

ČVUT V PRAZE
FAKULTA DOPRAVNÍ



**POSOUZENÍ POZORNOSTI ŘIDIČE
S POUŽITÍM NELINEÁRNÍ ANALÝZY DAT**

DIPLOMOVÁ PRÁCE

2016

BC. LUCIE ZÝKOVÁ



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

**Fakulta dopravní
d ě k a n**

Konviktská 20, 110 00 Praha 1

K616.....Ústav dopravních prostředků

ZADÁNÍ DIPLOMOVÉ PRÁCE
(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení studenta (včetně titulů):

Bc. Lucie Zýková

Kód studijního programu a studijní obor studenta:

N 3710 – LO – Logistika, technologie a management dopravy

Název tématu (česky): **Posouzení pozornosti řidiče s použitím nelineární analýzy dat**

Název tématu (anglicky): Driver's attention evaluation using non-linear data analysis

Zásady pro vypracování

Při zpracování diplomové práce se řiďte osnovou uvedenou v následujících bodech:


- Seznamte se s problematikou vozidlových simulátorů.
- Seznamte se s problematikou únavy řidičů.
- Potvrďte či vyvráťte hypotézu, zda snížená viditelnost nebo únava řidičů vyvolává chaotické chování.
- Na základě dat z vozidlového simulátoru využijte metodu vizuální, nelineární rekurentní analýzy a ověřte, zda má trajektorie vozidla chaotický charakter (za okolností snížené viditelnosti a únavy).


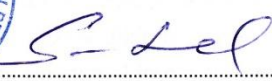
- Rozsah grafických prací: Dle pokynů vedoucího
- Rozsah průvodní zprávy: minimálně 55 stran textu (včetně obrázků, grafů a tabulek, které jsou součástí průvodní zprávy)
- Seznam odborné literatury: Jan Kodera, Tran Van Quang: Vizuální nelineární rekurentní analýza a její aplikace na český akciový trh, Politická ekonomie 2009, str. 305-322.
- Sanjeev Sharma: An Exploratory Study of Chaos in Human - Machine System Dynamics, IEEE trans. SMC part A: human systems, 2006 36(2), 319 - 326.

Vedoucí diplomové práce: **doc. Ing. Petr Vysoký, CSc.**
doc. Ing. Petr Bouchner, Ph.D.


Datum zadání diplomové práce: **29. června 2015**
(datum prvního zadání této práce, které musí být nejpozději 10 měsíců před datem prvního předpokládaného odevzdání této práce vyplývajícího ze standardní doby studia)

Datum odevzdání diplomové práce: **1. června 2016**
a) datum prvního předpokládaného odevzdání práce vyplývající ze standardní doby studia a z doporučeného časového plánu studia
b) v případě odkladu odevzdání práce následující datum odevzdání práce vyplývající z doporučeného časového plánu studia


.....
doc. Ing. Petr Bouchner, Ph.D. prof. Dr. Ing. Miroslav Svítek, dr. h. c.
vedoucí děkan fakulty
Ústavu dopravních prostředků

Potvrzuji převzetí zadání diplomové práce.


.....
Bc. Lucie Zýková
jméno a podpis studenta

V Praze dne..... 29. června 2015

Poděkování

Tímto bych moc ráda poděkovala svému vedoucímu práce doc. Ing. Petru Vysokému, CSc. A doc. Ing. Petru Bouchnerovi, Ph.D. za veškeré odborné rady, materiály a celkově za výborné vedení při zpracovávání této diplomové práce. Také děkuji všem, co se na experimentech podíleli nebo mi jakýmkoliv jiným způsobem pomáhali. Nelze opomenout ani rodinu, přátele a blízké, kteří mě podporovali během celého studia.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracovala samostatně a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o etické přípravě vysokoškolských závěrečných prací.

Nemám žádný závažný důvod proti užití tohoto školního díla ve smyslu § 60 Zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon).

V Praze dne 1. 6. 2016

.....

Bc. Lucie Zýková

Abstrakt

Autor: Bc. Lucie Zýková

Vedoucí práce: doc. Ing. Petr Vysoký, CSc.,

doc. Ing. Petr Bouchner, Ph.D.

Název: Posouzení pozornosti řidiče s použitím nelineární analýzy dat

Škola: České vysoké učení technické v Praze

Fakulta: Fakulta dopravní

Rok vydání: 2016

Klíčová slova: snížená viditelnost, únava, systém, chaos, nelineární analýza

Cílem této práce je zjistit, zda snížená viditelnost a únava řidičů vyvolávají chaotické chování. Oba experimenty – únava i pozornost – jsou založeny na datech získaných pomocí vozidlového simulátoru. Pro zjištění chaotického chování jsou tato data vyhodnocena pomocí vizuální, nelineární rekurentní analýzy. Práce se také zaměřuje na trajektorii vozidel a zjišťuje, zda snížená viditelnost a únava vytváří chaotický charakter trajektorie vozidla. Práce výsledky obou experimentů popisuje a porovnává.

Abstract

Author: Bc. Lucie Zýková

Thesis advisor: doc. Ing. Petr Vysoký, CSc.,

doc. Ing. Petr Bouchner, Ph.D.

Title: Driver's attention evaluation using non-linear data analysis

University: Czech Technical University in Prague

Faculty: Faculty of Transportation Sciences

Year of publication: 2016

Keywords: reduced visibility, tiredness, the system, chaos, non-linear analysis

The objective of this theses is to find out whether limited visibility and driver drowsiness causes chaotic behavior. Both drowsiness and attention research measurements are based on data from driving simulator. These data are analysed using visual non-linear recurrent analysis for chaotic behavior detection. The theses is also focused on vehicle trajectory and establishes whether limited visibility and drowsiness leads to chaotic character of vehicle trajectory. Results of both experiments are compared.

Obsah

ÚVOD	11
1. SYSTÉMY	12
1.1. Dynamické systémy	13
1.1.1 Nelineární dynamické systémy	14
1.1.2 Chaos.....	14
1.1.3. Deterministický chaos.....	15
2. TRAJEKTORIE SYSTÉMŮ	15
2.1. Fázový prostor.....	15
2.2. Atraktor dynamického systému.....	15
2.3. Trajektorie tlumeného rotátoru.....	16
3. NELINEÁRNÍ ANALÝZA CHAOTICKÝCH ČASOVÝCH ŘAD.....	18
3.1. Grafické zobrazení systému pomocí grafu fázového prostoru.....	18
3.2. Analýza pomocí rekurentního grafu.....	19
3.3. Kvantitativní rekurentní analýza.....	22
3.4. Střední vzájemná informace	24
3.4.1 Informace	24
3.4.2 Entropie.....	24
3.4.3. Vlastnosti střední vzájemné informace	25
3.5. Ljapunovův exponent.....	26
3.6. Metoda nepravých sousedů	27
4. EXPERIMENT	28
4.1. Tvorba a průběh experimentu – snížená viditelnost.....	28
4.1.1. Měření osoby.....	28
4.1.2. Data	28
4.2. Tvorba a průběh experimentu – únava řidičů.....	29
4.2.1. Data	29
4.2.2. Měření osoby.....	30
4.3. Práce s naměřenými daty.....	30
5. SOFTWARE – VISUAL RECCURRENCE ANALYSIS	31
6. VÝSLEDKY MĚŘENÍ.....	32
6.1. Analýza fázového prostoru.....	32

6.1.1. Pozornost řidičů.....	32
6.1.2. Únava řidičů	33
6.2. Analýza struktury systému pomocí rekurentních grafů	34
6.2.1. Pozornost řidičů.....	34
6.2.2. Únava řidičů	35
6.3. Analýza střední vzájemné informace.....	38
6.4. Analýza falešných sousedů	39
ZÁVĚR.....	41
SEZNAM POUŽITÉ LITERATURY	43
SEZNAM OBRÁZKŮ	45
SEZNAM TABULEK	45
SEZNAM PŘÍLOH	46
SEZNAM PŘÍLOH NA CD	47
PŘÍLOHA A: GRAFICKÉ ZOBRAZENÍ POHYBU ŘIDIČŮ – POZORNOST ŘIDIČŮ (ve fázové rovině).....	48
PŘÍLOHA B: GRAFICKÉ ZOBRAZENÍ POHYBU ŘIDIČŮ – ÚNAVA (ve fázové rovině)	51
PŘÍLOHA C: REKURENTNÍ GRAFY POZORNOSTI ŘIDIČŮ	52
PŘÍLOHA D: REKURENTNÍ GRAFY ÚNAVY ŘIDIČŮ.....	53
PŘÍLOHA E: REKURENTNÍ GRAFY ÚNAVY ŘIDIČŮ – VŠECHNY JÍZDY ŘIDIČŮ OS A PV	54
PŘÍLOHA F: STŘEDNÍ VZÁJEMNÁ INFORMACE- POZORNOST ŘIDIČŮ.....	56
PŘÍLOHA G: STŘEDNÍ VZÁJEMNÁ INFORMACE- ÚNAVA	58
PŘÍLOHA H: MANUÁL K ZÍSKÁNÍ REKURENTNÍHO GRAFU, STŘEDNÍ VZÁJEMNÉ INFORMACE A FALEŠNÝCH SOUSEDŮ V SOFTWARE VRA	60

ÚVOD

Cílem této diplomové práce je potvrzení či vyvrácení hypotézy, zda snížená viditelnost či únava řidičů vyvolává chaotické chování. K účelům této diplomové práce byla využita data z vozidlového simulátoru. Jedná se o dva experimenty – experiment únavy řidičů a pozornosti řidičů. Pomocí vizuální, nelineární analýzy je možné ověřit, zda má trajektorie vozidla, v případě snížené viditelnosti a únavy, chaotický charakter.

Práce je rozdělena do dvou částí. První je část teoretická, kde se nachází představení teorie systémů a teorie chaosu. V druhé části práce je samotná studie o chování řidičů a o trajektorii vozidel.

První kapitola Systémy obsahuje seznámení s problematikou. Dále se zabývá rozdělením systémů. Detailněji se věnuje nelineárním dynamickým systémům a chaosu.

V další kapitole se nachází představení trajektorií systémů. Pro pochopení experimentu je nutná znalost fázového prostoru, který se zde popisuje. Věnuje se také atraktorům dynamického systému. Pro lepší představu zde prezentuje různé příklady trajektorií systému s popisem, co se ve kterém systému děje a proč.

Velmi důležitou částí teorie je seznámení se základní nelineární analýzou chaotických časových řad. V kapitole se práce zaměřuje na datovou analýzu, která je nutná k vypracování této diplomové práce. Seznamuje čtenáře s grafickým zobrazením systémů pomocí grafu fázového prostoru. Dále představuje entropii a pro tuto práci velmi důležitou střední vzájemnou informaci. Pro zjištění struktury systému se zde nachází také popis analýzy pomocí rekurentního grafu. Dále se zaměřuje na popis kvantitativní rekurentní analýzy, Ljapunovova exponentu a metody nepravých sousedů.

Jak už bylo zmíněno, druhá část diplomové práce obsahuje samotný experiment. V kapitole Experiment se nachází popis tvorby a průběhu experimentu a to jak pro sníženou viditelnost, tak pro únavu řidičů. Představuje měření osoby a popisuje způsob zpracování jednotlivých získaných dat. Malou kapitolou v této práci je Software – Visual Recurrence Analysis, kde se nachází představení a popis programu.

Jedna z nejdůležitějších částí diplomové práce jsou Výsledky měření. Zde se nachází výsledky a závěry analýz. Jedná se o struktury systémů získané pomocí vizuální analýzy využitím rekurentních grafů a analýzu fázového prostoru, do které patří zjištění disperze u trajektorie unavených řidičů. Dále obsahuje výsledky střední vzájemné informace u obou experimentů. Pro naměřená data únavy řidičů je zde také zpracována analýza falešných sousedů.

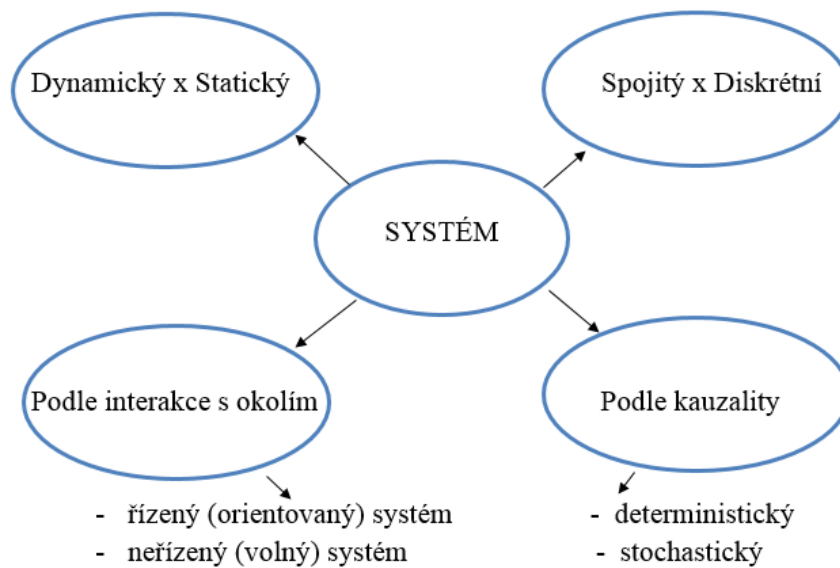
1. SYSTÉMY

System je jeden z nejrozšířenějších pojmů. Používá se jak ve vědeckých či technických disciplínách, tak v běžném životě. [1] Lze si ho představit jako uspořádanou množinu prvků, mezi nimiž působí vzájemné vazby. Takto vytvořený celek (systém) se pak projevuje vůči svému okolí odlišně, než jak by se projevował pouhý soubor stejných navzájem neprovázaných prvků. [2]

Při práci se systémy vycházíme z dat získaných pozorováním nebo měřením objektů. Objekt může být například lidský mozek, nervová buňka nebo počítač. Ty pak vyšetřujeme z různých (předem daných) hledisek. Pozorujeme (měříme) určité vlastnosti. [1]

Jako příklad systému lze uvést automobil. Je tvořen z hlavních prvků, jako je spalovací motor, spojka, převodovka, hřídel a kola. Tyto prvky umí samy o sobě například převést chemickou energii na energii tepelnou a následně na energii mechanickou. Točivý pohyb se spojkou převede do převodovky, kde se zredukuje na požadovanou hodnotu a přes hřídel se přeneše na kola, které uvedou vozidlo do pohybu. Jednotlivé komponenty mohou jako systém existovat i samy. Spalovací motor má systém zapalování, přívod směsi paliva, odvod výfukových plynů atd.

Obrázek 1 znázorňuje rozdělení systémů. Podle interakce s okolím se dělí na řízený a neřízený systém. U tohoto druhu jsou veličiny vstupu a výstupu rozlišitelné veličiny, kde vstup způsobuje změny v ostatních veličinách, výstup ovlivňuje pouze okolí systému. U neřízeného systému neexistuje nebo není známo dělení mezi vstupy a výstupy. Další dělení je podle kauzality systému na deterministický a stochastický systém. V deterministickém systému je chování zobrazeno množinou uspořádaných dvojic příčin a následků, kdežto u stochastického je jedné příčině přiřazeno více následků s různými pravděpodobnostmi. Příčina je zde nutnou, nikoli jen postačující podmínkou pro určení následku. Spojitý systém se vyznačuje tím, že jeho proměnné jsou veličiny spojitě v prostoru a čase. Velmi často je to i čas, který se záměrně odlišuje od ostatních veličin. Diskrétní systém obsahuje proměnné z řady celých čísel, nabývá tedy konečného počtu hodnot. Jedná se o kvantované či vzorkované spojitě systémy. Poslední dělení je na statické a dynamické systémy. U statických se proměnné s časem nemění. U dynamického systému výstup závisí nejen na okamžité hodnotě vstupů, ale také na jejich minulých hodnotách. Vymáčkne-li v automobilu spojku, auto pokračuje setrvačností podle toho, jak bylo rozjeté. [3]



Obrázek 1- Rozdělení systémů [3. autor]

1.1. Dynamické systémy

Většina systémů na světě je dynamická. Jejich životně důležitá vlastnost je existence časového vývoje chování v rámci systému. [4] Využijeme je tedy, je-li změna stavu systému popsána v čase (a to v mnoha případech pomocí zápisu vyjádřenou soustavou diferenciálních rovnic). Stav může být popsán i vektorem, který celý leží ve stavovém prostoru. [5] Většina dynamických systémů je nelineárních a velmi často vykazují chaotické chování. Techniky dynamických systémů jsou založeny na fyzikálních zákonech a matematických teoriích. [4]

Rozdělení dynamických systémů je jednoduché. Jedná se o systémy deterministické (kde lze celý systém přesně popsat) a stochastické (systém je popsán statistickými vlastnostmi jako je střední hodnota nebo směrodatná odchylka). Dalším možným rozdělením je dělení na systémy lineární a nelineární. U lineárních dynamických systémů lze uplatnit princip superpozice. Je-li vstup 2krát větší, zvětší se 2krát i výstup. Zde lze chování systému i předpovědět. U nelineárních systémů princip superpozice neplatí. Je zapotřebí využít diferenciálních rovnic. Jediný případ, kdy lze u nelineárních systémů využít princip superpozice je množina izolovaných bodů, tzv. fixních bodů. [5]

Okamžitá hodnota výstupu závisí nejen na okamžité hodnotě vstupu, ale také na historii systému, to znamená, že má systém svou paměť. [1]

1.1.1 Nelineární dynamické systémy

Lineární systémy jsou v tuto chvíli teoreticky, ale velmi důkladně prozkoumány. Důležité je zjištění, že nemohou vykazovat chaotické chování. Nelineární systémy jsou oproti tomu velmi obtížné na analytické zkoumání. V řadě případů si musíme vystačit pouze s numerickou analýzou. Ta samozřejmě silně využívá dnešní moderní výpočetní techniku. [6] Možná proto se vědci velmi dlouhou dobu vyhýbali nepravidelné stránce přírody. Nespoutanosti rozbouřeného moře, nepravidelnostem v atmosféře či v kolísání populace divočiny. Ovšem pozdější studie právě těchto neobvyklých jevů odhalila, že nepravidelnost, nelineárnost a chaos jsou zkrátka neodbouratelnými principy přírody. Chaotické chování se objevilo v počasí, ve shlukování aut na dálnicích, v plynutí ropy v podzemním potrubí, v proudění tekutin, v nervových sítích apod. Teorie nelineárních dynamických systémů tak překročila hranice různých vědeckých disciplín a ukázala být se vědou globálních systémů přírody. V literatuře se často termíny nelineární dynamika a chaos používají jako synonyma. Chaos je ovšem pouze jedním typem chování, které vykazují nelineární systémy. Je nutné dodat, že všechny chaotické systémy jsou nelineární, ovšem ne všechny nelineární systémy jsou chaotické. [4]

1.1.2 Chaos

Chaos lze uvažovat jako spojení deterministického a stochastického chování. Deterministické chování je ovládané exaktními a neporušitelnými pravidly, kdežto stochastické chování je bez zákonů a pravidel, je vlastně řízené náhodou. Chaos je pak definován jako nepravidelné chování podle přesných pravidel. Dnešní slovník slovo chaos definuje jako zmatek, nepořádek či stav s vysokou neuspořádaností. Lze tedy říct, chaotické chování je velmi složité, ale deterministické chování. Může vznikat jen u nelineárních systémů určité složitosti. Např. se může vyskytovat u systémů popsaných nelineárními rovnicemi třetího a vyššího řádu.

