



# 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

**FUZZY MODELY CHOVÁNÍ ŘIDIČE**

FUZZY MODELS OF DRIVER BEHAVIOUR

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. Michal Fišer**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. Miroslav Jirgl, Ph.D.**

**BRNO 2023**

# Diplomová práce

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

Ústav automatizace a měřicí techniky

**Student:** Bc. Michal Fišer

**ID:** 211143

**Ročník:** 2

**Akademický rok:** 2022/23

**NÁZEV TÉMATU:**

## Fuzzy modely chování řidiče

### POKYNY PRO VYPRACOVÁNÍ:

Cílem práce je nalézt vhodné fuzzy modely pro aproximaci datových řad reprezentujících řídicí zásahy řidiče při změně jízdního pruhu. Vstupní data budou získána z testovacích jízd na simulátoru řízení vozidla na UAMT.

1. Prostudujte problematiku modelování řidiče (se zaměřením na McRuerovy modely) a stručně popište.
2. Seznamte se s dostupným simulátorem řízení vozidla a strukturou měřených dat.
3. Identifikujte parametry McRuerova LTI modelu pro sadu řidičů.
4. Navrhněte vhodnou strukturu fuzzy modelu (modelů) pro aproximaci řídicího zásahu řidiče při přeježdění mezi pruhy.
5. Využitím optimalizačních metod určete parametry těchto modelů pro jednotlivé řidiče.
6. Porovnejte výstupy fuzzy modelů s lineárními (McRuerovými) modely.
7. Zhodnoťte dosažené výsledky.

### DOPORUČENÁ LITERATURA:

- [1] LEE, Kwang H. First Course on Fuzzy Theory and Applications [online]. Springer-Verlag Berlin Heidelberg, 2005. ISBN 3-540-22988-4.
- [2] MICHALÍK, D.; JIRGL, M.; ARM, J.; FIEDLER, P. Developing an Unreal Engine 4-Based Vehicle Driving Simulator Applicable in Driver Behavior Analysis-A Technical Perspective. Design for Transport Safety, 2021, roč. 7, č. 2, s. 1-17. ISSN: 2313-576X.

**Termín zadání:** 6.2.2023

**Termín odevzdání:** 17.5.2023

**Vedoucí práce:** Ing. Miroslav Jirgl, Ph.D.

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

### UPOZORNĚNÍ:

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

## **ABSTRAKT**

Diplomová práce se zabývá nalezením vhodného fuzzy modelu pro aproximaci datových řad reprezentujících řídicí zásahy řidiče při změně jízdního pruhu. Nejprve je v teoretické části představen úvod do problematiky modelování řidiče a systémů člověk-stroj, základy fuzzy logiky, fuzzy systémů a regulátorů, metody optimalizace a simulátor řízení vozidla. Práce se zaměřuje v oblasti modelování chování řidiče zejména na McRuerovy modely chování lidského operátora a v oblasti metod optimalizace na genetické algoritmy. Na základě této teorie jsou následně vytvořeny jednotlivé lineární modely chování řidiče. Data byla získávána na simulátoru řízení vozidla. Na tomto simulátoru bylo provedeno několik experimentů měření na reakci řidiče na skokovou změnu. Následně z naměřených dat byly identifikovány jednotlivé modely řidiče pomocí System Identification Toolboxu v programu Matlab. Dále je zde popsán návrh vhodné struktury fuzzy modelu. Poté následuje popis genetického algoritmu použitého pro identifikaci fuzzy modelu a na závěr jsou porovnány lineární a fuzzy modely.

## **KLÍČOVÁ SLOVA**

MMS, modely chování řidiče, McRuerovy modely, lidský operátor, simulátor řízení vozidla, fuzzy, Matlab, System Identification Toolbox, fuzzy modely, PD regulátor, genetický algoritmus, GA

## **ABSTRACT**

The master's thesis is concerned with finding a suitable fuzzy model for approximating data series representing driver's control interventions during lane changes. Firstly, the theoretical part presents an introduction to driver modelling and human-machine systems, the basics of fuzzy logic, fuzzy systems and controllers, optimization methods and a vehicle driving simulator. The thesis focuses mainly on McRuer models of human operator behaviour in the area of driver behaviour modelling and genetic algorithms in the area of optimisation methods. Based on this theory, individual linear models of driver behaviour are subsequently developed. The data were collected on a vehicle driving simulator. On this simulator, several experiments were conducted to measure the driver's response to a step change. Subsequently, the individual driver models were identified from the measured data using the System Identification Toolbox in Matlab. Furthermore, the design of a suitable fuzzy model structure is described. This is followed by a description of the genetic algorithm used to identify the fuzzy model and finally the linear and fuzzy models are compared.

## **KEYWORDS**

MMS, driver behavioural models, McRuer's models, human operator, driving simulator, fuzzy, Matlab, System Identification Toolbox, fuzzy models, PD controller, genetic algorithm, GA

FIŠER, Michal. *Fuzzy modely chování řidiče*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2023, 88 s. Diplomová práce. Vedoucí práce: Ing. Miroslav Jirgl, Ph.D.



## Prohlášení autora o původnosti díla

**Jméno a příjmení autora:** Bc. Michal Fišer  
**VUT ID autora:** 211143  
**Typ práce:** Diplomová práce  
**Akademický rok:** 2022/23  
**Téma závěrečné práce:** Fuzzy modely chování řidiče

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

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

Brno .....

.....

podpis autora\*

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Miroslavu Jirglovi, Ph.D. za odborné vedení, konzultace, trpělivost a další cenné rady při zpracování mé práce.

# Obsah

Úvod	13
<b>1 Problematika modelování řidiče</b>	<b>14</b>
1.1 Systém MMS	15
1.2 Modely chování lidského operátora	17
1.2.1 Precision Model	19
1.2.2 Další modely	21
<b>2 Fuzzy logika</b>	<b>24</b>
2.1 Funkce příslušnosti	24
2.2 Fuzzy číslo	24
2.3 Fuzzy systém	26
2.4 Fuzzy regulátory	28
2.4.1 Fuzzy P regulátor	29
2.4.2 PD regulátor	29
2.4.3 PI regulátor	30
2.4.4 PID regulátor	30
<b>3 Optimalizační metody</b>	<b>31</b>
3.1 Omezené nelineární optimalizační algoritmy	32
3.1.1 Metoda důvěryhodné oblasti	32
3.1.2 Algoritmus aktivní sady	32
3.2 Genetické algoritmy	32
3.2.1 Fitness funkce	33
3.2.2 Selektce	33
3.2.3 Křížení	35
3.2.4 Mutace	36
3.2.5 Elitismus	36
<b>4 Simulátor řízení vozidla</b>	<b>37</b>
4.1 Jízdní scénáře	37
4.1.1 Scénář kalibrace	37
4.1.2 Dálnice: Odezva na jednotkový skok	38
4.1.3 Dálnice: Scénář náhlých překážek	38
4.1.4 Dálnice: Jízda na dlouhé vzdálenosti	38
4.1.5 Losí test	38
4.2 Formát dat	38

<b>5</b>	<b>Identifikace parametrů McRuerova LTI modelů</b>	<b>39</b>
5.1	Popis experimentu . . . . .	39
5.2	Identifikace parametrů . . . . .	40
5.3	Identifikované LTI modely . . . . .	42
5.4	Porovnání modelů . . . . .	50
<b>6</b>	<b>Návrh vhodné struktury fuzzy modelu</b>	<b>53</b>
<b>7</b>	<b>Identifikace fuzzy modelu</b>	<b>55</b>
7.1	Genetický algoritmus . . . . .	55
7.2	Identifikované fuzzy modely . . . . .	59
<b>8</b>	<b>Porovnání fuzzy a LTI modelů</b>	<b>62</b>
	<b>Závěr</b>	<b>64</b>
	<b>Literatura</b>	<b>66</b>
	<b>Seznam příloh</b>	<b>69</b>
<b>A</b>	<b>Porovnání LTI McRuerových modelů</b>	<b>70</b>
<b>B</b>	<b>Parametry identifikovaných fuzzy modelů</b>	<b>78</b>
<b>C</b>	<b>Porovnání Fuzzy a LTI modelů</b>	<b>80</b>
<b>D</b>	<b>Obsah elektronické přílohy</b>	<b>88</b>

# Seznam obrázků

1.1	Blokové schéma chování lidského operátora v systému MMS [1, Fig.1]	14
1.2	Tři úrovně chování lidského operátora [6, Fig.1]	16
1.3	Blokové schéma modifikovaného OCM [13, Fig.17]	22
1.4	Hessův strukturální model [7, Fig.9]	22
2.1	Typy funkcí příslušnosti [14]	25
2.2	Typické názvy oblastí [14]	25
2.3	Struktura fuzzy systému [14]	26
2.4	Fuzzifikace Singletonem (vlevo), Obecná fuzzifikace (vpravo) [14]	27
2.5	Metoda těžiště (COG) [14]	27
2.6	Metoda středu součtů (COS) [14]	28
2.7	Metoda středu maxima (MOM) [14]	28
2.8	Bloková struktura fuzzy P a PD regulátoru [14]	29
2.9	Bloková struktura PI a PID regulátoru [14]	30
3.1	Ruletový výběr	34
3.2	Poziční výběr a) $SP = 1$ , b) $SP = 2$	34
3.3	Turnajový výběr	35
3.4	a) Jednobodové křížení, b) Vícebodové křížení	35
3.5	Mutace u binárního kódování	36
4.1	Simulátor [23, Fig.3]	37
5.1	Pohled řidiče v simulátoru [23, Fig.5]	39
5.2	Nezpracovaná naměřená data pro řidiče A	41
5.3	Vstupní a výstupní signály pro identifikaci řidiče A	42
5.4	Porovnání modelů pro řidiče A	44
5.5	Porovnání modelů pro řidiče B	45
5.6	Porovnání modelů pro řidiče C	45
5.7	Porovnání modelů pro řidiče D	46
5.8	Porovnání modelů pro řidiče E	47
5.9	Porovnání modelů pro řidiče F	48
5.10	Porovnání modelů pro řidiče G	49
5.11	Porovnání modelů pro řidiče H	49
5.12	Porovnání modelů pro řidiče I	50
6.1	Struktura fuzzy PD regulátoru ve Fuzzy toolboxu (Matlab)	53
6.2	Mapovací funkce signálu PD regulátoru	54
6.3	Pravidla fuzzy PD regulátoru	54
7.1	Fuzzy model	55
7.2	Kódování funkcí příslušnosti fuzzy PD regulátoru	55
7.3	Měřítka a časové zpoždění modelu 1 a 2 řidiče A	60

7.4	Funkce příslušnosti modelu 1 řidiče A . . . . .	60
7.5	Pravidla fuzzy modelu 1 řidiče A . . . . .	60
8.1	Porovnání modelů řidiče A . . . . .	62
8.2	Souhrn přesností fuzzy a lineárních modelů . . . . .	63
A.1	Porovnání Gross modelů pro řidiče A . . . . .	70
A.2	Porovnání Gross modelů pro řidiče B . . . . .	71
A.3	Porovnání Tustin-McRuerových modelů pro řidiče A . . . . .	72
A.4	Porovnání Tustin-McRuerových modelů pro řidiče B . . . . .	73
A.5	Porovnání Precision modelů pro řidiče A . . . . .	74
A.6	Porovnání Precision modelů pro řidiče B . . . . .	75
A.7	Porovnání Náhradních modelů pro řidiče A . . . . .	76
A.8	Porovnání Náhradních modelů pro řidiče B . . . . .	77
C.1	Porovnání modelů pro řidiče B . . . . .	80
C.2	Porovnání modelů řidiče C . . . . .	81
C.3	Porovnání modelů pro řidiče D . . . . .	82
C.4	Porovnání modelů řidiče E . . . . .	83
C.5	Porovnání modelů pro řidiče F . . . . .	84
C.6	Porovnání modelů řidiče G . . . . .	85
C.7	Porovnání modelů pro řidiče H . . . . .	86
C.8	Porovnání modelů řidiče I . . . . .	87

# Seznam tabulek

1.1	Shrnutí přenosových funkcí lidského operátora dle rovnice 1.1 pro základní řízené prvky v oblasti řezu [10] . . . . .	18
1.2	Shrnutí přenosových funkcí lidského operátora dle rovnice 1.2 pro různé řízené prvky [9] . . . . .	20
1.3	Tabulka typických hodnot parametrů precision modelu [11, 12] . . . . .	21
3.1	Ruletový výběr . . . . .	34
3.2	Poziční výběr . . . . .	34
5.1	Ukázka naměřených dat ze simulátoru řízení vozidla . . . . .	40
5.2	Souhrn přesností jednotlivých modelů sady řidičů . . . . .	51
B.1	Parametry identifikovaných fuzzy modelů 1 . . . . .	78
B.2	Parametry identifikovaných fuzzy modelů 2 . . . . .	79

## Seznam výpisů

7.1	Tvorba počáteční populace v prostředí Matlab. . . . .	56
7.2	Selekce a elitismus v prostředí Matlab. . . . .	57
7.3	Křížení v prostředí Matlab. . . . .	58
7.4	Mutace v prostředí Matlab. . . . .	59



# Úvod

Tato diplomová práce se bude zabývat nalezením vhodného fuzzy modelu pro aproximaci datových řad reprezentujících řídicí zásahy řidiče při změně jízdního pruhu.

V teoretické části diplomové práce bude popsán úvod do problematiky modelování řidiče a systémů člověk-stroj. Pokud je lidský operátor zapojen jako aktivní prvek do zpětnovazebního řídicího systému, je chování systému člověk-stroj takové, aby splňovalo požadované cíle. Jelikož se lidský operátor dokáže přizpůsobit rozmanitosti řízeného systému, je matematický popis lidského operátora nesmírně složitý, proto je nutné ho rozdělit do několika jednodušších částí. Jestliže budeme mít k dispozici účinný model, dostaneme díky němu aproximaci chování lidského operátora v nějaké omezené oblasti. Tato práce se zejména zaměří na McRuerovy modely chování lidského operátora, avšak stručně shrne i další modely.

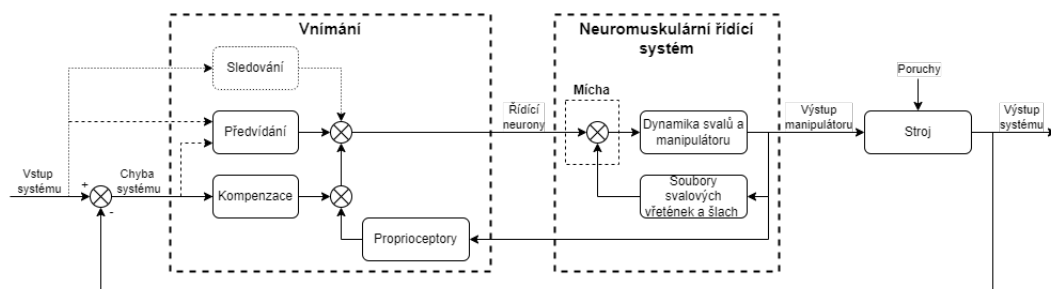
Dále zde budou stručně vysvětleny základy fuzzy logiky, fuzzy systémů a regulátorů a metody optimalizačních metod, zejména pak podrobněji omezené nelineární optimalizační algoritmy, které využívá System Identification Toolbox, a genetický algoritmus, který bude využit při identifikaci fuzzy modelu. V poslední části bude popsán simulátor řízení vozidla, na kterém budou naměřena data pro identifikaci modelů.

Praktická část diplomové práce se bude věnovat nejdříve identifikaci parametrů jednotlivých lineárních McRuerových modelů na sadě řidičů, které mezi sebou porovnáme na základě přesnosti výsledných modelů. Následně bude popsán výběr vhodné struktury fuzzy modelu pro aproximaci chování řidiče. Poslední část se bude zabývat identifikací fuzzy modelu pomocí genetického algoritmu.

V závěru diplomové práce proběhne zhodnocení a shrnutí dosažených výsledků.

# 1 Problematika modelování řidiče

Matematický popis lidského operátora je velmi složitý díky jeho všestrannosti a přizpůsobivosti při zpracování informací. Prvky pro snímání, zpracování a výpočet dat spolu s ovládacími prvky jsou propojeny jako vnitřní cesty zpracování signálu, které stejně jako funkční operace s vnitřními signály lze překonfigurovat dle aktuální měnící se situace. Lidský operátor tedy může přizpůsobovat jak zapojení jednotlivých cest, tak prováděné funkce [1, 2].



Obr. 1.1: Blokové schéma chování lidského operátora v systému MMS [1, Fig.1]

Na obrázku lze vidět blokové schéma lidského operátora, popisující jeho chování v interaktivním systému MMS (Man-Machine System / systém člověk–stroj), v němž člověk pracuje s vizuálně snímanými vstupy a komunikuje se strojem prostřednictvím manipulačního výstupu. Toto blokové schéma naznačuje minimální počet hlavních cest zpracování signálu u lidského operátora, které jsou zapotřebí k charakterizaci jeho různých rysů chování.

