



# 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

## VYUŽITÍ FUZZY LOGIKY PŘI MODELOVÁNÍ A HODNOCENÍ CHOVÁNÍ ŘIDIČE

MODELLING AND ASSESSMENT OF DRIVER BEHAVIOUR USING FUZZY LOGIC

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Martin Radvanský

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Miroslav Jirgl, Ph.D.

BRNO 2022

# Diplomová práce

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

Ústav automatizace a měřicí techniky

**Student:** Bc. Martin Radvanský

**ID:** 203331

**Ročník:** 2

**Akademický rok:** 2021/22

**NÁZEV TÉMATU:**

## Využití fuzzy logiky při modelování a hodnocení chování řidiče

### POKyny PRO VYPRACOVÁNÍ:

Cílem diplomové práce je studium problematiky modelování a hodnocení chování řidiče na základě měření na simulátoru řízení vozidla a následný návrh a realizace demonstrační úlohy pro využití fuzzy logiky (fuzzy systémů) pro tyto účely.

1. Proveďte stručnou rešerši používaných matematických modelů a nástrojů pro popis chování řidiče.
2. Seznamte se se strukturou a významem naměřených dat ze simulátoru řízení vozidla reprezentujících odezvy řidiče na definované vizuální podněty a proveďte základní analýzu dodané sady dat.
3. Prostudujte a následně vydefinujte oblasti aplikace fuzzy logiky při modelování a hodnocení chování řidiče.
4. Navrhněte demonstrační úlohu využívající fuzzy logiku pro modelování či hodnocení chování a schopností řidiče.
5. Implementujte tuto úlohu a otestujte na dodané sadě dat.
6. Vyhodnoťte dosažené výsledky.

### DOPORUČENÁ LITERATURA:

FENG, Yuxiang, Pejman IRAVANI, Chris BRACE a Chi-Hua CHEN. A Fuzzy Logic-Based Approach for Humanized Driver Modelling. Journal of Advanced Transportation [online]. 2021, 2021, 1-13 [cit. 2021-9-7]. ISSN 2042-3195. Dostupné z: doi:10.1155/2021/4413505

**Termín zadání:** 7.2.2022

**Termín odevzdání:** 18.5.2022

**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**

Práce obsahuje zpracovanou rešerši matematického modelování se zaměřením na chování řidiče při řízení vozidla. V dalším textu je obsaženo základní statistické zpracování dat získaných ze simulátoru řízení vozidla pro celkem 38 řidičů. Následně jsou navrženy možné přístupy k využití fuzzy systémů pro modelování chování řidiče. Hlavní část práce je zaměřena na ověření tří hypotéz souvisejících s použitím fuzzy inferenčních systémů k modelování chování řidiče.

## **KLÍČOVÁ SLOVA**

fuzzy systém, matematický model řidiče, chování řidiče, Takagi-Sugeno, Mamdani, optimalizace hejnem částic

## **ABSTRACT**

The work contains a research of mathematical modeling with a focus on the driver's behavior while driving. The following text contains the basic statistical processing of data obtained from the driving simulator for a total of 38 drivers. Subsequently, possible approaches to the use of fuzzy systems for modeling driver behavior are proposed. The main part of the work is focused on the verification of three hypotheses related to the use of fuzzy inference systems to model driver behavior.

## **KEYWORDS**

fuzzy system, mathematical driver model, driver behaviour, Takagi-Sugeno, Mamdani, particle swarm optimization

RADVANSKÝ, Martin. *Využití fuzzy logiky při modelování a hodnocení chování řidiče*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2022, 125 s. Diplomová práce. Vedoucí práce: Ing. Miroslav Jirgl, Ph.D.

## Prohlášení autora o původnosti díla

<b>Jméno a příjmení autora:</b>	Bc. Martin Radvanský
<b>VUT ID autora:</b>	203331
<b>Typ práce:</b>	Diplomová práce
<b>Akademický rok:</b>	2021/22
<b>Téma závěrečné práce:</b>	Využití fuzzy logiky při modelování a hodnocení 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 9. května 2022

.....

podpis autora\*

---

\*Autor podepisuje pouze v tištěné verzi.

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Miroslavu Jirglovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Dále bych rád poděkoval rodičům za podporu při studiu a pomoc při dokončení práce.

Brno 9. května 2022

.....

podpis autora

# Obsah

Úvod	14
<b>1 Matematické modely a nástroje pro popis chování lidské obsluhy</b>	<b>16</b>
1.1 Adaptivní model řízení člověkem	16
1.1.1 Lidský faktor v kontextu HiLCPS	16
1.1.2 Modelování a předvídání lidského chování	17
1.1.3 Víceúrovňový adaptivní model řízení	19
1.2 Systémy typu člověk-stroj	21
1.2.1 Chování založené na dovednostech	21
1.2.2 Chování založené na pravidlech	22
1.2.3 Chování založené na znalostech	22
1.2.4 Inovativní přístup k modelování lidského chování	23
1.3 Stochastická forma dynamického modelu řidiče	24
<b>2 Fuzzy logika</b>	<b>27</b>
2.1 Fuzzy množiny	27
2.1.1 Funkce příslušnosti	27
2.1.2 Tvary funkcí příslušností	28
2.1.3 Operace s fuzzy množinami	31
<b>3 Fuzzy systémy</b>	<b>34</b>
3.1 Použití fuzzy systémů v praxi	34
3.2 Výhody a nevýhody fuzzy systémů	35
<b>4 Typy fuzzy systémů</b>	<b>37</b>
4.1 Fuzzy systém Typ-1	37
4.2 Fuzzy systém Typ-2	39
<b>5 Modely fuzzy systémů</b>	<b>42</b>
5.0.1 Fuzzy systém typu Mamdani	43
5.0.2 Fuzzy systém typu Sugeno	43
<b>6 Simulátor řízení vozidla</b>	<b>46</b>
6.1 Vstupní zařízení	46
6.2 Scénáře	46
6.2.1 Dálnice – přejíždění mezi pruhy	47
6.2.2 Dálnice – dálková jízda	48
6.2.3 Scénář města	48

6.2.4	Scénář losího testu . . . . .	48
<b>7</b>	<b>Zdrojová data průběhu simulace</b>	<b>49</b>
7.1	Datový soubor . . . . .	49
7.2	Základní statistiky naměřených hodnot . . . . .	49
7.3	Vizualizace naměřených dat . . . . .	52
7.4	Chyby v datové sadě . . . . .	53
7.5	Průběh změny jízdního pruhu v simulaci . . . . .	54
7.6	Doba změny polohy a doba ustálení . . . . .	57
7.6.1	Reakční doba a její komponenty . . . . .	58
7.6.2	Počáteční doba změny polohy . . . . .	61
<b>8</b>	<b>Možnosti využití fuzzy logiky pro modelování chování řidiče</b>	<b>65</b>
8.1	Modelování a hodnocení řidiče pomocí fuzzy logiky v literatuře . . . . .	65
8.2	Nahrazení řidiče fuzzy regulátorem . . . . .	68
8.3	Hodnocení chování řidiče vůči optimální trajektorii . . . . .	69
8.4	Klasifikace řidičů s využitím fuzzy systémů . . . . .	70
<b>9</b>	<b>Experimentální část</b>	<b>71</b>
9.1	Modelování chování řidiče . . . . .	71
9.1.1	Použití fuzzy systému Mamdani . . . . .	72
9.1.2	Použití fuzzy systému Sugeno . . . . .	78
9.1.3	Použitelnost FIS při aproximaci charakteristiky . . . . .	87
9.2	Podobnost FIS modelu řidiče s časovým odstupem . . . . .	89
9.2.1	Zhodnocení podobnosti FIS s časovým odstupem . . . . .	94
9.3	Shlukování řidičů na základě jejich fuzzy modelu . . . . .	95
9.3.1	Vytvoření fuzzy modelů pro 38 řidičů . . . . .	96
9.3.2	Shlukování s využitím parametrů modelů FIS . . . . .	101
9.3.3	Shlukování naměřených dat řidičů . . . . .	103
9.3.4	Zhodnocení shlukování řidičů na základě parametrů FIS . . . . .	104
	<b>Závěr</b>	<b>107</b>
	<b>Literatura</b>	<b>108</b>
	<b>Seznam příloh</b>	<b>114</b>
	<b>A Příloha kapitoly 9.1.1</b>	<b>115</b>
	<b>B Příloha kapitoly 9.1.2</b>	<b>117</b>
	<b>C Příloha kapitoly 9.2</b>	<b>118</b>



<b>D Příloha kapitoly 9.3</b>	<b>120</b>
<b>E Struktura přiloženého CD/zip souboru</b>	<b>125</b>

# Seznam obrázků

1.1	Faktory, které určují a ovlivňují lidské chování . . . . .	17
1.2	Jednoduchý model lidského chování definovaný HRA . . . . .	18
1.3	Komplexní model lidského chování definovaný HRA . . . . .	18
1.4	Víceúrovňový adaptivní model řízení . . . . .	19
1.5	Model lidského chování podle Wentinka . . . . .	22
1.6	Jednosmyčkový kompenzační model . . . . .	23
1.7	Vícesmyčkový model . . . . .	23
1.8	Prekognitivní model s otevřenou smyčkou . . . . .	24
1.9	McRuerův kompenzační/anticipační/prekognitivní model řidiče . . . . .	25
1.10	Hessův a Modjtahedzadehův model řidiče . . . . .	25
1.11	MacAdamův optimální model řidiče . . . . .	26
1.12	Ukawův model řidiče . . . . .	26
2.1	Příklad funkce příslušnosti . . . . .	28
2.2	Příklady různých tříd funkcí příslušnosti . . . . .	30
2.3	Fyzikální význam parametrů zobecněné zvonové funkce . . . . .	30
2.4	Operace s fuzzy množinami . . . . .	33
4.1	Obecná struktura fuzzy logického řízení typu 1 . . . . .	37
4.2	Obecná struktura fuzzy logického řízení typu 2 . . . . .	40
5.1	Základní struktura fuzzy systémů . . . . .	42
5.2	Mamdaniho fuzzy uvažování založené na metodě max–min inference . . . . .	44
5.3	Fuzzy inferenční systém Takagiho a Sugena . . . . .	45
6.1	Simulátor: pohled od řidiče . . . . .	47
6.2	Simulátor: boční pohled . . . . .	47
7.1	Boxplot pro čas vzorkování přes celý dataset bez odlehlých hodnot . . . . .	50
7.2	Boxplot doby simulace . . . . .	51
7.3	Vizualizace dat ze simulátoru . . . . .	52
7.4	Zajímavé oblasti v datech . . . . .	53
7.5	Ukázka nestandardního průběhu simulace řidiče . . . . .	54
7.6	Průměrné průběhy změny jízdního pruhu . . . . .	55
7.7	Intervaly spolehlivosti pro průměrné hodnoty změny směru . . . . .	56
7.8	Porovnání intervalů spolehlivosti mezi zatáčkami . . . . .	56
7.9	Všechny průměrné změny jízdního pruhu doleva . . . . .	57
7.10	Všechny průměrné změny pruhu doprava . . . . .	57
7.11	Intervaly spolehlivosti pro zatočení vlevo a vpravo . . . . .	58
7.12	Faktory ovlivňující reakční dobu . . . . .	61
7.13	Doba změny polohy a doba ustálení . . . . .	63
7.14	Doba změny polohy v závislosti na směru změny pruhu . . . . .	63

7.15	Doba ustálení a změna jízdního pruhu . . . . .	64
8.1	Zjednodušený model nahrazení řidiče fuzzy regulátorem . . . . .	69
8.2	Nalezení rozdílu mezi optimálním a reálným průběhem regulace . . .	70
9.1	Převodní charakteristika úhlu natočení volantu a vzdálenosti od spline	72
9.2	Závislost otočení volantu na čase Mamdani ručně . . . . .	74
9.3	Funkce příslušnosti na vstupu FIS Mamdani ručně . . . . .	74
9.4	Funkce příslušnosti na výstupu FIS Mamdani ručně . . . . .	75
9.5	Průběh RMSE při optimalizaci pravidel FIS Mamdani . . . . .	76
9.6	Průběh RMSE při optimalizaci funkcí příslušností FIS Mamdani . . .	76
9.7	Rozložení hodnot RMSE pro sto opakování optimalizace pravidel . . .	77
9.8	Rozložení hodnot RMSE pro optimalizace funkcí příslušnosti . . . . .	78
9.9	Převodní charakteristika po optimalizaci pravidel . . . . .	79
9.10	Převodní charakteristika po optimalizaci funkcí příslušnosti . . . . .	79
9.11	Natočení volantu v čase po optimalizaci pravidel . . . . .	80
9.12	Natočení volantu v čase po optimalizaci funkcí příslušnosti . . . . .	80
9.13	Nastavení vstupních funkcí příslušnosti po jejich optimalizaci . . . . .	81
9.14	Nastavení výstupních funkcí příslušnosti po jejich optimalizaci . . . . .	81
9.15	Převodní charakteristika úhlu natočení volantu . . . . .	83
9.16	Zvolení přímek pro aproximaci FIS Sugeno . . . . .	84
9.17	Závislost otočení volantu na čase Sugeno ručně . . . . .	84
9.18	Funkce příslušnosti na vstupu FIS Sugeno ručně . . . . .	85
9.19	Průběh RMSE při optimalizaci funkcí příslušnosti FIS Sugeno . . . . .	86
9.20	Rozložení RMSE pro sto opakování optimalizace funkcí příslušnosti .	86
9.21	Výstupní lineární funkce FIS Sugeno . . . . .	87
9.22	Nastavení vstupních funkcí příslušnosti po optimalizaci . . . . .	88
9.23	Převodová charakteristika po optimalizaci funkcí příslušnosti . . . . .	88
9.24	Natočení volantu v čase po optimalizaci funkcí příslušnosti . . . . .	89
9.25	Naměřená data pro čtyři řidiče po týdnu . . . . .	90
9.26	Fuzzy modely typu Sugeno pro dvě měření s týdenním odstupem . . .	91
9.27	Porovnání RMSE jednotlivých fuzzy modelů . . . . .	92
9.28	Detailní pohled fuzzy modelů od prvního řidiče po týdnu . . . . .	93
9.29	Fuzzy model řidiče 200 a funkce příslušnosti . . . . .	94
9.30	Fuzzy model řidiče 203 a funkce příslušnosti . . . . .	95
9.31	Natočení volantu pro všechny řidiče . . . . .	97
9.32	Průměrné otočení volantem - všichni řidiči . . . . .	98
9.33	Nastavení předpisů přímek na výstupu FIS . . . . .	99
9.34	Nastavení parametrů funkcí příslušnosti . . . . .	101
9.35	Silhouette – shluky FIS . . . . .	102
9.36	Silhouette - shluky naměřená data . . . . .	103

9.37	Profily otočení volantu – shluky tři shluky z fuzzy modelů řidičů . . .	105
9.38	Profily otočení volantu – pět shluků z naměřených dat . . . . .	106
A.1	Převodová charakteristika po optimalizaci pravidel s nejvyšším RMSE	115
A.2	Natočení volantu v čase po optimalizaci pravidel s nejvyšší RMSE . .	115
A.3	Převodová charakteristika funkcí příslušnosti nejvyšší RMSE . . . . .	116
A.4	Natočení volantu v čase funkce příslušnosti nejvyšší RMSE . . . . .	116
B.1	Převodová charakteristika funkcí příslušnosti nejvyšší RMSE . . . . .	117
B.2	Natočení volantu v čase funkce příslušnosti nejvyšší RMSE . . . . .	117
C.1	Detailní pohled fuzzy modelů od druhého řidiče po týdn . . . . .	118
C.2	Detailní pohled fuzzy modelů od třetího řidiče po týdn . . . . .	118
C.3	Detailní pohled fuzzy modelů od čtvrtého řidiče po týdn . . . . .	119
D.1	Vzdálenost od spline pro všechny řidiče . . . . .	120
D.2	Průměrná vzdálenost od spline - všichni řidiči . . . . .	120
D.3	Skupina řidičů pro shluk 1 FIS . . . . .	121
D.4	Skupina řidičů pro shluk 2 FIS . . . . .	121
D.5	Skupina řidičů pro shluk 3 FIS . . . . .	122
D.6	Skupina řidičů pro shluk 1 naměřená data . . . . .	122
D.7	Skupina řidičů pro shluk 2 naměřená data . . . . .	123
D.8	Skupina řidičů pro shluk 3 naměřená data . . . . .	123
D.9	Skupina řidičů pro shluk 4 naměřená data . . . . .	124
D.10	Skupina řidičů pro shluk 5 naměřená data . . . . .	124

# Seznam tabulek

7.1	Základní charakteristiky atributů datasetu . . . . .	51
7.2	Průměrné doby odezvy na různé typy podnětů . . . . .	61
9.1	Užitá pravidla při tvorbě FIS Mamdani ruční ladění . . . . .	73
9.2	Pravidla FIS Mamdani získaná z první fáze optimalizace . . . . .	82
9.3	Užitá pravidla při tvorbě FIS Sugeno při ručním ladění . . . . .	82
9.4	Předpisy přímek použitých v konsekventu pravidel FIS Sugeno . . . . .	83
9.5	Hodnoty vah u pravidel FIS pro řidiče 200 . . . . .	93
9.6	Hodnoty vah u pravidel FIS pro řidiče 203 . . . . .	94
9.7	Počty řidičů ve shlucích parametry FIS . . . . .	103
9.8	Počty řidičů ve shlucích naměřená data . . . . .	104

# Úvod

Moderní technologie všude kolem nás se mění takovým tempem, že je velmi obtížné se těmto změnám neustále přizpůsobovat. Mnoho činností lidského života se ulehčuje, a například díky robotizaci je postupně odstraňována těžká práce nebo práce v nebezpečném prostředí. Tento technologický pokrok je v současném světě nezbytností a v rámci globální konkurenceschopnosti je i podstatnou součástí strategie od státu počínaje až po ty nejmenší firmy.

Jednou z věcí, která se zatím obtížně nahrazuje technologií je lidská obsluha. Ačkoliv lze najít snahy o vynechání lidského faktoru z výrobních procesů, stále ještě nejsme schopni dosáhnout, při současném stavu vědomostí, v globálním měřítku absolutní autonomie ve většině běžných i průmyslových procesů.

Lidský operátor je stále nezbytným prvkem při řízení nebo dohledu nad většinou procesů. Na rozdíl od počítačových řídicích systémů, které se chovají deterministicky a postupují dle zadaného programu, při interakci lidského operátora s technologií, je třeba brát na zřetel jistou míru nepředvídatelnosti či neadekvátní reakce operátora. To je způsobeno tím, že lidské chování, jakožto biologický systém je ovlivňován celou řadou faktorů. Problematika lidského operátora se stává velmi důležitou oblastí pro další technologický rozvoj a je aktivně studována. V minulosti publikované studie, zabývající se problematikou modelování lidského chování při řízení procesů, byly často pouze retrospektivního charakteru a mnohdy s malým rozsahem sledovaných subjektů se zaměřením převážně na psychologické faktory jedinců. S růstem digitálních technologií, množstvím senzorů a zapojením umělé inteligence při zpracování získaných dat jsou však nyní k dispozici prostředky, které nám umožní namodelovat lidské chování do velké hloubky.

Práce se zabývá oblastí modelování a hodnocení chování lidské obsluhy, se zaměřením na všeobecně známou oblast lidské činnosti, kterou je řízení vozidla. Pro získání informací o chování řidiče je využíváno simulátoru, který se snaží napodobit reálné prostředí a situace na silnici. Řízení vozidla lze považovat za samotnou větev v modelování, neboť tato problematika je velice náročná a existuje mnoho vlivů, které vstupují do chování lidského řidiče. Je třeba brát v potaz, že i samotné vozidlo se chová za různých podmínek jinak, obdobně nálada, chuť řídit, zda řidič pospíchá na určité místo a další faktory hrají významnou roli, která může výsledné chování řidiče ovlivnit. Vzhledem k tomu, že lidské myšlení a chování nelze považovat za binární, lze pro vytvoření modelu chování řidiče využít metod založených na fuzzy množinách a fuzzy systémech, které jsou pro člověka lépe srozumitelné.

První část diplomové práce je věnována matematickým modelům, které popisují chování lidské obsluhy. Další část se věnuje vysvětlení základům fuzzy logiky a fuzzy systémů, které budou použity pro následné modelování chování řidiče. Následuje po-

pis simulátoru pro řízení vozidla, ze kterého jsou čerpána veškerá naměřená data. Aby se získaná data dala správně vyhodnocovat, obsahuje další část základní statistickou analýzu. Po tomto kroku následuje část, která nastiňuje možnosti, jak by šlo využít metod fuzzy logiky a fuzzy systémů pro modelování chování řidiče. Dále následuje experimentální část práce, kde se zvolily tři samostatné hypotézy, které se následně ověřují. Závěr práce pak hodnotí dosažené výsledky.

# 1 Matematické modely a nástroje pro popis chování lidské obsluhy

Kapitola se věnuje přístupům, matematickým modelům pro popis chování řidiče.

## 1.1 Adaptivní model řízení člověkem

Na základě nejnovějších trendů ve výzkumu systémů se znalosti týkající se lidského faktoru a jeho chování v rámci systému, staly velmi důležitými pro moderní pojetí kyberneticko-fyzikálních systémů. Pro systémy zahrnující lidský prvek se používá označení kyberneticko-fyzikální systémy s lidským prvkem (CPHSs – Cyber-Physical Human Systems) nebo kyberneticko-fyzikální systémy s lidským prvkem ve smyčce (HiLCPSs – Human-in-the-Loop Cyber-Physical Systems).[1], [2]

Protože role člověka v kontextu HiLCPS je zásadní, existuje snaha modelovat, předvídat a vyhodnocovat chování člověka, jeho výkonnost a rizika související s lidským faktorem.

### 1.1.1 Lidský faktor v kontextu HiLCPS

HiLCPS vlastně představují zapojení člověka do procesu prostřednictvím vzájemné komunikace, zejména HMI (Human-Machine Interface) nebo HCI (Human-Computer Interface), které umožňují zásahy člověka do procesu.[3]

Člověk je velmi efektivní a univerzální součástí celého systému, protože je schopen velmi rychle řešit konkrétní úkoly nebo nepředvídatelné situace či problémy. Člověk je také snadno přizpůsobivý různým situacím a změnám podmínek. Na druhou stranu je lidské chování ovlivněno mnoha faktory, jako je únava, stres nebo motivace, které jsou pro výkon člověka velmi důležité. Proto je pochopení lidského chování složitým problémem, kde výsledek závisí na mnoha různých faktorech. Tento proces chování lidské obsluhy je definován především individuálními schopnostmi, příslušnými omezeními a aktuálními vzorci chování, a to mentálními, emocionálními a fyzickým stavem jedince, jak je znázorněno na obrázku. 1.1.[4]

Klíčovým rozdílem mezi HiLCPS a plně autonomním systémem je tedy přítomnost lidského faktoru, jehož vliv je pro výsledné chování HiLCPS klíčový. Aby bylo možné zaručit spolehlivost modelu HiLCPS, je zapotřebí dostatek informací a odpovídající model lidského operátora.[2]





Obr. 1.1: Faktory, které určují a ovlivňují lidské chování [4]

### 1.1.2 Modelování a předvídání lidského chování


Lidský mozek je složitá biologická struktura, která je zodpovědná za lidské chování v různých situacích. Modelování lidského chování a jeho předvídání je náročná multidisciplinární problematika, v níž se neustále objevují nové poznatky.

Vědním oborem zabývajícím se lidským faktorem a jeho hodnocením, zejména v oblasti jeho spolehlivosti v rámci celého hybridního systému je Human Reliability Assessment (HRA). Princip HRA spočívá ve studiu lidského chování v rámci různých provozních činností a hodnocení spolehlivosti, rizik a dalších důležitých vlastností celého procesu. Zahrnuje více než 50 metod, například CREAM, THERP, SLIM, ATHEANA atd.[5]

Kromě toho HRA definuje také dva základní modely chování definující zpracování informací lidským mozkem (jednoduchý a komplexní model HRA). V obou případech je vstupní signál (podnět) vnímán receptory a následně je neuronovými sítěmi přenášen do mozku, kde je zpracován a následně je provedena adekvátní akce. Tuto akci provádí neuromuskulární systém. Rozdíl obou modelů spočívá v jejich komplexnosti a přístupu například ke kvantifikaci chyb.


První model 1.2 zvažuje pouze jednoduchý přístup k popisu reakce člověka na různé podněty. Tento model zahrnuje výše popsany základní princip zpracování informací, rozšířený o dopřednou reprezentaci okamžité reakce bez zásahu mozku, např. reakce na bolest. Tento model využívá první generace metod HRA, jako jsou

THERP, ASEP nebo HEART, které se zaměřují především na dovednostní a pravidlovou bázi lidské činnosti.[6]



Obr. 1.2: Jednoduchý model lidského chování definovaný HRA [7]

Druhý model 1.3 využívá především druhou generaci metod HRA. Tyto metody, jako je ATHEANA nebo CREAM, využívají komplexní shodu chybových scénářů, která usnadňuje identifikaci a kvantifikaci chyb.



Obr. 1.3: Komplexní model lidského chování definovaný HRA [7]

Ačkoli je princip podobný předchozímu, je tento koncept složitější. Studuje také zpětné interakce mezi akcemi a vjemy na základě kognitivních procesů využívajících zpětnou vazbu. Tento přístup se snaží zahrnout i roli lidského poznávání, které je definováno jako „akt nebo proces poznávání zahrnující jak uvědomování, tak posuzování“ ze strany operátora.

Společným rysem první a druhé generace HRA a příslušných modelů je snaha analyzovat a předvídat chování člověka v různých situacích za účelem prevence selhání systému. Všechny metody však vyžadují dostatek informací o celých činnostech spojených se sledovaným úkolem a procesem. Tyto informace jsou často nedostupné a hodnocení se opírá o předem definované hodnoty parametrů pro jednoduché operace, které jsou často uvedené v příslušných normách.[5]

Současné trendy spojené s využíváním simulačních technologií přinášejí nové možnosti i do této komplikované oblasti. Principiálně se využívá vhodný simulátor posuzovaného procesu, který je vybavený moduly pro sběr dat. Poskytnuté informace se pak využívají k analýze chování člověka a jeho reakcí v rámci různých scénářů. Tento přístup je často označován v literatuře jako třetí generace metod HRA.[7]

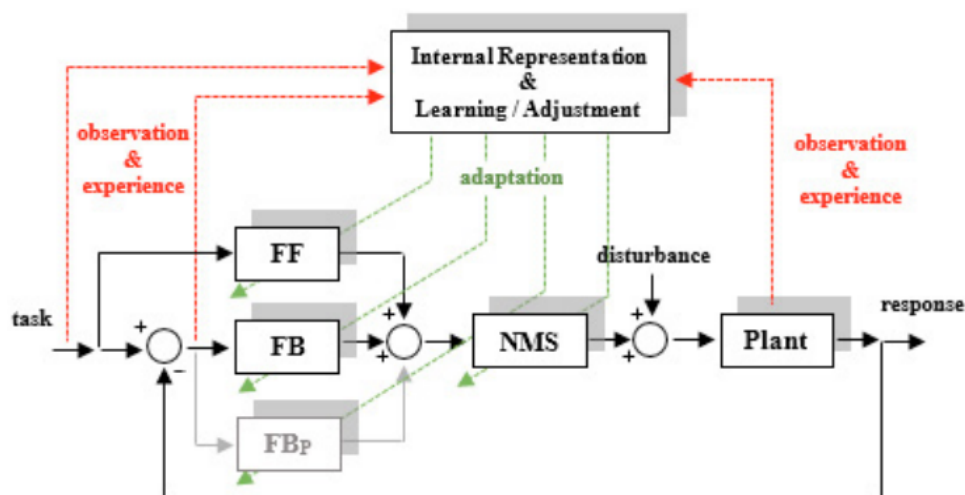
Simulátory lze kromě získávání modelovacích dat s úspěchem využít i pro průběžné trénování potřebných návyků a vytváření naučených postupů u lidského operátora. Tím je umožněno sjednotit rutinní postupy při zachování široké škály variant jednání v různých náhodných nebo standardních situacích.[8]

Třetí generace metod HRA se navíc zaměřila i na kvalitativní hodnocení chování obsluhy a hledání modelů, které přesněji popisují interakci mezi obsluhou a řízeným systémem nebo procesem. Tímto přístupem se investice vložené do tvorby simulátorů vrací v relativně krátké době a výstupy lze využít k optimalizaci vlastních procesů.

### 1.1.3 Víceúrovňový adaptivní model řízení

Charakter prezentovaných modelů HRA odpovídá Rasmussenovu obecnému modelu lidského chování. Skládá se z několika úrovní pro různé typy řízení. Tyto úrovně jsou následující[9]:

- Úroveň regulace (kompenzační zpětnovazební regulace).
- Úroveň koordinace (řízení na základě pravidel).
- Organizační nebo kognitivní úroveň (řízení na základě znalostí).