Kdyby tvůrci slovníku měli tento výraz vyjádřit přesně, museli by použít definici chaosu jako zdánlivě stochastické chování v deterministickém systému. Příklad chaosu lze uvést na stroji vyrábějícím bonbóny. V tomto zařízení se 2 ocelové metly otáčejí a zároveň se posouvají ze strany na stranu. Je zde proces mísení (sloučení ingrediencí) a rozpínání (za účelem vytvoření dlouhých řetězců z krystalů cukru pro docílení křehké lámavosti bonbónů). Stroj pracuje veškerý čas periodicky (dokola, sem a tam), ale hmota se stane chaotická. Pravidelná příčina má za následek nepravidelný výsledek. [7]

Velmi podstatná vlastnost chaotických systémů je ta, že i malý rozdíl na vstupu systému může vytvořit ohromující rozdíl na výstupu. Je tedy velmi citlivě závislý na vstupních podmínkách. Chaotické chování se podobá náhodnému šumu, ale v krátkém období je předvídatelné. Tato krátkodobá předvídatelnost je užitečná v oblastech, které sahají od předpovědi počasí až po předpovědi ekonomické (burzy). [4]

1.1.3. Deterministický chaos

Chovají-li se skutečné systémy v přírodě chaoticky, nazýváme toto chování deterministickým chaosem. Jde o proces samoorganizace složitých systémů. Vznikají zde soustavy koherentních struktur, které se ovšem chovají v souladu s přírodními zákony. Zaměříme-li se na jednu určitou strukturu systému, její vývoj má prvky náhodnosti. Ovšem při pohledu na tento systém jako na celek se však vyvíjí zcela zákonitě, tedy deterministicky. [8]

Mezi vlastnosti deterministického chaosu patří například neperiodičnost, tedy neopakovatelné chování. Nikdy by se systém neměl dostat do stavu, ve kterém už byl. Další záležitostí je citlivá závislost na volbu počátečních podmínek, tedy efekt motýlích křídel. Mávnutí křídel v New Yorku způsobí bouři nad Jižní Amerikou. [8]

2. TRAJEKTORIE SYSTÉMŮ

2.1. Fázový prostor


Prostor fyzikálních stavů určitého systému je definován jako fázový prostor. Každý bod fázového prostoru tedy jednoznačně určuje stav myšleného systému. Mluvíme-li o stavu, mluvíme o souboru veličin nesoucích informaci o minulé historii dynamického systému. Historie je nutná pro stanovení budoucího chování při známých hodnotách vstupních veličin. Každým tímto výše zmíněným bodem prochází jedna trajektorie, která popisuje časový vývoj systému. Všechny body fázového prostoru tak určují všechny jeho možné stavy (stavy, do kterých se daný systém může dostat). Má tedy takový počet rozměrů, kolik má daný systém stavových proměnných. Jedná se o vizualizaci vývoje systému. Jestliže ponecháme systém vyvíjet, vytváří se ve fázovém prostoru křivka nebo množina bodů. Záleží na tom, zda se jedná čas spojitý nebo diskrétní. Pokud necháme systém vyvíjet dostatečně dlouho, křivka ve fázovém prostoru zvyrazňuje určitou fázovou trajektorii, ve speciálním případě atraktor. [9]

2.2. Atraktor dynamického systému

Nejdůležitější vlastností dynamických systémů je dlouhodobé chování. Z množiny všech možných pohybů celého systému pak vybírá mnohem menší množinu. Stavy po spuštění nazýváme přechodné děje. Po doznění přechodového děje se systém dostane do ustáleného stavu. Ustálený stav může být reprezentován jediným bodem nebo uzavřenou trajektorií, které se říká mezní cyklus a odpovídá periodickému ději. U některých nelineárních systémů je trajektorie nalézající se v blízkosti mezního cyklu přitahována (atrahována) tímto mezním cyklem a pak takovýto mezní cyklus nazýváme atraktor. Atraktor je cokoliv, v čem se systém v jisté části fázového prostoru ustálí. [7] Tento limitní (konečný) stav může být zobrazen ve

fázovém prostoru jako bod nebo limitní cyklus. Bod je konečný stav klidu, ke kterému systém spěje. Limitní cyklus je uzavřená křivka, která odpovídá periodickému pohybu. Pokud je atraktor tvořen uzavřenou hranicí, lze jeho chování předpovídat na libovolně dlouhou dobu. Naopak atraktor s neuzavřenou hranicí značí chaotické chování. [10]

Mezi nejznámější tzv. podivné atraktory patří Lorenzův atraktor. Jedná se o podivný atraktor, protože zde nedojde k ustálení systému ani po velmi dlouhém čase. Tento Lorenzův atraktor je zobrazen ve dvojdimenzionálním fázovém prostoru na obrázku 2. Vzniká tedy konvergující křivka. [10]



Obrázek 2- Lorenzův atraktor [5]

2.3. Trajektorie tlumeného rotátoru

Následující příklad umožňuje nahlédnout do trajektorií dynamického systému. Jedná se o tlumený rotátor. Příklad nabízí různé hodnoty tlumení a počáteční podmínky, čímž přináší náhled do změn trajektorie systému při zásahu do zadání.

Pohybová rovnice systému:

$$\ddot{\phi} = -\frac{g}{l} \sin \phi - \frac{k}{m} \omega + \frac{A}{ml^2} \cos \theta, \quad (1)$$

(kde A je amplituda působící síly a $\theta = \Omega t$ je její fáze, parametr Ω je úhlová frekvence síly)

Odpovídající soustava stavových rovnic dynamického systému (nahrazení diferenciální rovnice druhého řádu dvěma diferenciálními rovnicemi prvního řádu) je:

$$\begin{aligned} \dot{\phi} &= \omega \\ \dot{\omega} &= -\frac{g}{l} \sin \phi - \frac{k}{m} \omega + \frac{A}{ml^2} \cos \theta \\ \dot{\theta} &= \Omega \end{aligned} \quad (2)$$

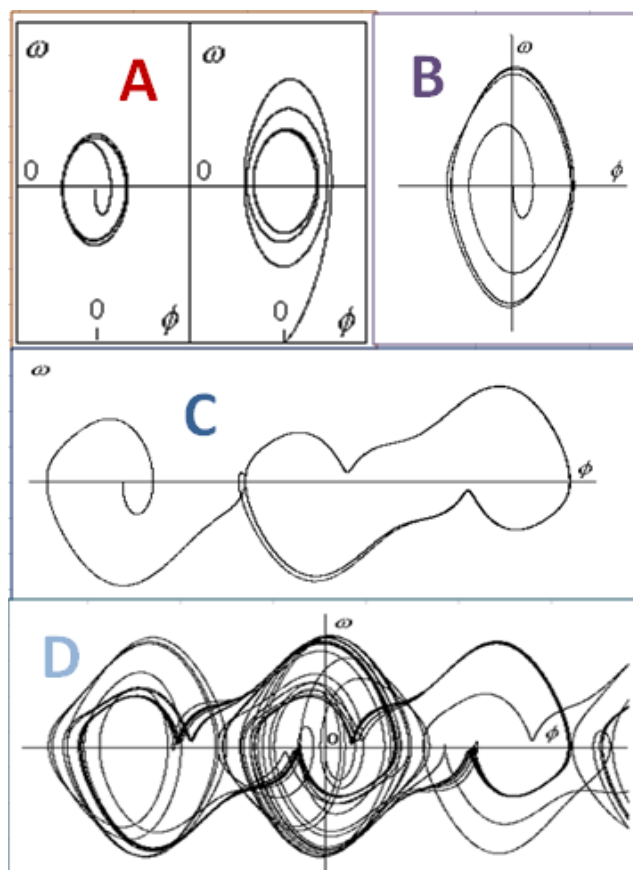
Pro snížení počtu parametrů přepíšeme soustavu do bezrozměrného tvaru:

$$\begin{aligned}\dot{\phi} &= \omega \\ \dot{\omega} &= -\sin\phi - \frac{l}{q}\omega + p\cos\theta\end{aligned}\quad (3)$$

$$\dot{\theta} = \Omega$$

(kde q je tlumicí koeficient a p koeficient amplitudy vnější síly)

Obrázek 3 znázorňuje trajektorie daného systému s různými variantami jejich koeficientů. Obrázek je rozdělen do čtyř částí A, B, C a D. V oblasti A se nachází trajektorie s parametry $W=2/3$, $q=2$, $p=0.5$. Část B zobrazuje stejnou trajektorii, jako je v oblasti A, pouze s úpravou vnější síly p na $p = 0,9$. I zde se systém ustálil, ovšem s větší amplitudou. Úsek C ukazuje systém s $p = 1,08$, i zde se systém ustálí, ale v limitním cyklu s dlouhým a složitým průběhem. V části D je trajektorie pro $p = 1,15$, kde se systém vyvíjí chaoticky. I v případě, že se systém do stavu limitního cyklu dostane, po určité době ho opustí. [11]



Obrázek 3 – Trajektorie tlumeného rotátoru [11, autor]

3. NELINEÁRNÍ ANALÝZA CHAOTICKÝCH ČASOVÝCH ŘAD

Jak odlišit případy, kdy řada s relativně složitou dynamikou je generována nelineárním deterministickým systémem a kdy se jedná o řadu stochastickou? V současné době se analýzou časových řad zabývají i ekonomové, kteří zkoumají možnost deterministického popisu finančních řad. Kdyby se tato varianta potvrdila, byla by možná predikce dynamiky časových řad, což by sloužilo k předpovídání stavu časových řad. Dlouhodobá predikce je zde ještě složitější. Důvodem je exponenciální rozbíhavost dostatečně blízkých trajektorií nelineárního dynamického systému společně s nepřesností měření. V některých případech je ale možné vytvořit atraktor, který lze použít pro dlouhodobou předpověď. [12]

Tato diplomová práce pojednává o chaotickém chování řidiče automobilu v případě snížené viditelnosti a únavě řidičů. V obou experimentech pracujeme s neperiodickými kmity. Pomocí statistické analýzy dat je možné získat pouze závěry z histogramů a jiných statistických veličin, ale nezjistíme, zda jsou časové řady chaotické, resp. o jaký signál polohy automobilu se jedná. Z teorie již víme, že chaotický signál může vzniknout pouze v nelineárních systémech, proto je nutná nelineární analýza chaotických časových řad. Teprve z ní se můžeme dozvědět, o jaké signály se v tomto případně jedná.


Předpoklad, že dané kmity budou chaotické má své odůvodnění. Většina analytických modelů řidiče jako regulátoru je lineárních. Zrovna tak jako modelů dynamiky automobilu. Lineární systém nemůže vykazovat trvalé kmity. Řidič ale udržuje automobil na silnici kmitavými pohyby volantu (s frekvencí 0,1-1 Hz). To znamená, že řidič musí ve skutečnosti fungovat jako nelineární regulátor. Proto existuje hypotéza, že zmíněné kmity budou chaotické.

3.1. Grafické zobrazení systému pomocí grafu fázového prostoru

Kvalitativní dynamika systémů může být reprezentována i v grafické podobě. Jde o metodu Phase plot, tedy zobrazení na fázovém prostoru. Jedná se o nejjednodušší metodu. Fázový graf pracuje s časovou řadou celého systému (nebo její určené části). Jde o 2D graf. Obě osy znázorňují časovou řadu systému – aktuální hodnotu a hodnotu zpoždění (tedy předcházející hodnotu). Předcházející hodnota se přibližně rovná derivaci aktuální hodnoty. Fázový graf tímto způsobem poskytuje prostorové zobrazení vývoje dynamického nelineárního systému prostřednictvím jeho trajektorie. Zde zkoumaný systém aproximujeme systémem druhého řádu.

Obrázek 4 obsahuje prostorové zobrazení vývoje systému, který obsahuje data z jízdy řidiče 1 ve vozidlovém simulátoru na okruhu bez snížených viditelnostních podmínek. Na grafu je zřejmé, že se řidič většinu jízdy zdržoval ve vzdálenosti 1,5 m od pravé krajnice. Vertikální osa y nám zobrazuje velikost změny po sobě jdoucích měření. Vzdálenost mezi jednotlivými body představuje rychlost reakce řidiče. Jak často a po jaké době změnil chování v podobě ovládní volantu. Ve skutečnosti může jít o systém mnohem vyššího řádu a aproximace je

velmi nepřesná. Poněkud kvalifikovanější aproximaci umožňuje dále popsaná metoda rekurentního grafu.

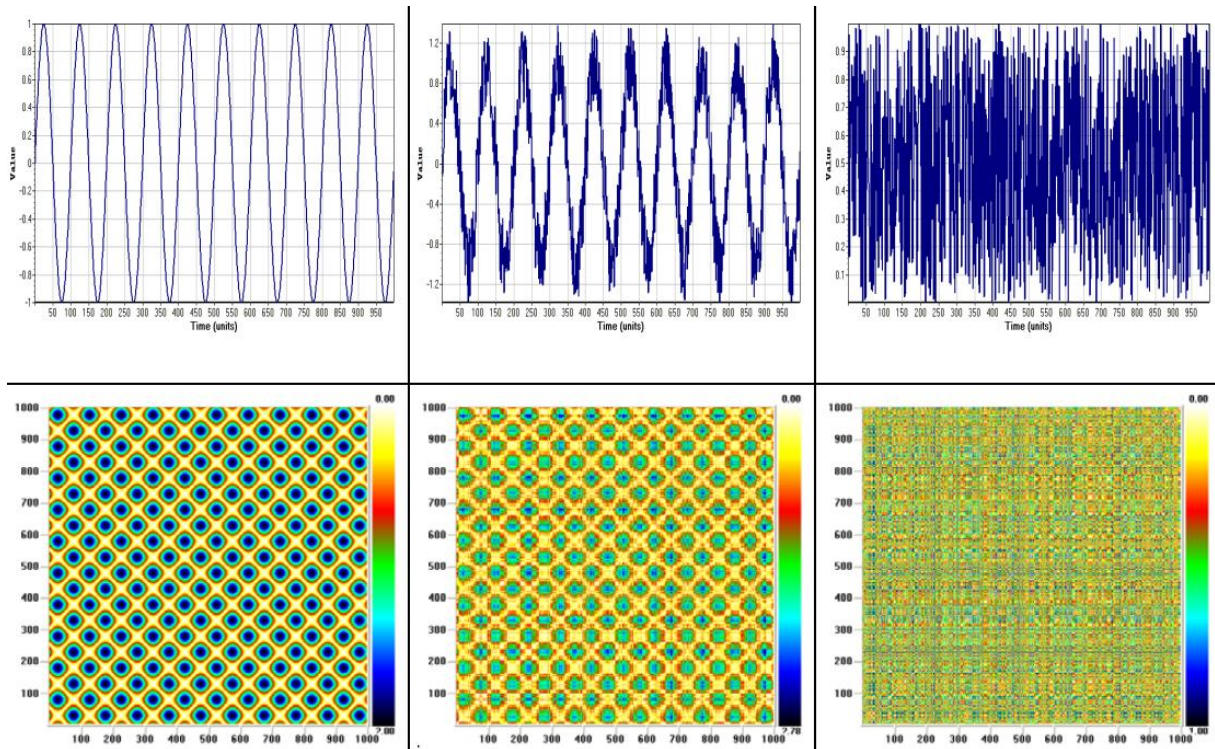


Obrázek 4 – Trajektorie vozidla

3.2. Analýza pomocí rekurentního grafu

Recurrence Plot Analysis je poměrně nová technika, která zkoumá nelinearitu dynamického systému a slouží k posouzení časových řad. Určuje blízkost bodů – měřených hodnot (každý s každým) ve 2D grafu, který obsahuje všechny možné trajektorie generované systémem. Přesněji řečeno zkoumá, zda jednotlivé stavy příslušného systému z dané časové řady jsou sobě blízké nebo od sebe vzdálené podle určitého, předem zvoleného prahu. Vzdálenosti mezi jednotlivými body jsou dány absolutní nebo euklidovskou metrikou. [4] Základním předpokladem rekurentního grafu je teze, že sekvence následných měření se uskutečňuje pomocí dynamického procesu a interakcí mezi danými proměnnými v čase. Jako příklad lze uvést počasí nebo akciový trh. Oba jsou velmi složité systémy, jejichž vývoj ovlivňuje spousta faktorů. U akciového trhu je chování dáno jak ekonomickým, tak politickým prostředím, investory i obchodníky. Všechny tyto složité systémy mají jedno společné a to vzájemné interakce faktorů v daném systému v čase. [13]

Rekurentní graf je grafický nástroj, který zkoumá dynamiku systému. Nabízí nám několik důležitých statistik, které poskytují cenné informace o charakteru našeho procesu. Zobrazuje vzdálenosti mezi všemi páry vektorů v systému několika barvami. Světlé barvy (žlutá, červená a oranžová) zobrazují krátké vzdálenosti mezi vektory, zatímco tmavé barvy (černá, modrá) ukazují velké vzdálenosti. Vzdálenosti mezi vektory zobrazuje pomocí souřadnicového systému x a y , kde obě osy obsahují počet všech zkoumaných veličin, proto se vždy jedná o čtvercovou soustavu. [13]



Obrázek 5- Rekurentní grafy 3 odlišných signálů [14]

Pro lepší představu se na obrázku 5 nachází rekurentní grafy tří signálů. U prvního zleva se jedná o časovou řadu funkce $\sin(t)$. Prostřední graf ukazuje stejnou řadu funkce $\sin(t)$, ale s bílým šumem. Na posledním, pravém obrázku se nachází rekurentní graf náhodného signálu – bílého šumu. Jak je z obrázku zřejmé, každý graf obsahuje na své pravé straně barevnou mapu, která zobrazuje vzdálenosti mezi jednotlivými body. Základní myšlenka interpretace rekurentního grafu je jednoduchá. Je-li signál opravdu náhodný a nemá-li žádnou strukturu, barvy na rekurentním grafu budou jednotné a nevytvoří žádné identifikovatelné vzory. Naopak, bude-li systém deterministický, graf bude popsán odlišnými barvami. [14]

Jelikož osy obsahují stejný počet hodnot, jedná se o graf symetrický podle diagonály (se sklonem 45°). Pro pochopení lze uvést tento příklad časové řady cen (€) určitého produktu na akciovém trhu:

Pondělí: 8029
 Úterý: 7785
 Středa: 7900
 Čtvrtek: 8417
 Pátek: 8452
 Pondělí: 8592
 Úterý: 8975
 ...