Při popisu jednotlivých částí obrázku začneme zcela vpravo, kde nalezneme stroj řízený člověkem. Vlevo od něj se nachází neuromuskulární řídicí systém, výstupní mechanismus člověka, jenž je vlastním rozhraním mezi člověkem a strojem. Toto je velice komplikovaný zpětnovazební řídicí systém a zahrnuje dynamiku končetin, svalů a manipulátoru v dopředné smyčce a soubory svalových vřetének a šlachových orgánů jako zpětnovazební prvky.

Posledním blokem úplně vlevo je vnímání, kde se mohou nacházet až tři druhy řízení a proprioceptivní zpětnovazební smyčka zahrnující další smyslové zdroje (kloubní receptory, periferní vidění atd.), které indikují výstupní polohu končetin. Na základě přítomnosti jednotlivých druhů řízení se může struktura systému MMS jevit jako otevřená nebo uzavřená smyčka, popřípadě jejich kombinace.

Kompenzační řízení bude přítomné v bloku vnímání, pokud se příkazy a poruchy objevují náhodně a pokud lidský operátor reaguje pouze na poruchy systému nebo na výstupní veličiny řízeného prvku. Touto formou systém vykonává nepřetržité řízení v uzavřené smyčce na základě minimalizace chyby systému v přítomnosti příkazů a poruch.

Jestliže lze odlišit vstupní příkazy od výstupů systému na základě zobrazení či náhledu, připojí se ke kompenzaci ještě sledovací řízení. Sledování zajišťuje řízení v otevřené smyčce ve spojení s kompenzační uzavřenou smyčkou korigující chyby. Tímto spojením lze dosáhnout mnohem lepší kvality řízení než v případě samotného kompenzačního řízení.

Je-li dosaženo úplné znalosti dynamiky řízeného prvku a bloku vnímání, může lidský operátor predikovat chování systému a díky tomu správně načasovat sekvenci neuromuskulárních příkazů, aby výsledkem byly přesně požadované výstupy systému. Prediktivní řízení bývá spojováno s kompenzačním ve formě dvou-režimového řízení, kdy je řízení realizováno pomocí predikce a doplněno kompenzací pro snížení chyby systému [1, 2].

## 1.1 Systém MMS

Systém MMS je tvořen biologickým / psychologickým / sociálním systémem (člověk nebo skupina lidí) a technologickým systémem (stroj) bez ohledu na jeho stupeň složitosti. Mezi nejlépe prozkoumané typy systémů MMS patří zejména:

- řízení aut, letadel, lodí a vlaků, v těchto systémech se jedná zejména o úlohy stabilizace, řízení, navigace a následnou kontrolu,
- výrobní a technologické procesy, kde jsou nasazeny počítače a počítačové systémy pro řízení a automatizaci výrobních postupů (jaderné elektrárny, chemická zařízení), systém člověk – počítač a jejich vzájemná interakce.

Lidský operátor v systému MMS je zcela výjimečný regulátor, který je vysoce adaptivní a zároveň je schopný zapojit své myšlení do regulačních zásahů. Díky této schopnosti zajistí variabilitu a různorodost postupů při plnění zadaného úkolu. Pokud je člověk v systému MMS aktivním řídicím prvkem se zpětnou vazbou, pak vede své chování a regulační zásahy ke splnění bezpečnosti systému a celkového cíle.

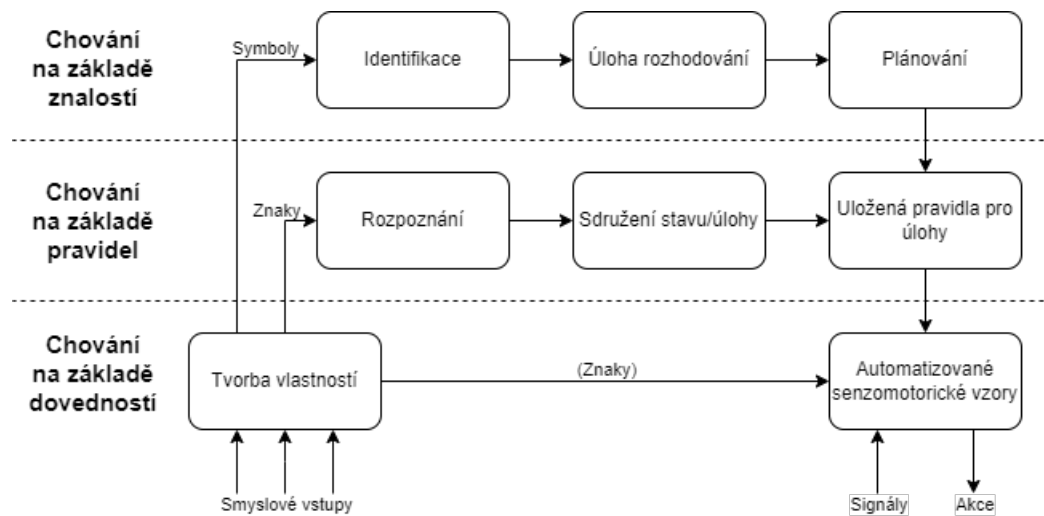
Člověk potřebuje pro úspěšné ovládání, manipulaci či řízení systému znát základní pravidla komunikace, bez kterých není schopen se s daným strojem "dorozumět". U výměny informací v systémech MMS je nezbytné, aby byla obousměrná. Člověk musí mít možnost nejen zasáhnout a ovlivnit stav systému, ale také určit způsob a velikost svých akčních zásahů na základě zpětné vazby [3, 4, 5].

Výměna informací v systémech MMS je možná:

- přímou formou, kdy člověk získává informace přímým pozorováním a vnímáním,
- zprostředkovanou formou, kdy informace jsou získány na základě měření pomocí dalších přístrojů nebo senzorů [3].

Popisem lidského chování se zabýval Jens Rasmussen, který jej kategorizoval podle zcela odlišných způsobů reprezentace omezení v chování deterministického

prostředí či systému do tří typických úrovní: chování založené na dovednostech, znalostech a pravidlech. Jednotlivé úrovně chování a jejich vztahy jsou znázorněny na obrázku 1.2 [6].



Obr. 1.2: Tři úrovně chování lidského operátora [6, Fig.1]

Chování založené na dovednostech představuje senzomotorické úkony a činnosti, které probíhají bez vědomé pozornosti a kontroly jako plynulé, automatizované a vysoce integrované vzorce chování. Smyslové vjemy nejsou vnímány a selektovány a slouží pouze pro podvědomou aktualizaci a orientaci vnitřní mapy. Z hlediska řízení se tedy jedná převážně o přímé řízení, pouze ve výjimečných situacích se jedná o jednoduché zpětnovazební řízení.

Chování založené na pravidlech je posloupnost činností, které je ve známé situaci řízeno uloženým pravidlem nebo postupem. Tato posloupnost je složena na základě předchozích zkušeností, sdělena z know-how jiné osoby nebo připravena vědomým řešením problémů a plánováním. Chování je strukturováno jako dopředné řízení pomocí uloženého pravidla. Zpětnovazební korekce by vyžadovala pochopení a analýzu aktuální odezvy prostředí, což můžeme považovat za nezávislou souběžnou činnost na vyšší úrovni (chování založené na znalostech).

Chování založené na znalostech se projevuje během neznámých situací, kdy není k dispozici žádná předchozí zkušenost ani know-how. Chování je řízeno na základě cíle a znalostí. Pro tuto událost je cíl jasně daný na základě analýzy prostředí a záměrů osoby. Následně je vybrán užitečný plán z různých možností, které jsou testovány vzhledem k cíli metodou pokusů a omylů nebo předpovědí účinků plánu.

Podobné rozlišení mezi různými kategoriemi lidského chování bylo navrženo i dalšími lidmi:

- Paul Morris Fitts rozlišuje tři fáze učení se dovednostem: ranou (kognitivní), přechodnou (asociační) a konečnou (autonomní) fází,

- Alfred North Whitehead pojednává o symbolismu a operuje se třemi kategoriemi lidských činností: instinktivním, reflexním a symbolicky podmíněným jednáním [6].

## 1.2 Modely chování lidského operátora

Výzkum chování člověka hrál zásadní roli v letectví, v němž se zaměřili na techniky modelování pilotů. Následky tohoto výzkumu přinesly významný pokrok při modelování chování řidiče. Existující modely chování člověka lze rozdělit do tří typů modelů: založené na teorii řízení, na principu chování z fyziologického hlediska a na technikách inteligence [7].

Významným představitelem v oblasti matematického modelování lidských operátorů byl Duane T. McRuer, který se s týmem spolupracovníků specializoval na průnik dynamických systémů a lidského chování, známé jako teorie manuálního řízení. Výsledkem výzkumu byl jednoduchý a účinný princip „Crossover model“, který vedl ke konstrukci vozidel s lepšími výkony a zároveň k bezpečnějšímu a jednoduššímu ovládání [8].

Lidský operátor je schopný změnit své chování pro splnění základní podmínky uzavřené smyčky, která je požadovaná po každém dobrém zpětnovazebním řídicím systému. Těmito základními podmínkami jsou:

- zajištění požadovaného vztahu mezi příkazem a odezvou,
- potlačení nežádoucích vstupů a poruch,
- omezení vlivu kolísání a nejistot ve složkách řídicí smyčky,
- zajištění dostatečné rezervy stability uzavřené smyčky.

V kompenzační regulační smyčce se splní tyto čtyři podmínky tak, že velikost amplitudy frekvenční odezvy otevřené smyčky je velmi velká ve frekvenčním rozsahu vstupního pásma a velmi malá mimo něj. Jelikož nelze realizovat extrémně prudkou změnu, která by destabilizovala systém uzavřené smyčky, využívá se základního pravidla pro syntézu ve frekvenční oblasti [9]: Najděte či vytvořte na amplitudové frekvenční charakteristice úsek o sklonu -20 dB/dekádu v oblasti vstupní šířky pásma nebo za ní a nastavte zesílení takové, aby se frekvence řezu nacházela u horního okraje tohoto úseku při zachování dostatečné stability.

V crossover modelu se snaží lidský operátor přizpůsobovat akční zásah dynamice soustavy tak, aby stabilizoval celý systém a aby přenosová funkce otevřené smyčky měla v okolí frekvence řezu  $\omega_c$  integrační charakter. Základním crossover modelem je tedy spíše model chování MMS v otevřené smyčce než samotný model chování lidského operátora.

Crossover model je:

$$F_0(j\omega) = F_R(j\omega) \cdot F_S(j\omega) = \frac{\omega_c}{j\omega} \cdot e^{-j\omega\tau} \quad (1.1)$$

,kde	$F_0(j\omega)$	...	Frekvenční přenos otevřené smyčky
	$F_R(j\omega)$	...	Frekvenční přenos regulátoru (člověk)
	$F_S(j\omega)$	...	Frekvenční přenos soustavy (stroj)
	$j$	...	Imaginární jednotka
	$\omega$	...	Frekvence [ $rad \cdot s^{-1}$ ]
	$\omega_c$	...	Frekvence řezu [ $rad \cdot s^{-1}$ ]
	$\tau$	...	Dopravní zpoždění [s]

Frekvence řezu odpovídá zesílení smyčky a zohledňuje adaptivní kompenzaci zesílení řízeného prvku lidským operátorem. Tento model obvykle vede ke správným charakteristikám uzavřené smyčky, jelikož skutečný tvar funkce otevřené smyčky daleko od oblasti frekvence řezu má jen malý vliv na dynamiku uzavřené smyčky. Díky tomu je vhodnou aproximací pro mnoho inženýrských účelů systémů MMS [9].

Přenosová funkce řízené soustavy v okolí $\omega_c$	Aproximační přenosová funkce lidského operátora	Přenosová funkce otevřené smyčky
$F_S(p) = K_S$	$F_R(p) = \frac{K_R}{p} \cdot e^{-\tau p}$	$F_0(p) = \frac{\omega_c}{p} \cdot e^{-\tau p}$
$F_S(p) = \frac{K_S}{p}$	$F_R(p) = K_R \cdot e^{-\tau p}$	$F_0(p) = \frac{\omega_c}{p} \cdot e^{-\tau p}$
$F_S(p) = \frac{K_S}{p \cdot (p + a)}$	$F_R(p) = K_R \cdot (p + a) \cdot e^{-\tau p}$	$F_0(p) = \frac{\omega_c}{p} \cdot e^{-\tau p}$
$F_S(p) = \frac{K_S}{p^2}$	$F_R(p) = K_R \cdot p \cdot e^{-\tau p}$	$F_0(p) = \frac{\omega_c}{p} \cdot e^{-\tau p}$
$F_S(p) = \frac{K_S}{(p - \lambda)}$	$F_R(p) = K_R \cdot e^{-\tau p}$	$F_0(p) = \frac{\omega_c}{(p - \lambda)} \cdot e^{-\tau p}$
$F_S(p) = \frac{K_S}{(p + a) \cdot (p - \lambda)}$	$F_R(p) = K_R \cdot (p + a) \cdot e^{-\tau p}$	$F_0(p) = \frac{\omega_c}{(p - \lambda)} \cdot e^{-\tau p}$

Tab. 1.1: Shrnutí přenosových funkcí lidského operátora dle rovnice 1.1 pro základní řízené prvky v oblasti řezu [10]

Přenosové funkce lidského operátora dle rovnice 1.1 pro základní řízené prvky v oblasti frekvence řezu jsou shrnuty v tabulce 1.1. Lze vidět, že i přes odlišné přenosové funkce lidského operátora jsou přenosové funkce otevřené smyčky shodné ve čtyřech případech a u zbylých dvou se liší pouze v části jmenovatele. V oblasti frekvenční odezvy budou však patřit všechny do stejné kategorie pro hodnoty  $\omega_c \gg \lambda$  [10].

Nejjednodušší forma přenosové funkce lidského operátora, která odpovídá crossover modelu v otevřené smyčce, je:

$$F_R(p) = K_R \cdot \frac{T_L(p) + 1}{T_I(p) + 1} \cdot e^{-p\tau} \quad (1.2)$$

- ,kde  $K_R$  ... Statické zesílení  
 $T_L$  ... Prediktivní časová konstanta (předstih - lead) [s]  
 $T_I$  ... Setrvačná časová konstanta (zpoždění - lag) [s]  
 $\tau$  ... Efektivní časové zpoždění [s] (Obsahuje dopravní zpoždění a vysokofrekvenční neuromuskulární zpoždění)  
 $p$  ... Laplaceův operátor

Prediktivní a setrvačná časová konstanta  $T_L$  a  $T_I$  je nastavována lidským operátorem tak, aby se dosáhlo sklonu amplitudy přenosu otevřené smyčky  $|F_0|$  -20 dB/dek v širokém frekvenčním rozsahu, v okolí frekvence řezu  $\omega_c$ , jak to požaduje crossover model. Správnou volbou statického zesílení  $K_R$  lze stabilizovat systém, nejlépe v širokém rozsahu  $K_R$ . Při nízkých frekvencích se získá  $F_0 \gg 1$ , čím se zajistí dobrá nízkofrekvenční odezva uzavřené smyčky na systémové příkazy a potlačení poruch. Příklady přenosových funkcí lidského operátora dle rovnice 1.2 pro různé řízené prvky jsou uvedeny v tabulce 1.2 [9].

