

Univerzita Karlova v Praze

1. lékařská fakulta

Specializace ve zdravotnictví

Zdravotnická technika a informatika



## Diplomová práce

# Aplikace metod automatické klasifikace při monitorování únavy řidičů

Vedoucí: Ing. Pavel Smrčka, PhD.

Autor: Bc. Jan Cimbálník

Praha, květen 2010

Prohlášení

Prohlašuji, že jsem práci s názvem

**Aplikace metod automatické klasifikace při monitorování únavy řidičů**

vypracoval samostatně a použil k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k práci.

Nemám 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 dne

podpis

## **Poděkování**

Děkuji vedoucímu mé diplomové práce panu Ing. Pavlu Smrčkovi PhD. za ochotu, rady a čas, který mi věnoval při vypracování mé diplomové práce a za poskytnuté programy, které mi pomohly při vypracování mé práce.

## Abstrakt

Cílem této práce bylo zpracovat data z projektu „Bdící auto, spící řidič,“ která byla naměřena v letech 2000 – 2002. Dále z těchto dat získat příznaky, které by byly vhodné pro rozlišení, zda je řidič bdělý či unavený. Poté zhodnotit relevantnost jednotlivých příznaků a vybrané příznaky pak použít pro automatickou klasifikaci únavy a bdělosti řidičů.

V teoretické části práce je popsána únava jako fyziologický úkaz, popsány základní principy použitých metod automatické klasifikace a zhotovena rešerše aktuálního stavu řešení dané problematiky.

V praktické části je popsán postup experimentu, při kterém byla data získána. Poté následuje samotný popis metodiky této práce, kdy byly signály elektrookulografie a signálu z Hallovy sondy, který reprezentoval natočení volantu, předzpracovány v programu Matlab. Následně pak byly vypočteny příznaky z jednotlivých signálů, vyexportovány do programu MS Excel, kde byly zpracovány do formy grafů a statisticky zhodnoceny. Po vyřazení nerelevantních příznaků byly použity metody automatické klasifikace pro rozlišení bdělosti a únavy.

**Klíčová slova:** automatická klasifikace, detekce únavy, elektrookulogram, Hallova sonda, řidič motorového vozidla

## **Abstract**

The goal of this thesis was to process data from the project “Wakeful car, sleeping driver,” which were acquired during the period of 2000-2002. Furthermore, to obtain attributes from the data which would be appropriate for determination whether the driver is awake or tired. Moreover to evaluate the relevance of the attributes and to use them for automatic fatigue and alertness classification in drivers.

The theoretical part describes fatigue as a physiological phenomenon and discusses the current state of research of the issue.

The practical part then describes the experiment in which the data was obtained. This is followed by the description of the methodology of this study where signals of elektrooculography and the hall probe, which represented the steering wheel angle, were pre-processed in Matlab. Subsequently, the attributes were calculated from the individual signals and exported to MS Excel, where they were processed into the form of graphs and statistically evaluated. After the removal of irrelevant attributes automatic classification methods were used for discrimination between alertness and fatigue.

**Key words:** automatic classification, fatigue detection, elektrooculogram, Hall’s probe, driver

## Obsah

|       |   |    |
|-------|---|----|
| 1.    | Psychofyzilogické projevy únavy .....                       | 6  |
| 1.1   | Únava .....   | 6  |
| 1.1.1 | Únava psychická a nuda .....                                | 6  |
| 1.1.2 | Únava fyzická .....   | 7  |
| 1.1.3 | Únava a výkonnost .....                                     | 7  |
| 1.2   | Přímé indikátory únavy .....                                | 8  |
| 1.3   | Nepřímé indikátory únavy .....                              | 8  |
| 1.3.1 | Elektroencefalografie .....                                 | 9  |
| 1.3.2 | Elektrookulografie .....                                    | 9  |
| 1.3.3 | Elektrokardiografie .....                                   | 9  |
| 1.3.4 | Signály získané ze zpracování videa .....                   | 10 |
| 1.3.5 | Signály reprezentující laterální pozici .....               | 10 |
| 1.3.6 | Signály z natočení volantu .....                            | 10 |
| 2.    | Metody automatické klasifikace .....                        | 11 |
| 2.1   | Neuronové sítě .....  | 11 |
| 2.2   | Rozhodovací stromy .....                                    | 12 |
| 2.3   | Metoda K-nejbližší sused .....                              | 13 |
| 2.4   | Naivní Bayesův klasifikátor .....                           | 13 |
| 2.5   | Support vector machine (Algoritmy podpůrných vektorů) ..... | 14 |
| 3.    | Současný stav řešení .....                                  | 15 |
| 4.1   | Komerčně zavedené systémy .....                             | 17 |
| 4.1.1 | „SAM“ systém .....  | 17 |
| 4.1.2 | DAS 2000 Road Alert System .....                            | 17 |
| 4.1.3 | SafeTRAC .....  | 17 |
| 4.1.4 | TravAlert .....   | 17 |
| 4.1.5 | Systémy zavedené automobilkami .....                        | 17 |
| 4.2   | Systémy patentované a ve vývoji .....                       | 18 |

|       |  |    |
|-------|--|----|
| 3.2.1 | System pracující s analýzou EKG, HRV a síly úchopu volantu ..... | 18 |
| 3.2.2 | System dále rozvíjející snímání EKG.....                         | 20 |
| 3.2.3 | System hodnotící signály získané z videozáznamu.....             | 21 |
| 3.2.4 | System DROWSI WP3.....   | 21 |
| 3.2.5 | Projekt „SAVE“.....  | 22 |
| 3.2.6 | „AWAKE“ system.....  | 22 |
| 4.    | Měření .....   | 24 |
| 5.    | Metody .....   | 26 |
| 5.1   | Předzpracování dat.....  | 26 |
| 5.2   | Vypočtené příznaky za signálů EOG a Hallovy sondy.....           | 27 |
| 5.3   | Vyhodnocení dat v programu Microsoft Excel.....                  | 30 |
| 5.3.1 | Grafy v časové oblasti .....                                     | 30 |
| 5.3.2 | Burzovní grafy.....  | 31 |
| 5.3.3 | Statistické hodnocení pomocí studentova t-testu .....            | 31 |
| 5.4   | Aplikace metod automatické klasifikace v programu Weka .....     | 32 |
| 6.    | Výsledky .....   | 34 |
| 6.1   | Řidič 1 .....  | 35 |
| 6.2   | Řidič 2.....   | 38 |
| 6.3   | Řidič 3.....   | 41 |
| 6.4   | Řidič 4.....   | 43 |
| 6.5   | Celkové vyhodnocení výsledků .....                               | 46 |
| 7.    | Diskuse.....   | 47 |
| 8.    | Závěr .....  | 48 |
|       | Literatura.....  | 49 |
|       | Přílohy.....   | 51 |
|       | Příloha č. 1 .....   | 51 |
|       | Příloha č. 2 .....   | 61 |

## **Seznam příloh**

**Příloha č. 1** – Kód programu

**Příloha č. 2** – Burzovní grafy



## Seznam použitých symbolů a zkratek

### Zkratky

|                |  |
|----------------|--|
| <b>EKG</b>     | Elektrokardiografie  |
| <b>EOG</b>     | Elektrookulografie   |
| <b>EEG</b>     | Elektrookulografie   |
| <b>PERCLOS</b> | Percentage of eyelid closure (procento zavření víčka)  |
| <b>HRV</b>     | Heart rate variability (Variabilita srdečního rytmu)   |
| <b>SVM</b>     | Support vector machine (Podpůrné vektory)  |
| <b>GPS</b>     | Global positioning system  |
| <b>AECS</b>    | Eye closure speed (Rychlost zavření oka)   |
| <b>stdSAV</b>  | Standard deviation of steering wheel angle velocity (Směrodatná odchylka rychlosti natočení volantu) |
| <b>maxSAV</b>  | Maximum of steering wheel angle velocity (Maximum rychlosti natočení volantu)                        |

### Symboly

|                                |  |
|--------------------------------|--|
| <b>P()</b>                     | Pravděpodobnost výskytu jevu v závorkách               |
| <b><i>p</i></b>                | Pozice píku v záznamu                                  |
| <b><math>\theta</math></b>     | Úhel natočení volantu                                  |
| <b><math>\omega</math></b>     | Úhlová rychlost natočení volantu                       |
| <b><math>H_0</math></b>        | Nulová hypotéza  |
| <b><math>m_i</math></b>        | Medián hodnoty   |
| <b><math>\Delta A_p</math></b> | Rozdíl v amplitudě píku od začátku píku po jeho vrchol |
| <b><math>\Delta t_p</math></b> | Rozdíl v čase od začátku píku po jeho vrchol           |

# 1. Úvod

Je známo, že únava je, společně s alkoholem a nepřiměřenou rychlostí, jedna z hlavních příčin dopravních nehod v automobilové dopravě. Studie provedené ve Francii, Spojených Státech a Austrálii prokázaly, že počet nehod způsobených únavou, a potažmo nesoustředěností řidiče na dopravní situaci, se pohybuje od 3 do 33% z celkového počtu nehod (1) (2) (3). Této příčině dopravních nehod se většina států snaží zabránit například povinným používáním tachografických kotoučů u nákladních vozidel a autobusů, varovnými cedulemi, připomínající řidičům důležitost odpočinku, masivními reklamami v médiích a tisku, konáním různých společenských akcí zaměřených na bezpečnost jízdy či umístěním havarovaných aut s varováním proti únavě na okraj vozovky (Austrálie).

Jedním z možných prostředků pro snížení počtu dopravních nehod z důvodu únavy je systém zabudovaný přímo v autě. Takovýto systém pak včas varuje řidiče zvukovým či vizuálním signálem, že podléhá únavě či dokonce mikrosnánku.

Tato práce se zabývá analýzou signálů získaných přímo z fyziologických ukazatelů řidičova organismu (EKG, EOG, apod.), ale i signálů, které vyplývají z interakce řidič – auto (pohyby volantem, zrychlení, apod.). Následně pak získáním příznaků únavy z vybraných signálů, a statistickým posouzením relevantnosti jednotlivých příznaků a nakonec aplikací automatických klasifikátorů na vybrané relevantní příznaky. Navazuje tak na projekt „Spící řidič, bdící auto,“ který byl řešen v letech 2000-2002, z něhož jsou použita data pro analýzu.

V části teoretické je popsána únava jako fyziologický úkaz a metody detekce únavy. Teoretická část dále pokračuje rozdělením systémů pro detekci únavy a rešerší komerčně zavedených technologií a systémů ve vývoji.

Následuje část praktická, která popisuje experiment, během něhož byla data naměřena, metody použité při řešení práce, výsledky, diskusi a závěr.

## **2. Psychofyziologické projevy únavy**

Je zřejmé, že na řidiče vozidla působí z hlediska únavy několik různých faktorů, které jsou známy i laické veřejnosti. Mezi ně patří počet hodin spánku v několika posledních dnech, celková fyzická únava, délka jízdy, denní doba, roční doba, počasí atd. Faktory, které již tak zřejmé nejsou, se zakládají na psychickém stavu řidiče, tj. mentální únavy, která vzniká nikoliv v důsledku fyzického vyčerpání, ale zejména kvůli opakování stejných úkonů po dlouhou dobu (4).

### **2.1 Únava**

Je důležité si uvědomit, že únava je přechodový stav, mezi spánkem a bdělostí, a pokud není přerušen, vede k přechodu do spánku. Definice únavy jsou často velmi nepřesné, a z tohoto důvodu se únava dělí do dvou kategorií, a to na únavu psychickou a únavy fyzickou.

#### **2.1.1 Únava psychická a nuda**

Psychická únava je považována za stupňující se a kumulativní proces, který je spojován s neochotou cokoli dělat, sníženou efektivitou a bdělostí a narušenou mentální výkonností. Je nutno zmínit, že psychická výkonnost může být ovlivněna několika dalšími faktory, jako jsou vliv prostředí, psychické zdraví, psychická aktivita, atd. Hlavními projevy mentální únavy jsou pak zejména malátnost, lhostejnost, pocity útlumu a zhoršení chuti k jakékoli činnosti. Obecně se také projevuje neochotou k jakýmkoli psychickým, či fyzickým výkonům a netečností.

Při charakteristice psychické únavy je důležité uvést také vztah mezi mentální únavou a nudou, protože tyto dva stavy na sebe mohou vzájemně působit nebo jeden může vyvolat druhý a naopak. Někteří autoři dokonce považují nudu za jistou formu psychické únavy, protože nuda je provázena sníženou aktivitou mozku (5). Fyziologické aspekty jsou spojeny nízkými úrovněmi stimulace, opakováním stále stejných stimulů nebo s mentálními či fyzickými nároky. Toto vede k funkčnímu stavu centrálního nervového systému, charakterizovanému nízkými hodnotami mozečkové aktivity, provázeným pocity ospalosti a malátnosti, snížené bdělosti, neochotou plnit úkoly a poklesem pozornosti. Což jsou všechno symptomy podobné symptomům psychické únavy. Proto je pochopitelné, že někteří vědci často považují mentální únavu a nudu za totožnou věc, protože oba stavy jsou provázeny poklesem aktivity mozku. V dopravě je pak mnoho situací, které mohou být zároveň nudné a psychicky náročné a tudíž se projeví celkovou ospalostí (5).

### **2.1.2 Únava fyzická**

Fenomén snížené svalové výkonnosti po námaze je nazýván svalová únava a je charakterizován sníženou svalovou silou a pohyblivostí. Svalová únava přispívá ke zhoršené koordinaci a může vést k závažným chybám a nehodám. Během svalové kontrakce dochází k biochemickým dějům, pro dodání energie. Ve svalu, kterému není dodáváno dostatek energie, pak dochází k anaerobním dějům, což vede ke vzniku kyseliny mléčné a zvyšuje se acidóza ve svalové tkáni. Fyzická únava je komplexní stav, který je ovlivňován několika psychofyziologickými faktory. Zmíněný stav pak vede k:

- 1) Poklesu bdělosti, mentální koncentrace a motivace
- 2) Poklesu pracovního výkonu
- 3) Pomalejším a slabším svalovým kontrakcím
- 4) Svalovému třesu a lokální bolesti
- 5) Zatížení dýchacích, oběhových a neuromuskulárních funkcí
- 6) Snížení frekvence signálu elektromyogramu
- 7) Zvýšení akumulace laktátu ve svalech
- 8) Zvýšení teploty tělesného jádra

Uvedené příznaky zdaleka nejsou všechny symptomy fyzické únavy, avšak patří k těm nejdůležitějším. Z výše uvedených informací vyplývá, že těžká fyzická práce před řízením může způsobit či umocnit únavu během řízení, jako tomu například může být u řidičů kamiónů, kteří náklad nakládají manuálně (4).

### **2.1.3 Únava a výkonnost**

V několika posledních desetiletích, kdy vzrostl objem automobilové dopravy, začíná být zřejmé, že únava má podstatný dopad na výkonnost řidiče, což může vést k chybám při řízení a zvýšenému riziku nehod. Výkonnost v delším časovém období, jako je například řízení vozidla, většinou vyžaduje větší kognitivní úsilí než úsilí fyzické. Kognitivní úsilí zahrnuje udržování bdělosti, selektivní pozornost a komplexní rozhodování. Kromě vlivu délky jízdy, bylo prokázáno, že také denní tělesné rytmy mají dopad na výkonnost jedince při řízení (6). To znamená, že pokud u řidiče nastane únava během dne, kdy se přirozená fyziologická aktivita zvyšuje, nebude snížení výkonnosti tak významné, jako kdyby nastala během noci.