Obr. 1.4: Víceúrovňový adaptivní model řízení [10]

Rasmussenův model je obecně platný pro všechny běžné činnosti člověka. Ačkoli nepřináší konkrétnější popis činnosti člověka nebo jeho schopností, byl základem pro nové modely, které jsou průběžně navrhovány a ověřovány. Jedním z těchto modelů který z něj přímo vychází je také víceúrovňový adaptivní model řízení, viz obrázek 1.4 [10]. Principiálně se skládá z několika samostatných částí (regulátorů) a smyček popisující přístup člověka k řízení procesu.

Základní částí celého řídicího systému je zpětnovazební regulátor FB související s kompenzační regulací. Hlavní úkol této smyčky spočívá v rychlé reakci na změny a kompenzaci regulační chyby  $e(t)$ . Pro tyto účely se používá vyrovnávací forma McRuerova modelu [11] s prediktivní časovou konstantou  $T_L$ , setrvačnou časovou konstantou  $T_I$ , zesílením  $K_{FB}$  a reakčním zpožděním  $\tau$ , viz rovnice 1.1.

$$FB(s) = K_{FB} \cdot \frac{T_L s + 1}{T_I s + 1} \cdot e^{-\tau s} \quad (1.1)$$

Časová konstanta  $T_I$  souvisí s implementací naučených stereotypů a rutin. Konstanta  $T_L$  odpovídá zkušenostem lidské obsluhy a odráží její schopnost předvídat blízký budoucí řídicí vstup, tj. předvídat situaci, která může nastat. Vztah mezi  $T_L$  a  $T_I$  (vyrovnávací část) spolu se ziskem  $K_{FB}$  odráží adaptaci člověka na řízený prvek. Reakční zpoždění  $\tau$  udává zpoždění mezi vnímáním očima a reakcí mozku. Tyto parametry odpovídají podnětům vnímání, zpracování informací a výběru vhodné řídicí akce, obdobně jak je definuje jednoduchý model HRA (obr. 1.2).

Druhou částí je dopředný regulátor FF. Tento regulátor zajišťuje náhledový režim řízení, který je zaměřen na minimalizaci regulační chyby  $e(t)$  od žádané hodnoty [11]. V případě jednoduchých úloh se tento typ regulace používá i pro korekci náhlých změn nebo nepředvídatelné situace místo regulátoru FB.[12]

Neposlední částí lidského řídicího systému je kognitivní část, která je zodpovědná za poznávací procesy, konkrétně za učení, vnitřní reprezentaci dat a optimalizaci nebo úpravu řízení. Modelování tohoto regulátoru je vzhledem k odlišným strategiím každého člověka velmi obtížné a většinou se modeluje pomocí neuronových sítí a pravděpodobnostních přístupů.[13]

Na základě výše uvedených faktů lze proces řízení rozdělit do dvou nebo tří fází. V první fázi je aktivní především regulátor FB, protože je vyžadována rychlá kompenzace změny žádané hodnoty. Ve druhé fázi je snaha minimalizovat chybu řízení  $e(t)$  a aktivován je především regulátor typu „pursuit“ nebo FF. Při složité dynamice řízeného prvku však můžeme s výhodou modelovat „pursuit“ regulátor jako doplněk k regulátoru FB, např. k  $FB_p$ . Třetí fáze spočívá v plánování a optimalizaci strategie a v případě jednodušších úloh se často modeluje společně s druhou fází.

Výsledná řídicí akce se provádí prostřednictvím neuromuskulárního systému (NMS) a aktuátoru. Popisná funkce pro NMS vychází z McRuerova modelu a je obecně definována jako LTI systém druhého řádu s frekvencí  $\omega$  a tlumením  $\xi$ , viz rovnice 1.2.[11][10]

$$NMS(s) = \frac{K_{NM}}{(s^2 + 2 \cdot \xi_{NM} \cdot \omega_{NM} \cdot s + \omega_{NM}^2)} \quad (1.2)$$

Jednotlivé regulátory tak spolu s neuromuskulárním systémem představují obecný adaptivní model řízení člověkem.

Většina popsaných regulátorů je obvykle implementována v lineárním tvaru. Lidské chování je však obecně nelineární, a to především z důvodu různých typů omezení, která je třeba identifikovat, matematicky popsat a zahrnout do výsledného modelu chování. Ostatní, které nelze snadno matematicky popsat, se běžně sloučí do tzv. zbytkové funkce a modelují se např. pomocí aditivního šumu. Mezi nejvýznamnější nelinearity patří prahový prvek související s vlastnostmi lidského vnímání nebo nasycení vnějšími podněty. Ty z velké části spolu s reakčním zpožděním a hodnotou parametrů vyrovnávacího prvku představují skupinu základních fyzikálních omezení pro člověka.[6]

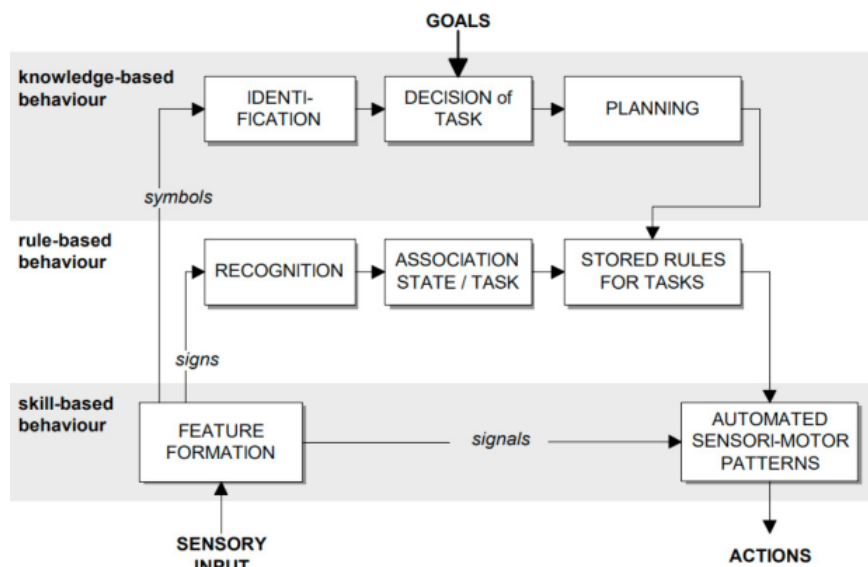
## 1.2 Systémy typu člověk-stroj

Systémy typu člověk–stroj (MMS–Man–Machine systems) jsou tvořeny, když člověk (v roli řídicího prvku) používá složitý nástroj – stroj. V našem případě je typickým příkladem takového systému člověk řídicí automobil. Cílem takového systému je efektivní a úspěšné řízení, z čehož plyne nutnost správně navrženého regulátoru. V tomto případě je regulátor tvořen lidským řidičem a jeho kvalita je dána jeho praktickou schopností řízení vozidla. Nicméně i při rutinním používání vozidla se často setkáváme s neočekávanými situacemi s měnícími se podmínkami. To vyžaduje neustálou adaptaci regulátoru (člověka) jeho učením a přizpůsobováním. Z tohoto hlediska můžeme předpokládat, že člověk je velmi efektivní a univerzální regulátor. Regulační zásahy do systémů člověk-stroj se mění na základě našich zkušeností. Lze říci, že člověk představuje formu učícího se, adaptivního regulátoru a jeho atributy odpovídají atributům běžného průmyslového regulátoru. Chování takových „lidských regulátorů“ lze matematicky popsat a vyhodnotit. Je třeba ovšem zohlednit důležitou součást lidského chování – a tou je lidské vědomí.[14]

MMS jsou založeny na vzájemné spolupráci člověka a stroje. V těchto systémech člověk vykonává různé provozní a řídicí činnosti. Znalost těchto činností je spolu s modelem chování stroje nezbytná pro vytvoření matematického modelu celého systému. Pokud by byl takový model správně navržen, mohl by být použit ke sledování systému jako celku a k vyvozování závěrů ze simulací. Činnosti operátora jsou závislé na složitosti takového systému a lze je rozdělit do tří kategorií/úrovní, jak je znázorněno na obrázku 1.5.[15]

### 1.2.1 Chování založené na dovednostech

Nejnižší úroveň kontroly MMS je bez vědomé kontroly. Je založena na rychlých a automatizovaných motorických funkcích, které ovládají příslušné svaly. Typickým



Obr. 1.5: Model lidského chování podle Wentinka [16]

příkladem úkolu založeného na dovednostech je chůze. Z pohledu řidiče jsou takovými úkoly: rozjezd vozidla, udržování vozidla v jízdním pruhu nebo udržování rychlosti vozidla podle rychlostního limitu. V tomto případě je lidský pohybový aparát považován za řídicí jednotku. Sensorickým vstupem je spojitý nebo diskrétní signál, například vizuálně vnímaná informace o okolí řidiče. [16]

## 1.2.2 Chování založené na pravidlech

Na této úrovni jsou obtížnější úkoly rozpoznávány a spojovány s konkrétním provedením na základě pravidel nebo naučených postupů. Takové provedení může být odvozeno ze zkušeností osoby nebo naučeno z pokynů jiné osoby. Příkladem takového úkolu je předjíždění, odbočování nebo jízda podle dopravních značek. [17]


## 1.2.3 Chování založené na znalostech

Tvoří nejvyšší úroveň lidského řízení a kontroly. Obsluha vnímá a analyzuje globální cíl úkolu. Podle celkových cílů se vytváří optimální plán na základě znalostí a zkušeností člověka. Řidič například analyzuje dopravní situaci nebo chování řidičů ostatních řidičů, a podle toho reaguje, např. zpomaluje nebo předjíždí. [17]

## 1.2.4 Inovativní přístup k modelování lidského chování

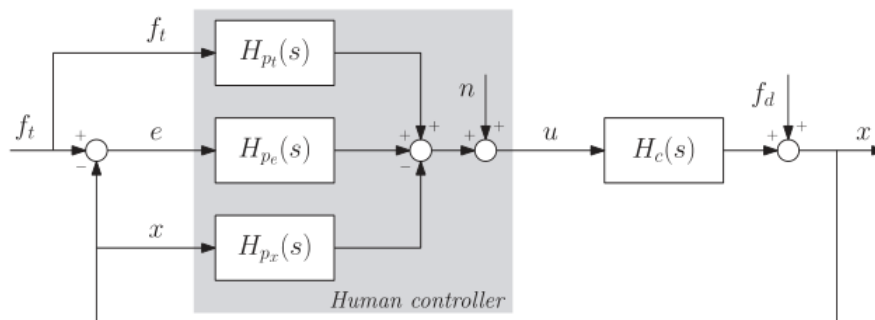
Většina současných modelů lidského chování vychází z technologií a metod vytvořených v 60. letech 20. století, které omezují chápání lidského poznávání a ovládání. Moderní kybernetická teorie popisuje lidské řídicí systémy jako systémy LTI zpětnou vazbou. Faktor časové invariance omezuje nejdůležitější aspekt lidského řízení - schopnost učit se a přizpůsobovat se měnícím se situacím. [18]

V 60. letech 20. století byla Krendelem a McRuerem stanovena hierarchie sukcesivní organizace vnímání (SOP) pro lidské řízení. Hierarchie je rozdělena do tří fází – kompenzační, sledovací a prekognitivní. V kompenzační fázi (znázorněné na obrázku 1.6) působí lidský regulátor pouze na zpětnou vazbu informací o chybě mezi výstupem systému a žádoucím vstupem. Většina současných metod se spoléhá na tuto jednosmyčkovou kompenzační fázi, a to především z důvodu její jednoduchosti a snazšího dohledávání adaptace lidského regulátoru. [10]



Obr. 1.6: Jednosmyčkový kompenzační model [10]


Pokročilejší vícesmyčkový model nabízí kombinaci dopředné odezvy ( $H_{pt}$ ), kompenzační zpětnovazební odezvy ( $H_{pe}$ ) a výstupní zpětnovazební odezvy systému ( $H_{px}$ ), jak je znázorněno na obrázku 1.7. Dopředným modelům nebyla věnována taková pozornost kvůli složitosti jejich modelování.[10]



Obr. 1.7: Vícesmyčkový model [10]

Prekognitivní model znázorněný na obrázku 1.8 je závislý na znalostech lidského operátora. V této fázi mohou mít lidské řídicí jednotky vyvinuty čistě řídicí odezvy

v otevřené smyčce na základě reprezentace dynamiky řízeného systému a dalších atributů. Regulátor se nespolehá na žádnou zpětnou vazbu. [19]



Obr. 1.8: Prekognitivní model s otevřenou smyčkou [10]


### 1.3 Stochastická forma dynamického modelu řidiče

Mezi pokročilejší formy modelu řidiče patří stochastické formy dynamického modelu řidiče ve smyčce pro řízení vozidla a simulaci řidiče. Výhodou takového modelu je, že rozdíly ve zkušenostech řidičů a jejich podmínkách lze modelovat statisticky. Kromě toho lze jako stochastický vstup do dynamického modelu vozidla modelovat odchylky, které se vyskytují v důsledku vnějších faktorů a prostředí, jako je například led nebo sněhová pokrývka na vozovce.

Jeden z prvních modelů řidiče vznikl na základě práce pro letecký průmysl jako reprezentace chování pilotů, kterou představil McRuer. Na obrázku 1.9 je znázorněn model řidiče, který obsahuje smyčky zpětné vazby pro polohu v ose  $Y$ ,  $Y_V$  a směrový úhel  $\psi$  z modelu vozidla  $G_V$ . Tyto smyčky působí prostřednictvím kompenzačního členu  $G_{DC}$  pro řízení polohy v jízdním pruhu; zpětnovazebního členu  $G_{DA}$  pro předvídání změn v dráze; a posledního členu  $G_{DP}$ , který představuje prekognitivní řízení. [20]


Další model řidiče, který navrhli Hess a Modjtahedzadeh [21], je na obrázku 1.10. Tento model rovněž vznikl na základě práce pro letecký průmysl jako reprezentace chování pilotů. Na obr. 1.10 představuje prvek  $G_{NM}$  neuromuskulární systém druhého řádu ramen řidiče. Prvek  $G_{P1}$  má jako vstup, výstup neuromuskulárního systému  $\delta(t)$ , což je vstup řidiče do řízení vozidla. Prvek  $G_{P2}$  dostává svůj vstup z výstupu  $G_{P1}$ . Oba tyto prvky představují zpětnou vazbu proměnných, odvozených z pohybu lidských končetin a svalové tkáně, a označují se jako „proprioceptivní“ prvky zpětné vazby. Prvek  $G_L$  je prvek s časovým zpožděním, který představuje





Obr. 1.9: McRuerův kompenzační/anticipační/prekognitivní model řidiče [20]


zpoždění zpracování signálu lidským tělem. Prvky  $G_{NM}$ ,  $G_{P1}$ ,  $G_{P2}$  a  $G_L$  představují vysokofrekvenční kompenzaci modelu vozidla. Prvek  $G_C$  je regulátor PD, který představuje nízkofrekvenční kompenzaci modelu vozidla. Regulátor  $G_C$  je realizován lidským řidičem a jeho výstupní signál  $u_1(t)$  představuje vizuální vodicí pokyn. Pojem  $G_I$  je takzvaný „náhledový“ prvek, zahrnující filtr prvního řádu a faktor časového předstihu, který představuje předstih vstupu, odpovídající jediné konstantní „vzdálenosti pohledu vpřed“ nebo „cílovému bodu“ v závislosti na konkrétní rychlosti jízdy vpřed. vzdálenost náhledu se považuje za přibližně 21 m při rychlosti 32–48 km za hodinu, což odpovídá přibližně 1,5 s v čase. [22][23]



Obr. 1.10: Hessův a Modjtahedzadehův model řidiče [20]


Na obrázku 1.11 je vyobrazen optimální model řidiče. Složka  $G_V$  představuje samotný model vozidla,  $G_{prev}$  modeluje reakce řidiče na předchozí průběh cesty. Prvek  $G_{DLY}$  představuje dílčí model efektu zpoždění řidiče. Pracuje se zpožděním řidiče, dobou náhledu a pro vytvoření velikosti akčních zásahů se používají techniky optimálního řízení. [24]

Obrázek 1.12 ukazuje Ukawův model řidiče. Prvek  $G_c(s)$  představuje přenosovou funkci PD regulátoru. Prvek  $G_{act}(s)$  představuje automatický pohon řízení, který je považován za „přístroj, který otáčí předním kolem čepu pomocí hydraulického



Obr. 1.11: MacAdamův optimální model řidiče [20]

posilovače řízení se servomotorem namontovaným na hřídeli řízení“. Prvek  $G_{act}(s)$  se odhaduje pomocí „mrtvého času plus prvku zpoždění druhého řádu“. Prvek  $G_{\psi\delta}(s)$  představuje přenosovou funkci mezi úhlem vybočení  $\psi$  (výstup) a vstupním úhlem řízení  $\delta$ . Člen  $L$  je takzvaná „predikční vzdálenost“ (přibližně 20 m). [25]



Obr. 1.12: Ukawův model řidiče [20]

## 2 Fuzzy logika

S klasickým pojetím logiky (binární logikou) se pravděpodobně setkal v běžném životě snad každý. Typickým příkladem může být světlo, které svítí či nesvítí. Tato logika pracuje s přesně dvěma stanovenými hodnotami ve významu pravda, či nepravda (v technice se používá spíše logická nula, či logická jedna). Tato binární logika tak tvoří v podstatě základ všech moderních technologií v našem okolí.

Reálný svět nicméně není černo–bílý, nejde vždy přesně určit, zda daný předpoklad patří do jedné, či druhé skupiny. Jednoduchým a pochopitelným příkladem může být vaření, kde podle receptu se má uvařit nějaký pokrm. V receptech se často objevují instrukce jako „přidejte kus másla“, „přilejte trochu smetany“, „špetku soli“, či jen „přiměřeně“, ovšem, kolik to je přesně dané suroviny?

Slovo fuzzy pochází z anglického jazyka a dalo by se přeložit jako nejasný, mlhavý, neurčitý. Z tohoto kontextu se dá usoudit, že fuzzy logika bude pracovat s více než dvěma logickými hodnotami. Obvykle pracuje s hodnotami na spojitém intervalu  $\langle 0, 1 \rangle$ , kterých je nekonečně mnoho.

Základní myšlenku o fuzzy logice uvedl v roce 1965 Lotfím Zadeh z Kalifornské univerzity v Berkeley. Tato myšlenka vznikla především z teorie fuzzy množin, ze které následně vznikla fuzzy logika. Zadehova myšlenka spočívala v rozšíření základní dvoustavové logiky o podobu neurčitosti pro modelování reálného světa. Jedná se tedy o snahu vytvořit vícehodnotovou logiku se spojitým přechodem mezi hodnotami 0–1. Matematická reprezentace neurčitosti znamená, že existuje aparát, jak uchopit, pracovat a kvantifikovat neurčitost a to i přesto, že neurčitost nemá kořeny v matematice, nýbrž právě v poznání reálného světa. [27]

### 2.1 Fuzzy množiny

Slouží pro zobecnění tzv. charakteristické funkce, nabývající více pravdivostních hodnot. Množina těchto hodnot je zpravidla z intervalu reálných čísel  $\langle 0, 1 \rangle$ . Aby nedošlo k záměně s klasickou množinou, je ve fuzzy teorii používán výraz ostrá množina (crisp set).

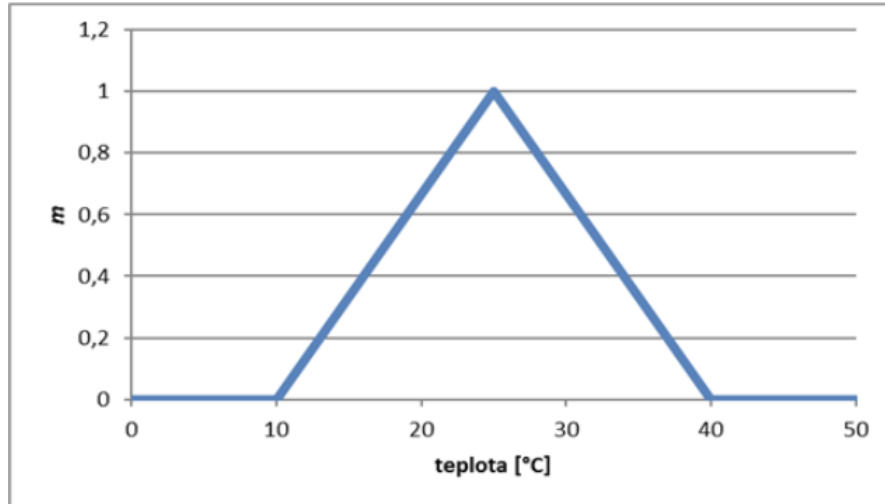
#### 2.1.1 Funkce příslušnosti

Pro libovolnou ostrou množinu je definována charakteristická funkce, která mapuje univerzum do dvouprvkové množiny. Ve fuzzy množinách je takto funkce zobecněna a nazývá se jako funkce příslušnosti (membership function) a mapuje univerzum na celý interval  $\langle 0, 1 \rangle$ , včetně krajních hodnot.

Funkce příslušnosti  $\mu_F$  fuzzy množiny F je tedy popsána funkcí:

$$\mu_F : U \rightarrow \langle 0, 1 \rangle \quad (2.1)$$

Příklad, jak může vypadat průběh funkce příslušnosti je na obrázku 2.1. Nennulových hodnot dosahuje funkce příslušnosti v hodnotách teplot 10 až 40 ° Celsia.



Obr. 2.1: Příklad funkce příslušnosti [26]

## 2.1.2 Tvary funkcí příslušností

Z definice fuzzy lze snadno vidět, že specifikace vhodné funkce příslušnosti je nezbytná při určování fuzzy množiny. Je třeba poznamenat, že specifikace vhodné funkce příslušnosti je dost subjektivní v tom smyslu, že tato funkce zadaná pro stejný koncept, například „rychlý“ nebo „vysoký“, který se může podle kontextu jeho použití lišit.

Tato subjektivita chápání funkce příslušnosti pochází z neurčité povahy abstraktních pojmů. Ve skutečnosti jde o subjektivní chápání pojmů a nenáhodné jevy fuzzy množin jsou primárním rozdílem mezi teorií fuzzy množin a teorií pravděpodobnosti, která se zabývá naopak objektivním šetřením náhodných jevů.

Několik typických běžně používaných funkcí příslušnosti je uvedeno na obrázku 2.2. Tyto parametrizované funkce příslušnosti hrají důležitou roli ve studiu fuzzy množin a fuzzy systémech.  $\lambda$  funkce příslušnosti je určena třemi parametry (a, b, c) takto [27]:

$$\lambda(x; a, b, c) = \max \left( \min \left( \frac{x - a}{b - a}, \frac{c - x}{c - b} \right), 0 \right) \quad (2.2)$$

Příklad lambda funkce příslušnosti definované  $\lambda(x; 20, 60, 80)$  je znázorněn na obrázku 2.2 (a)

$\pi$  funkce příslušnosti je určena čtyřmi parametry (a, b, c, d) jako:

$$\pi(x; a, b, c, d) = \max \left( \min \left( \frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right) \quad (2.3)$$

Příklad  $\pi$  funkce příslušnosti definované jako  $\pi(x; 10, 20, 60, 80)$  je znázorněna na obrázku 2.2 (b). Je zřejmé, že  $\lambda$  funkce příslušnosti je speciálním případem  $\pi$  funkce příslušnosti.

Tyto dvě formy funkcí příslušnosti se hojně používají při studiu fuzzy množin a fuzzy systémů díky jejich jednoduchému vyjádření a výpočetní efektivitě. Protože se však tyto funkce příslušnosti skládají z rovných úseček, nejsou v místech zlomu mezi úsečkami hladké, což může vést k potížím v některých aplikacích, například v aplikacích zahrnujících derivace funkcí příslušnosti. V takových případech jsou žádoucí hladké funkce příslušnosti a níže jsou uvedeny typické příklady takových funkcí příslušnosti. [27].

Gaussova funkce příslušnosti je určena dvěma parametry ( $\sigma, c$ ) takto,

$$\text{Gaussian}(x; \sigma, c) = e^{-\left(\frac{x-c}{\sigma}\right)^2} \quad (2.4)$$

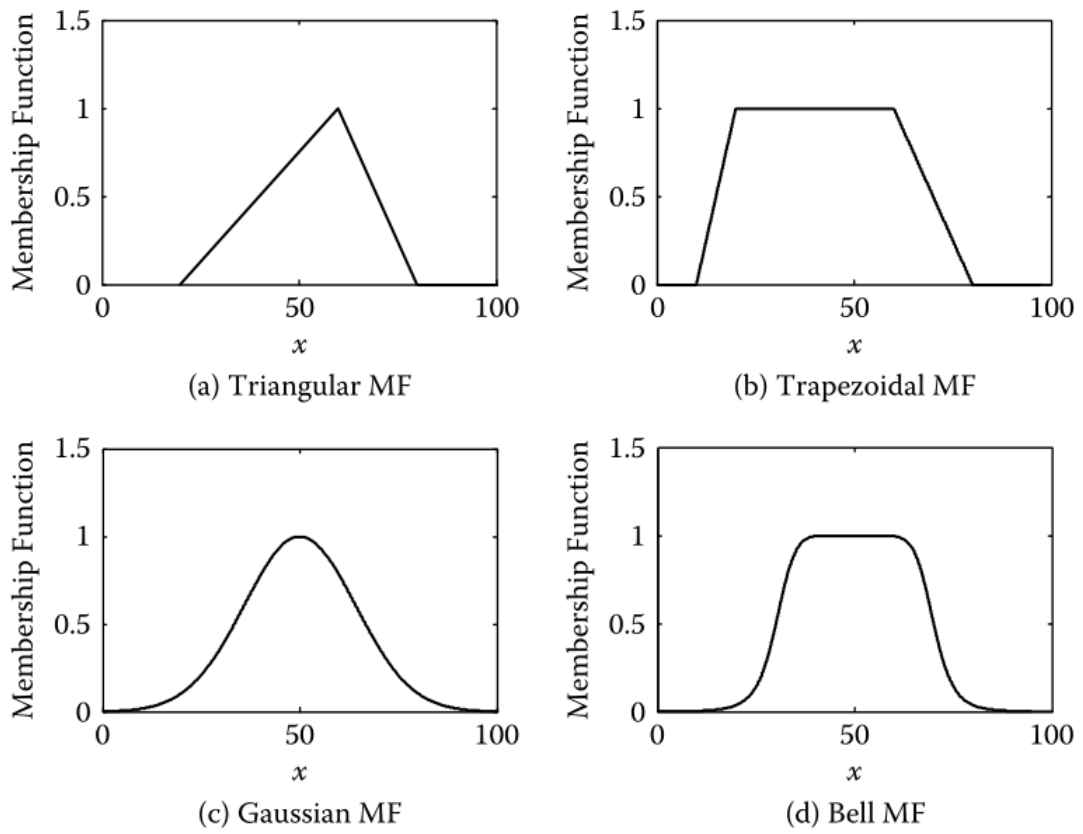
kde parametry ( $c, \sigma$ ) představují střed a šířku funkce příslušnosti. Příklad Gaussovy funkce příslušnosti definované pomocí  $\text{Gauss}(x; 20, 50)$  je následující na obrázku 2.2 (c)

Zobecněná zvonovitá funkce příslušnosti je určena třemi parametry (a, b, c) takto,

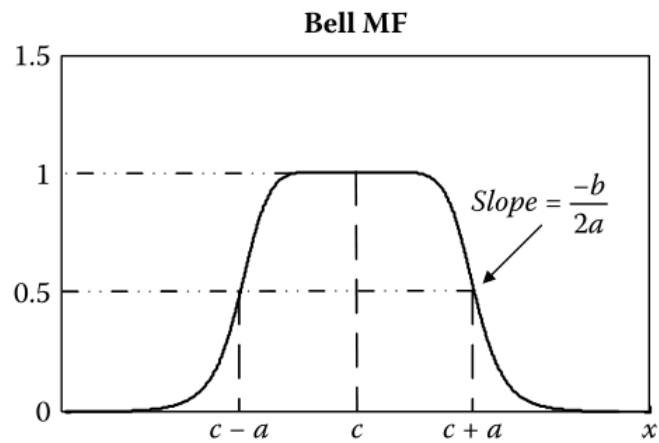
$$\text{bell}(x; a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}} \quad (2.5)$$

kde  $c$  a  $a$  představují střed, resp. šířku funkce příslušnosti a parametr  $b$  je obvykle kladný. Příklad zvonové funkce příslušnosti definované vztahem  $\text{bell}(x; 20, 4, 50)$  je znázorněn na obrázku 2.2 (d). Požadovanou zobecněnou zvonovitou funkcí příslušnosti lze získat vhodnou volbou množiny parametrů (a, b, c). Konkrétně můžeme nastavit  $c$  a  $a$  tak, aby se měnil střed a šířka funkce příslušnosti, a pak pomocí  $b$  řídit sklony na středu a šířce funkce příslušnosti v bodech křížení. Obrázek 2.3 znázorňuje fyzikální význam jednotlivých parametrů zvonovitého tvaru funkce příslušnosti.