$Y_i = (x_i, x_{i-d}, x_{i-2d}, \dots, x_{i-(m-1)d})$, kde i znázorňuje časový index, m zobrazuje dimenzi systému a d je časové zpoždění. Výsledkem je poté $Y = (y_1, y_2, y_3, \dots, Y_{n-(m-1)d})$, kde N se rovná délce původní řady.

Budeme-li předpokládat, že dimenze systému bude 3, tj půjde o diskrétní systém popsany diferenční rovnicí třetího řádu.

Pro $d=1$ a $m=3$ bude výsledek příkladu: $Y_{\text{středa}} = (7900, 7785, 8029)$, $Y_{\text{čtvrtek}} = (8417, 7900, 7785)$, $Y_{\text{pátek}} = (8452, 8417, 7900)$ atd.

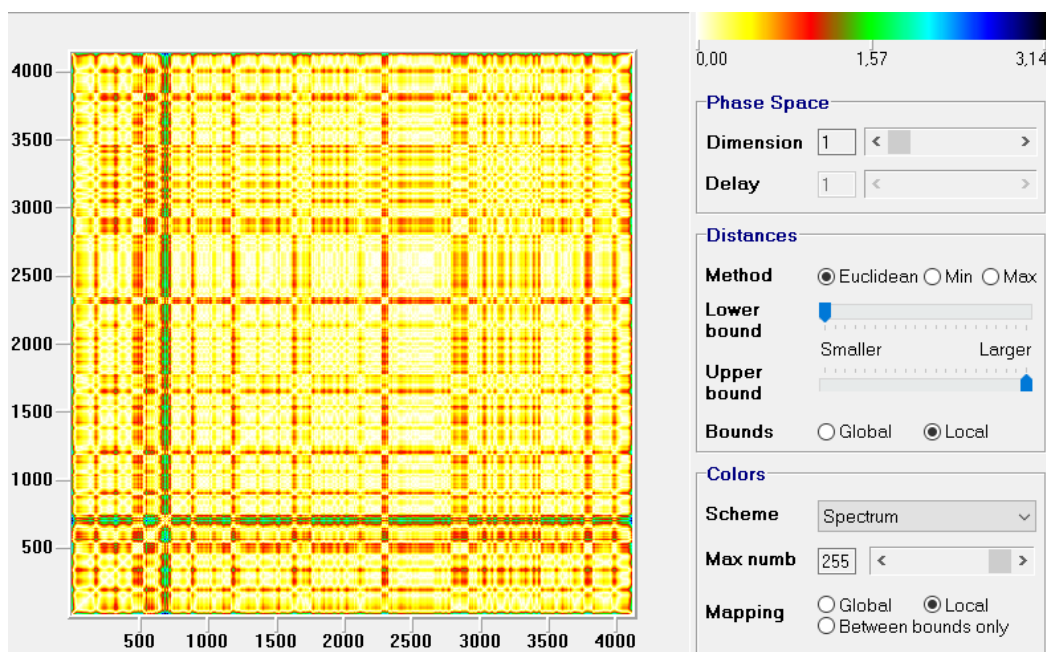
Vzdálenost mezi jednotlivými vektory se pak počítá následovně:

$$\text{Distance}(Y_{\text{středa}}, Y_{\text{úterý}}) = [(7900 - 8417)^2 + (7785 - 7900)^2 + (8029 - 7785)^2]^{1/2} = 583$$

$$\text{Distance}(Y_{\text{středa}}, Y_{\text{úterý}}) = 583$$

Z výsledné struktury můžeme na první pohled vyčíst, o jaký se jedná systém. Jedná-li se o samostatné body, znamená to, že stavy ve fázovém prostoru jsou jedinečné, systém na nich dlouho nezůstává nebo silně fluktuuje. Existuje-li diagonální linie, znamená to existenci nestabilních periodických orbit, což je charakteristickým znakem přítomnosti determinismu. Pokud existují pouze tyto diagonály, jde o periodický signál. Vzdálenosti od jednoho stavu se opakují pravidelně. Vertikální a horizontální linie značí setrvání systému v jednom bodě nebo se z něj jen málo vychylují a systém je tak uvězněn. Pravá strana rekurentního grafu obsahuje mapu barev. Ta definuje vzdálenosti v odpovídající barvě.[12]

Obrázek 6 obsahuje rekurentní graf získaný pomocí software Visual Recurrence Analysis. Na grafu je znázorněna jízda řidiče 1 na vozidlovém simulátoru bez snížených viditelnostních podmínek. Na obrázku není patrná žádná diagonální struktura, tudíž zde neexistuje periodické chování. Jsou zde patrné svislé sloupce, což značí místa, kde se stavy systému odchylojí od ostatních stavů na větší vzdálenost. Dle mapy barev je jasné, že čím je barva tmavší, tím se od sebe dva stavy odchylojí více. Vizuálně je zde možné vyloučit determinismus a periodicity. Rekurentní graf obsahuje z 90% pouze žlutou barvu, i z toho důvodu je zřejmé, že se jedná o systém náhodného chování.



Obrázek 6 – Rekurentní graf jízdy řidiče 1 bez snížené viditelnosti

3.3. Kvantitativní rekurentní analýza

Rekurentní graf je velmi užitečná pomůcka pro zjištění přítomnosti determinismu ve zkoumaných časových řadách. Jelikož je jeho interpretace pouze grafická, závisí také na vizuální schopnosti člověka rozlišovat různé vzory. Oko některých lidí může určité vzory nerozlišit a mohou tak podlehnout tkzv. Optickým klamům. Z tohoto důvodu byla vytvořena rekurentní analýza. Díky ní je možné kvantifikovat vlastnosti rekurentních grafů několika statistikami. Před samotnými statistikami je nutné pochopit dané závislosti:

Statistika

$R_{ij} = 1$, pokud stavy (i,j) jsou rekurentní, $R_{ij} = 0$, jinak.

Délka diagonálního úseku

$D_{ij} = 1$, pokud $(i-1,j-1), (i,j)$ a $(i+1,j+1)$ jsou rekurentní, $D_{ij} = 0$, jinak.

Délka vertikálního úseku

$V_{ij} = 1$, pokud $(i-1,j-1), (i,j)$ a $(i+1,j+1)$ jsou rekurentní, $D_{ij} = 0$, jinak.

Kde i a j jsou rekurentní, pokud vzdálenosti mezi nimi je menší než prahová hodnota.

Počet rekurentních stavů pro stav i

$$RR_i = \sum_{j=1}^N R_{ij} \quad (4)$$

Nechť d je délka jednoho diagonálního úseku a v je délka jednoho vertikálního úseku, pak $P(d)$ a $P(v)$ jsou pravděpodobnosti výskytu diagonálního nebo vertikálního úseku délky d v rekurentním grafu.

$$P(d) = \sum_{i,j=1}^N (1 - R_{i-1,j-1})(1 - R_{i+1,j+1}) \prod_{k=0}^{d-1} R_{i+k,j+k} \quad (5)$$

$$P(v) = \sum_{i,j=1}^N (1 - R_{i,j})(1 - R_{i,j+v}) \prod_{k=0}^{v-1} R_{i,j+k} \quad (6)$$

Rekurentní míra

Jedná se o pravděpodobnost opětovného výskytu určitého stavu. Zjistíme ji jako podíl rekurentních stavů.

$$RR = \frac{1}{N^2} \sum_{i,j=1}^N R_{ij} \quad (7)$$

Míra determinismu

Míra determinismu je spojena s předvídatelností dynamického systému. Čím je vyšší, tím je vyšší předvídatelnost systému. Je definována jako podíl stavů tvořících diagonální úseky na počtu všech rekurentních stavů.

$$DET = \frac{\sum_{v=v_{\min}}^N d P(v)}{\sum_{i,j=1}^N Rij} \quad (8)$$

Laminarita

Pomocí laminarity zjistíme počet ojedinělých stavů v systému. Vypočítáme ji jako podíl stavů tvořících vertikální úseky na počtu všech rekurentních stavů.

$$LAM = \frac{\sum_{v=v_{\min}}^N v P(v)}{\sum_{i,j=1}^N Rij} \quad (9)$$

Trend

Jde o trend, který je regresní koeficientem lineárních závislosti mezi hustotou rekurentních stavů v jedné linii paralelní s diagonálou a její vzdálenosti k diagonále. Poskytuje informace o stacionaritě systému.

$$TREND = \frac{\sum_{i=1}^N \left(i - \frac{N}{2}\right) (RR_i - RR_i)}{\sum_{i=1}^N \left(i - \frac{N}{2}\right)^2} \quad (10)$$

Nejdelší diagonální úsek

Délka diagonálních linií je spojena s dobou, kdy části trajektorie systému běží vedle sebe, převrácená hodnota nejdelší diagonálního úseku se považuje za přibližný odhad nejvyššího Ljapunovova exponentu.

$$MAXLINE = \max (\{d_i | i = 1, \dots, N_d\}) \quad (11)$$

Informace o komplexnosti deterministické struktury

Jedná se entropii, která poskytuje informace o komplexnosti struktury.

$$ENTR = - \sum_{d=d_{\min}}^N p(d) \ln (p(d)) \quad (12)$$

Průměrná doba zdržení systému v jednom ojedinělém stavu

Doba v pasti TT (tramping time) je definována jako průměrná délka všech vertikálních linií.

$$TT = \frac{\sum_{v=v_{\min}}^N v p(v)}{\sum_{v=v_{\min}}^N p(v)} \quad (13) \quad [12]$$

3.4. Střední vzájemná informace

Střední vzájemnou informaci je možné využít pro zjištění hloubky paměti nelineárního dynamického systému. Tedy nejstarší hodnoty, která má vliv na okamžitý průběh fázové trajektorie. Pro pochopení této problematiky je nutné vysvětlit několik pojmů z Teorie informace.

3.4.1 Informace

Za informace považujeme údaje, čísla, znaky, zprávy, oznámení. Za informaci můžeme považovat i samotný obsah zprávy či sdělení. V informatice se jedná o obsah jakéhokoliv oznámení (údaje o čemkoliv). [15] Jedná se o omezení neurčitosti. [1]

Informacemi se zabývají dva obory – informatika a teorie informace. Obsah sdělení a význam zprávy řeší informatika, množstvím a měřením informací se zabývá teorie informace. Pro toto měření informačního množství se využívá název vypůjčený z fyziky a to entropie. [15]

Rozlišujeme informaci syntaktickou, sémantickou a pragmatickou. Syntaktická se zabývá uspořádáním symbolů nesoucích zprávu, sémantická se zabývá významem zprávy a pragmatická zachycuje hodnotový pohled na zprávu. Zde se budeme zabývat informací syntaktickou.

3.4.2 Entropie

Množství informace ve zprávě měříme na základě odstranění neurčitosti, kterou zachycujeme pomocí entropie. Entropie (informační entropie) je střední hodnota informace připadající na jeden symbol, je vyjádřena vzorcem:

$$H = \frac{I}{n} = -K \sum_{i=1}^s P_i \ln P_i \quad (14)$$

kde H = entropie,

n = délka zprávy

K = konstanta (závisící na volbě jednotek)

P_i = pravděpodobnost výskytu symbolu i, z intervalu (0,1) – (ne, ano)

I = informace, kterou měříme v bitech

Pro zprávu o délce n=1 ve dvojkové abecedě:

$$I = K \ln 2 = 1, K = \frac{1}{\ln 2} \text{ (bit)} \quad (15) \quad [1]$$

Jednotku volíme jako informaci nesenou jedním symbolem nejjednodušší – dvojkové abecedy.

3.4.2.1 Vlastnosti entropie

Entropie $H(X) = 0$, jsou-li všechny pravděpodobnosti kromě jedné rovny nule a právě jedna pravděpodobnost rovna jedné. Pak hodnota signálu ($P = 1$) nastává s jistotou (není zde žádná neurčitost).

Naopak, jsou-li pravděpodobnosti výskytu všech hodnot jsou stejné, platí: $P(x_1) = P(x_2) = \dots = P(x_s) = 1/s$, potom dosahuje entropie svého maxima, tedy:

$$H_{\max}(X) = \log_2 s. \quad (16) \quad [1]$$

3.4.3. Vlastnosti střední vzájemné informace

Použití střední vzájemné informace umožňuje určit odhad hloubky paměti systému. Střední vzájemná informace měří sílu závislosti dvou nebo více veličin. Nezávisí na to jestli jde o veličiny generované systémem lineárním či nelineárním. Pomocí střední vzájemné informace sledujeme sílu závislosti daného vzorku na vzorku o krok, dva kroky atd. až o n kroků zpožděných. Pokud u k -tého vzorku klesá střední informace k nule, nenesou vzdálenější vzorky již žádnou podstatnou informaci pro původní vzorek a příslušný počet zpožděných kroků vlastně udává hloubku paměti.

Střední vzájemná informace udává, v jaké míře závisí obdržená zpráva Y na zaslané zprávě X , tedy: máme-li dva signály x_i a y_j , které jsou na sobě závislé. Neurčitost výběru hodnoty x za předpokladu znalosti hodnoty y je dána podmíněnou entropií $H(X/Y)$.

Jedná se nezápornou funkci, $T(X:Y) \geq 0$. Je symetrická, $T(X:Y) = T(Y:X)$. Je rovna nule, jsou-li x a y statisticky nezávislé veličiny. Je-li $T(X:Y) = \min(H(X), H(Y))$, pak x a y jsou vázány funkční závislostí $y = f(x)$, kde $f(x)$ je monotónní funkce. [1]

$$H(X) - H(X/Y) = T(X:Y), \quad (17)$$

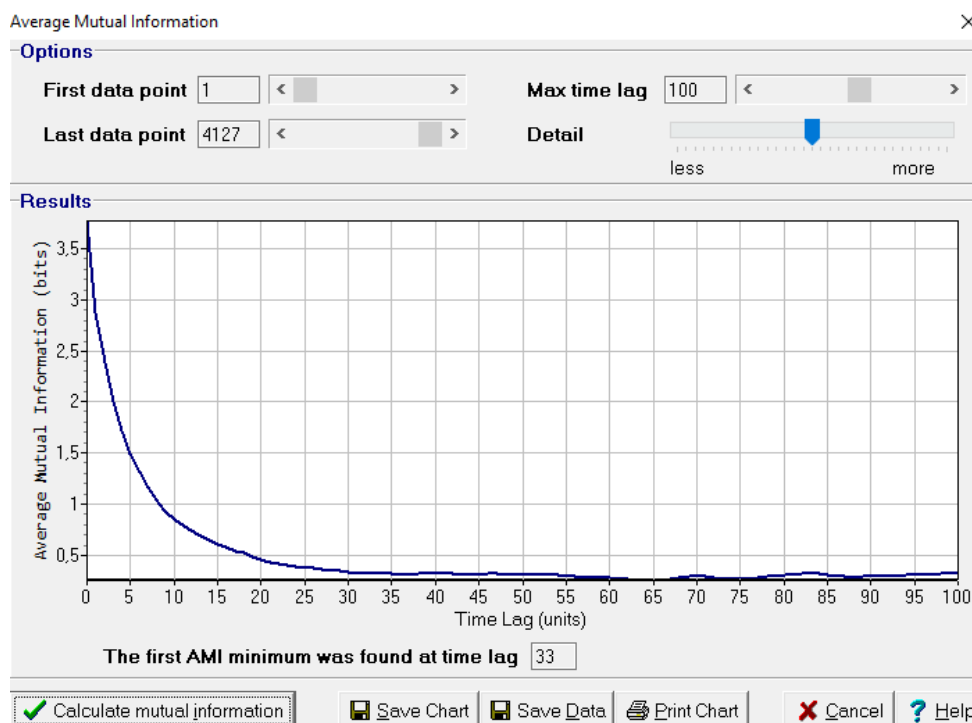
kde $T(X:Y)$ je veličina nazývaná střední vzájemná informace. Chceme-li vyjádřit tuto podmíněnou entropii prostřednictvím entropie sdružené, pak je střední vzájemná informace vyjádřena jako:

$$T(X:Y) = H(X) + H(Y) - H(X, Y). \quad (18)$$

Technika původně vychází z Teorie informace. To vysvětluje, proč se zde nachází vysvětlení pojmů z tohoto odvětví a proč jsou výsledné hodnoty dány v bitech. [6] Tato funkce hledá první minimum, které je poté považováno za místo, které obsahuje nejméně informací o dalším vzorku. Základem je dobrá volba časového zpoždění T , které je dáno stavem systému $X(t)$. Střední vzájemná informace je odpovědí na otázku: „Je dáno měření $X(t)$, kolik bitů

může být průměrně předpovězeno při $X(t+T)$ “. Graf této funkce kolísá – roste, klesá, roste. Tam, kde dosáhne svého prvního minima, tam se nachází hledané místo.[13]

Na obrázku 7 se nachází ukázka zjištění střední vzájemné informace. Jde o výpočet pomocí softwaru Visual Recurrence Analysis, který zjišťuje střední vzájemnou informaci u dat získaných z jízdy řidiče 1 (na vozidlovém simulátoru) bez snížených viditelnostních podmínek. Data zachycují vzdálenost vozidla od pravé krajnice vozovky. Software zde zachytil první minimum ve stopě 33. To znamená, že nejnižší hodnota střední vzájemné informace byla nalezena ve 33% ujeté dráhy.