U profesionálních řidičů a lidí, kteří jsou zvyklí řídit denně, může únava dosahovat vyšších úrovní, předtím než se tento fakt projeví na řízení samotném. Je však nutné podotknout, že i tato únava způsobuje útlum, zpomalení senzomotorických funkcí, zpomalení zpracování vjemů, a

proto může mít vliv na reakční dobu v případech náhlých a nepředvídatelných situací. Z tohoto důvodu není vhodné se při detekci únavy řidiče soustředit pouze na přímé ukazatele řízení (jako poloha auta na silnici, rychlost či pohyby volantů), ale je potřeba věnovat pozornost také percepčním, kognitivním a motorickým dovednostem, které jsou spojeny se samotným řízením. Pro tato měření se pak jako nejvhodnější veličiny jeví některá z fyziologických funkcí, na kterou má únava vliv.

## **2.2 Přímé indikátory únavy**

Jediným známým indikátorem únavy, který odráží samotnou únavu přímo je vyšetření metabolismu a průtoku krve v mozku.

Pokud je člověk podroben fyzické zátěži, vzniká v mozkových tkáních okamžitá poptávka po  $O_2$ , protože v mozku nejsou žádné jiné zdroje  $O_2$ , zvýšený metabolismus je závislý pouze na zvýšeném koncentračním gradientu. Avšak během maximální fyzické zátěže, koncentrace mozkového  $O_2$  klesá, kvůli možné arteriální desaturaci a hyperventilační hypokapnii. V důsledku toho, dochází ke zhoršené aktivaci svalových motorických jednotek (7).

Naopak během cvičení, které trvá delší dobu, vnímaná únava pak odpovídá hromadění amoniaku v mozku a získaná data dále podporují teorii, že nedostatek glykogenu v astrocytech limituje schopnost mozku aktivovat rychlejší metabolismus (7).

Tento ukazatel je pro aplikaci v této práci samozřejmě nepoužitelný, ale uvádím ho jako jediný dosud známý přímý ukazatel únavy.

## **2.3 Nepřímé indikátory únavy**

Pro měření a detekci únavy je možno, kromě biochemických ukazatelů v krvi a moči (zejména pozůstatky katecholaminů) (8), použít několika fyziologických signálů a signálů přímo souvisejících s jednáním řidiče na vozovce.

Mezi ně patří signály, které je možno detekovat přímo z povrchu těla – EOG, EEG, EKG, odpor kůže, teplota kůže, síla stisku volantů nebo signály, které lze měřit bez přímého kontaktu s tělem, mezi něž patří zejména analýza videozáznamu a z ní vyplývající – směr pohledu, mrkání a překrytí oka víčkem (PERCLOS). Signály zmíněné v tomto odstavci jsou většinou považovány za tzv. referenční, protože prokazatelně nesou informaci o únavě, avšak jejich naměření v praxi je jen obtížné.

Mezi veličiny, které naopak lze úspěšně v praxi použít patří takové, které odráží chování řidiče při jízdě. Jde zejména o zrychlení, pohyby volantu či systém, který detekuje relativní polohu auta na vozovce.

### **2.3.1 Elektroencefalografie**

Z těchto signálů se jeví jako nejlepší, nejspolehlivější a s největší schopností predikce signál EEG(1). Tento signál je záznam inhibiční a stimulační činnosti kortikálních neuronů. Jednotlivé signály se sumují a takovýto signál je detekován elektrodami umístěnými na skalpu. Při únavě je se pak projevuje měřitelný posun ve frekvenčních vlastnostech měřeného signálu.

Přestože je signál EEG pravděpodobně nejlepší pro detekci únavy řidiče, v praxi nemá přílišné využití z důvodu potřebných měřicích přístrojů. Řidič by si tak po nástupu do vozidla musel nasazovat EEG čepici či jiné měřicí zařízení na hlavu, což je samozřejmě pro denní využití nepřijatelné.

### **2.3.2 Elektrookulografie**

Dalším slibným ukazatel je elektrookulografie. Protože je mnoho sensorických a motorických spojitostí mezi aktivitou mozku a ovládním zraku, může pohyb očí poskytnout cenné informace o počínající či probíhající únavě. Bylo zjištěno, že při bdělém stavu dochází k rychlým pohybům očí a občasnému mrknutí, zatímco při probíhající únavě je toto vystřídáno pomalými nebo žádnými pohyby očí a rychlým rytmickým mrkáním (4). Tyto změny byly poměrně markantní a vyskytovaly se u většiny testovaných dobrovolníků, dokonce předtím, než se únava projevila na signálu EEG. Proto má tento ukazatel velký potenciál pro detekci únavy u řidičů. Jeho nezměrnou výhodou je pak také bezkontaktnost (pouze částečná v případě analýzy videozáznamu) a nepotřebnost složitějších měřicích zařízení. Je nutno také zmínit, že elektrookulografie je principiálně elektromyografie, proto se na záznamu mohou vyskytovat artefakty, které nemají přímou souvislost s pohyby očí.

### **2.3.3 Elektrokardiografie**

Dalším možným ukazatelem je signál EKG, potažmo z něho vypočítaná HRV a tepová frekvence. Tepová frekvence byla použita pro měření únavy, a bylo prokázáno, že dochází k jejímu snížení během dlouhého nočního řízení, a rovněž během únavy. Byl také prokázán vliv na ukazatel HRV, kdy při zvětšující se únavě dochází ke zvyšování HRV, což lze vysvětlit poklesem cerebelární aktivity. Některé studie prokázaly, že rytmus sinusového uzlu úzce souvisí s mentální zátěží. Obzvláště pak má sinusový rytmus vliv u HRV parametru ve frekvenční oblasti 0,06 – 0,14 Hz, kdy dochází k poklesu v důsledku psychické zátěže. Co více, toto

frekvenční pásmo je nezávislé na vlivech tělesné teploty, dechové frekvence a motorické aktivity. A právě proto je tento ukazatel velmi vhodný pro měření únavy, která vzniká při požadavcích na řízení (7). Avšak vyvstává zde podobný problém jako u EEG, kdy je obtížná aplikace měření tohoto parametru v praxi. Tento problém lze vyřešit zabudováním EKG elektrod do volantu (8). Tomuto tématu se budu věnovat později v mé práci.

#### **2.3.4 Signály získané ze zpracování videa**

Stupeň únavy lze také posoudit z videozáznamu tváře řidiče, a to zejména zpracováním atributů jako jsou výraz ve tváři, přivření víček (PERCLOS) a aspekty chování, jako jsou mnutí očí, zívání či pokyvování hlavou (4). Je samozřejmé, že pro použití takového přístupu je nejprve třeba pořídit nezávislý a referenční snímek, tj. tváře řidiče v čilém stavu. Tento přístup byl v systémech pro detekci únavy zatím uplatňován poměrně zřídka.

#### **2.3.5 Signály reprezentující laterální pozici**

Tyto signály jsou získány z kamer, které detekují pozici vozidla na vozovce vzhledem k postranním a středovým čarám. Unavení řidiči mají tendence se k těmto čarám přibližovat více než řidiči čilí, kteří se naopak drží více uprostřed pruhu. Při zpracovávání těchto signálů je však třeba dbát na to, aby byl eliminován vliv charakteru vozovky, předjízdní, a podobné běžné překřížování a přibližování k postranním čarám.

#### **2.3.6 Signály z natočení volantu**

Variabilita otáčení volantem je závislá na únavě řidiče (11). Je to zejména z důvodu tzv. mikrokorekcí, které bdělý řidič provádí častěji, a proto s menší amplitudou. Tohoto faktu se příznaky počítané ze signálu z volantu snaží využít. Je však nutno provádět korektury pro aktuální vozovku, aby nebyla chybně detekována únava na vlnité cestě.

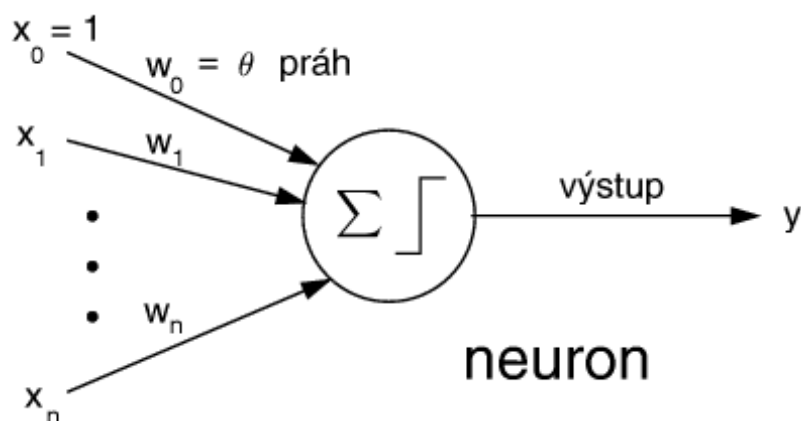
### 3. Metody automatické klasifikace

Metody automatické klasifikace spadají do oboru umělé inteligence. Klasifikátory jsou algoritmy, které pracují na základě přiřazování tříd jednotlivým skupinám dat. Klasifikátorů je celá řada, proto se v této kapitole věnuji pouze klasifikátorům, kterých jsem použil při vypracování této práce s důrazem pouze na základní principy jednotlivých metod.

#### 3.1 Neuronové sítě

Neuronová síť je síť mnoha jednoduchých procesorů, navzájem bohatě propojených. Graf propojení se nazývá topologie sítě. Jednotlivé procesory se nazývají neurony, protože zjednodušeně modelují neurony lidského centrálního nervového systému a jejich formální, popř. technický návrh je mnohdy inspirován vlastnostmi mozku a periferního nervstva (12).

Základem neuronových sítí je jeden neuron tzv. Perceptron. Do tohoto neuronu se sbíhá  $n$  spojů (axonů), které reprezentují buď výstupy jiných neuronů, nebo podněty z vnějšího okolí. Z každého vstupu přichází informace  $x_i$ , ve formě reálného čísla. Každý spoj vedoucí do neuronu je navíc obdařen dalším reálným číslem  $w_i$ , které udává váhu spoje (12). Výstup perceptronu je pak slouží jako vstup do dalšího neuronu nebo výstup systému.



Obr. 1 Perceptron neuronové sítě

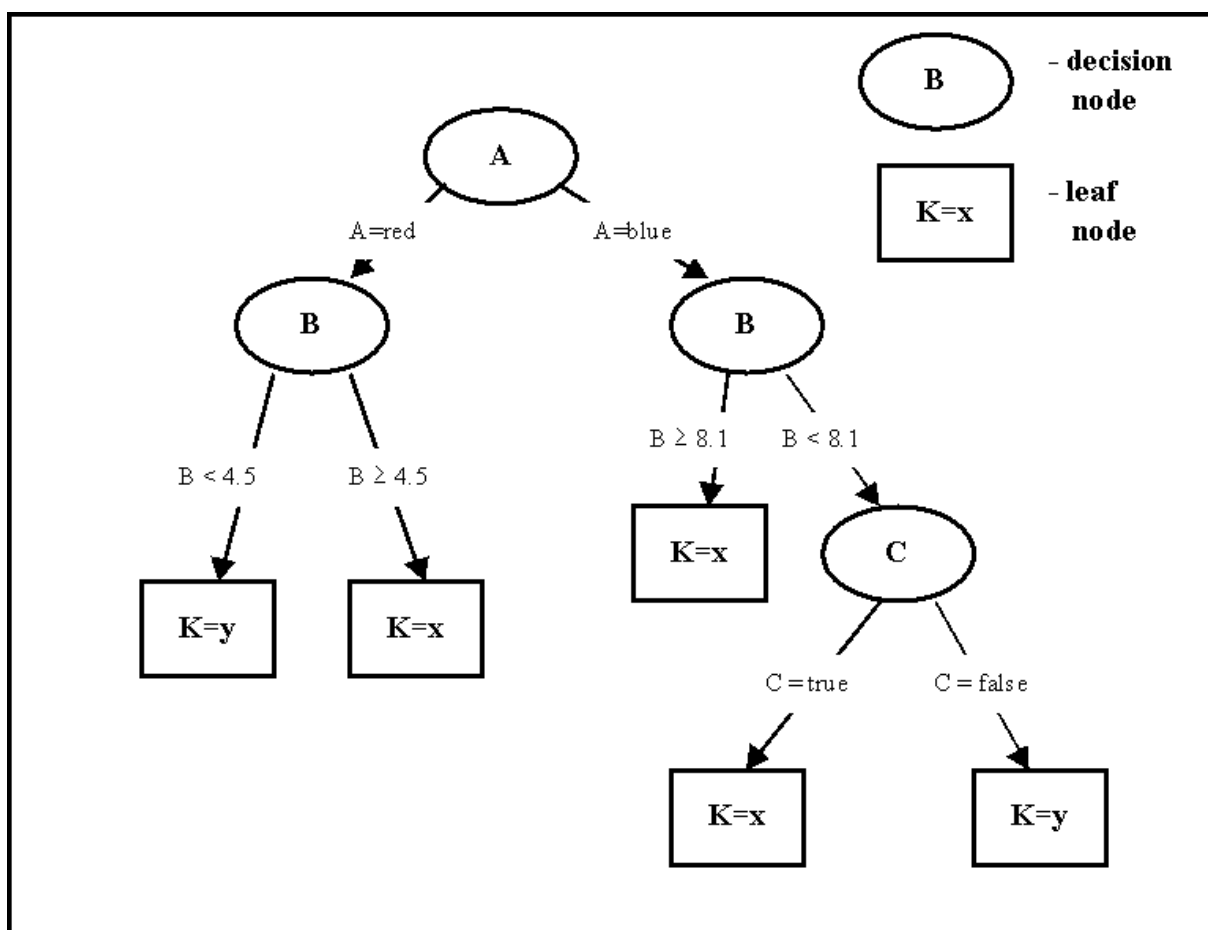
Neuronové sítě nacházejí uplatnění zejména tam, kde je složitost vstupních dat příliš složitá a ruční návrh by byl nepraktický.



## 3.2 Rozhodovací stromy

Rozhodovací stromy jsou silným a populárním nástrojem pro klasifikaci a predikci. Hlavní výhodou rozhodovacích stromů oproti neuronovým sítím je fakt, že rozhodovací stromy ukazují pravidla, která pak mohou být graficky vyjádřeny. Rozhodovací strom je klasifikátor stromové struktury, kde každý uzel je:

- Listem – ukazuje hodnotu třídy
- Rozhodovací uzel – specifikuje test na hodnotu příznaku, podle něhož se větví na podstromy pro každé výstupy testu




Obr. 2 Ukázka grafu jednoduchého rozhodovacího stromu

Hlavní výhodou rozhodovacích stromů je praktická vizualizace podmínek, za pomoci jednoduchého grafu (viz. Obr. 2).