Je třeba poznamenat, že výše popsany seznam funkcí příslušnosti není v žádném případě vyčerpávající. Pro konkrétní aplikace lze vytvořit mnoho dalších funkcí příslušnosti. [27]



Obr. 2.2: Příklady různých tříd funkcí příslušnosti [27]



Obr. 2.3: Fyzikální význam parametrů zobecněné zvonové funkce [27]

### 2.1.3 Operace s fuzzy množinami

V teorii fuzzy řízení, kde pracujeme s fuzzy podmnožinami, potřebujeme mít k dispozici způsoby jejich vzájemných kombinací. Metody kombinování fuzzy množin by měly zobecňovat známě metody pro běžné množiny. Různé operátory používané ke kombinování fuzzy množin se nazývají fuzzy spojky nebo agregační operátory.

Různé operátory pro agregaci fuzzy množin mohou být matoucí. Pokud se teorie fuzzy množin používá jako jazyk pro modelování reálných situací nebo systémů, je důležité nejen to, aby operátory splňovaly určité axiomy nebo měly určité formální vlastnosti (např. asociativitu a komutativitu). Rovněž ale i operátory musí být také vhodnými modely chování reálných systémů, a to lze obvykle prokázat pouze empirickým testováním. V praxi může být důležitým hlediskem také numerická efektivita výpočtů.[28]

Obyčejné podmnožiny, známé také jako ostré množiny, označené jako  $X$  se často kombinují nebo negují pomocí průniku (AND), sjednocení (OR) a doplňku ( $B'$ ):

$$\begin{aligned}\mathbf{AND} : A \cap B &= \{x \in X : x \in A \text{ and } x \in B\} \text{ (průnik)} \\ \mathbf{OR} : A \cup B &= \{x \in X : x \in A \text{ or } x \in B\} \text{ (sjednocení)} \\ \mathbf{B}' : X - B &= \{x \in X : x \notin B\} \text{ (doplňk)}\end{aligned} \quad (2.6)$$

Tyto operace jsou určeny jejich charakteristickými funkcemi. Charakteristické funkce pro průnik, sjednocení a doplněk jsou následující :

$$\begin{aligned}(A \cap B)(x) &= \begin{cases} 1 & \text{if } x \in A \text{ and } x \in B \\ 0 & \text{if } x \notin A \text{ or } x \notin B \end{cases} \\ (A \cup B)(x) &= \begin{cases} 1 & \text{if } x \in A \text{ and } x \in B \\ 0 & \text{if } x \notin A \text{ or } x \notin B \end{cases} \\ (X - B)(x) &= \begin{cases} 1 & \text{if } x \notin B \text{ and } x \in X \\ 0 & \text{if } x \in B \text{ or } x \notin X \end{cases}\end{aligned} \quad (2.7)$$

Podobně jako u běžných množin platí operace doplněk, sjednocení a průnik, které lze definovat i pro fuzzy množiny.[28]

#### Doplňk fuzzy množin

Doplňk fuzzy množiny  $A$  označujeme jako  $\bar{A}$ , jejíž funkce příslušnosti je definována jako:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (2.8)$$

## Sjednocení fuzzy množin

Sjednocení dvou fuzzy množin A a B je fuzzy množina C, zapsaná jako  $C = A \cup B$ , jejíž funkce příslušnosti je definována jako:

$$\mu_c(x) = \max(\mu_A(x), \mu_B(x)) \quad (2.9)$$

nebo zkráceně,

$$\mu_c(x) = \mu_A(x) \vee \mu_B(x) \quad (2.10)$$

## Průnik fuzzy množin

Průnik dvou fuzzy množin A a B je fuzzy množina C, zapsaná jako  $C = A \cap B$ , jejíž funkce příslušnosti je definována jako:

$$\mu_c(x) = \min(\mu_A(x), \mu_B(x)) \quad (2.11)$$

nebo zkráceně,

$$\mu_c(x) = \mu_A(x) \wedge \mu_B(x) \quad (2.12)$$

Intuitivnější definice sjednocení fuzzy množin A a B je nejmenší fuzzy množina, která obsahuje A i B. Podobně průnik fuzzy množin A a B je největší fuzzy množina, která je obsažena v A i B.

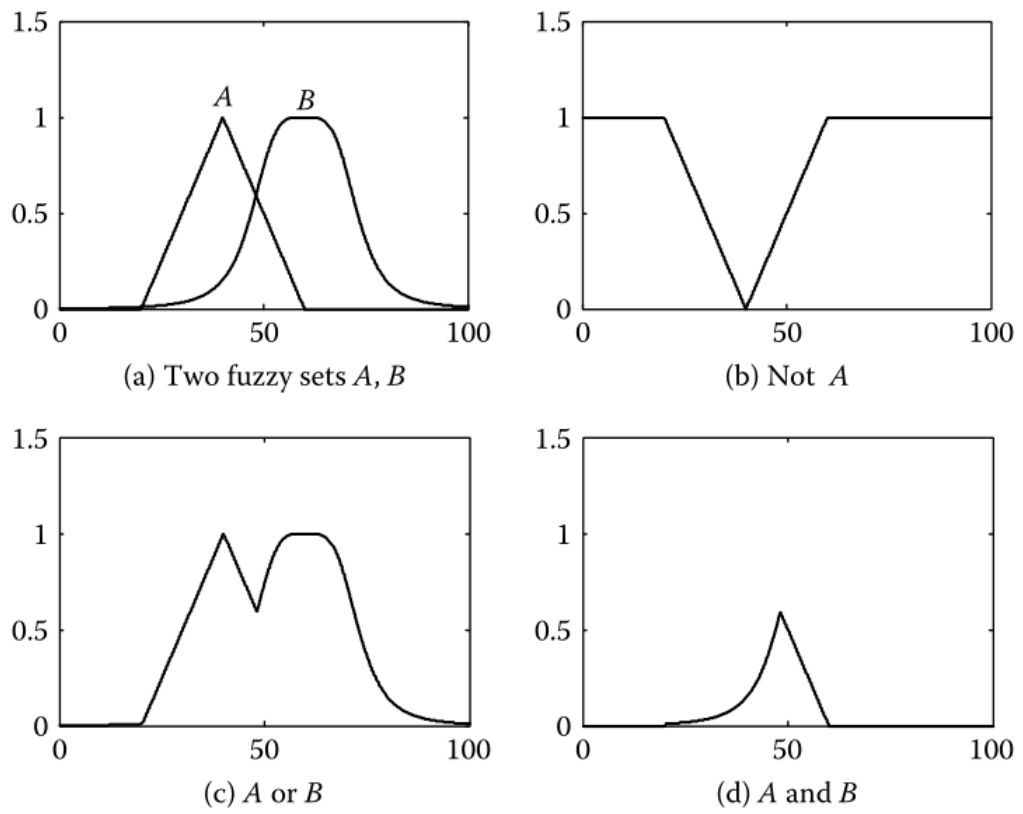
Základní operace s fuzzy množinami definované v definicích 2.8 - 2.12 jsou znázorněny na obrázku 2.4 s příkladem dvou fuzzy množin: (a) dvě fuzzy množiny A a B, (b) doplněk A, (c) sjednocení A a B a (d) průnik A a B.

Operace max a min však v některých případech přinášejí určité obtíže při analýze fuzzy inferenčních systémů. Následující vztahy jsou proto často používanými alternativami pro fuzzy operace AND a OR [27]:

$$\mu_{A \cap B}(x) = \mu_A(x) \mu_B(x) \quad (2.13)$$

$$\mu_{A \cup B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \mu_B(x) \quad (2.14)$$





Obr. 2.4: Operace s fuzzy množinami [27]

## 3 Fuzzy systémy

Britský inženýr Ebrahim Mamdani jako první použil fuzzy množiny v praktickém řídicím systému, a to téměř náhodou. Na počátku 70. let 20. století vyvíjel automatizovaný řídicí systém pro parní stroj využívající odborných znalostí lidské obsluhy. Jeho původním záměrem bylo vytvořit systém založený na bayesovské teorii rozhodování, což je metoda definování pravděpodobnosti v podmínkách nejistoty, která bere v úvahu události, které nastaly až poté, co byly upraveny předpovědi budoucích výsledků.

Obsluha podle potřeby nastavila škrtecí klapku a ohřev kotle. Aby se udržely otáčky parního stroje a tlak v kotli. Mamdani začlenil reakce obsluhy do inteligentního algoritmu (matematický algoritmus), který se naučil řídit motor. Jak však brzy zjistil, algoritmus si ve srovnání s lidským operátorem vedl špatně. Napadlo ho, že lepší metodou by mohlo být vytvoření abstraktního popisu chování stroje.

Dalším vývojem se Mamdani a jeho kolegové rozhodli použít metodu umělé inteligence, zvanou expertní systém založený na pravidlech, která kombinovala lidské odborné znalosti s umělou inteligencí s řadou logických pravidel pro využití těchto znalostí. Zatímco se snažili napsat tradiční pravidla pomocí počítačového jazyka Lisp, narazili na nový článek Lotfiho Zadeha o využití fuzzy pravidel a algoritmů pro analýzu a rozhodování ve složitých systémech. Mamdani se okamžitě rozhodl vyzkoušet fuzzy přístup a během „pouhého týdne“ poté, co si přečetl Zadehův článek vytvořil fuzzy regulátor. Jak Mamdani napsal, „bylo to překvapivé, jak snadné bylo navrhnout regulátor na principu pravidlech založených na kombinaci lingvistických a matematických proměnných.“ [29]

### 3.1 Použití fuzzy systémů v praxi

O 20 let později Ebrahim Mamdani napsal, že překvapení, které pocítoval v souvislosti s úspěchem fuzzy regulátoru, vycházelo z kulturních předsudků ve prospěch konvenční teorie řízení. Většina reálných regulačních systémů je založena na proporcionálně-integračně-derivačním (PID) regulátoru. Tento přístup předpokládá lineární nebo rovnoměrné chování řízeného systému. Navzdory tomuto zjednodušení jsou PID regulátory v praxi velmi oblíbené a používané, protože si zachovávají dobrou výkonnost a jsou schopny udržet regulační průběh i v případě, že se objeví velké vnější poruchy, které mohou způsobit celkovou nestabilitu systému.

Fuzzy logika je obecně zcela bez problémů přijímána a používána zejména východními národy jako je Čína, Japonsko, Korea a mnoho dalších. Na druhou stranu tradiční národy střední a západní Evropy a USA měly s přijímáním neurčitosti určitý historický problém. Jednou z uváděných „nevýhod“ fuzzy logiky bylo, že pracuje

často jen s několika jednoduchými pravidly. Což neodpovídalo očekávání lidí v tom, jak by měl „dobrý“ regulátor vypadat. Současně bylo poukazováno na malou rychlost a obtížnou vyrobiteľnost. Naštěstí v dnešní době již tyto přežitky a mýty jsou za námi a fuzzy systémy jsou přijímány jako funkční a zcela přirozený vývojový krok. Podle Mamdaniho zkušenosti, fuzzy regulátory ukazují, že jsou často robustnější a stabilnější než klasické PID regulátory.[30]

Existuje pět typů systémů, u nichž je využití neurčitosti výhodné:

- Složité systémy, které je obtížné nebo nemožné modelovat.
- Systémy řízené lidskými odborníky.
- Systémy se složitými a spojitými vstupy a výstupy.
- Systémy, které využívají lidská pozorování jako vstupy nebo jako základ pro pravidla.
- Systémy, které jsou přirozeně vágní, jako například systémy v behaviorálních a sociálních vědách.[31]

## 3.2 Výhody a nevýhody fuzzy systémů

V této části jsou shrnuty poznatky z literatury, o fuzzy systémech, týkající se jejich výhod a nevýhod.

**Výhody** fuzzy logiky pro řízení systému:

- Často stačí méně hodnot, pravidel a rozhodnutí pro dosažení požadovaného řízení.
- Lze vyhodnotit více sledovaných proměnných.
- Používají se jazykové, nikoli číselné proměnné, což se podobá způsobu lidského myšlení.
- Vztahuje výstup ke vstupu, aniž by bylo nutné rozumět všem proměnným, což umožňuje navrhnout systém, který může být přesnější a stabilnější než systém s konvenčním řídicím systémem.
- Jednoduchost fuzzy systémů umožňuje řešit dosud nevyřešené problémy.
- Rychlá tvorba prototypů je možná díky tomu, že tvůrce systému nemusí o systému vědět všechny podrobnosti.
- Jejich výroba je levnější než u běžných systémů, protože jsou jednodušší na konstrukci.
- Mají zvýšenou robustnost.
- Zjednodušují získávání a reprezentaci znalostí.
- Několik málo pravidel je schopno zahrnout i velkou cílovou složitost.[29]

**Nevýhody fuzzy systémů:**

- Je často obtížné vytvořit model z fuzzy systému.
- Ačkoli je jejich návrh jednodušší a prototypování rychlejší než u konvenčních řídicích systémů, fuzzy systémy vyžadují více simulací a jemného doladění, než začnou fungovat.
- Snad největší nevýhodou je kulturní předpojatost ve Spojených státech, která upřednostňuje matematicky přesné nebo ostré systémy a lineární modely pro řídicí systémy.[29]

## 4 Typy fuzzy systémů

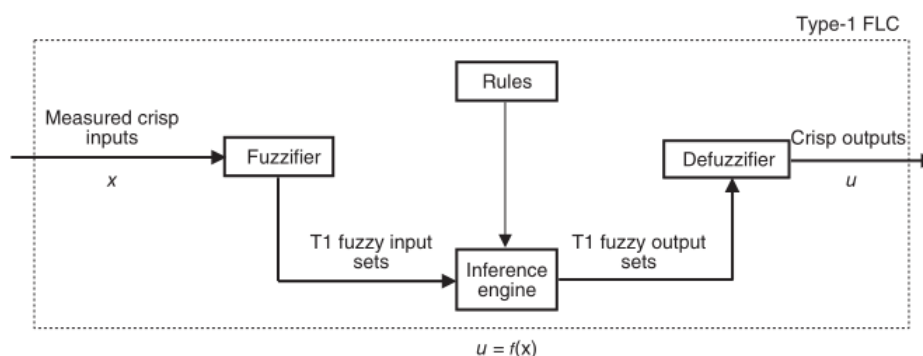
V této kapitole jsou popsány základní dva typy fuzzy systémů, včetně jejich vlastností, výhod, nevýhod a jejich vzájemné porovnání.

### 4.1 Fuzzy systém Typ-1

Fuzzy systém popsaný kompletně pomocí fuzzy množin typu 1 se nazývá fuzzy systém typu 1 a patří mezi nejstarší typy používaných fuzzy systémů.

V systémech řízených člověkem řídicí cyklus začíná tím, že člověk převede fyzikální veličinu (např. vzdálenost) z čísel na slova nebo vjemy (např. docela blízko). Vstupní slova (nebo vjemy) pak vyvolávají znalosti člověka, které se nashromáždily díky jeho zkušenostem, a výsledkem jsou slova představující akce (např. mírně sešlápnout pedál plynu). Operátor pak provede akci tak, aby uvedl do činnosti dané zařízení, které propojuje lidskou obsluhu s řízeným systémem (např. sešlápnout pedál akcelerace pouze o 10 procent může představovat akci „mírně sešlápnout plynový pedál“). Protože lidé myslí a uvažují pomocí nepřesných jazykových informací, snaží se FLC (Fuzzy Logic Controller) napodobit a převést jazykové řídicí informace na číselné řídicí informace, které lze použít v automatických řídicích systémech.

Ve snaze napodobit lidské řídicí činnosti se FLC typu 1, jehož struktura je znázorněna na obrázku 4.1, skládá ze čtyř hlavních komponent: fuzzifikátoru, pravidel, inferenčního mechanismu a defuzzifikátoru, přičemž činnost jednotlivých komponent lze popsat následovně: [32]



Obr. 4.1: Obecná struktura fuzzy logického řízení typu 1 [33]

*Modul fuzzifikace* mapuje každou měřenou číselnou vstupní proměnnou na fuzzy množinu. Jednou z motivací pro tento postup je, že měření mohou být poškozena šumem (i po provedené filtraci šumu). Například naměřenou teplotu  $26^\circ$  Celsia

lze modelovat jako trojúhelníkovou fuzzy množinu typu 1, která je symetricky vystředěna kolem hodnoty 26 ° Celsia, kde základna trojúhelníku souvisí s nejistotou tohoto měření. Pokud se však domníváme, že nejistota měření neexistuje, pak lze měření modelovat jako ostré množiny.

*Pravidla* mají strukturu **když–pak (if–then)**, například **když** *Teplota je nízká a Tlak je vysoký, pak rychlost ventilátoru je Nízká*. Každá část *když (if)* pravidla se nazývá *Antecedent* a část *pak (then)* pravidla se nazývá *Konsekvent*. Pravidla mapují vstupní fuzzy množiny k výstupním fuzzy množinám. Všechna pravidla systému tvoří *bázi pravidel*.

*Inferenční modul* rozhoduje o tom, která pravidla z báze pravidel se spustí, jaké jsou jejich vstupní hodnoty pro spuštění (pomocí fuzzy množin, které mu poskytuje modul fuzzyfikace). Inferenční mechanismus může také kombinovat stupeň aktivace každého pravidla s následnou fuzzy množinou tohoto pravidla tak, aby vytvořil výstupní fuzzy množinu pravidla (tj. výstupní množinu aktivovaného pravidla). Následně pak kombinuje všechny výstupní množiny aktivovaných pravidel tak, aby vytvořil agregovanou výstupní fuzzy množinu pomocí fuzzy operátorů, případně přeposílá stupeň aktivace každého pravidla přímo do modulu defuzzifikace, kde jsou následně všechny hodnoty agregovány do finálního výstupu.

*Modul defuzzifikace* obdrží buď agregované sady fuzzy výstupů z inferenčního modulu, nebo stupně aktivace pro každé pravidlo. Následně tyto vstupní data zpracuje tak, aby vytvořil ostré výstupní hodnoty, které jsou následně předány fyzickým akčním členům, jež ovládají skutečné zařízení.[32]

Obecně platí, že reálné řídicí systémy, jako jsou řídicí systémy s fuzzy logikou, jsou ovlivněny následujícími nejistotami:

- Nejistoty vstupů do FLC. Například měření senzoru může být ovlivněno vysokou úrovní šumu a měnicími se podmínkami pozorování, jako jsou měnicí se podmínky prostředí, například vítr, déšť, vlhkost apod. Kromě šumu měření mohou být nepřesné a vykazovat nejistotu i další možné vstupy do FLC, například odhadnuté pozorovatelem nebo vypočtené pomocí modelu procesu.
- Nejistoty týkající se řídicích výstupů, které mohou vzniknout v důsledku změn vlastností aktuátoru způsobených opotřebením, změnami prostředí a podobně.
- Nejistoty týkající se změny provozních podmínek regulátoru, například změny parametrů zařízení.
- Nejistoty způsobené rušivými vlivy působícími na systém, pokud tyto vlivy nelze měřit, např. vítr narážející na vozidlo.

Ve FLC typu 1 jsou všechny tyto nejistoty zpracovány pomocí FS typu 1 přímo v antecedentech a konsekventech pravidel a také prostřednictvím zvoleného typu fuzzyfikátoru.

Jako fuzzifikátoru lze použít:

1. Singleton fuzzifikátor, ve kterém je naměřená hodnota považována za ideální a je modelována pomocí ostré množiny;
2. Fuzzifikátor typu 1, ve kterém je naměřená hodnota považována za signál obsahující stacionární šum a je modelována jako normální fuzzy hodnota z fuzzy množiny typu 1 .

FLC typu 1 zobrazený na obrázku 4.1 je nelineární regulátor, který mapuje své vstupy  $x$  na výstup  $u$ , tj.  $u = f(x)$ , kde  $f$  je nelineární funkce, která je tvořena operacemi fuzzy logiky a matematikou fuzzy množin. Často je  $f(x)$  vytvořena z lingvistických pravidel, která shrnují lidské znalosti nebo zkušenosti (nebo mohou být zkonstruována z dat), FLC typu 1 tedy přímo mapuje tyto znalosti nebo zkušenosti do nelineárního regulačního uspořádání, jehož explicitní matematické vyjádření není ve většině případů známo.

Existují dvě základní architektury FLC typu 1, které se liší především v důsledcích fuzzy pravidel. Těmito architekturami jsou [32]:

- Mamdaniho FLC, který vypracovali Mamdani a Assilian, v němž tvoří antecedenty a konsekventy pravidel lingvistické pojmy, např: Pokud  $x_1$  je nízký a  $x_2$  je vysoký, pak  $u$  je nízký. Lingvistické proměnné v Mamdaniho FLC jsou reprezentovány fuzzy množinami typu 1.
- Takagi–Sugeno (TS) FLC nebo Takagi–Sugeno–Kang (TSK) FLC, ve kterých jsou antecedenty pravidel rovněž tvořeny lingvistickými pojmy (modelované pomocí fuzzy množin typu 1), ale konsekvent každého pravidla je modelován jako matematická funkce vstupních proměnných: Pokud je  $x_1$  nízká a  $x_2$  vysoká, pak  $u = g(x_1, x_2)$ , kde  $g(x_1, x_2)$  je polynomiální funkce  $x_1$  a  $x_2$  (může to být konstanta, lineární nebo kvadratická funkce atd.). Příkladem pravidla TSK FLC prvního řádu je: Pokud je  $x_1$  nízký a  $x_2$  vysoký, pak  $u = c_0 + c_1x_1 + c_2x_2$  kde  $c_0, c_1, c_2$  jsou parametry funkce.

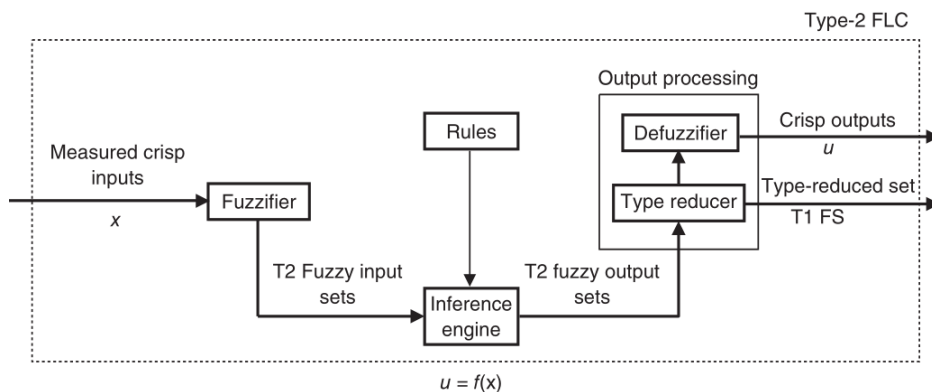
## 4.2 Fuzzy systém Typ–2

FLC typu 2 je znázorněn na obrázku 4.2. Obsahuje pět hlavních částí: fuzzifikátor, pravidla, inferenční mechanismus, typový reduktor a defuzzifikátor. V FLC typu 2 jsou vstupy a/nebo výstupy reprezentovány fuzzy množinou typu 2 a fungují následovně: ostré vstupy získané ze vstupních sensorů jsou fuzzifikovány do vstupních fuzzy množin typu 2, které pak aktivují inferenční mechanismus, jenž používá stejná pravidla jako FLC typu 1 k vytvoření výstupních fuzzy množin typu 2. Ty jsou následně zpracovány typovým reduktorem, který převede fuzzy množiny typu 2 na fuzzy množiny typu 1 (tento krok se nazývá typová redukce [34], [35]), načež jsou

tyto fuzzy množiny typu 1 defuzzifikovány a vytvoří ostrý výstup, který lze například použít jako příkaz pro akční člen v řídicím systému. Redukce typu následovaná defuzzifikací se obvykle označuje jako zpracování výstupu.[32]

V části 4.1 byly představeny některé zdroje neurčitostí, kterým čelí reálné řídicí systémy obecně. Fuzzy řízení je také ovlivněno:

- Lingvistickými nejistotami, protože význam slov, která jsou použita v jazykových proměnných antecedentů a konsekventů, může být neurčitý, tj. stejná slova mohou mít pro různé návrháře FLC různé významy.[36]
- Kromě toho se odborníci ne vždy shodují a často uvádějí různé důsledky pro stejné antecedenty. Průzkum mezi experty často vede k výběru různých možností jako důsledek pravidla a tím tato neurčitost představuje nejistotu ohledně důsledku pravidla.[36]



Obr. 4.2: Obecná struktura fuzzy logického řízení typu 2 [33]

Ve FLC typu 2 jsou všechny tyto nejistoty modelovány pomocí MF (Membership function) a fuzzy množiny typu 2 v antecedentech a/nebo konsekventech pravidel a také pomocí druhu fuzzifikátoru. Zde existují následující varianty:

1. Singleton fuzzifikátor (obdobně jako u FLC typu 1), ve kterém je naměřená hodnota považována za ideální a je pak modelována pomocí ostré množiny.
2. Fuzzifikátor typu 1 (obdobně jako u FLC typu 1), ve kterém je naměřená hodnota považována za signál a stacionární šum, je modelována jako normální fuzzy hodnota z fuzzy množiny typu 1.
3. Fuzzifikátor typu 2, ve kterém je naměřená hodnota považována za signál a nestacionární šum, přičemž je modelována jako fuzzy hodnota ovšem z fuzzy množiny typu 2.

Fuzzy systém typu 2 si lze představit jako soubor mnoha vložených fuzzy systémů typu 1, jejichž ostrý výstup se získá agregací výstupů všech vložených fuzzy systémů typu 1. V důsledku toho má FLC T2 za určitých podmínek potenciál překonat

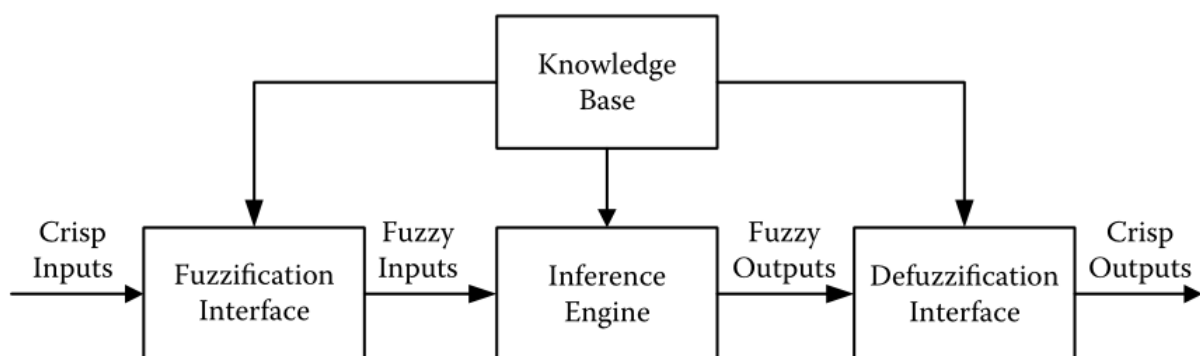


FLC T1, protože se vypořádává s nejistotami ve vstupech pomocí agregací mnoha vložených FLC T1.

FLC T2, obdobně jako FLC T1 je regulátorem s proměnnou strukturou, lze zde použít i stejné architektury Mamdani a TSK. V Mamdani nebo TSK FLC jsou použité fuzzy množiny typu 2. Stejně jako jejich protějšky jsou Mamdani a TSK FLC typu 2 univerzálními aproximátory. [32]

## 5 Modely fuzzy systémů

Fuzzy systémy jsou založené na pravidlech nebo znalostech, které vycházejí z konceptu fuzzy množin, fuzzy pravidel IF–THEN a fuzzy uvažování. Typický fuzzy systém, zejména v aplikacích fuzzy logického řízení, se skládá ze čtyř složek: báze znalostí nebo báze fuzzy pravidel, inferenčního mechanismu, fuzzifikačního a defuzzifikačního rozhraní. Blokové schéma struktury fuzzy systému je znázorněno na obrázku 4.2 [37]



Obr. 5.1: Základní struktura fuzzy systémů [27]

Znalostní báze neboli báze fuzzy pravidel obsahuje sadu fuzzy IF–THEN pravidel a databázi. Databáze je deklarativní část báze znalostí, která popisuje definice objektů (faktů, termínů) a definice funkcí příslušnosti použitých ve fuzzy pravidlech. Fuzzy pravidla jsou procedurální částí znalostní báze, která obsahuje informace o tom, jak lze tyto objekty použít k tomu, aby plnily svou úlohu – odvozování závěrů.

Inferenční mechanismus, který je ústřední součástí fuzzy systému, je mechanismus ve formě fuzzy uvažování a provádí inferenční proceduru na základě fuzzy pravidel a daných podmínek za účelem vyvození závěrů.

