



**ČVUT**

ČESKÉ VYSOKÉ  
UČENÍ TECHNICKÉ  
V PRAZE

**F3**

**Fakulta elektrotechnická  
Katedra měření**

**Diplomová práce**

# **Systém detekce nepozornosti řidiče**

**Bc. Jan Kočí**

**Květen 2024**

**Vedoucí práce: Ing. Jan Sobotka, Ph.D.**



## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Kočí** Jméno: **Jan** Osobní číslo: **492330**  
Fakulta/ústav: **Fakulta elektrotechnická**  
Zadávací katedra/ústav: **Katedra měření**  
Studijní program: **Kybernetika a robotika**

## II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

**System detekce nepozornosti řidiče**

Název diplomové práce anglicky:

**Driver Distraction Detection System**

Pokyny pro vypracování:

1. Proveďte rešerši existujících systémů detekce nepozornosti řidiče.
2. S ohledem na možnosti platformy „Inteligentní auto“ implementujte navržený koncept vlastního systému detekce nepozornosti.
3. Systém bude detekovat vizuální a manuální nepozornost řidiče při různých scénářích jízdy.
4. Pohled řidiče bude sledován pomocí kamery.
5. Demonstrujte funkčnost navrženého systému.

Seznam doporučené literatury:

- [1] Christer Ahlstrom, George Georgoulas, and Katja Kircher. Towards a context-dependent multi-buffer driver distraction detection algorithm. IEEE transactions on intelligent transportation systems. 2021, 23 (5), 4778–4790.
- [2] Katja Kircher, and Christer Ahlstrom. Minimum required attention: A human-centered approach to driver inattention. Human factors. 2017, 59 (3), 471–484.
- [3] Alexey Kashevnik, Roman Shchedrin, Christian Kaiser, and Alexander Stocker. Driver Distraction Detection Methods: A Literature Review and Framework. IEEE Access. 2021, 9 60063-60076. DOI 10.1109/ACCESS.2021.3073599.
- [4] Nejtek, J.: Framework pro sběr dat a řízení inteligentního vozu, Diplomová práce ČVUT FEL, 2022

Jméno a pracoviště vedoucí(ho) diplomové práce:

**Ing. Jan Sobotka, Ph.D. katedra měření FEL**

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **15.02.2024**

Termín odevzdání diplomové práce: **24.05.2024**

Platnost zadání diplomové práce:

**do konce letního semestru 2024/2025**

Ing. Jan Sobotka, Ph.D.  
podpis vedoucí(ho) práce

podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.  
podpis děkana(ky)

## III. PŘEVZETÍ ZADÁNÍ

Diplomant bere na vědomí, že je povinen vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

\_\_\_\_\_  
Datum převzetí zadání

\_\_\_\_\_  
Podpis studenta



## Poděkování / Prohlášení

Rád bych vyjádřil své upřímné poděkování všem, kteří mi pomohli při tvorbě této diplomové práce a kteří mě podporovali během celého mého studia. Především bych chtěl poděkovat vedoucímu mé práce Ing. Janu Sobotkovi, Ph.D. za jeho cenné rady, trpělivost a ochotu pomoci.

Prohlašuji, že jsem tuto práci vypracoval samostatně a že jsem veškeré použité informační zdroje uvedl v seznamu použité literatury v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací. Při práci jsem použil nástroje GitHub Copilot, ChatGPT za účelem korekce a reformulace textu, hledání zdrojů a programování. Dále DeepL Translator za účelem překladu textu. V Praze dne 24.5.2024

## Abstrakt / Abstract

Tato práce se zaměřuje na problematiku pozornosti řidiče, která je klíčovým faktorem bezpečnosti silničního provozu. V první části práce je definována pozornost a jsou představeny faktory které ji ovlivňují. Ve druhé části se práce věnuje způsobům, jakými lze měřit pozornost řidiče a zjišťovat, zda je řidič pozorný či nikoli. Výsledkem je návrh detekčního systému pro monitorování vizuální a manuální nepozornosti řidiče, který bude integrován do platformy Inteligentní auto. Navržený systém využívá kamerového sledování pohledu řidiče a jeho funkčnost je demonstrována v praxi.

**Klíčová slova:** pozornost řidiče, detekce nepozornosti, sledování pohledu, detekce obličeje

This thesis focuses on the issue of driver attention, which is a key factor in road safety. In the first part of the paper, attention is defined and the factors that influence it are presented. In the second part of the thesis, the ways in which driver attention can be measured and whether the driver is attentive or not are discussed. The result is the design of a detection system to monitor the visual and manual inattention of the driver, which will be integrated into the Intelligent Car platform. The proposed system uses camera tracking of the driver's gaze and its functionality is demonstrated in practice.

**Keywords:** driver attention, distraction detection, gaze tracking, face detection

**Title translation:** Driver Distraction Detection System

# Obsah /

<b>1 Úvod</b>	<b>1</b>		
1.1 Motivace	1		
1.2 Cíl práce	1		
1.3 Pozornost řidiče	1		
1.4 State-of-the-Art	2		
<b>2 Faktory ovlivňující pozornost řidiče</b>	<b>4</b>		
2.1 MiRA	4		
2.1.1 Povědomí o situaci	4		
2.1.2 Satisficing	5		
2.1.3 Samourčování náročnosti	5		
2.2 Fyziologické faktory	5		
2.2.1 Únava	5		
2.2.2 Stres a intoxikace	6		
2.3 Vliv automatizace	6		
<b>3 Multizónový přístup</b>	<b>8</b>		
<b>4 Rozpoznání zón</b>	<b>11</b>		
4.1 Vzdálenost od kamery	11		
4.2 Směr pohledu	12		
4.3 Rozpoznání zóny	14		
4.4 Otočení dozadu	15		
4.5 Kalibrace kamery	16		
<b>5 Interakce s vozem a získání dat</b>	<b>17</b>		
5.1 Získání dat z vozu	17		
5.1.1 Infotainment	17		
<b>6 Rozpoznání jízdních situací</b>	<b>19</b>		
6.1 Typy situací	19		
6.1.1 Jízda v pruhu	19		
6.1.2 Přejíždění mezi pruhy	20		
6.1.3 Couvání na parkovišti	20		
6.1.4 Nastavení parametrů	21		
<b>7 Implementace systému</b>	<b>22</b>		
7.1 Architektura systému	22		
7.1.1 Sběr dat	22		
7.1.2 Zpracování dat	22		
7.1.3 Tracking situace a pozornosti	23		
7.1.4 Výstupní modul	23		
<b>8 Realizace ve vozidle</b>	<b>24</b>		
8.1 Počítač a připojení	24		
8.2 Kamera	24		
8.3 Nastavení referenčních vektorů zón	26		
<b>9 Výsledky</b>	<b>29</b>		
		9.1 Eye-tracking	29
		9.2 Tracking pozornosti	31
		9.3 Shrnutí	32
		<b>10 Závěr</b>	<b>34</b>
		<b>Literatura</b>	<b>36</b>
		<b>A Seznam použitých zkratk</b>	<b>41</b>
		<b>B Příložené soubory</b>	<b>42</b>

