v rámci projektu SECREDAS. Data budou sloužit čistě k vědeckým účelům pro zjišťování kvality řízení a chování řidičů.

1. Identifikační číslo:
2. Na škále od 1 do 10 uveďte, jak odpočatí se cítíte (1 – vyčerpaní, 10 – plně odpočatí):
3. Na škále od 1 do 10 uveďte míru Vaší aktuální psychické pohody (1 – extrémně ve stresu, 10 – ledový klid):
4. Uveďte v hodinách, jak dlouho jste před testovacím měřením spali:
5. Požili jste před měřením nějaký druh stimulantu? *káva / čaj / energetický drink / žádný*
6. Kolik je Vám let?
7. Jste držitelem/držitelkou řidičského oprávnění skupiny B? *ano / ne*
8. Kolik let jste držitelem/držitelkou řidičského průkazu?
9. Jak často jezdíte autem? (Uveďte kupříkladu za týden nebo jiný časový interval)
.....
10. Kolik km najezdíte průměrně za rok? km
11. Souhlasím se zpracováním mých údajů, které budou naměřeny během testování na simulátoru CDS: *ano / ne*

V Brně dne:

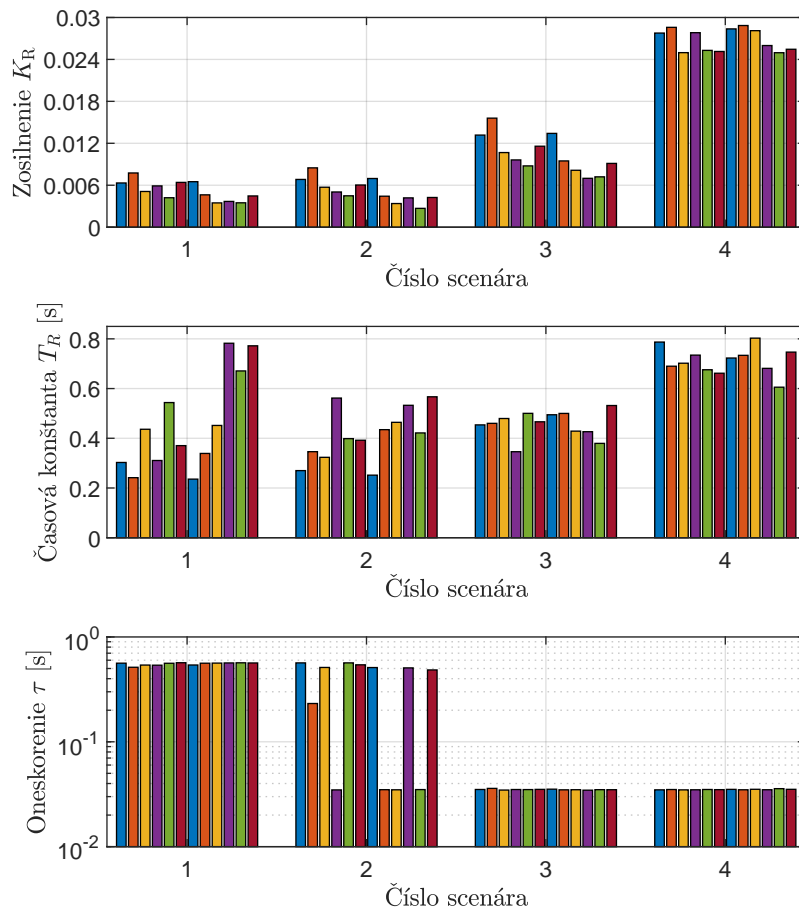
Podpis testované osoby:

B Identifikované hodnoty parametrov jednotlivých modelov



Obr. B.1: Identifikované hodnoty parametrov pre statický Dongesov model

Identifikované parametre pre McRuerov model 1. rádu



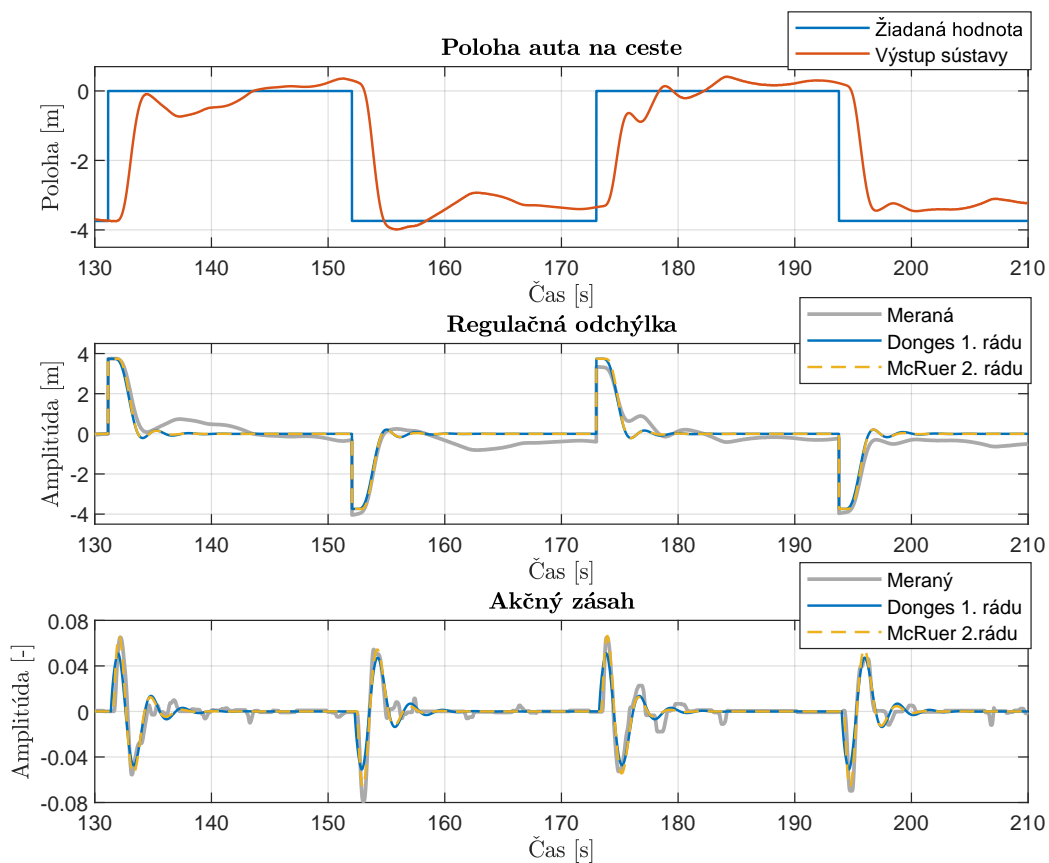
Obr. B.2: Identifikované hodnoty parametrov pre McRuerov model 1. rádu

Tab. B.1: Identifikované hodnoty parametrov McRuerovho modelu 1. rádu

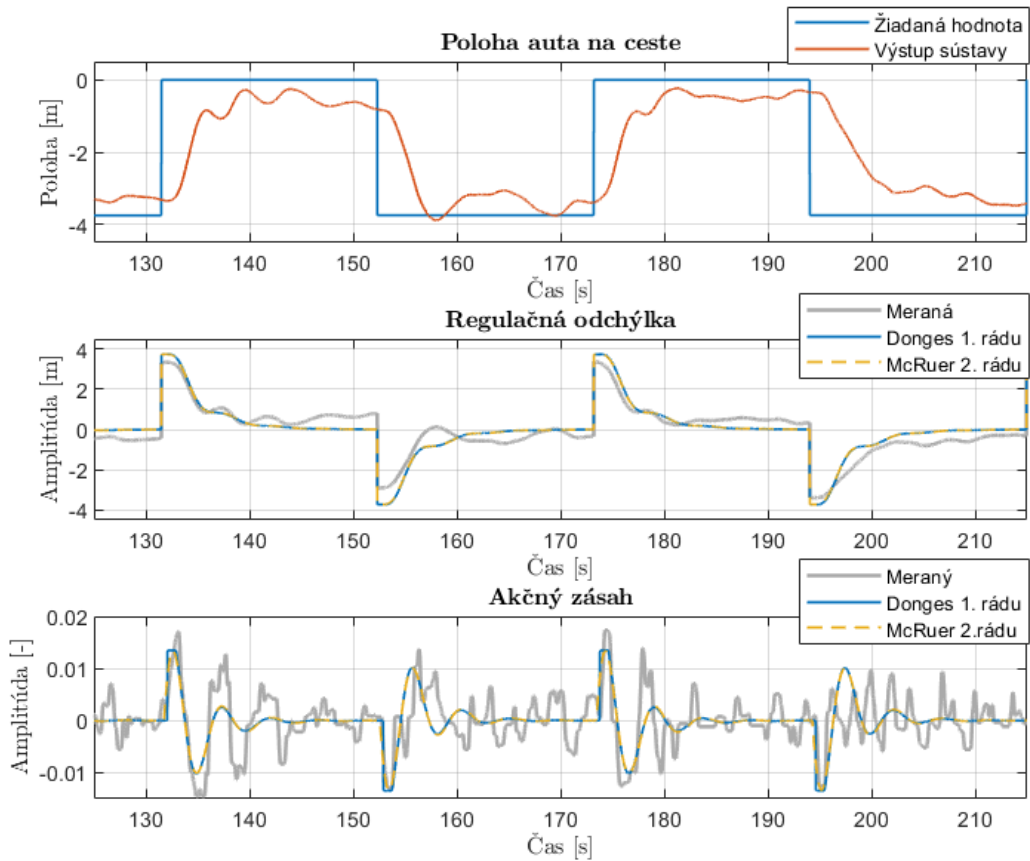
Číslo scenára	K_R	T_R [s]	τ [s]
1	$0,0052 \pm 0,0008$	$0,45 \pm 0,13$	$0,55 \pm 0,01$
2	$0,005 \pm 0,001$	$0,41 \pm 0,07$	$0,34 \pm 0,14$
3	$0,0103 \pm 0,0015$	$0,46 \pm 0,04$	$0,0350 \pm 0,0002$
4	$0,0268 \pm 0,0009$	$0,71 \pm 0,04$	$0,0351 \pm 0,0002$