### 3.3 Metoda K-nejbližší soused

Tento algoritmus pracuje na principu klasifikace podle nejbližšího souseda, který patří mezi trénovací data. Metoda K-nejbližší soused patří k jednodušším metodám klasifikace mezi algoritmy pro strojové učení. Klasifikace probíhá tak, že předmět (či daný soubor příznaků) je přiřazen určité třídě podle toho, kolik nejbližších sousedů do ní patří. Pokud je  $k=1$ , pak je tato hodnota přiřazena nejbližšímu sousedovi. Postup klasifikace tohoto algoritmu je zřejmý z Obr. 3.



Obr. 3 Princip metody K-nejbližší soused

Jak je patrné, pokud by  $k=3$ , pak by zelenému kruhu byla přiřazena třída červený trojúhelník, ale pokud by  $k=5$ , tak by mu byla přiřazena třída modrý čtverec.

### 3.4 Naivní Bayesův klasifikátor

Naivní Bayesův klasifikátor je jednoduchý klasifikátor založený na Bayesově teorému s nezávislými (naivními) předpoklady. Bayesův teorém je matematicky formulován v Rov. 1.

$$P(H|E) = \frac{P(H|E) \times P(H)}{P(E)}$$


Rov. 1 Bayesův teorém

*Apriorní* pravděpodobnost hypotézy  $P(H)$ , odpovídá znalostem o zastoupení jednotlivých hypotéz (tříd) bez ohledu na další informace. Podmíněná pravděpodobnost  $P(H|E)$ , též nazývaná *aposteriorní*, vyjadřuje, jak se změní pravděpodobnost hypotézy, pokud víme, že nastalo  $E$ .  $P(E)$  vyjadřuje pravděpodobnost evidence (pozorování).

Naivní Bayesův klasifikátor se využívá například při analýzách textu, jako jsou emailové spam filtry a podobně.

### 3.5 Support vector machine (Algoritmy podpůrných vektorů)

Metoda podpůrných vektorů patří mezi kategorii tzv. jádrových algoritmů. Tyto metody se snaží využít metody poskytované efektivními algoritmy pro nalezení lineární hranice a zároveň jsou schopny representovat vysoce složité nelineární funkce. Jedním ze základních principů je převod daného původního vstupního prostoru do jiného, vícedimensionálního, kde již lze od sebe oddělit třídy lineárně.



Obr. 4 Schematický postup při vytváření vícedimensionálního prostoru SVM

## 4. Současný stav řešení

V současné době, zejména v posledním desetiletí dochází k velkému nárůstu v dopravě, a to především v dopravě jak automobilové, tak kamionové. Z hlediska tohoto nárůstu dopravních prostředků na vozovkách je žádoucí, aby byla monitorována únava řidičů a zvláště pak řidičů profesionálních.

V posledních desetiletích bylo vypracováno několik studií a systémů, které měly za úkol zjistit, jak řidiči podléhají únavě a na jaké vlastnosti a schopnosti má tato únava vliv. Ať už jsou to schopnost řídit a udržovat vozidlo na vozovce či fyziologické vlastnosti řidičova organismu.

Doktor Brown z Cambridgeské univerzity při hodnocení užitečnosti systémů pro detekci únavy řidiče formuloval několik základních tezí, z jakých důvodů mají být tyto systémy vyvíjeny (9). Jsou to:

1. Únava je stálé nebezpečí pro profesionální řidiče při výkonu práce
2. Někteří z řidičů jsou nuceni řídit unaveni, z důvodu včasného dojetí do cíle cesty
3. Sama únava ovlivňuje schopnost řidiče objektivně posoudit svůj stav bdělosti

Přesto však dodává, že je nutno přistoupit s jistou opatrností k implementaci těchto automatických systémů. A to zejména z důvodů:

1. Jejich schopnosti správně posoudit únavu řidiče ve všech dopravních situacích
2. Jejich možného zneužití nesvědomitými řidiči (či zaměstnavateli) pro opodstatnění pokračování v cestě, která měla být z důvodu únavy již dávno ukončena

Při implementaci systémů pro detekci únavy je také zapotřebí brát v potaz fakt, že tento systém musí splňovat požadavky na spolehlivost, možnost zobecnění výsledků, specifitu a senzitivitu. Zároveň musí být schopny řidiče včas varovat o snížené schopnosti řídit, a proto musí operovat v reálném čase, s malými či žádnými požadavky na kalibraci. Dále by pak v žádném případě neměly omezovat řidiče při řízení nebo ho jakkoliv vyrušovat. Posledním, ale velmi důležitým faktorem je také kompatibilita s dalšími systémy a cena.

Systémy pro monitorování únavy lze rozdělit do čtyř kategorií (10):

1. Systémy připraven pro výkon (fitness-to-duty)

Tyto systémy pracují na principu posouzení únavy pracovníka (řidiče) z hlediska schopnosti podávat výkon při nadcházejícím úkolu. Využití nachází například u pracovníků v dolech, ale byly již také použity pro posouzení schopnosti řídit u řidičů kamiónů.

2. Systémy založené na matematickém modelu bdělosti

Tyto systémy využívají matematického modelu k předpovídání únavy a ospalosti v různých časových okamžicích. Využívají k tomu algoritmické posouzení dat, jako jsou doba spánku, denní doba, cirkadiální rytmy, a další faktory způsobující únavu. Využití nachází například pro firmy, které jsou pak schopny podle takového modelu sestavovat rozvrhy a délku pracovní doby.

3. Systémy pracující na principu detekce pohybu vozidla

Tato skupina systémů posuzuje řidičův výkon prostřednictvím proměnných, které odrážejí únavu řidiče na chování vozidla. Mezi takovéto proměnné patří: Rychlost vozidla, zrychlení, pozice na vozovce (přejíždění postranních čar apod.). Je známo, že tyto veličiny se mění v závislosti na bdělosti řidiče. Výhody těchto systémů spočívají zejména v jednoduché aplikovatelnosti a nepotřebnosti přímo sledovat řidiče. Tento přístup má však i své nevýhody, mimo jiné správné určení kritických hodnot pro posouzení kdy je řidič unaven a kdy není.

4. On-line systémy monitorující stav řidiče

Tyto systémy využívají měření fyziologických dat řidičova organismu, a k tomu využívají údaje získané z očí, srdce, mozkové aktivity, atd. Je známo, že člověk (tedy i řidič) přijímá většinu informací z okolí vizuálně. Proto se jako nejslibnější fyziologický aspekt jeví veličiny, které detekují pohyby očí a mrkání.

## **4.1 Komerčně zavedené systémy**

### **4.1.1 „SAM“ systém**

Tento systém je prodáván firmou Rebman Driver Systems Ltd. a je to detektor, který je instalován pod volant a má detekovat únavu řidiče prostřednictvím mikrokorekčních pohybů pomocí magnetického senzoru. Společnost ovšem neposkytuje žádné principy algoritmu ani žádný důkaz funkčnosti (13).

### **4.1.2 DAS 2000 Road Alert System**

DAS 2000 Road Alert Systém detekuje překřížení postraní čáry nebo čáry po pravé ruce. Pokud je čára překročena bez použití blinkru, tak systém vydá zvukový signál, aby upozornil řidiče na hrozící nebezpečí mikrosnánku (13).

### **4.1.3 SafeTRAC**

SafeTRAC Drowsy Driver Warning Systém, který prodává americká firma AssistWare Technology Inc., pracuje na principu detekce postraních čar prostřednictvím kamery umístěné v blízkosti předního skla a pomocí detekce natočení volantu (13).

### **4.1.4 TravAlert**

Systém je prodáván firmou TravAlert Safety International a pracuje na principu detekce pohybu volantu. O tomto produktu je poměrně málo dostupných informací (13).

### **4.1.5 Systémy zavedené automobilkami**

V současné době využívá, v některých svých modelech, automatického systému pro detekci únavy řidiče dva několik světových výrobců aut.

Systém Attention Assist firmy Mercedes – Benz využívá k těmto účelům několika signálů. Jedním z nejdůležitějších je signál nesoucí informaci o pohybech volantu. Dalšími signály, které tento systém využívá pro detekci únavy, jsou: charakter sešlapování pedálů, akcelerometry – dopředu-dozadu a doleva-doprava a tachometr. Kromě signálů, které jsou přímým ukazatelem jízdy řidiče, bere tento systém také v potaz faktory, které jsou řidičem neovlivnitelné. Mezi ně patří například momentální dopravní situace nebo vnější fyzikální faktory, jako jsou rychlost větru či povrch silnice. Tento systém také zohledňuje délku jízdy a denní dobu (11).

Systém Driver Alert Control v kombinaci se systémem Lane Departure Warning firmy Volvo upřednostňuje pro detekci únavy řidiče relativní polohu auta a vozovce za využití kamer a

senzorů (detekce polohy postranní čáry apod.) před přímou analýzou řídičova chování a tělesných ukazatelů únavy (12).

Za zmínku také stojí systém Nissan Anti-Drunk Driving Technology společnosti Nissan. Tento systém sice neměří přímou únavu řidiče, ale využívá stejných veličin pro posouzení schopnosti řídit vozidlo. Tento systém využívá analýzu videozáznamu a veličin z něho detekovatelných, tj. výraz v obličeji, zívání, mrkání, apod. Dále pak využívá, stejně jako systém společnosti Volvo, detekci relativní pozice auta na vozovce za použití detekce polohy postranních čar. Jestliže je u řidiče detekována opilost, automaticky dojde k zamčení převodovky a znemožnění jízdy. Tento systém byl implementován v modelu Nissan Fuga sedan (13).

## 4.2 Systémy patentované a ve vývoji

Vedle systémů, které jsou již komerčně zavedeny, existují také technologie, které jsou teprve ve vývoji nebo jsou patentovány, avšak nebyly zatím použity v širší praxi. Kromě systémů využívajících již zmíněné signály jsou to i systémy, které se svou technologií soustředí na detekci únavy pomocí jiných ukazatelů než již zmíněné systémy.

### 4.2.1 Systém pracující s analýzou EKG, HRV a síly úchopu volantu

Jak již bylo zmíněno dříve, pro signály snímané přímo z těla existuje jistá limitace z důvodu nutnosti aplikace elektrod přímo na pokožku. Tento systém však využívá elektrod zabudovaných přímo do volantu (Obr 1.)

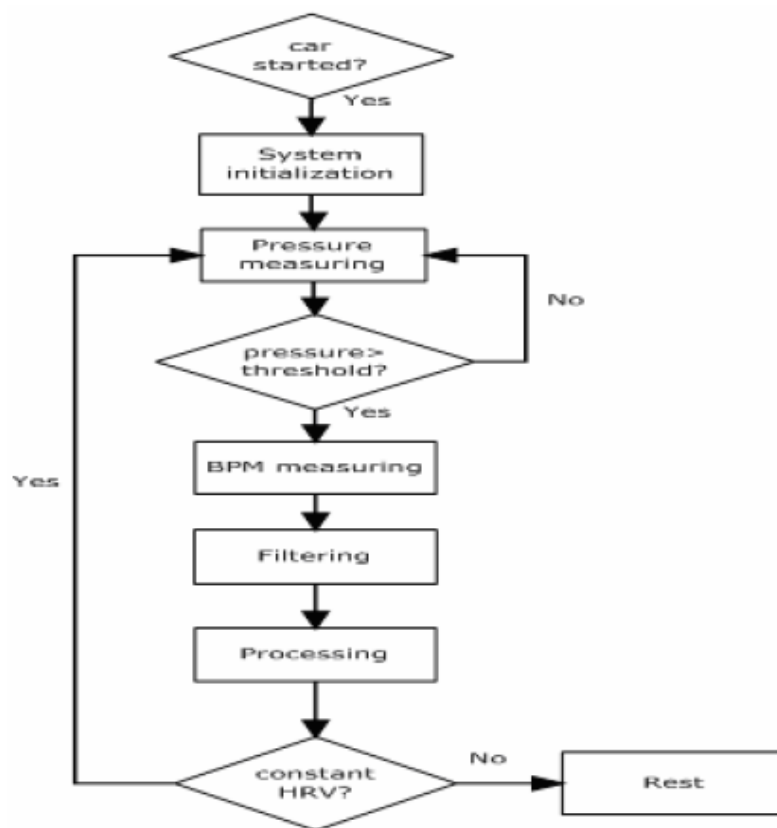


Obr. 5 Hardwarové vybavení systému pro detekci EKG signálu a síly úchopu volantu (8).

System sestává ze dvou částí – hardwarové a softwarové. Hardwarová pak z analogové, která zprostředkovává samotné snímání fyziologických signálů a jejich přenos do části digitální. Po analogově-digitálním převodu se v části digitální signály filtrují a předzpracovávají, ale kromě toho tato část také zprostředkovává přenos informace do vysílacího zařízení rozraní Bluetooth, Zigbee či klasického sériového kabelu.

Softwarová část pak na získané signály aplikuje jednoduchý algoritmus (Obr. 2), který vykonává následující úkony:

1. Přijímá signál přicházející z hardwarové části
2. Filtruje signál
3. Zpracovává signál
4. Analyzuje signály pro včasnou detekci vznikající únavy



Obr. 6 Blokové schéma algoritmu pro zpracování signálů z volantu (8).

Dle výsledků pokusů signály EKG, HRV a síly stisku volantu byly vhodné pro detekci únavy a dosahovaly uspokojivých výsledků (8). System má však samozřejmě určité limity, protože vyžaduje jistou minimální dobu snímání, proto aby mohl vyhodnotit řidičův stav



(nutnost získat dostatečný počet srdečních cyklů). Další limitace by pro praxi pak byly situace, kdy řidič např. uchopí volant v jiné poloze, či použije řidičské rukavice.

Přesto se tento přístup jeví jako slibný, obzvláště pak v kombinaci s technologiemi využívající vizuální metody a metody relativní polohy auta na vozovce.

#### 4.2.2 Systém dále rozvíjející snímání EKG

Tento systém dále rozvíjí přístup snímání EKG a analýzy variability srdečního rytmu (HRV). Kromě podobného mechanismu elektrod na volantu (v tomto případě sestávajících z vodivé látky), implementuje ještě elektrody zabudované do sedadla řidiče (taktéž z vodivé látky). Jednotlivé elektronické okruhy jsou pak přizpůsobeny oběma metodám snímání EKG. Signál z elektrod, které jsou na sedadle, je ještě upraven speciálním obvodem pro odstranění šumu.