Obrázek 7 – Zjištění střední vzájemné informace pomocí softwaru VRA

3.5. Ljapunovův exponent

Jak už bylo zmíněno, chaotické systémy vystihuje jejich velká citlivost na počáteční podmínky. Stupeň chaotičnosti je možné vyjádřit parametrem, který je nazýván jako Ljapunovův exponent. Exponent vyjadřuje růst nekonečně malé chyby v čase. Jedná se o základní nástroj sloužící pro popis dynamického systému. Výpočet stupně chaotičnosti je poměrně obtížně zvládnutelný. Problémy, které zde existují, jsou ale vyváženy informacemi, které jejich nalezením získáme. Exponenty svými hodnotami jasně říkají, jak se systém chová.

Ljapunovův exponent ukazuje, zda blízké dráhy atraktoru divergují nebo konvergují. Pro každý systém existuje takových exponentů několik (právě jeden pro každou dimenzi). Nejdůležitější hodnota je ale ta největší. Maximální exponent nejvíce dlouhodobě ovlivňuje chování systému.

Je-li hodnota exponentu záporná – dráhy v čase konvergují a dynamický systém není na počáteční podmínky citlivý. Je-li ale exponent kladný, vzdálenosti mezi blízkými dráhami v čase exponenciálně rostou a systém je na počáteční podmínky citlivý. Zobrazení takových drah se nachází na obrázku 8. Chaotický systém musí mít minimálně jeden tento exponent kladný. Tzn., že v alespoň jednom směru se od sebe musí sousední trajektorie exponenciálně vzdalovat. [16]



Obrázek 8 - Divergující dráhy atraktoru [16]

Trochu přesněji, pro dynamický systém s diskrétním časem $X_{n+1} = f(x_n)$ lze časový vývoj odchylky vyjádřit diferenciálem $dx_{n+1} = J(x_n) * dx_n$, kde

$$J_{ij} = \frac{df_i}{dx_j} \quad (19)$$

Je Jacobiho matice parciálních derivace zobrazení f . Jelikož se jedná o velmi složitou matematiku a exponent není jednou z analýz této diplomové práce, největší Ljapunovův exponent je pak:

$$\lambda_{\max} = \sup \lambda(y(0)) \quad (20) \quad [17]$$

Přesný popis výpočtu se nachází v [17].

Další možností výpočtu je Wolfův algoritmus neboli volba několika blízkých bodů, které necháme v čase rozvíjet a zároveň sledujeme rychlost růstu této jejich vzájemné vzdálenosti. [14]

3.6. Metoda nepravých sousedů

Metoda nepravých sousedů zaručuje, že body v rekonstruovaném stavovém prostoru jsou sousedy v důsledku dynamiky systému a ne z důvodu malého počtu rozměrů rekonstruovaného prostoru. Určuje dostatečnou dimenzi vnoření, která nám udává informaci o řádu diferenciální rovnice, kterou nejlépe aproximujeme daný dynamický systém. Jestliže tuto dimenzi vnoření zvolíme nízkou, dva body (v původním, neznámém prostoru byly daleko od sebe) budou v rekonstruovaném prostoru naopak velice blízko. Metoda tvoří postupně ze

skalárních dat vektory v dimenzi $d=1$, $d=2$, atd. Poté v každé dimenzi najde pro všechny tyto body nejbližšího souseda a uloží si jeho vzdálenost. Následně zvýší dimenzi o 1 a porovná vzdálenosti. Pokud se tato vzdálenost výrazně liší, šlo o nepravého souseda. Postup metoda opakuje tak dlouho, dokud počet nepravých sousedů není dostatečně nízký. [18]

4. EXPERIMENT

Cílem experimentu je posouzení pozornosti řidiče pomocí nelineární analýzy dat. Data jsou rozdělena do dvou částí – posouzení pozornosti řidiče ve snížených viditelnostních podmínkách a posouzení pozornosti řidiče při nedostatku spánku, tedy při únavě. Výsledky byly získány z vozidlových simulátorů Fakulty dopravní ČVUT. Experiment snížené viditelnosti byl proveden v červnu roku 2014 za účelem mé bakalářské práce [19], kde jsem s daty také pracovala. Únava řidičů byla provedena pro účely disertační práce [20]. Celkem bylo zpracováno 55 datových souborů vzniklých ve vozidlových simulátorech. 11 řidičů absolvovalo 3 měření pozornosti řidičů a 4 řidiči se zúčastnili 6 měření únavy řidičů.

4.1. Tvorba a průběh experimentu – snížená viditelnost

Experiment byl proveden na vozidlovém simulátoru napodobující Škodu Octavia II. Zde jel každý řidič 3x stejnou trasu a to ve 3 různých viditelnostních podmínkách. Trasa byla vedena v polích mezi vesnicemi po silnici 2. třídy, aby obsahovala co největší počet směrových oblouků. Silnice měla klasický asfaltový povrch s 2 jízdními pruhy. Řidiči vyjeli z parkoviště v jedné z vesnic a projeli okruh o délce 5,2 km, kde na stejném místě opět zastavili. První jízdu absolvovali v husté mlze s viditelností 10 m. Druhé kolo projížděli s viditelností 20 m a poslední okruh jeli bez snížené viditelnosti za jasného dne. Ostatní účastníci silničního provozu v simulaci byli záměrně vypnuti, okolní provoz tak byl nulový.

4.1.1. Měřené osoby

11 osob, které se experimentu zúčastnili, tvořilo náhodně působící skupinu. Jedinou podmínkou bylo držení řidičského oprávnění. Ze všech účastníků bylo 73% mužů a 27% žen. 70% řidičů bylo 22 let.

4.1.2. Data

Při každé jízdě vznikl samostatný datový soubor v programu Matlab s naměřenými hodnotami. Pro účel této diplomové práce jsem využila hodnoty času (vzorkování po 8 ms) a vzdálenosti vozidla od středu jízdního pruhu [m]. Tohoto experimentu se zúčastnilo 11 řidičů s tím, že každý projel všechny 3 druhy viditelností, vzniklo tedy 33 datových souborů.

Pro práci s daty jsem všechna měření neexportovala do softwaru Microsoft Excel. Převzorkovala jsem časové hodnoty na každé 10. zaznamenání, tedy vzniklo vzorkování po

80 ms. Vzdálenost od centra pruhu jsem přepočítala na vzdálenost vozidla od pravé krajnice a to z důvodu, aby se u obou experimentů (viditelnost i únava) využívalo stejných veličin.

4.2. Tvorba a průběh experimentu – únava řidičů

Experiment únavy byl také proveden na vozidlovém simulátoru. Zde se jednalo o dlouhé měření, které trvalo od dopoledne prvního dne do rána druhého dne. Řidiči během tohoto měření nesměli usnout. Jedna jízda obsahovala tři stejné okruhy o celkové vzdálenosti 28 950 m. Trvání jedné jízdy bylo zhruba 22 min. Celou dráhu byla snaha projíždět rychlostí 80 km/hod. Tento experiment je zaměřen zejména na zkoumání únavových stavů, které jsou navozovány postupnou spánkovou deprivací. Poprvé tento experiment proběhl v květnu roku 2003. [20]

4.2.1. Data

I zde po každé jízdě vznikl datový soubor v programu Matlab. Z naměřených hodnot jsem využila zaznamenání času (s) a odchylky od pravé krajnice (m). Jelikož se u vizuálních analýz jedná o porovnání trajektorií unavených versus neunavených řidičů a posouzení struktur jízd též unavených a neunavených řidičů, pracovala jsem pouze s první a poslední jízdou. U nevizuálních analýz jsme pro přesné výsledky využila vždy šest jízd. Jedná se zhruba o tyto časy:

1. 10:00 hod
2. 14:00 hod
3. 20:00 hod
4. 00: 00 hod (druhého dne)
5. 03:00 hod
6. 06:00 hod.

Řidiči samozřejmě mezi jednotlivými jízdami nespali. Díky tomuto měření je možné zjišťovat, zda jízda unavených řidičů vyvolává chaotické chování.

Data jsem opět neexportovala do Microsoft Excelu. Zde jsem využila vzorkování po každém 100 zaznamenání, tudíž jednotlivé hodnoty byly po 0,3375 s (to odpovídá 7,5 m). Jednotlivé jízdy jsou pojmenovány iniciálami řidičů a časem měření. Jedná se o HV, ML, OS a PV (u HV_1009 jde o jízdu řidiče H. V. v 10:09 hod).

4.2.2. Měřené osoby

V celkovém souboru testovaných osob byla nejčastěji zastoupena skupina „mladých“ osob ve věku cca 22-28 let (osoby z řad studentů), vlastně pouze u dvou testovaných osob byl věk vyšší (v jednom případě nad 30 let a v druhém případě nad 60 let. [20])

4.3. Práce s naměřenými daty

Rekurentní graf

Pro získání rekurentního grafu bylo nutné data upravit tak, aby vznikl textový soubor pouze s naměřenými, již upravenými (převzorkovanými) daty. Tyto textové soubory, vytvořené ze všech 44 jízd, se jednoduše nahrály do softwaru Visual Recurrence Analysis – viz kapitola 5, který rekurentní graf zpracoval. To, jak program rekurentní graf vytváří, je již v této práci popsáno – kapitola 3.2.

Graf fázového prostoru

Graf fázového prostoru byl zpracován v Microsoft Excel, kde jsem k již převzorkovaným naměřeným hodnotám přidala sloupec s rozdílem dvou po sobě jdoucích naměřených hodnot. Vznikly tak odchylky mezi jednotlivými hodnotami vzdálenosti od pravé krajnice vozidla. Tyto veličiny jsem zanesla do bodového grafu, který zobrazuje trajektorii řidičů jak při řešení pozornosti, tak při únavě. Všechny tři jízdy s rozdílnou viditelností byly zaneseny do jednoho grafu pro porovnání chování. Pro znázornění detailu trajektorií byla data u experimentu pozornosti dále upravena na každou 33. naměřenou hodnotu (šlo o soubor dat o počtu 3300, proto byla zvolena hodnota 33.). Grafy detailu trajektorií jsou vypracovány na příloženém CD.

Rozptyl

Pro číselné zjištění rozdílu trajektorií v experimentu pozornosti bylo využito charakteristiky variability – rozptylu (=disperze). Díky němu je možné určit, jak se řidiči s klesající viditelností vzdalují či přibližují pravé krajnici vozovky. Rozptyl udává, jak jsou hodnoty v daném souboru rozptýleny a vypočteme ho jako:

$$\text{Var}(X) = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2 \quad (21)$$

kde N je počet všech naměřených hodnot, X_i je naměřená hodnota i a \bar{X} představuje průměrnou hodnotu souboru. [21]

Střední vzájemná informace

Střední vzájemná informace byla zjištěna pomocí softwaru Visual Recurrence Analysis. Všechna naměřená data byla převedena do textového souboru, který se poté nahrál do softwaru. Podrobnější popis práce s VRA se nachází v příloze H – Manuál k získání rekurentního grafu, střední vzájemné informace a falešných sousedů v softwaru VRA. Opět se zde pracovalo s hodnotami vzdálenosti od pravé krajnice. Pro získání přesnějších výsledků bylo nutné vyhodnocovat nejen celé časové řady získané v obou experimentech, ale také určité úseky.

Falešní sousedé

I u analýzy falešných sousedů bylo využito softwaru VRA. Opět je vše popsáno v manuálu v příloze H. Tato metoda byla použita pouze pro experiment únavy. Pomocí VRA byla získána dostatečná dimenze vnoření a procento falešných sousedů. Software nám nabídne jak číselné vyhodnocení vložené časové řady, tak i grafické znázornění.

5. SOFTWARE – VISUAL RECCURRENCE ANALYSIS

Visual Recurrence Analysis (VRA), v překladu Vizuální nelineární rekurentní analýza, je softwarový balíček určený pro analýzu a posouzení topologií systémů a stacionární predikci nelineárních a chaotických časových řad. Hlavní využití VRA spočívá v zobrazení a využití rekurentních grafů, které slouží k analýze dynamických systémů. Další funkce tohoto softwaru, která byla využita v této diplomové práci je analýza Střední vzájemné informace – Mutual information. [13]

Program je napsán v programovacím jazyce C++. První verze byla vydána v roce 1996. Od té doby je pravidelně aktualizována a to několikrát do roka. Získal nejvyšší 5 hvězdičkové ohodnocení od softwarových kritiků. VRA je využíváno v mnoha oborech, jako příklad lze uvést optiku, ekonomiku, matematiku, fyziku, akustiku nebo ekologii. Software je volně dostupný a nachází se na přiloženém CD. [13]

Autorem VRA je ruský inženýr Eugene Kononov žijící v Americe. Pracuje jako Java Developer pro mezinárodní společnost ve Springfieldu v Massachusetts, ale ve volném čase se věnuje nelineárním dynamickým systémům, teorii chaosu a financím. Roku 1996 tento program napsal v programovacím jazyce C++ za účelem analýz finančních časových řad. [13]

6. VÝSLEDKY MĚŘENÍ


6.1. Analýza fázového prostoru

6.1.1. Pozornost řidičů

Průběhy trajektorií jednotlivých jízd jsou znázorněny ve fázové rovině, kde na vodorovnou osu vynášíme polohu vozidla (vzdálenost vozidla od pravého okraje dopravního pruhu). Na svislou osu vynášíme rychlost této změny.

Obě skupiny experimentů, pozornost i únava, mají společné rysy zpracovaných fázových prostorů. Pro zjištění tvaru křivky fázového prostoru všech 33 naměřených souborů byla provedena detailní analýza trajektorií s využitím různých vzorkování (zkrácení dat až na každý 33 vzorek).


Chování s převzorkovanými daty je zobrazeno na obrázku 12, kde se nachází trajektorie jízdy řidiče 2 v experimentu měření pozornosti. Ostatní detailní grafy jízd jsou k nahlédnutí na přiloženém CD. Jak bude vidět níže a v přiložených grafech, všechny výsledné trajektorie mají velmi podobné chování. Křivky vývoje systémů v čase krouží kolem nulové hodnoty osy y . Vypadá to, jako by systém dostával do limitního cyklu. Každý tento stav ale po určité době opustí a začne se velmi podobně vyvíjet o kus dále. Dá se tedy říci, že se trajektorie řidičů chová chaoticky.



Obrázek 9 – Trajektorie jízdy řidiče 2 bez snížené viditelnosti

Obrázek 13 zobrazuje trajektorii všech tří jízd řidiče 1 v experimentu pozornosti. Z tohoto fázového prostoru je zřejmé, že s rostoucí viditelností se zvyšuje vzdálenost od pravé krajnice. Čím jasnější byla viditelnost, tím se řidiči více vzdalovali pravé krajnici. Bez snížené

viditelnosti se řidič dostal až do vzdálenosti více jak 3 m. Při husté mlze, tedy ve viditelnosti 10 m se řidič držel ve svém pruhu. Osa y, znázorňující velikost změny mezi vzdáleností od pravé krajnice dvou po sobě jdoucích hodnot, vykazuje opačný trend. S rostoucí viditelností extrémní odchylek klesají. Nejstabilnější jízda tedy nastává při nesnížené viditelnosti. Grafy řidičů 2 – 11 se nacházejí v příloze A – Grafické zobrazení pohybu řidičů – pozornost řidičů.