Rozhraní fuzzifikace (fuzzifikátor) je mechanismus pro transformaci reálně vyjádřených proměnných na fuzzy množiny. Je dobře známo, že ostrou hodnotu vstupu lze transformovat na fuzzy množinu v podobě fuzzy singletonu, který má nulovou hodnotu funkce příslušnosti všude kromě konkrétního bodu, kde je hodnota funkce příslušnosti rovna jedné. Rozhraní fuzzifikace využívající techniku fuzzy singletonu bylo široce přijato v aplikacích fuzzy řízení. Ve skutečnosti mají sledované vstupy v typických aplikacích fuzzy řízení vždy ostré hodnoty. Rozhraní fuzzifikace tyto ostré hodnoty škáluje, transformuje rozsah hodnot vstupních proměnných na odpovídající univerzum a poté převede škálované vstupní hodnoty na vhodné lingvistické hodnoty, které lze definovat jako fuzzy množinu (fuzzy singleton). Tato metoda

fuzzifikace je účinná, jednoduchá a snadno se implementuje. Tento typický proces fuzzifikace, často používaný v aplikacích fuzzy řízení, se obvykle nazývá singletonová fuzzifikace a odpovídající rozhraní se nazývá singletonový fuzzifikátor.

Na druhé straně defuzzifikační rozhraní (defuzzifikátor) je mechanismus pro transformaci fuzzy množiny nad výstupním univerzem na proměnnou s reálnou hodnotou. Cílem defuzzifikace je získat ostrou hodnotu, která nejlépe interpretuje fuzzy množinu.

Ukázalo se, že fuzzy systém s ostrými vstupy a výstupy je ve skutečnosti nelineárním mapováním ze vstupního do výstupního prostoru. Přesněji řečeno, fuzzy systém popisuje transformaci ze souboru lingvistických fuzzy pravidel IF–THEN, která jsou často popsána přirozeným jazykem na matematické nelineární mapování, které odpovídá určité matematické funkci. Právě tato užitečná vlastnost fuzzy systémů vede k jejich širokému uplatnění v různých oborech, zejména v aplikacích fuzzy řízení.

V aplikacích fuzzy řízení se hojně využívají následující dva typy fuzzy systémů. Je třeba poznamenat, že hlavní rozdíly mezi těmito dvěma fuzzy systémy spočívají v důsledcích (consequences) jejich fuzzy pravidel. [27]

### 5.0.1 Fuzzy systém typu Mamdani

Mamdaniho fuzzy systém byl navržen jako první pokus o řízení parního stroje a kotle. Typické fuzzy pravidlo v Mamdaniho fuzzy systému má tvar

$$IF\ x_1\ is\ A_1, \dots, \text{ and } x_k\ is\ A_k, \ THEN\ y\ is\ B \quad (5.1)$$


kde  $x = (x_1, \dots, x_k)$  a  $y$  jsou lingvistické proměnné,  $A_1, \dots, A_k$  jsou fuzzy množiny v antecedentu a  $B$  je fuzzy množina v konsekventu.

Typické fuzzy uvažování Mamdaniho fuzzy systému je založeno na metodě max-min inference. Na obrázku 5.2 je znázorněna taková fuzzy inference pro Mamdaniho fuzzy systém se dvěma pravidly IF–THEN.

Pokud se pro fuzzy uvažování použijí různé T-norm operátory pro fuzzy operace AND, respektive S-norm operátory pro fuzzy OR, lze získat další typy Mamdaniho fuzzy systémů. [38], [39]

### 5.0.2 Fuzzy systém typu Sugeno

Alternativní typ fuzzy systémů, známý jako Takagi–Sugeno (T–S) fuzzy systémy, navrhli Takagi a Sugeno (1985) ve snaze vyvinout systematický přístup k aproximaci



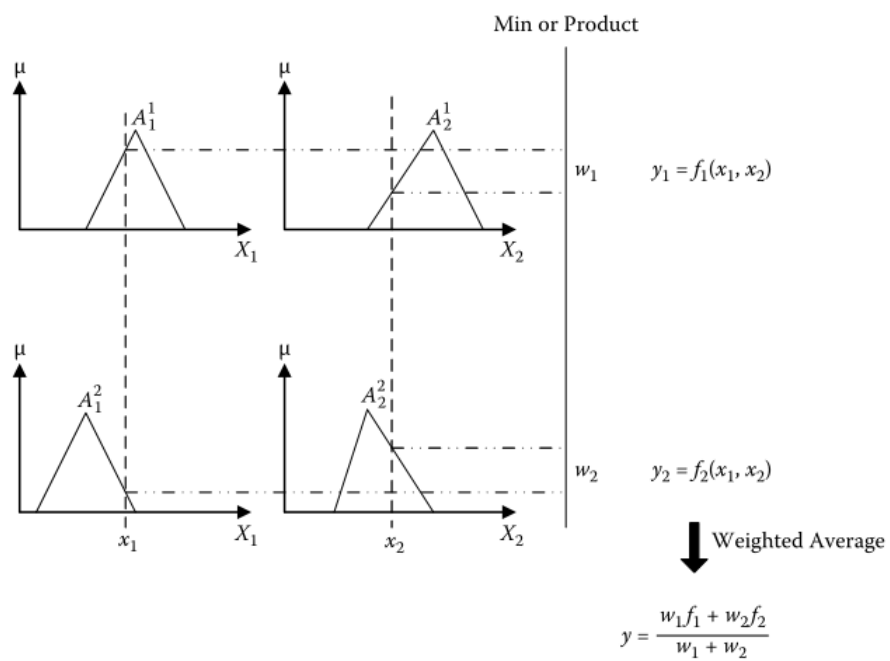
Obr. 5.2: Mamdaniho fuzzy uvažování založené na metodě max–min inference [27]

nelineární funkce. Typické fuzzy pravidlo ve fuzzy systému T–S má tvar [27]

$$IF x_1 \text{ is } A_1, \dots, \text{ and } x_k \text{ is } A_k, \text{ THEN } y = f(x_1, \dots, x_k) \quad (5.2)$$

kde  $x = (x_1, \dots, x_k)$  a  $y$  jsou jazykové proměnné,  $A_1, \dots, A_k$  jsou fuzzy množiny v antecedentu a  $y = f(x_1, \dots, x_k)$  je nejčastěji polynom vstupní proměnné  $x$ , ale může to být libovolná funkce, pokud dokáže vhodně popsat výstup systému v oblasti určené antecedentem pravidla. Pokud je  $f(x_1, \dots, x_k)$  polynom prvního řádu, výsledný fuzzy model se nazývá fuzzy systém T–S prvního řádu, který byl původně navržen Takagi a Sugeno, Sugeno a Kang. Je-li funkce  $f$  konstantní, pak mluvíme o fuzzy systému T–S nultého řádu, který lze považovat za speciální případ Mamdaniho fuzzy systému, kde je důsledek každého pravidla určen fuzzy singletonem.

Výstup T–S fuzzy systému se získá váženým průměrem ostrých výstupů fuzzy pravidel. Tím se lze vyhnout časově náročnému postupu defuzzifikace. Na obrázku 5.3 je uveden příklad grafické interpretace fuzzy uvažování pro T–S fuzzy systém se dvěma pravidly. [40]



Obr. 5.3: Fuzzy inferenční systém Takagiho a Sugena [27]

## 6 Simulátor řízení vozidla

V níže uvedeném textu je popis simulátoru určeného k simulaci a sběru dat pro řízení vozidla. Je zde popsána jeho základní koncepce a vlastnosti. Simulátor slouží pro bezpečné sledování chování řidiče a získávání relevantních údajů. Nutno zdůraznit, že vytvoření simulátoru nebylo součástí práce, ale byl pouze využit k získání dat. Klíčové vlastnosti simulátoru jsou následující:

- Softwarové prostředí simulátoru - herní enginy nabízejí komplexní integrované vývojové prostředí s užitečnými nástroji a prostředky, které značně zjednodušují aplikační vývoj. V simulátoru je využito nástroje Unreal Engine kvůli své uživatelské přívětivosti, prostředí, vstřícné komunitě, velkému množství dostupných aplikací a prostředků, jako je například fyzický model vozidla, implementovaná podpora fyziky PhysX od společnosti NVIDIA a další. [41]
- Scénáře, které simulují reálné situace. Klíčové atributy chování řidiče jsou získávány záznamem dat ze senzorů napojených na simulátor a dále použity pro analýzy chování lidského řidiče.
- Konstrukce simulátoru – nezbytné hardwarové komponenty, které simulují kabinu řidiče obsahují: volant s odpovídající přesností a stupněm volnosti, pedály, řadicí páku a stolní monitor s dostatečně širokým zorným úhlem.
- Software pro sběr dat.[18]

### 6.1 Vstupní zařízení

Vozidlo v simulátoru řízení auta lze ovládat pomocí volantu a pedálů Logitech G920. Volant má rozsah otáčení 900 stupňů a zpětnou vazbu pomocí dvou motorů. Brzdový pedál je nelineární - lépe odpovídá fyzickému chování pedálu ve vozidle. K dispozici je také řadicí páka Driving Force Shifter. Vše je spojeno v konstrukci se sedadlem a širokoúhlým monitorem.

### 6.2 Scénáře

V simulátoru řízení autoři implementovali několik scénářů, které umožňují simulovat situace, ve kterých je vhodné získávat data o řidiči. Celý systém simulátoru je vytvořen tak, aby bylo možné relativně snadno přidávat nové varianty simulace v závislosti na výzkumných cílech.



Obr. 6.1: Simulátor: pohled od řidiče



Obr. 6.2: Simulátor: boční pohled

### 6.2.1 Dálnice – přejíždění mezi pruhy

Scénář obsahuje mapu dálnice, která je dlouhá přes 8 kilometrů a nemá žádné zatáčky - jedná se o dlouhou a rovnou trasu. Uživatel, který si vybere tento scénář, se objeví na dálnici se svým vozidlem a jeho úkolem, po zobrazení výzvy ke změně jízdního pruhu, je přejet do vedlejšího pruhu. Maximální rychlost vozidla si volí uživatel sám nebo ji nastaví obsluha simulátoru (lze ji změnit buď v hlavní nabídce, nebo při

pozastavení aplikace). Po dosažení požadované rychlosti se v určitém časovém intervalu změni poloha středu jízdního pruhu, který musí uživatel používat. Tato změna je podmíněna udržováním rychlosti kolem stanovené rychlosti a náhodně generovaným zpožděním mezi 10 a 30 sekundami. Tato simulace provádí ověření schopností řidiče reakce na požadavek změny jízdního pruhu. Jakmile vozidlo projede předem definovanou délkou trati, dochází k automatickému ukončení simulace. [18]

### **6.2.2 Dálnice – dálková jízda**

Tento scénář opět zahrnuje dlouhou dálnici, i když v tomto případě má dlouhé zatáčky. Nejedná se tedy o přímou trasu. Účelem tohoto scénáře je změřit chování řidiče během dlouhé jízdy a jeho schopnost udržet pozornost a udržet stejný směr. Hlavním měřeným údajem je vzdálenost od středu jízdního pruhu, kterou musí řidič udržet co nejmenší. Poloha jízdního pruhu se však proti předchozímu scénáři nemění. [18]

### **6.2.3 Scénář města**

Mapa města obsahuje mnoho zatáček a kratších či delších tras. Hlavním účelem scénáře je umožnit uživateli vyzkoušet si vozidlo a donutit ho často měnit rychlost, zrychlovat a brzdit. Během scénáře se ukládá trasa, kterou uživatel projede, aby ji bylo možné porovnat s jeho předchozími jízdami. Na základě dalších výsledků měření můžeme vytvořit ideální trasu, kterou by měl uživatel absolvovat. V budoucnu lze tento scénář použít s algoritmy pro autonomní řízení a naměřené trasy porovnat s těmi, které projeli skuteční řidiči. Tím by se mohla určit spolehlivost algoritmů nebo efektivita řidičů. [18]

### **6.2.4 Scénář losího testu**

Jedná se o scénář založený na skutečném měření chování vozidel na krátkých trasách. Jeho cílem je otestovat stabilitu vozidla a spolehlivost modelu vozidla implementovaného v simulátoru. Test je definován normou ISO 388-2:2011, která definuje rozměry zkušební dráhy, prováděný manévr, požadovanou dynamiku vozidla a přilnavost povrchu. Tuto zkoušku lze použít pro osobní automobily definované normou ISO 3833 a lehká užitková vozidla do maximální hmotnosti 3,5 tuny. [18]



## 7 Zdrojová data průběhu simulace

V této práci se dále používají data získaná ze simulátoru chování řidiče. Zpracovávaná data pocházejí z varianty simulace „přejíždění do pruhu“ sledující chování řidiče při požadavku na přejetí do jiného pruhu vozovky při konstantní rychlosti. Tato simulace odpovídá reakci systému na jednotkový skok. Vlastní simulace je započata spuštěním simulátoru, navolením názvu souboru pro uložení dat simulátoru. Po dokončení simulace je vytvořen požadovaný datový soubor.

### 7.1 Datový soubor

Datový soubor je uložen v textovém formátu s oddělovačem údajů a prvním řádkem obsahující názvy sloupců (formát CSV). Ukázka formátu datového souboru výstupu simulace:

```
Time(ms); X pos; Y pos; SplineDistance; Velocity;
WheelAngle; HeartBeat\_ms
21340;37;33161;0.385156;91.0;0.004166;0.988235;0
21348;37;33179;0.385391;91.0;0.004166;0.988235;0
21355;37;33197;0.385469;91.0;0.004166;0.988235;0
21362;37;33216;0.385625;91.0;0.004166;0.988235;0
```

Popis jednotlivých sloupců:


- **Time(ms)** – čas odečtení hodnot ze stavu simulátoru, hodnota je v ms.
- **X pos** – pozice vozidla od středu jízdního pruhu, hodnota je v m.
- **Y pos** – ujetá vzdálenost vozidla od počátku simulace, hodnota je bezrozměrná.
- **SplineDistance** - vzdálenost středu kapoty vozidla od požadovaného středu jízdního pruhu, hodnota je v m.
- **Velocity** – okamžitá rychlost vozidla, hodnota je v km/h.
- **WheelAngle** – okamžitý úhel natočení volantů, hodnota je normalizovaná do intervalu  $<-1,1>$  odpovídající úhlu natočení v rozsahu  $<-450^\circ, 450^\circ>$ .
- **HeartBeat\\_ms** – srdeční tep.
- Poslední sloupec dat je naplněn jen hodnotou 0.

### 7.2 Základní statistiky naměřených hodnot

Aktuální datová sada obsahuje naměřené hodnoty z právě jedné kompletní simulace pro 38 unikátních řidičů. Pro jednoho konkrétního řidiče je k dispozici celkem 5

simulací, které následovaly bezprostředně po sobě. Statistické zpracování dat bylo prováděno pomocí skriptů jazyka R [42].

Sloupec Time(ms) obsahuje časovou značku, při které došlo k zaznamenání stavu systému/řidiče. Aby bylo možné srovnávat jednotlivé průběhy reakce na jednotkový skok (představovaný požadavkem na změnu jízdního pruhu), je třeba, aby byl interval vzorkování stejný pro všechny simulace. Z analýzy dat plyne, že průměrný čas mezi vzorky za všechny zkoumané simulace (38) je 7,254 ms, při odstranění odlehklých hodnot v prvním a čtvrtém quartilu. Zobrazení boxplotu pro čas vzorkování přes celý dataset s vyřazením o odlehklých hodnot je na obrázku 7.1



Obr. 7.1: Boxplot pro čas vzorkování přes celý dataset bez odlehklých hodnot

Určitá proměnnost v čase vzorkování je způsobena více faktory. V první řadě je třeba vzít v potaz, že software pro simulaci není provozován na RT systému a není tedy zaručeno operačním systémem, že bude dodržen stále stejný čas vzorkování. Dalším faktorem, který má vliv na čas vzorkování je použití herního systému Unreal Engine, kdy složitost scény spolu s rychlostí obnovování displeje může vnést zpoždění do vzorkování stavu simulátoru. Jako jeden z významných faktorů podílejících se na proměnném čase vzorkování je nutno uvést i použití celočíselného datového typu pro uložení času a tím i nejmenší rozlišovací hodnotu kterou je 1 ms. Proměnnost času vzorkování 6-9 ms se projevuje tak, že vzorky stejného pořadového čísla od okamžiku jednotkového skoku se v některých případech liší až o 1,5 s, což ovlivňuje správné určení času časového zpoždění nebo doby ustálení.


Řešením uvedeného problému je převzorkování dat na pevnou hodnotu času např. se vzorkem 20 ms. Toto převzorkování lze snadno provést pomocí metody lineárního

převzorkování, kdy se pro hodnotu v odpovídajícím čase použije nejbližší zaznamenaná hodnota. V dalším textu se pracuje s převzorkováním dat na hodnotu vzorkování 20 ms. Následující tabulka 7.1 obsahuje základní charakteristiky ostatních atributů datasetu:

Tab. 7.1: Základní charakteristiky atributů datasetu

Atribut	Minimum	Maximum	Medián	Průměr
X_Pos	-98	443	71	157,5
Y_Pos	0	365425	169634	170780
SplineDistance [m]	-4,457	4,264	-0,035	-0,080
Velocity [km/h]	0,0	93,0	91	85,48
WheelAngle [°]	-42,607	44,763	-0,021	-0,014


Pro každou jednotlivou simulaci je nastavena stejná délka trvání a to 2,5 min, v reálu, ale díky dříve uvedeným omezením použitého řešení a operačního systému dochází k situaci, kdy je v podstatě každá simulace jiné délky. Průměrná délka simulace pro všech 38 jedinečných simulací je 154 s, což odpovídá přibližně době 2 minuty a 33 sekund. Boxplot variability doby simulace je na obrázku 7.2.



Obr. 7.2: Boxplot doby simulace

## 7.3 Vizualizace naměřených dat

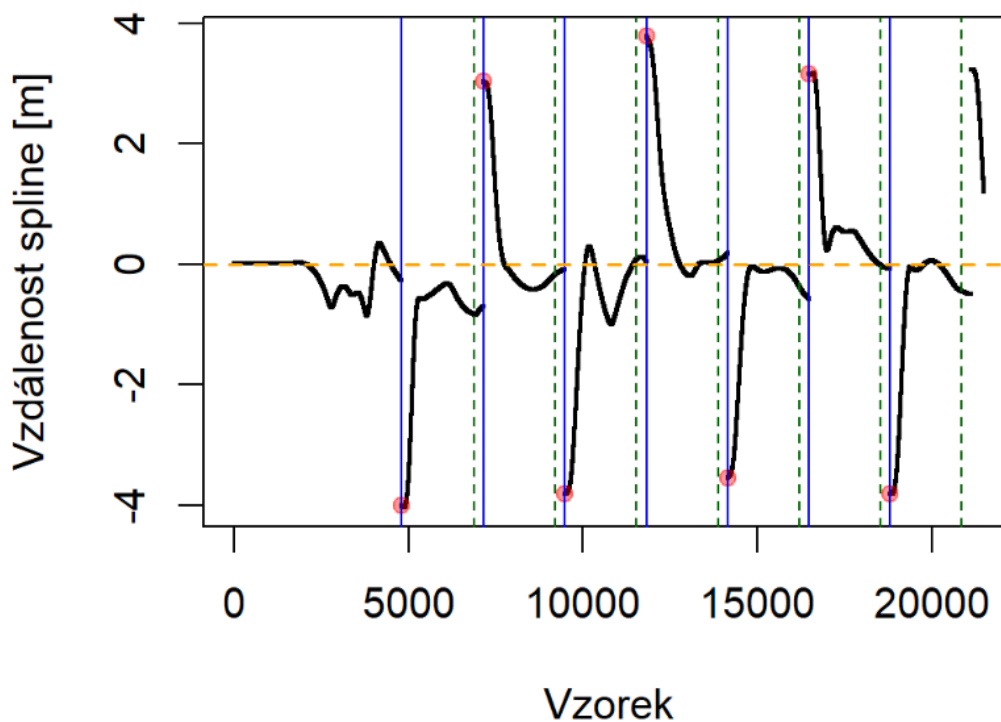
Pro lepší pochopení vztahů v datech je na následujícím obrázku 7.3 zobrazen grafický průběh základních naměřených hodnot pro jeden úplný průběh celé simulace vybraného uživatele.



Obr. 7.3: Vizualizace dat ze simulátoru

Oranžový průběh zachycuje úhel natočení volantu ve stupních a spodní zelený graf ukazuje vzdálenost středu vozidla od spline reprezentující střed jízdního pruhu. Na tomto grafu lze snadno identifikovat okamžiky, kdy dochází v rámci simulace k výzvě ke změně jízdního pruhu – výrazná změna hodnoty vzdálenosti od středu jízdního pruhu. Záporná hodnota reprezentuje přesun z pravého do levého jízdního pruhu vozovky a kladná pak přechod z levého do pravého. Na zde uvedeném příkladu lze tedy vidět celkem čtyři požadavky na přejetí z pravého do levého pruhu a tři požadavky na přejetí z levého do pravého pruhu (poslední čtvrtý požadavek není dokončen).

Pro další analýzy je třeba z průběhů naměřených dat vybrat pouze zajímavé oblasti (AOI area of interest). Délka AOI je nastavena na hodnotu 15 s od zobrazení požadavku na změnu jízdního pruhu. Obrázek 7.4 zobrazuje červeným bodem a modrou vertikální čarou okamžik požadavku na změnu jízdního pruhu vygenerovaný simulátorem a zelená čárkovaná vertikála pak zobrazuje časový interval 15 s od zobrazení požadavku. Pouze ty části datového souboru, které splňují úplnost ve smyslu délky časového úseku 15 s jsou zahrnuty jako AOI v dalších analýzách. Úseky kratší než 15 s nejsou v dalších analýzách dále uvažovány.



Obr. 7.4: Zajímavé oblasti v datech

Hodnota 15 s byla zvolena jako časový interval, ve kterém se provádí analýzy zaměřené na identifikaci stavu ustálení. Z uvedeného obrázku 7.4 je patrné, že každá simulace se skládá z několika přejetí mezi jízdními pruhy. Je tedy potřeba se v dalších analýzách také zaměřit nejen na samostatné přejetí mezi pruhy, ale i celkový průběh změny pruhu v rámci celé délky simulace.


## 7.4 Chyby v datové sadě

Při vizuální kontrole dat byly nalezeny průběhy, které se vymykají očekávanému tvaru změny jízdního pruhu. Pro vznik těchto nestandardních průběhů lze stanovit dvě základní příčiny:

1. Při simulaci došlo k chybě a simulace byla restartována. Tato chyba je snadno algoritmicky identifikovatelná. Stačí ověřit, zda jsou časové značky pouze v rostoucí aritmetické posloupnosti. V případě, že je nalezena časová značka se zápornou diferencí, došlo k restartu simulace. Takové simulace jsou z další analýzy vyřazeny.
2. Osoba, která je v simulovaném prostředí, neřídí vozidlo v simulaci v souladu s pokyny. Identifikace těchto průběhů je strojově obtížná a jednou variantou je ověření očekávaného počtu extrémních výkyvů ve vzdálenosti od spline před-

stavující střed požadovaného jízdního pruhu. Viz obrázek 7.5.

Získaná data ze simulátoru jsou v konzistentní formě a neobsahují nezadané či náhodné extrémní hodnoty. Tato vlastnost činí jejich základní statistické zpracování bezproblémovým. Z celkového počtu 42 provedených a dostupných simulací byly pouze 4 simulace odstraněny z důvodu nestandardních průběhů.




Obr. 7.5: Ukázka nestandardního průběhu simulace

## 7.5 Průběh změny jízdního pruhu v simulaci

Jednou z možností pro stanovení globálního průběhu pro změnu jízdního pruhu je varianta průměrování hodnot přes všechny průběhy. Obrázek 7.6 ukazuje průměrný průběh změny jízdního pruhu. Horní graf zobrazuje černou čárkovanou křivkou průměrnou hodnotu změny jízdního pruhu. Jednotlivé barevné křivky ukazují průběh všech změn jízdního pruhu v rámci simulace. Pro porovnatelné zobrazení a výpočet průměru je změna směru zprava doleva upravena vynásobením hodnotou -1 a jsou použity převzorkované hodnoty.

Při zpracování křivek průměrů se projevila zajímavá charakteristika křivek, kdy se v rámci jedné simulace průměrné křivky změny jízdního pruhu liší podle směru přejezdu. Tedy zleva doprava nebo naopak. I na obrázku 7.6 lze pozorovat rozdíl mezi křivkami pro vybočení vpravo a vlevo. Na následujícím obrázku 7.7 jsou zobrazeny průměrné křivky společně s jejich intervaly spolehlivosti. Z nich je patrný




Obr. 7.6: Průměrné průběhy změny jízdního pruhu

výrazný rozptyl hodnot reprezentovaný šířkou intervalu spolehlivosti mezi vybranými změnami směru.

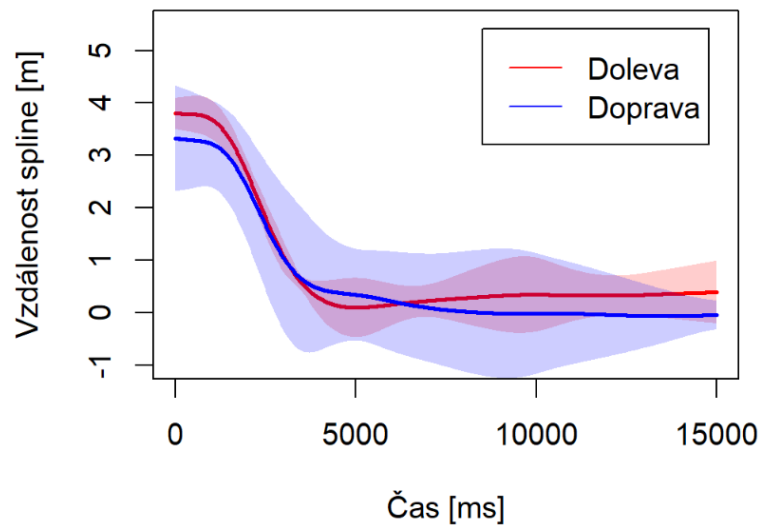
Zobrazení porovnání průměrného průběhu změny jízdního pruhu a intervalů spolehlivosti mezi změnou směru vlevo a vpravo ukazuje obrázek 7.8. V tomto konkrétním případě neexistuje z důvodu překrytí intervalů spolehlivosti statisticky významný rozdíl mezi těmito průběhy.

Zobrazení všech průběhů simulací a vypočteného průměrného tvaru změny směru doleva a doprava jsou na následujících obrázcích 7.9 a 7.10.

Finální srovnání všech levých a pravých změn směru a jejich intervalů spolehlivosti je na obrázku 7.11. Intervaly pro každý směr jsou velmi úzké a vzhledem k tomu, že se nepřekrývají, tak jejich průběhy vykazují statisticky významného rozdílu mezi změnou směru vlevo a vpravo. Nicméně z uvedeného tvaru křivek lze vyzpat, že zde existuje určité posunutí mezi křivkami, které by mohlo odpovídat chování řidiče při přejezdu do levého pruhu, kdy tato méně obvyklá situace působí na odhad




Obr. 7.7: Intervaly spolehlivosti pro průměrné hodnoty změny směru



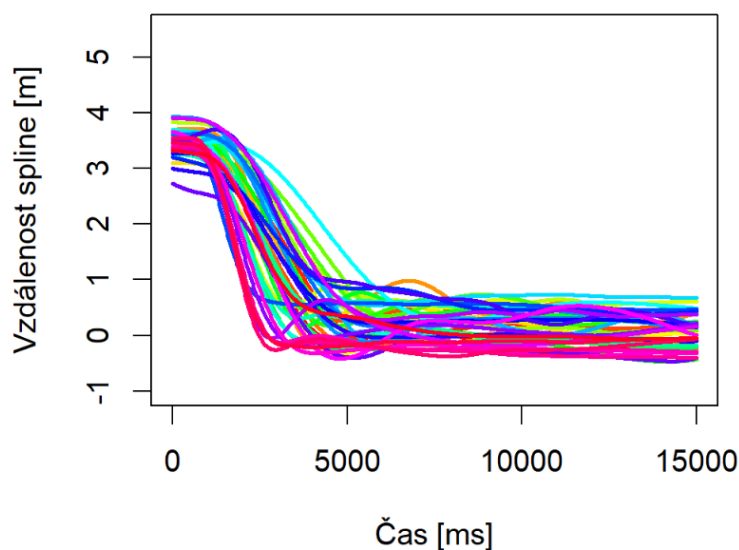
Obr. 7.8: Porovnání intervalů spolehlivosti mezi zatáčkami

vzdálenosti řidiče tak, že považuje svou polohu za odpovídající a správnou. Tato hypotéza by šla potvrdit či vyvrátit nalezením odchylky obou křivek a porovnáním





Obr. 7.9: Všechny průměrné změny jízdního pruhu doleva

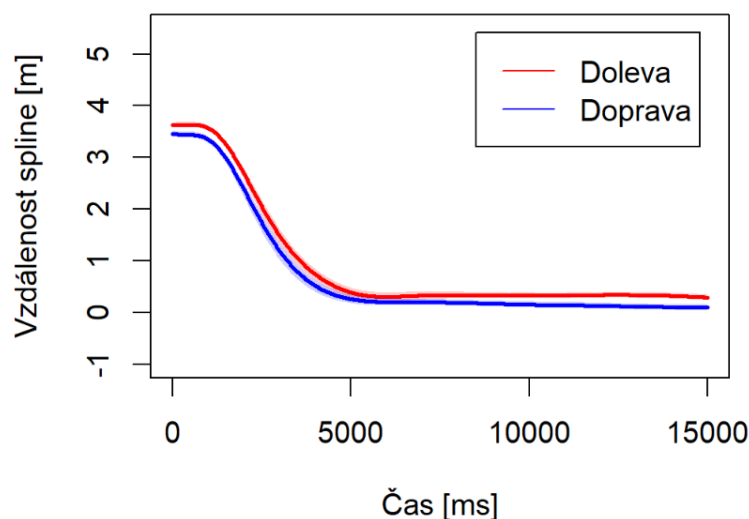


Obr. 7.10: Všechny průměrné změny pruhu doprava

s jeho vrozeným upřednostňováním jedné či druhé ruky. K tomuto by bylo třeba vyhodnotit ovšem dodatečné informace o řidiči, které nejsou k dispozici.