## Tabulky / Obrázky

<b>4.1</b> Klíčové body obličeje .....	14
<b>5.1</b> Vybrané signály z CAN sběrnice a jejich využití.....	17
<b>6.1</b> Parametry zón při jízdě v pruhu.....	20
<b>6.2</b> Parametry zón při přejíždění mezi pruhy.....	20
<b>6.3</b> Parametry zón při couvání.....	20
<b>8.1</b> Tabulka s technickými parametry kamery .....	25
<b>2.1</b> Mikrokorekce volantu při normálním stavu a při únavě ....	6
<b>3.1</b> Auto s řidičem a zónami .....	8
<b>3.2</b> Závislost faktoru $w_s$ na rychlosti vozidla.....	10
<b>4.1</b> Kalibrace vzdálenosti .....	11
<b>4.2</b> Převodní charakteristika vzdálenosti očí na vzdálenost od kamery .....	12
<b>4.3</b> Klíčové body obličeje .....	13
<b>4.4</b> Klíčové body těla.....	15
<b>4.5</b> Kalibrace kamery pomocí šachovnicového vzoru .....	16
<b>7.1</b> Architektura systému .....	22
<b>7.2</b> Notifikace při nedostatku pozornosti.....	23
<b>8.1</b> Foto auta.....	24
<b>8.2</b> Počítač ARK-3520P.....	25
<b>8.3</b> Použitá webkamera .....	25
<b>8.4</b> Pohled na nástavec zepředu ...	26
<b>8.5</b> Pohled na nástavec shora .....	26
<b>8.6</b> Nástavec na kameru.....	27
<b>8.7</b> Nástroj pro nastavení referenčních vektorů zón .....	27
<b>8.8</b> Ukázka konfiguračního souboru s referenčními vektory zón .....	28
<b>9.1</b> Výstup sledování pohledu při pohledu do strany.....	30
<b>9.2</b> Výstup sledování pohledu při pohledu dopředu.....	30
<b>9.3</b> Výstup sledování pozornosti v čase, laboratorní podmínky ..	31
<b>9.4</b> Výstup sledování pozornosti v čase, reálné podmínky za stání.....	32
<b>9.5</b> Výstup sledování pozornosti v čase, reálné podmínky za jízdy.....	32
<b>9.6</b> Výstup sledování pozornosti v čase při couvání, laboratorní podmínky.....	32



# Kapitola 1

## Úvod

V této práci se zabývám pozorností řidiče. V první části práce se věnuji tomu, co je to pozornost a jak ji můžeme měřit. Dále ukazuji faktory ovlivňující pozornost řidiče. V druhé části práce se věnuji popisu vývoje vlastní systému pro detekci nepozornosti řidiče. V poslední části práce se věnuji testování vlastnímu systému.

### 1.1 Motivace

Dostatek pozornosti je klíčový pro bezpečnost silničního provozu. Každoročně dochází k mnoha dopravním nehodám, které jsou přímo spojeny s nedostatečnou pozorností řidičů. Význam této problematiky je zřejmý nejen z hlediska osobní bezpečnosti jednotlivých účastníků silničního provozu, ale také z hlediska ekonomických a sociálních nákladů spojených s dopravními nehodami. Od roku 2024 je povinností výrobců automobilů v Evropské unii implementovat systémy, které monitorují pozornost řidiče a v případě potřeby zasáhnou [1]. Podle statistik amerického Národního úřadu pro bezpečnost silničního provozu (NHTSA) v roce 2022 bylo 3 308 lidí zabito a téměř 290 000 bylo zraněno v důsledku nehod způsobených nedostatkem pozornosti řidiče. S tím že reálné číslo může být vyšší, protože lidé často odmítají přiznat, že byli nepozorní [2]. Evropská komise odhaduje, že nedostatek pozornosti řidiče je příčinou 5 - 20 % všech dopravních nehod [3].

V dnešní době se automobily stávají stále více autonomními, ale stále je nutná přítomnost řidiče, který musí v případě potřeby převzít kontrolu nad vozidlem. Pokročilé systémy ADAS přebírají větší nebo menší část řízení vozidla, ale řidič je stále zodpovědný za bezpečnost jízdy. Právě snížené nároky na řidiče mohou způsobit, že řidič bude mít tendenci věnovat se jiným činnostem, než je řízení vozidla. Proto mají výrobci povinnost implementovat systémy, které pomáhají řidiči udržet pozornost [4]. Nějaké takové systémy již existují, ale jedná se zpravidla o systémy rozpoznávající pouze únavu, nebo to že řidič nedrží ruce na volantu.

### 1.2 Cíl práce

Cílem této práce je provést rešerši existujících systémů pro detekci nepozornosti řidiče. Na základě zjištěných informací bude vyvinut nový koncept detekčního systému, který bude integrován do platformy „Inteligentní auto“ [5]. Tento systém se zaměří na detekci vizuální a manuální nepozornosti řidiče během různých jízdních scénářů. Pozornost řidiče bude monitorována pomocí kamery, která sleduje jeho pohled. Funkčnost navrženého systému bude následně demonstrována v praxi.

### 1.3 Pozornost řidiče

Pozornost je omezený zdroj, který člověk věnuje částečně všem činnostem, které vykonává. Jedná se o kognitivní proces, který má za cíl zpracovávat informace a vytvářet

vnitřní představu o stavu okolí. Pro nás je důležité, aby dostatečná část pozornosti byla věnována řízení vozidla.