## 1.2.1 Precision Model

Tento model popisuje chování lidského operátora v širším rozsahu frekvencí pro různé dynamiky s ohledem na rovnici 1.1 a rozšiřuje rovnici 1.2 o neuromuskulární systém, jehož matematický popis vychází z fyziologického a neurologického popisu člověka. Obecný tvar rovnice precision modelu je dán:

$$F_R = K_R \cdot \frac{T_L p + 1}{T_I p + 1} \cdot e^{-p\tau} \cdot \underbrace{\frac{1}{\left[ \left( \frac{p}{\omega_N} \right)^2 + \frac{2\xi_N p}{\omega_N} + 1 \right]}}_{\text{Neuromuskulární systém}} \quad (1.3)$$

- , kde  $K_R$  ... Statické zesílení  
 $T_L$  ... Prediktivní časová konstanta (předstih - lead) [s]  
 $T_I$  ... Setrvačná časová konstanta (zpoždění - lag) [s]  
 $\tau$  ... Čisté dopravní zpoždění [s]  
 $\omega_N$  ... Frekvence kmitů neuromuskulárního systému [ $rad \cdot s^{-1}$ ]  
 $\xi_N$  ... Tlumení neuromuskulárního systému  
 $p$  ... Laplaceův operátor

Ačkoli je tento model celkem podrobný, častěji se lze setkat v literatuře s jednoduššími tvary této rovnice. Jednou z variant je aproximace neuromuskulárního

Přenosová funkce řízené soustavy v okolí $\omega_c$	Typ přenosové funkce lidského operátora	Přenosová funkce lidského operátora
$F_S(p) = K_S$	"Lag-lead"	$F_R(p) = \frac{K_R}{T_I p + 1} \cdot e^{-p\tau}$
$F_S(p) = \frac{K_S}{p}$	"High-frequency lead"	$F_R(p) = K_R \cdot e^{-p\tau}$
$F_S(p) = \frac{K_S}{p^2}$	"Low-frequency lead"	$F_R(p) = K_R \cdot (T_L p + 1) \cdot e^{-p\tau}$
$F_S(p) = \frac{K_S}{p \cdot (T p + 1)}$	"Mid-frequency lead" ( $T > \tau$ )	$F_R(p) = K_R \cdot (T_L p + 1) \cdot e^{-p\tau}$
	"High-frequency lead" ( $T < \tau$ )	$F_R(p) = K_R \cdot e^{-p\tau}$
$F_S(p) = \frac{K_S}{\left(\frac{p}{\omega_n}\right)^2 + \frac{2\epsilon}{\omega_n} + 1}$	"Low-frequency lead" ( $\omega_c \ll \frac{1}{\tau}$ )	$F_R(p) = K_R \cdot (T_L p + 1) \cdot e^{-p\tau}$
	"Lag-lead" ( $\omega_c > \frac{1}{\tau}$ )	$F_R(p) = \frac{K_R}{T_I p + 1} \cdot e^{-p\tau}$

Tab. 1.2: Shrnutí přenosových funkcí lidského operátora dle rovnice 1.2 pro různé řízené prvky [9]

systemu pomocí čistého dopravního zpoždění  $\tau_N$ , tzv. Gross model. Výsledná přenosová funkce má pak tvar:

$$F_R = K_R \cdot \frac{T_L p + 1}{T_I p + 1} \cdot e^{-p(\tau + \tau_N)} \quad (1.4)$$

- , kde  $K_R$  ... Statické zesílení  
 $T_L$  ... Prediktivní časová konstanta (předstih - lead) [s]  
 $T_I$  ... Setrvačná časová konstanta (zpoždění - lag) [s]  
 $\tau$  ... Čisté dopravní zpoždění [s]  
 $p$  ... Laplaceův operátor

V současnosti bývá nejpoužívanější variantou rovnice 1.3 model, kde se neuromuskulární systém aproximuje setrvačným článkem prvního řádu s jednou časovou konstantou  $T_N$ . Tato varianta precision modelu je nazývána Tustin-McRuerův model a popisuje ho rovnice [10, 11]:

$$F_R = K_R \cdot \frac{(T_L p + 1)}{(T_I p + 1) \cdot (T_N p + 1)} \cdot e^{-p\tau} \quad (1.5)$$



- , kde  $K_R$  ... Statické zesílení  
 $T_L$  ... Prediktivní časová konstanta (předstih - lead) [s]  
 $T_I$  ... Setrvačná časová konstanta (zpoždění - lag) [s]  
 $T_N$  ... Neuromuskulární časová konstanta [s]  
 $\tau$  ... Čisté dopravní zpoždění [s]  
 $p$  ... Laplaceův operátor

V literatuře lze nalézt experimentálně zjištěné intervaly, ve kterých se hodnoty jednotlivých parametrů nejčastěji pohybují, viz tabulka 1.3.

Parametr	Typická hodnota
$\tau$	$(0, 1 - 1) s$
$T_L$	$(0, 2 - 6, 1) s$
$T_I$	$(0, 1 - 3, 7) s$
$T_N$	$(0, 05 - 2, 2) s$
$\omega_N$	<i>okolo</i> $20 \text{ rad} \cdot s^{-1}$
$\xi_N$	<i>okolo</i> $0.7$

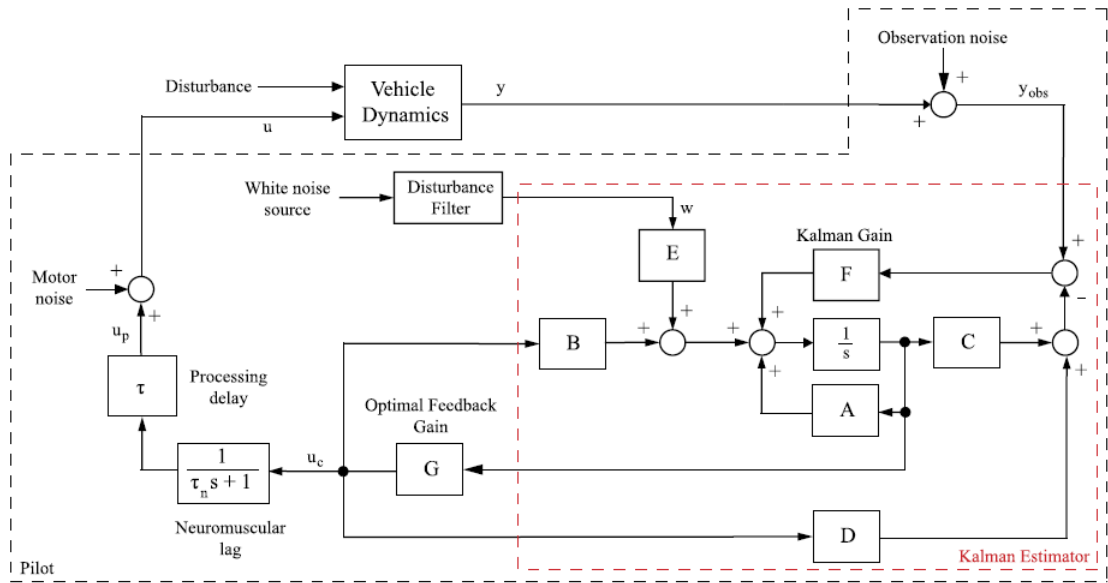
Tab. 1.3: Tabulka typických hodnot parametrů precision modelu [11, 12]

## 1.2.2 Další modely

Na rozdíl od kvazilineárního McRuerova modelu je model optimálního řízení (OCM – Optimal Control Model) a dynamika řízených prvků vyjádřena ve stavových proměnných. Tento model předpokládá, že dobře vyškolený a motivovaný lidský operátor se chová optimálním způsobem, přičemž je omezen pouze fyzickými možnostmi. Tato omezení jsou modelována jako časové zpoždění, pozorovací šum, který zde reprezentuje úroveň přesnosti pozorování přístrojů a rozložení pozornosti vůči jednotlivým přístrojům, a šum motorického systému. Obrázek 1.3 ukazuje blokové schéma OCM, které zahrnuje Kalmanův filtr, Kalmanovu predikci, optimální zpětnou vazbu, neuromuskulární dynamiku a časové (reakční) zpoždění. Optimální řešení se hledá pomocí následující kvadratické matice [7, 13]:

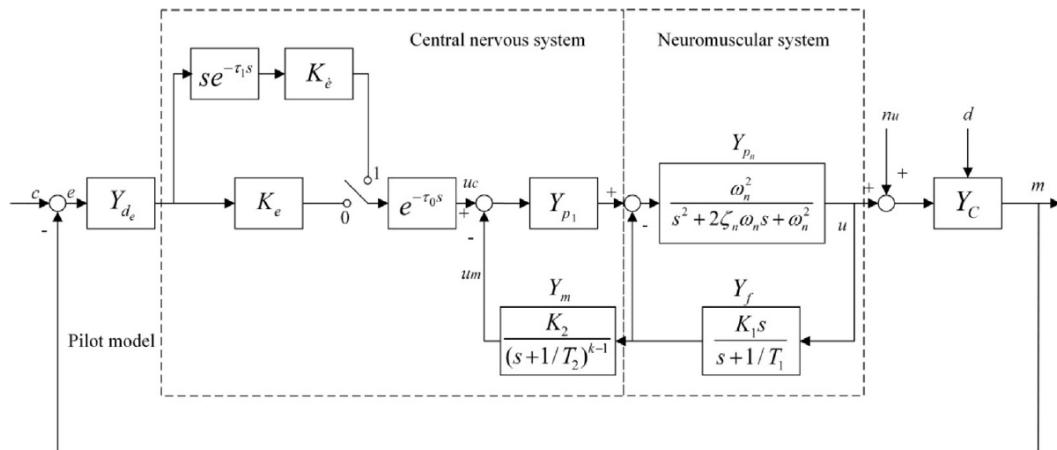
$$J(u) = E \lim_{\eta \rightarrow \infty} \frac{1}{\eta} \int_0^{\eta} (\mathbf{y}^T \mathbf{Q} \mathbf{y} + \mathbf{u}^T \mathbf{R} \mathbf{u} + \dot{\mathbf{u}}^T \mathbf{S} \dot{\mathbf{u}}) dt \quad (1.6)$$

- , kde  $u$  ... vektor akčního zásahu (výstup lidského operátora)  
 $y$  ... vektor výstupů řízeného prvku  
 $Q$  ... váha na výstupu interního modelu  
 $R$  ... váha řízení lidského operátora  
 $S$  ... váha rychlosti řízení lidského operátora



Obr. 1.3: Blokové schéma modifikovaného OCM [13, Fig.17]

I přes výhody McRuerova kvazilineárního modelu a OCM, nedokážou popsat základní strukturu dynamiky lidského operátora. Hessův strukturální model vychází z izomorfního modelu a jeho klíčovou myšlenkou je simulace zpětnovazebních cest z různých smyslových modalit. Parametry zpětné vazby, označované jako proprioceptivní, jsou vyladěny tak, aby odpovídaly crossover modelu v blízkosti frekvence řezu.



Obr. 1.4: Hessův strukturální model [7, Fig.9]

Jedna z verzí modelu je znázorněna na obrázku 1.4, kde  $Y_{de}$  je přenosová funkce dynamiky zobrazení,  $K_e$ ,  $K_e$ ,  $\tau_0$  a  $\tau_1$  reprezentují zesílení a časové zpoždění centrálního zpracování. Pulzní logika  $Y_{p1} = 1$  zde modeluje ovládání neuromuskulárního

systemu pomocí nervových impulzů a společně s prvkem  $Y_m$  popisují vnitřní zpětno-vazební smyčku lidského operátora. Prvek  $Y_{pn}$  je modelem otevřené smyčky neuro-muskulární dynamiky konkrétní končetiny řídicího manipulátoru a  $Y_f$  jsou svalová vřeténka.

Kromě Hessova strukturálního modelu patří k modelům založených na lidské fyziologii i Hosmanův deskriptivní model, jehož cílem bylo vyvinout a získat poznatky o vlivu vizuální a vestibulární stimulace na vnímání a chování pilota při řízení, a biodynamický model, který představuje účinky pohybu těla ve zrychlujícím se prostředí a dokáže předpovědět účinky pohybu na lidské zdraví, pohodlí nebo výkonnost.

Další kategorií jsou modely založené na inteligenci (fuzzy modely, neuronové sítě, neuro-fuzzy modely). Tyto modely jsou schopné zvládnout vysoce nelineární systémy nebo případy, kdy je přesný matematický popis řízeného prvku téměř nemožný. Jejich nevýhodou však jsou složitější a časově náročnější metody pro nastavení parametrů a validaci vytvořeného modelu [7].

## 2 Fuzzy logika

Jak již bylo nastíněno v úvodu tato práce se zabývá aproximací chování řidiče pomocí fuzzy modelu. Ještě než bude proveden návrh vhodného fuzzy modelu, musí být představeny základy fuzzy logiky a popsána struktura fuzzy systému.

Slovo fuzzy pochází z angličtiny a znamená „mlhavý, nejasný, neostrý nebo neurčitý“. Člověk, který stojí před řešením složitějšího úkolu, neuvažuje pomocí přesných hodnot, ale spíše „počítá“ s nenumerními hodnotami, např. blízko, rychle, málo atd.

Tradiční dvouhodnotové logické systémy, teorie množin a teorie pravděpodobnosti jsou nedostatečné pro řešení nepřesností, nejistot a složitostí reálného světa. Proto ačkoli je nejistota většinou nežádoucí, stává se velmi cennou, pokud ji uvažujeme s ostatními charakteristikami modelů systémů. Obecně platí, že větší nejistota snižuje složitost a zvyšuje důvěryhodnost výsledného modelu.


Lofti A. Zadeh představil teorii fuzzy množin, což jsou množiny s neurčitými hranicemi. Zadeh zpochybňoval teorii pravděpodobnosti i samotnou dvoustavovou logiku, tj. tvrzení, že prvek  $u$  je členem fuzzy množiny  $A$ , nemusí být nutně pravdivé nebo nepravdivé, ale může být pravdivé jen do určité míry. Jednotlivé prvky tedy mohou do fuzzy množiny patřit s větším nebo menším stupněm příslušnosti, který je reprezentován hodnotami reálných čísel z uzavřeného intervalu  $[0, 1]$ . Toto je vlastně základní koncept fuzzy množin, který je jednoduchý a intuitivní a který tvoří zobecnění klasické (ostré) množiny, kde mezi prvky patřící a nepatřící do množiny existuje jednoznačný rozdíl [14, 15].

### 2.1 Funkce příslušnosti


Funkce příslušnosti (membership function) mapuje univerzum na celý interval  $[0,1]$ , tj. každý prvek  $u$  z univerza  $U$  má určitý stupeň příslušnosti  $\mu_F(u) \in [0, 1]$ . Funkce příslušnosti může mít různý tvar, nejčastěji se pro snadnější výpočet používají po částech lomené funkce, viz obrázek 2.1. Jednotlivé oblasti se většinou pojmenovávají významově nezávisle: NB (Negativ Big – Negativní velký), NM (Negativ Medium – Negativní střední), NS (Negativ Small – Negativní malý), ZO (Zero – nulový), PS (Positive Small – Pozitivní malý), PM (Positive Medium – Pozitivní střední) a PB (Positive Big – Pozitivní velký), viz obrázek 2.2 [14].

### 2.2 Fuzzy číslo

Fuzzy číslo je vyjádřeno jako fuzzy množina definující fuzzy interval v reálných číslech. Fuzzy číslo by mělo být konvexní a normalizované, tj. funkce příslušnosti



Obr. 2.1: Typy funkcí příslušnosti [14]



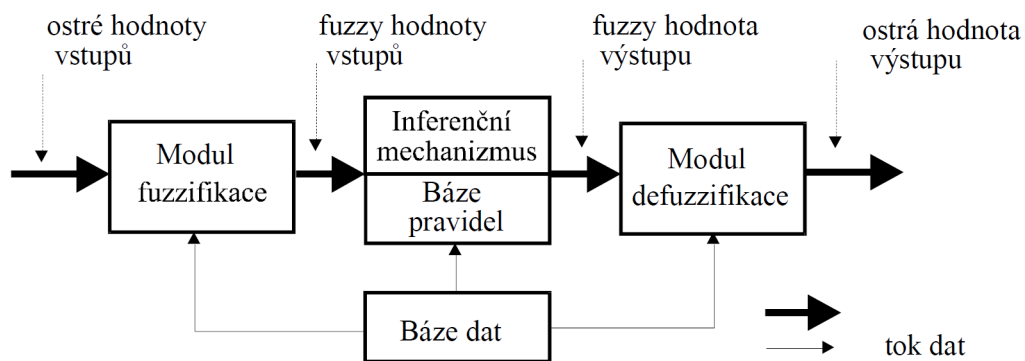
Obr. 2.2: Typické názvy oblastí [14]

nabývá maximální hodnoty 1. Dále by měla být funkce příslušnosti po částech spojitá

a definovaná na reálných číslech [16].

## 2.3 Fuzzy systém

Fuzzy systém je takový systém, jehož proměnné jsou definované slovními hodnotami (fuzzy množinami). Každá proměnná je definována na určitém univerzu, které bývá většinou interval reálných čísel. Fuzzy systém je tedy duchem mnohem blíže lidskému myšlení než klasické logické systémy, tudíž poskytuje účinný prostředek pro zachycení nepřesné povahy skutečného světa. Jak lze vidět na obrázku 2.3, fuzzy systém se skládá ze čtyř částí: fuzzifikace, znalostní báze, inferenčního mechanismu a defuzzifikace.




Obr. 2.3: Struktura fuzzy systému [14]

Cílem fuzzifikace je transformovat vstupní ostré hodnoty na hodnoty fuzzy. Toto je nejčastěji realizováno tak, že vstupní ostrá hodnota je považována za fuzzy číslo se speciálním typem funkce příslušnosti tzv. Singletonem. Pokud by ovšem byla vstupní data zarušena náhodným šumem, můžeme je považovat za fuzzy číslo s trojúhelníkovou funkcí příslušnosti. Následně pak toto číslo náleží do fuzzy množiny s nějakou příslušností (obrázek 2.4). Vstupní hodnoty mohou být ještě před fuzzifikací normalizovány přepočtem do interní číselné reprezentace na základě měřítka.

Znalostní báze se dělí na dvě části: bázi dat a bázi pravidel. Báze dat obsahuje údaje o fuzzy množinách a o fyzikálních rozsazích jednotlivých vstupních / výstupních veličin. Báze pravidel obsahuje všechna vyhodnocovací pravidla systému. Počet fuzzy členů ve vstupním prostoru určuje maximální počet pravidel. Pokud by měl fuzzy systém dvě vstupní proměnné, které obě mají 5 členů, pak maximální počet pravidel by byl 25 ( $5 \cdot 5$ ). Pravidla jsou zapsána ve formě:

$$\textit{if} (vstup = \langle hodnota \rangle) \textit{ then} (výstup = \langle hodnota \rangle)$$



Obr. 2.4: Fuzzifikace Singletonem (vlevo), Obecná fuzzifikace (vpravo) [14]


Inferenční mechanismus simuluje proces lidského rozhodování na základě fuzzy pravidel. Jeho úlohou je postupně vyhodnocovat všechna pravidla a slučovat jejich výsledky do jedné fuzzy množiny.