Obrázek 10 - Porovnání trajektorie všech jízd řidiče 1

6.1.2. Únava řidičů

Při grafickém zobrazení trajektorie řidiče a porovnání první odpolední jízdy a poslední ranní jízdy vyšly najevo u všech 4 řidičů stejné závěry. Osa x, znázorňující vzdálenost vozidla od pravé krajnice, v případě prvních jízd (bez únavy řidiče) dosahovala hodnot maximálně do 3 m. Řidiči se drželi na silnici bez jakýchkoliv problémů. Při posledních jízdách už tomu tak nebylo. Jak je patrné z obrázku 14, při ranní jízdě řidič několikrát sjel ze silnice. Hlavní ukazatel, osa y, která znázorňuje velikost změny vzdálenosti od pravé krajnice, se v obou jízdách také velmi liší. První okruh zajeli řidiči s odchylkami 0,6 m až (-0,5) m. Jízda byla mnohem stabilnější, netrhali volantem. Jízda unavených řidičů nad ránem ukazuje změny mezi dvěma za sebou zaznamenanými hodnotami až 2 m. Postupně se jedním pohybem dokázali odchýlit až o 2 m. Vzdálenosti mezi jednotlivými body v grafu ukazují, jak byl řidič při ranní jízdě unavený. Reagoval mnohem pomaleji než při první jízdě. V porovnání s poslední jízdou nejsou body ani viditelné. Únava řidičů je nepřehlédnutelná. Grafy ostatních řidičů jsou umístěny v příloze B: Grafické zobrazení pohybu řidičů – únava.

Zobrazení pohybu řidiče HV - experiment únava



Obrázek 11 – Porovnání trajektorie obou jízd řidiče 1

6.2. Analýza struktury systému pomocí rekurentních grafů

6.2.1. Pozornost řidičů

Analýza zkoumající strukturu systému přinesla celkem jednoznačné závěry a to pro všechny skupiny měření (okruh bez snížené viditelnosti, za viditelnosti 20 m a za viditelnosti 10 m). Rekurentní graf pracoval se vzdáleností vozidla od pravé krajnice po celou dobu daného experimentu. V žádném ze získaných grafů se nenachází diagonální linie (samozřejmě kromě úhlopříčky grafu, která se díky čtvercovitému tvaru musí nacházet všude). Žádná z jízd nebyla systémem deterministickým, nenacházely se zde žádné periodicity. Nejčastějším jevem jsou svislé čáry, které znázorňují stavy, jenž se od ostatních jevů odchyľují na největší vzdálenost.

Jelikož jsou si struktury všech jízd řidičů velmi podobné, je zde jasné, že různé intenzity snížené viditelnosti nevyvolávají chaotické chování řidičů.

Například řidič 1 má nejjasnější vychýlení ve vzorku 700, ve kterém se delší dobu vychyloval na vzdálenost 1,57 m od pravé krajnice. Kvůli velkému počtu se všechny rekurentní grafy se nacházejí na přiloženém CD. Grafy řidičů 1-4 jsou zobrazeny v příloze C – Rekurentní grafy pozornosti řidičů.

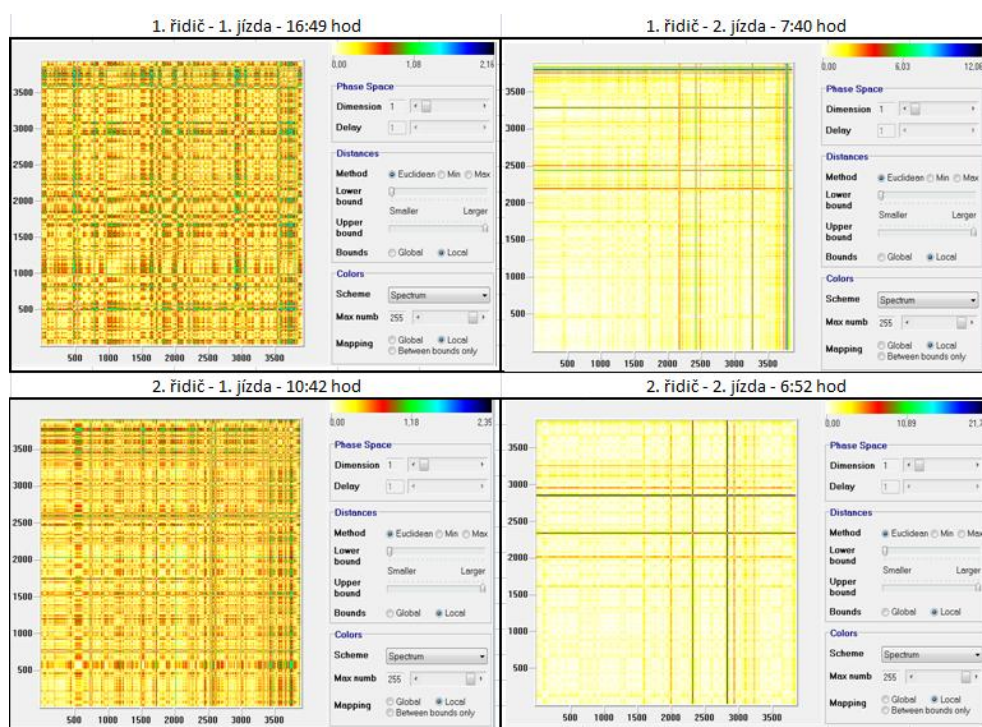
Dalším závěrem této analýzy je maximální vzdálenost řidičů od pravé krajnice. Barevné mapy, které se nachází na pravé straně zpracovaných rekurentních grafů v příloze, ukazují vzdálenosti zobrazené na grafu v určité barvě, tudíž lze vyčíst také maximální vzdálenost, v tomto případě, vozidla od pravé krajnice. Z rekurentního grafu lze vyčíst počet vzorků, se kterým software pracoval. Víme tedy, o jaký počet zaznamenaných dat se v daném měření jednalo.

Za nesnížené viditelnosti bylo průměrně naměřeno - 2773 dat, za viditelnosti 20 m - 4091 dat a za viditelnosti 10 m se jednalo průměrně o 6000 dat. Z toho vyplývá, že řidiči s rostoucí mlhou zpomalovali – jeli delší dobu, proto bylo naměřeno více dat.

Bez snížených viditelnostních podmínek byla průměrná maximální vzdálenost od pravé krajnice 3,8 m, za viditelnosti 20 m - 3,2 a za viditelnosti 10 m - 2,6 m. Čím větší vzdálenost viditelnosti byla na simulátoru spuštěna, tím se řidiči více odchylovali od pravé krajnice.

6.2.2. Únava řidičů

Rekurentní grafy chování řidičů při sledování únavy vykazovaly dva jevy. Všechny první jízdy řidičů (tedy bez únavy) jsou v grafu zobrazeny jako mozaiky. Tyto mozaiky se velmi podobají bílému šumu. Naopak poslední, ranní jízda se vždy zobrazila jako čistý, žlutý graf se svislými čarami. Opět ani v jednom případě nelze říct, že se jedná o deterministický systém. Obrázek 9 představuje rekurentní grafy řidičů 1 a 2. Grafy ostatních řidičů jsou umístěny v příloze D - Rekurentní grafy únavy řidičů.



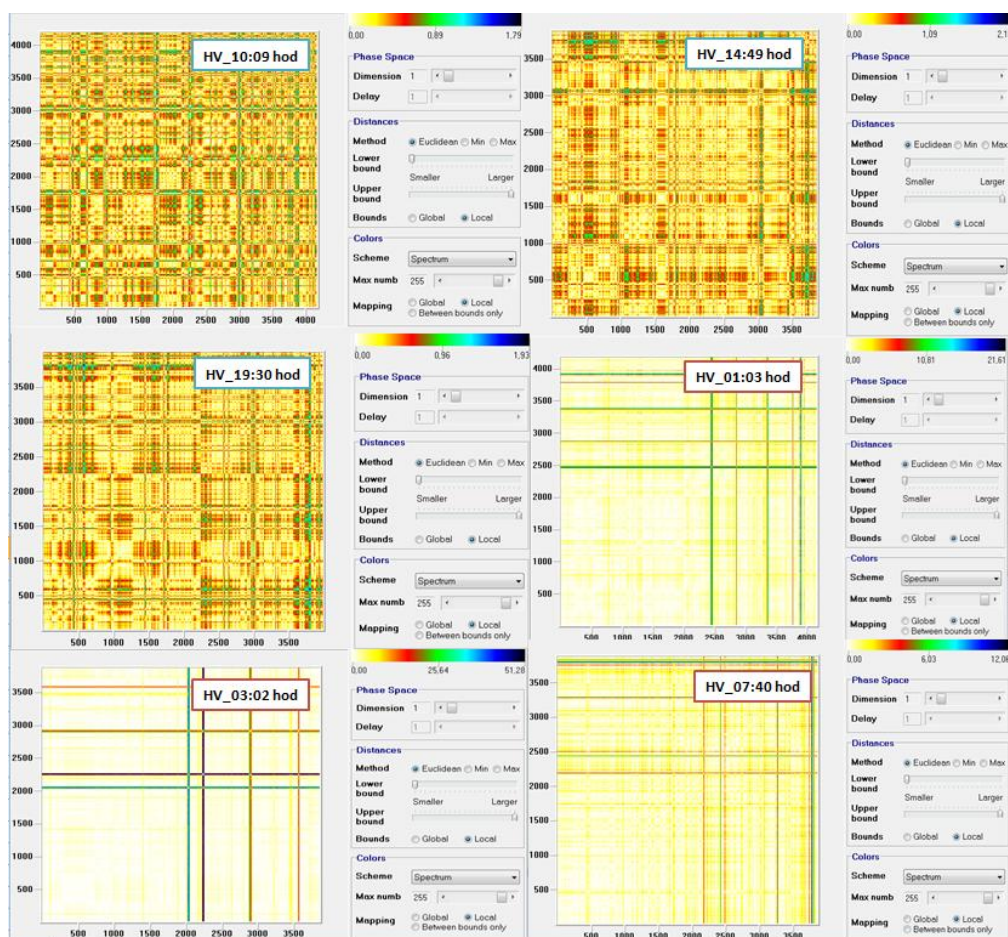
Obrázek 12 - Rekurentní grafy řidičů 1 a 2 z měření Únavy

Co je velmi zajímavé, že jsou si rekurentní grafy všech 4 řidičů velmi podobné. Na první pohled až stejné. Všechny první jízdy obsahují stejnou škálu barev a to téměř i ve stejném množství. Na první pohled je zřejmé, že jízdy neunavených řidičů vykazovaly mnohem více determinismu než poslední, ospalé jízdy. Ty jsou vcelku vybarveny pouze žlutou barvou a to bez žádných vzniklých struktur. Ovšem oproti analýze pozornosti řidiče, zde se od sebe

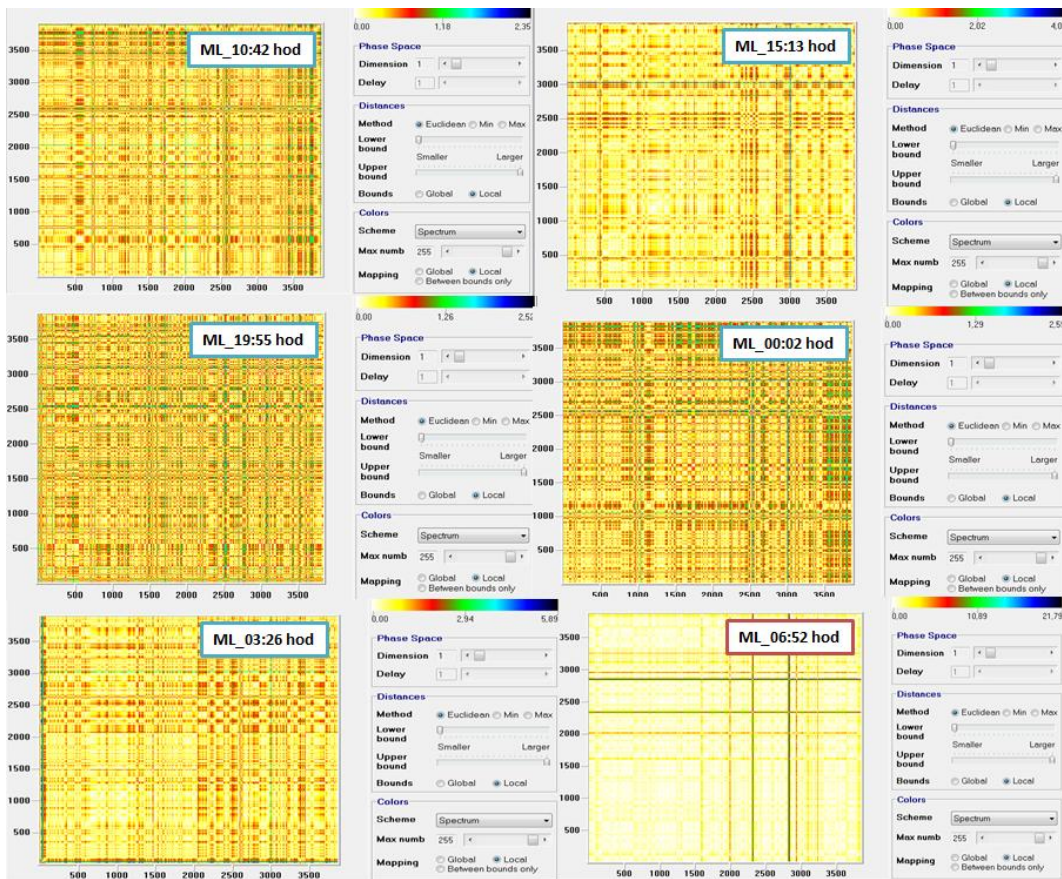
struktury systémů stejného řidiče vždy liší. Vizuální analýza ukázala, že únava řidičů vykazuje známky chaotického chování.

Průměrné hodnoty maximální vzdálenosti od pravé krajnice jsou zde u jednotlivých skupin velmi rozdílné. Při první jízdě se řidiči drželi zhruba ve svém pruhu, průměrně tedy v maximální vzdálenosti 1,89 m od pravé krajnice. Při poslední ranní jízdě šlo průměrně o maximální vzdálenost 14,5 m, což znamená absolutní vychýlení řidičů ze silnice, což podle barevných map nastalo u všech ranních jízd řidičů.

Obrázek 10 a 11 slouží k porovnání chování dvou řidičů. Na obrázku 10 se nachází všech 6 jízd řidiče HV. Z grafů je zřejmé, že po 00:00 hod nastala změna v řidičově chování. Evidentně přišla únava. Oproti tomu u řidiče ML (obrázek 11) nastala únava až v ranních hodinách. První změna je evidentní až v poslední jízdě v 6:52 hod. Z těchto dvou jízd je patrný rozdíl v příchodu únavy. U řidiče HV nastala hned po půlnoci, kdežto u řidiče ML až v poslední ranní jízdě.



Obrázek 13 - Rekurentní graf všech jízd řidiče HV



Obrázek 14-Rekurentní graf všech jízd řidiče ML

V příloze E: Rekurentní grafy únavy řidičů – všechny jízdy řidičů OS a PV. U řidiče OS nastala viditelná změna chování ve 4:17 hod. Zajímavé jsou výsledky řidiče PV, který má strukturu všech jízd podobnou těm, které nastaly u jiných řidičů až v posledních jízdách. Žádná velká změna v chování u tohoto řidiče patrná není. Je možné říci, že byl řidič unavenější po celou dobu měření, ovšem rostoucí trend únavy nalezen nebyl.

Jak už bylo řečeno, celá tato analýza je pouze vizuální. Pro číselné vyjádření struktury systému je možné využít poměrně složitou kvantitativní rekurentní analýzu, která je popsána v kapitole 3.3..

6.2.2.1. Disperze

Z grafického zobrazení pohybu řidičů (obrázek 13 + ostatní na CD) je patrné, že čím nižší byla viditelnost, tím se řidiči více drželi ve svém pruhu. Je překvapivé, že s klesající viditelností narůstala bezpečnost jízdy – řidiči se drželi ve svém pruhu a nevyjížděli do protisměru. Pro doplnění této analýzy je v tabulce 1 stanovena disperze (= rozptyl) vzdáleností od pravé krajnice. Jedná se o všechna měření experimentu pozornost. I zde je klesající trend. Čím je nižší je viditelnost, tím se hodnoty rozptylu snižují. Průměr všech výsledků ukazuje, že rozptyl hodnot je u viditelnosti 10 m více jak 4x nižší než při jízdách bez snížené viditelnosti. To znamená, že se naměřené hodnoty vzdálenosti od pravé krajnice

v podmínkách bez snížené viditelnosti jsou více jak 4x více rozptýlena kolem střední hodnoty než data naměřená při viditelnosti 10 m.

Tabulka 1-Rozptyl hodnot vzdálenosti od pravé krajnice, experiment pozornost

ROZPTYL hodnot vzdálenosti od pravé krajnice [m ²]	Řidič					
Viditelnost	1	2	3	4	5	6
Bez omezení	0,1207	0,174	0,3104	0,2197	0,1465	0,1766
20 m	0,0329	0,0597	0,0951	0,0426	0,0409	0,128
10 m	0,085	0,0893	0,0697	0,0345	0,0539	0,0599
	7	8	9	10	11	Průměr
Bez omezení	0,8266	0,9951	0,3997	0,2369	0,1157	0,338355
20 m	0,192308	0,1807	0,1191	0,1617	0,0899	0,103901
10 m	0,1017	0,0727	0,0969	0,0682	0,0546	0,071491

Tato poněkud překvapivá zjištění naprosto odporují hypotéze, že by jízda unaveného řidiče byla podobná jako jízda řidiče za snížené viditelnosti. Naopak ukazuje se, že čím horší je viditelnost, tím menší je disperze polohy v dopravním pruhu. Neunavený řidič jede tím opatrněji a s menšími odchylkami, čím je horší viditelnost. To je přímo opačné chování než u řidiče unaveného, u kterého s narůstající únavou narůstá disperze polohy i rychlosti.