Lépe se pracuje s absencí pozornosti, proto budeme dále hovořit o nepozornosti. Nepozorností označujeme stav, kdy se subjekt věnuje něčemu jinému, než hlavnímu cíli. Důležitým projevem nepozornosti je snížení schopnosti reagovat na neočekávané situace. Měřitelným projevem nepozornosti je snížení reakční doby.

Činnost, které se věnuje řidič, místo řízení, označujeme jako, Non-driving Related Activity (NDRA). Podle toho, jak se NDRA projevuje, můžeme rozlišit tři základní druhy nepozornosti: vizuální, kognitivní a manuální.

Manuální nepozornosti jsou činnosti, které vyžadují fyzickou interakci s jinými objekty, než které jsou nutné pro řízení vozu. Kognitivní nepozornost je stav, kdy subjekt myslí na jiné věci. Samotná kognitivní nepozornost je složitá na detekci, protože se neprojevuje žádnými fyzickými projevy. Vizuální nepozornost je stav, kdy subjekt sleduje věci, které nejsou přímo spojené s úkolem řídit vůz.

Velmi často se jedná o kombinaci více druhů nepozornosti. Například, když řidič telefonuje, tak se jedná o kombinaci manuální a kognitivní nepozornosti. Kde manuální nepozornost je způsobena tím, že řidič drží telefon a kognitivní nepozornost je způsobena tím, že řidič myslí na to, co mu druhá osoba říká [6].

## 1.4 State-of-the-Art

V této sekci se zaměřím na současné technologie a metody používané k detekci nepozornosti řidiče, zahrnující elektroencefalografii (EEG), analýzu stylu jízdy, rozpoznávání manuální nepozornosti z obrazů, využití parametrů pozornosti v autonomním řízení a detekci emocí řidiče. Počátečním bodem pro rešerši byly práce [6–7], kde autoři provedli shrnutí metod detekce nepozornosti řidiče a identifikovali klíčové oblasti výzkumu.

EEG je jednou z metod, která se používá pro měření mozkové aktivity a může být využita k detekci nepozornosti. Tato technologie umožňuje sledovat změny v mozkových vlnách, které mohou indikovat únavu, ospalost nebo jiné stavy nepozornosti. EEG je efektivní nástroj pro monitorování i jinak složitě detekovatelné kognitivní nepozornosti. Zásadním limitem je ale, že se jedná o intruzivní metodu, kde je nutné připojení elektrod k hlavě řidiče. Proto se tato technologie dá použít pouze v experimentálních podmínkách pro stanovení ground truth [8–9].

Další metodou pro detekci nepozornosti je analýza stylu jízdy, která může být prováděna pomocí dat z různých senzorů ve vozidle. Tato metoda může zahrnovat analýzu rychlosti, zrychlení, udržování odstupů a dalších parametrů jízdy. V [10] se zabývají hodnocením metod pro detekci nepozornosti na základě stylu jízdy, hlavními parametry je udržování odstupů od kraje pruhů a vozidel. V [11] autoři zkoumají vliv nepozornosti na ovládání pedálů brzd a plynu a navrhují metodu pro detekci tohoto stavu.

Manuální nepozornost lze detekovat pomocí analýzy obrazů z kamer umístěných v interiéru vozidla. Tyto kamery mohou sledovat pohyby rukou řidiče a identifikovat, kdy řidič manipuluje s jinými objekty, než jsou ovládací prvky vozidla. Výzkumy ukazují, že hluboké učení a analýza obrazů mohou být efektivními nástroji pro detekci manuální nepozornosti [12–13]. Dále Drive-net je jedním z příkladů systémů, které využívají tyto technologie pro detekci nepozornosti řidiče [14].

Vizuální nepozornost je stav, kdy řidič nesleduje cestu před sebou, což může být detekováno pomocí eyetrackingu. Eyetracking technologie umožňuje sledovat pohyb očí a identifikovat, kdy řidič nesleduje cestu [15]. Kombinace vizuální a kognitivní nepozornosti je zvláště nebezpečná, protože oba tyto stavy mohou výrazně snížit schopnost

řidiče reagovat na nečekané situace [16]. Eyetracking může být využit i pro optimalizaci designu HMI, kde je cílem co nejpřirozenější a nejméně rušivé prostředí [17].

Emoce řidiče mohou výrazně ovlivnit jeho pozornost a schopnost řídit vozidlo. Detekce emocí může být prováděna pomocí analýzy hlasu, konduktivity kůže nebo sledování výrazů obličeje. Výzkumy ukazují, že určité emoce, jako je vztek nebo úzkost, mohou zvýšit riziko nepozornosti a nehod [18–20].

Pokročilé systémy asistence řidiče (ADAS) mohou využívat parametry pozornosti pro vyvážení vlivu řidiče při autonomní jízdě. Tyto systémy sledují stav pozornosti řidiče a v případě potřeby přebírají kontrolu nad vozidlem. Výzkumy ukazují, že integrace těchto parametrů může zvýšit bezpečnost a efektivitu autonomního řízení [21].

# Kapitola 2

## Faktory ovlivňující pozornost řidiče

Pro praktické využití je důležité definovat, co to je pozornost respektive nepozornost. V této kapitole se budeme zabývat definicí nepozornosti a jejími vlastnostmi. Dále se zabýváme tím jaké faktory ovlivňují pozornost řidiče a jak se tyto faktory dají detekovat. Na závěr se zaměříme na současný stav regulace zaměřené na monitoring pozornosti.

V literatuře se setkáváme s několika definicemi nepozornosti. Tyto definice se v kontextu řízení se dají shrnout do dvou verzí, kde obě ale mají své slabiny. První definice říká: *Stav nepozornosti nastává, když řidič přesune svou pozornost z řízení vozidla na jinou činnost, kde nedostatek pozornosti může způsobovat nebezpečí.* Druhá definice říká: *Stav nepozornosti nastává, když řidič přesune svou pozornost z řízení vozidla na jinou činnost, nezávisle na tom, zda tato činnost způsobuje nebezpečí.*

První definice je závislá na vyhodnocení nebezpečí. Nebezpečí v tomto případě lze objektivně vyhodnotit až zpětně. Takto je definice použita například v článku [22].