Cílem defuzzifikace je získat z fuzzy množiny, výsledek inferenčního mechanismu, ostrou hodnotu výstupní veličiny. Pokud jsme provedli při fuzzifikaci normalizaci vstupu, musíme zde provést denormalizaci opět podle měřítek. Existuje celá řada metod defuzzifikace, dále je uvedeno pár z nich [14, 16]:

Metoda středu plochy (COA – Center of Area) neboli metoda těžiště (COG – Center of Gravity) je nejpoužívanější metodou. Jak název napovídá výsledná ostrá hodnota veličiny je určena jako souřadnice těžiště. Pro spojité a diskrétní univerzum  $Y$  získáme výslednou ostrou hodnotu:

$$y^* = \frac{\int_Y y \cdot \mu_B(y) \cdot dy}{\int_Y \mu_B(y) \cdot dy} \quad (2.1)$$

$$y^* = \frac{\sum_{j=1}^m y_j \cdot \mu_B(y_j)}{\sum_{j=1}^m \mu_B(y_j)} \quad (2.2)$$




Obr. 2.5: Metoda těžiště (COG) [14]

Metoda středu součtů (COS – Center of Sum) je modifikací metody těžiště, která zohledňuje překryv funkcí příslušnosti. Pro spojitý a diskrétní univerzum  $Y$  získáme výslednou ostrou hodnotu ( $k$  je číslo pravidla a  $r$  je počet pravidel):

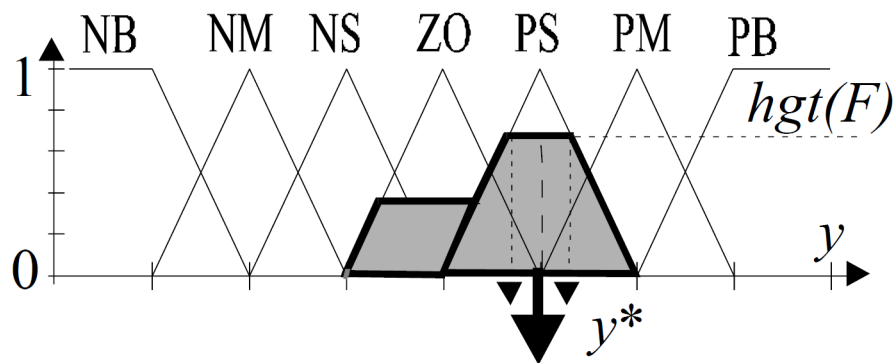
$$y^* = \frac{\int_Y y \cdot \sum_{k=1}^r \mu_k(y) \cdot dy}{\int_Y \sum_{k=1}^r \mu_k(y) \cdot dy} \quad (2.3)$$

$$y^* = \frac{\sum_{j=1}^m y_j \cdot \sum_{k=1}^r \mu_k(y_j)}{\sum_{j=1}^m \sum_{k=1}^r \mu_k(y_j)} \quad (2.4)$$



Obr. 2.6: Metoda středu součtů (COS) [14]

Metoda středu maxima (MOM – Mean of Maximum) dává jako výslednou ostrou hodnotu střední hodnotu všech výstupních členů, jejichž funkce příslušnosti dosahují maxima [14, 16].



Obr. 2.7: Metoda středu maxima (MOM) [14]

## 2.4 Fuzzy regulátory

Struktura fuzzy regulátoru se skládá stejně jako u fuzzy systému z fuzzifikace, znalostní báze, inferenčního mechanismu a defuzzifikace. Jednotlivé bloky plní stejnou



funkci jako u fuzzy systému [14].

### 2.4.1 Fuzzy P regulátor

Klasický P regulátor je popsán rovnicí:

$$u(k) = K_R \cdot e(k) \quad (2.5)$$

- , kde  $K_R$  ... zesílení regulátoru  
 $u(k)$  ... akční zásah regulátoru  
 $e(k)$  ... odchylka regulované hodnoty od požadované

Blokovou strukturu fuzzy P regulátoru lze vidět na obrázku 2.8 (vlevo). F značí modul fuzzifikace, D modul defuzzifikace a IM inferenční mechanismus se znalostní bází, která obsahuje pravidla ve tvaru:

$$if (e(k) = \langle hodnota \rangle) then (u(k) = \langle hodnota \rangle)$$

, kde hodnota je symbolické jméno hodnoty jazykové proměnné [14].

### 2.4.2 PD regulátor


Klasický PD regulátor je popsán rovnicí:

$$u(k) = K_R \cdot e(k) + K_D \cdot \Delta e(k) \quad (2.6)$$

- , kde  $K_D$  ... prediktivní časová konstanta  
 $\Delta e(k)$  ... diference odchylky  $e(k)$

Blokovou strukturu fuzzy PD regulátoru lze vidět na obrázku 2.8 (vpravo). Soubor pravidel fuzzy PD regulátoru má následující tvar [14]:

$$if (e(k) = \langle hodnota \rangle) and (\Delta e(k) = \langle hodnota \rangle) then (u(k) = \langle hodnota \rangle)$$



Obr. 2.8: Bloková struktura fuzzy P a PD regulátoru [14]

### 2.4.3 PI regulátor

Klasický PI regulátor je popsán rovnicí:

$$u(k) = K_R \cdot e(k) + K_I \cdot \delta e(k) \quad (2.7)$$

, kde  $K_I$  ... integrační zisk  
 $\delta e(k)$  ... sumace odchylky  $e(k)$

Fuzzy PI regulátor je často realizován tak, že provedeme diferenci této rovnice, tím získáme na výstupu přírůstek akčního zásahu. Proto musíme ještě za blok defuzifikace doplnit sumátor, abychom získali výsledný akční zásah. Diferenciací rovnice 2.7 dostaneme:

$$\Delta u(k) = K_R \cdot \Delta e(k) + K_I \cdot e(k) \quad (2.8)$$

Blokovou strukturu fuzzy PI regulátoru lze vidět na obrázku 2.9 (vlevo). Soubor pravidel fuzzy PI regulátoru má následující tvar [14]:

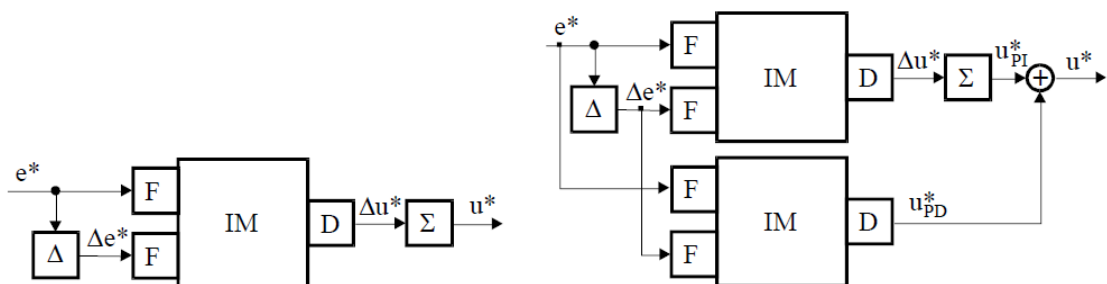
*if* ( $e(k) = \langle \text{hodnota} \rangle$ ) *and* ( $\Delta e(k) = \langle \text{hodnota} \rangle$ ) *then* ( $\Delta u(k) = \langle \text{hodnota} \rangle$ )

### 2.4.4 PID regulátor

Klasický PID regulátor je popsán rovnicí:

$$u(k) = K_R \cdot e(k) + K_D \cdot \Delta e(k) + K_I \cdot \delta e(k) \quad (2.9)$$

Fuzzy PID regulátor má kubickou matici pravidel, která se obtížně vytváří. Proto se většinou regulátor řeší jako součtově pracující fuzzy PI a PD regulátor, viz obrázek 2.9 (vpravo) [14].



Obr. 2.9: Bloková struktura PI a PID regulátoru [14]

## 3 Optimalizační metody

K identifikaci modelů se často používají různé optimalizační a vyhledávací metody, které nám dokáží efektivně prohledat prostor řešení a naleznout optimální či suboptimální řešení.

Cílem optimalizace je najít optimální či téměř optimální řešení s ohledem na nízkou výpočetní náročnost. Výpočetní náročnost u optimalizačních metod lze měřit jako čas (čas výpočtu) a prostor (paměť počítače), kterou metoda spotřebuje. Optimalizaci nejsme většinou schopni vyřešit v jediném kroku, ale provádí se určitý proces, který nás vede k řešení problému. Tento proces se dělí do postupně provádějících se kroků: rozpoznání a definice problému, konstrukce a řešení modelů a hodnocení a implementace řešení. Rozlišujeme dva různé typy optimalizačních metod: přesné optimalizační metody, které zaručují nalezení optimálního řešení, avšak za cenu vyšší výpočetní náročnosti, a heuristické optimalizační metody, kde nemáme záruku, že nalezené řešení bude optimální. Přesné optimalizační metody se volí převážně u problémů, u kterého výpočetní náročnost roste polynomiálně s velikostí problému. V současnosti se převážně využívají heuristické optimalizační metody, které jsou sice vázány na kvalitu vráceného řešení, avšak výpočetní náročnost metody je menší než u přesných metod, zejména díky využití efektivních mechanismů pro prohledávání vyhledávacího prostoru. Prvky moderní heuristiky jsou reprezentací a variační operátory, fitness funkce, počáteční řešení a vyhledávací strategie [16, 17].

### **Přesné optimalizační metody:**

- Analytické a numerické metody
  - Přímé metody
  - Gradientní metody
- Metody pro lineární a spojité problémy
  - Lineární programování
  - Simplexová metoda
  - Metoda vnitřních bodů
- Metody pro diskrétní problémy
  - Metody stromového vyhledávání
  - Metody větvení a ohraničení
  - Dynamické programování

### **Heuristické optimalizační metody:**

- Variabilní vyhledávání v okolí
- Řízené lokální vyhledávání
- Iterační lokální vyhledávání
- Evoluční strategie

## 3.1 Omezené nelineární optimalizační algoritmy

Omezená nelineární minimalizace řeší problém nalezení vektoru  $x$ , který je lokálním minimem ke skalární funkci  $f(x)$  podléhající omezením na přípustné  $x$  [20]:

$$\min_x f(x)$$

### 3.1.1 Metoda důvěryhodné oblasti

Metoda důvěryhodné oblasti je numerická optimalizační metoda, která se používá k řešení problémů nelineární optimalizace. Namísto hledání objektivního řešení původní funkce, metoda definuje okolí kolem aktuálního nejlepšího řešení jako důvěryhodnou oblast v každém kroku. Tyto kroky jsou generovány pomocí kvadratického modelu účelové funkce a pokud krok není přijatelný, zmenší velikost důvěryhodné oblasti a najde nový krok [21, 22].

### 3.1.2 Algoritmus aktivní sady

Při omezené optimalizaci je obecným cílem transformovat problém na snazší dílčí problém, který lze následně vyřešit a použít jako základ iterativního procesu. Charakteristickým znakem velké třídy raných metod je převod omezeného problému na základní neomezený problém pomocí penalizační funkce pro omezení. Tímto způsobem je problém řešen pomocí posloupnosti parametrizovaných neomezených optimalizací, které v limitě konvergují k problému. Tyto metody jsou dnes považovány za relativně neefektivní a byly nahrazeny metodami, které se zaměřovaly na řešení problému Karush-Kuhn-Tuckerovy (KKT) rovnice. KKT rovnice jsou nezbytnými podmínkami pro optimalitu pro omezený optimalizační problém.

Řešení KKT rovnic tvoří základ mnoha nelineárních programovacích algoritmů. Tyto algoritmy se pokoušejí vypočítat Lagrangeovy multiplikátory přímo. Vázané kvazi-Newtonovy metody zaručují superlineární konvergenci shromažďováním informací druhého řádu týkající se KKT rovnic pomocí kvazi-Newtonovy aktualizace. Tyto metody se běžně označují jako metody sekvenčního kvadratického programování (SQP) [20].

## 3.2 Genetické algoritmy

Koncept genetického algoritmu (GA) představil John H. Holland z Michiganské univerzity. Základní mechanismy GA jsou podobné darwinovským principům o biologické evoluci: reprodukce a "přežití nejschopnějšího". Díky své široké použitelnosti, snadnému použití a globální perspektivě se v poslední době stále více uplatňují

při řešení optimalizačních a vyhledávacích problémů. Typický algoritmus se sestává s následující posloupností operací:

1. vytvoření počáteční populace o velikosti  $n$  jedinců,
2. vyhodnocení každého jedince v populaci,
3. kontrola ukončovací podmínky, při splnění se algoritmus ukončí a vrátí nejlepšího jedince v populaci,
4. výběr dvojic jedinců z populace, popřípadě výběr nejlepších jedinců,
5. vytvoření nových jedinců křížením vybraných dvojic,
6. na nové jedince se aplikuje operátor mutace,
7. nahrazení staré populace novou,
8. jdi na krok 2.

Tento cyklus končí, pokud je splněna ukončovací podmínka nebo dosažením předem stanoveného limitu iterací. Jednotlivé parametry jedinců se nejčastěji kódují pomocí binárních řetězců, avšak mohou být kódovány i do řetězců reálných čísel nebo symbolických řetězců [16, 18].

### 3.2.1 Fitness funkce

Potřebujeme funkci, která by vyhodnotila vhodnost jednotlivých řešení. Fitness funkce je tedy důležitou částí GA, jelikož vyjadřuje, jak dobré řešení jedinec představuje. Funkce by měla být navržena tak, aby lepším řešením dávala vyšší hodnoty fitness funkce. Pokud existuje funkce, kterou je třeba optimalizovat, obvykle se používá jako fitness funkce [16].

### 3.2.2 Selektce

Pomocí operátoru selektce vybíráme vhodné jedince pro reprodukci, vybrané jedince nazýváme rodiči. Při selektci nejprve vyhodnotíme možnost jedince být vybrán na základě jeho fitness funkce. Tudíž čím vyšší má jedinec hodnotu fitness funkce, tím vyšší má možnost výběru [16, 18].


#### Ruletový výběr

Pravděpodobnost výběru jedince se rovná poměru jeho hodnoty fitness funkce k součtu hodnot fitness funkcí všech jedinců. Takže tato metoda dává jedincům pravděpodobnost výběru lineárně úměrnou jejich fitness funkci.

Jedinec	Fitness	$P_i$
1	31	0,19
2	42	0,26
3	25	0,15
4	54	0,33
5	12	0,07

Tab. 3.1: Ruletový výběr

- 1
- 2
- 3
- 4
- 5




Obr. 3.1: Ruletový výběr

### Poziční výběr

Na rozdíl od ruletového výběru není pravděpodobnost výběru lineárně úměrná jejich fitness funkci, ale je stanovena podle pořadí jejich fitness funkce.

Jedinec	Fitness	Pořadí	SP	$P_i$	SP	$P_i$
1	31	3	0,9	0,20	1,2	0,20
2	42	2	0,95	0,21	1,6	0,27
3	25	4	0,85	0,19	0,8	0,13
4	54	1	1,00	0,22	2,0	0,33
5	12	5	0,8	0,18	0,4	0,07


Tab. 3.2: Poziční výběr



Obr. 3.2: Poziční výběr a) SP = 1, b) SP = 2

### Turnajový výběr

Turnaje se účastní  $n$  náhodně vybraných jedinců. Vítězem se stává jedinec s vyšší fitness funkcí, který je umístěn do nové populace. Takto se postupuje, dokud nezaplníme všechny místa v nové populaci.



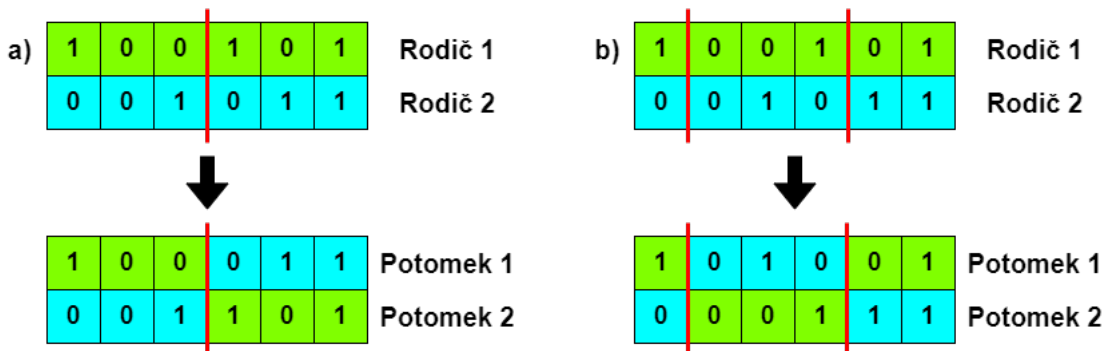
Obr. 3.3: Turnajový výběr

### 3.2.3 Křížení

Operátory křížení vytvářejí nové jedince (potomky) výměnou informací o vybraných jedincích (rodičích). Operace křížení se neprovádí na každém jedinci, ale GA rozhodne na základě dané pravděpodobnosti, zda ke křížení dojde či ne. Tato pravděpodobnost je dána uživateli [16, 19].