## 7.6 Doba změny polohy a doba ustálení

Pro doplňkový popis chování řidiče, byly v rámci této práce extrahovány z jednotlivých měření (a jednotlivých reakcí na požadavek změny směru) specifické informace o počáteční *době změny polohy* a *době ustálení*. Zavedení uvedených pojmů bude



Obr. 7.11: Intervaly spolehlivosti pro zatočení vlevo a vpravo

následovat dále v této kapitole.

### 7.6.1 Reakční doba a její komponenty

Reakční doba nebo také rychlost reakce člověka je obecně nejkratší čas vedoucí k reakci/odpovědi člověka na vnější podnět. Měřením reakční doby se zabývá reaktometrie a znalost reakční doby člověka je využívána v mnoha lidských činnostech, ve kterých hraje člověk ústřední řídicí nebo kontrolní roli.

Ačkoliv se může na první pohled zdát, že je měření a obecně stanovení reakční doby u člověka jednoduchá záležitost, opak je pravdou. Velmi často pro nás není důležitá samotná reakční doba člověka, ale reakční doba složeného systému člověk–stroj. Jako klasický a každému srozumitelný příklad využití reakční doby je použití při rekonstrukci dopravních nehod. Zde je často používána „standardní“ reakční doba 1,5 sekundy, pro souhrnnou reakci systému řidič–vozidlo na vnější podnět.

Ve skutečnosti je ale reakční doba obecně komplikovaným chováním složeného systému a je ovlivněna velkým množstvím proměnných a rychlost reakce řidiče je možné měnit tréninkem či jeho vnitřním a vnějším stavem. Obecně tedy nemůže existovat jedna hodnota reakční doby, která by platila univerzálně.

Existuje několik různých tříd reakčních časů, z nichž každá má poněkud odlišné vlastnosti. V dalším textu bude popsána především reakční dobu řidiče vozidla.[43]

#### Součásti reakční doby

Když člověk reaguje na vnější podnět, tedy to co slyší, vidí nebo cítí, může být celková reakční doba rozložena na sekvenci jednotlivých základních komponent.

1. **Doba mentálního zpracování** - jedná se o dobu, kterou člověk potřebuje, aby si uvědomil, že došlo k vnějšímu signálu, a rozhodl se reagovat. Je to například čas, který řidič potřebuje k tomu, aby zjistil, že chodec jde po vozovce přímo před ním, a rozhodl se, že má použít brzdy. Doba duševního zpracování je sama o sobě složena ze čtyř dílčích fází [43]:

- **Pocit (sensation):** čas potřebný k detekci sensorického vstupu z objektu. („Na vozovce je překážka.“) Reakční doba se obvykle snižuje s větší intenzitou vstupního signálu (jas, kontrast, velikost, hlasitost atd.), pozorováním a lepšími podmínkami viditelnosti. Kratší reakční časy jsou také dosahovány pro sluchové podněty než pro vizuální. Tato fáze není pravděpodobně řízena vědomím rozhodováním člověka, jedná se spíše o variantu reflexního chování.
- **Vnímání/rozpoznávání:** čas potřebný k rozpoznání významu vjemu. („Tvar je osoba.“) To vyžaduje použití informací z paměti k interpretaci sensorického vstupu. V některých případech je tato fáze velmi rychlá. V jiných případech může „řízená odezva“ trvat značnou dobu. Obecně lze říci, že nový vstup zpomaluje odezvu, obdobně jako nízká pravděpodobnost vnějšího podnětu a také moment překvapení.
- **Situační povědomí:** čas potřebný k rozpoznání a interpretaci scény, extrahování jejího významu a případně extrapolaci do budoucnosti. Jakmile například řidič rozpozná chodce na vozovce a spojí tento vjem se znalostí své vlastní rychlosti a vzdálenosti, uvědomí si, co se děje a co se bude dít dál – auto míří k chodci a může mít za následek kolizi, pokud nebude podniknuta nějaká akce. Stejně jako u vnímání/rozpoznávání zpomaluje nová událost fázi mentálního zpracování.
- **Výběr a příprava odezvy:** čas potřebný k rozhodnutí, jakou, pokud vůbec nějakou, reakci provést a mentálně vytvořit pohyb. („Měl bych řídit doleva místo brzdění.“) Volba odezvy se zpomaluje, pokud existuje více možných signálů. Cvičením různých situací se naopak potřebný čas rozhodnutí zkracuje. Některé studie ukazují, že většina lidí vykazuje přípravné svalové potenciály před skutečným vykonáním pohybu. Lze tedy říci, že rozhodnutí reagovat nastává znatelně rychleji, než lze pozorovat nebo měřit jakoukoliv fyzickou odezvu.

Uvedené čtyři fáze jsou obvykle sloučeny dohromady jako pojem „doba vnímání“, což je nesprávné pojmenování, protože výběr reakce a některé aspekty situačního uvědomění jsou rozhodnutí, nikoli vnímání.

2. **Doba pohybu** – Jakmile je odpověď organismu vybrána, musí být fyzicky proveden požadovaný pohyb. Například chvíli trvá, než se zvedne noha z plynového pedálu, přesune se stranou k brzdě a poté sešlápne pedál.

Na dobu pohybu má vliv několik faktorů. Obecně platí, že složitější pohyby vyžadují delší dobu pohybu, zatímco praxe a cvičení zkracují dobu pohybu. Yerkes–Dodsonův zákon říká: „že silné emocionální vzrušení, které může být vyvoláno nouzovou situací, zrychluje pohyby hrubé motoriky, ale zhoršuje jemné detailní pohyby.“

3. **Doba odezvy zařízení** – Mechanickým zařízením chvíli trvá, než se aktivují, a to i poté, co došlo k akčnímu zásahu. Například řidič, který šlápne na brzdový pedál, nezastaví auto okamžitě. Zastavení je vlastně funkcí mechanického přenosu síly od pedálu na brzdový systém a fyzikálních sil jako je gravitace či tření.

Z pohledu řidiče existují faktory, které ovlivňují reakční dobu. Při zachování předpokladu denního světla a dobré viditelnosti, lze identifikovat tyto základní faktory. [43]

- **Očekávání** – Reakční časy jsou do značné míry ovlivněny tím, zda je řidič připravený na nenadálé události, například brždění.
- **Důležitost/naléhavost** – Lidé brzdí rychleji, když je velká důležitost/naléhavost, kdy je čas ke srážce kratší. Řidič jede rychleji a/nebo je překážka při prvním spatření blízko.
- **Kognitivní zátěž** – V případech, že řidičovu pozornost spotřebovávají jiné činnosti například spojené s řízením, doba brždění se prodlouží.
- **Propojení stimulu a odezvy** – Někteří lidé mají silná propojení mezi vjemy a reakcemi. Aktivace těchto propojení „stimul–odezva“ bývá velmi rychlé, s malou potřebou přemýšlení a s nízkou mírou chybovosti. Slabé či žádné propojení stimulu a odezvy obvykle znamená pomalou reakci a vysokou pravděpodobnost chyby reakce.
- **Refrakterní doba** – Po reakci na vnější podnět nervový systém člověk přechází do tzv. refrakterní doby. Během určitého časového období jsou nové reakce obecně pomalejší, než kdyby nedošlo k žádnému předchozímu podnětu následovanému reakcí organismu.
- **Věk** – Přestože většina základních výzkumů zjistila, že starší lidé reagují pomaleji než mladší, údaje o brzdě době u starších řidičů nejsou zcela statisticky průkazné ve prospěch mladších řidičů.
- **Pohlaví** – Z provedených průzkumů se zdá pravděpodobné, že ženy reagují o něco pomaleji než muži.
- **Viditelnost** – Při špatné viditelnosti se prodlužuje reakční doba. Nízký kontrast, periferní sledování, špatné počasí atd. má negativní vliv na reakční dobu jedince.
- **Složitost odezvy** – Složitější svalové reakce obecně trvají déle. Například brždění vyžaduje zvednout nohu z plynu, přesunout se do strany k brzdovému

pedálu a poté sešlápnout. To je mnohem složitější a komplexnější pohyb než je prosté otáčení volantem.

Doba odezvy je individuálním parametrem každého řidiče a závisí na mnoha dalších faktorech, jako jsou zkušenosti, únava a stres. Hodnota tohoto parametru má přímý vliv na bezpečnost při jízdě a míra ohrožení zdraví a života závisí na rychlosti reakce řidiče.[44]

Tab. 7.2: Průměrné doby odezvy na různé typy podnětů [44]


Typ podnětu	Časový interval odezvy [s]
Jednoduchý	0,7 - 0,85
Komplexní, očekávaný	1 - 1,15
Komplexní, neočekávaný	1,3 - 1,5

Podrobně tuto problematiku popisuje článek [44]. Pojednává o studii reakční doby řidičů na měřicí dráze s využitím tří různých typů podnětů. Výsledky testů ve formě reakčních časových intervalů jsou uvedeny v tabulce 7.2. V rámci studie byly testovány reakce řidičů na:

- **Jednoduchý podnět** – na událost na signalizačním zařízení v zorném poli řidiče.
- **Komplexní podnět, očekávaný** – řidiči byli informováni, že v určitém okamžiku během testu dojde k události, na kterou musí reagovat.
- **Komplexní podnět, neočekávaný** – řidiči nevěděli, že za jízdy dojde k události.

## 7.6.2 Počáteční doba změny polohy

Jeden z charakteristických parametrů systému řidič–vozidlo je počáteční doba změny polohy. Dle popisu z předchozí kapitoly 7.6.1 lze jednotlivé komponenty reakční doby chápat jako sérii po sobě jdoucích časových intervalů, tak jak je zobrazeno na obrázku 7.12. Časy  $t_a$ ,  $t_b$  a  $t_c$  (čas reakce na vnější podnět, doba šíření signálu z mozku



Obr. 7.12: Faktory ovlivňující reakční dobu

do svalů rukou, doba vykonání mechanického pohybu končetinou) představují individuální charakteristiku každého člověka, která je závislá na jeho psychickém a

fyzickém stavu. Doba  $t_d$  představuje čas potřebný ke změně pozice kol vozidla a je závislá na mechanických parametrech řízené soustavy. V případě použití simulátoru je tato hodnota konstantní.

**Definice 1:** Pod pojmem **počáteční doba změny polohy**  $t_z$  (viz rovnice 7.1) bude v dalším textu uvažován čas mezi požadavkem na změnu směru (jednotkový skok) a časem, kdy dojde ke změně vzdálenosti  $d$  vozidla vůči spline představující střed jízdního pruhu o 10 % z počáteční vzdálenosti od středu jízdního pruhu v okamžiku požadavku na změnu pruhu.

$$t_z = t_a + t_b + t_c + t_d + t_{dz} \quad (7.1)$$

Kde  $t_a$  je čas reakce na vnější podnět,  $t_b$  doba šíření signálu z mozku do svalů rukou,  $t_c$  doba vykonání mechanického pohybu končetinou,  $t_d$  doba mechanické odezvy vozidla,  $t_{dz}$  je čas potřebný k posunutí vozidla v určitém směru o vzdálenost  $d$ .


**Definice 2:** Pod pojmem **doba ustálení** bude v dalším textu uvažován časový interval mezi počátkem požadavku na změnu jízdního pruhu a časem  $\leq 15$  s kdy dojde ke změně hodnoty vzdálenosti mezi středem požadovaného jízdního pruhu a středem vozidla o hodnotu  $\geq \pm 10$  % počáteční maximální vzdálenosti od středu jízdního pruhu v okamžiku přijetí požadavku na změnu jízdního pruhu. Tato hodnota se získá při vyhodnocení křivky změny směru od jejího konce v čase 15 s směrem k počátku.

Na následujícím obrázku 7.13 je zobrazena doba změny polohy a doba ustálení pro změnu jízdního pruhu doleva. Šedá oblast označuje hodnoty 10 % maxima v horní části grafu. Ve spodní části je hodnota určující dobu ustálení symetrická kolem nuly. Červená vertikální čára představuje doba změny polohy (levá čára), respektive dobu ustálení (časový interval mezi nulou a pravou červenou čarou).

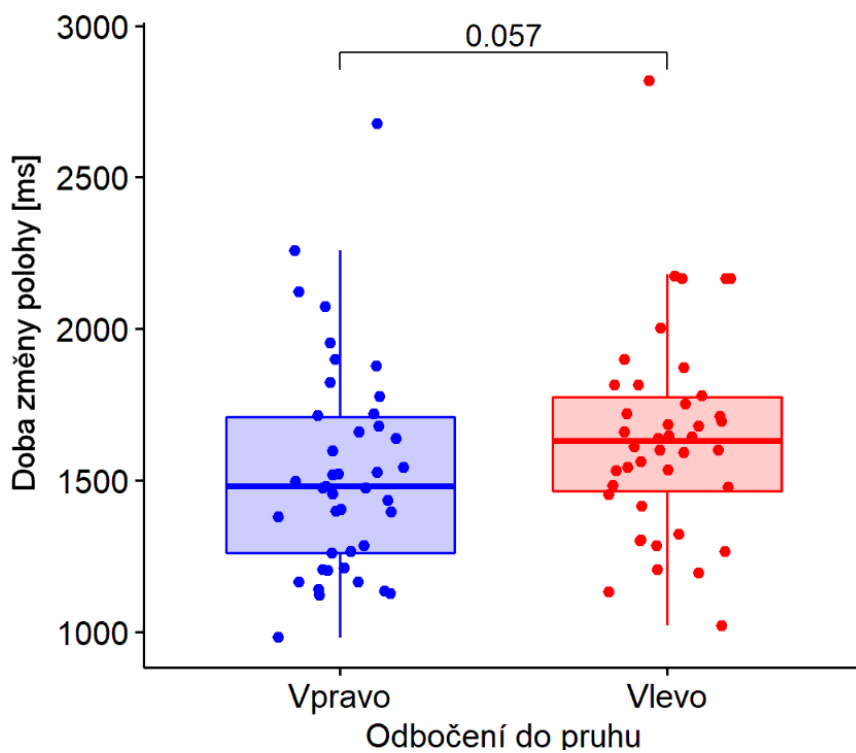
Vztah mezi dobou změny polohy a směrem změny jízdního pruhu je zachycen pomocí boxplotů na obrázku 7.14. Číslo v horní části obrázku představuje p-hodnotu Wilcoxonova testu.

Pro ověření statisticky významného rozdílu mezi mediánem doba změny polohy pro změnu jízdního pruhu, je použit Wilcoxonův test. Vzhledem k tomu, že p-hodnota 0,057 Wilcoxonova testu není menší než hladina významnosti  $\alpha = 0,05$  nelze zamítnout nulovou hypotézu o shodnosti mediánu doby změny polohy.

Vztah mezi dobou ustálení a směrem změny jízdního pruhu je zachycen pomocí boxplotů na obrázku 7.15. V případě, že aplikujeme Wilcoxonův test pro ověření, že hodnota mediánu doby změny polohy pro změnu směru doprava je menší než medián pro změnu směru doleva, pro hladinu významnosti  $\alpha = 0,05$ , výsledná p-hodnota



Obr. 7.13: Doba změny polohy a doba ustálení




Obr. 7.14: Doba změny polohy v závislosti na směru změny pruhu

je 0,02829, z čehož plyne, že hodnota mediánu doba změny polohy pro změnu jízdního směru doprava je signifikantně menší než medián reakční doby pro změnu směru doleva. Korelační koeficient vyjadřující vztah mezi dobou změny polohy pro změnou

jízdního pruhu vlevo a vpravo je 0,757, což potvrzuje očekávanou pozitivní korelaci. Síla testu korelace má hodnotu 0,928 a odpovídá vysoké spolehlivosti výsledku vzájemné korelace.

Na dalším obrázku 7.15 je pomocí boxplotů zachycen vztah mezi mediánem doby ustálení pro změnu jízdního pruhu.



Obr. 7.15: Doba ustálení a změna jízdního pruhu

Wilcoxonův test hypotézy na rovnost mediánů pro hladinu významnosti  $\alpha = 0,05$  vrátil p-hodnotu 0,781, což pro hypotézu  $H_0$  o rovnosti mediánů znamená, že ji nelze zamítnout. Ani jednostranné testy hypotéz o větší či menší hodnotě mediánu doby ustálení nevedly k zamítnutí patřičné nulové hypotézy  $H_0$ . Z uvedeného lze vyvodit závěr, že doba ustálení není závislá na změně jízdního pruhu. Nicméně je třeba tento závěr potvrdit větším množstvím dat. Korelace doby ustálení pro změny jízdního pruhu vlevo a vpravo je hodnota 0,136. Tato hodnota vypovídá o nezávislosti mezi dobami ustálení pro různé směry. Při ověření síly testu pro výpočet korelace je hodnota testovacího kritéria 0.095. Tato malá hodnota odpovídá současně i malé důvěryhodnosti získaného výsledku korelace. Pro dosažení důvěryhodnosti korelace je třeba opakovaného ověření na větším vzorku dat. <sup>1</sup>

<sup>1</sup>Zdrojový kód je v sekci statistika\_R v zip souboru a na CD



## 8 Možnosti využití fuzzy logiky pro modelování chování řidiče

Tato kapitola je věnována k vydefinování oblastí aplikace fuzzy logiky při modelování a hodnocení chování řidiče. K nalezení řešení se jeví využití fuzzy přístupu jako zcela přirozená volba. Vychází to z požadavků při řízení vozidla, kdy se netočí volantem o přesnou hodnotu, ale „přiměřeně“ na základě zkušeností. Tento přístup tak přímo vybízí k využití možností fuzzy systémů, kde je zcela přirozené použití jazykových výrazů jako je např. malá, střední a velká změna polohy volantu. Současně to odpovídá i přirozenému pojetí pro lidského řidiče, který neuvažuje v přesných hodnotách, ale spíše v rozsazích otočení volantem.

### 8.1 Modelování a hodnocení řidiče pomocí fuzzy logiky v literatuře

Využití fuzzy logiky a regulátorů v oblasti řízení procesů, zejména jako alternativní varianta k tradičním regulátorům se stalo běžnou součástí aplikačních návrhů. Fuzzy systémy tak nepochybně patří mezi oblasti, kterým je věnována pozornost nejen v aplikovaném, ale i teoretickém výzkumu.

V monografii [45] jsou představeny směry ve vývoji, aplikacích inteligentních a adaptivních systémů. Publikace je zaměřena na výsledky výzkumu v oblasti identifikace a řízení systémů. Autoři v ní představují modely rekurentních neurofuzzy a fuzzy kognitivních sítí (FCN). Uvedené modely jsou vhodné pro použití v komplexních a časově proměnných systémech. Pro neurofuzzy adaptivní řízení jsou uváděny důkazy a odvození platnosti tvrzení, z nichž vyplývají doporučení pro volbu hyperparametrů představených algoritmů. V díle jsou ukázány koncepty systémů kombinující adaptivní fuzzy systémy a rekurentní neuronové sítě k dosažení velmi přesných aproximací, které lze dále použít pro adaptivní řízení. Všechny teoretické poznatky jsou představeny na úlohách zahrnující příklady z oblasti výroby energie, řízení komplexních procesů i ukázky řešení problémů s testováním adaptivního řízení. Ačkoliv se jedná o starší monografii (2014), jedná se o velmi názorný a popisný zdroj zahrnující fuzzy i neurofuzzy systémy.

Kromě použití fuzzy systémů při řízení, lze najít využití fuzzy logiky v oblasti expertních a pravidlových systémů jak je uvedeno například v Silerově knize [46]. Aplikace fuzzy logiky a inferenčního mechanismu společně s bázi pravidel je účelně zakomponována do řešení nejistot v případovém usuzování. Na expertní systémy lze mino jiné nahlížet také jako na pravidlové systémy a z tohoto pohledu jsou fuzzy sys-

témy určitým rozšířením tohoto paradigmatu o fuzzy množiny. Funkce příslušnosti z fuzzy systému umožňuje lépe pracovat se skrytými vazbami uvnitř pravidlového systému a dosažený výsledek zahrnuje i spolehlivost odpovědi danou odpovídající funkcí příslušnosti aktivovaného pravidla. Použití fuzzy množin v pravidlových systémech také umožňuje pohodlně řešit nejednoznačnosti či dokonce rozpory v datech a pracovat tak efektivně i s vágními pojmy.

Problematika použití metod fuzzy logiky pro hodnocení nebo modelování řídiče není v popředí výzkumu či vývoje a je tedy relativně málo zdrojů, které se na tento problém zaměřují. Následující odstavce popisují některé z nalezených a dostupných prací s touto problematikou.

Jeden z prvních článků týkajících se modelování řídiče za použití fuzzy logiky je Zeyadův článek [47]. Autoři v tomto článku představují návrh a realizaci modelu řídicího systému, který je schopen ovládat vozidlo podobně jako lidský řidič a napodobovat tak specifické lidské chování v řídicím procesu. Navržený model je vytvořen tak, aby byl schopen ovládat a řídit podélné i příčné pohyby vozidla na vozovce společně se změnami zrychlování a brzdění. Výsledný navržený model systému je prezentován a testován na simulátoru vozidla, který má integrovanou strategii aktivního řízení a přímého řízení změny směru vozidla, který byl také vyvinut v rámci řešení dané problematiky. Prezentované výsledky potvrdily úspěšnost navrženého systému při běžných činnostech, jako je sledování zatačky a vyhýbání se kolizím s náhodnými objekty.

Přístup, který se zaměřuje na analýzu, hodnocení a klasifikaci chování řidičů ukazuje Yonsiho článek [48], popisující návrh metodologie založené na fuzzy segmentování/shlukování, využitelné pro explorativní analýzu vícedimenzionálních dat/signálů. V tomto článku je navržená metodologie ukázána na příkladu analýzy chování řidiče při předjíždění jiného vozidla. Autoři článku se věnují využití histogramů četností naměřených hodnot a jejich předzpracování oknem různé velikosti pro následné provedení průměrování získaných hodnot. Průměry jsou dále použity k vytvoření funkcí příslušností, kde odpovídající fuzzy hodnoty jsou dále využity v metodě multi-correspondence analysis (MCA) a ve vizualizaci. Autoři prezentují metodu na příkladu obsahujícím vícerozměrná data získaná zaznamenáním informací pro 34 řidičů v 15 situacích předjíždění. V příkladu se pracuje s deseti sledovanými parametry jako jsou např. čas rozhodnutí k předjíždění, délce předjíždění, rychlosti akcelerace, rychlosti zařazení zpět do pruhu a další. Výsledkem je segmentace řidičů do skupin s charakteristickým způsobem předjíždění.

Hodnocení rozptýlení řidiče během jízdy, s využitím fuzzy přístupů zapojením modelů emocí u řidiče, je možné najít v Rizaově článku [49]. Autoři představují mo-

del kognitivního asistenta pro řidiče, tvořící systém prevence nehod s ohledem na různé typy rozptýlení řidiče. Navržený model je systémem založeným na zapouzdřeném systému Emotion Enabled Cognitive Driver Assistant (EECDA), který bere v potaz účinky vnějších faktorů na úroveň rozptýlení pozornosti řidiče. Autoři uvádějí, že jsou schopni algoritmicky generovat emoce strachu vycházející z pocitu nebezpečí takovým způsobem, že v okamžiku, kdy existující možné nebezpečí vyplývající z povahy situace překročí určitou definovanou hranici, systém vysílá řidiči dvě zvuková upozornění, aby došlo k akci řidiče omezující riziko nehody. Jádrem navrženého systému je kombinace fuzzy inferenčního systému typu Takagi–Sugeno, který je odpovědný za zpracování vstupních podnětů (pohyb očí, úhel natočení hlavy, rychlost a četnost pohybů či změny pohybu vozidla) a jejich vyhodnocení, vzhledem ke změně a úrovni pozornosti řidiče. Dalším důležitým prvkem je fuzzy regulátor, který přijímá jako vstupy nejen naměřené hodnoty jako je rychlost, vzdálenost a další, ale také úroveň pozornosti z předřazeného FIS. Rozhodnutí o provedení akce je následně prováděno samostatným rozhodovacím systémem.

Aplikace fuzzy přístupů lze najít v Daiově článku [50], který se zabývá asistentem pro podporu řízení vozidla v případě řízení bez mechanické vazby volant–kola. Práce se zaměřuje na zapojení modelu, tvořeného fuzzy systémem, který byl navržen tak, aby bral do úvahy charakteristiky řidiče. Navržený systém podpory řízení využívá fuzzy systému typu Takagi–Sugeno, na jehož vstup je přivedeno pět základních parametrů, které charakterizují řidiče při řízení vozidla. Je vytvářen model, který se snaží popsat složený systém řidič–vozidlo–silnice při průjezdu jízdním pruhem za předpokladu dobré viditelnosti. Fuzzy systém je použit pro elegantní zpracování nejistot ve vstupních datech, ale i ve zpětné vazbě. Při návrhu jsou brány v potaz také různé druhy časového zpoždění včetně kompenzace neuromuskulárního systému při zatáčení. Autoři do modelu zavádí fuzzy dynamický kompenzátor pro dosažení stabilizace systému.

Použití fuzzy logiky pro asistenční systémy vozidla patří mezi relativně často publikované přístupy. Vaskonez v článku [51] vytváří asistenční systém, který je zaměřen na zajištění bezpečného zastavení/zpomalení vozidla v případě vyhodnocení překročení stanovené hranice rizika pro pokračování v jízdě. Navržený bezpečnostní systém řízení je tvořen z několika částí. V první řadě se zpracovávají kognitivní parametry řidiče zahrnující věk, postavení hlavy, ospalost, kvalitu spánku/únavu, úroveň stresu, použití brýlí a další. Dalším subsystémem je sensorický systém obsahující analýzu scény a analýzu jízdy společně s parametry vozidla. Výstupy z těchto podsystémů jsou zpracovány pomocí fuzzy rozhodovacího systému a je vygenerován akční zásah pro zrychlení nebo brzdění pohonného systému vozidla. Navržený fuzzy rozhodovací systém je typu Mamdani s využitím trojúhelníkových a pí funkcí příslušnosti na vstupu, množina fuzzy pravidel obsahuje optimalizovaná pravidla zahrnující kogni-

tivní i senzorické vstupy a na výstupu je po defuzzifikaci získána optimální hodnota rychlosti vozidla.

Z uvedeného přehledu dostupných článků je patrné, že zejména v posledních pěti letech je využívání fuzzy systémů ve spojitosti s řízením vozidla zaměřeno především na vytváření asistenčních systémů do vozidel. Během tvorby této rešerše nebyly nalezeny články výhradně zaměřené na modelování či hodnocení chování řidiče, ale většinou se jednalo o demonstrační aplikaci fuzzy přístupu k řešení problémů z oblasti řízení vozidla. Z výše uvedeného tedy plyne, že modelování chování a hodnocení řidiče pomocí fuzzy systémů je potenciálně málo zkoumanou oblastí a naskýtá se zde příležitost pro návrh vlastních směrů dalšího výzkumu a vývoje.

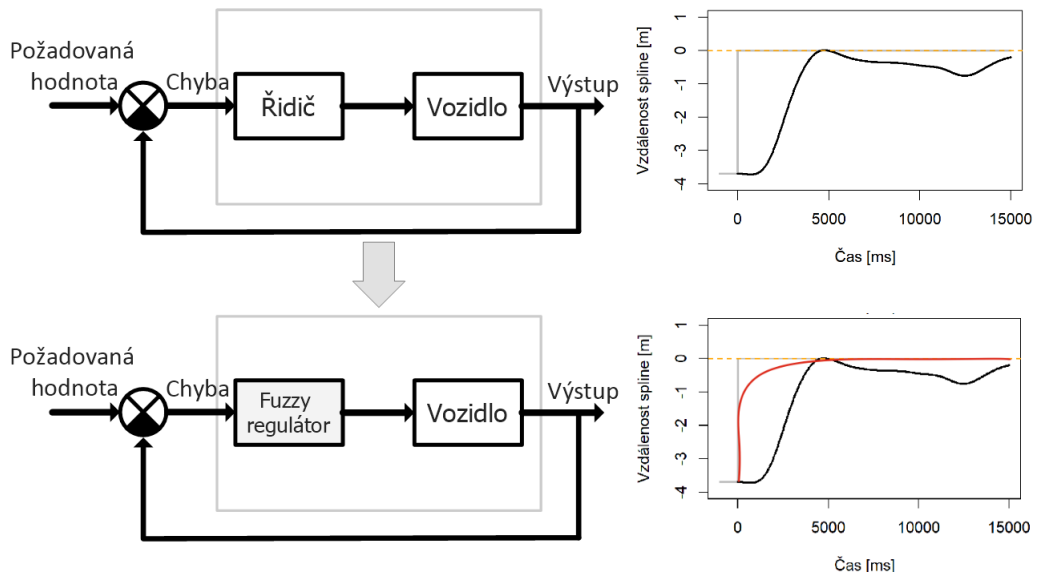
Pokud se zaměříme na práci s naměřenými daty ze simulátoru, můžeme uvažovat minimálně o třech základních přístupech, využívajících možností fuzzy systémů při modelování chování a hodnocení řidiče za volantem vozidla.