Druhá definice je nezávislá na vyhodnocení nebezpečí, je ale velmi obecná a přísná. Takto je definice použita například v článku [23], dále podle ní pracují v různých pracích, které jsou ale zaměřené primárně na počítačové vidění, kde se na datasetech testuje jestli řidič drží mobil, pije nebo jiné chování, příklad toho je [13]. V tomto případě je vyžadováno naprosté soustředění na řízení vozidla. To se neshoduje s realitou, kde řidiči běžně provádějí i jiné činnosti, například poslouchají hudbu nebo mluví s spolujezdcem. Ve článku [24] ukazují že takovéto chování statisticky nezvyšuje riziko nehody. Podle této definice by tedy byli všichni řidiči nepozorní.

### 2.1 MiRA

Dále budeme používat termín Minimal Required Attention (MiRA). To je kompromis mezi našimi dvěma definicemi. Pracuje s myšlenkou, že řidič má nějakou mentální kapacitu a v různých situacích je pro řízení potřeba větší, či menší část této kapacity. Se zbytkem ale může řidič dělat cokoli, dokud s dostatečnou frekvencí vzorkuje informace o prostředí a tím si udržuje vnitřní reprezentaci situace na silnici [25].

#### 2.1.1 Povědomí o situaci

Povědomí o situaci (Situation Awareness, SA) je proces vnímání elementů v prostředí, porozumění jejich významu a predikce jejich stavu v budoucnosti. V kontextu řízení je to schopnost řidiče vnímat a porozumět situaci na silnici.

Termín SA pochází z letecké psychologie z 80. let minulého století. Vysvětlují se v něm lidské chyby, které vyplývaly z nedostatečného pochopení současné situace a stavu různých systémů [26]. Každý účastník dopravního systému má své vlastní povědomí o situaci a to musí komunikovat s okolím. Účastníky dopravního systému jsou řidiči, prvky infrastruktury a automatické systémy vozů. Pokud některý z těchto účastníků nemá dostatečné povědomí o situaci, tak může ohrozit celý systém [27].

Naším cílem je, aby řidič měl dostatečné povědomí o situaci, aby mohl bezpečně řídit vozidlo. Proto se zaměříme na první část SA, tedy na dostatečné vnímání situace. V případě nedostatku řidiče upozorníme.

### ■ 2.1.2 Satisficing

Koncept satisficing, popsany ve vztahu k řízení vozidla, vychází z teorie, že lidé se často snaží najít dostatečně uspokojivé řešení problému místo toho, aby hledali optimální řešení. V kontextu řízení vozidla to znamená, že řidiči se nezaměřují na dosažení maximální možné pozornosti, ale spíše na dosažení takové úrovně pozornosti, která je dostatečná pro bezpečné řízení vozidla v daných podmínkách. Tento přístup umožňuje řidičům efektivně spravovat své kognitivní zdroje, aby byli schopni reagovat na měnící se situace na silnici bez zbytečného vyčerpání. Satisficing je tak praktickou strategií, která reflektuje realitu každodenního řízení, kde řidiči musí neustále vyvažovat mezi různými úrovněmi pozornosti a potřebou udržet bezpečnost. Tento koncept zdůrazňuje, že dokonce i v běžných situacích může být **dost dobré** rozhodnutí plně funkční a bezpečné [28].

### ■ 2.1.3 Samourčování náročnosti

Schopnost řidičů sami určovat náročnost řízení v závislosti na okolních podmínkách je klíčovým aspektem bezpečného řízení vozidla. V praxi to znamená, že řidiči aktivně přizpůsobují své chování na silnici tak, aby reflektovalo aktuální situaci a její požadavky na pozornost. V některých situacích, jako jsou husté městské provozování nebo složité meteorologické podmínky, může být vyžadována vyšší úroveň pozornosti. Řidiči v takových momentech obvykle zvyšují svou pozornost a soustředění, aby efektivně reagovali na dynamické dění na silnici.

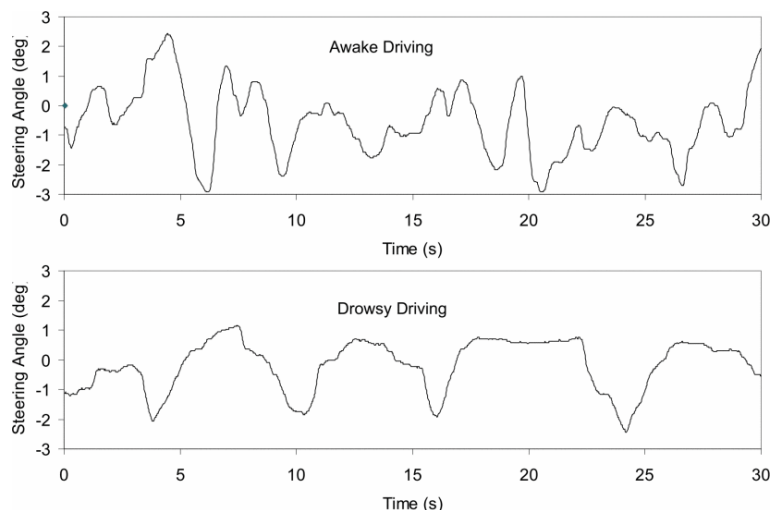
Příklady takového chování jsou, že řidiči při vykonávání NDRA typicky telefonování snižují rychlost a drží si stálý odstup od vozidla před sebou [29]. Nebo opačně při málo náročných situacích, jako je čekání na semaforech, řidiči mohou být více náchylní k používání mobilních telefonů nebo jiných zařízení, protože riziko nehody je mnohem menší [30]. Tato schopnost adaptace je důležitá pro udržení bezpečnosti na silnicích, protože umožňuje řidičům reagovat pružně na měnící se podmínky a zároveň si zachovat dostatečnou rezervu pozornosti pro neočekávané situace. To vše pomáhá zamezit nehodám a zvyšuje celkovou plynulost provozu.

## ■ 2.2 Fyziologické faktory

Fyziologické faktory ovlivňují pozornost řidiče a jeho schopnost reagovat na provozní situace. Mezi tyto faktory patří úroveň únavy, stresu, konzumace alkoholu a drog, zdravotní stav a další. Projevují se zhoršením reakční doby, motorických a kognitivních schopností.