#### Binární kódování:

- jednobodové křížení,
- vícebodové křížení.



Obr. 3.4: a) Jednobodové křížení, b) Vícebodové křížení

**Reálné kódování:**

- bodové křížení,
- konvexní křížení,


$$P = p \cdot R_1 + (1 - p) \cdot R_2, p \in \langle 0, 1 \rangle \quad (3.1)$$

- křížení prolnutím.

$$g = rand(\min(g_1, g_2) - \alpha|g_1 - g_2|, \max(g_1, g_2) + \alpha|g_1 - g_2|) \quad (3.2)$$

### 3.2.4 Mutace

Operátor mutace mění některé náhodně vybrané parametry jedinců. Díky mutaci můžeme uniknout z lokálního optima, jelikož můžeme získat potomka, který se liší od svých rodičů. Pravděpodobnost mutace by však měla být velmi nízká, jinak by proces hledání mohl ztratit svůj směr [16, 19].

**Binární kódování:**

Obr. 3.5: Mutace u binárního kódování

**Reálné kódování:**

- změna o předem danou či náhodnou hodnotu,
- nahrazení náhodným číslem z daného intervalu,
- dynamická mutace, mění svou hodnotu v čase.

### 3.2.5 Elitismus

Typický GA zcela nahradí starou populaci nově vytvořenými jedinci, avšak je tu možnost, že jedinec s nejlepší fitness funkcí v nové generaci bude horší než jedinec ze staré populace a mohli bychom tak přijít o dobré řešení. Proto se používá elitismus, kdy se zkopíruje  $x$  nejlepších jedinců ze staré populace do další [16].



## 4 Simulátor řízení vozidla

Simulátor je založen na herním frameworku Unreal Engine 4. Systém je schopný vytvářet různé typy chování vozidla, vlastní scénáře jízdy a cykly měření pro získávání údajů o výkonu řidiče. Simulace umožňuje řidičům si vyzkoušet nebezpečné situace nebo situace náročné na dovednosti, které se vyskytují v běžném provozu [23].



Obr. 4.1: Simulátor [23, Fig.3]

### 4.1 Jízdní scénáře

V simulátoru se nachází několik scénářů různých situací, které poskytují komplexní informace o chování řidiče [23].

#### 4.1.1 Scénář kalibrace

Tento scénář umožňuje řidiči zvyknout si na chování vozidla. Řidič jede po silnici, na níž se nacházejí malé zatáčky a několik dopravních kuželů.

### 4.1.2 Dálnice: Odezva na jednotkový skok

Simulace se skládá z dlouhé rovné dálnice. Po dosažení určité požadované rychlosti je řidič v náhodných časových intervalech povinen změnit jízdní pruh, o čemž je vizuálně informován pomocí směrové šipky.

### 4.1.3 Dálnice: Scénář náhlých překážek

Obdobně jako u odezvy na jednotkový skok jede řidič po rovné dálnici, avšak v náhodných časových intervalech se před autem objevují překážky, kterým se řidič musí vyhnout.

### 4.1.4 Dálnice: Jízda na dlouhé vzdálenosti

Úkolem tohoto scénáře je několikrát projet dlouhou dálniční smyčkou, jejíž jeden průjezd trvá 15-25 minut, a přitom se snažit udržet ve stejném jízdním pruhu. Při vybočení z pruhu je řidič vizuálně varován, aby se vrátil zpět do pruhu. Simulace cílí na dlouhou dálniční jízdu, při které je vysoká pravděpodobnost únavy a ospalosti.

### 4.1.5 Losí test

Tato možnost je založena na reálném testu, jehož postupy jsou definovány normou. Jedná se o test použitelný při hodnocení schopnosti řidiče ovládat vozidlo a zároveň měří schopnosti a dynamiku vozidla.

## 4.2 Formát dat

Data jsou ukládána do souboru CSV. Pro každý scénář existuje samostatný soubor CSV, který obsahuje sadu naměřených dat o chování řidiče v dané situaci. Struktura dat je následující [23]:

- časové razítko,
- pozici X,
- pozici Y,
- odchylku od středu pruhu,
- rychlost vozidla,
- úhel natočení volantu,
- srdeční tep.

## 5 Identifikace parametrů McRuerova LTI modelu

Data pro identifikaci byla získána na simulátoru řízení vozidla, který byl zmíněn v předešlé kapitole. Pro zjednodušení identifikace modelu chování řidiče byl uvažován pouze jednoduchý systém s jedním vstupem a výstupem. Toto zjednodušení je provedeno tak, že řidič jede konstantní rychlostí po rovné silnici bez zatáček a simulátor je připevněn v pevné stabilní pozici, tudíž řidič nemá žádnou zpětnou vazbu. Řidič tedy sledoval pouze vzdálenost od středu pruhu a výstupem bylo natočení volantu. Řidičův pohled lze vidět na obrázku 5.1.



Obr. 5.1: Pohled řidiče v simulátoru [23, Fig.5]

### 5.1 Popis experimentu

Základem tohoto experimentu je měření akčního zásahu řidiče na skokovou změnu jízdního pruhu. Tato situace může v realitě nastat, pokud řidič předjíždí vozidlo, či se vyhýbá překážce. Řidič měl za úkol zrychlit na maximální rychlost 91 km/h a tu zachovat po celou dobu experimentu, následně se měl držet v daném jízdním pruhu, dokud nebude vyzván k jeho změně. Po vyzvání řidič musí přejet do druhého pruhu, ve kterém se poté musí držet do další výzvy. Pro tento experiment byl využit scénář Dálnice: Odezva na jednotkový skok, ve kterém každý řidič jel po rovné dálnici a reagoval na 17-32 skokových změn jízdního pruhu podle délky jeho jízdy.

Na základě výše popsaného experimentu bylo provedeno několik měření s řidiči, studenty Vysokého učení technického v Brně. Data ze simulátoru byla získána v souboru .csv, který obsahoval: čas experimentu, pozici X a Y, odchylku od středu pruhu, rychlost vozidla a úhel natočení volantu. Ukázkou části naměřených dat ze simulátoru řízení vozidla lze vidět v tabulce 5.1.

Time(ms)	Xpos	Ypos	SplineDistance	Velocity	WheelAngle
30471	4	61013	-3.685078	91.0	-0.019120
30478	5	61032	-3.676016	91.0	-0.019120
30485	6	61050	-3.666641	91.0	-0.019089
30492	7	61068	-3.657422	91.0	-0.018967
30499	8	61086	-3.648281	91.0	-0.018936
30506	9	61104	-3.638906	91.0	-0.018875
30514	10	61122	-3.629609	91.0	-0.018753
30521	11	61139	-3.620156	91.0	-0.018723
30528	12	61158	-3.610469	91.0	-0.018540
30535	13	61176	-3.600703	91.0	-0.018509
30542	14	61194	-3.591094	91.0	-0.018357
30549	15	61212	-3.581250	91.0	-0.018296
30556	16	61230	-3.571484	91.0	-0.018143
30563	17	61248	-3.561563	91.0	-0.018082

Tab. 5.1: Ukáзка naměřených dat ze simulátoru řízení vozidla

## 5.2 Identifikace parametrů

Identifikace parametrů byla provedena v programu Matlab a jeho System Identification Toolboxu, kde byl použit odhad pomocí procesního modelu. Vstupním signálem byla změna jízdního pruhu (skoková změna), která byla pro řidiče převedena na odchylku od středu pruhu  $e(t)$  a výstupem bylo natočení volantu řidičem  $u(t)$ . Pro názorné porovnání přesnosti jednotlivých McRuerových modelů byly pro odhad uvažovány tyto modely:

- Gross model – rovnice 1.4

$$F_R = K_R \cdot \frac{T_{LP} + 1}{T_{IP} + 1} \cdot e^{-p(\tau + \tau_N)}$$

- Tustin-McRuerův model – rovnice 1.5

$$F_R = K_R \cdot \frac{(T_{LP} + 1)}{(T_{IP} + 1) \cdot (T_{NP} + 1)} \cdot e^{-p\tau}$$

- Precision model – rovnice 1.3


$$F_R = K_R \cdot \frac{T_L p + 1}{T_I p + 1} \cdot e^{-p\tau} \cdot \frac{1}{\left[ \left( \frac{p}{\omega_N} \right)^2 + \frac{2\xi_N p}{\omega_N} + 1 \right]}$$

Jelikož identifikace u předchozích modelů vycházela dobře jen pro některé skoky, byl přidán ještě následující náhradní model [24]:

$$F_R = K_R \cdot \frac{p}{T^2 p^2 + 2\xi T p + 1} \cdot e^{-p\tau} \quad (5.1)$$

- ,kde
- $K_R$  ... Statické zesílení
  - $T$  ... Časová konstanta [s]
  - $\xi$  ... Tlumení
  - $\tau$  ... Reakční zpoždění [s]
  - $p$  ... Laplaceův operátor

V tomto případě lze pohyb vozidla aproximovat dvojitým integrátorem, tudíž podle McRuerova crossover zákona se musí tato dynamika kompenzovat regulátorem ve tvaru  $K_R \cdot p \cdot e^{-p\tau}$ . Jmenovatel modelu reprezentuje vliv neuromuskulárního systému a vnitřní zpětné vazby z prvního stavu řízeného systému souvisejícího s vnímáním rychlosti [24].



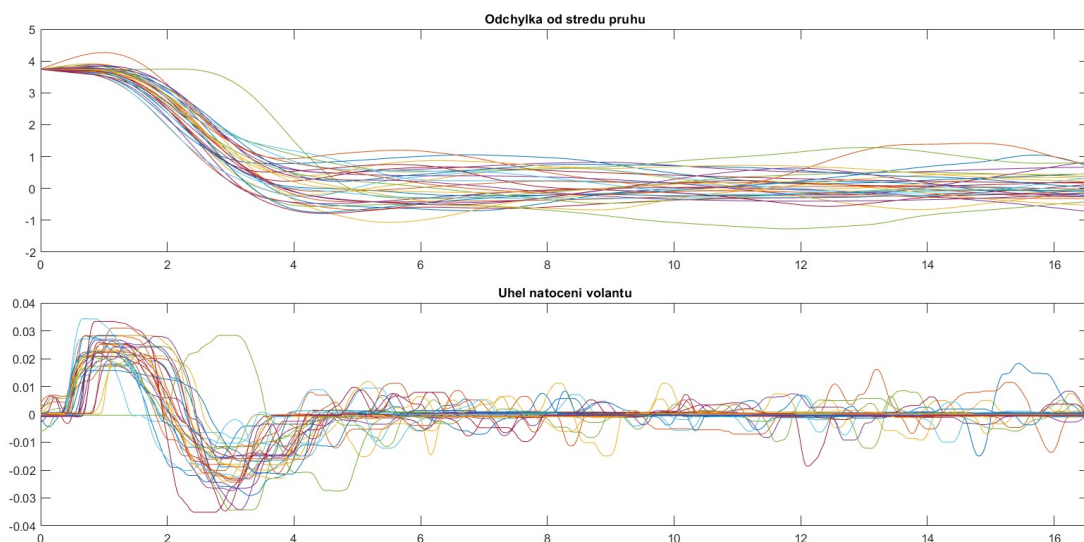
Obr. 5.2: Nezpracovaná naměřená data pro řidiče A

Před identifikací parametrů jednotlivých modelů bylo třeba nejdříve zpracovat naměřená data. Z naměřených dat byly vyčteny data potřebná pro identifikaci: čas experimentu, odchylka od středu pruhu a úhel natočení volantu, viz obrázek 5.2. Následně byla data rozdělena na jednotlivé skoky a začátky jednotlivých skoků byly

posunutú na stejnou počáteční hodnotu. Data po zpracování lze vidět na obrázku 5.3 pro řidiče A. Po úpravě byly data rozděleny na validační a trénovací skoky, kdy prvních 5 skoků bylo přiřazeno jako validační a zbylé skoky jako trénovací.

### 5.3 Identifikované LTI modely

U řidičů A a B jsou pro porovnání uvedeny vždy tři modely. První odpovídá nejlépe hodnocenému modelu na trénovacích datech, druhý model nejlépe hodnocenému na validačních datech a třetí je průměrný model. Průměrný model byl získán aritmetickým průměrem parametrů modelů, které měly hodnocení vyšší než 75% z nejvyšší hodnoty přesnosti na trénovacích datech. Tato hodnota byla vybrána, jelikož u této hodnoty průměrný model vykazoval nejvyšší přesnost u většiny dat. Průměrný model se počítal přibližně z 10 - 20 identifikovaných modelů, u náhradního modelu až z 30 modelů. Hodnota Best fit v závorce u názvu modelu odpovídá hodnotě nejvyšší přesnosti modelu na trénovacích datech. U zbylých řidičů je uveden pouze nejlepší z modelů a hodnoty přesnosti všech tří modelů pro porovnání lze vidět v tabulce 5.2.



Obr. 5.3: Vstupní a výstupní signály pro identifikaci řidiče A

Pro řidiče A vyšly identifikované modely následovně:

- Gross model (Best fit 48,34%):

$$F_R = 4,42 \cdot 10^{-4} \cdot \frac{16,03p + 1}{0,62p + 1} \cdot e^{-0,72p}$$

$$F_R = 3,68 \cdot 10^{-4} \cdot \frac{16,07p + 1}{0,70p + 1} \cdot e^{-0,73p}$$

$$F_R = 4,75 \cdot 10^{-4} \cdot \frac{14,75p + 1}{0,63p + 1} \cdot e^{-0,71p}$$

- Tustin-McRuerův model (Best fit 61,46%)

$$F_R = 2,39 \cdot 10^{-4} \cdot \frac{(32,61p + 1)}{(0,38p + 1)^2} \cdot e^{-0,39p}$$

$$F_R = 2,11 \cdot 10^{-4} \cdot \frac{(32,61p + 1)}{(0,34p + 1)^2} \cdot e^{-0,46p}$$

$$F_R = 2,49 \cdot 10^{-4} \cdot \frac{(32,61p + 1)}{(0,35p + 1)^2} \cdot e^{-0,46p}$$

- Precision model (Best fit 79,09%)

$$F_R = 4,49 \cdot 10^{-4} \cdot \frac{13,37p + 1}{3,6 \cdot 10^{-3}p + 1} \cdot e^{-0,71p} \cdot \frac{1}{\left[ \left( \frac{p}{2,17} \right)^2 + \frac{2 \cdot 0,29p}{2,17} + 1 \right]}$$

$$F_R = 5,01 \cdot 10^{-4} \cdot \frac{10,52p + 1}{3,6 \cdot 10^{-3}p + 1} \cdot e^{-0,34p} \cdot \frac{1}{\left[ \left( \frac{p}{1,81} \right)^2 + \frac{2 \cdot 0,33p}{1,81} + 1 \right]}$$

$$F_R = 6,21 \cdot 10^{-4} \cdot \frac{10,41p + 1}{3,6 \cdot 10^{-3}p + 1} \cdot e^{-0,54p} \cdot \frac{1}{\left[ \left( \frac{p}{2,10} \right)^2 + \frac{2 \cdot 0,26p}{2,10} + 1 \right]}$$

- Náhradní model (Best fit 74,08%)

$$F_R = 5,00 \cdot 10^{-3} \cdot \frac{p}{0,28p^2 + 0,42p + 1} \cdot e^{-0,29p}$$

$$F_R = 4,50 \cdot 10^{-3} \cdot \frac{p}{0,32p^2 + 0,38p + 1} \cdot e^{-0,43p}$$

$$F_R = 5,30 \cdot 10^{-3} \cdot \frac{p}{0,29p^2 + 0,34p + 1} \cdot e^{-0,41p}$$

Pro řidiče **B** vyšly identifikované modely následovně:

- Gross model (Best fit 43,65%):

$$F_R = 5,78 \cdot 10^{-4} \cdot \frac{8,51p + 1}{0,58p + 1} \cdot e^{-0,79p}$$

$$F_R = 7,18 \cdot 10^{-4} \cdot \frac{8,68p + 1}{0,96p + 1} \cdot e^{-0,59p}$$


$$F_R = 6,01 \cdot 10^{-4} \cdot \frac{14,76p + 1}{0,68p + 1} \cdot e^{-0,81p}$$

- Tustin-McRuerův model (Best fit 60,69%)

$$F_R = 1,70 \cdot 10^{-4} \cdot \frac{(33,22p + 1)}{(0,30p + 1)^2} \cdot e^{-0,70p}$$

$$F_R = 2,11 \cdot 10^{-4} \cdot \frac{(32,61p + 1)}{(0,45p + 1)^2} \cdot e^{-0,60p}$$

$$F_R = 1,99 \cdot 10^{-4} \cdot \frac{(33,08p + 1)}{(0,61p + 1)(0,20p + 1)} \cdot e^{-0,61p}$$