Obr. 7 Vlevo – elektrody na volantu, vpravo – elektrody na sedadle řidiče

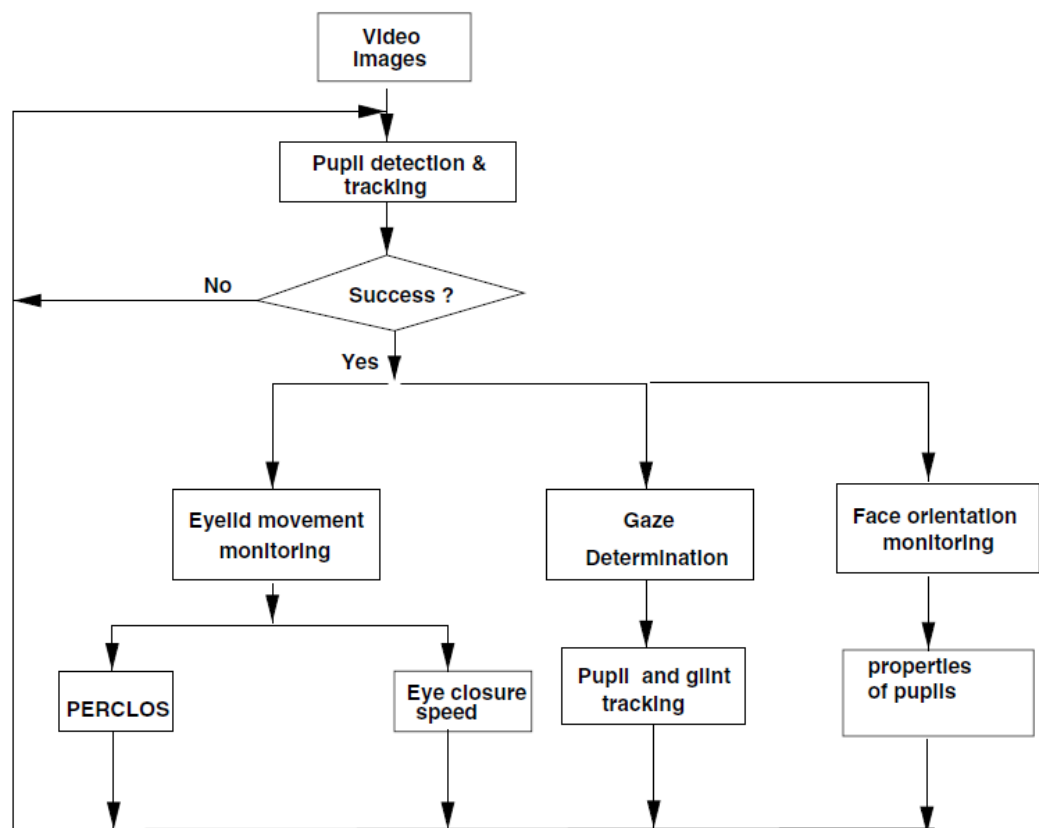
Dle autorů dosahují oba přístupy uspokojivých výsledků. Nespornou výhodou tohoto přístupu je samozřejmě jeho neinvazivnost, avšak má i nevýhody, které nelze opomenout:

1. Podobně jako u předešlého systému, musím mít řidič obě ruce na elektrodách, V okamžiku, kdy změní úchop volantu, signál mizí. Podobně, pokud si řidič nasadí rukavice, není detekován žádný signál.
2. Senzor na sedadle je velmi náchylný na impedanční změny a rušivé elementy z prostředí
3. HRV každé jedince je individuální, proto je nutné přizpůsobit jednotlivá měření každému člověku.

### 4.2.3 Systém hodnotící signály získané z videozáznamu

Takto získané signály jsou považovány za jedny z nejlepších ukazatelů únavy. A to nejen z hlediska možnosti detekovat jednotlivé signály, ale také z hlediska doby potřebné pro jejich snímání, aby bylo možné je vyhodnotit. Jedním z takovýchto systémů byl popsán pány Qiang Jinem a Xiaojie Yangem (14).

Mezi informace, které tento systém zpracovává, patří signály získané vyhodnocením videozáznamu. Informace získané z oblasti očí lze rozdělit na dva různé signály – PECLOS (percentage of eye closure over the pupil – procentuální překrytí oka víčkem) a rychlost mrknutí. Dále tento systém analyzuje pohled řidiče a pozici jeho hlavy. Na obr. 3 je toto schematicky znázorněno.



Obr. 8 Schéma systému popsaného Qiang Jinem a Xiaojie Yangem (14).

### 4.2.4 Systém DROWSI WP3

Tento systém je vyvíjen na řidičském simulátoru (Obr. 4), výhodou čehož je, že je možno simulovat i extrémní situace, které by za normálních experimentů v autě nebylo možno podstoupit (17).



**Obr. 9 Simulátor pro systém DROWSI WP3 (17)**

System využívá pro detekci únavy fyziologických parametrů získaných zejména z pohybů očí, jako jsou např. doba zavírání oka, délka mrknutí, apod. Ale také pak signálů charakterizující jízdu řidiče jako jsou zrychlení, či úhel natočení volantu. Zajímavé jsou pak signály získané ze síly úchopu volantu, a síly sešlapávání brzdového pedálu. Ojediněným je pak systém dvou proužků po stranách řidiče, které detekují kontakt v případě, že řidič usne a atypicky se nakloní do strany.

#### **4.2.5 Projekt „SAVE“**

Tento projekt využívá signálů z úhlu natočení volantu, laterálního zrychlení a detekci mrkání oka. Co je zajímavé na tomto projektu je to, že je navržen tak, že pokud detekuje únavu řidiče a řidič několikanásobně nedbá na varování, automobil převezme řízení a donutí řidiče zastavit (18).

#### **4.2.6 „AWAKE“ systém**

System AWAKE se skládá ze tří základních modulů. Modulu pro diagnózu bdělosti (Hypovigilance Diagnosis Module), modulu pro určení rizika dopravy (Traffic Risk Estimation Module) a modulu pro varování řidiče (Driver Warning System) (19). Vztah jednotlivých modulů je patrný z obrázku níže.



## 5. Měření

Data byla získána z měření, která proběhla v letech 2000 – 2002, v rámci projektu „Spící řidič, bdící auto.“ Měření probíhala formou jízdy do cílové destinace a zpět. Probandi byli členové týmu „Spící řidič, bdící auto.“ Při první jízdě byli řidiči odpočatí a čilí, druhou jízdu pak absolvovali po spánkové deprivaci, čímž byla navozena únava. Při každé jízdě byl v autě přítomen tříčlenný tým, sestávající z řidiče, spolujezdce a technika. Z každé jízdy pak byl zhotoven protokol, ve kterém byl popsán průběh celé jízdy, a byly zaznamenány jednotlivé události, které během jízdy nastaly. Na konci protokolu pak bylo stručné subjektivní zhodnocení jízdy samotným řidičem.

Pro samotná měření bylo využito auto Škoda Octavia, které bylo zapůjčeno firmou Škoda auto. Dále byl použit venkovní a vnitřní kamerový systém a mobilní měřicí systém, který sestával z:

- Polygraf pro snímání biologických a technických signálů
- Jednotka unifikované signálové sběrnice
- Jednotka pro bezkontaktní snímání polohy volantu
- Jednotka pro měření hygienických parametrů kabiny
- Jednotka pro snímání axiálního a radiálního zrychlení




**Obr. 11 Mobilní měřicí systém zepředu (vlevo) a zezadu (vpravo)**

Mobilní systém sestával z počítače (PC Pentium 200 MHz), LCD monitoru, pevných disků odolných proti vibracím o kapacitě 6GB a byl napájen pomocí UPS. Při jízdách byl pak ovládán technikem, který seděl na levém zadním sedadle.

Polygraf, pomocí kterého se snímaly jednotlivé signály, byl systém BrainScope, M&I s.r.o., Neurosciece Technology Research Ltd. s následujícími parametry:

- 32 unipolárních vstupů
- 8 bipolárních vstupů
- vstupní rozsah +/- 100  $\mu$ V až +/- 10 mV
- dolní mezní kmitočet 0,015 - 1,5 Hz
- horní mezní kmitočet 30 - 1000 Hz
- A/D převodník 14 bitů
- vzorkovací kmitočet typicky 100 - 500 Hz
- CMRR min. 94 dB na 50 Hz
- Interní kalibrace
- IEC 601.1 třída I typ BF
- 5 digitálních vstupů
- TTL logika
- 8 externích analogových vstupů
- Vstupní rozsah symetrický ŠŠ 2V
- Nahrávací software E<sup>A</sup>SYS2



Obr. 12 Polygraf BrainScope

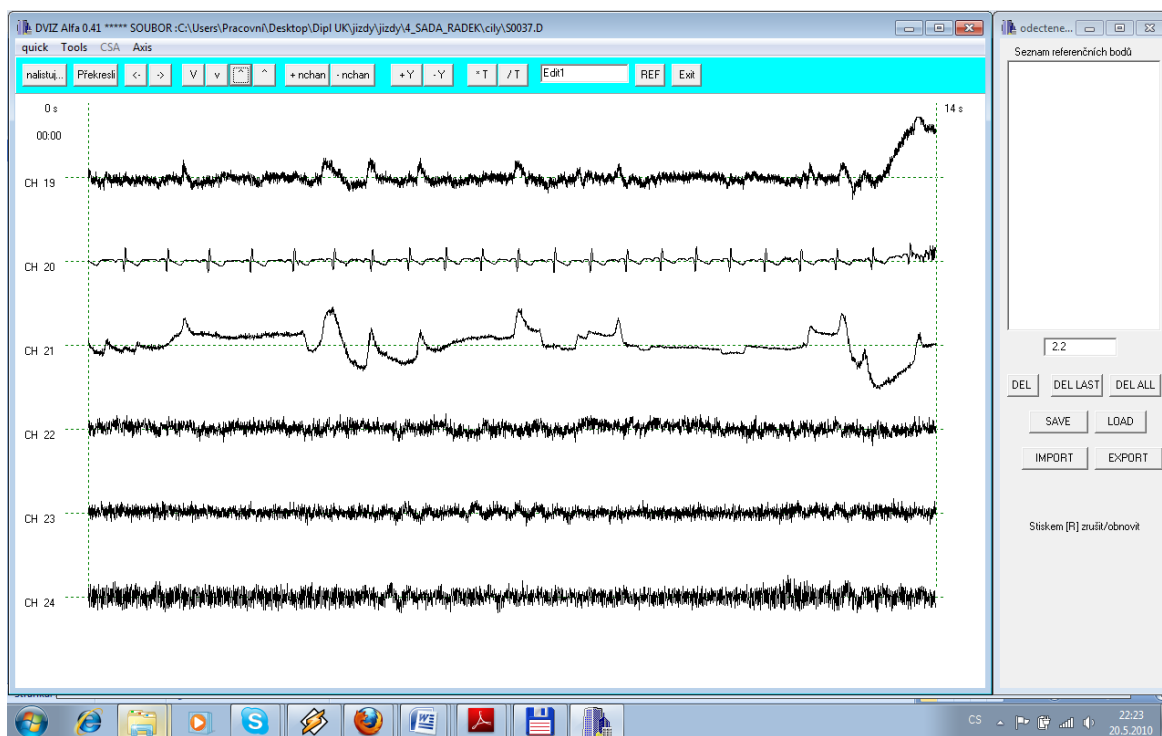
Pro měření pak byly použity následující kanály a veličiny při vzorkovací frekvenci 200 Hz:

1. Kanály 1 – 19 – Záznam EEG
2. Kanál 20 – Záznam EKG
3. Kanály 21 – 22 – Záznam EOG – horizontální a vertikální
4. Kanály 23 – 24 – Zrychlení axiální a radiální
5. Kanál 25 – Záznam z Hallovy sondy ve volantu
6. Kanál 26 – Optický snímač z volantu
7. Kanál 27 – Hladina hluku v kabině
8. Kanál 28 – Změny teploty v kabině
9. Kanál 29 – Hladina světla v kabině

## 6. Metody

### 6.1 Předzpracování dat

Pro první, vizuální hodnocení dat a export do textového souboru z souboru datového s koncovkou .d jsem využil program dviz42b, který mi poskytl vedoucí mé práce Ing. Pavel Smrčka Ph.D.



Obr. 13 Ukázka programu dviz42b

Pro hodnocení únavy jsem vybral záznam EOG, který byl zaznamenáván kanálem 21 a záznam z Hallovovy sondy, který byl zaznamenáván kanálem 25. Tyto kanály jsem z jednotlivých záznamů jízd vyexportoval za pomoci programu dviz42b do textových souborů.

Takto transformovaná data jsem dále načítal do programu Matlab, kde jsem prováděl předzpracování signálů. Nejprve jsem signály nevzorkoval v poměru 1:20, což vedlo ke změně vzorkovací frekvence na 20 Hz. Dále jsem na signál EOG aplikoval filtr horní propust', abych ho zbavil nízkofrekvenčních složek. Následně jsem aplikoval filtr dolní propust', a to zejména z důvodu kvalitnější detekce jednotlivých mrknutí.

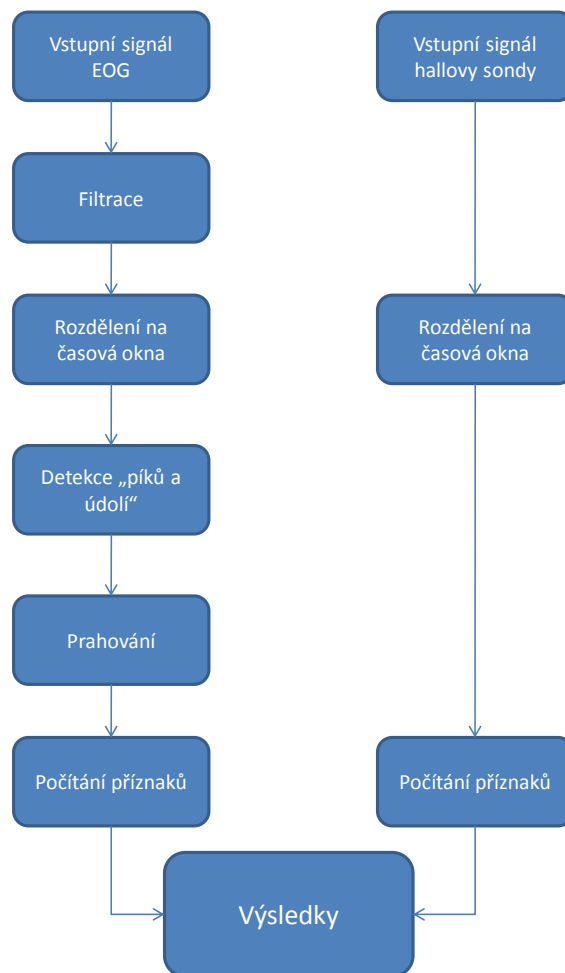
Z takto upravených signálů jsem pak prováděl výpočet jednotlivých příznaků pro rozlišení bdělosti a únavy. K jednotlivým signálům bylo potřeba přistupovat individuálně, protože se lišily v napěťovém rozpětí, což bylo pravděpodobně způsobeno odlišným umístěním EOG elektrod.

## 6.2 Vypočtené příznaky za signálů EOG a Hallovy sondy

Pro výpočet příznaků ze signálů EOG a Hallovy sondy, jsem signál rozdělil na jednotlivá časová okna, která měla rozsah 30s.

Pro detekci jednotlivých píků v EOG, které reprezentovaly jednotlivá mrknutí, jsem nejprve v daném okně detekoval maxima a minima signálu. Pro tento účel jsem využil algoritmus volně dostupný na internetu – `peak_valley.m`. Následné stanovení, které hodnoty jsou píky mrknutí, jsem naprogramoval prahovací podmínku.

Signál Hallovy sondy jsem taktéž zpracovával v časovém okně o velikosti 30s, přičemž jednotlivé příznaky jsem počítal bez úprav daného signálu (s výjimkou příznaku posledního).