### ■ 2.2.1 Únava

V současnosti už nové vozy musejí mít asistenční systémy, které monitorují únavu řidiče. Tyto systémy mohou být založeny na detekci mikrokorekcí volantu, které řidič provádí, když je unavený. Pro udržení vozidla v pruhu je potřeba provádět mikrokorekce volantu. Podle četnosti a intenzity těchto korekcí lze odhadnout únavu řidiče. Odpočatý řidič provádí korekce rychleji a s menší intenzitou, než unavený řidič. Na obrázku 2.1 je vidět rozdíl mezi mikrokorekcemi volantu při normálním stavu a při únavě [31–32]. Únava se nejvíce projevuje v nočních hodinách a na dálnicích, kde je



**Obrázek 2.1.** Mikrokorekce volantu při normálním stavu a při únavě [31].

monotónní prostředí. Rizikem je i mikrospánek, kdy řidič na krátkou dobu usne. Riziko se zvyšuje s délkou jízdy, proto mají profesionální řidiči povinnost dodržovat přestávky. Asistenční systémy vozů nebo i navigační aplikace s tímto pracují a upozorňují řidiče na nutnost přestávky.

Vliv únavy je velmi významný, protože způsobuje zhoršení reakční doby, snížení pozornosti a zhoršení schopnosti rozhodování. Únava způsobuje podle dat z USA až 30 % nehod [33]. Její vliv se srovnává s lehkou intoxikací alkoholem [34].

### 2.2.2 Stres a intoxikace

Intoxikace a stres mohou mít významný vliv na schopnost řízení a bezpečnost na silnicích. Intoxikace, typicky způsobená konzumací alkoholu nebo jiných psychoaktivních látek, výrazně snižuje motorické schopnosti, reakční čas a schopnost rozhodování řidiče. Řízení v takovém stavu je nejen nebezpečné, ale také přímo zakázané zákonem, což může vést k vážným právním následkům včetně pokut a zákazu řízení. Na druhou stranu, stres, ať už krátkodobý nebo chronický, způsobuje psychické a fyzické napětí, které může řidiče rozptylovat nebo vést k agresivnímu chování na silnici. Řidiči pod stresem mohou přijímat impulzivní nebo riskantní rozhodnutí, což zvyšuje pravděpodobnost konfliktů a nehod. Tento psychologický stav může také ovlivnit schopnost udržovat koncentraci a pohotově reagovat na neočekávané změny v provozních podmínkách. Proto je důležité, aby řidiči byli si vědomi svého psychického a fyzického stavu před a během řízení a přijímali opatření k zajištění bezpečnosti všech účastníků silničního provozu.

## 2.3 Vliv automatizace

S rozvojem pokročilých asistenčních systémů a autonomních vozidel se mění i role řidiče. Hlavní funkcí řidiče se více stává dohled nad systémem a případná intervence v případě potřeby namísto aktivního řízení. Procesy, které byly dříve vykonávány řidičem, jako je sledování okolí, udržování rychlosti a směru jízdy, jsou nyní přebírány asistenčními systémy.

Řidiči, kteří plní pouze dozorčí roli jsou náchylnější k rozptýlení a ztrátě pozornosti. Toto se projevuje u systémů z úrovně SAE 2 a 3, kde řidič není aktivně zapojen do řízení, ale musí být připraven kdykoliv převzít kontrolu nad vozidlem [35]. Převzetí

kontroly nad vozidlem je právě kritickou situací, kde při špatném rozhodnutí může dojít k nehodě.

U částečně automatizovaných systémů se projevuje efekt, kde řidič častěji a déle odhlíží od vozovky, než když řídí manuálně. A to i bez přítomnosti potenciálních rozptýlení, jako je mobilní telefon, jídlo nebo jiná osoba v autě [36]. K zamezení takovýchto situací je důležitý monitoring pozornosti řidiče a feedback od systému, pokud je řidič nepozorný [37].


V případě nehody vyvstává i otázka odpovědnosti. Monitoring pozornosti může chránit výrobce před žalobami za selhání systému. V pracích [38–39] ukazují frameworky pro sloučení lidského a strojového řízení, kde je důležité mít jasně definované role a odpovědnosti, tím se dá eliminovat riziko nehody a mezery v zodpovědnostech.

## Kapitola 3

### Multizónový přístup

Multizónový přístup je motivován tím, že řidič musí věnovat pozornost celému výhledu z vozidla, nikoliv jenom jedné oblasti. Výhled z vozidla je přirozeně rozdělen do zón odpovídajících jednotlivým směrům. Používá se rozdělení do čtyř zón, které odpovídají směrům dopředu, dozadu, vlevo a vpravo.

Na obrázku 3.1 je zobrazeno schéma auta s řidičem a vizualizací jednotlivých zón. Zóny odpovídají výhledům z jednotlivých oken vozidla. Výhled z čelního skla je pro zónu dopředu, výhledy z bočních skel jsou pro zóny vlevo respektive vpravo a výhled z zadního skla je pro zónu dozadu, k té zároveň patří zpětná zrcátka a při couvání vestavěná obrazovka.



**Obrázek 3.1.** Auto s řidičem a zónami.



Princip je založen na práci [40], kde byl navržen detekční algoritmus pro řidiče autobusu AttenD 2.0. Hlavní výhodou používání více zón je možnost adaptace na různé jízdní scénáře, což rozšiřuje možnosti aplikace oproti systému, který by pracoval pouze s jednou zónou.

Každá zóna má jinou důležitost, která se mění v závislosti na jízdním scénáři. Při jízdě v pruhu po dálnici je nejdůležitější zóna dopředu; postranní zóny jsou minoritní, dokud řidič nechce měnit pruhy. Na křižovatkách jsou výhledy do stran mnohem více důležité. Proto je třeba mít systém schopný adaptovat se na různé jízdní scénáře.

Pro každou zónu běží samostatný sledovací mechanismus, který zaznamenává, kdy se dané zóně naposledy řidič věnoval. Sledovací mechanismus sleduje intenzitu pozornosti mezi 0 a 1 respektive 0 až 100 procent. Čím je hodnota sledovacího mechanismu blíže k 1, tím více má řidič o dané zóně přehled. Pokud sledovací mechanismus dosáhne hodnoty 0, detekuje se nedostatečná pozornost řidiče k dané zóně, a v takovém případě se spustí varování.