C Priebehy meraných a modelovaných signálov

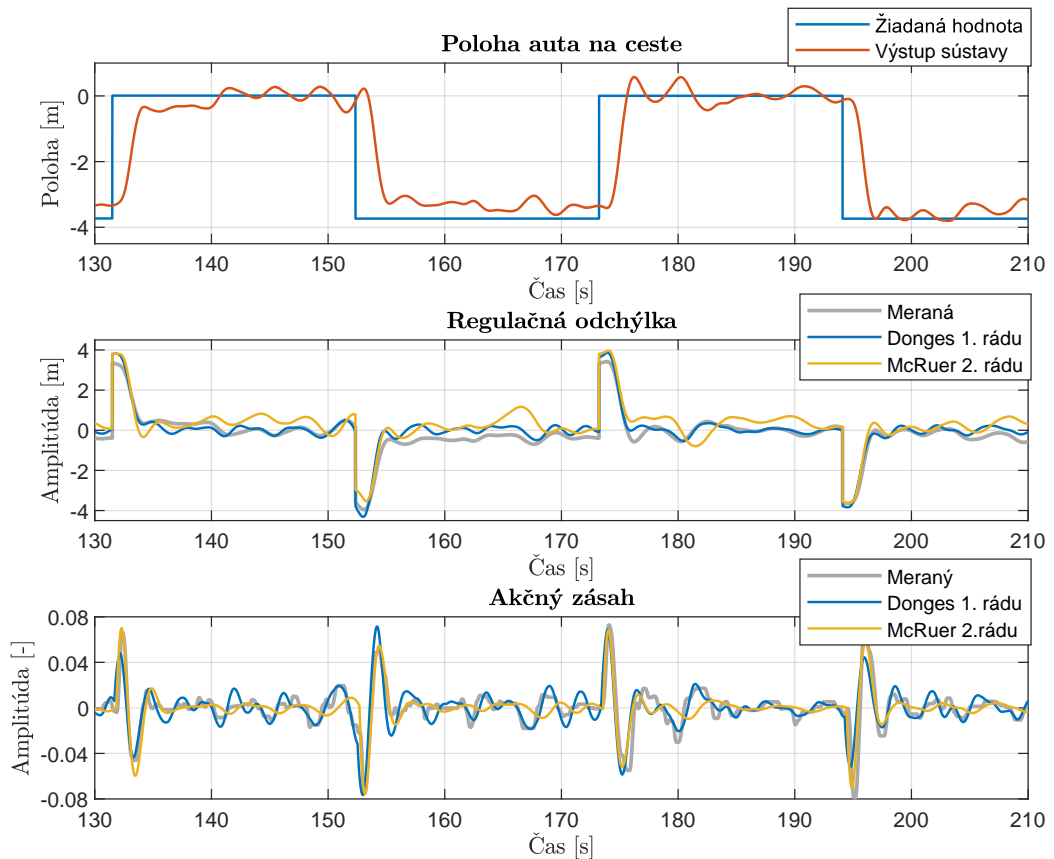
C.1 Dongesov model s filtrom 1. rádu a McRuerov model 2. rádu