## 8.2 Nahrazení řidiče fuzzy regulátorem

Při řízení motorového vozidla je změna směru ovlivňována jeho řidičem. Z pohledu regulace se tedy na řidiče můžeme dívat jako na regulátor, který na základě podnětů, které dostává z jeho okolí, ovlivňuje natočení volantu, aby dosáhl požadovaného stavu řízení. Chování řidiče je ovlivněno velkým množstvím vnějších faktorů, které způsobují, že průběh řízení vozidla není často úplně optimální a je závislý na mnoha dalších okolnostech. Zjednodušený a ilustrativní pohled na řidiče v roli regulátoru a změny trajektorie vozidla je zobrazen v horní části obrázku 8.1.

Z průběhu křivky je patrné, že regulační průběh není v tomto případě zcela ideální. Můžeme zde vidět, že dosažení požadovaného ustáleného stavu, reprezentovaného čarou v hodnotě 0 na ose Y, není dosaženo ani po 15 sekundách od počátku změny směru. V okamžiku příchodu jednotkového skoku (simulujícího externí podnět), který je zobrazen šedou křivkou v grafu, je vidět počáteční zpoždění, které odpovídá součtu reakční doby řidiče a mechanickým vůlím systému vozidla. Průběh vlastní regulace tak zobrazuje jeho nedokonalost, a to zejména v nepřesném dosažení cílové pozice vozidla.

Pokud bychom chtěli uvažovat o zcela autonomním řízení, bylo by možné nahradit prvek řidiče (v tomto případě regulátoru) například fuzzy regulátorem. Při jeho použití se dá očekávat, že se dosáhne podstatného zlepšení regulačního průběhu, tak jak je zobrazeno ve spodní části obrázku 8.1.




Obr. 8.1: Zjednodušený model nahrazení řidiče fuzzy regulátorem

### 8.3 Hodnocení chování řidiče vůči optimální trajektorii

Další oblastí, ve které by šlo použít fuzzy systémy, je možnost hodnocení chování řidiče vůči optimální trajektorii, která je modelována pomocí fuzzy regulátoru. Při řízení vozidla se projevuje individuální charakteristika každého řidiče. Lze vypočítat rozdíly ve způsobu řízení, délce reakční doby a doby dosažení ustálení polohy vozidla, a to zejména v závislosti na směru, dále pak v závislosti na psychickém stavu řidiče, na jeho únavě, pohlaví, staří.

Možnou oblastí, kterou by se dalo zaobírat, je shlukování jednotlivých řidičů do skupin s podobnými vlastnostmi například podle jejich odchylek od ideálního průběhu, který by byl tvořen fuzzy regulátorem. Optimální dráha změny jízdního pruhu dosažená pomocí fuzzy regulátoru by mohla být porovnáována s křivkami získanými z průběhu řízení na simulátoru. Tato situace je názorně zobrazena na obrázku 8.2, kde se jedná pouze o ilustrační obrázek. Pojem optimální průběh regulace je velmi těžce definovatelný, protože může být ovlivněn různými požadavky, jako je například rychlost dosažení požadované hodnoty, tolerance překmitu a další.

Uvedeným postupem by došlo k rozdělení řidičů do skupin podle odchylek jejich strategie řízení od optimálního průběhu poskytovaném fuzzy regulátorem, jak bylo uváděno v kapitole 8.2.



Obr. 8.2: Nalezení rozdílu mezi optimálním a reálným průběhem regulace

## 8.4 Klasifikace řidičů s využitím fuzzy systémů

Alternativní metoda pro klasifikaci řidičů by mohla být založena na aproximaci průběhu reakce řidiče na jednotkový skok. Aproximace tohoto průběhu by pak byla realizována například pomocí fuzzy systému s co nejmenším počtem funkcí příslušnosti. Výsledná aproximace by se použila pro další metody při shlukování řidičů například založené na porovnání aproximačních funkcí a jejich parametrů. Do procesu shlukování by mohly dále vstupovat také další související parametry jako je doba změny polohy, doba ustálení a další. Při tomto přístupu by bylo výhodné využití lineárního modelu pro aproximaci pomocí Takagi–Sugeno fuzzy systému, který je relativně snadné vytvořit.

## 9 Experimentální část

Experimentální část této práce je zaměřena na využití fuzzy inferenčních systémů (FIS) k modelování jednotlivých řidičů a jejich následnému shlukování tak, jak je uvedeno v kapitole 8.3. V následujících kapitolách budou ověřeny následující hypotézy.

1. Reakci řidiče na jednotkový skok je možné modelovat pomocí fuzzy inferenčního systému s akceptovatelnou přesností.
2. Existuje podobnost mezi modely jednoho řidiče vytvořených pomocí FIS v různých časových odstupech při dodržení stejných vstupních podmínek.
3. Lze identifikovat skupiny řidičů modelovaných pomocí FIS s podobnými charakteristikami.

### 9.1 Modelování chování řidiče

První část experimentu se zaměřuje na samotné modelování řidiče. Byla použita data z osobního měření řidičů, kdy každý týden v určitý den proběhlo vlastní měření na čtyřech různých řidičích. Kapitola sestává ze dvou podkapitol, kde je snaha namodelovat chování řidiče pomocí fuzzy modelů Mamdani a Sugeno, typu 1. Oba tyto fuzzy modely se vytváří dvěma metodami.

1. Ručního ladění – s využitím designeru z toolboxu prostředí Matlab.
2. Optimalizační metody – optimalizace hyperparametrů fuzzy modelů za použití genetického algoritmu z Fuzzy toolboxu prostředí Matlab.

Pro testování, zda vůbec lze aproximovat pomocí fuzzy modelů chování řidiče, bylo užito průměru všech zatáček od všech měřených řidičů. To znamená, že výsledný průměr obsahoval zhruba 254 zatáček. Funkce příslušnosti se v této kapitole uvažovaly pouze trojúhelníkové a to zejména pro svou jednoduchost definice (počátek, střed a konec).

Ve všech případech jsou na vstup fuzzy modelu přivedeny průměrná originální data od řidičů, konkrétně vzdálenost od středu požadovaného jízdního pruhu (spline). Výstupem vytvořeného FIS je na výstupu úhel natočení volantu. Tímto postupem jsme schopni obdržet převodní charakteristiku mezi úhlem natočení volantu a vzdáleností od spline. Touto cestou dostáváme reálný model chování řidiče ve smyslu natočení volantu v závislosti na vzdálenosti od spline, bez zahrnutí řízené soustavy.

Vstupní data vykazovala chování, které nelze popsat funkční závislostí. Pro některé hodnoty vzdálenosti od spline, zejména v oblasti kolem nuly, byly pro stejnou vzdálenost od spline přiřazeny různé úhly natočení volantu. Tento problém lze chápat v souvislosti s lidským řidičem, kdy i přesto, že je dosaženo téměř nulové


odchyly dochází ke korekci směru, natočením volantu. Tento stav v datech se projevuje v modelech jako nepřesnost v aproximaci.

### 9.1.1 Použití fuzzy systému Mamdani

Při návrhu fuzzy systému typu Mamdani bylo zohledňováno, aby byl co nejjednodušší. To spočívá v omezení počtu funkcí příslušnosti, včetně pravidel. Bylo provedeno několik různých konfigurací nastavení fuzzy systému typu Mamdani, ale jako kompromis se nejlépe jevílo použít sedm funkcí příslušnosti na vstupu, sedm pravidel a na výstupu využít sedm funkcí příslušnosti.

#### Návrh FIS Mamdani pomocí ručního ladění

Při ručním návrhu fuzzy systému typu Mamdani docházelo ke značným obtížím, které se týkaly vlastního ladění. Při počtu sedmi funkcí příslušnosti na vstupu a výstupu v kombinaci s pravidly se lze dostat na velkou variabilitu, jak ovlivnit výslednou aproximaci. Počet sedmi funkcí příslušnosti byl zvolen experimentálně tak, aby se pokryla rovnoměrně celá převodní charakteristika. Výsledná chyba RMSE mezi skutečným a aproximovaným průběhem, které se podařilo reálně dosáhnout je  $166,25^\circ$  (dosažená aproximace je zobrazena na obrázku 9.1).



Obr. 9.1: Převodní charakteristika úhlu natočení volantu a vzdálenosti od spline

Přehled pravidel, která se aplikovala na výsledný model je v tabulce 9.1. Návrh pravidel byl minimalizován na 7 a tato pravidla byla zvolena experimentálně a na



základě zkušeností a intuice chování řidiče, ačkoliv doporučení z nápovědy k Fuzzy toolboxu na nastavení pravidel je kombinace všech lingvistických hodnot výstupních funkcí příslušnosti (49 pravidel).

Tab. 9.1: Užitá pravidla při tvorbě FIS Mamdani ruční ladění


	Antecedent	Konsekvent
1.	Spline je hodně blízko	Úhel volantu je udržuj směr
2.	Spline je docela blízko	Úhel volantu je trochu doprava
3.	Spline je málo blízko	Úhel volantu je více doprava
4.	Spline je přiměřeně blízko	Úhel volantu je hodně doprava
5.	Spline je málo daleko	Úhel volantu je přiměřeně doprava
6.	Spline je docela daleko	Úhel volantu je hodně doleva
7.	Spline je hodně daleko	Úhel volantu je středně doleva

Na obrázku 9.1 je zobrazena konkrétní převodní charakteristika úhlu natočení volantu na vzdálenosti od spline. Jak již bylo zmíněno dříve, ruční ladění fuzzy modelu typu Mamdani je velice složité, časově náročné a nepřesné. Naladění tohoto aproximovaného průběhu trvalo zhruba dvě hodiny a dosažená přesnost řešení se ani daleka neblíží originálnímu průběhu. Celkový čas strávený nad testováním ručního vytvoření FIS typu Mamdani, byl v řádu cca 20 hodin, kdy bylo třeba zvolit a otestovat počty funkcí příslušnosti a pravidel. Obrázek 9.2 ukazuje průběh otáčení volantu v čase. Chyba aproximace v převodní charakteristice se také promítá i do časové domény. Opět je zde dosaženo velice malé podobnosti mezi aproximací a originálním průběhem natočení volantu řidičem.


Přehled nastavení jednotlivých funkcí příslušnosti ukazuje obrázek 9.3. Jak je patrné z obrázku, není jednoduché správně nastavit funkce příslušnosti, a to i při relativně malém počtu pouze sedmi funkcí příslušnosti. Dle doporučení uváděných u Fuzzy toolboxu je úvodní nastavení funkcí příslušnosti (vstupních i výstupních) rovnoměrné rozložení v celém rozsahu osy x a s překrytím 50 %. Uvedené doporučení ani zdaleka nedosahuje takové přesnosti jako zde prezentované ruční nastavení. Detailní zobrazení pro funkce příslušnosti, které jsou přiřazeny k výstupu fuzzy modelu typu Mamdani, je na obrázku 9.4.

### Optimalizace FIS Mamdani

Vzhledem k obtížnosti nastavení FIS ručně jsou k dispozici v rámci Fuzzy toolboxu optimalizační metody pro ladění hyperparametrů FIS. Jedná se zejména o funkce *getTunableSettings*, *tunefisOptions*, *tunefis*. Pomocí funkce *getTunableSettings* se načítají potřebná data z předem vytvořeného FIS, který se bude v dalším kroku optimalizovat.




Obr. 9.2: Závislost otočení volantu na čase Mamdani ručně



Obr. 9.3: Funkce příslušnosti na vstupu FIS Mamdani ručně

Pro FIS typu Mamdani bylo počátečně nastaveno sedm funkcí příslušnosti na vstupu i výstupu, s překrytím mezi funkcemi 50 %. Pravidla byla nastavena každý s každým, tedy celkově 49 pravidel. Funkce *tunefisOptions* nám poslouží k nastavení parametrů optimalizace. Byly zde specifikovány parametry tak, že optimalizace je



Obr. 9.4: Funkce příslušnosti na výstupu FIS Mamdani ručně

typu „*Tuning*“ a maximální počet pravidel byl nastaven na 49. Taktéž v této funkci byla zvolena optimalizační metoda, a to genetický algoritmus. Posledními parametry jsou počet generací genetického algoritmu, který byl nastaven na 200 a velikost populace byla ponechána v základním nastavení 100.


Hlavní funkcí je *tunefis*, v rámci které probíhá vlastní optimalizace. Do této funkce se předává tzv. „*Cost function*“, která počítá chybu řešení (použita je RMSE) a algoritmus se snaží o její minimalizaci. Na základě její hodnoty se v rámci algoritmu upravuje fuzzy model. Výstupem *tunefis* je nový FIS model, který má již optimalizované parametry při minimalizované hodnotě RMSE.

Vzhledem ke složitosti optimalizačního problému, kdy je třeba navrhnout 42 parametrů jen pro funkce příslušnosti a dále vybrat odpovídající počet pravidel z možného počtu 49. Podle doporučení z nápovědy Fuzzy toolboxu je vhodné postupovat při optimalizaci ve dvou fázích.

První fáze provádí optimalizaci pravidel na výstupu FIS. Po nalezení nejlepšího řešení se pak pokračuje optimalizací vstupních a výstupních funkcí příslušnosti. Fuzzy systém umožňuje přiřadit ke každému pravidlu také jeho váhu, nicméně podpora optimalizace neobsahuje optimalizaci těchto vah. Proto jsou váhy u všech pravidel nastaveny na hodnotu jedna.


Obrázek 9.5 ukazuje příklad průběhu, jak klesá chyba v první fázi optimalizace a to pro jeden optimalizační cyklus. Chyba RMSE se s počtem generací snižuje a postupně klesá. V rámci genetického algoritmu je nastaveno ukončení optimalizace

na dosažení maximálního počtu 200 optimalizačních cyklů nebo v průběhu pěti po sobě následujících generací nedochází ke změně RMSE. V uvedeném příkladu se RMSE z počáteční hodnoty šest stupňů, po určitém čase sníží až na hodnotu 5,35 °.



Obr. 9.5: Průběh RMSE při optimalizaci pravidel FIS Mamdani


Po optimalizaci pravidel fuzzy modelu, následuje druhá fáze optimalizace a to optimalizace funkcí příslušností FIS. V tomto případě je z počáteční chyby RMSE 4,75 ° dosaženo na konci celého optimalizačního cyklu ustálené hodnoty RMSE 2,75 °. Viz obrázek 9.6 se zobrazením klesajícího průběhu chyby RMSE. Optimalizace byla přerušena u 192 generace z důvodu konstantní hodnoty RMSE.



Obr. 9.6: Průběh RMSE při optimalizaci funkcí příslušností FIS Mamdani

V rámci korektní aplikace optimalizace, je provedeno celkově 100 opakování optimalizace FIS. Teprve z tohoto množství získaných výsledků, kdy se pro každý

krok uchovávají nejlepší nalezené hyperparametry, se vybere výsledné optimální řešení. Boxplot na obrázku 9.7 zobrazuje rozložení nejlepších hodnot RMSE pro sto opakování optimalizace pravidel modelu Mamdani.




Obr. 9.7: Rozložení hodnot RMSE pro sto opakování optimalizace pravidel

Boxplot na obrázku 9.8 zobrazuje rozložení nejlepších hodnot RMSE pro sto opakování optimalizace vstupních a výstupních funkcí příslušností modelu Mamdani. Dle očekávání je chyba RMSE po druhém kroku optimalizace funkcí příslušnosti menší než při optimalizaci pouze výstupních pravidel FIS.

S využitím optimalizačních metod se váže jeden problém a to je časová náročnost takového postupu. Vlastní provádění optimalizací bylo realizováno ve virtualizovaném prostředí Windows7 x64 na domácím NAS serveru obsahujícím čtyřjádrový procesor AMD RX-4121ND pracujícím na frekvenci 2.1 GHz se 48GB RAM a 10TB pevného disku s SSD cache. Pro virtuální systém byly vyhrazeny dvě fyzická jádra a celkem 12 GB RAM. Vzhledem k nedostupnosti toolboxu pro Matlab pro podporu paralelního zpracování, byly optimalizace prováděny pouze na jednom přiděleném jádru. Celková doba optimalizace se vzhledem k 100 opakování protáhla na celkem 33,5 hodiny strojového času, ve kterém bylo provedeno vyhodnocení více než 4 milionů variant hyperparametrů.

Výsledkem provedené optimalizace je tedy FIS, který má nejmenší globální hodnotu RMSE. Na následujících obrázcích jsou graficky zobrazeny převodní charakteristiky (obrázky 9.9, 9.10) a charakteristiky v časové doméně (obrázky 9.11, 9.12)



Obr. 9.8: Rozložení hodnot RMSE pro sto opakování optimalizace funkcí příslušnosti

pro optimalizovaný FIS a porovnány s originálním průměrným průběhem získaným z měření na simulátoru, pro obě fáze optimalizace.


Zobrazení průběhů pro nejhorší výsledky optimalizace (největší dosažená hodnota RMSE) je součástí přílohy A. FIS s největší chybou v rámci optimalizace dosahují lepších výsledků než ladění prováděná ručně. Ruční ladění systému i této relativně malé složitosti při jedné vstupní a jedné výstupní proměnné je v podstatě nereálné pokud chceme dosáhnout vysoké míry aproximace.

Získaný optimalizovaný FIS obsahuje následujících 7 pravidel (tabulka 9.2), která byla nalezena v rámci první fáze optimalizace. Tato pravidla vedla po optimalizaci pravidel k nejmenší chybě RMSE. Optimalizace vycházela ze všech 49 kombinací. Detailní pohled na optimalizované nastavení funkcí příslušnosti jak na vstupu, tak na výstupu je ukázáno na obrázcích 9.13 a 9.14.


### 9.1.2 Použití fuzzy systému Sugeno

Vzhledem k vysokému počtu hyperparametrů potřebných k nastavení fuzzy systémů typu Mamdani pro aproximaci průběhu změny otočení volantem, se jako často používaná alternativa, která je schopna aproximovat průběh převodní charakteristiky, jeví fuzzy systém typu Sugeno. Detailní popis tohoto systému lze nalézt v kapitole 5.0.2.

Využití fuzzy systému typu Sugeno ulehčí práci s ručním laděním díky relativně málo nutných hyperparametrů a i celkové pochopitelnosti systému. Fuzzy systém je




Obr. 9.9: Převodní charakteristika po optimalizaci pravidel




Obr. 9.10: Převodní charakteristika po optimalizaci funkcí příslušnosti

schopen aproximovat průběh s využitím pouze vstupních funkcí příslušnosti v kombinaci s lineárními funkcemi na výstupu. Výstupní pravidla systému jsou velmi jednoduchého tvaru, kdy antecedent obsahuje pouze vyhodnocení náležitosti vstupní hodnoty do rozsahu platnosti funkce příslušnosti a konsekvent přiřazuje tomuto




Obr. 9.11: Natočení volantu v čase po optimalizaci pravidel




Obr. 9.12: Natočení volantu v čase po optimalizaci funkcí příslušnosti

vstupu právě jednu lineární funkci. Lineární funkce jsou vytvářeny na základě lineárního aproximovaného průběhu a jejich tvorba je víceméně intuitivní záležitostí.





Obr. 9.13: Nastavení vstupních funkcí příslušnosti po jejich optimalizaci



Obr. 9.14: Nastavení výstupních funkcí příslušnosti po jejich optimalizaci

### Ruční ladění fuzzy systému Sugeno

Ruční ladění modelu při užití Sugeno fuzzy systému představovalo jednodušší práci, protože bylo možné ladit pouze překrytí a posun funkcí příslušnosti na vstupu. Pravidla jsou pevně daná a na výstupu každého pravidla je právě jeden funkční předpis

Tab. 9.2: Pravidla FIS Mamdani získaná z první fáze optimalizace

	Antecedent	Konsekvent
1.	Spline je hodně blízko	Úhel volantu je udržuj směr
2.	Spline je docela blízko	Úhel volantu je trochu doprava
3.	Spline je málo daleko	Úhel volantu je hodně doprava
4.	Spline je přiměřeně blízko	Úhel volantu je mírně doleva
5.	Spline je středně blízko	Úhel volantu je udržuj směr
6.	Spline je středně daleko	Úhel volantu je mírně doprava
7.	Spline je hodně daleko	Úhel volantu je středně doprava

přímky. Tyto předpisy přímek se získaly z průměrného modelu průběhu převodní charakteristiky od všech řidičů. V rámci testování ladění FIS bylo jako nevýhodnější počet přímek popisujících vstupní charakteristiku zvoleno pět výstupních přímek a pět vstupních funkcí příslušnosti. Pravidlem uplatňovaným při využití Sugeno FIS je minimalizovat počet funkcí příslušnosti, a tím dosáhnout co nejmenší komplexnosti navrhovaného systému při zachování požadované přesnosti aproximace. Finální nejmenší chyba RMSE po ručním ladění vyšla s hodnotou 10,15 °.

Ačkoliv dle obrázku 9.15 vypadají oba průběhy (originální i aproximovaný) velmi podobně, jak již bylo zmíněno v kapitole při použití systému Mamdani, problém způsobují hodnoty v oblasti, kde se řidič pohybuje v okolí nulové odchylky od požadovaného stavu (vzdálenosti od spline). Tabulka 9.3 ukazuje všechna pravidla použitá při ruční tvorbě FIS typu Sugeno a vychází z obecně platných doporučení. Co se týká časové náročnosti ručního ladění fuzzy modelu, pro dosažení uvedené hodnoty RMSE je doba potřebná pro naladění modelu kolem jedné a půl hodiny práce.

Tab. 9.3: Užitá pravidla při tvorbě FIS Sugeno při ručním ladění


Antecedent	Konsekvent
Spline leží v mf1	Wheel_angle leží na line1
Spline leží v mf2	Wheel_angle leží na line2
Spline leží v mf3	Wheel_angle leží na line3
Spline leží v mf4	Wheel_angle leží na line4
Spline leží v mf5	Wheel_angle leží na line5

Pro demonstraci, zda lze touto metodou aproximovat hodnoty, a tím získat fuzzy model řidiče pomocí FIS typu Sugeno, byly zvoleny následující předpisy přímek, které byly získány z obrázku 9.16. Jedná se o lineární předpisy přímek představující linearizaci aproximované funkce s požadavkem na jejich překrytí. Na tomto obrázku jsou pro lepší představu vyznačeny jednotlivé přímky a zároveň i demonstrace, že

Tab. 9.4: Předpisy přímek použitých v konsekventu pravidel FIS Sugeno

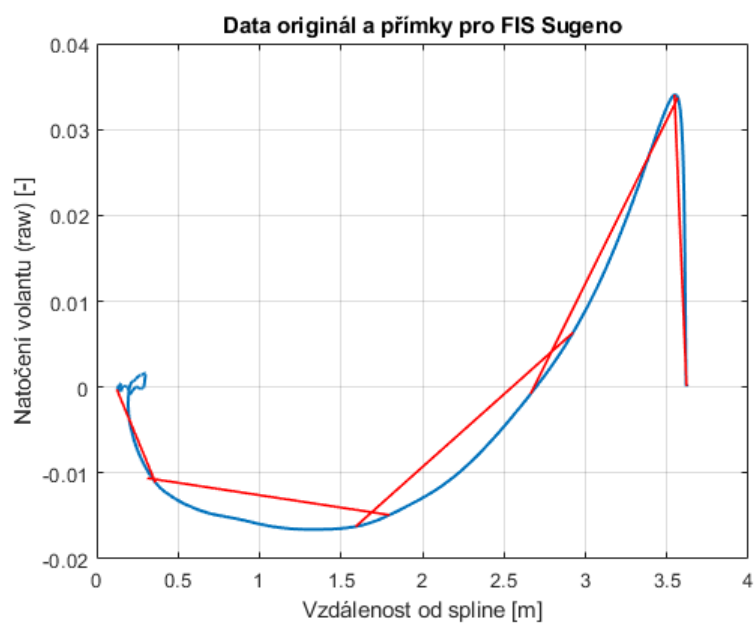
	funkce
line1	natočení volantu = $-0,0457 \cdot spline + 0,0054$
line2	natočení volantu = $-0,0029 \cdot spline - 0,0097$
line3	natočení volantu = $0,0169 \cdot spline - 0,0431$
line4	natočení volantu = $0,0382 \cdot spline - 0,1024$
line5	natočení volantu = $-0,4613 \cdot spline - 1,6700$

pouhým tímto rozložením přímek a využití fuzzy systému lze aproximovat i ne zcela triviální průběh funkce.




Obr. 9.15: Převodní charakteristika úhlu natočení volantu Sugeno ručně


Obrázek 9.17 představuje finální podobu naladěného fuzzy systému typu Sugeno, který ze vstupu, na kterém je průměr průběhu vzdálenosti od spline, na výstupu poskytne úhel otočení volantu v čase. Bohužel, od času zhruba čtyř sekund dochází k nepřesné aproximaci, a to z důvodu, že k jedné hodnotě vzdálenosti od spline, je přiřazeno více hodnot úhlu natočení volantu a fuzzy systém Sugeno s tím v dané konfiguraci nedokáže poradit a bylo by třeba zvýšit počet funkcí příslušnosti systému pro dosažení lepšího průběhu aproximace. Pro hrubou aproximaci to však lze být dostačující vzhledem k poměru doby ručního ladění a dosažené přesnosti. Nastavení funkcí příslušností jsou zobrazeny na obrázku 9.18.



Obr. 9.16: Zvolení přímek pro aproximaci FIS Sugeno



Obr. 9.17: Závislost otočení volantu na čase Sugeno ručně



Obr. 9.18: Funkce příslušnosti na vstupu FIS Sugeno ručně


### Optimalizace fuzzy systému Sugeno pomocí genetického algoritmu

Stejně jako v předchozím případě použití systému Mamdani, byla ověřena možnost optimalizace FIS typu Sugeno, která je zahrnuta přímo ve Fuzzy toolboxu prostředí Matlab. Optimalizovat se bude převodová charakteristika, která vznikla průměrováním naměřených dat od řidičů. Naším cílem je tedy co nejlépe aproximovat úhel natočení volantu pro danou vzdálenost od středu požadovaného jízdního pruhu.

Vzhledem k tomu, že vycházíme ze stejných předpokladů jako u ručního ladění FIS Sugeno, je počet vstupních funkcí příslušnosti nastaven na stejnou hodnotu pět a také jsou použita stejná výchozí pravidla a lineárními funkce v konsekventu. Nastavení optimalizačních parametrů je zvoleno podle doporučených hodnot a to 200 generací, velikost populace v generaci je 100 a je provedeno celkem 100 optimalizačních cyklů. Použitý hardware je stejný, jak je popsáno v kapitole 9.1.1 s optimalizací FIS typu Mamdani.


Celková doba optimalizace byla v tomto případě kratší a činila celkem 10,25 hodiny. Kratší doba optimalizace vychází z toho, že je prováděn pouze jeden typ optimalizace, a to vstupních funkcí příslušnosti. Současně se na kratší době optimalizace podílela i skutečnost, že je menší stavový prostor hyperparametrů, kterých je celkem 15 hodnot (pro každou funkci příslušnosti se hledají tři parametry).

Obrázek 9.19 zobrazuje klesající průběh chyby RMSE při optimalizaci. V tomto konkrétním případě byla ukončena optimalizace při dosažení 118 generace, jelikož nedošlo ke změně RMSE v předchozích několika generacích.




Obr. 9.19: Průběh RMSE při optimalizaci funkcí příslušnosti FIS Sugeno

Pro získání vypovídající hodnoty průběhu optimalizace je prováděno celkem 100 opakovaných optimalizací. Výsledné rozložení hodnoty RMSE z těchto sto opakování je zachyceno v boxplotu na obrázku 9.20. Nejlepší dosažená hodnota RMSE je 3,42 °.



Obr. 9.20: Rozložení RMSE pro sto opakování optimalizace funkcí příslušnosti

Výstupní lineární funkce, které tvoří předpisy přímek a jsou součástí konsekvntu jsou zobrazeny na obrázku 9.21. Tyto lineární funkce byly vytvořeny při ručním ladění FIS Sugeno a byly použity i při optimalizaci pomocí genetického algoritmu.




Obr. 9.21: Výstupní lineární funkce FIS Sugeno

Optimalizované vstupní funkce příslušnosti jsou zobrazeny na obrázku 9.22. Pokud porovnáme nastavení vstupních funkcí příslušnosti vytvořených ručním laděním a pomocí optimalizace, lze konstatovat, že se nastavení funkcí o moc neliší, čímž lze říci, že ruční ladění FIS bylo provedeno relativně přesně.