Obr. 14 Postup při zpracování signálu



V časových oknech jsem pak počítal následující příznaky:

1. Počet mrknutí
2. Průměrná šířka mrknutí
3. Rychlost zavření oka (tj. náběžná hrana píku při mrknutí)
4. Rychlost otevření oka (tj. sestupná hrana píku při mrknutí)
5. Průměrná vzdálenost mrknutí
6. Počet mrknutí pod určitou frekvenční hranicí
7. Směrodatná odchylka úhlu natočení volantu
8. Směrodatná odchylku rychlosti natočení volantu
9. Mód úhlu natočení volantu
10. Maximální rychlost natočení volantu
11. Průměrná hodnota power spektra vysokých frekvencí

### **Počet mrknutí**

Tento ukazatel vycházel z předpokladu, že unavený řidič mrká častěji než řidič čilý. Příznak jsem odečítal jednoduchým ověřením velikosti proměnné, ve které byla daná mrknutí aktuálního okna.

### **Průměrná šířka mrknutí**

Zde jsem bral v úvahu předpoklad, že unavený řidič, na rozdíl od čilého oči zavírá i otevírá pomaleji. Pro výpočet tohoto příznaku jsem šířku, kterou jsem spočítal odečtením pozice konce píku od pozice začátku píku.

$$PSM = \frac{\sum_{i=0}^n (p_{i_k} - p_{i_z})}{p_n}$$

**Rov. 2 Výpočet průměrné šířky mrknutí**

### **Rychlost zavření oka**

Tento ukazatel, označován v literatuře také jako AECS, vypovídá zejména o „padání víček“ řidiče. Na EOG se tak projeví pomalejší sestupnou hranou daného píku. Výpočet tohoto příznaku jsem prováděl jako podíl změny napětí za daný časový úsek (resp. Počet vzorků signálu)

$$AECS = \frac{\sum_{i=0}^n \frac{\Delta A_{p_i}}{\Delta t_{p_i}}}{p_n}$$

**Rov. 3 Výpočet průměrné rychlosti zavření oka**

### **Rychlost otevření oka**

Předpoklad u tohoto příznaku vycházel, podobně jakou u předchozích dvou, z celkově zpomalené aktivity očních víček řidiče. Výpočet příznaku byl analogií příznaku Rychlost zavření oka, tj. podíl změny napětí za daný časový úsek (resp. Počet vzorků signálu).

### **Průměrná vzdálenost mrknutí**

Bylo prokázáno, že řidič, který je unaven zavírá oči pomaleji než řidič čilý nebo se mrkání vyskytuje v takzvaných „salvách,“ tzn. několik rychle po sobě jdoucích rychlých mrknutí. Toto bylo východiskem pro výpočet příznaku. Ten jsem prováděl odečítáním pozic jednotlivých píků.

$$PVM = \frac{\sum_{i=0}^n (p_{i+1} - p_i)}{p_n}$$

**Rov. 4 Výpočet průměrné vzdálenosti mrknutí**

### **Počet mrknutí pod určitou frekvenční hranicí v histogramu**

Tento příznak pracoval s předpokladem detekce již zmíněných „salv“ mrknutí. To znamená, že pokud by se v daném časovém okně vyskytla taková sekvence, projevil by se to na histogramu frekvence mrknutí unaveného řidiče jako nárůst počtu mrknutí ve vyšší frekvenci za sebou.

### **Průměrná hodnota úhlu natočení volantu**

Tento příznak byl navrhnut podle dostupných údajů z literatury (17), kde je popsáno, že je významný rozdíl mezi hodnotami tohoto příznaku u čilých a unavených řidičů. Výsledkem tohoto článku byl fakt, že unavení řidiči se drží více levé postranní čáry nežli řidiči čilí. Testy z jiné literatury tento fakt nepotvrzují (18), přesto je tento příznak slibným ukazatelem únavy.

### **Směrodatná odchylka rychlosti natočení volantu**

Příznak byl vybrán na základě potvrzení relevantnosti v literatuře (18), kde bylo potvrzeno, že je zjevný rozdíl v hodnotách tohoto příznaku u čilých a unavených řidičů. Vychází se z předpokladu, že čilý řidič provádí během jízdy tzv. „mikrokorekce,“ zatímco řidič unavený nechává vozidlo jet jedním směrem delší dobu a poté upraví směr náhle.

### **Mód úhlu natočení volantu**

Mód úhlu natočení volantů je definován jako suma absolutní hodnoty úhlu natočení volantu minus průměrná hodnota tohoto úhlu, dělená počtem těchto hodnot (viz. Rovnice 4). Je používán pro kompenzaci offsetu, který obvykle u měření úhlu volantu bývá přítomen.

$$ModeSA = \frac{1}{N} \sum_{i=0}^n (\theta_i - \theta_m)$$

**Rov. 5 Výpočet módu natočení volantu**

### **Maximální rychlost natočení volantu**

Podobně jako u příznaku mód úhlu, předpokládá tento příznak náhle korekce směru jízdy doprostřed vozovky od krajnice po delší době bez pohybů volantu.

$$Max = \sum_{i=0}^n \max(\omega_i)$$

**Rov. 6 Výpočet maximální rychlost natočení volantu**

### **Průměrná hodnota power spektra vysokých frekvencí**

Tento příznak obsahuje, na rozdíl od ostatních příznaků, které se vypočítávají z natočení volantu, složitější výpočet, včetně Fourierovy transformace. Signál natočení volantu je nejprve filtrován filtrem typu horní propust', aby se odfiltrovaly pomalé pohyby volantu. Poté je ze signálů pomocí rychlé Fourierovy transformace spočítáno power spektrum signálu v daném časovém okně a vypočítána průměrná hodnota energie tohoto spektra.


Teorie tohoto příznaku spočívá také v měření „mikrokorektur.“ Protože unavený řidič provádí mikrokorektury méně často, avšak využívá k tomu většího úhlu, mělo by docházet ke zvětšení energie nesené daným signálem.

## **6.3 Vyhodnocení dat v programu Microsoft Excel**

Po předzpracování signálů a vypočtení jednotlivých příznaků jsem tabulky s výsledky exportoval do programu Microsoft Excel, kde jsem data vizualizoval prostřednictvím grafů.

### **6.3.1 Grafy v časové oblasti**


Nejprve jsem zanesl do grafů hodnoty jednotlivých příznaků v závislosti na čase. Tyto grafy posloužily pro vizuální zhodnocení jednotlivých příznaků a t některých již byla patrná relevance pro rozlišování bdělosti a únavy. Na obr. 7 je příklad takového grafu. Všechna takto zpracovaná data jsou k dispozici v elektronických přílohách na přiloženém CD.



Obr. 15 Příklad grafu pro zobrazení hodnoty příznaku v časové oblasti

### 6.3.2 Burzovní grafy

Následně jsem data zpracovával do „box grafů,“ neboli burzovních grafů. Z těchto grafů bylo patrné statistické rozložení hodnot jednotlivých příznaků. Pro výpočet jsem použil statistické funkce, které při výpočtu vyřadí část krajních extrémních hodnot (5% na každé straně rozložení). Pro ilustraci opět uvádím jeden z grafů (Obr. 8). Zbylé grafy jsou v příloze na CD.



Obr. 16 Příklad burzovního grafu

### 6.3.3 Statistické hodnocení pomocí studentova t-testu

Pro statistické hodnocení relevantnosti jednotlivých příznaků jsem použil oboustranného studentova t-testu. Jako nulovou hypotézu jsem zvolil tvrzení, že daná rozdělení jsou shodná, tj:

$$H_0: m_{\bar{c}} = m_u$$

#### Rov. 7 Nulová hypotéza

Pro lepší přehlednost jsem dále do tabulky zahrnul výpočet  $(1-TTEST)*100$ , a následně jsem hodnoty tohoto výpočtu, které byly nad 95 (tzn. že hladina významnosti  $\alpha=0,05$ ).

## 6.4 Aplikace metod automatické klasifikace v programu Weka

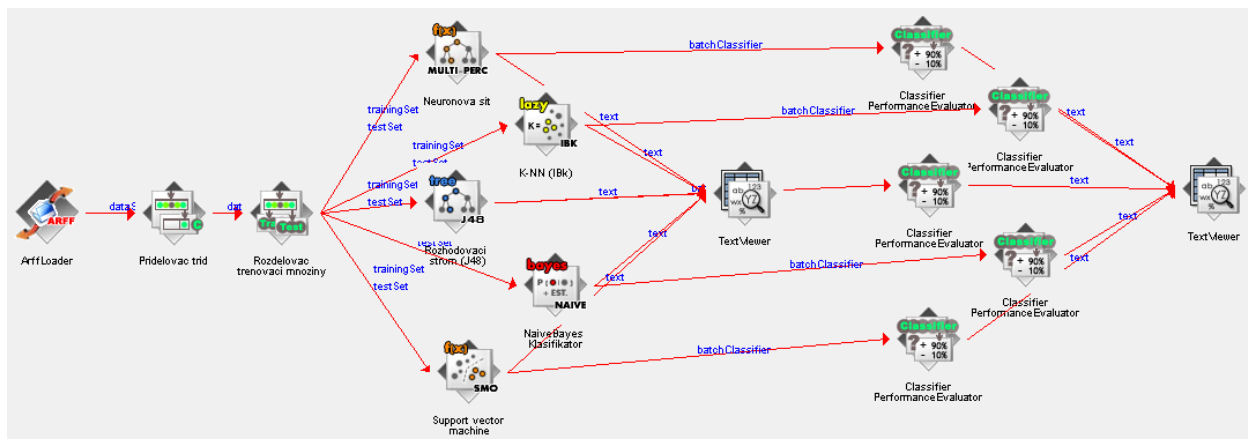
Automatickou klasifikací jsem prováděl v programu open source programu Weka, který byl vyvinut na Univerzite Waikato na Novém Zélandě. Program jsem vybral kvůli jednoduché manipulaci, mé předchozí zkušenosti s ním, a v neposlední řadě také kvůli možnosti případného exportu z programovacího jazyka Java do programovacího jazyka C++.

Pro automatickou klasifikaci jsem použil následující algoritmy:

1. Klasifikátor K-nejbližší soused (IBk)
2. Rozhodovací strom (J48)
3. Naivní bayesův klasifikátor
4. Metoda podpůrných vektorů
5. Neuronová síť

Aby bylo možno využít programu Weka pro klasifikaci, bylo nutné exportovat data z jednotlivých listů excelu do souborů formátu .arff. Tyto soubory jsou klasickými textovými soubory, které mají na svém začátku hlavičku definující relaci a označující jednotlivé příznaky a stavy. Kromě definování hlavičky byla ještě zapotřebí úprava souboru pomocí nahrazení čárek za tečky a následujícím nahrazení tabulátorů, které oddělovaly jednotlivé sloupce dat, za čárky. Nakonec jsem označil data, kdy byl řidič cílým stavem – cíly, a kdy byl řidič unaveným stavem – unaveny.

Pro sestavení samotné klasifikace, kdy jsem využil modul KnowledgeFlow programu Weka a to zejména kvůli jednoduché a přehledné manipulaci s daty. V tomto modulu jsem sestavil postup pro automatickou klasifikaci dat. Nejprve jsem zařadil blok pro načítání arff souboru, následovaný blokem pro výběr stavu a blokem pro rozdělení dat na trénovací a testovací množiny (poměrem 2:1). Po rozdělení dat, jsem množiny použil pro trénování a testování jednotlivých klasifikátorů. Pro vizualizaci natrénovaných klasifikátorů jsem zařadil vizualizační blok, prostřednictvím něhož bylo možné nahlédnout do sestavených klasifikátorů. Nakonec byly zařazeny bloky pro hodnocení úspěšnosti jednotlivých klasifikátorů a bloky pro následnou vizualizaci výsledků. Schéma v modulu KnowledgeFlow je znázorněno na Obr. 9.



Obr. 17 Schéma v modulu KnowledgeFlow programu Weka

Výsledky úspěšnosti jednotlivých klasifikátorů u jednotlivých řidičů jsem zpracoval v tabulkách programu MS Excel.

## 7. Výsledky

Data, která jsem měl k dispozici, byla naměřena v průběhu pěti jízd od 5 různých řidičů. Jak již bylo zmíněno, bylo potřeba k jednotlivým měřením přistupovat individuálně, z důvodu rozdílných amplitudových rozpětí a individuálních dispozic. Například: Někdo nosí čočky a v důsledku toho mrká častěji, než někdo kdo čočky nenosí. Z tohoto důvodu jsem vyhodnocoval jednotlivé řidiče a posuzoval schopnost příznaků rozlišit mezi bdělostí a únavou individuálně.

Průběhy jednotlivých jízd a podmínky, za kterých byly vykonány, jsou uvedeny v protokolech, které lze nalézt na přiloženém CD. Nejprve provádím subjektivní hodnocení jednotlivých příznaků na základě vizuálního zhodnocení grafů, přičemž grafy, které jsou zajímavé pro klasifikaci uvádím, a zbylé grafy jsou zařazeny do příloh na CD. Výsledky pro každého řidiče jsou shrnuty v tabulce t-testu a tabulce úspěšnosti klasifikátorů.

V poslední části této kapitoly generalizuji data, tj. vyhodnocuji, které příznaky byly relevantní u kolika řidičů, a to formou přehledové tabulky, kde barevná pole znázorňují příznaky, které byly pro daného řidiče relevantní. Nakonec vyhodnocuji celkovou úspěšnost jednotlivých klasifikátorů.

Součástí učení jednotlivých klasifikátorů bylo také vytvoření podmínek pro klasifikaci. Tyto podmínky jsou zpracovány v příloze na přiloženém CD.


## 7.1 Řidič 1

K těmto jízdám není přiloženo subjektivní hodnocení únavy řidičem, proto nelze ohodnotit korelaci mezi křivkou a subjektivním pocitem. Křivky pro čilý stav EOG obsahují 3 ostré píky. 2 z nich mají nulovou hodnotu, což bylo pravděpodobně způsobeno chybnou detekcí mrknání a třetí má naopak hodnotu vysokou, což mohlo být způsobeno zarušením signálu.

**Počet mrknutí** - Průběh je do tří čtvrtin téměř nerozlišitelný – obě křivky mají přibližně stejnou střední hodnotu. Přibližně po třech čtvrtinách záznamu dochází k rozestupu křivek a znatelnému rozdílu mezi čilým a unaveným stavem.

**Průměrná šířka mrknutí** - Křivky mají znatelně odlišnou střední hodnotu a příležitostně se překříží.


**Rychlost zavření oka** - Křivky jsou již na první pohled jasně rozlišitelné, přičemž střední hodnota křivky pro čilý stav je až dvojnásobná.



Graf 1 Rychlost zavření oka, řidič 1

**Rychlost otevření oka** - Podobně jako u předešlého příznaku je rozdíl v křivkách patrný. Křivka pro stav čilý v průběhu výrazněji klesá ke křivce pro stav unavený.