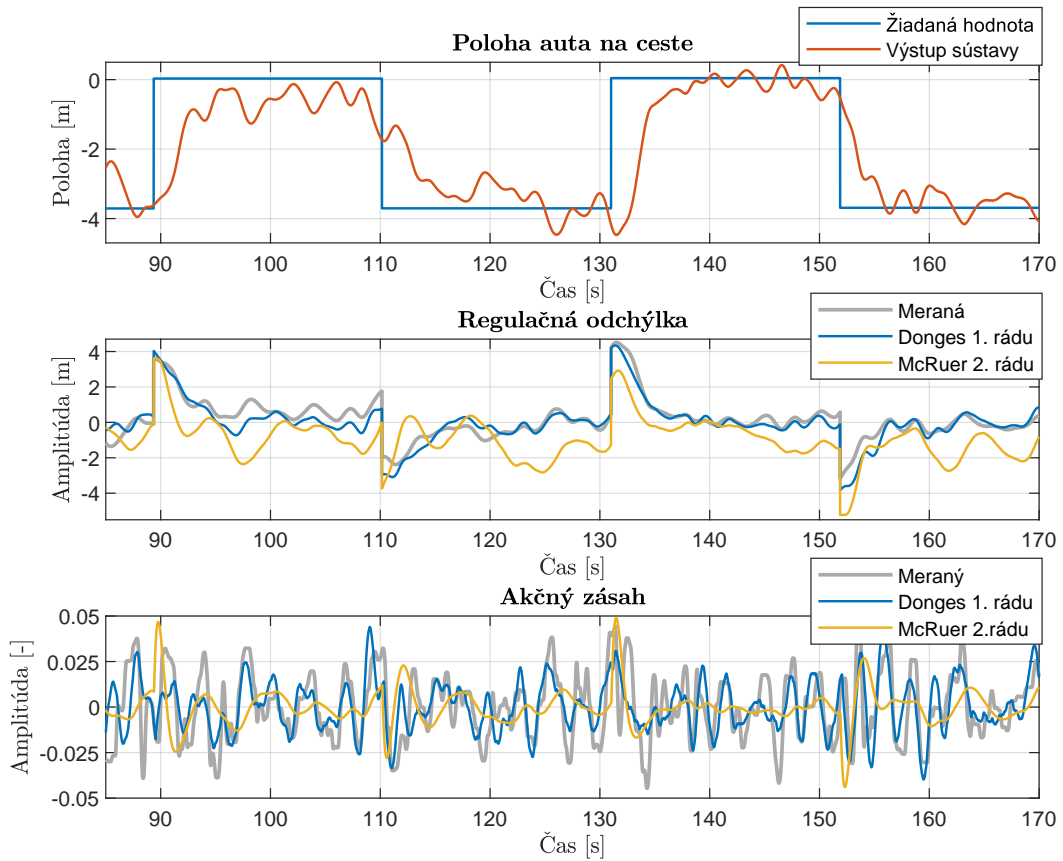
Obr. C.1: Priebehy meraných a modelovaných signálov – scenár 1, vodič 1