Při běžné jízdě rovněž v pruhu platí, že pro bezpečnou jízdu by neměl řidič ztrácet zónu dopředu z očí déle než 2 sekundy. Pro každou zónu je potřebná doba jiná a k tomu se ještě přidává potřeba adaptace na různé jízdní scénáře. Sledování pozornosti je tedy následující: pokud se řidič dané zóně věnuje, hodnota sledovacího mechanismu se zvyšuje kvadraticky až do maxima. Pokud se řidič zóně nevěnuje, hodnota sledovacího mechanismu lineárně klesá. K tomu přidáváme aditivní pokles hodnoty sledovacího mechanismu v případě manuálního ovládání prvků vozidla, ovládání rádia nebo nastavení klimatizace.

Dalším aspektem pro výpočet pozornosti je rychlost vozidla. Čím je vozidlo rychlejší, tím vyšší se předpokládá potřeba pozornosti. Proto je třeba zohlednit rychlost vozidla při výpočtu pozornosti. Fakticky se pracuje s relativní rychlostí k maximální povolené rychlosti.

Výpočet pozornosti je tedy následující:

$$A[0] = 1 \quad (1)$$

$$A[i] = A[i-1] + G[i] - M[i] \quad (2)$$

Úroveň pozornosti v čase  $i$  je dána hodnotou  $A[i]$ .  $G[i]$  je hodnota zvyšující nebo snižující pozornost podle směru pohledu řidiče,  $M[i]$  snižuje hodnotu pozornosti pokud v čase  $i$  řidič manuálně použil nějaký prvek. Iniciální hodnota pro všechny zóny je 1, protože předpokládáme, že řidič má úplnou představu o svém okolí na začátku jízdy.

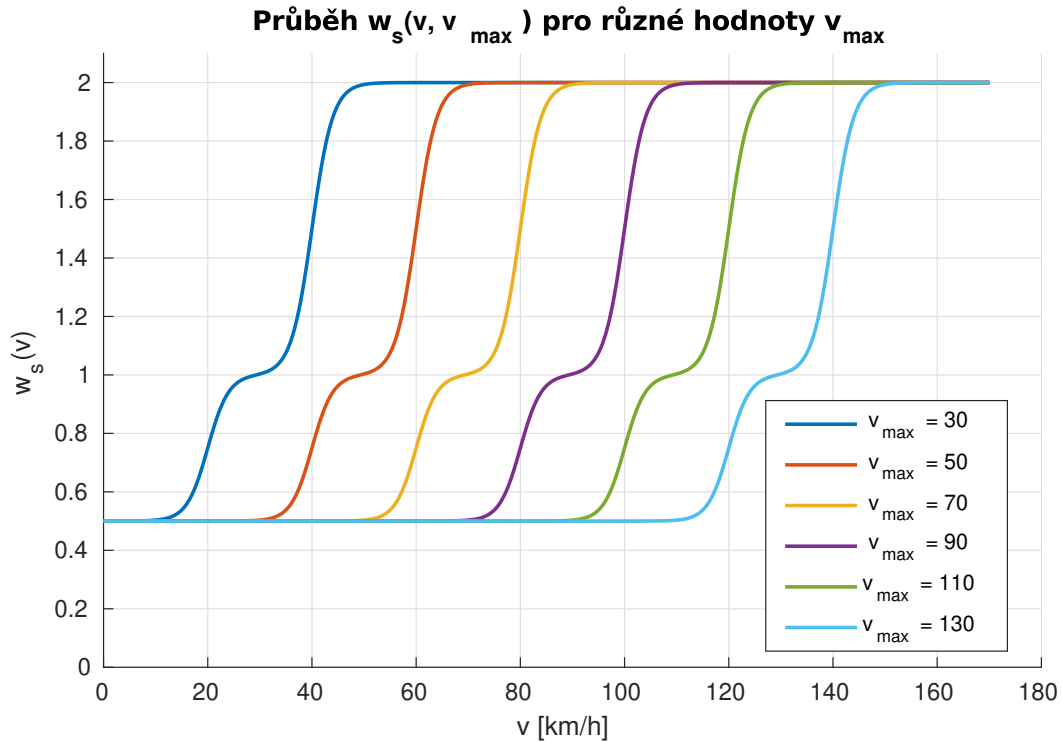
$$G[i] = \begin{cases} -g_e(Z, S)w_s & \text{pro } s[i] = 0, \\ s[i]g_f(Z, S)w_s^{-1}g_s^2 & \text{pro } s[i] > 0, \end{cases} \quad (3)$$

$$g_s[i] = \begin{cases} 0 & \text{pro } s[i] = 0, \\ g_s[i-1] + 1 & \text{pro } s[i] > 0, \end{cases} \quad (4)$$

$G[i]$  má různou hodnotu pokud se úroveň doplňuje, nebo snižuje. Pokud se snižuje, je dána pouze faktorem  $g_e(Z, S)$ , který znamená rychlost snižování v závislosti na zóně  $Z$  a situaci  $S$ . V následující kapitole (4) je ukázán výpočet  $s[i]$ , jedná se o hodnotu, která určuje jestli se řidič dívá přímo, periferním viděním, nebo vůbec. Parametr  $w_s$  přidává požadavky na pozornost podle poděru mezi maximální povolenou a aktuální rychlostí. Dále  $g_f$  je obdobný  $g_e$ , znamená rychlost doplňování, hodnoty nemusí být stejné. Dalším doplňovacím faktorem je  $g_s$  ten zaručuje kvadratické doplňování.

$$w_s = \frac{1}{2} + \frac{1}{2} \frac{1}{1 + e^{p(-v+v_{max}-q)}} + \frac{1}{1 + e^{p(-v+v_{max}+q)}} \quad (5)$$

Aktuální rychlost vozidla je  $v$ , maximální povolená rychlost je  $v_{max}$ ,  $p$  a  $q$  jsou parametry, které určují tvar funkce. Funkce nabývá hodnoty od 0.5 do 2, to znamená, že požadavky při nízké rychlosti jsou poloviční a naopak při vysoké rychlosti jsou dvojnásobné. Jsou použity parametry  $p = 0.5$  a  $q = 10$ . Na obrázku 3.2 je zobrazena závislost faktoru  $w_s$  na rychlosti vozidla a různých limitech rychlosti.