6.3. Analýza střední vzájemné informace

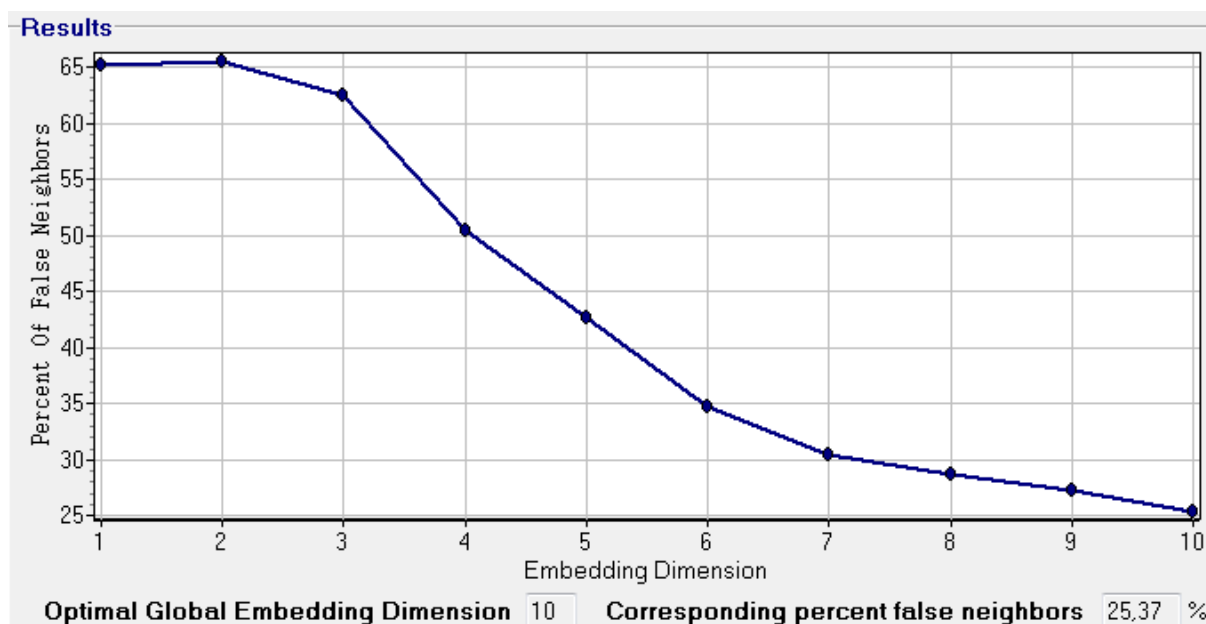
Další hypotéza byla založena na tom, že i velmi unavený řidič jede po krátkou dobu po začátku jízdy velmi dobře (10 – 15 minut jede jako neunavený a teprve později se začíná projevovat únava na větším rozptylu trajektorie). To znamená, že průběh trajektorie je nestacionární (zcela jistě ve střední hodnotě a disperzi) a nabízí se hypotéza, že se v rámci této nestacionarity bude měnit i hloubka paměti. To je zde ověřováno pomocí rychlosti konvergence střední vzájemné informace. Ukázalo se však při pouhém vizuálním porovnání křivek na obrázcích v přílohách F a G (kde se nacházejí výsledky analýzy Střední vzájemné informace pro experiment pozornosti i únavy řidičů), že změny nejsou významné a že rozhodně změny v konvergenci střední vzájemné informace nejsou vhodné jako ukazatel únavy řidiče.

Z výsledku je zřejmé, že odhad informace je velmi citlivý na počet vzorků. Proto byla vypracována také analýza, kde byl proveden výpočet střední vzájemné informace na daných úsecích. Z výsledků jednotlivých úseků uložených na příloženém CD (Střední vzájemné informace – úseky) je patrný rozdíl mezi například první ujetou částí unaveného a neunaveného řidiče. Už ale není jasné, čím je tento rozdíl zapříčiněn. I po podrobnější analýze střední vzájemné informace bylo zjištěno, že toto vizuální porovnání není vhodný ukazatel únavy řidiče.

6.4. Analýza falešných sousedů

Zjištění správné, dostatečné dimenze vnoření metodou nepravých sousedů bylo provedeno pro experiment únavy. Především výsledky ukázaly, že viditelnost nevyvolává chaotické chování. Změna viditelnostních podmínek neovlivnila strukturu systému. Střední vzájemná informace také žádné překvapivé výsledky neukazuje. Proto se zaměřuji pouze na řešení únavy řidičů.

Pomocí softwaru VRA bylo možné zjistit optimální dimenzi vnoření a procento falešných sousedů pro všechny jízdy experimentu únava. Obrázek 15 zobrazuje, jak jednotlivé výsledky vypadaly. Ostatní jsou graficky znázorněny na příloženém CD. Z obrázku je patrné, že dimenze 10 byla vybrána po výpočtech falešných sousedů. Dostatečně nízký počet nastal až v dimenzi 10.



Obrázek 15- Procento falešných sousedů v jízdě řidiče HV v 10:09 hod

V tabulce 2 jsou vypracovány výsledky optimální dimenze vnoření a procentuální hodnota falešných sousedů pro všechny jízdy experimentu únavu. Získané dimenze ani falešní sousedé nevykazují trend ve vztahu ke vznikající únavě. Procento falešných sousedů se průměrně pohybuje kolem 25% a optimální dimenze kolem hodnoty 8. Nelze prohlásit, že jsou výsledky ovlivněny rostoucí únavou.

Tabulka 2- Optimální dimenze vnoření a procento falešných sousedů

Řidič	čas jízdy	Optimální dimenze vnoření	Procento falešných sousedů
HV	10:09	10	25,37%
	14:45	10	21,43%
	19:30	7	24,37%
	1:03	8	19,76%
	3:02	10	27,78%
	7:40	10	25,13%
Průměr HV		9,166666667	23,97%
ML	10:42	8	25,85%
	15:13	6	30,73%
	19:55	7	22,16%
	0:02	8	28,61%
	3:26	9	17,85%
	6:52	8	26,58%
Průměr ML		7,666666667	25,30%
OS	11:49	10	29,64%
	15:54	9	22,63%
	17:45	9	27,37%
	22:46	10	23,54%
	2:20	10	23,54%
	4:17	8	21,00%
Průměr OS		9,333333333	25,02%
PV	10:41	10	26,04%
	15:41	10	26,29%
	18:47	10	26,03%
	22:36	10	25,00%
	1:57	10	29,18%
	7:15	10	26,23%
Průměr PV		10	26,46%

Zajímavostí na těchto výsledcích je propojení s dynamikou řidiče. Struktura dynamiky řidiče se nemění, mění se pouze časové konstanty (parametry modelů). Přenos řidiče jako zpětnovazebního regulátoru je uveden ve vzorci 21, kde $G(p)$ je přenos modelu operátora, K_0 uvádí zesílení operátora, T_L , T_N a T_A představují časové konstanty a T_d je dopravní zpoždění.

$$G(p) = \frac{Ke^{TdP}(T_A p + 1)}{(T_L p + 1)(T_N p + 1)} \quad (22) \quad [22]$$

ZÁVĚR

Motivací k experimentu bylo takové zjištění, že se únava řidičů projevuje velmi markantně na činnosti okohybných svalů. Proto také někteří výrobci nabízejí indikátory únavy řidiče založené na sledování pohybů oka a očních víček kamerou umístěnou před řidičem. Na místě je otázka, zda chování unaveného řidiče, kterému se zavírají oči, nebude podobné chování řidiče jedoucímu za snížené viditelnosti. Tato podobnost ovšem nebyla zkoumána na základě sledování očních pohybů ale na trajektorii vozidla, která je mnohem lépe měřitelná než samotné oční pohyby.

Analýza trajektorií vozidel pomocí fázových prostorů v případě experimentu pozornosti ukázala jasný závěr. S rostoucí viditelností se také zvyšuje vzdálenost od pravé krajnice. Čím nižší byla viditelnost, tím jel řidič opatrněji. Co se týče únavy, každý řidič během ranních, unavených jízd sjel několikrát ze silnice. Unavený řidič také trhal více volantem a reagoval mnohem pomaleji než při jeho první, neunavené jízdě. Už z této první analýzy bylo zřejmé, že na řidiče v posledních jízdách experimentu únavy opravdu přišla ospalost.

Zjištění disperze všech jízd experimentu pozornosti vyvrátila hypotézu, že je jízda unaveného řidiče podobná jako jízda za snížené viditelnosti. Bylo zjištěno, že je tomu přesně naopak. Čím horší byla viditelnost, tím menší existovala disperze polohy v dopravním pruhu.

Pomocí rekurentních grafů bylo zjištěno, že jízdy v případě řešení pozornosti nevykazují deterministické chování. Všechny rekurentní grafy si byly velmi podobné a nezáleželo na viditelnosti. Intenzita snížené viditelnosti nevyvolává chaotické chování řidičů. Také bylo zjištěno, že s rostoucí mlhou řidiči zpomalovali. V případě únavy to bylo jiné. Čím více byl řidič neunavený, tím struktura jeho jízdy ukazovala více determinismu. Jízdy unavených řidičů obsahovaly známky chaotického chování. Díky změnám v rekurentních grafech bylo možné určit, kdy který řidič začal pociťovat únavu. První řidič HV začal být unavený hned po půlnoci, druhý řidič ML až v ranních hodinách, OS kolem 4:17 hod ráno. Ovšem poslední řidič PV byl alespoň podle visuální analýzy unavený po celou dobu měření.

Zpracovaná analýza střední vzájemné informace ukázala pouze to, že pouze visuální porovnání získaných křivek nejsou znatelné významné změny. Proto se tato analýza ukázala visuálně jako nevhodný ukazatel únavy.

Poslední výsledky přinesla analýza falešných sousedů. Zde byla zjištěna optimální dimenze vnoření a procento falešných sousedů pro všechny jízdy řidičů v experimentu únavy. Dimenze ani falešní sousedé neprokázali žádný trend v závislosti na únavě.

Cílem práce bylo potvrdit či vyvrátit hypotézu, zda snížená viditelnost nebo únava řidičů vyvolávají chaotické chování. To vše na základě dat získaných pomocí vozidlového simulátoru a vizuální, nelineární, rekurentní analýzy. Diplomová práce všechny tyto výsledky přinesla a dokázala rozpoznat únavu řidiče na základě dat trajektorií řidičů. Všechny tyto zjištění by tedy mohly pomoci budoucímu výzkumu predikce únavy bez měření očních pohybů ale pomocí snímání trajektorie vozidla.

SEZNAM POUŽITÉ LITERATURY

- [1] KOTEK Zdeněk, VYSOKÝ Petr, ZDRÁHAL Zdeněk *Kybernetika*. Praha SNTL 1990
- [2] Základní pojmy teorie systémů [online]. [cit. 2016-04-16]. Dostupné z: http://www.kip.zcu.cz/kursy/svt/svt_www/5_soubory/5_2.html
- [3] Teorie systémů: Základní pojmy obecné teorie systémů [online]. , 1-3 [cit. 2016-04-16]. Dostupné z: <http://labe.felk.cvut.cz/~obitko/xkui/materialy/systemy.pdf>
- [4] SANJEEV SHARMA: An Exploratory Study of Chaos in Human - Machine System Dynamics, IEEE trans. SMC part A: humansystems, 2006 36(2), 319 - 326
- [5] TIŠNOVSKÝ, Pavel. *Nelineární dynamické systémy: Základní pojmy* [online]. [cit. 2016-04-16]. Dostupné z: <http://www.fit.vutbr.cz/~tisnovpa/fract/clanky/2.htm>
- [6] RAIDL, Aleš, Barbora KLIKOVÁ a Hynek BEDNÁŘ. *Deterministický chaos, meteorologie a klima: Aplikace matematiky pro učitele*. Matematicko-fyzikální fakulta Univerzita Karlova, Praha, 2011.
- [7] STEWART, Ian. *Hraje Bůh kostky?: nová matematika chaosu*. 1. vyd. Praha: Argo, 2009. Zip (Argo: Dokořán). ISBN 978-80-257-0024-2.
- [8] HLADÍK, Michal. *Deterministický chaos - princip a aplikace*. 2006. Bakalářská práce. Univerzita Tomáše Bati ve Zlíně, fakulta aplikované informatiky.
- [9] Fázový prostor [online]. [cit. 2016-04-16]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/1271-fazovy-prostor>
- [10] GLEICK, James, Jaroslav SEDLÁŘ a Martin NĚMEC. *Chaos: vznik nové vědy*. Brno: Ando Publishing, 1996. Nová věda. ISBN 80-86047-04-0.
- [11] Simulace nelineárního dynamického systému: Trojrozměrný fázový prostor [online]. [cit. 2016-04-16]. Dostupné z: <http://www.fce.vutbr.cz/studium/materialy/Dynsys/kap8/kap8a.htm>
- [12] KODERA Jan, VAN QUANG Tran: Vizuální nelineární rekurentní analýza a její aplikace na český akciový trh, *Politická ekonomie* 2009, str. 305-322
- [13] KONONOV, Eugene. Introduction to VRA: About VRA and Its Author. 2006.
- [14] BABINEC, P., M. KUČERA a M. BABINCOVÁ. *Global characterization of time series using fractal dimension of corresponding recurrence plots_ from dynamical systems to heart physiology*. 2005, , 87-93.
- [15] PŘICHYSTAL, Jan. *Úvod do teorie informace* [prezentace]. PEF MZLU v Brně, 2007 [cit. 2016-04-16]. Dostupné z: www.lss.fd.cvut.cz/vyuka/mp/20rks/deterministicky-chaos

- [16] RACKOVÁ, Lenka. Metody vykreslování chaotických atraktorů. Brno, 2009. Bakalářská práce. Fakulta informatiky, Masarykova Univerzita. Vedoucí práce Mgr. Jiří Chmelík.
- [17] POKORNÝ, Pavel. *Deterministický chaos - plod počítačové fyziky*. Ústav matematiky, VŠCHT Praha, Technická 5, 166 28 Praha 6, 2008.
- [18] DĚDIČ, Martin. *Predikce chaotických časových řad*. Praha, 2010. Diplomová práce. VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE, Fakulta informatiky a statistiky.
- [19] ZÝKOVÁ, Lucie. *Vliv světelných podmínek na řízení motorových vozidel - simulátorová studie*. 2014. Bakalářská práce. ČVUT, fakulta dopravní
- [20] SÝKORA, Ondřej. *Analýza změn v chování lidského operátora-řidiče na základě analýzy trajektorie vozu*. 2008. Disertační práce. České vysoké učení technické v Praze Fakulta dopravní. Vedoucí práce Doc. Ing. Petr Vysoký, CSc.
- [21] Rozptyl [online]. [cit. 2016-05-28]. Dostupné z: <http://www.matematika.cz/rozptyl>
- [22] VYSOKÝ, Petr. *Řidič* [prezentace]. [cit. 2016-05-28]

SEZNAM OBRÁZKŮ

Obrázek 1- Rozdělení systémů [3. autor].....	13
Obrázek 2- Lorenzův atraktor [5]	16
Obrázek 3 – Trajektorie tlumeného rotátoru [11, autor].....	17
Obrázek 4 – Trajektorie vozidla.....	19
Obrázek 5- Rekurentní grafy 3 odlišných signálů [14].....	20
Obrázek 6 – Rekurentní graf jízdy řidiče 1 bez snížené viditelnosti	21
Obrázek 7 – Zjištění střední vzájemné informace pomocí softwaru VRA.....	26
Obrázek 8 - Divergující dráhy atraktoru [16]	27
Obrázek 12 – Trajektorie jízdy řidiče 2 bez snížené viditelnosti.....	32
Obrázek 13 - Porovnání trajektorie všech jízd řidiče 1	33
Obrázek 14– Porovnání trajektorie obou jízd řidiče 1	34
Obrázek 9 - Rekurentní grafy řidičů 1 a 2 z měření Únavy	35
Obrázek 10 - Rekurentní graf všech jízd řidiče HV	36
Obrázek 11-Rekurentní graf všech jízd řidiče ML	37
Obrázek 15- Procento falešných sousedů v jízdě řidiče HV v 10:09 hod.....	39

SEZNAM TABULEK

Tabulka 1-Rozptyl hodnot vzdálenosti od pravé krajnice, experiment pozornost.....	38
Tabulka 2- Optimální dimenze vnoření a procento falešných sousedů	40

SEZNAM PŘÍLOH

- Příloha A Grafické zobrazení pohybu řidičů – pozornost řidičů (ve fázové rovině)
- Příloha B Grafické zobrazení pohybu řidičů – únava (ve fázové rovině)
- Příloha C Rekurentní grafy pozornosti řidičů
- Příloha D Rekurentní grafy únavy řidičů
- Příloha E Rekurentní grafy únavy řidičů – všechny jízdy řidičů OS a PV
- Příloha F Střední vzájemná informace – pozornost řidičů
- Příloha G Střední vzájemná informace – únava
- Příloha H Manuál k získání rekurentního grafu, střední vzájemné informace a falešných sousedů v softwaru VRA

SEZNAM PŘÍLOH NA CD

Složky:


- Grafy fázového prostoru
- Naměřená data
- Střední vzájemná informace – únava
- Visual recurrence analysis software VRA - instalace

Soubory:

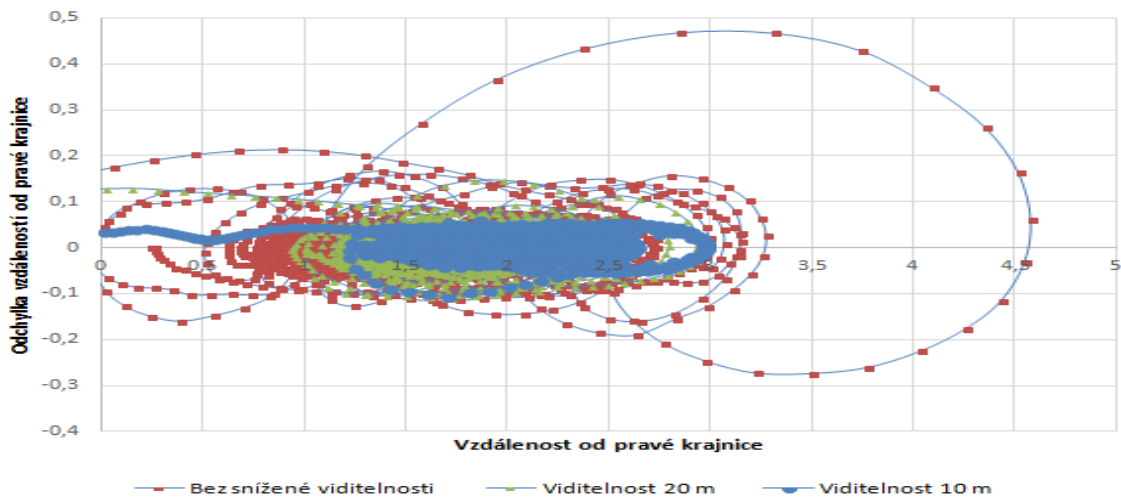
- Falešní sousedé – únava
- Rekurentní grafy všech jízd – únava
- Rozptyl – pozornost
- Struktury – pozornost
- Střední vzájemná informace – úseky HV a PV
- SVI – únava
- SVI – pozornost
- Pozornost – diagramy
- Pozornost – diagramy – 1 na celou skupinu
- Stručný popis dat na CD
- DP_Posouzení pozornosti řidiče s použitím nelineární analýzy dat_Zýková

PŘÍLOHA A: GRAFICKÉ ZOBRAZENÍ POHYBU ŘIDIČŮ – POZORNOST ŘIDIČŮ (ve fázové rovině)


Zobrazení pohybu řidiče 2 - experiment POZORNOST




Zobrazení pohybu 3 - experiment POZORNOST




Zobrazení pohybu řidiče 4 - experiment pozornost



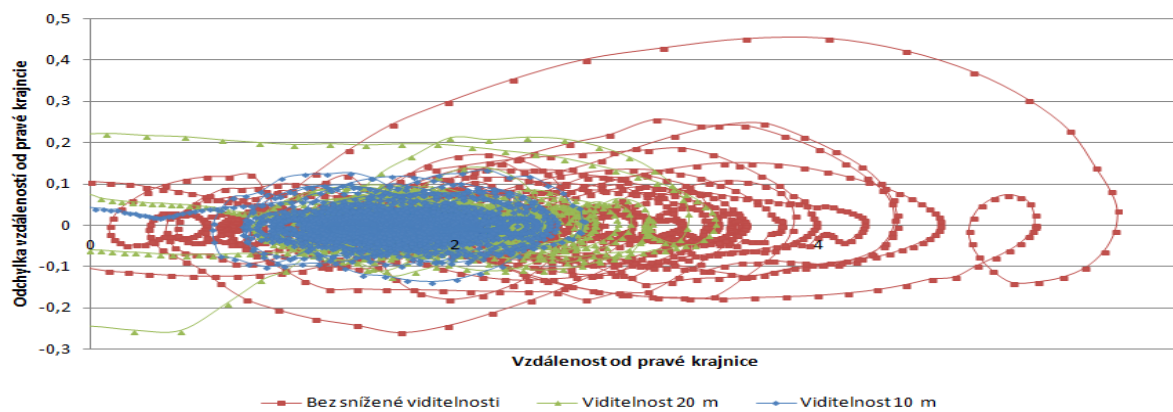
Zobrazení pohybu řidiče 5 - experiment POZORNOST




Zobrazení pohybu řidiče 6 - experiment POZORNOST




Zobrazení pohybu řidiče 7 - experiment POZORNOST




Zobrazení pohybu řidiče 8 - experiment POZORNOST



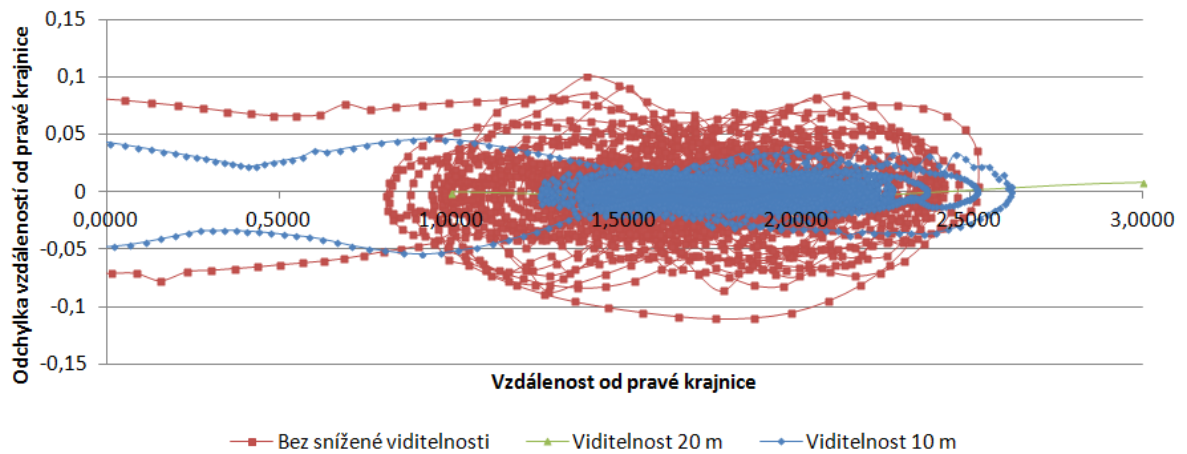
Zobrazení pohybu řidiče 9 - experiment POZORNOST



Zobrazení pohybu řidiče 10 - experiment POZORNOST

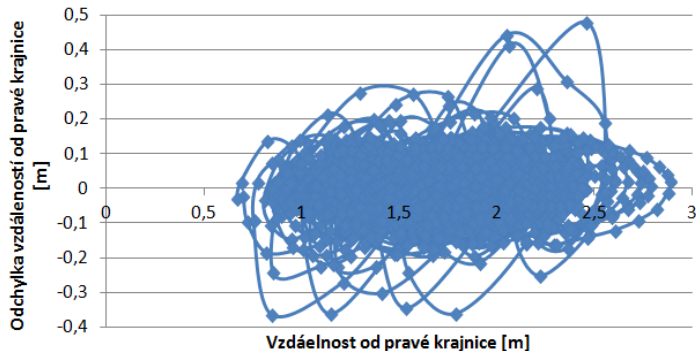


Zobrazení pohybu řidiče 11 - experiment POZORNOST




PŘÍLOHA B: GRAFICKÉ ZOBRAZENÍ POHYBU ŘIDIČŮ – ÚNAVA (ve fázové rovině)