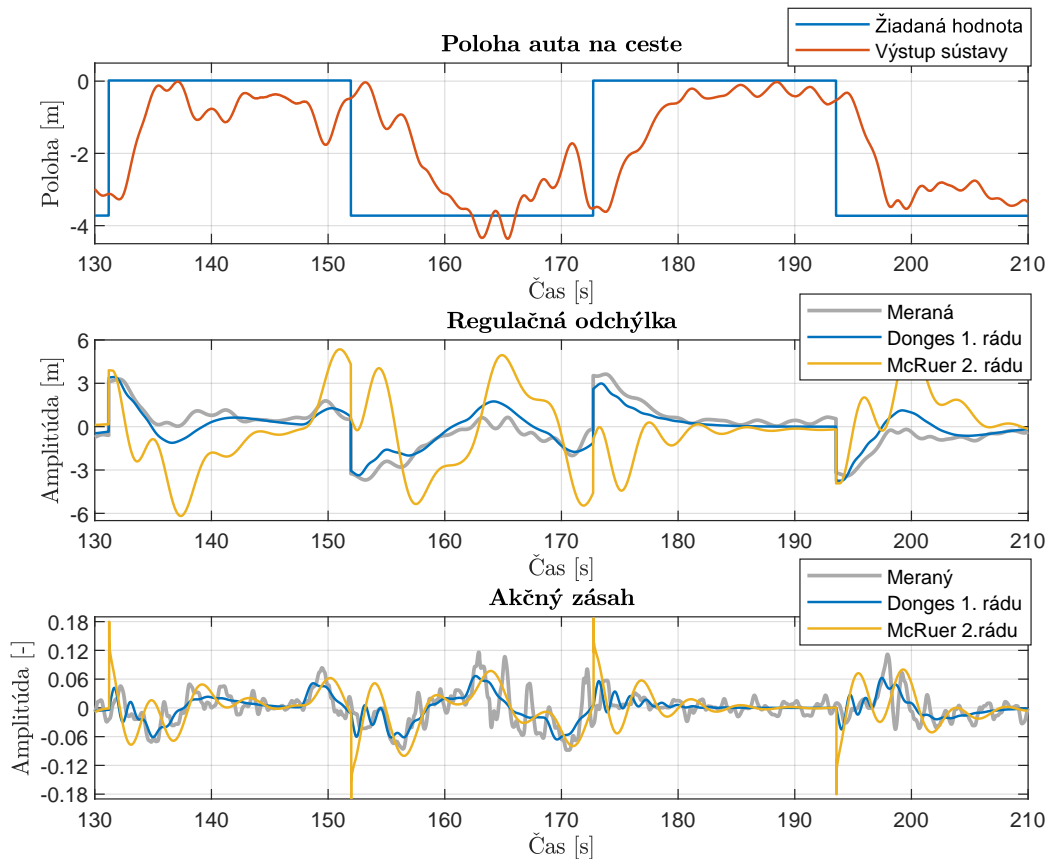
Obr. C.2: Priebehy meraných a modelovaných signálov – scenár 1, vodič 9