Na posledních dvou obrázcích 9.23 a 9.24 jsou zobrazeny charakteristiky srovnávající originální průběh a průběh aproximovaný, získaný jako výstup optimalizovaného FIS typu Sugeno. Oba obrázky ukazují, že provedená optimalizace dosahuje lepších výsledků než optimalizace ruční. V příloze B jsou zobrazeny aproximace s nejhorším RMSE.

### 9.1.3 Použitelnost FIS při aproximaci charakteristiky

Vzhledem k získaným výsledkům, při kterých byla ověřována možnost využití aproximace převodové charakteristiky mezi vzdáleností od středu požadovaného jízdního pruhu a úhlem natočení volantu, lze konstatovat, že použitím FIS typu Sugeno lze dosáhnout přiměřené míry přesnosti při aproximaci. Využití optimalizačních metod se jeví jako jediné použitelné řešení, byť v tomto konkrétním případě bylo dosaženo korektní aproximace i pomocí ručního ladění. Laděním FIS ručním způsobem bylo




Obr. 9.22: Nastavení vstupních funkcí příslušnosti po optimalizaci



Obr. 9.23: Převodová charakteristika po optimalizaci funkcí příslušnosti

dosaženo RMSE 10,15 ° a při využití optimalizace byla dosažená hodnota RMSE aproximace 3,42 °, což odpovídá téměř trojnásobnému zlepšení přesnosti aproximace. Součástí experimentu bylo i použití FIS typu Mamdani, nicméně v tomto případě byla při ručním ladění dosažena hodnota RMSE 166,25 °, jež odpovídá téměř 16 krát





Obr. 9.24: Natočení volantu v čase po optimalizaci funkcí příslušnosti

horšímu výsledku proti FIS typu Sugeno. Použití optimalizace modelu FIS dosáhlo chyby RMSE 2,75 °, což je lepší výsledek než u FIS Sugeno, nicméně optimalizace trvala téměř třikrát déle. Na základě uvedených faktů lze přijmout hypotézu, že fuzzy systémy typu Mamdani a Sugeno lze s úspěchem použít pro aproximaci (a tím vytvoření modelu s akceptovatelnou chybou) převodové charakteristiky při analýze dat chování systému řidič–vozidlo získaných ze simulátoru.<sup>1</sup>

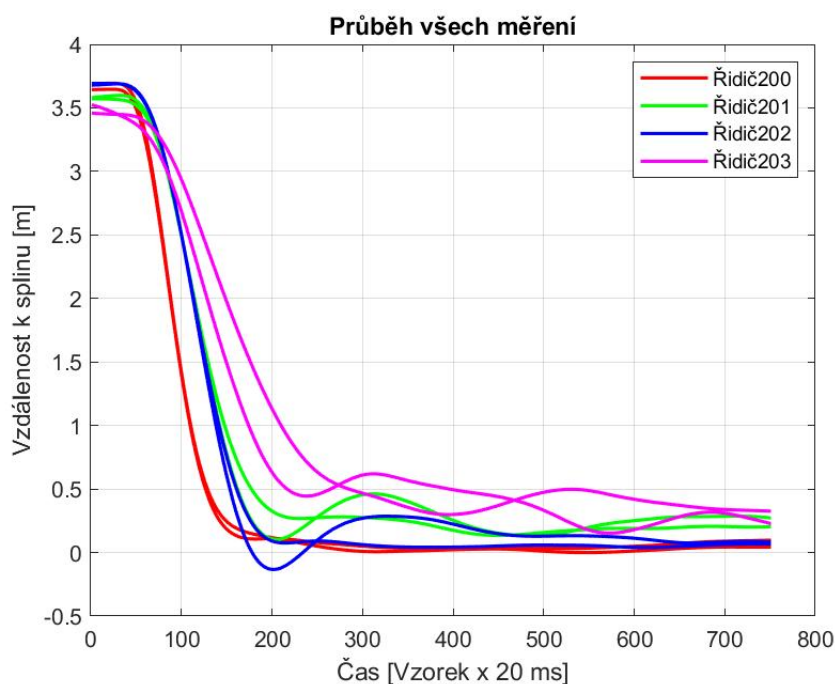
## 9.2 Podobnost FIS modelu řidiče s časovým odstupem

Za pomocí simulátoru vozidla jsme schopni získat data a následně i namodelovat chování řidiče pomocí fuzzy systémů tak, jak je popsáno v předchozí kapitole. Z dlouhodobého pohledu a pokročilých analýz je však také důležité zjistit, zda jsme schopni jednotlivé řidiče, a tím pádem i jejich modely rozlišit v průběhu času. Pokud bychom chtěli pouze zjistit podobnost mezi stylem jízdy jednoho řidiče s odstupem času, mohli bychom porovnat přímo naměřené hodnoty ze simulátoru, čímž bychom sice zjistili podobnost, ale nezískali model chování řidiče.

V této kapitole bude proveden experiment pro ověření hypotézy, že existuje podobnost chování řidičů, a tím pádem i jejich modelů vytvořených s časovým od-

<sup>1</sup>Zdrojový kód je v sekci Experiment 1 v zip souboru a na CD

stupem při zachování pokud možno stejných vstupních podmínek. Součástí tohoto experimentu je vytvoření fuzzy modelů typu Sugeno bez použití optimalizace. Modelování FIS je zaměřeno v tomto případě na aproximaci vzdálenosti od středu požadovaného jízdního pruhu. Tento přístup modeluje systém jako celek, tedy model zahrnuje komplexní systém řidič–regulovaná soustava. Získaný model systému lze akceptovat, jelikož je regulovaná soustava tvořena simulátorem, který nemění své vlastnosti a je tak jeho chování pro všechny řidiče a v průběhu času konstantní.




Obr. 9.25: Naměřená data pro čtyři řidiče po týdnu

V rámci experimentu byly získány záznamy měření od čtyř různých řidičů přibližně stejného věku 24 roků (řidič 200, řidič 201, řidič 202, řidič 203) ze dvou stejně dlouhých po sobě jdoucích jízd a stejné měření se pak následně opakovalo o týden později. Aby bylo zajištěno měření za stejných podmínek, probíhalo měření vždy ve stejný den (pondělí) a čas (cca 11:00). Dále před každým měřením měl řidič k dispozici dostatečný čas, přibližně 10 minut, aby se seznámil s prostředím simulátoru a zvykl si tak například na tuhost volantu.

Jelikož samotné měření trvá relativně dlouhou dobu, v našem případě jedna jízda trvala cca deset minut bez zahrnutí aklimatizace, jednalo se celkově o dost časově náročnou činnost. Tato časová náročnost společně s nutností opakování a neochotou dalších osob se experimentu zúčastnit, jsou hlavní příčinou malého počtu měřených řidičů.

Celkově jsou tedy zpracovávána data od čtyř řidičů, kde každý z nich má čtyři záznamy z testovací jízdy (dva v jedno dni a další dva za týden). Pro další zpracování měření jsou vždy dva průběhy z jednoho dne zprůměrovány (jedná se o všechny změny směru bez rozdílu levého a pravého odbočení). Ukázky jednotlivých průběhů měření jsou zobrazeny na obrázku 9.25. Již z tohoto obrázku je patrné, že chování řidiče je i s týdenním odstupem při zachování stejných podmínek téměř totožné.

Ze surových dat měření byly následně ručně vytvořeny fuzzy modely řidičů pro každý týden samostatně. Fuzzy model byl vytvořen typu Sugeno za použití co nejmenšího množství funkcí příslušnosti pro snadné ruční ladění modelu. Při zachování rozumné míry přesnosti aproximace bylo použito čtyř funkcí příslušnosti jako rozumný kompromis mezi přesností a složitostí ručního vytváření modelu. Dle obrázku 9.26 lze vypožorovat existenci určité podobnosti chování řidiče při opakovaném měření, obdobně jako u originálních dat z měření. Taktéž stojí za povšimnutí, že každý z řidičů (reprezentován jednou barvou) má svůj charakteristický styl jízdy.



Obr. 9.26: Fuzzy modely typu Sugeno pro dvě měření s týdenním odstupem

Ačkoliv je možné pomocí explorativní analýzy křivek fuzzy modelů chování řidiče identifikovat vzájemnou podobnost průběhů jednoho řidiče ve dvou různých časech měření a naopak vzájemnou nepodobnost řidičů mezi sebou, je třeba pro potvrzení či zamítnutí hypotézy zvolit objektivnější metodu.

Pro jednotlivé fuzzy modely řidičů bylo provedeno vzájemné porovnání mezi

sebou s výpočtem hodnoty RMSE, zachycující jejich vzájemnou podobnost. Na obrázku 9.27 jsou zobrazeny vzájemné hodnoty RMSE mezi fuzzy modely.

	200_1	200_2	201_1	201_2	202_1	202_2	203_1	203_2
200_1		1,69	8,94	9,70	8,26	8,12	24,64	15,43
200_2	1,69		9,88	10,92	9,39	9,09	25,29	16,30
201_1	8,94	9,88		3,27	4,79	5,03	16,22	6,95
201_2	9,70	10,92	3,27		3,58	4,47	17,07	7,76
202_1	8,26	9,39	4,79	3,58		2,14	19,31	10,28
202_2	8,12	9,09	5,03	4,47	2,14		19,12	10,57
203_1	24,64	25,29	16,22	17,07	19,31	19,12		10,54
203_2	15,43	16,30	6,95	7,76	10,28	10,57	10,54	


Obr. 9.27: Porovnání RMSE jednotlivých fuzzy modelů

Pro lepší orientaci je na obrázku zvolena barevná škála, která menší hodnoty RMSE (křivky jsou si více podobné) zobrazuje zelenou barvou a vysoké hodnoty RMSE (křivky jsou málo podobné) pak barvou červenou. Diagonála tabulky je prázdná, jelikož porovnání křivky se sebou samou není v požadovaném kontextu zajímavou informací. Z tabulky plyne, že nejmenší hodnoty RMSE (největší podobnost) mají právě křivky patřící jednomu řidiči.

Označení v záhlaví a řádku tabulky značí číslo řidiče a za podtržítkem je pak číslo měření (1 – první měření, 2 – opakované měření po týdnu). Jediný nesoulad lze pozorovat u hodnot RMSE u druhého měření řidiče 203, označeného 203\_2. Ačkoliv je hodnota RMSE mezi prvním (203\_1) a druhým (203\_2) měřením opět nejmenší, druhé měření vykazuje menší chybu RMSE s řidičem číslo 201. K řidiči číslo 203 je třeba poznamenat, že ačkoliv ostatní řidiči jsou dle jejich vyjádření častými uživateli vozidla a praváci, řidič 203 v podstatě od autoškoly vozidlo neřídí a je levák. Toto je částečně i vidět v křivkách na obrázku 9.25.

Velmi dobrou podobnost při řízení u jednoho řidiče při týdenním odstupu lze ilustrovat na obrázku 9.28. Přestože je mezi daty použitými pro vytvoření dvou fuzzy modelů týdenní rozdíl, zdrojová data i jejich fuzzy modely jsou téměř totožné. Chyba RMSE fuzzy modelů s odstupem týdne činí pouze 1,69 m.

Přesnost modelování chování systému řidič–vozidlo je zobrazena na následujících obrázcích. Zvolený minimální počet funkcí příslušnosti přinesl výsledky s relativně malou chybou aproximace průběhů. Detailní pohled na fuzzy modely prvního řidiče je na obrázku 9.28, kde se podařilo nejlépe aproximovat originální průběh z obou týdňů měření. Ostatní fuzzy modely a jejich průběhy jsou k dispozici v příloze C.



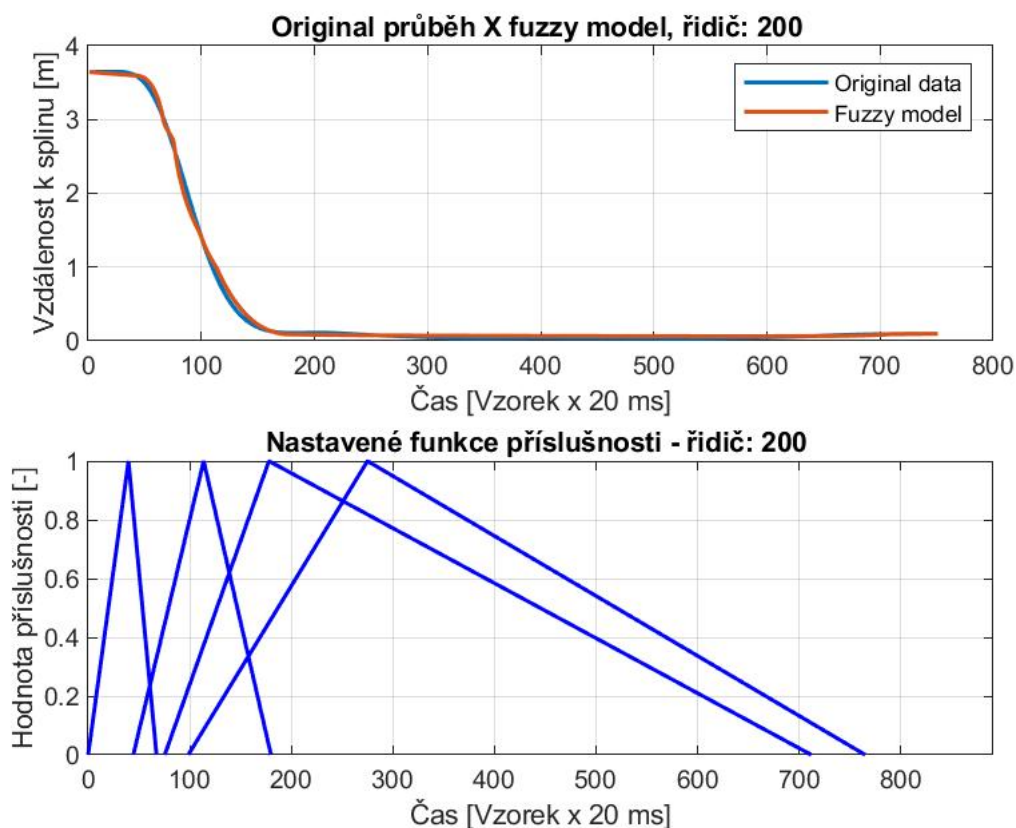
Obr. 9.28: Detailní pohled fuzzy modelů od prvního řidiče po týdnu

Na obrázku 9.29 je detail, jak se podařilo pomocí fuzzy modelu typu Sugeno aproximovat originální naměřený průběh pro řidiče číslo 200. Obrázek dále ukazuje v jeho dolní části nastavení jednotlivých funkcí příslušnosti. Celkový počet pravidel pro model je čtyři. Při vytváření fuzzy modelu bylo také použito kromě nastavení vstupních funkcí příslušnosti i úpravy vah všech pravidel FIS. Hodnota váhy je v rozmezí 0–1, kde 0 představuje úplné ignorování pravidla. Nastavené hodnoty vah pro řidiče 200 jsou v následující tabulce 9.5:

Tab. 9.5: Hodnoty vah u pravidel FIS pro řidiče 200

Pravidlo	Váha
Pravidlo 1	0,35
Pravidlo 2	0,42
Pravidlo 3	0,7
Pravidlo 4	1

Fuzzy model pro řidiče 203 a nastavení funkcí příslušnosti je na obrázku 9.30. Nastavení hodnot vah jednotlivých pravidel pro řidiče 203 je uvedeno v tabulce 9.6.



Obr. 9.29: Fuzzy model řidiče 200 a funkce příslušnosti

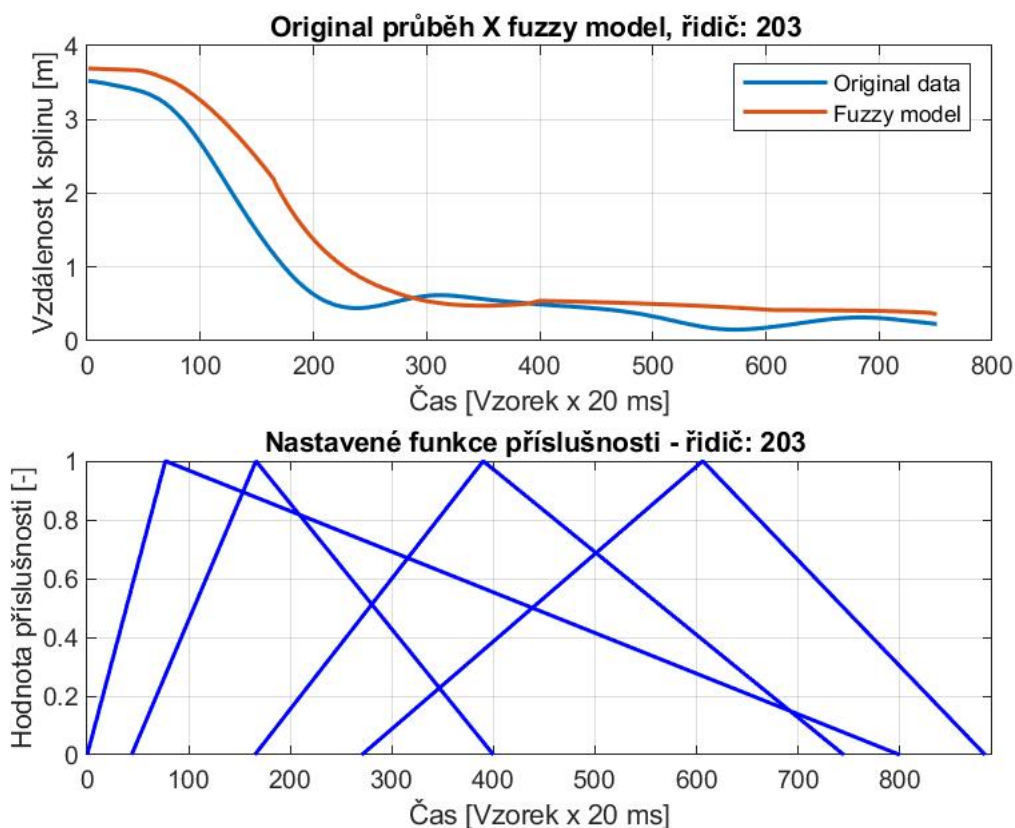
Tab. 9.6: Hodnoty vah u pravidel FIS pro řidiče 203

Pravidlo	Váha
Pravidlo 1	0,30
Pravidlo 2	0,20
Pravidlo 3	1,00
Pravidlo 4	0,45

### 9.2.1 Zhodnocení podobnosti FIS s časovým odstupem

Potvrzení nebo zamítnutí hypotézy o tom, že i při delším časovém období mezi měřeními pro jednoho řidiče, existuje silná podobnost v řídicovém chování, se nepodařilo statisticky významně prokázat. Je to zejména způsobeno malým množstvím řidičů, jejichž měření se podílely na výsledcích tohoto experimentu. Ačkoliv se dala identifikovat v datech i vytvořených fuzzy systémech podobnost chování jednotlivých řidičů, nelze s jistotou prokázat či vyvrátit vyřčenou hypotézu.

Je samozřejmé, že odlišnosti v chování jednoho řidiče v delším časovém intervalu



Obr. 9.30: Fuzzy model řidiče 203 a funkce příslušnosti

mohou nastat například únavou, špatným spánkem, stresem, vnějším prostředím a i v neposlední řadě nedostatečnou aklimatizací na simulátor. Je tedy třeba v budoucnu použít větší množství řidičů a různých časových intervalů mezi měřeními, k získání relevantních a spolehlivých výsledků.<sup>2</sup>

### 9.3 Shlukování řidičů na základě jejich fuzzy modelu

V této kapitole bude proveden experiment, jehož cílem bude potvrzení či vyvrácení hypotézy, že parametry fuzzy inferenčního systému typu Sugeno lze využít pro nalezení skupin řidičů a charakteristických průběhů změny úhlu natočení volantu. Jednou z výhod tohoto přístupu je, že jsme schopni zmenšit dimenzi analyzovaných dat.

Při ověření platnosti této hypotézy vycházíme z potvrzené hypotézy z kapitoly 9.1, že pomocí fuzzy systému lze modelovat chování řidiče (úhel natočení volantu v

<sup>2</sup>Zdrojový kód je v sekci Experiment 2 v zip souboru a na CD

závislosti na vzdálenosti od středu požadovaného jízdního pruhu).

V rámci analýz budeme pracovat s datovou sadou 38 řidičů, kteří se v roce 2021 zúčastnili akce Noc vědců na fakultě Elektrotechniky a Komunikačních technologií VUT v Brně. Těchto 38 osob si vyzkoušelo řízení simulátoru ve zkrácené verzi simulace trvající přibližně 3 minuty. V rámci tohoto časového intervalu provedli každý z nich kolem sedmi změn jízdního pruhu. Doplňkové informace o jednotlivých řidičích jako je věk, pohlaví, zkušenost s řízením, vlastnictví řidičského průkazu, aktuální psychický stav nejsou k dispozici. Taktéž nebyla před vlastním průběhem simulace provedena žádná trénovací jízda pro seznámení se s chováním simulátoru.

Celý průběh experimentu lze rozdělit do několika samostatných částí.

1. Vytvoření fuzzy modelů typu Sugeno pro každého řidiče.
2. Provedení shlukové analýzy nad parametry fuzzy modelu všech řidičů.
3. Shluková analýza nad změřenými daty všech řidičů.
4. Porovnání získaných výsledků a zhodnocení experimentu.

### 9.3.1 Vytvoření fuzzy modelů pro 38 řidičů


Z důvodu celkově menší složitosti systémů typu Sugeno je tento typ FIS jasnou volbou pro ověření hypotézy. Při vytvoření modelu pro každého řidiče samostatně, budeme postupovat v podstatě obdobným způsobem tak, jak je uvedeno v kapitole 9.1.2. Nicméně vzhledem k tomu, že optimalizační metody v Fuzzy toolboxu Matlabu neobsahují optimalizace vah výstupních pravidel, padla volba na vytvoření vlastního optimalizátoru, který nám umožní optimalizovat kromě nastavení vstupních funkcí příslušnosti také váhy výstupních pravidel.

Na následujícím obrázku 9.31 je zobrazen průběh změny natočení volantu simulátoru v čase pro všechny řidiče. Již letným pohledem je patrné, že variabilita naměřených hodnot je opravdu vysoká.

Pro získání představy o průměrné změně úhlu natočení volantu v čase, přes všechny řidiče, byl vytvořen obrázek 9.32. V příloze D na obrázku D.1 je zobrazen průběh vzdálenosti od středu požadovaného jízdního pruhu pro všechny řidiče a také jeho průměrná hodnota (obrázek D.2).

Protože pracujeme s FIS Sugeno, musíme získat tolik výstupních lineárních funkcí, kolik máme výstupních pravidel. Tak jako ve všech předchozích případech, tak i v tomto se snažíme o minimalizaci počtu pravidel. Výstupní lineární funkce byly vytvořeny podle převodové charakteristiky na obrázku 9.33, zobrazující vztah mezi vzdáleností od spline a úhlem natočení volantu. Červené čáry v grafu představují pět lineárních funkcí použitých jako konsekventy pravidel fuzzy systému.





Obr. 9.31: Vzdálenost od spline v čase pro všechny řidiče


### Průběh optimalizace FIS

Pro každého řidiče byl vytvořen FIS typu Sugeno s pěti vstupními trojúhelníkovými funkcemi příslušnosti, pěti výstupními pravidly. Váhy u všech pravidel byly nastaveny na hodnotu jedna. Tak, jak bylo již popsáno v předchozích odstavcích, pro zamýšlené použití nelze použít optimalizační metody přímo z toolboxu Matlabu, byla tedy zvolena a naprogramována alternativní metoda, která nám umožňuje optimalizovat také váhy jednotlivých pravidel.

Z důvodu relativně snadné implementace a množství ilustrativních příkladů byla zvolena jako optimalizační metoda Particle Swarm Optimization (PSO). Detailní popis metody PSO lze nalézt například v knize [52]. Implementace optimalizačního algoritmu v Matlabu obsahuje kód z [53], který je upraven pro potřeby vycházející z jeho použití pro optimalizaci FIS (limity generování pozice částic v prohledávaném prostoru). Využití implementace v Matlabu umožňuje upravit chování algoritmu dle požadavku optimalizace, přestože je tak dosaženo nižší rychlosti provádění, nicméně v použitém experimentu není toto limitujícím faktorem.

Vytváření optimalizovaných FIS probíhalo ve dvou krocích:

1. Optimalizace nastavení vstupních funkcí příslušnosti.
2. Optimalizace vah výstupních pravidel.




Obr. 9.32: Průměrné otočení volantem - všichni řidiči

Nastavení algoritmu PSO bylo provedeno tak, že maximální počet iterací byl stanoven na 1000 a velikost populace byla nastavena na 100 jedinců. Pro získání relevantních výsledků byla každá optimalizace opakována desetkrát. Tímto způsobem byla provedena napřed optimalizace funkcí příslušnosti a po nalezení nejlepšího výsledku (nejmenší hodnoty RMSE) z deseti opakování (běhů), pak následovala obdobným způsobem i optimalizace vah výstupních funkcí.

Vzhledem k množství dat a počtu iterací byla optimalizace FIS pro každého řidiče prováděna na výpočetní serveru s následujícími parametry:

- 2x CPU Intel Xeon E5-2680v2 na základní frekvenci 2,8 GHz
- Celkově 20 jader / 40 vláken.
- 768 GB RAM.
- Úložiště 12 TB.
- Matlab R2020a

Použití toolboxu Matlabu pro paralelní zpracování, umožnilo podstatně zrychlit získání výsledků ve srovnání s předchozími experimenty prováděnými na domácím NAS serveru ve virtualizovaném prostředí. Celková doba potřebná k provedení všech optimalizací byla přibližně 16 hodin a 32 minut. Server nebyl pouze vyhrazen pro provádění skriptů tohoto experimentu, bylo mu přiděleno pouze 6 jader, proto nebylo dosaženo kratší doby zpracování všech optimalizací.



Obr. 9.33: Nastavení předpisů přímek na výstupu FIS

Samotná optimalizace byla řešena takovým způsobem, že algoritmus PSO generoval v prvním kroku celkem 15 (pět trojúhelníkových funkcí příslušnosti a každá je definována třemi hodnotami) hodnot v intervalu  $\langle 0; 1 \rangle$  pro každého jedince v populaci. Následně se ve fitness funkci tyto hodnoty převedly na rozsah platný pro hodnoty vzdálenosti od spline a byl proveden výpočet chyby RMSE dané konfigurace FIS. Každá iterace algoritmu uložila nejlepší konfiguraci nastavení parametrů FIS pro další zpracování. Pro každý z deseti běhů optimalizace byla uložena nejlepší konfigurace (s nejmenším RMSE) z tisíce provedených iterací v rámci běhu.

Po provedení každého běhu optimalizace vstupních funkcí příslušnosti byla následně spuštěna optimalizace vah nejlepšího řešení z běhu. Výsledkem deseti běhů optimalizace vah je opět sada deseti nejlepších konfigurací (každá konfigurace je tvořena pěti hodnotami vah pravidel v rozsahu  $\langle 0; 1 \rangle$ ), které společně s odpovídající konfigurací nastavení vstupních funkcí příslušnosti definují FIS Sugeno.

Z množiny deseti nejlepších konfigurací (vzniklých z deseti běhů), je vytvořena finální datová sada pro další zpracování. Tato datová sada je tvořena celkově 20 atributy v rozsahu  $\langle 0; 1 \rangle$  pro každého z 38 řidičů. Prvních 15 atributů je nastavení trojúhelníkových funkcí příslušnosti a dalších pět atributů jsou váhy výstupních pravidel.

## Převod pozice částice na funkci příslušnosti

Implementace optimalizace FIS typu Sugeno je pomocí algoritmu Particle Swarm Optimization relativně snadná záležitost. Lze použít implementaci přímo v prostředí Matlab, která je rychlejší, případně se pokusit implementovat algoritmus PSO podle mnoha zdrojů jako je ten, ze kterého bylo vycházeno v této práci. [53] Uvedenou implementaci nelze použít pro optimalizaci funkcí příslušnosti FIS přímo, ale je třeba provést úpravy kódu tak, aby vyhovoval danému použití.

Při optimalizaci je třeba se zaměřit na specifika použití, v tomto případě se jedná o vygenerování vektoru hodnot sloužících k popisu vstupních funkcí příslušnosti. V algoritmu PSO se generuje vektor pozice částice z náhodně generovaných složek a v rámci generací dochází ke změně polohy částice v  $n$ -rozměrném prostoru podle směru a rychlosti pohybu. To vede v obecném případě ke konvergenci do víceméně optimálního řešení.