Obr. 5.4: Porovnání modelů pro řidiče A

- Precision model (Best fit 75,78%)

$$F_R = 3,99 \cdot 10^{-5} \cdot \frac{105,56p + 1}{5,7 \cdot 10^{-3}p + 1} \cdot e^{-1,05p} \cdot \frac{1}{\left[\left(\frac{p}{1,83}\right)^2 + \frac{2 \cdot 0,16p}{1,83} + 1\right]}$$

$$F_R = 4,13 \cdot 10^{-5} \cdot \frac{105,58p + 1}{5,7 \cdot 10^{-3}p + 1} \cdot e^{-0,39p} \cdot \frac{1}{\left[\left(\frac{p}{1,47}\right)^2 + \frac{2 \cdot 0,41p}{1,47} + 1\right]}$$

$$F_R = 4,50 \cdot 10^{-5} \cdot \frac{105,58p + 1}{5,7 \cdot 10^{-3}p + 1} \cdot e^{-0,60p} \cdot \frac{1}{\left[\left(\frac{p}{1,72}\right)^2 + \frac{2 \cdot 0,28p}{1,72} + 1\right]}$$

- Náhradní model (Best fit 70,67%)

$$F_R = 4,90 \cdot 10^{-3} \cdot \frac{p}{0,44p^2 + 0,53p + 1} \cdot e^{-0,52p}$$

$$F_R = 4,20 \cdot 10^{-3} \cdot \frac{p}{0,46p^2 + 0,54p + 1} \cdot e^{-0,43p}$$

$$F_R = 4,80 \cdot 10^{-3} \cdot \frac{p}{0,40p^2 + 0,41p + 1} \cdot e^{-0,40p}$$

Pro řidiče C vyšly identifikované modely následovně:


- Gross model (Best fit 54,29%):

$$F_R = 1,44 \cdot 10^{-4} \cdot \frac{27,29p + 1}{0,21p + 1} \cdot e^{-0,43p}$$

- Tustin-McRuerův model (Best fit 11,50%)

$$F_R = -3,6 \cdot 10^{-3} \cdot \frac{(2,10 \cdot 10^{-5}p + 1)}{(5,05 \cdot 10^{-4}p + 1)(0,02p + 1)} \cdot e^{-0,87p}$$






Obr. 5.5: Porovnání modelů pro řidiče B

- Precision model (Best fit 80,04%)

$$F_R = 2,64 \cdot 10^{-4} \cdot \frac{15,03p + 1}{0,02p + 1} \cdot e^{-0,30p} \cdot \frac{1}{\left[ \left( \frac{p}{6,87} \right)^2 + \frac{2 \cdot 0,35p}{6,87} + 1 \right]}$$

- Náhradní model (Best fit 76,50%)

$$F_R = 0,03 \cdot \frac{p}{0,03p^2 + 0,11p + 1} \cdot e^{-0,27p}$$



Obr. 5.6: Porovnání modelů pro řidiče C

Pro řidiče D vyšly identifikované modely následovně:

- Gross model (Best fit 41,27%):

$$F_R = 1,28 \cdot 10^{-4} \cdot \frac{31,26p + 1}{0,27p + 1} \cdot e^{-0,48p}$$

- Tustin-McRuerův model (Best fit 47,19%)


$$F_R = 5,14 \cdot 10^{-4} \cdot \frac{(7,47p + 1)}{(0,18p + 1)(0,10p + 1)} \cdot e^{-0,38p}$$

- Precision model (Best fit 68,25%)

$$F_R = 1,17 \cdot 10^{-4} \cdot \frac{43,26p + 1}{0,15p + 1} \cdot e^{-0,21p} \cdot \frac{1}{\left[ \left( \frac{p}{5,66} \right)^2 + \frac{2 \cdot 0,60p}{5,66} + 1 \right]}$$

- Náhradní model (Best fit 67,64%)

$$F_R = 4,50 \cdot 10^{-3} \cdot \frac{p}{0,07p^2 + 0,29p + 1} \cdot e^{-0,21p}$$



Obr. 5.7: Porovnání modelů pro řidiče D

Pro řidiče E vyšly identifikované modely následovně:

- Gross model (Best fit 44,39%):

$$F_R = 1,20 \cdot 10^{-3} \cdot \frac{4,86p + 1}{0,56p + 1} \cdot e^{-0,61p}$$

- Tustin-McRuerův model (Best fit 54,58%)


$$F_R = 3,44 \cdot 10^{-5} \cdot \frac{(213,72p + 1)}{(0,42p + 1)(0,41p + 1)} \cdot e^{-0,41p}$$

- Precision model (Best fit 64,75%)

$$F_R = 8,77 \cdot 10^{-4} \cdot \frac{5,69p + 1}{7,40 \cdot 10^{-3}p + 1} \cdot e^{-0,33p} \cdot \frac{1}{\left[\left(\frac{p}{1,96}\right)^2 + \frac{2 \cdot 0,29p}{1,96} + 1\right]}$$

- Náhradní model (Best fit 79,16%)

$$F_R = 5,60 \cdot 10^{-3} \cdot \frac{p}{0,31p^2 + 0,40p + 1} \cdot e^{-0,29p}$$



Obr. 5.8: Porovnání modelů pro řidiče E

Pro řidiče F vyšly identifikované modely následovně:

- Gross model (Best fit 32,36%):

$$F_R = 2,51 \cdot 10^{-4} \cdot \frac{17,70p + 1}{0,26p + 1} \cdot e^{-0,61p}$$

- Tustin-McRuerův model (Best fit 29,80%)


$$F_R = -2,3 \cdot 10^{-3} \cdot \frac{(2,32p + 1)}{(0,38p + 1)^2} \cdot e^{-1,58p}$$

- Precision model (Best fit 77,37%)

$$F_R = 3,51 \cdot 10^{-4} \cdot \frac{12,09p + 1}{0,15p + 1} \cdot e^{-0,31p} \cdot \frac{1}{\left[\left(\frac{p}{3,27}\right)^2 + \frac{2 \cdot 0,18p}{3,27} + 1\right]}$$

- Náhradní model (Best fit 70,34%)

$$F_R = 3,30 \cdot 10^{-3} \cdot \frac{p}{0,11p^2 + 0,12p + 1} \cdot e^{-0,47p}$$



Obr. 5.9: Porovnání modelů pro řidiče F

Pro řidiče G vyšly identifikované modely následovně:

- Gross model (Best fit 49,24%):

$$F_R = 3,14 \cdot 10^{-4} \cdot \frac{14,30p + 1}{0,45p + 1} \cdot e^{-0,42p}$$

- Tustin-McRuerův model (Best fit 59,05%)

$$F_R = 2,39 \cdot 10^{-4} \cdot \frac{(23,77p + 1)}{(0,31p + 1)(0,22p + 1)} \cdot e^{-0,24p}$$

- Precision model (Best fit 79,86%)

$$F_R = 5,70 \cdot 10^{-4} \cdot \frac{5,86p + 1}{0,02p + 1} \cdot e^{-0,24p} \cdot \frac{1}{\left[ \left( \frac{p}{3,02} \right)^2 + \frac{2 \cdot 0,25p}{3,02} + 1 \right]}$$

- Náhradní model (Best fit 77,26%)

$$F_R = 3,00 \cdot 10^{-3} \cdot \frac{p}{0,14p^2 + 0,21p + 1} \cdot e^{-0,14p}$$


Pro řidiče H vyšly identifikované modely následovně:

- Gross model (Best fit 34,72%):

$$F_R = 1,1 \cdot 10^{-3} \cdot \frac{4,26p + 1}{0,42p + 1} \cdot e^{-0,65p}$$

- Tustin-McRuerův model (Best fit 55,70%)

$$F_R = 1,89 \cdot 10^{-4} \cdot \frac{(35,02p + 1)}{(0,34p + 1)(0,26p + 1)} \cdot e^{-0,53p}$$




Obr. 5.10: Porovnání modelů pro řidiče G

- Precision model (Best fit 78,59%)

$$F_R = 1,52 \cdot 10^{-4} \cdot \frac{31,98p + 1}{0,01p + 1} \cdot e^{-0,39p} \cdot \frac{1}{\left[\left(\frac{p}{2,10}\right)^2 + \frac{2 \cdot 0,24p}{2,10} + 1\right]}$$

- Náhradní model (Best fit 76,97%)

$$F_R = 5,40 \cdot 10^{-3} \cdot \frac{p}{0,27p^2 + 0,30p + 1} \cdot e^{-0,36p}$$



Obr. 5.11: Porovnání modelů pro řidiče H

Pro řidiče I vyšly identifikované modely následovně:

- Gross model (Best fit 40,39%):

$$F_R = 4,86 \cdot 10^{-5} \cdot \frac{79,69p + 1}{0,49p + 1} \cdot e^{-0,53p}$$

- Tustin-McRuerův model (Best fit 60,29%)


$$F_R = 1,20 \cdot 10^{-5} \cdot \frac{(469,93p + 1)}{(0,41p + 1)(0,41p + 1)} \cdot e^{-0,25p}$$

- Precision model (Best fit 71,18%)

$$F_R = 1,87 \cdot 10^{-4} \cdot \frac{20,41p + 1}{0,01p + 1} \cdot e^{-0,16p} \cdot \frac{1}{\left[ \left( \frac{p}{2,21} \right)^2 + \frac{2 \cdot 0,42p}{2,21} + 1 \right]}$$

- Náhradní model (Best fit 72,62%)

$$F_R = 3,60 \cdot 10^{-3} \cdot \frac{p}{0,22p^2 + 0,40p + 1} \cdot e^{-0,15p}$$



Obr. 5.12: Porovnání modelů pro řidiče I

## 5.4 Porovnání modelů

Pro každý lineární model řidiče byl po identifikaci vybrán nejlepší model na trénovacích datech, nejlepší model na validačních datech a poté byl vypočítán průměrný model. V příloze A lze vidět pro názornost porovnání odezev těchto 3 modelů na validačních datech pro řidiče A a B. Souhrn přesností jednotlivých modelů řidičů se nachází v tabulce 5.2.

	Řidič A			Řidič B			Řidič C		
	TD	VD	P	TD	VD	P	TD	VD	P
GM	27,24	29,61	27,82	33,60	34,98	10,73	23,24	25,83	25,23
TMM	33,32	35,16	32,01	38,82	44,02	42,24	3,01	6,60	0,85
PM	33,89	45,03	26,90	16,48	55,28	41,37	36,89	45,43	39,71
NM	41,34	45,94	44,30	54,20	55,11	47,20	36,21	39,98	35,11
	Řidič D			Řidič E			Řidič F		
	TD	VD	P	TD	VD	P	TD	VD	P
GM	24,27	24,28	22,88	32,34	35,72	19,72	20,91	23,69	14,34
TMM	28,81	30,50	27,39	44,30	46,76	28,30	3,78	13,00	4,99
PM	16,51	35,97	3,22	54,61	54,63	45,32	27,64	37,26	6,43
NM	16,80	35,65	16,93	37,75	55,40	53,40	39,88	39,88	36,00
	Řidič G			Řidič H			Řidič I		
	TD	VD	P	TD	VD	P	TD	VD	P
GM	25,14	26,70	22,56	22,53	26,18	17,99	23,09	35,96	16,57
TMM	31,05	33,96	30,90	35,51	39,01	35,32	35,90	45,77	40,44
PM	23,51	30,30	15,44	53,70	53,70	49,46	44,37	53,32	51,70
NM	21,58	36,63	31,98	51,36	52,93	54,02	43,94	55,04	53,31

Tab. 5.2: Souhrn přesností jednotlivých modelů sady řidičů

Můžeme si všimnout, že model, který vyjde po identifikaci jako nejlepší, nemusí být poté nejlepší i při použití na jiných datech. U řidičů je zjevné, že čím podrobnější model byl použit, tím vzrostla i jeho přesnost na validačních datech. Z tabulky 5.2 lze vyčíst, že nejlépe se podařilo aproximovat řidiče B, E, H a I, kde přesnost přesáhla 50%, naopak nejhůře dopadl řidič D, který má pouze 36%. Lze si všimnout, že ne všechny modely šly dobře identifikovat, nejlépe to lze pozorovat u řidiče C a F u Tustin-McRuerova modelu, kde se přesnost pohybuje velmi nízko na rozdíl od Gross modelu. Jak již bylo dříve řečeno, musel být přidán náhradní model, který je též zjednodušením precision modelu, avšak v přesnosti se mu nejen vyrovná, ale naopak je často ještě přesnější.

Při porovnání jednotlivých parametrů s typickými hodnotami z tabulky 1.3 si můžeme všimnout, že typickým hodnotám odpovídá pouze dopravní zpoždění  $\tau$  a u Gross a Tustin-McRuerova modelu ještě setrvačná  $T_I$  a neuromuskulární  $T_N$  časová konstanta, jinak se většina parametrů modelů u řidičů pohybuje mimo okolí typických hodnot. Neuromuskulární systém je sice nedílnou součástí modelu lidského operátora, avšak v tomto modelu je součástí modelu spolu s vnitřní zpětnou vazbou z prvního stavu řízení systému, který souvisí s vnímáním rychlosti změny polohy [24]. Tudíž identifikovaný model neodpovídá pouze modelu s neuromuskulár-

ním systémem, ale má i vnitřní zpětnou vazbu, a z tohoto důvodu nesedí parametry modelu s typickými hodnotami.



## 6 Návrh vhodné struktury fuzzy modelu

Lineární McRuerovy modely byly již představeny v úvodní kapitole a v předchozí kapitole identifikovány. Nyní při návrhu vhodné struktury fuzzy regulátoru budeme z těchto modelů vycházet, zejména z McRuerova precision modelu (Rovnice 1.3), u kterého se ponechá část s neuromuskulárním systémem a dopravním zpožděním a zbytek se nahradí fuzzy regulátorem.


$$F_R = \underbrace{K_R \cdot \frac{T_L p + 1}{T_I p + 1}}_{\text{Nahrazeno Fuzzy PD}} \cdot e^{-p\tau} \cdot \frac{1}{\left[ \left( \frac{p}{\omega_N} \right)^2 + \frac{2\xi_N p}{\omega_N} + 1 \right]}$$

Dále i z jeho zjednodušení náhradního modelu (Rovnice 5.1), kde se kromě reakčního zpoždění nahradí celý model.

$$F_R = K_R \cdot \underbrace{\frac{p}{T^2 p^2 + 2\xi T p + 1}}_{\text{Nahrazeno Fuzzy PD}} \cdot e^{-p\tau}$$


Existují čtyři typy fuzzy regulátorů: P, PD, PI a PID. Nahrazení této dynamiky systému P regulátorem by nebylo možné, tudíž nebude uvažován. Při použití PI regulátoru by nešlo nijak ovlivnit derivační charakter modelu, a to by bylo také nežádoucí, tudíž zbývají poslední dvě možnosti PD a PID regulátor. PID regulátor tuto dynamiku zcela nahrazuje, avšak také ztíží samotnou identifikaci modelu. Když se ovšem podíváme na identifikované precision modely, můžeme si všimnout, že setrvačná časová konstanta  $T_I$  je velmi malá. Při jejím zanedbání nám model plně nahradí i PD regulátor a identifikace modelu by se zjednodušila. Pro aproximaci chování lidského operátora byl tedy vybrán fuzzy PD regulátor, který při nahrazení precision modelu doplní neuromuskulární systém s dopravním zpožděním a při nahrazení náhradního modelu pouze dopravní zpoždění.

Dále by se měla navrhnout ještě struktura samotného fuzzy PD regulátoru. PD regulátor má dva vstupní signály odchylku  $e(t)$  a diferenci odchylky  $\Delta e(t)$  a jeden výstupní signál akční zásah  $u(t)$  (Obrázek 6.1).



Obr. 6.1: Struktura fuzzy PD regulátoru ve Fuzzy toolboxu (Matlab)

Pro zjednodušení identifikace regulátoru bude uvažováno, že oba vstupní signály v bloku fuzzifikace a výstupní signál v bloku defuzzifikace bude mapován pomocí tří  $\Lambda$  funkcí příslušnosti (Obrázek 6.2), které mají na vstupu či výstupu normalizované hodnoty v rozsahu  $[-1, 1]$ .



Obr. 6.2: Mapovací funkce signálu PD regulátoru


Jelikož máme 2 vstupy a každý vstup má 3 funkce příslušnosti, bude zapotřebí nastavit 9 pravidel, které lze vidět na obrázku 6.3. Následně při identifikaci bude zapotřebí ladit celkem 12 parametrů pro 9 funkcí příslušnosti. Těmito parametry bude možné nastavit překrytí jednotlivých funkcí příslušnosti.