Obr. C.3: Priebehy meraných a modelovaných signálov – scenár 2, vodič 2

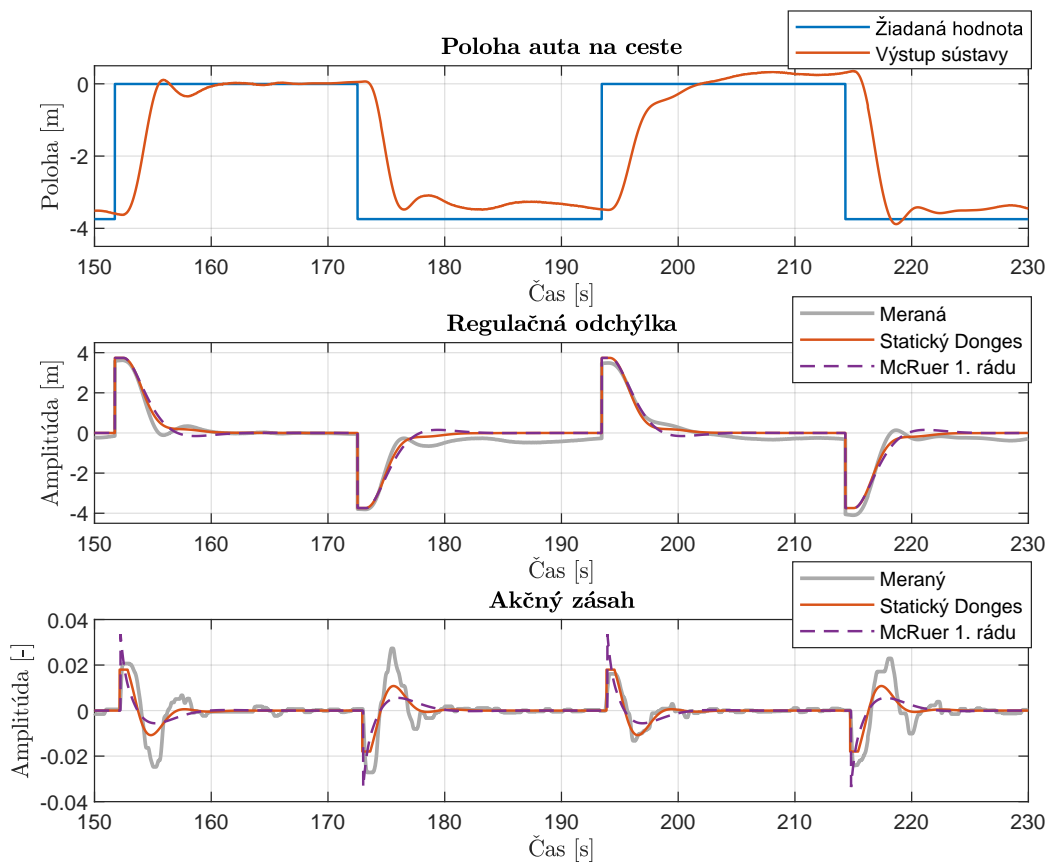


Obr. C.4: Priebehy meraných a modelovaných signálov – scenár 3, vodič 8

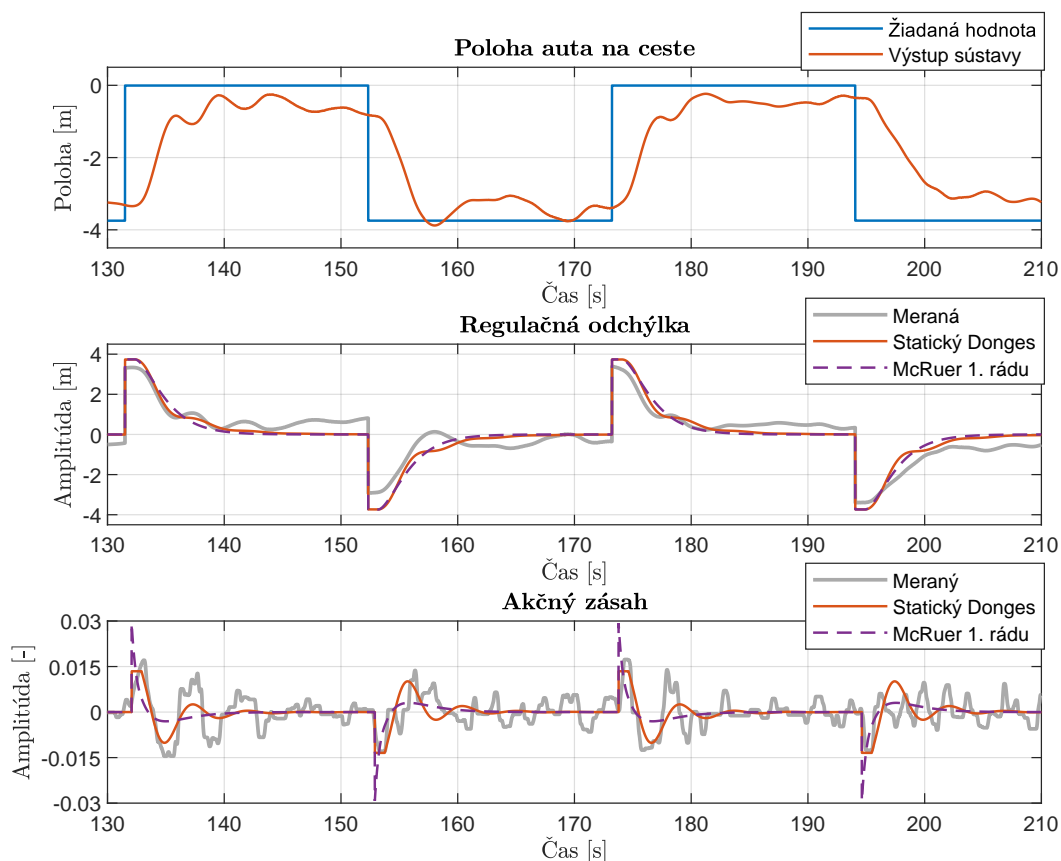