Graf 2 Rychlost otevření oka, řidič 2

**Průměrná vzdálenost mrknutí** - Křivky nejsou jasně odlišitelné, křivka čilého řidiče obsahuje několik ostrých píků.

**Histogramový počet** - Křivky nejsou jasně rozlišitelné, pouze v poslední čtvrtině je náznak jisté rozbíhavosti.

**Průměr úhlu** - Křivky nejasně rozlišitelné. Křivka unaveného řidiče se pohybuje spíše pod křivkou čilého řidiče.

**stdSAV** - Křivky nejasně rozlišitelné. Křivka unaveného řidiče se opět pohybuje spíše pod křivkou čilého řidiče.

**Mód úhlu** - Křivky nejasně rozlišitelné. Křivka čilého řidiče vykazuje větší a ostřejší píky.

**maxSAV** - Křivky nerozlišitelné.

**Průměr power spektra** - Křivky nejasně rozlišitelné. Křivka unaveného řidiče probíhá mírně pod křivkou čilého řidiče.

| Studentův t-test |                             |                        |                      |                       |
|------------------|-----------------------------|------------------------|----------------------|-----------------------|
| Příznaky         | Počet mrknutí               | Průměrná šířka mrknutí | Rychlost zavření oka | Rychlost otevření oka |
| TTEST            | 1,25362E-06                 | 4,60553E-27            | 2,46363E-60          | 3,38254E-63           |
| (1-TTEST)*100    | 99,99987464                 | 100                    | 100                  | 100                   |
| Příznaky         | Průměrná vzdálenost mrknutí | Histogramový počet     | Průměr úhlu          | stdSAV                |
| TTEST            | 0,561599067                 | 0,9827178              | 8,23753E-08          | 4,15593E-05           |
| (1-TTEST)*100    | 43,84009329                 | 1,728220024            | 99,99999176          | 99,99584407           |
| Příznaky         | Mód úhlu                    | maxSAV                 | Průměr power spektra |                       |
| TTEST            | 0,427518946                 | 0,289116866            | 1,67609E-07          |                       |
| (1-TTEST)*100    | 57,24810538                 | 71,08831343            | 99,99998324          |                       |

**Tab. 1 Výsledky studentova t-testu pro jednotlivé příznaky, řidič 1**

Příznaky relevantní pro tohoto řidiče byly:

1. Počet mrknutí
2. Průměrná šířka mrknutí
3. Rychlost zavření oka
4. Rychlost otevření oka
5. Průměr úhlu
6. stdSAV
7. Průměr power spektra

| Klasifikátor             | Úspěšnost [%] |
|--------------------------|---------------|
| K-nejbližší soused       | 96,19         |
| Rozhodovací strom (J48)  | 89,52         |
| Naive Bayes klasifikátor | 95,24         |
| Podpurné vektory         | 96,19         |
| Neuronová síť            | 97,14         |

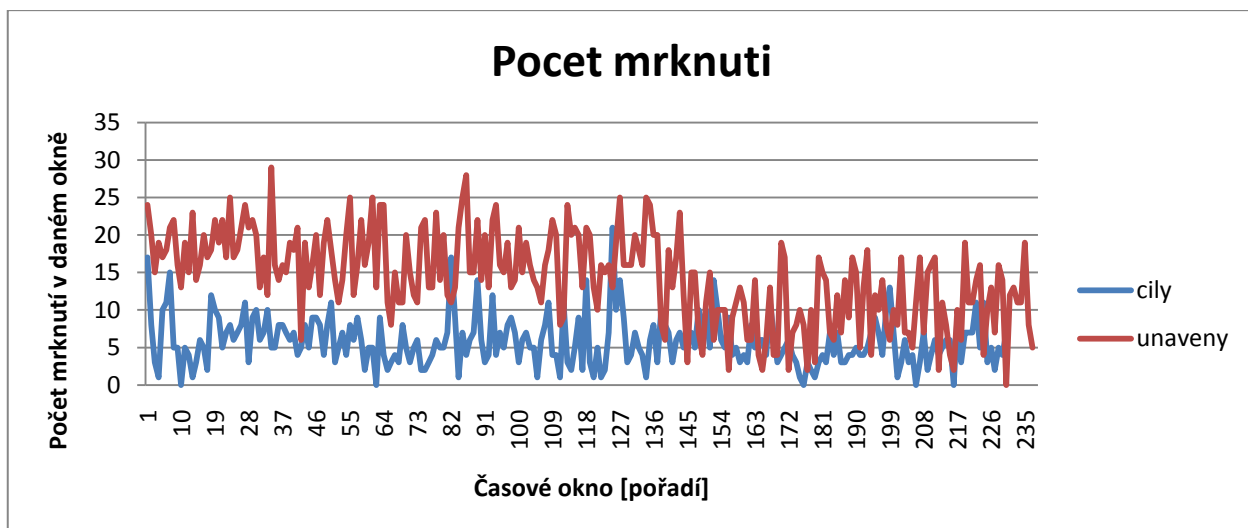
**Tab. 2 Úspěšnost jednotlivých klasifikátorů, řidič 1**

Nejvyšší úspěšnost u řidiče 1 dosahoval klasifikátor neuronová síť, a to s úspěšností 97,14%.

## 7.2 Řidič 2

V grafech, které hodnotí EOG se opět objevuje několik ostrých píků, které jsou opět způsobeny absencí mrknutí v daném časovém okně. Protokol s hodnocením řidiče chyběl.

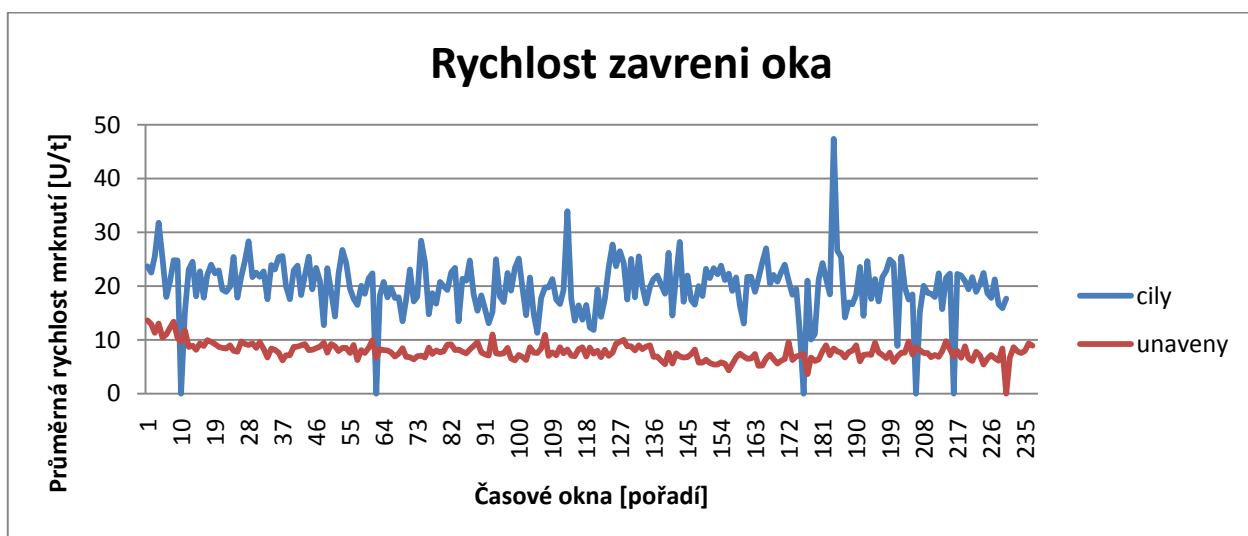
**Počet mrknutí** – na rozdíl od řidiče 1 byl u tohoto řidiče dle vizuálního posouzení grafu potvrzen předpoklad, že unavený řidič mrká častěji. Křivky jsou poměrně jasně rozlišitelné s mírným přiblížením na konci grafu.



Graf 3 Počet mrknutí, řidič 2


**Průměrná šířka mrknutí** – Křivky se překrývají a mají poměrně stejnou střední hodnotu. Křivka čilého řidiče má pouze o něco větší variabilitu než křivka řidiče unaveného.

**Rychlost zavření oka** – U těchto křivek je opět možné rozpoznat rozdíl mezi stavy řidiče.



Graf 4 Rychlost zavření oka, řidič 2


**Rychlost otevření oka** – i tyto dvě křivky jsou poměrně jasně odlišitelné, avšak ne tak jasně jako u předchozího příznaku.



Graf 5 Rychlost otevření oka, řidič 2

**Průměrná vzdálenost mrknutí** – Křivky u tohoto příznaku jsou mírně rozlišitelné přibližně do půlky grafu, kde sbíhají.

**Histogramový počet** – Křivky jsou poměrně jasně rozlišitelné. Křivka čilého řidiče se pohybuje blízko osy x.



Graf 6 Histogramový počet, řidič 2

**Průměr úhlu** – Křivky jsou téměř nerozlišitelné, mají přibližně stejný průběh.

**stdSAV** – Křivky jsou opět poměrně stejné a v průběhu času se několikrát překříží.

**Mód úhlu** – Křivky nerozlišitelné.

**maxSAV** – Křivky opět nejasně rozlišitelné, pouze přibližně uprostřed jsou na obou křivkách znatelné píky.

**Průměr power spektra** – Křivky nerozlišitelné.

| Studentův t-test |                             |                        |                      |                       |
|------------------|-----------------------------|------------------------|----------------------|-----------------------|
| Příznaky         | Počet mrknutí               | Průměrná šířka mrknutí | Rychlost zavření oka | Rychlost otevření oka |
| TTEST            | 9,38719E-58                 | 0,427005261            | 9,75146E-69          | 4,46834E-67           |
| (1-TTEST)*100    | 100                         | 57,29947391            | 100                  | 100                   |
| Příznaky         | Průměrná vzdálenost mrknutí | Histogramový počet     | Průměr úhlu          | stdSAV                |
| TTEST            | 9,21229E-19                 | 3,73622E-45            | 0,476540602          | 0,01469065            |
| (1-TTEST)*100    | 100                         | 100                    | 52,34593983          | 98,53093496           |
| Příznaky         | Mód úhlu                    | maxSAV                 | Průměr power spektra |                       |
| TTEST            | 0,96971454                  | 0,059926156            | 0,238326372          |                       |
| (1-TTEST)*100    | 3,028545992                 | 94,00738437            | 76,16736279          |                       |

**Tab. 3** Výsledky studentova t-testu pro jednotlivé příznaky, řidič 2

Příznaky relevantní pro tohoto řidiče byly:

1. Počet mrknutí
2. Rychlost zavření oka
3. Rychlost otevření oka
4. Průměrná vzdálenost mrknutí
5. Histogramový počet
6. stdSAV

| Klasifikátor             | Úspěšnost [%] |
|--------------------------|---------------|
| K-nejbližší soused       | 97,65         |
| Rozhodovací strom (J48)  | 97,65         |
| Naive Bayes klasifikátor | 95,29         |
| Podpůrné vektory         | 97,06         |
| Neuronová síť            | 96,47         |

**Tab. 4** Úspěšnost jednotlivých klasifikátorů, řidič 2

Nejvyšší úspěšnost u řidiče 2 dosahovaly shodně klasifikátory K-nejbližší soused a Rozhodovací strom (J48), a to s úspěšností 97,14%.


## 7.3 Řidič 3

U tohoto řidiče byl jednoznačný pouze jeden příznak, a to Rychlost zavření oka. K dispozici byl i subjektivní vnímání únavy řidiče. Ten však nekorespondoval s křivkou příznaku.

**Počet mrknutí** – Křivky nejsou jasně rozlišitelné a v průběhu se několikrát překříží.

**Průměrná šířka mrknutí** – Křivky nejasně rozlišitelné, přičemž mají téměř stejnou střední hodnotu i variabilitu.

**Rychlost zavření oka** – Stejně jako u předchozích dvou řidičů je u tohoto příznaku jasně rozlišitelný rozdíl mezi křivkami čilého a unaveného řidiče.



Graf 7 Rychlost zavření oka, řidič 3

**Rychlost otevření oka** – Křivky jsou nejasně rozlišitelné.

**Průměrná vzdálenost mrknutí** – Křivky mírně rozlišitelné. Křivka unaveného řidiče je mírně pod křivkou čilého řidiče.

**Histogramový počet** – Mírně znatelný rozdíl mezi křivkami, avšak hodnoty obou křivek klesají často na hodnotu nula.

**Průměr úhlu** – Křivky nerozlišitelné.

**stdSAV** – Křivky nerozlišitelné.

**Mód úhlu** – Křivky nerozlišitelné.

**maxSAV** – Křivky nerozlišitelné.

## Průměr power spektra – Křivky nerozlišitelné.

| Studentův t-test |                             |                        |                      |                       |
|------------------|-----------------------------|------------------------|----------------------|-----------------------|
| Příznaky         | Počet mrknutí               | Průměrná šířka mrknutí | Rychlost zavření oka | Rychlost otevření oka |
| TTEST            | 1,22054E-26                 | 0,015044576            | 5,09341E-27          | 2,1752E-05            |
| (1-TTEST)*100    | 100                         | 98,49554243            | 100                  | 99,9978248            |
| Příznaky         | Průměrná vzdálenost mrknutí | Histogramový počet     | Průměr úhlu          | stdSAV                |
| TTEST            | 4,76376E-13                 | 1,79662E-28            | 0,751950003          | 0,346091728           |
| (1-TTEST)*100    | 100                         | 100                    | 24,80499966          | 65,39082722           |
| Příznaky         | Mód úhlu                    | maxSAV                 | Průměr power spektra |                       |
| TTEST            | 0,335599001                 | 0,942173518            | 0,36553187           |                       |
| (1-TTEST)*100    | 66,44009994                 | 5,782648242            | 63,44681297          |                       |

Tab. 5 Výsledky studentova t-testu pro jednotlivé příznaky, řidič 3

Příznaky relevantní pro tohoto řidiče byly:

1. Počet mrknutí
2. Průměrná šířka mrknutí
3. Rychlost zavření oka
4. Rychlost otevření oka
5. Průměrná vzdálenost mrknutí
6. Histogramový počet


| Klasifikátor             | Úspěšnost [%] |
|--------------------------|---------------|
| K-nejbližší soused       | 76,58         |
| Rozhodovací strom (J48)  | 79,75         |
| Naive Bayes klasifikátor | 75,32         |
| Podpůrné vektory         | 78,48         |
| Neuronová síť            | 79,75         |

Tab. 6 Úspěšnost jednotlivých klasifikátorů, řidič 3

Nejvyšší úspěšnost u řidiče 3 dosahovaly shodně klasifikátory neuronová síť a Rozhodovací strom (J48), a to s úspěšností 79,75%.

## 7.4 Řidič 4


**Počet mrknutí** – Křivky poměrně dobře rozlišitelné, avšak na jejich konci dochází k překřížování.



Graf 8 Počet mrknutí, řidič 4

**Průměrná šířka mrknutí** – Křivky nerozlišitelné.

**Rychlost zavření oka** – Stejně jako u ostatních řidičů, i u tohoto bylo jasně rozlišitelné, zda je unavený nebo ne podle tohoto příznaku.




Graf 9 Rychlost zavření oka, řidič 4



**Rychlost otevření oka** – Křivky nerozlišitelné.

**Průměrná vzdálenost mrknutí** – Křivka unaveného řidiče je zřetelně pod křivkou řidiče čilého, avšak rozdíl není výrazný.