**Obrázek 3.2.** Charakteristika faktoru  $w_s$  pro různé limity rychlosti.

# Kapitola 4

## Rozpoznání zón

V této kapitole se zaměříme na klíčové prvky rozpoznávání zón a směru pohledu řidiče. K určení zóny, do které se řidič dívá, je třeba znát směr pohledu a vzdálenost od kamery. V této kapitole popíši, jak získat tyto informace a jak je využívám pro rozpoznání zóny.

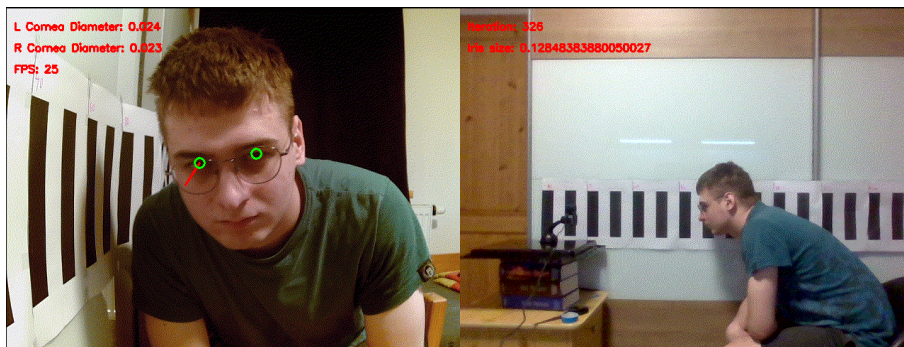
### 4.1 Vzdálenost od kamery

Pro správné určení zóny, do které se řidič dívá, je nutné znát vzdálenost řidiče od kamery. Tuto vzdálenost lze zjistit pomocí kalibrace. Výsledkem kalibrace jsou parametry matematické funkce, která převádí vzdálenost očí řidiče na vzdálenost od kamery.

Vzdálenost mezi očima je v populaci dospělých podobná, přičemž průměrná hodnota činí 64 mm u mužů a 62 mm u žen. Je však důležité mít na paměti, že tato hodnota může variabilně oscilovat v závislosti na faktorech jako je věk, pohlaví a etnická příslušnost. Pro účely kalibrace jsem použil svou vlastní vzdálenost mezi očima. Tento krok s sebou nese určitou míru nepřesnosti, která může ovlivnit výsledky, pokud jsou aplikovány na širší populaci. Nicméně, v rámci této práce jsem se rozhodl tuto odchylku zanedbat, přestože jsem si vědom potenciálního vlivu na výsledky [41].

Získání dat pro kalibraci proběhlo následovně: Použil jsem dvě kamery - hlavní web-kameru, kterou používám v autě, a pomocnou kameru. Pomocnou kameru jsem umístil kolmo ke zdi, co nejdále od ní, zatímco kalibrovanou jsem umístil přibližně 15 cm od zdi a nasměroval ji rovnoběžně se stěnou. Na stěnu jsem umístil značky v rozestupu 5 cm a poté jsem spustil natáčení obou kamer. Pohyboval jsem se lineárně od kamery v rozmezí cca 10 cm až po více než metr. Během tohoto pohybu jsem si zaznamenával vzdálenost mezi očima. Po natočení videa jsem prošel jednotlivé snímky a zaznamenal jsem si vzdálenost mezi očima při každé klíčové značce. Tím jsem získal dvojice hodnot - vzdálenost od kamery, vzdálenost mezi očima.

Na obrázku 4.1 je pohled na kalibraci vzdálenosti. Je zde sloučený obraz z obou kamer.



**Obrázek 4.1.** Náhled na kalibraci vzdálenosti.


Následně jsem provedl kalibraci pomocí metody nejmenších čtverců. Vzdálenost od kamery je nepřímo úměrná vzdálenosti mezi očima. Používám následující rovnice:

$$y(d) = ad^{-1} + b \quad (1)$$

$$\min_{a,b} \sum_{i=1}^n (ad_i^{-1} + b - y_i)^2. \quad (2)$$

Kde  $y_i$  je vzdálenost od kamery,  $d_i$  je vzdálenost mezi očima a  $a$ ,  $b$  jsou parametry kalibrace. Parametry  $a$ ,  $b$  jsou lineární ke vzdálenosti od kamery.

Převodní charakteristika vzdálenosti od kamery na vzdálenost mezi očima



**Obrázek 4.2.** Převodní charakteristika vzdálenosti očí na vzdálenost od kamery.

Po minimalizaci jsem získal parametry  $a = 3.274$ ,  $b = 0.054$ . Na obrázku 4.2 je zobrazena převodní charakteristika vzdálenosti očí na vzdálenost od kamery.