Obr. C.5: Priebehy meraných a modelovaných signálov – scenár 4, vodič 8

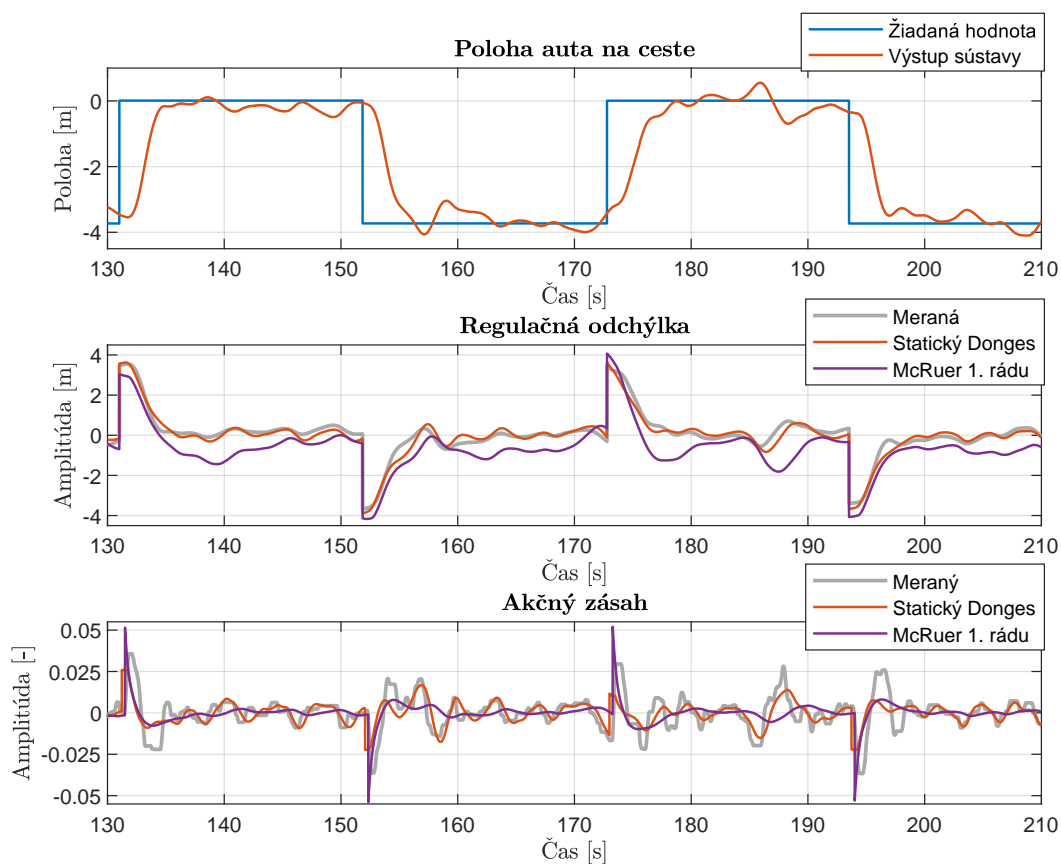
C.2 Statický Dongesov model a McRuerov model 1. rádu



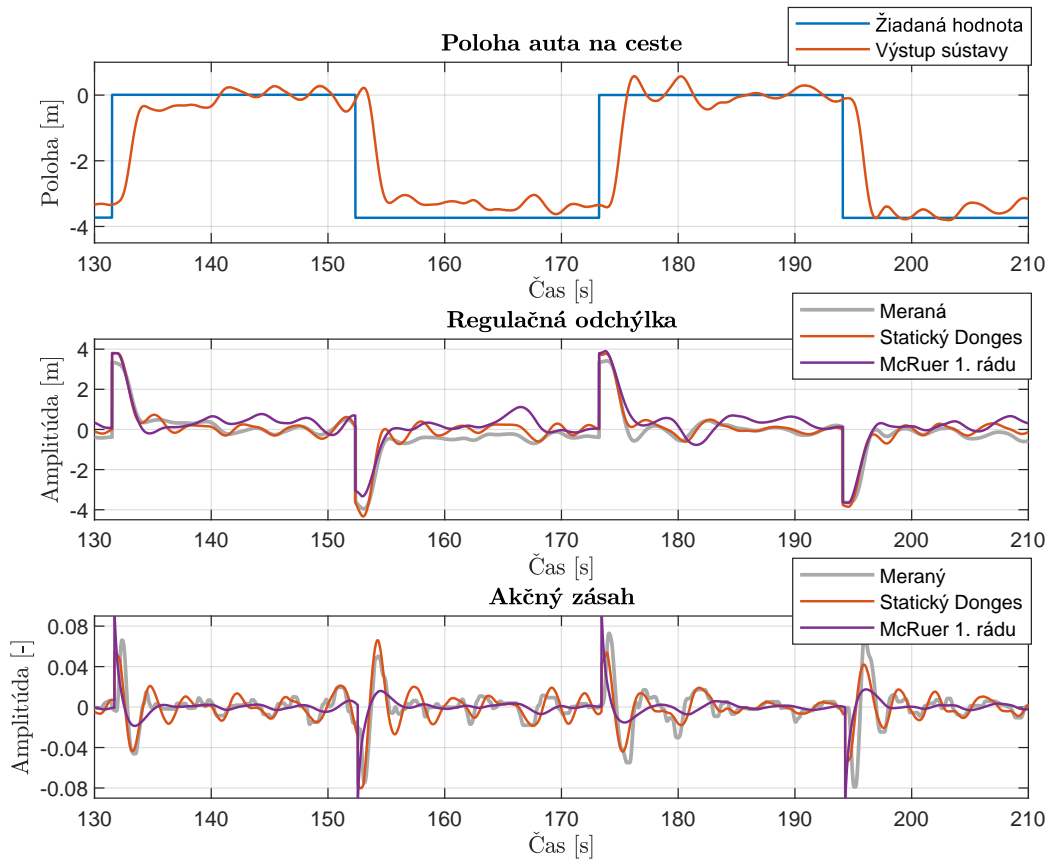
Obr. C.6: Priebehy meraných a modelovaných signálov – scenár 1, vodič 3