Trajektorie řidiče HV - 16:49 hod




Trajektorie řidiče HV - 7:40 hod




Trajektorie řidiče ML - 10:42 hod




Trajektorie řidiče ML - 6:52 hod




Trajektorie řidiče OS - 11:49 hod




Trajektorie řidiče OS - 4:17 hod



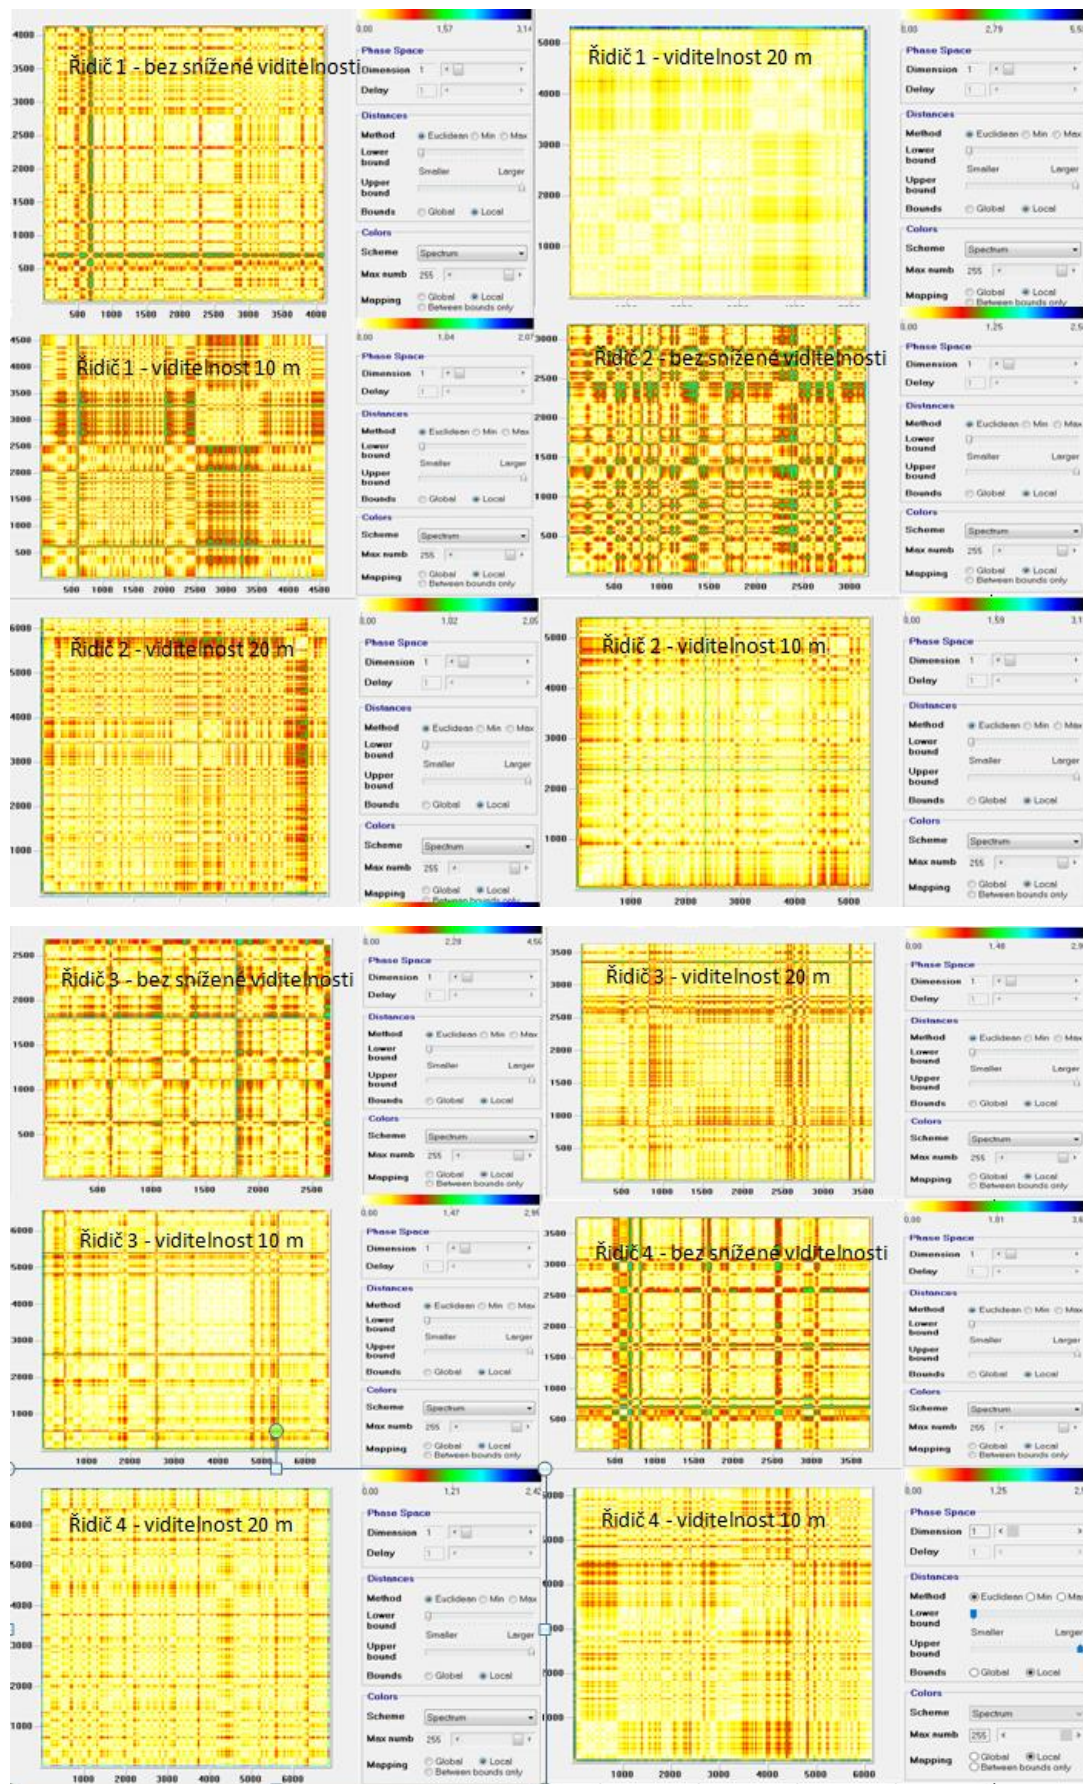
Trajektorie řidiče PV - 10:41 hod



Trajektorie řidiče 4 - 7:15 hod

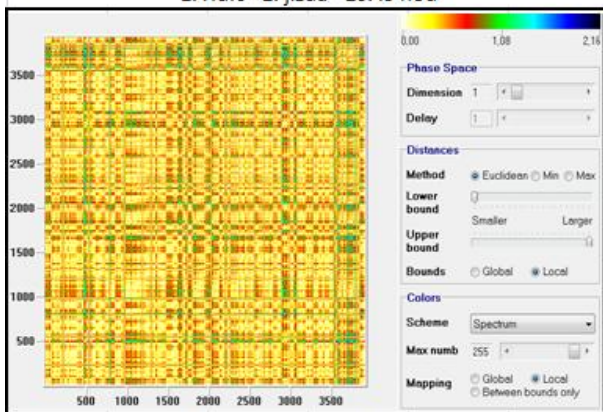


PŘÍLOHA C: REKURENTNÍ GRAFY POZORNOSTI ŘIDIČŮ

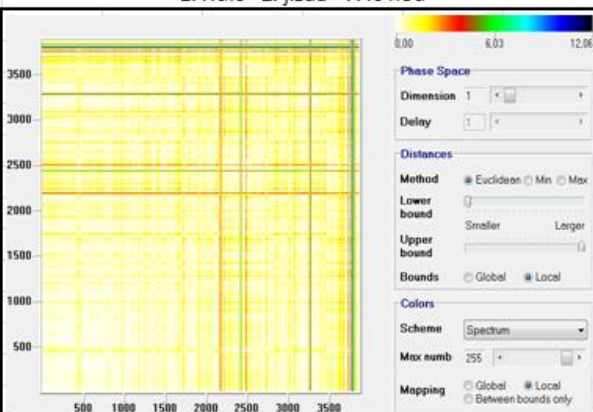


PŘÍLOHA D: REKURENTNÍ GRAFY ÚNAVY ŘIDIČŮ

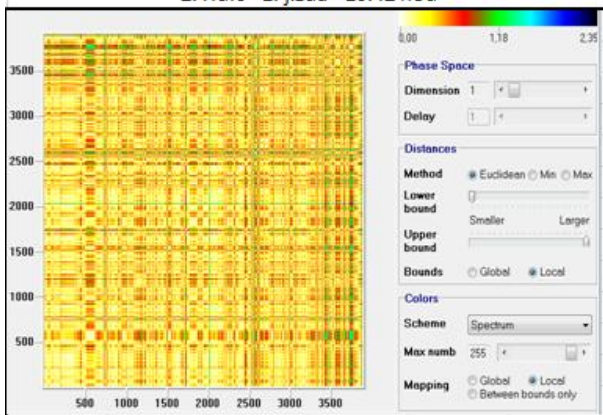
1. řidič - 1. jízda - 16:49 hod




1. řidič - 2. jízda - 7:40 hod



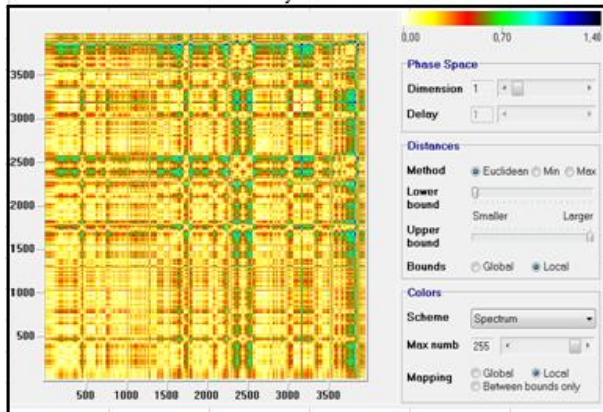
2. řidič - 1. jízda - 10:42 hod




2. řidič - 2. jízda - 6:52 hod



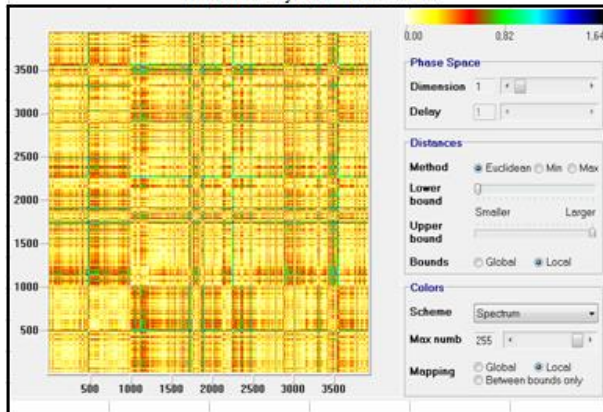
3. řidič - 1. jízda - 11:49 hod



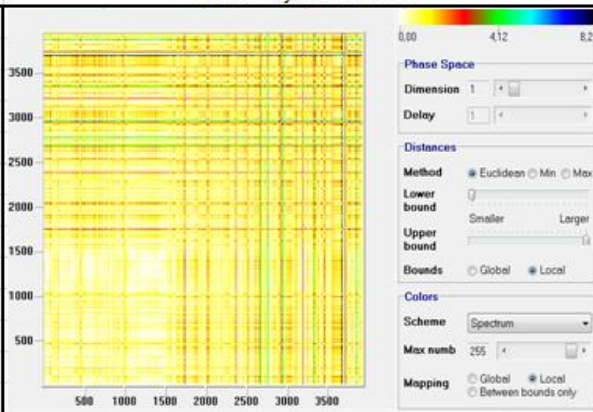
3. řidič - 2. jízda - 4:17 hod



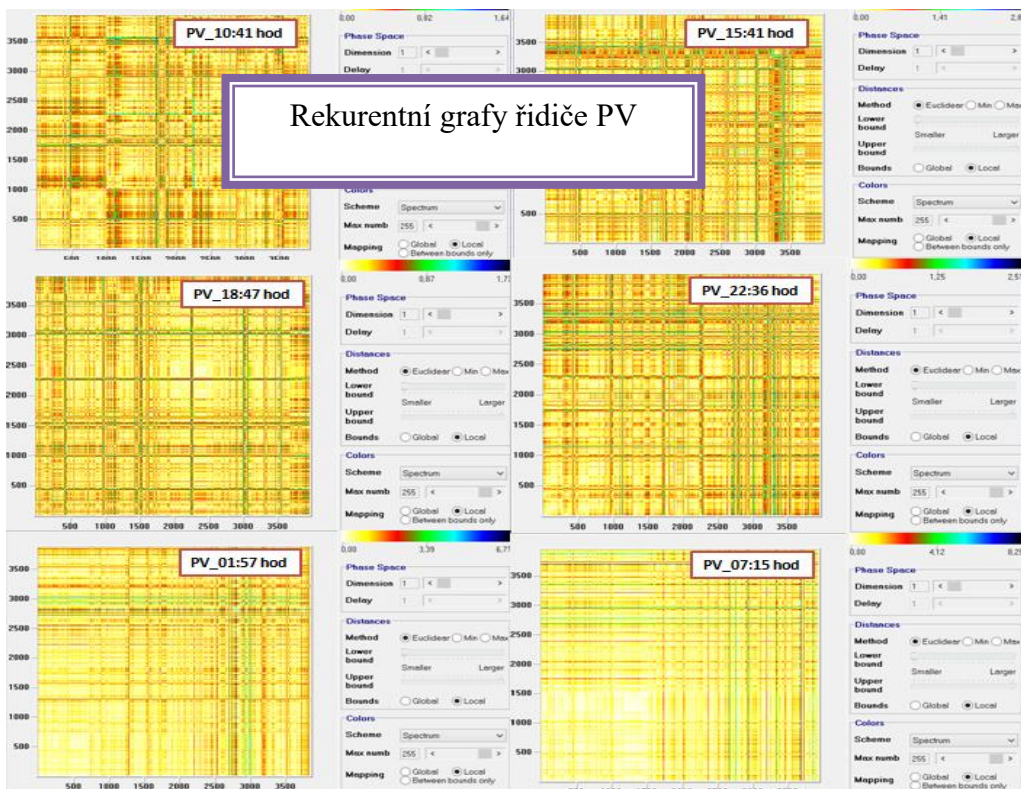
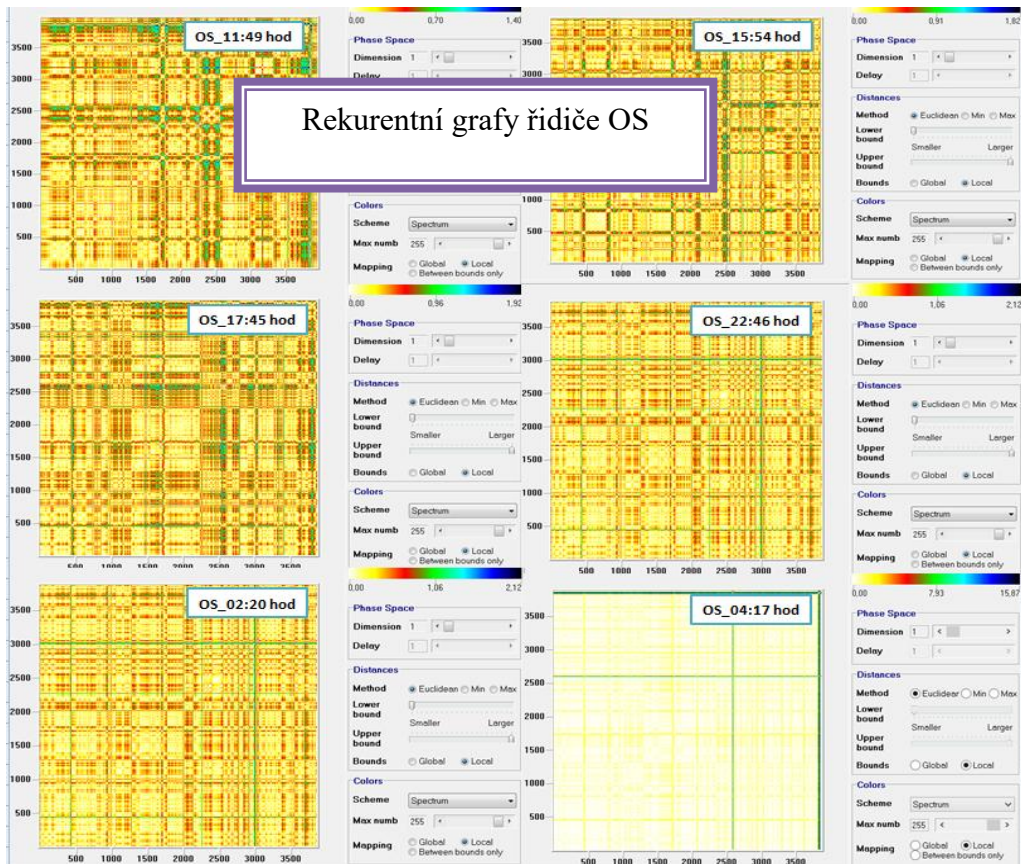
4. řidič - 1. jízda - 10:41 hod









4. řidič - 2. jízda - 7:15 hod









PŘÍLOHA E: REKURENTNÍ GRAFY ÚNAVY ŘIDIČŮ – VŠECHNY JÍZDY ŘIDIČŮ OS A PV



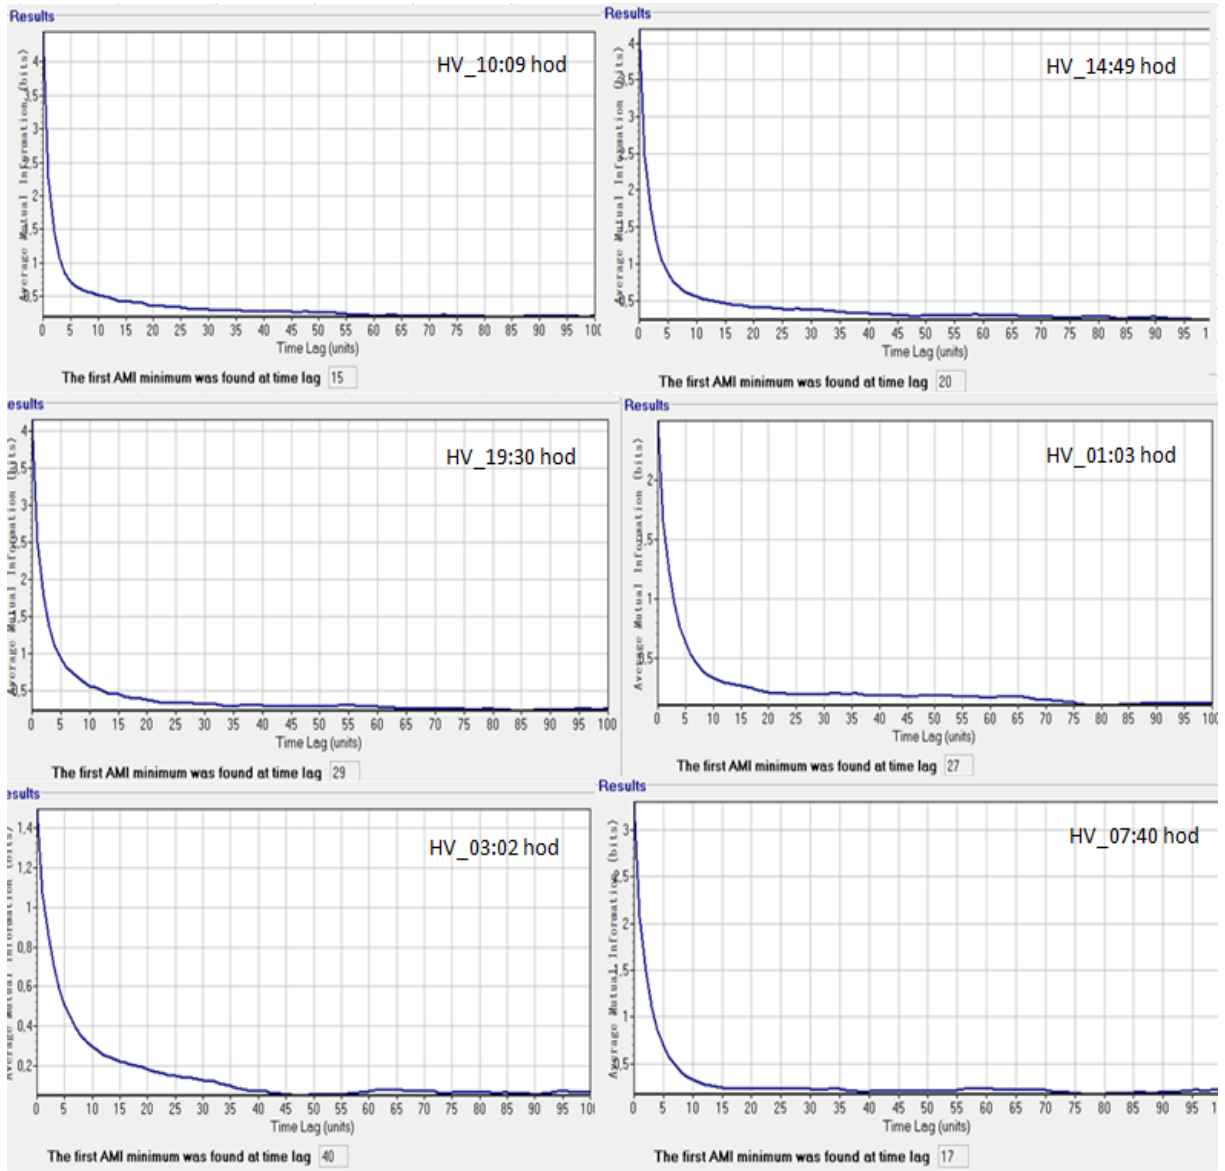
PŘÍLOHA F: STŘEDNÍ VZÁJEMNÁ INFORMACE- POZORNOST ŘIDIČŮ











PŘÍLOHA G: STŘEDNÍ VZÁJEMNÁ INFORMACE- ÚNAVA

Řidič HV – všechny jízdy



Řidič PV – všechny jízdy




PŘÍLOHA H: MANUÁL K ZÍSKÁNÍ REKURENTNÍHO GRAFU, STŘEDNÍ VZÁJEMNÉ INFORMACE A FALEŠNÝCH SOUSEDŮ V SOFTWARE VRA

1) Recurrence plot

Pro získání rekurentního grafu je nutné naměřená (získaná) data – časovou řadu upravit tak, aby tvořila textový soubor s koncovkou .dat. Je nutné, aby desetinná čárka byla nahrazena tečkou. Datová řada nesmí obsahovat žádné znaky kromě čísel a teček.

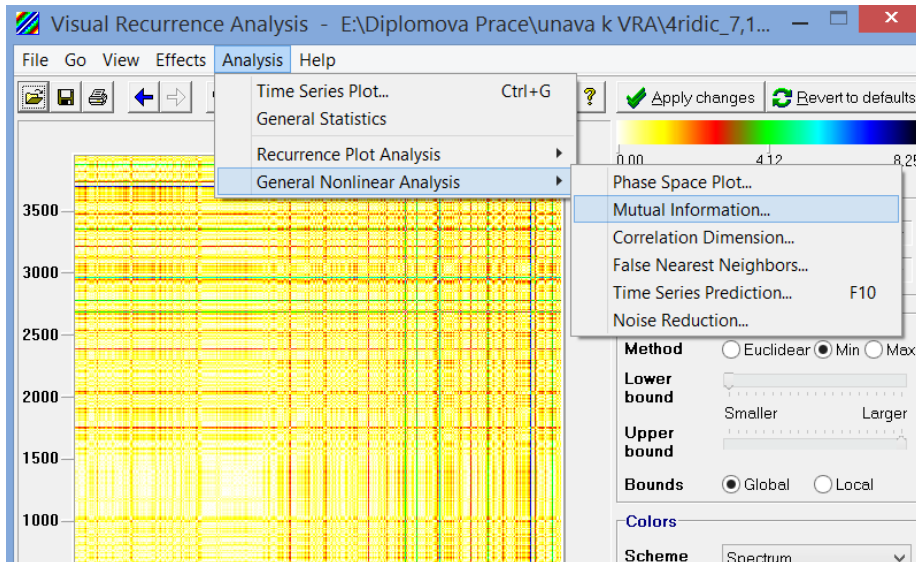
Dále textový soubor nahrajeme do softwaru VRA. Pomocí ikony Load signal (vpravo nahoře, pod File) nahrajeme data do programu. Ihned poté se nám zobrazí zjištěná struktura. Na pravé straně vidíme barevnou mapu, která obsahuje jednotlivé vzdálenosti ve struktuře, zobrazené určitou barvou. V oddělení Colors je možné nastavit danou škálu barev a to pomocí oddělení Scheme. Při jakékoliv úpravě musíme dané změny aplikovat pomocí tlačítka Apply changes (vlevo nahoře, nad barevnou mapou). Ve stejné řadě ikon, jako se nachází Apply changes nalezneme i tlačítka pro Zoom, díky kterým můžeme přibližovat výslednou strukturu. Vpravo od Zoomu se nachází ikona View recurrence plot full screen, která zobrazí strukturu systému přes celou obrazovku. Vše je možné samozřejmě vytisknout nebo uložit a to pomocí tlačítek Save a Print nacházejících se vedle ikony Load Signal v pravém horním rohu.




2) Mutual information

Pro zjištění Střední vzájemné informace potřebujeme stejný datový soubor, jaký byl popsán v bodě 1).

Opět soubor nahrajeme pomocí ikonky Load signal. V záložce Analysis klikneme na příkaz General Nonlinear Analysis a poté na Mutual Information.



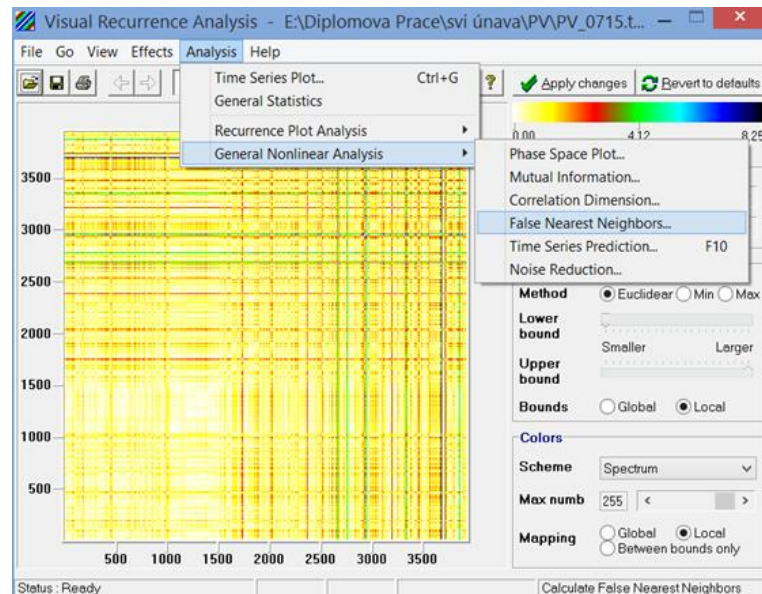
Poté se zobrazí okno Average Mutual Information, kde si v horní části nastavíme, jaký bude první a poslední bod zjišťované časové řady (First data point a Last data point). Také je možné přednastavit Maximální časovou stopu. Tím upravíme osu x. Hodnotou 100 je časová řada graficky rozdělena na 100 částí. Dále je možné nastavit míru detailů při zobrazení – Detail (less, more). Výsledek můžeme uložit nebo vytisknout pomocí tlačítek pod grafem Save Chart či Save data. Save Chart uloží pouze část s grafem. Pro tisk slouží ikona Print Chart.



3) False nearest neighborst + optimal global embedding dimension

I pro získání falešných sousedů a dimenze vnoření potřebujeme stejný datový soubor, jaký byl popsán v bodě 1).

Opět soubor nahrajeme pomocí ikonky Load signal. V záložce Analysis klikneme na příkaz General Nonlinear Analysis a poté na False Nearest Neighborst.



Otevře se okno, ve kterém klikneme vpravo dole na Calculate FNN. Vypočítá se nám hodnota falešných sousedů a dimenze vnoření. Na grafu vidíme, kdy která hodnota nastala. V nastavení (horní část okna) můžeme určit spodní i horní hranici dimenze (tlačítko Min dimension a Max dimension). Poté se nám zobrazí hodnoty pouze v tomto daném intervalu. Hodnota Speed vs. Accuracy určuje rychlost a přesnost výpočtů. Čím více se kurzor přiblíží k pravé straně – faster, tím software počítá rychleji a nepřesněji.