**Histogramový počet** – Poměrně jasně rozlišitelné křivky.



Graf 10 Histogramový počet, řidič 4

**Průměr úhlu** – Křivky nerozlišitelné.

**stdSAV** – Křivka čilého řidiče se pohybuje mírně pod křivkou řidiče unaveného.

**Mód úhlu** – Křivky nerozlišitelné.

**maxSAV** – Podobně jako u příznaku stdSAV se křivka čilého řidiče pohybuje mírně pod křivkou řidiče unaveného.

**Průměr power spektra** – Křivky nerozlišitelné.

| Studentův t-test |                             |                        |                      |                       |
|------------------|-----------------------------|------------------------|----------------------|-----------------------|
| Příznaky         | Počet mrknutí               | Průměrná šířka mrknutí | Rychlost zavření oka | Rychlost otevření oka |
| TTEST            | 3,53635E-59                 | 0,993990517            | 0,001429755          | 1,24304E-08           |
| (1-TTEST)*100    | 100                         | 0,600948311            | 99,85702454          | 99,99999876           |
| Příznaky         | Průměrná vzdálenost mrknutí | Histogramový počet     | Průměr úhlu          | stdSAV                |
| TTEST            | 9,42423E-15                 | 4,08279E-35            | 0,951561573          | 2,33135E-08           |
| (1-TTEST)*100    | 100                         | 100                    | 4,843842661          | 99,99999767           |
| Příznaky         | Mód úhlu                    | maxSAV                 | Průměr power spektra |                       |
| TTEST            | 0,813070211                 | 0,000203992            | 0,900523122          |                       |
| (1-TTEST)*100    | 18,69297887                 | 99,97960078            | 9,94768779           |                       |

**Tab. 7 Výsledky studentova t-testu pro jednotlivé příznaky, řidič 4**

Příznaky relevantní pro tohoto řidiče byly:

1. Počet mrknutí
2. Rychlost zavření oka
3. Rychlost otevření oka
4. Průměrná vzdálenost mrknutí
5. Histogramový počet
6. stdSAV
7. maxSAV

| Klasifikátor             | Úspěšnost [%] |
|--------------------------|---------------|
| K-nejbližší soused       | 75,16         |
| Rozhodovací strom (J48)  | 80,25         |
| Naive Bayes klasifikátor | 80,89         |
| Podpůrné vektory         | 80,89         |
| Neuronová síť            | 78,34         |

**Tab. 8 Úspěšnost jednotlivých klasifikátorů, řidič 4**

Nejvyšší úspěšnost u řidiče 4 dosahovaly shodně klasifikátory Naive Bayes klasifikátor a Podpůrné vektory, a to s úspěšností 80,89%.

## 7.5 Celkové vyhodnocení výsledků

Pro zjištění, který příznak má největší vypovídací hodnotu jsem provedl srovnání jednotlivých t-testů do tabulky.

| Řidič   | Počet mrknutí | Průměrná šířka mrknutí | Rychlost zavření oka | Rychlost otevření oka | Průměrná vzdálenost mrknutí | Histogramový počet | Průměr úhlu | stdSAV | Mód úhlu | maxSAV | Průměr power spektra |
|---------|---------------|------------------------|----------------------|-----------------------|-----------------------------|--------------------|-------------|--------|----------|--------|----------------------|
| 1       | 4             | 2                      | 4                    | 4                     | 3                           | 3                  | 1           | 3      | 0        | 1      | 1                    |
| 2       | 4             | 2                      | 4                    | 4                     | 3                           | 3                  | 1           | 3      | 0        | 1      | 1                    |
| 3       | 4             | 2                      | 4                    | 4                     | 3                           | 3                  | 1           | 3      | 0        | 1      | 1                    |
| 4       | 4             | 2                      | 4                    | 4                     | 3                           | 3                  | 1           | 3      | 0        | 1      | 1                    |
| Četnost | 4             | 2                      | 4                    | 4                     | 3                           | 3                  | 1           | 3      | 0        | 1      | 1                    |

Tab. 9 Vyhodnocení vypovídací hodnoty příznaků

Jak je možné vyčíst z tabulky, nejlepšími ukazateli únavy se ukázaly 3 příznaky – Počet mrknutí, Rychlost zavření oka, Rychlost otevření oka, které vyšly jako relevantní u všech řidičů. Následovaly příznaky Průměrná vzdálenost mrknutí, Histogramový počet a stdSAV, které byly relevantní u 3 řidičů. Průměrná šířka mrknutí byla relevantní u 2 řidičů a Průměr úhlu, maxSAV a Průměr power spektra pouze u jednoho. Příznak Mód úhlu se neuplatnil ani u jednoho řidiče.

Celková úspěšnost klasifikátorů je shrnuta v tabulce 10. Po zprůměrování klasifikací u jednotlivých řidičů vyšel jako nejlepší klasifikátor Podpůrných vektorů.

| Klasifikátor             | Celková úspěšnost [%] |
|--------------------------|-----------------------|
| K-nejbližší soused       | 86,39                 |
| Rozhodovací strom (J48)  | 86,79                 |
| Naive Bayes klasifikátor | 86,69                 |
| Podpůrné vektory         | 88,16                 |
| Neuronová síť            | 87,93                 |

Tab. 10 Celková úspěšnost jednotlivých klasifikátorů

## 8. Diskuse

Byla potvrzena domněnka, že signály nesou informaci o únavě řidiče. Jednotlivé příznaky se pak lišily z hlediska rozlišení únavy a bdělosti.

Rychlost zavírání oka se jevila jako nejspolehlivější indikátor únavy, a to už po vizuálním posouzení příznaků v programu Excel. Toto odpovídá předpokladu, že u unaveného řidiče dochází k „padání víček,“ což je v zásadě pomalé zavírání očí.

Dalšími dvěma příznaky, které bylo možno použít pro klasifikaci u všech řidičů, byly Počet mrknutí a Rychlost otevírání oka. Tudíž byly potvrzeny předpoklady, že unavený řidič mrká s vyšší frekvencí a jednotlivá mrknutí jsou časově delší než u řidiče bdělého.

Dva příznaky, které měly detekovat „salvy“ mrknutí u unaveného řidiče byly Průměrný počet mrknutí a Histogramový počet. U tří řidičů byla tato hypotéza potvrzena, avšak průkaznost těchto příznaků by měla být ještě ověřena. Zejména příznak Histogramový počet by mohl být modifikován pro dosažení lepších výsledků při individuálním přístupu k jednotlivým řidičům.

Výhodou příznaků, které operují s frekvencí a rychlostí mrkání je, že je lze také získat z analýzy videa. Proto mají velký potenciál v určování únavy řidiče, zejména pak v kombinaci s příznakem PERCLOS. Tyto závěry potvrzuje i dostupná literatura (4).

Ze signálu Hallovy sondy nebyly potvrzeny předpoklady. Přestože některé z příznaků byly hodnoceny jako relevantní v literatuře (21). To mohlo být způsobeno například rozdílnými měřicími podmínkami.

## 9. Závěr

Cílem této diplomové práce bylo analyzovat data, neměřená v letech 2000 – 2002 v rámci programu „Spící řidič, bdící auto.“ Z vybraných signálů (EOG a Hallova sonda) pak vypočíst příznaky pro klasifikaci dvou různých psychofyzilogických stavů, a to stavu „čilý“ a stavu „unavený.“ Po vypočtení pak na relevantní příznaky aplikovat vybrané metody umělé inteligence pro vytvoření a analýzu rozhodovacích pravidel.

Pro analýzu signálů byl použit program Matlab, pomocí kterého byly vypočteny příznaky pro klasifikaci. Nejprve bylo vytvořeno časové okénko, ve kterém pak byly jednotlivé příznaky počítány. Toto okénko mělo hodnotu 30s. Jednotlivé časové úseky a příznaky z nich vypočtené pak byly převedeny do tabulkového procesoru MS Excel, kde byla data analyzována vizuálně pomocí grafů znázorňujících průběh příznaku v čase a pomocí burzovních grafů, znázorňujících rozložení jednotlivých příznaků. Po analýze vizuální byla data analyzována statisticky pomocí studentova t-testu. Příznaky, které byly relevantní pro klasifikaci, pak byly použity v programu Weka, kde byly testovány vybrané metody somatické klasifikace.

Po vizuální analýze se jevil jako nejúčinnější příznak pro klasifikaci – Rychlost zavření oka. U bdělých řidičů je tento parametr znatelně vyšší, kdežto se zvyšující se únavou klesá. Dalšími slibnými příznaky byly Rychlost otevření oka a Počet mrknutí. Zde však již nebyl rozdíl mezi bdělým a čilým řidičem tak markantní. Ze signálu Hallovy sondy se pak žádný příznak nebyl jednoznačně využitelný pro klasifikaci.

Úspěšnost klasifikačních metod se pak lišila podle řidičů. Celkově nejúspěšnější metoda pak byly neuronové sítě.

V této práci jsem zabýval celým průběhem zpracování signálů, od získání příznaků z daných signálů, až po aplikaci automatické klasifikace. Za výsledky využitelné pro praxi a další práci považuji zejména algoritmus pro počítání příznaků a pravidla sestavená jednotlivými klasifikátory, které jsou k dispozici v přílohách na CD.

Dle mého názoru by se následující řešení mělo zabývat příznaky, které jednoznačně rozlišovaly mezi bdělostí a únavou, tj. rychlost zavření a otevření víčka a počet mrknutí, popřípadě i histogramový počet. Dále pak aplikací sofistikovanějších klasifikačních metod a zařazením dalších signálů a příznaků do procesu klasifikace. V neposlední řadě by také bylo vhodné zavést fuzzy rozhodování, kdy bude únava klasifikována jen s určitou pravděpodobností.

## Literatura

1. **P Philip, F. Vervialle, P Le Breton, J Taillard, J A Horne.** Fatigue, alcohol, and serious road crashes in France: factorial study of national data. *BMJ Journal*. 2001, 322.
2. **RJ, Pierce.** Driver sleepiness: occupational screening and physician's role. *Australian and New Zealand Journal of Medicine*. 1999, 29.
3. **James M. Lyznicki, Theodore C. Doege, Ronald M. Davis, Michael A. Williams.** Sleepiness, Driving, and Motor Vehicle Crashes. *The Journal of the American Medical Association*. 1998, 279.
4. **Saroj K.L., Ashley Craig.** A critical review of the psychophysiology of driver fatigue. *Biological Psychology*. 55, 2001.
5. **Grandjean, E.** Fatigue in Industry. *British Journal of Industrial Medicine*. 36, 1979.
6. **S., Adkins.** Performance, Heart Rate and Respiration on the day-night continuum. *Percept Mot Skills*. 18, 1964.
7. **Secher NH, Seifert T, Van Lieshout JJ.** Cerebral blood flow and metabolism during exercise, implications for fatigue. *Applied Physiology*. 2008, 104.
8. **JK Sluiter, AJ van der Beek, MH Frings-Dresen.** Work stress and recovery measured by urinary catecholamines and cortisol excretion in long distance coach drivers. *Occup. Env. Med.* 1998, 55.
9. **Lal, Saroj Kusum Lata.** The Psychophysiology of Driver Fatigue/Drowsiness: Electroencephalography, Electro-oculogram, Electrocardiogram and Psychological Effects. *Doctorate Thesis*. 2001.
10. **E. Rogado, J.L. García, R. Barea, L.M. Bergasa, E. Lopéz,** *Driver fatigue detection system*. Bangkok : Proceedings of the 2008 IEEE, 2009.
11. **Albert Kirchner, Marcus Uddman, Jesper Sandin.** Vehicle Control and Drowsiness. *VTI meddelande*. 2002, 922.
12. **Vladimír Mařík, Olga Štěpánková, Jiří Lažanský a kol.** *Umělá inteligence (I)*, Academia. 80-200-0496-3.

13. **Brown, I.D.** Prospects for technological countermeasures against driver fatigue. *Accid. Anal. and Prev.* Jul, 1997, 29.
14. **Tim Horberry, Laurence Hartley, Gerald P. Krueger, Nick Mabbot,** *Fatigue Detection Technologies for Drivers: A Review of Existing Operator Centered Systems.* 2001.
15. **Mercedes-Benz.** Mercedes-Benz-log. *Mercedes-Benz-log.* [Online] [Citace: 22. 4 2010.] <http://mercedes-benz-blog.blogspot.com/2007/12/mercedes-benz-fatigue-detection-system.html>.
16. <http://www.automobile.com>. *automobile.com.* [Online] [Citace: 25. 4 2010.] <http://www.automobile.com/volvos-driver-alert-control-a-take-down-on-distracted-and-tired-driving.html>.
17. [www.automotogadgets.com](http://www.automotogadgets.com). *automotogadgets.com.* [Online] [Citace: 29. 4 2010.] <http://www.automotogadgets.com/nissan-anti-drunk-driving-technology.html>.
18. **Qiang Ji, Xiaojie Yang.** *Computer Vision Systems - Real Time Visual Cues Extraction for Monitoring Driver Vigilance.* Springer Berlin / Heidelberg, 2001. 978-3-540-42285-3.
19. **Intelligent vehicle safety systems.** Drowsi, drowsiness intervention. *Drowsiness algorithms and indicators.* 2008.
20. **E. Bekiaris, S. Nikolaou, A. Mousadakou.** *System for effective Assessment of driver vigilance and Warning.* AWAKE Consortium, 2004.
21. **Fagerberg, Kalle.** Vehicle-Based Detection of Inattentive Driving for Integration in an Adaptive Lane Departure Warning System - Drowsiness Detection. *Master of Science Thesis.* Stockholm, 2004.