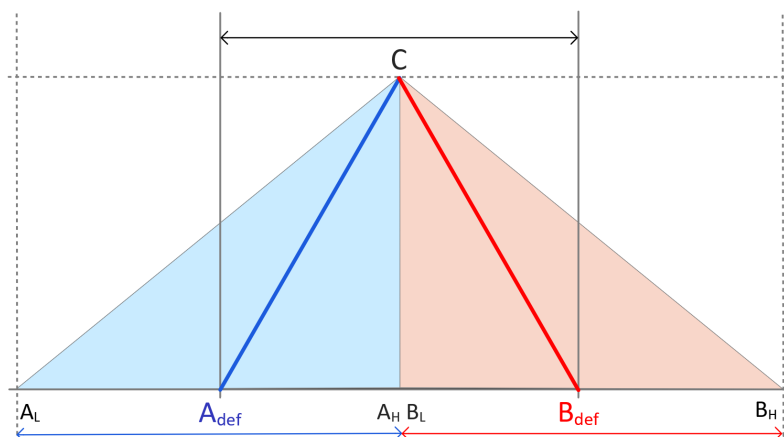
Tento postup nelze přímo aplikovat na nastavení funkcí příslušnosti. Každá funkce příslušnosti trojúhelníkového tvaru je definována třemi hodnotami. Jedná se o krajní hodnoty a střed. Přičemž musí být zajištěno, že levý krajní bod definující funkci příslušnosti má hodnotu nižší než hodnota pravého krajního bodu a poslední vrchol trojúhelníku leží mezi těmito hodnotami. Toto chování není v obecném algoritmu PSO nijak řešeno. Je tedy třeba provést úpravy algoritmu PSO tak, aby bylo možné na základě polohy částice vytvořit funkci příslušnosti.

Prvním krokem je omezení rozsahu generované polohy částice v prostoru na rozsah hodnot uvnitř jednotkové hyperkrychle dimenze 15. Tato úprava je celkem jednoduchá a lze jí dosáhnout změnou PSO algoritmu tak, že generované hodnoty každé dimenze jsou pouze v intervalu  $\langle 0; 1 \rangle$ . Pro pět vstupních funkcí příslušnosti je tedy poloha každé částice definována vektorem s patnácti složkami. Takto získaný vektor slouží následně pro vygenerování popisu pěti funkcí příslušnosti. Obrázek 9.34 definuje způsob parametrizace jedné funkce příslušnosti.

Vektor 15-ti hodnot získaný z PSO je rozdělen po třech prvcích definující jednu funkci příslušnosti. Pro každou funkci příslušnosti je definována základní poloha krajních bodů  $A_{def}$  a  $B_{def}$  vycházejících z krajních bodů odpovídající úsečky, které jsou použity pro vytvoření lineární výstupní funkce daného pravidla viz. obrázek 9.33. Následně se hodnota z intervalu  $\langle 0; 1 \rangle$  přepočte na reálnou hodnotu pozice takovým způsobem, že nové hodnoty bodů  $A$  a  $B$  leží v intervalech (vztahy 9.1):

$$\begin{aligned} \langle A_L; A_H \rangle &= \left\langle A_{def} - \frac{B_{def} - A_{def}}{2}; A_{def} + \frac{B_{def} - A_{def}}{2} \right\rangle \\ \langle B_L; B_H \rangle &= \left\langle B_{def} - \frac{B_{def} - A_{def}}{2}; B_{def} + \frac{B_{def} - A_{def}}{2} \right\rangle \end{aligned} \quad (9.1)$$

Parametry vstupní trojúhelníkové funkce příslušnosti  $A'_i, B'_i, C'_i$  se získají z hodnot nalezených algoritmem PSO  $\langle v_1; v_2; v_3 \rangle_i, \forall i \in \{1..5\}$  podle následujícího vztahu 9.2:



Obr. 9.34: Nastavení parametrů funkcí příslušnosti

$$\begin{aligned}
 A'_i &= A_{def} - \frac{B_{def} - A_{def}}{2} - v_1 \cdot (B_{def} - A_{def}) \\
 B'_i &= B_{def} - \frac{B_{def} - A_{def}}{2} - v_2 \cdot (B_{def} - A_{def}) \\
 C'_i &= A'_i + v_3 \cdot (B'_i - A'_i)
 \end{aligned} \tag{9.2}$$

Po vytvoření vstupních funkcí příslušnosti je proveden výpočet RMSE. Z provedených 100 opakování je vybrán takový vektor patnácti hodnot, pro který je RMSE nejmenší. Následuje krok optimalizace vah jednotlivých funkcí příslušnosti. V tomto případě je pomocí algoritmu PSO vygenerován vektor s pěti hodnotami váhy odpovídající každému výstupnímu pravidlu. Z provedených sto opakování je opět vybrán vektor pěti vah odpovídající minimálnímu RMSE při srovnání originálního průběhu převodové charakteristiky a charakteristiky vzniklé aproximací pomocí FIS typu Sugeno. Vektory nejlepších parametrů pro vytvoření funkcí příslušnosti a vah pro každého řidiče jsou dále použity pro shlukovou analýzu.


### 9.3.2 Shlukování s využitím parametrů modelů FIS

Dalším krokem po vytvoření modelů všech řidičů je provedení vlastního shlukování získané datové sady. Jako shlukovací algoritmus bylo použito v Matlabu dostupné shlukování pomocí algoritmu K-means. Detailní popis fungování shlukování tímto algoritmem lze nalézt například v článku [54].

Algoritmus K-means patří mezi stochastické algoritmy, kdy výsledek shlukování je závislý na počáteční konfiguraci vygenerovaných bodů v prostoru možných řešení. Dalším problémem algoritmu je nutnost zvolení počtu shluků, které se bude algoritmus snažit v datech vytvořit. Pro volbu optimálního počtu shluků lze využít

funkce *evalcluster* používající Calinsky–Harabasz index [55](strana 194) pro hodnocení kvality shluků. Aplikací této metody byly navrženy tři shluky jako optimální počet ze zpracovávané datové sady.

Následujícím krokem bylo provedení vlastního shlukování metodou K–means pro tři shluky. Získání nejlepšího možného výsledku shlukování bylo provedeno stonásobným opakováním shlukování. Jako finální výsledek pak bylo vybráno nejlepší řešení na základě hodnoty vzájemné separability shluků. Výsledek shlukování je vizualizován na obrázku 9.35 pomocí Silhouette plotu [56] a ukazuje kvalitu shlukování. Silhouette index ukazuje, jak daný řidič patří do shluku. Nejlepší možná hodnota Silhouette indexu je jedna. V případě, že je index záporný je řidič přiřazen do shluku nesprávně.



Obr. 9.35: Silhouette – shluky FIS

Po provedeném shlukování byly vytvořeny tři shluky obsahující počty řidičů uvedené v následující tabulce 9.7.


Grafické znázornění shluků naměřených dat úhlu natočení volantu v čase pro řidiče přiřazené jednotlivým shlukům je v příloze D na obrázcích D.3, D.4, D.5.

Tab. 9.7: Počty řidičů ve shlucích parametry FIS

Shluk	Počet řidičů
Shluk 1	19
Shluk 2	9
Shluk 3	10

### 9.3.3 Shlukování naměřených dat řidičů

Pro srovnání výsledků shlukování z parametrů fuzzy systémů Sugeno všech řidičů bylo provedeno shlukování naměřených dat úhlu natočení volantu u všech řidičů. Datová sada použitá ke shlukování má dimenzi 38 řádků a 751 sloupců. Průběh zpracování dat probíhal stejným způsobem jako v předchozí kapitole. V první řadě byl proveden odhad počtu shluků v datové sadě. Navržená hodnota optimálního počtu shluků, použitím funkce *evalcluster*, je v tomto případě pět. Následně bylo provedeno vlastní shlukování pomocí algoritmu K-means se sto násobným opakováním. Výsledkem provedeného shlukování je pět shluků řidičů. Kvalita shlukování je zobrazena pomocí Silhouette plotu na obrázku 9.36.



Obr. 9.36: Silhouette - shluky naměřená data

Po provedeném shlukování bylo vytvořeno pět shluků obsahujících počty řidičů

uvedené v následující tabulce 9.8.

Tab. 9.8: Počty řidičů ve shlucích naměřená data

Shluk	Počet řidičů
Shluk 1	9
Shluk 2	1
Shluk 3	6
Shluk 4	1
Shluk 5	21

Grafické znázornění shluků naměřených dat úhlu natočení volantu v čase pro řidiče přiřazené jednotlivým shlukům je v příloze D na obrázcích D.6, D.7, D.8, D.9, D.10.

### 9.3.4 Zhodnocení shlukování řidičů na základě parametrů FIS

Po provedení obou částí experimentu jsme získali dvě shlukování řidičů. Jeden výsledek shlukování je vytvořen na datové sadě o dimenzi 38 řidičů a 20 atributů, která vznikla vytvoření fuzzy modelu Sugeno pro každého jednotlivého řidiče. Parametry tohoto modelu, konkrétně hodnoty nastavení pěti trojúhelníkových vstupních funkcí příslušnosti a pěti vah výstupních pravidel tvoří atributy datové sady. Druhým výsledkem určeným především k porovnání je shlukování naměřených dat každého řidiče a datová sada má dimenzi 38 řidičů a 751 atributů.


Na základě navrženého optimálního počtu shluků jsem získali pro shlukování dat fuzzy modelů celkem tři shluky a pro shlukování naměřených dat to je shluků pět. Pro každý ze shluků lze průměrováním obsažených dat získat průměrnou hodnotu změny natočení volantu všech řidičů ve shluku. Tyto průměrné charakteristické průběhy můžeme považovat za jakýsi profil který je obsažený v datech shluku.

Na následujících obrázcích 9.37 a 9.38, jsou zobrazeny jednotlivé profily patřící různým shlukům v jednom obrázku. Při srovnání jednotlivých profilů je vidět, že profily vycházející z dat optimalizovaných fuzzy systémů odpovídají v podstatě profilům vytvořených z dat měření. Větší množství profilů/shluků při shlukování naměřených dat je způsobeno tím, že shluky 2 a 4 obsahují právě jednoho řidiče s velmi odlišným průběhem úhlu natočení volantu a jsou tedy vyčleněni do samostatných shluků/profilů. V případě shluků vytvořených pomocí parametrů FIS jsou tito krajní řidiči přiřazeni optimalizátorem do některého shluku.

Není jednoduché na základě tohoto experimentu jednoznačně potvrdit či vyvrátit hypotézu o tom, že lze použít parametry fuzzy modelů Sugeno pro shlukovou




analýzu, avšak v tomto případě jsme získali výsledky odpovídající shlukování provedenému nad naměřenými hodnotami. Zcela nepochybnou výhodou je ovšem fakt, že lze pracovat s modelem každého řidiče, a tím redukovat dimenzi problému z 751 hodnot měření v čase na 20 hodnot nastavení fuzzy systému v tomto konkrétním případě. V rámci tohoto experimentu lze tedy považovat platnost hypotézy za prokázanou.<sup>3</sup>



Obr. 9.37: Profily otočení volantu – tři shluky z fuzzy modelů řidičů

<sup>3</sup>Zdrojový kód je v sekci Experiment 3 v zip souboru a na CD



Obr. 9.38: Profily otočení volantu – pět shluků z naměřených dat

## Závěr

V rámci kapitoly 1 byla provedena rešerše používaných matematických modelů pro popis chování řidiče vozidla. Následně byla popsána základní myšlenka fuzzy logiky a fuzzy systémů, jejich výhody a nevýhody (kapitoly 2–5). Byl popsán simulátor řízení vozidla, ze kterého byla získána naměřená data. Nad těmito daty byla provedena základní statistická šetření, ze kterých se vychází pro vyhodnocení řidiče v daném scénáři (kapitola 7). Další část (kapitola 8) se věnuje vlastnímu vydefinování oblasti aplikace fuzzy logiky při modelování a hodnocení chování řidiče. Experimentální část byla zaměřena na použitelnosti fuzzy inferenčních systémů k modelování chování řidičů, ve které byly navrženy následující úlohy.

První hypotéza se snažila ověřit možnosti použití fuzzy systému pro modelování otočení volantem v závislosti na vzdálenosti od středu požadovaného jízdního pruhu. Pro ověření této metody bylo využito ručního modelování i optimalizačních metod, založených na genetickém algoritmu. Pracovalo se s fuzzy systémy typu 1 Mamdani a Sugeno, přičemž oba přístupy byly schopny modelovat řidiče s akceptovatelnou přesností. Tuto hypotézu můžeme tedy přijmout.

Druhá hypotéza se snaží odpovědět na otázku, zda fuzzy modely chování řidiče vytvořené s časovým odstupem vykazují vzájemnou podobnost. V rámci ověření této hypotézy se pracovalo s velmi malým počtem řidičů (4), což bohužel vedlo k neprokazatelnému přijetí, či zamítnutí hypotézy. Ačkoliv byly zjištěny indicie, které ukazují na pravdivost hypotézy, bude třeba pro její přijetí či zamítnutí pracovat s rozsáhlejším souborem řidičů a větším množstvím časových intervalů mezi jízdami.

V poslední hypotéze se řeší otázka, zda je možné nalézt shluky řidičů na základě parametrů získaných z fuzzy systémů typu Sugeno. Jedná se především o hodnoty nastavení funkcí příslušností a vah jednotlivých pravidel. Tímto přístupem je možné zmenšit dimenzi problému z původních 751 vzorků představujících průběh chování řidiče v čase, na pouhých 20 parametrů, definujících fuzzy inferenční systém. Shlukování získaných parametrů bylo provedeno K-means algoritmem a výsledné shluky vykazovaly konzistentní charakteristiky. Hypotézu lze považovat za potvrzenou.

Tato práce je natolik komplexního charakteru, že existuje nespočet různých směrů, kterými by se mohla ubírat. Mezi nejzásadnější problém, který je potřeba do budoucna vyřešit, je získání dostatečně velkého množství měření od různých řidičů (různého věku, pohlaví, zkušeností). Narůst množství použitelných měření lze pak využít při ověření hypotézy číslo 2 o podobnosti průběhu v čase. Současně je možné informace o řidičích využít v dalších analýzách k získání například profilů podle věku nebo pohlaví.

## Literatura

- [1] Edward A. Lee. The past, present and future of cyber-physical systems: A focus on models. *Sensors*, 15(3):4837–4869, 2015. URL: <https://www.mdpi.com/1424-8220/15/3/4837>, doi:10.3390/s150304837.
- [2] Gunar Schirner, Deniz Erdogmus, Kaushik Chowdhury, and Taskin Padir. The future of human-in-the-loop cyber-physical systems. *Computer*, 46:36–45, 01 2013. doi:10.1109/MC.2013.31.
- [3] Sirajum Munir, John A. Stankovic, Chieh-Jan Mike Liang, and Shan Lin. Cyber physical system challenges for Human-in-the-Loop control. In *8th International Workshop on Feedback Computing (Feedback Computing 13)*, San Jose, CA, June 2013. USENIX Association. URL: <https://www.usenix.org/conference/feedbackcomputing13/workshop-program/presentation/munir>.
- [4] Dr Wali Mughni. *Human Factors in Aviation*. Aviation Institute of Management, May. URL: <https://www.slideshare.net/wmughni/human-factors-in-aviation-62599359>.
- [5] Julie Bell and Justin Holroyd. Review of human reliability assessment methods. *Health & Safety Laboratory*, 78, 2009.
- [6] M. Jirgl, Z. Bradac, and P. Fiedler. Adaptive human control model and its usability in modeling of human-in-the-loop cyber physical systems. *IFAC-PapersOnLine*, 52(27):415–420, 2019. 16th IFAC Conference on Programmable Devices and Embedded Systems PDES 2019. URL: <https://www.sciencedirect.com/science/article/pii/S2405896319326461>, doi: <https://doi.org/10.1016/j.ifacol.2019.12.697>.
- [7] Anthony J Spurgin. *Human reliability assessment theory and practice*. CRC press, 2009.
- [8] DJ Allerton. The impact of flight simulation in aerospace. *The Aeronautical Journal*, 114(1162):747–756, 2010.
- [9] Jens Rasmussen. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-13:257–266, 1983.
- [10] Max Mulder, Daan Pool, David Abbink, Erwin Boer, Peter Zaal, Frank Drop, Kasper van der El, and Marinus M. Van Paassen. Manual control cybernetics:

- State-of-the-art and current trends. *IEEE Transactions on Human-Machine Systems*, PP:1–18, 10 2017. doi:10.1109/THMS.2017.2761342.
- [11] Duane McRuer and Ezra Krendel. Mathematical models of human pilot behavior. page 83, 01 1974.
- [12] Christian Roesener, Michael Harth, Hendrik Weber, Johanna Josten, and Lutz Eckstein. Modelling human driver performance for safety assessment of road vehicle automation. *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 735–741, 2018.
- [13] Haobin Jiang, Huan Tian, and Yiding Hua. Model predictive driver model considering the steering characteristics of the skilled drivers. *Advances in Mechanical Engineering*, 11(3):1687814019829337, 2019. arXiv:<https://doi.org/10.1177/1687814019829337>, doi:10.1177/1687814019829337.
- [14] M. Havlikova, Sona Sediva, Zdenek Bradac, and Miroslav Jirgl. A man as the regulator in man-machine systems. *Advances in Electrical and Electronic Engineering*, 12, 12 2014. doi:10.15598/aeer.v12i5.1121.
- [15] Jens Rasmussen. Information processing and human-machine interaction. *An approach to cognitive engineering*, 1986.
- [16] M Wentink, LPS Stassen, I Alwayn, RJA W Hosman, and HG Stassen. Rasmussen’s model of human behavior in laparoscopy training. *Surgical endoscopy and other interventional techniques*, 17(8):1241–1246, 2003.
- [17] Marie Havlíková. Diagnostika systému s lidským operátorem. 2008.
- [18] D. Michalik, O. Mihalik, M. Jirgl, and P. Fiedler. Driver behaviour modeling with vehicle driving simulator. *IFAC-PapersOnLine*, 52(27):180–185, 2019. 16th IFAC Conference on Programmable Devices and Embedded Systems PDES 2019. URL: <https://www.sciencedirect.com/science/article/pii/S2405896319327028>, doi:<https://doi.org/10.1016/j.ifacol.2019.12.753>.
- [19] Ezra S. Krendel and Duane T. McRuer. A servomechanisms approach to skill development. *Journal of the Franklin Institute*, 269(1):24–42, 1960. URL: <https://www.sciencedirect.com/science/article/pii/0016003260902453>, doi:[https://doi.org/10.1016/0016-0032\(60\)90245-3](https://doi.org/10.1016/0016-0032(60)90245-3).

- [20] Magomed Gabibulayev and Bahram Ravani. A Stochastic Form of a Human Driver Steering Dynamics Model. *Journal of Dynamic Systems, Measurement, and Control*, 129(3):322–336, 02 2005. arXiv:[https://asmedigitalcollection.asme.org/dynamicsystems/article-pdf/129/3/322/5651366/322\\\_1.pdf](https://asmedigitalcollection.asme.org/dynamicsystems/article-pdf/129/3/322/5651366/322\_1.pdf), doi:10.1115/1.2098927.
- [21] A Modjtahedzadeh and RA Hess. A model of driver steering dynamics for use in assessing vehicle handling qualities. *Advanced automotive technologies, 1991*, 1991.
- [22] RA Hess and A Modjtahedzadeh. A control theoretic model of driver steering behavior. *IEEE Control Systems Magazine*, 10(5):3–8, 1990.
- [23] A Modjtahedzadeh and Ronald A Hess. A model of driver steering control behavior for use in assessing vehicle handling qualities. 1993.
- [24] Charles C MacAdam. Application of an optimal preview control for simulation of closed-loop automobile driving. *IEEE Transactions on systems, man, and cybernetics*, 11(6):393–399, 1981.
- [25] H Ukawa, H Idonuma, and Takeshi Fujimura. A study on the autonomous driving system of heavy duty vehicle. *International journal of vehicle autonomous systems*, 1(1):45–62, 2002.
- [26] Ing. CSc. Radim Farana, Prof. *Jak inteligentní je pračka – fuzzy logika*. Centre of Excellence IT4Innovations, division of the University of Ostrava, Institute for Research and Applications of Fuzzy Modeling, duben. URL: <https://slideplayer.cz/slide/2411449/>.
- [27] G. Feng. *Analysis and Synthesis of Fuzzy Control Systems: A Model-Based Approach*. Automation and Control Engineering. Taylor & Francis, 2010. URL: <https://books.google.cz/books?id=2fmLtgEACAAJ>.
- [28] H.T. Nguyen, N.R. Prasad, C.L. Walker, and E.A. Walker. *A First Course in Fuzzy and Neural Control*. CRC Press, 2003. URL: <https://books.google.cz/books?id=wvPKBQAAQBAJ>.
- [29] F.M. McNeill and E. Thro. *Fuzzy Logic: A Practical Approach*. Elsevier Science, 2014. URL: <https://books.google.cz/books?id=3jGjBQAAQBAJ>.
- [30] David I Brubaker. Fuzzy-logic basics-intuitive rules replace complex math. *EDN*, 37(13):111, 1992.
- [31] Hellendoorn Driankov. Reinfrank, “an intro. to fuzzy control”, 1993.

- [32] J. Mendel, H. Hagnas, W.W. Tan, W.W. Melek, and H. Ying. *Introduction To Type-2 Fuzzy Logic Control: Theory and Applications*. IEEE Press Series on Computational Intelligence. Wiley, 2014. URL: <https://books.google.cz/books?id=C1HcAwAAQBAJ>.
- [33] Jerry M Mendel, Robert I John, and Feilong Liu. Interval type-2 fuzzy logic systems made simple. *IEEE transactions on fuzzy systems*, 14(6):808–821, 2006.
- [34] Nilesh Naval Karnik, Jerry M Mendel, and Qilian Liang. Type-2 fuzzy logic systems. *IEEE transactions on Fuzzy Systems*, 7(6):643–658, 1999.
- [35] Qilian Liang and Jerry M Mendel. Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on Fuzzy systems*, 8(5):535–550, 2000.
- [36] Jerry M Mendel. *Uncertain rule-based fuzzy systems: introduction and new directions*. Springer, 2017.
- [37] Chuen-Chien Lee. Fuzzy logic in control systems: fuzzy logic controller. i. *IEEE Transactions on systems, man, and cybernetics*, 20(2):404–418, 1990.
- [38] Ebrahim H Mamdani. Application of fuzzy algorithms for control of simple dynamic plant. In *Proceedings of the institution of electrical engineers*, volume 121, pages 1585–1588. IET, 1974.
- [39] Ebrahim H Mamdani. Advances in the linguistic synthesis of fuzzy controllers. *International Journal of Man-Machine Studies*, 8(6):669–678, 1976.
- [40] Tomohiro Takagi and Michio Sugeno. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15(1):116–132, 1985. doi:10.1109/TSMC.1985.6313399.
- [41] J. Gregory. *Game Engine Architecture*. CRC Press, 2017. URL: <https://books.google.cz/books?id=L1LSBQAAQBAJ>.
- [42] The R Foundation. *The R Project for Statistical Computing*. The R Foundation for Statistical Computing, c/o Institute for Statistics and Mathematics. URL: <https://www.r-project.org/>.
- [43] Marc Green. Driver reaction time. *Visual Expert Human Factors: http://www.visualexpert.com/Resources/reactiontime.html*, 2000.
- [44] Paweł Drożdżel, Sławomir Tarkowski, Iwona Rybicka, and Rafał Wrona. Drivers’ reaction time research in the conditions in the real traffic. *Open Engineering*, 10(1):35–47, 2020.

- [45] Yiannis Boutalis, Dimitrios Theodoridis, Theodore Kottas, and Manolis A Christodoulou. System identification and adaptive control. *Theory and Applications of the Neurofuzzy and Fuzzy Cognitive Network Models*, 2014.
- [46] William Siler and James J Buckley. *Fuzzy expert systems and fuzzy reasoning*. John Wiley & Sons, 2005.
- [47] Y Zeyada, E El-Beheiry, M El-Arabi, and D Karnopp. Driver modeling using fuzzy logic controls for human-in-the-loop vehicle simulations. In *Current Advances in Mechanical Design and Production VII*, pages 85–94. Elsevier, 2000.
- [48] Karine Younsi, Pierre Loslever, Jean-Christophe Popieul, and Philippe Simon. Fuzzy segmentation for the exploratory analysis of multidimensional signals: Example from a study on driver overtaking behavior. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41(5):892–904, 2011.
- [49] Faisal Riaz, Sania Khadim, Rabia Rauf, Mudassar Ahmad, Sohail Jabbar, and Junaid Chaudhry. A validated fuzzy logic inspired driver distraction evaluation system for road safety using artificial human driver emotion. *Computer Networks*, 143:62–73, 2018.
- [50] Mengmeng Dai, Jinxiang Wang, Nan Chen, and Guodong Yin. Fuzzy steering assistance control for path following of the steer-by-wire vehicle considering characteristics of human driver. In *2018 IEEE Intelligent Vehicles Symposium (IV)*, pages 892–897. IEEE, 2018.
- [51] Juan Pablo Vasconez, Michelle Viscaino, Leonardo Guevara, and Fernando Auat Cheein. A fuzzy-based driver assistance system using human cognitive parameters and driving style information. *Cognitive Systems Research*, 64:174–190, 2020.
- [52] Maurice Clerc. *Particle swarm optimization*, volume 93. John Wiley & Sons, 2010.
- [53] Kalami M. Heris. *Particle Swarm Optimization in MATLAB*. Yarpiz. URL: <https://yarpiz.com/50/ypea102-particle-swarm-optimization>.
- [54] Kristina P. Sinaga and Miin-Shen Yang. Unsupervised k-means clustering algorithm. *IEEE Access*, 8:80716–80727, 2020. doi:10.1109/ACCESS.2020.2988796.




- [55] Giuseppe Bonaccorso. *Machine learning algorithms*. Packt Publishing Ltd, 2017.
- [56] Peter J. Rousseeuw. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20:53–65, 1987. URL: <https://www.sciencedirect.com/science/article/pii/0377042787901257>, doi:[https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7).


## Seznam příloh

A Příloha kapitoly 9.1.1	115
B Příloha kapitoly 9.1.2	117
C Příloha kapitoly 9.2	118
D Příloha kapitoly 9.3	120
E Struktura přiloženého CD/zip souboru	125


## A Příloha kapitoly 9.1.1




Obr. A.1: Převodová charakteristika po optimalizaci pravidel s nejvyšším RMSE



Obr. A.2: Natočení volantu v čase po optimalizaci pravidel s nejvyšší RMSE




Obr. A.3: Převodová charakteristika po optimalizaci funkcí příslušnosti s nejvyšším RMSE




Obr. A.4: Natočení volantu v čase po optimalizaci funkcí příslušnosti s nejvyšší RMSE

## B Příloha kapitoly 9.1.2




Obr. B.1: Převodová charakteristika po optimalizaci funkcí příslušnosti s nejvyšším RMSE




Obr. B.2: Natočení volantu v čase po optimalizaci funkcí příslušnosti s nejvyšší RMSE


## C Příloha kapitoly 9.2



Obr. C.1: Detailní pohled fuzzy modelů od druhého řidiče po týdnu




Obr. C.2: Detailní pohled fuzzy modelů od třetího řidiče po týdnu




Obr. C.3: Detailní pohled fuzzy modelů od čtvrtého řidiče po týdnu

## D Příloha kapitoly 9.3




Obr. D.1: Vzdálenost od spline pro všechny řidiče




Obr. D.2: Průměrná vzdálenost od spline - všichni řidiči







Obr. D.3: Skupina řidičů pro shluk 1 FIS




Obr. D.4: Skupina řidičů pro shluk 2 FIS




Obr. D.5: Skupina řidičů pro shluk 3 FIS




Obr. D.6: Skupina řidičů pro shluk 1 naměřená data




Obr. D.7: Skupina řidičů pro shluk 2 naměřená data



Obr. D.8: Skupina řidičů pro shluk 3 naměřená data



Obr. D.9: Skupina řidičů pro shluk 4 naměřená data



Obr. D.10: Skupina řidičů pro shluk 5 naměřená data

## E Struktura přiloženého CD/zip souboru

/	
	dokument ..... Text diplomové práce
	Data ..... Originální data měření
	Data38 ..... Data měření pro 38 řidičů
	Data4 ..... Data měření pro 4 řidiče opakovaně
	statistika_R ..... Soubory pro základní statistiku v R
	data ..... Data ve formátu pro prostředí R pro 38 řidičů
	data_long ..... Data ve formátu pro prostředí R pro 4 řidiče
	documents ..... Výstupní dokumenty csv pro 38 řidičů
	documents_long ..... Výstupní dokumenty csv pro 4 řidičů
	DoStat.R ..... Základní statistické analýzy a import dat
	Experiment 1
	fuzzy_data ..... Vstupní data
	Mamdani_optimalizace ..... Část optimalizace fuzzy Mamdani
	Sugeno_optimalizace ..... Část optimalizace fuzzy Sugeno
	ulozene_obrazky ..... Výstupní obrázky z experimentu 2 ručně
	experiment1.m ..... Matlab script experimentu 1
	Experiment 2
	documents ..... Pracovní data experimentu 2
	fuzzy_modely ..... Fuzzy modely pro experiment 2
	porovnani ..... Výstupy experimentu 2
	experiment2.m ..... Matlab script experimentu 2
	Experiment 3
	Data ..... Data průměry experimentu 3
	Data_mereni ..... Vstupní data 38 řidičů experimentu 3
	Documents ..... Výstupní dokumenty experimentu 3
	DoShlukovani.m ..... Experiment 3 – shlukování
	runOptimalizace.bat ..... Optimalizace pro 38 řidičů