1. If (e is N) and (de is N) then (u is N) (1)
2. If (e is N) and (de is Z) then (u is N) (1)
3. If (e is N) and (de is P) then (u is Z) (1)
4. If (e is Z) and (de is N) then (u is N) (1)
5. If (e is Z) and (de is Z) then (u is Z) (1)
6. If (e is Z) and (de is P) then (u is P) (1)
7. If (e is P) and (de is N) then (u is Z) (1)
8. If (e is P) and (de is Z) then (u is P) (1)
9. If (e is P) and (de is P) then (u is P) (1)

Obr. 6.3: Pravidla fuzzy PD regulátoru

## 7 Identifikace fuzzy modelu

Pro identifikaci jsou použity fuzzy modely, které byly specifikovány v minulé kapitole, viz obrázek 7.1. Hodnoty parametrů neuromuskulární části modelu vycházejícího z precision modelu jsou dosazeny na základě typických hodnot z tabulky 1.3, za parametr  $\omega_N$  byla dosazena hodnota  $20 \text{ rad} \cdot \text{s}^{-1}$  a za  $\epsilon_N$  hodnota 0,7.




Obr. 7.1: Fuzzy model

### 7.1 Genetický algoritmus

K identifikaci parametrů fuzzy modelu byl použit genetický algoritmus, který je v současné době jedním z nejpoužívanějších optimalizačních algoritmů, díky svému snadnému a širokému použití. Dalšími výhodami genetického algoritmu jsou nižší výpočetní náročnost oproti klasickým numerickým metodám, efektivita prohledávání prostoru všech řešení a použitelnost na diskrétní a nelineární modely.

Základním prvkem genetického algoritmu je jedinec, který měl v našem případě 25 genů (parametrů), které se nechají rozdělit do tří skupin: Měřítko a časové zpoždění (4), funkce příslušnosti (12) a pravidla (9). Tyto parametry byly kódovány pomocí řetězce reálných čísel. Funkce příslušnosti byly zakódovány (viz obrázek 7.2) tak, že krajní body funkce příslušnosti Z jsou realizovány jako vzdálenost od vrcholu funkce a krajní body funkcí N a P pak jako velikost překrytí s funkcí Z.



Obr. 7.2: Kódování funkcí příslušnosti fuzzy PD regulátoru

Ve výpise 7.1 si lze všimnout, že počáteční populace je generována se 100 jedinci, ze kterých se následně podle vyhodnocení vybere 15 nejlepších. Tímto přístupem je zajištěna dobrá počáteční populace, bez které bychom se nemuseli dostat k dobrému výsledku. Nastavení rozmezí pro počáteční generování měřítek vychází z analýzy výsledků po několika pokusech identifikace v širším prostoru. Parametry  $a$  a  $b$  byly omezeny na velikost 1, aby funkce příslušnosti  $Z$  nepřekračovala meze  $\langle -1; 1 \rangle$  a parametry překrytí  $c$  a  $d$  byly omezeny na velikost 2, aby při maximální velikosti parametru  $a$  nebo  $b$  bylo možné funkcí příslušnosti  $N$  či  $P$  pokrýt celé rozmezí. Následně pravidla jsou generována jako celočíselné hodnoty od 1 do 3, kde 1 odpovídá funkci příslušnosti  $N$  na výstupu, 2 funkci  $Z$  a 3 funkci  $P$ .

Výpis 7.1: Tvorba počáteční populace v prostředí Matlab.

```

1 %% Pocatecni populace
2 n = 100;
3 PP = [0.3 * rand(n,1) ...
4       30 * rand(n,1) + 40 ...
5       0.2 * rand(n,1) ...
6       rand(n,7) ...
7       2 * rand(n,6) ...
8       randi([1, 3], n, 9)];
9
10 % Vyhodnoceni
11 Vpp = GAVyhodnoceni(PP, Pdfis, eT, eD, uT, Model);
12
13 % Vyber 15 nejlepsich jedincu
14 [M, I] = maxk(Vpp, 15);
15 P = PP(I, :);
16 Vp = M;

```

Pro selekci byl vybrán ruletový výběr, který je vidět realizovaný na výpisu 7.2. Nejprve je nutné vynulovat záporné hodnoty fitness funkce, jelikož s nimi nelze udělat komulativní ohodnocení. Následně je vypočítána pravděpodobnost selekce a komulativní ohodnocení jedince. Selekcce je realizována vygenerováním náhodných čísel a na základě porovnání s komulativním ohodnocením jsou vybráni jedinci. Nakonec jsou ještě vybráni nejlepší jedinci pomocí elitismu, kteří se přímo dostávají do další generace.

Výpis 7.2: Selekce a elitismus v prostředí Matlab.

```

1 %% Ruletovy vyber
2 % Znevazeni zapornych fitness funkci
3 Vp = Vp .* (Vp > 0);
4
5 % Pravdepodobnost selekce
6 pVp = Vp / sum(Vp);
7
8 % Komulativni ohodnoceni jedincu
9 for k = 1:length(Vp)
10     kVp(k) = sum(pVp(1:k));
11 end
12
13 % Vyber jedincu
14 selVp = rand(1, Pocet(1));
15 for k = 1:Pocet(1)
16     for l = 1:length(kVp)
17         if selVp(k) <= kVp(l)
18             sP(k, :) = P(l, :);
19             break;
20         end
21     end
22 end
23
24 %% Elitismus
25 [~, sortVp] = sort(Vp, "descend");
26 eP = P(sortVp(1:Pocet(2)), :);

```

Křížení parametrů je realizováno pomocí prolnutí až na parametry pravidel, kde bylo použito jednobodové křížení, kdy se parametry kříží v náhodně vygenerovaném bodě. U křížení prolnutí je nejdříve spočítána minimální a maximální hodnota pro generování nového parametru, následně je zkontrolováno omezení parametrů zpoždění a parametrů  $a$  a  $b$  v intervalu  $\langle 0; 1 \rangle$  a parametrů  $c$  a  $d$  v intervalu  $\langle 0; 2 \rangle$ . Tvorba potomků s výpočtem minimální a maximální hodnoty pro generování pak vychází z rovnice 3.2.

Potomci vytvoření křížením mají následně 15% šanci na mutaci, která je realizována vynásobením parametru hodnotou 1,1 a pro pravidla nahrazením náhodně vygenerovaným celým číslem od 1 do 3.

Výpis 7.3: Křížení v prostředí Matlab.

```

1 %% Krizení prolnutím
2 for l = 1:16
3     % Minimalni a maximalni hodnota
4     % pro generovani nove hodnoty parametru
5     M = mink([Rd(k, l) Rd(k+1, l)], 2, 2);
6     Mi = M(:, 1) - alpha * abs(M(:, 1) - M(:, 2));
7     Ma = M(:, 2) + alpha * abs(M(:, 1) - M(:, 2));
8
9     % Omezení parametru
10    if l > 10
11        Mi = max([Mi zeros(length(k), 1)], [], 2);
12        Ma = min([Ma 2*ones(length(k), 1)], [], 2);
13    elseif l > 3
14        Mi = max([Mi zeros(length(k), 1)], [], 2);
15        Ma = min([Ma ones(length(k), 1)], [], 2);
16    end
17
18    % Tvorba potomku
19    Pt([k k+1], l) = reshape((Ma - Mi) .* ...
20        rand(length(k),2) + Mi, [12, 1]);
21 end
22
23 %% Krizení bodové
24 for l = 17:25
25     % Generování bodu krizení
26     x = randi([17,24], 6);
27
28     % Tvorba potomku
29     Pt(k, 17:25) = [Rd(k, 17:x) Rd(k+1, x+1:25)];
30     Pt(k+1, 17:25) = [Rd(k+1, 17:x) Rd(k, x+1:25)];
31 end

```

Výpis 7.4: Mutace v prostředí Matlab.

```

1 % 15% sance na mutaci
2 m = ((rand(size(P)) < 0.15) + 10) / 10;
3
4 % Mutace realizovana nasobenim cislem 1.1
5 mP = P .* m;
6
7 % Mutace pro pravidla - nahrazeni nahodnym cislem
8 for a = 1:size(P, 1)
9     for b = 17:25
10        if rem(mP(a, b), 1) > 0
11            mP(a, b) = randi([1, 3]);
12        end
13    end
14 end

```

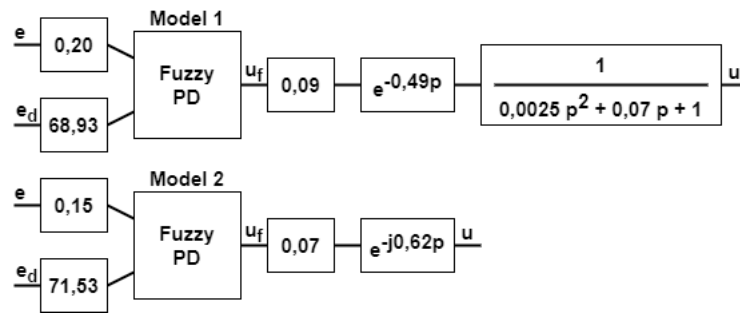
Ve funkci vyhodnocení se nejprve vybere typ fuzzy modelu a upraví se funkce příslušnosti a pravidla fuzzy regulátoru. Následně se vypočítá akční zásah fuzzy regulátoru a pomocí funkce compare se vyhodnotí jednotliví jedinci. Funkce compare počítá fitness funkci pomocí normalizované střední kvadratické chyby:

$$fit = 100 \cdot \left( 1 - \frac{\|u - \hat{u}\|}{\|u - mean(u)\|} \right) \quad (7.1)$$


## 7.2 Identifikované fuzzy modely

Pomocí genetického algoritmu byly identifikovány 2 modely pro každého řidiče. První model vychází z precision modelu, jehož součástí je kromě fuzzy PD regulátoru i dopravní zpoždění a neuromuskulární systém, a druhý model z náhradního modelu, kde kromě regulátoru je ještě reakční zpoždění.

V příloze B lze vidět výsledné parametry a pravidla identifikovaných fuzzy modelů, kde TD znamená přesnost na trénovacích datech a VD přesnost na validačních datech. Pro lepší představu významu hodnot jednotlivých parametrů v tabulce je zde přiložen vizuální příklad pro řidiče A. Na obrázku 7.3 lze vidět jednotlivá měřítka a časové zpoždění pro model 1 i 2, na obrázku 7.4 jsou zobrazeny funkce příslušnosti pro oba vstupy i výstup modelu 1, které jsou upraveny na základě identifikovaných parametrů, a na posledním obrázku 7.5 jsou přehledně zobrazeny pravidla fuzzy modelu 1.



Obr. 7.3: Měřítka a časové zpoždění modelu 1 a 2 řidiče A



Obr. 7.4: Funkce příslušnosti modelu 1 řidiče A

		<b>e</b>		
		<b>N</b>	<b>Z</b>	<b>P</b>
<b>eD</b>	<b>Z</b>	P	N	Z
	<b>Z</b>	N	Z	P
	<b>P</b>	P	P	P


Obr. 7.5: Pravidla fuzzy modelu 1 řidiče A



Jak si lze všimnout model 1 s neuromuskulárním systémem je na validačních datech o něco přesnější u 6 z 9 řidičů. Obdobně jako u lineárních modelů se nejlépe podařilo identifikovat modely u řidičů A, B, E, H a I, u kterých přesnost vystoupala až nad 50%, naopak u řidiče C, D a F se přesnost pohybovala okolo 40%.

## 8 Porovnání fuzzy a LTI modelů


Když porovnáme nejlepší LTI model s fuzzy modely, viz obrázek 8.2 a příloha C, lze si všimnout, že fuzzy modely jsou ve většině případů o něco přesnější než nejlepší lineární model. Největší rozdíl mezi fuzzy a nejlepším lineárním modelem je u řidičů A a B, kde je rozdíl okolo 7%. Dále pak u řidiče G je rozdíl mezi lineárním modelem a fuzzy modelem 1 jen 3%, avšak fuzzy model 2 vyšel oproti nim o více než 10% přesnější. Lze si všimnout, že nejlepší lineární model předčil oba dva fuzzy modely u řidiče C a alespoň jeden model u řidiče E a I. Nejvyrovnanější modely vyšli u řidiče H, kde se oba fuzzy modely a jeden lineární vešly do rozmezí 2%. Pro lepší představu rozdílu přesností jednotlivých modelů je zde přidán obrázek 8.1, kde jsou graficky porovnány odezvy jednotlivých modelů řidiče A.



Obr. 8.1: Porovnání modelů řidiče A

Rozdíly mezi lineárními a fuzzy modely se sice nemusí zdát moc velké, ale musíme brát v potaz, že identifikované fuzzy modely mají jen 3 funkce příslušnosti pro každý vstup i výstup a je také brán pouze PD regulátor. Přidáním více funkcí příslušnosti či změnou jejich tvaru by šlo dosáhnout ještě vyšší přesnosti u aproximace dat, avšak by k tomu byl nutný daleko vyšší výpočetní výkon.

Pokud bychom porovnávaly modely na základě potřebného výpočetního výkonu k identifikaci vzhledem k jejich výsledné přesnosti, lépe by z toho vyšli určitě lineární modely, jelikož algoritmus pro jejich identifikaci trval v rozmezí 5-20 minut v závislosti na složitosti identifikovaného modelu a velikosti trénovacích dat. Oproti tomu identifikace fuzzy modelu trvala zhruba 20-30 minut v závislosti na počtu generací a při velikosti populace o 15 jedincích.



Obr. 8.2: Souhrn přesností fuzzy a lineárních modelů

# Závěr

Jak již bylo zmíněno v úvodu, cílem této diplomové práce bylo nalézt vhodný fuzzy model pro aproximaci datových řad reprezentujících řídicí zásahy řidiče při změně jízdního pruhu. Pro splnění tohoto cíle se postupovalo podle bodů zadání.

Nejprve bylo nutné prostudovat problematiku modelování chování lidského operátora. Tato problematika je velmi komplexní, a proto byla tato oblast zaměřena především na McRuerovy modely chování lidského operátora. Teorie říká, že člověk je velmi všestranný a adaptivní regulátor. Mezi nejpoužívanější modely v současnosti patří Tustin-McRuerův model, který je zjednodušením precision modelu. Toto zjednodušení spočívá v aproximaci neuromuskulárního systému setrvačným článkem prvního řádu.

Na základě těchto poznatků poté byly identifikovány tři různé modely pro dva řidiče v prostředí Matlab – System Identification Toolbox. Pro identifikaci se použila naměřená data ze simulátoru řízení vozidla a odhad se vytvořil pomocí procesního modelu. Zde bylo zjištěno, že ne na všech datech lze nalézt dobré řešení, a tudíž musel být přidán ještě čtvrtý model, který se dokázal lépe přizpůsobit jednotlivým datům. Dospělo se k závěru, že čím podrobnější model jsme identifikovali, tím byl přesnější. Tomuto se vymykal pouze přidáný čtvrtý model, který je také zjednodušením precision modelu, ale v přesnosti se mu nejen dokáže vyrovnat, ale dokáže být ještě přesnější. Pokud porovnáme parametry neuromuskulární části modelu s jeho typickými hodnotami, zjistíme, že většina parametrů se liší od typických hodnot. To vyplývá z toho, že neuromuskulární systém je sice nedílnou součástí lidského operátora, avšak v těchto modelech je součástí zpětné vazby z prvního stavu řízení systému a tudíž identifikované hodnoty neodpovídají pouze neuromuskulární části, ale i parametrů zpětné vazby.

Pro získání lepší aproximace chování lidského operátora lze použít fuzzy modely. Tohoto tématu se týká další část diplomové práce, kde bylo potřeba nejdříve nastudovat fuzzy teorii a na jejím základě poté navrhnout vhodnou strukturu fuzzy modelu.

Navrhovaný fuzzy model vychází z McRuerova precision modelu, kde se zachová neuromuskulární část s dopravním zpožděním a zbytek se nahradí fuzzy PD regulátorem, a náhradního modelu, ve kterém se nahradí fuzzy PD regulátorem vše kromě reakčního zpoždění. Fuzzy PD regulátor byl vybrán jednak z důvodu malé setrvačné časové konstanty u precision modelu, kterou lze zanedbat, a zároveň díky jednodušší identifikaci oproti PID regulátoru a možnosti ovlivnit i derivační charakter modelu oproti PI regulátoru.

K identifikaci parametrů fuzzy modelu byl vybrán genetický algoritmus, který díky svému snadnému a širokému použití je jednou z nejpoužívanějších optimalizač-

ních metod současnosti. Fuzzy model byl zakódován pomocí řetězce reálných čísel do 25 parametrů, které obsahovali: 3 měřítka, časové zpoždění, funkce příslušnosti a 9 pravidel. Funkce příslušnosti byly zakódované od středu funkce Z, kdy 2 parametry udávaly vzdálenost krajních bodů funkce Z od jejího vrcholu a další 2 poté překrytí s funkcemi N a P.

V počáteční populaci bylo vygenerováno 100 jedinců, ze kterých se následně vybralo 15 nejlepších, z nichž se vytvořila následující generace za pomoci operátorů selekce, křížení a mutace. Selekcce byla prováděna ruletovým výběrem, kdy se vybralo 12 jedinců, ze kterých se následně vytvořili jejich potomci. K nim se přidaly 3 nejlepší jedinci z původní populace, pomocí elitismu. Fitness funkce byla vyhodnocována funkcí compare, která pro výpočet přesnosti používá normalizovanou střední kvadratickou chybu.