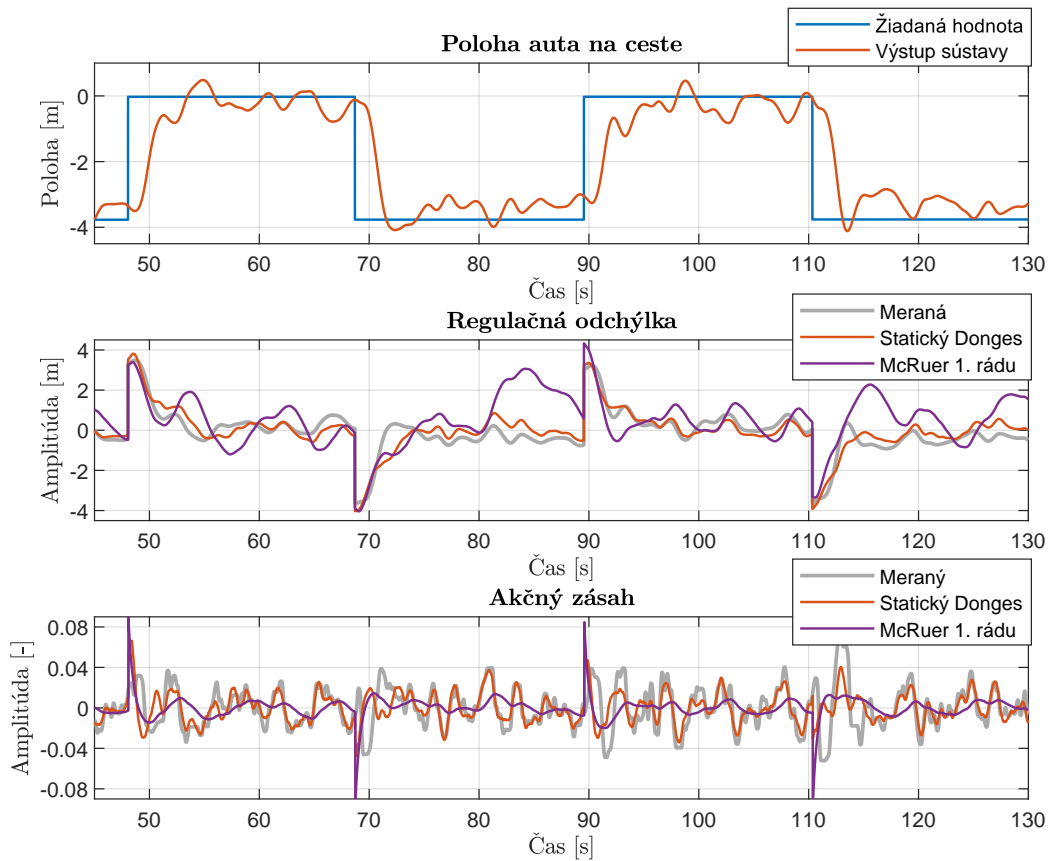
Obr. C.7: Priebehy meraných a modelovaných signálov – scenár 1, vodič 9




Obr. C.8: Priebehy meraných a modelovaných signálov – scenár 2, vodič 6




Obr. C.9: Priebehy meraných a modelovaných signálov – scenár 2, vodič 2




Obr. C.10: Priebehy meraných a modelovaných signálov – scenár 3, vodič 3



Obr. C.11: Priebehy meraných a modelovaných signálov – scenár 3, vodič 8



Obr. C.12: Priebehy meraných a modelovaných signálov – scenár 4, vodič 12



Obr. C.13: Priebehy meraných a modelovaných signálov – scenár 4, vodič 8