# Přílohy

## Příloha č. 1

Soubor nacteni.m

```
close all;
clc;

%% nacteni dat

load s0049_21.txt;c1_EOG_hor=s0049_21*(-1);
load s0049_25.txt;c1_Hallovka=s0049_25;

load s0050_21.txt;u1_EOG_hor=s0050_21;
load s0050_25.txt;u1_Hallovka=s0050_25;

%% prevzorkovani

resamp=10;
Fvz=200/resamp;

c1_EOG_hor=resample (c1_EOG_hor,1,resamp)';
c1_Hallovka=resample (c1_Hallovka,1,resamp)';

u1_EOG_hor=resample (u1_EOG_hor,1,resamp)';
u1_Hallovka=resample (u1_Hallovka,1,resamp)';

%% filtrace
filter_lowpass=fir1(3,0.05,'low');
filter_highpass = fir1(40,0.06,'high');%filter na EOG - 3 Hz cutoff,'high'

c1_EOG_hor=convn(c1_EOG_hor,filter_lowpass,'same'); %pro puvodni signal staci
zmenit jmeno
u1_EOG_hor=convn(u1_EOG_hor,filter_lowpass,'same');

c1_EOG_hor=convn(c1_EOG_hor,filter_highpass,'same'); %pro puvodni signal
staci zmenit jmeno
u1_EOG_hor=convn(u1_EOG_hor,filter_highpass,'same');
```



## Soubor okenko.m

```
close all;
clc;

%% okenko

sirkaokna=30; %sirka casoveho okenka
posunokna=30; %posun casoveho okneka

%% c1

%EOG_c1

pocetvzorku=size (c1_EOG_hor); %pocet vzorku
pocetokenek=floor (pocetvzorku (1,2)/((200/resamp)*sirkaokna)); %zaokrouhleny
(dolu) pocet okenek

for k=1:pocetokenek-1
    i=(1+(1*k-1))*(200/resamp)*posunokna; %ukazatel zacatek okna
    j=i+(200/resamp)*sirkaokna; %ukazatel konec okna
    pocitani=c1_EOG_hor (i:j); %docasny obsah okna

    %operace v okenku

    [p v]=peak_valley(pocitani); %detekuju peaky a udoli

    s=size(v);%velikost promenne v
    r=1;%krokovac pro zapis do promenne mrknuti

    for e=2:(s(1,1)-1) %od 2 protoze prvni hodnota je nesmysl
        if (v(e,2)<-75) % prahuju detekovane mrknuti -20kou
            mrknuti(r,:)=(v(e,:)); %ukladam vyprahovane hodnoty do promenne
            r=r+1;
        end
    end

    %zapis do vystupu

    if (exist('mrknuti','var')==0) %overuju jestli v useku bylo mrknuti
        vysledky_c1 (k,1)=0;%pocet mrknuti v useku
        vysledky_c1 (k,2)=0;%prumerna sirka mrknuti v useku
        vysledky_c1 (k,3)=0;%prumerna rychlost nabezne hrany mrku (atribut
AECS-eye closure speed)
        vysledky_c1 (k,4)=0;%prumerna rychlost sestupne hrany mrku
        vysledky_c1 (k,5)=0;%prumerna vzdalenost dvou mrknuti
        vysledky_c1 (k,6)=0;

    else
        %pocitam vzdalenost mrku
        r=1;
        vm=size(mrknuti);
        for l=2:vm(1,1)
            vzdalenostm(r,:)=(mrknuti(l,1)-mrknuti(l-1,1));
            r=r+1;
        end
    end
end
```

```

%overuju jestli byly dva mrky
if (exist('vzdalenostm','var')==0)
    vzdalenostm=0;
end

%overuju jestli byly dva mrky
if (exist('vzdalenostm','var')==0)
    vzdalenostm=0;
end

pocetpiku=size(mrknuti);%pocitam piky

vysledky_c1 (k,1)=pocetpiku (1,1);%pocet mrknuti v useku
vysledky_c1 (k,2)=mean (mrknuti (:,3));%prumerna sirka mrknuti v useku
vysledky_c1 (k,3)=abs (mean (mrknuti (:,4)));% prumerna rychlost nabezne
hrany mrku (atribut AECS-eye closure speed)
vysledky_c1 (k,4)=abs (mean (mrknuti (:,5)));%prumerna rychlost sestupne
hrany mrku
vysledky_c1 (k,5)=mean(vzdalenostm);%prumerna vzdalenost mrku
vysledky_c1 (k,6)=sum(histc(vzdalenostm,4:30));
end

clear pocetpiku mrknuti v vzdalenostm;%musim vynulovat
end

%c1_Hallovka

pocetvzorku=size (c1_Hallovka); %pocet vzorku
pocetokenek=floor (pocetvzorku (1,2)/((200/resamp)*sirkaokna)); %zaokrouhleny
(dolu) pocet okenek
for k=1:pocetokenek-1
    i=(1+(1*k-1))*(200/resamp)*posunokna; %ukazatel zacatek okna
    j=i+(200/resamp)*sirkaokna; %ukazatel konec okna
    pocitani=c1_Hallovka (i:j); %docasny obsah okna
    pocitanil=gradient (pocitani);%prvni derivace - rychlost (normalizovany
signal)
    %operace v okenku

    %pro modeSA
    v=size(pocitani);

    %pro powerhighfreq
    f1= fir1(40,0.4,'high');%0,02 Hz cutoff
    fs= convn(pocitani,f1,'same');%filtruju signal, dostavam mikrokorekce
    ts=abs(fft(fs,v(1,2)));%transformuju signal fourierem

    vysledky_c1 (k,7)=mean (abs (pocitani));%smerodatna odchylka lateralniho
natoceni MVLP
    vysledky_c1 (k,8)=std (pocitanil);%smerodatna odchylka prumerne rychlosti
stdSAV
    vysledky_c1 (k,9)=(sum(pocitani-mean(pocitani)))/(v(1,2));%modeSA
    vysledky_c1 (k,10)=max(pocitanil);%maximalni rychlost
    vysledky_c1 (k,11)=mean(ts.^2);%PowerHighFreq

end

```

```

%% u1

%EOG_u1

pocetvzorku=size (u1_EOG_hor); %pocet vzorku
pocetokenek=floor (pocetvzorku (1,2)/((200/resamp)*sirkaokna)); %zaokrouhleny
(dolu) pocet okenek

for k=1:pocetokenek-1
    i=(1+(1*k-1))*(200/resamp)*posunokna; %ukazatel zacatek okna
    j=i+(200/resamp)*sirkaokna; %ukazatel konec okna
    pocitani=u1_EOG_hor (i:j); %docasny obsah okna

    %operace v okenku

    [p v]=peak_valley(pocitani); %detekuju peaky a udoli

    s=size(v);
    r=1;

    for e=2:(s(1,1)-1) %od 2 protoze prvni hodnota je nesmysl
        if (v(e,2)<-100) % prahuju detekovane mrknuti -20kou
            mrknuti(r,:)=(v(e,:)); %ukladam vyprahovane hodnoty do promenne
            r=r+1;
        end
    end
end

%zapis do vystupu

if (exist('mrknuti','var')==0) %overuju jestli v useku bylo mrknuti
    vysledky_u1 (k,1)=0;%pocet mrknuti v useku
    vysledky_u1 (k,2)=0;%prumerna sirka mrknuti v useku
    vysledky_u1 (k,3)=0;%prumerna rychlost nabezne hrany mrku (atribut
AECS-eye closure speed)
    vysledky_u1 (k,4)=0;%prumerna rychlost sestupne hrany mrku
    vysledky_u1 (k,5)=0;%prumerna vzdalenost dvou mrknuti
    vysledky_u1 (k,6)=0;

else
    %pocitam vzdalenost mrku
    r=1;
    vm=size(mrknuti);
    for l=2:vm(1,1)
        vzdalenostm(r,:)=(mrknuti(l,1)-mrknuti(l-1,1));
        r=r+1;
    end

    %overuju jestli byly dva mrky
    if (exist('vzdalenostm','var')==0)
        vzdalenostm=0;
    end

pocetpiku=size(mrknuti);%pocitam piky

vysledky_u1 (k,1)=pocetpiku (1,1);%pocet mrknuti v useku

```

```

    vysledky_u1 (k,2)=mean (mrknuti (:,3));%prumerna sirka mrknuti v useku
    vysledky_u1 (k,3)=abs (mean (mrknuti (:,4)));% prumerna rychlost nabezne
hrany mrku (atribut AECS-eye closure speed)
    vysledky_u1 (k,4)=abs (mean (mrknuti (:,5)));%prumerna rychlost sestupne
hrany mrku
    vysledky_u1 (k,5)=mean(vzdalenostm);%prumerna vzdalenost mrku
    vysledky_u1 (k,6)=sum(histc(vzdalenostm,4:30));
    end

clear pocetpiku mrknuti v vzdalenostm;%musim vynulovat
end

%u1_Hallovka

pocetvzorku=size (u1_Hallovka); %pocet vzorku
pocetokenek=floor (pocetvzorku (1,2)/((200/resamp)*sirkaokna)); %zaokrouhleny
(dolu) pocet okenek
for k=1:pocetokenek-1
    i=(1+(1*k-1))*(200/resamp)*posunokna; %ukazatel zacatek okna
    j=i+(200/resamp)*sirkaokna; %ukazatel konec okna
    pocitani=u1_Hallovka (i:j); %docasny obsah okna
    pocitanil=gradient (pocitani);%prvni derivace - rychlost (normalizovany
signal)
    %operace v okenku

    %pro modeSA
    v=size(pocitani);

    %pro powerhighfreq
    f1= fir1(40,0.4,'high');%0,02 Hz cutoff
    fs= convn(pocitani,f1,'same');%filtruju signal, dostavam mikrokorekce
    ts=abs(fft(fs,v(1,2)));%transformuju signal fourierem

    vysledky_u1 (k,7)=mean (abs (pocitani));%smerodatna odchylka lateralniho
natoceni MVLP
    vysledky_u1 (k,8)=std (pocitanil);%smerodatna odchylka prumerne rychlosti
stdSAV
    vysledky_u1 (k,9)=(sum(pocitani-mean(pocitani)))/(v(1,2));%modeSA
    vysledky_u1 (k,10)=max(pocitanil);%maximalni rychlost
    vysledky_u1 (k,11)=mean(ts.^2);%PowerHighFreq

end

```

## Souboor peak\_valley.m

```
function [peak, valley] = peak_valley(seq)

% peak_valley - compute peaks and valleys of sequence
% -----
%
% [peak, valley] = peak_valley(seq)
%
% Input:
% -----
% seq - input sequence
%
% Output:
% -----
% peak - peak array
% valley - valley array

%-----
% Author: Harold Figueroa
%-----
% $Revision: 1.3 $
% $Date: 2003-09-16 01:26:31-04 $
%-----

% there exist more concise representations which store the output
% information implicitly

%-----
% FIND PEAKS AND VALLEYS
%-----

%--
% check input and put vector in column form
%--

if (min(size(seq)) == 1)
    seq = seq(:);
else
    error('Input must be a vector.');
```

```
end

%--
% get length of sequence
%--

n = length(seq);

%--
% get interior peak indices and values
%--

pix = find((seq(2:(n - 1)) > seq(1:(n - 2))) & (seq(2:(n - 1)) > seq(3:n))) +
1;

if (~isempty(pix))
    pv = seq(pix);
else
```

```

        pv = [];
    end

    %--
    % get interior valley indices and values
    %--

    vix = find((seq(2:(n - 1)) < seq(1:(n - 2))) & (seq(2:(n - 1)) < seq(3:n))) +
    1;

    if (~isempty(vix))
        vv = seq(vix);
    else
        vv = [];
    end

    %--
    % evaluate extremes at start and end of sequence
    %--

    if (seq(1) < seq(2))

        vix = [1; vix];
        vv = [seq(1); vv];

    elseif (seq(1) > seq(2))

        pix = [1; pix];
        pv = [seq(1); pv];

    end

    if (seq(end) < seq(end - 1))

        vix = [vix; n];
        vv = [vv; seq(n)];

    elseif (seq(end) > seq(end - 1))

        pix = [pix; n];
        pv = [pv; seq(n)];

    end

    %--
    % compute peak widths and depths
    %--

    for k = 1:length(pix)

        %--
        % compute left
        %--

        tmp = find(vix < pix(k));

        if (~isempty(tmp))

```

```

    tmp = vix(max(tmp));

    plw(k) = tmp - pix(k);
    pld(k) = seq(tmp) - pv(k);

else

    if (pix(k) == 1)
        plw(k) = 0;
        pld(k) = 0;
    else
        plw(k) = nan;
        pld(k) = nan;
    end

end

%--
% compute right
%--

tmp = find(vix > pix(k));

if (~isempty(tmp))

    tmp = vix(min(tmp));

    prw(k) = tmp - pix(k);
    prd(k) = seq(tmp) - pv(k);

else

    if (pix(k) == n)
        prw(k) = 0;
        prd(k) = 0;
    else
        prw(k) = nan;
        prd(k) = nan;
    end

end

end

%--
% pack peak results structure array
%--

% width and depth of an extremum can be used in many applications

if (length(pix))

    for k = 1:length(pix)

```

```

    peak(k,1) = pix(k);%pozice x

    peak(k,2) = pv(k);%hodnota

    peak(k,3) = (abs (plw(k))+ abs (prw(k)));%sirka

    % peak(k,4).depth = [pld(k), prd(k)];%hloubka

    peak(k,4) = pld(k)/plw(k);%rychlost nabezne hrany (zavirani oka)

    peak(k,5) = prd(k)/prw(k);%rychlost sestupne hrany (otevirani oka)

end

else

    peak = [];

end

%--
% compute valley widths and depths if needed
%--

if (nargin == 1)

    %--
    % compute valley widths and depths
    %--

    for k = 1:length(vix)

        %--
        % compute left
        %--

        tmp = find(pix < vix(k));

        if (~isempty(tmp))

            tmp = pix(max(tmp));

            vlw(k) = tmp - vix(k);
            vld(k) = seq(tmp) - vv(k);

        else

            if (vix(k) == 1)
                vlw(k) = 0;
                vld(k) = 0;
            else
                vlw(k) = nan;
                vld(k) = nan;
            end

        end

    end

end

```



```

%--
% compute right
%--

tmp = find(pix > vix(k));

if (~isempty(tmp))

    tmp = pix(min(tmp));

    vrw(k) = tmp - vix(k);
    vrd(k) = seq(tmp) - vv(k);

else

    if (vix(k) == n)
        vrw(k) = 0;
        vrd(k) = 0;
    else
        vrw(k) = nan;
        vrd(k) = nan;
    end

end

end

%--
% pack valley results structure array
%--

% width and depth of an extremum can be used in many applications

if (length(vix))

    for k = 1:length(vix)

        valley(k,1) = vix(k);%pozice udoli

        valley(k,2) = vv(k);%hodnota udoli

        valley(k,3) = (abs (vlw(k))+ abs (vrw(k)));%sirka udoli

        % valley(k,4) = [vld(k), vrd(k)];

        valley(k,4) = vld(k)/vlw(k);%rychlost nabezne hrany udoli
(zavirani oka)

        valley(k,5) = vrd(k)/vrw(k);%rychlost sestupne hrany (otevirani
oka)









    end
else
    valley = [];
end

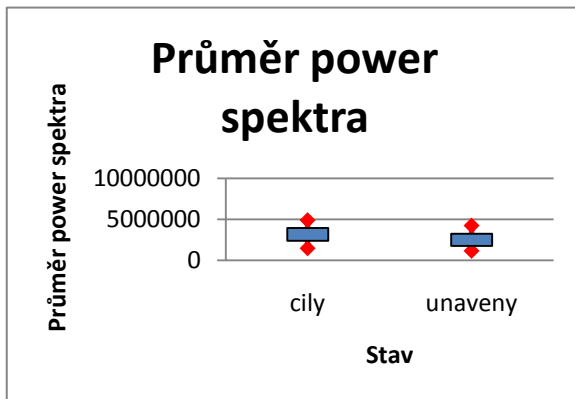


end
end









```



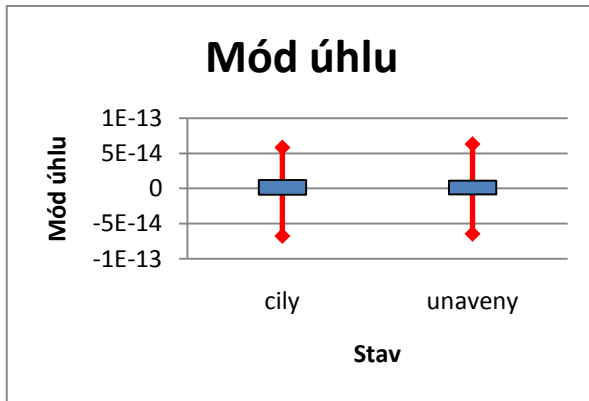
## Příloha č. 2









Burzovní grafy řidič 1
















Burzovní grafy řidič 4