Když porovnáme identifikované LTI a fuzzy modely, lze si všimnout, že ve většině případů jsou o něco přesnější fuzzy modely. Největší rozdíl přesností je u řidiče A a B, kde jsou fuzzy modely asi o 7% přesnější, naopak u řidiče C vyšel o 2% přesnější lineární model. Z čehož vyplývá, že za pomoci fuzzy modelů se nechá lépe aproximovat chování řidiče než za pomoci zjednodušených LTI modelů, avšak za cenu požadavku na vyšší výpočetní výkon.

Přesnost fuzzy modelů lze ještě zvýšit ať už přidáním dalších funkcí příslušností nebo změnou jejich tvaru. Dalším zpřesněním by mohlo být použití fuzzy PID regulátoru, který by mohl lépe reagovat na změny. Avšak nevýhodou zvýšení přesnosti by byl určitě požadavek na velký výpočetní výkon a také na čas identifikace, jelikož bychom řešení hledali v daleko větším vyhledávacím prostoru.

# Literatura

- [1] MCRUER, Duane T. Human dynamics in man-machine systems. *Automatica* [online]. Pergamon Press, 1980, 16(3), str. 237-253 [cit. 2022-10-07]. ISSN 0005-1098. Dostupné z: doi:10.1016/0005-1098(80)90034-5
- [2] MCRUER, Duane T., Wade ALLEN a David WEIR. The Man/Machine Control Interface. *IFAC Proceedings Volumes* [online]. 1978, 1(11), str. 2225-2231 [cit. 2022-10-07]. ISSN 1474-6670. Dostupné z: doi:10.1016/S1474-6670(17)66210-4
- [3] HAVLÍKOVÁ, Marie. Člověk v systémech člověk – stroj. *Journal of Safety Research and Applications* [online]. 2008, (3) [cit. 2022-10-07]. Dostupné z: <https://www.bozpinfo.cz/josra/clovek-v-systemech-clovek-stroj>.
- [4] HAVLÍKOVÁ, Marie. Dynamika lidského operátora v systémech MMS. *Automatizace* [online]. 2008, 51(1), str. 17-20 [cit. 2022-10-07]. Dostupné z: [https://user.unob.cz/jalovecky/HMI/R2008/Zdroje/Havl%C3%ADkov%C3%A1\\_Dynamika%20lidsk%C3%A9ho%20oper%C3%A1tora.pdf](https://user.unob.cz/jalovecky/HMI/R2008/Zdroje/Havl%C3%ADkov%C3%A1_Dynamika%20lidsk%C3%A9ho%20oper%C3%A1tora.pdf).
- [5] JOHANNSEN, Gunnar. Man-Machine Systems - Introduction and Background. *IFAC Proceedings Volumes* [online]. 1982, 15(6), str. XIII-XVII [cit. 2022-10-12]. ISSN 1474-6670. Dostupné z: doi:10.1016/S1474-6670(17)62878-7
- [6] RASMUSSEN, Jens. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE transactions on systems, man, and cybernetics* [online]. New York, NY: IEEE, 1983, SMC-13(3), str. 257-266 [cit. 2022-10-07]. ISSN 0018-9472. Dostupné z: doi:10.1109/TSMC.1983.6313160
- [7] XU, Shuting, Wenqian TAN, Alexander V. EFREMOV, Liguó SUN a Xiangju QU. Review of control models for human pilot behavior. *Annual Reviews in Control* [online]. 2017, (44), str. 274-291 [cit. 2022-10-07]. ISSN 1367-5788. Dostupné z: doi:10.1016/j.arcontrol.2017.09.009
- [8] A Tribute to Duane T McRuer. *System Technology Inc.* [online]. [cit. 2022-10-24]. Dostupné z: <https://www.systemstech.com/company/history/a-tribute-to-duane-t-mcruer/>
- [9] MCRUER, Duane T. a Henry R. JEX. A Review of Quasi-Linear Pilot Models. *IEEE Transactions on Human Factors in Electronics* [online]. 1967, HFE-8(3), str. 231-249 [cit. 2022-10-24]. Dostupné z: doi:10.1109/THFE.1967.234304

- [10] MCRUER, Duane T. a Ezra S. KRENDEL. Mathematical Models of Human Pilot Behavior. *Advisory Group for Aerospace Research and Development* [online]. Paříž: National Technical Information Service, 1974 [cit. 2022-10-24]. Dostupné z: [https://www.researchgate.net/publication/235141382\\_Mathematical\\_Models\\_of\\_Human\\_Pilot\\_Behavior](https://www.researchgate.net/publication/235141382_Mathematical_Models_of_Human_Pilot_Behavior).
- [11] JIRGL, Miroslav. Analýza modelů chování pilota při řízení letu letounu [online]. Dizertační práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. 2017 [cit. 2022-12-13]. Dostupné z: <https://dspace.vutbr.cz/handle/11012/61784>.
- [12] JIRGL, Miroslav, Marie HAVLÍKOVÁ a Zdeněk BRADÁČ. The Dynamic Pilot Behavioral Models. *Procedia Engineering* [online]. 2015, (100), str. 1192-1197 [cit. 2022-10-24]. ISSN 1877-7058. Dostupné z: doi:10.1016/j.proeng.2015.01.483
- [13] LONE, Mudassir a Alastair COOKE. Review of pilot models used in aircraft flight dynamics. *Aerospace Science and Technology* [online]. 2014, 34(1), str. 55–74 [cit. 2022-10-24]. Dostupné z: doi:10.1016/j.ast.2014.02.003
- [14] JURA, Pavel. Základy fuzzy logiky pro řízení a modelování [online]. Brno: Vysoké učení technické v Brně, Nakladatelství VUTIUM, 2003 [cit. 2022-10-24]. ISBN 80-214-2261-0. Dostupné z: <https://www.vut.cz/studenti/predmety/detail/259112>.
- [15] YUAN, Bo a George J. KLIR. Fuzzy Sets and Fuzzy Logic Theory and Applications [online]. New Jersey: Prentice Hall, 1995 [cit. 2022-10-24]. ISBN 01-310-1171-5. Dostupné z: <http://www.pzs.dstu.dp.ua/logic/bibl/yuan.pdf>.
- [16] LEE, Kwang H. First course on fuzzy theory and applications [online]. New York: Springer-Verlag, 2005 [cit. 2022-10-07]. ISBN 3-540-22988-4. Dostupné z: <https://engineering.futureuniversity.com/BOOKS%20FOR%20IT/First%20Course%20n%20Fuzzy%20Theory%20and%20Application.pdf>.
- [17] ROTHLAUF, Franz. Design of Modern Heuristics: Principles and Application [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011 [cit. 2023-04-28]. Natural Computing Series. ISBN 978-3-540-72962-4. Dostupné z: doi:10.1007/978-3-540-72962-4\_3
- [18] DEB, Kalyanmoy. An introduction to genetic algorithms. *Sadhana* [online]. 1999, 24(4-5), str. 293–315 [cit. 2023-04-08]. Dostupné z: doi:10.1007/BF02823145


- [19] HONZÍK, Petr. Evoluční algoritmy [online]. Vysoké učení technické v Brně, 2014 [cit. 2023-04-08]. Dostupné z: [http://vision.uamt.feec.vutbr.cz/STU/lectures/09\\_Evolucni\\_algoritmy.pdf](http://vision.uamt.feec.vutbr.cz/STU/lectures/09_Evolucni_algoritmy.pdf)
- [20] Constrained Nonlinear Optimization Algorithms. *MathWorks Help Center* [online]. [cit. 2023-04-15]. Dostupné z: <https://www.mathworks.com/help/optim/ug/constrained-nonlinear-optimization-algorithms.html#brnox01>
- [21] CHOU, Chun-Yu, Yun-Chung PAN, Chen-Hua WANG a Ting-Guang YEH. Trust-region methods. *Cornell University Computational Optimization Open Textbook* [online]. 2021 [cit. 2023-04-15]. Dostupné z: [https://optimization.cbe.cornell.edu/index.php?title=Trust-region\\_methods](https://optimization.cbe.cornell.edu/index.php?title=Trust-region_methods)
- [22] NOCEDAL, Jorge a Stephen J. WRIGHT. Numerical Optimization. *Springer Series in Operations Research and Financial Engineering* [online]. New York, NY: Springer, 1999 [cit. 2023-04-15]. Dostupné z: doi:10.1007/0-387-22742-3\_4
- [23] MICHALÍK, David, Miroslav JIRGL, Jakub ARM a Petr FIEDLER. Developing an Unreal Engine 4-Based Vehicle Driving Simulator Applicable in Driver Behavior Analysis-A Technical Perspective. *Design for Transport Safety* [online]. MDPI, 2021, 7(2), str. 1-17 [cit. 2022-10-07]. ISSN 2313-576X. Dostupné z: doi:10.3390/safety7020025
- [24] JIRGL, Miroslav, Petr FIEDLER a Zdeněk BRADÁČ. Human Driver Performance Assessment based on HiLCPS Concept [online]. Vysoké učení technické v Brně [cit. 2023-04-08].




# Seznam příloh

A Porovnání LTI McRuerových modelů	70
B Parametry identifikovaných fuzzy modelů	78
C Porovnání Fuzzy a LTI modelů	80
D Obsah elektronické přílohy	88


# A Porovnání LTI McRuerových modelů




Obr. A.1: Porovnání Gross modelů pro řidiče A




Obr. A.2: Porovnání Gross modelů pro řídiče B




Obr. A.3: Porovnání Tustin-McRuerových modelů pro řidiče A




Obr. A.4: Porovnání Tustin-McRuerových modelů pro řidiče B



Obr. A.5: Porovnání Precision modelů pro řídiče A




Obr. A.6: Porovnání Precision modelů pro řídiče B



Obr. A.7: Porovnání Náhradních modelů pro řidiče A





Obr. A.8: Porovnání Náhradních modelů pro řidiče B

## B Parametry identifikovaných fuzzy modelů


Řidič	A	B	C	D	E	F	G	H	I
TD	52,54	46,14	39,70	43,47	63,43	39,40	51,98	55,83	54,84
VD	53,80	63,47	43,05	39,46	59,43	41,40	50,54	56,22	56,76
$M_e$	0,20	0,17	0,26	0,35	0,17	0,17	0,23	0,17	0,26
$M_{ed}$	68,93	54,90	94,60	56,12	49,65	68,20	64,49	64,01	59,37
$M_u$	0,09	0,04	0,06	0,08	0,12	0,10	0,04	0,06	0,05
$\tau$	0,49	0,70	0,25	0,28	0,56	0,47	0,37	0,59	0,55
$A_1$	1,00	0,43	0,46	0,58	0,59	0,56	1,00	0,88	0,53
$B_1$	0,98	0,67	0,76	0,66	0,72	0,98	0,40	1,09	1,09
$A_2$	0,99	0,57	0,78	0,90	0,60	0,99	1,10	0,61	0,88
$B_2$	1,00	0,31	0,69	0,42	0,33	1,08	0,90	0,41	0,28
$A_3$	0,97	0,03	1,10	0,76	1,09	0,84	1,10	0,69	0,98
$B_3$	0,52	0,43	1,01	0,41	0,35	0,49	0,75	0,73	0,86
$C_1$	1,63	1,19	1,43	2,12	1,27	1,24	1,15	1,34	1,39
$D_1$	2,09	1,89	1,95	1,51	1,93	0,17	1,98	1,13	0,27
$C_2$	2,06	2,00	0,64	1,04	1,39	1,93	0,89	0,49	1,63
$D_2$	2,06	0,84	1,94	1,99	1,93	1,68	0,12	0,75	1,20
$C_3$	1,90	0,41	1,64	1,73	0,78	0,17	1,06	0,82	1,19
$D_3$	1,97	0,11	0,51	1,81	0,33	1,28	1,30	1,37	1,54
Pravidla (e / eD)									
N / N	P	N	Z	Z	N	N	N	P	P
N / Z	N	P	N	N	Z	P	Z	N	N
N / P	P	N	Z	N	Z	N	Z	P	N
Z / N	N	N	Z	N	Z	Z	N	N	N
Z / Z	Z	P	Z	Z	Z	Z	N	Z	Z
Z / P	P	P	P	P	Z	P	P	P	P
P / N	Z	Z	N	N	N	N	N	Z	Z
P / Z	P	Z	P	P	P	N	P	P	P
P / P	P	P	P	P	P	P	Z	P	P

Tab. B.1: Parametry identifikovaných fuzzy modelů 1


Řidič	A	B	C	D	E	F	G	H	I
TD	50,63	48,56	38,92	46,05	55,32	40,67	39,28	53,54	48,66
VD	52,83	62,88	38,21	41,87	52,39	44,43	38,79	56,25	52,30
$M_e$	0,15	0,07	0,22	0,28	0,14	0,22	0,31	0,26	0,20
$M_{ed}$	71,53	69,07	86,90	50,46	55,53	47,86	67,01	66,54	84,33
$M_u$	0,07	0,05	0,05	0,10	0,06	0,10	0,07	0,08	0,04
$\tau$	0,62	0,73	0,31	0,35	0,62	0,59	0,56	0,62	0,72
$A_1$	0,69	0,41	0,04	0,69	0,79	0,88	0,65	0,36	0,99
$B_1$	0,32	0,31	0,31	1,01	0,39	0,73	0,28	0,52	1,03
$A_2$	0,88	0,79	0,22	0,51	0,52	0,61	1,11	0,69	0,97
$B_2$	0,80	0,84	0,10	0,41	0,89	0,72	0,99	0,20	0,74
$A_3$	0,80	0,88	0,75	0,83	0,33	0,38	0,90	0,99	0,50
$B_3$	0,80	0,80	0,56	0,48	0,65	0,13	0,95	0,38	0,13
$C_1$	2,12	0,62	0,84	1,97	1,80	0,29	1,56	0,46	1,60
$D_1$	0,23	0,54	1,99	1,52	1,26	1,31	0,48	1,38	1,80
$C_2$	0,77	0,77	0,06	1,44	0,06	0,56	1,96	1,42	1,41
$D_2$	0,77	0,79	1,52	1,31	1,31	1,82	2,02	0,91	2,15
$C_3$	0,77	0,77	1,17	0,12	0,24	1,39	1,67	1,36	0,15
$D_3$	0,70	0,78	0,50	1,38	0,47	2,13	1,94	0,30	0,47
Pravidla (e / eD)									
N / N	N	P	P	N	Z	P	N	N	Z
N / Z	Z	N	N	N	N	P	P	Z	N
N / P	P	P	N	P	N	N	N	P	Z
Z / N	Z	N	Z	Z	N	Z	Z	N	N
Z / Z	Z	Z	Z	N	Z	Z	Z	Z	N
Z / P	Z	N	N	Z	N	Z	Z	P	P
P / N	Z	Z	N	Z	N	N	N	Z	N
P / Z	P	P	P	P	P	P	P	P	P
P / P	Z	P	P	Z	P	P	P	Z	P

Tab. B.2: Parametry identifikovaných fuzzy modelů 2


## C Porovnání Fuzzy a LTI modelů




Obr. C.1: Porovnání modelů pro řídiče B




Obr. C.2: Porovnání modelů řídiče C



Obr. C.3: Porovnání modelů pro řidiče D




Obr. C.4: Porovnání modelů řídiče E




Obr. C.5: Porovnání modelů pro řídiče F






Obr. C.6: Porovnání modelů řídiče G



Obr. C.7: Porovnání modelů pro řídiče H



Obr. C.8: Porovnání modelů řídiče I

## D Obsah elektronické přílohy

V přiložené elektronické příloze lze najít elektronickou verzi této diplomové práce a složku Matlab, která obsahuje všechna data a části kódu z prostředí Matlab. Soubor IdentFuzzy.m slouží pro identifikaci fuzzy modelů, soubor IdentLTI.m pro identifikaci lineárních modelů a soubory začínající GA jsou funkce, které se volají při identifikaci fuzzy modelů. Základní fuzzy PD regulátor a zpracovaná data jsou uložena ve složce Data.

```
/.....kořenový adresář přiloženého archivu
├── Matlab ..... soubory kódu v matlabu
│   ├── Data ..... fuzzy PD regulátor a zpracovaná data
│   │   ├── PD.fis
│   │   ├── RData.mat
│   │   ├── RBDData.mat
│   │   ├── RCDData.mat
│   │   ├── RDDData.mat
│   │   ├── REDData.mat
│   │   ├── RFDData.mat
│   │   ├── RGDData.mat
│   │   ├── RHDData.mat
│   │   └── RIDData.mat
│   ├── GA.m
│   ├── GAKrizeni.m
│   ├── GAMutace.m
│   ├── GASelekce.m
│   ├── IdentFuzzy.m ..... soubor s identifikací fuzzy modelů
│   └── IdentLTI.m ..... soubor s identifikací lineárních modelů
└── DP_Fiser.pdf
```