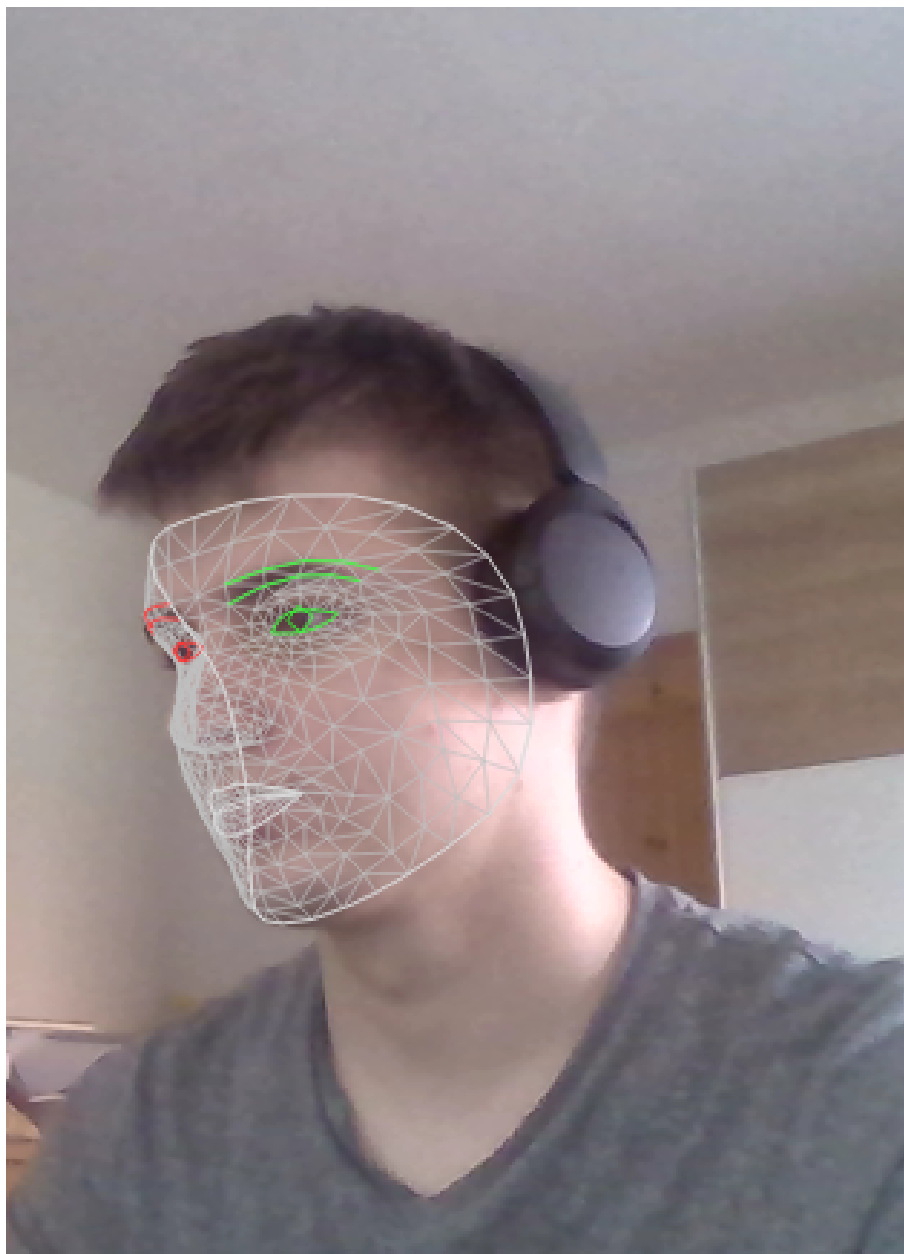
Vynechal jsem kompenzaci perspektivy, protože jsem zjistil, že výsledky jsou dostatečně přesné i bez ní. Pouze jsem při natáčení sekvence dbal na to, aby poměr vzdálenosti mezi kamerou hlavou oproti vzdálenosti mezi hlavou a stěnou byl co největší a tím efekt byl co nejmenší. Výsledky kalibrace jsou dostatečně přesné pro účely této práce.

Pro mojí aplikaci je důležité aby detekce vzdálenosti nebyla závislá na směru, kam se řidič dívá. Proto používám vzdálenost mezi očima, ve 3D prostoru místo 2D obrazu. Na obrázku 4.3 je zobrazena maska detekce klíčových bodů obličeje z úhlu. Při pohledu z boku je na obraze vzdálenost očí menší než při pohledu zepředu.

Klíčové body obsahují informaci o relativní poloze očí vůči středu obličeje a tím i jejich Euklidovskou vzdálenost. A právě tato vzdálenost je vstupem pro kalibraci vzdálenosti.

## 4.2 Směr pohledu

Pro rozpoznání zóny, do které se řidič dívá, je nutné znát směr pohledu řidiče. K tomu používám MediaPipe, jedná se o deep learningový framework od Googlu. Konkrétně jejich model pro detekci klíčových bodů obličeje.



**Obrázek 4.3.** Ukázka masky s klíčovými body obličeje.

Model detekuje 468 klíčových bodů obličeje. Pro rozpoznání směru pohledu využívám pozici klíčových bodů očí, špičky nosu, brady a koutků úst. Na obrázku 4.3 je zobrazena maska klíčových bodů obličeje. K určení směru pohledu je třeba získat pozici hlavy a očí.

Pracuji opět s 3D modelem průměrného lidského obličeje. V tabulce 4.1 jsou uvedeny klíčové body obličeje a jejich pozice v 3D prostoru. Počátek souřadnicového systému je na špičce nosu.

Klíčové body z tabulky kromě středu oka použiji pro získání rotační matice a translačního vektoru mezi souřadnicemi kamery a obličeje. Z rovnice pro pinhole kameru vychází

Klíčový bod	x	y	z
Nos	0.0	0.0	0.0
Brada	0.0	-73.6	-12.5
Koutek levého oka	-43.3	32.7	-26.0
Koutek pravého oka	43.3	32.7	-26.0
Levý koutek úst	-28.9	-28.9	-24.1
Pravý koutek úst	28.9	-28.9	-24.1
Střed pravého oka	29.05	33.7	-39.5

**Tabulka 4.1.** Tabulka klíčových bodů obličeje.

rovnice:

$$S \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \mathbf{M} [\mathbf{R} \mid \mathbf{t}] \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}, \quad (3)$$

kde  $S$  je neznámý škálovací faktor,  $u$  a  $v$  jsou obrazové souřadnice,  $x$ ,  $y$  a  $z$  jsou světové souřadnice,  $\mathbf{M}$  je matice kamery,  $\mathbf{R}$  je rotační matice a  $\mathbf{t}$  je translační vektor.

Matici kamery  $\mathbf{M}$  znám z kalibrace kamery. Rotační matici a translační vektor získám pomocí solvePnP od OpenCV. Jako vstupní data použiji klíčové body obličeje a jejich světové souřadnice.

Když získám výsledek, tak můžu zpětně transformovat pozici zornice do souřadnic obličeje. Body v prostoru, kterým definuji směr pohledu jsou střed pravého oka a bod  $s$ , který získám z následující rovnice:

$$\mathbf{s} = \mathbf{c} + (\mathbf{p} - \mathbf{c})t,$$

kde  $\mathbf{c}$  je střed pravého oka,  $\mathbf{p}$  je střed zornice a  $t$  škálovací faktor, kterým je určena vzdálenost bodu od středu oka. Dále ještě podle [42] upravuji výsledek podle pozice hlavy zpět do obrazové roviny.

Nyní mám vypočtený vektor 3D prostoru, který představuje směr pohledu řidiče. Vektor je odolný vůči pohybu hlavy a vzdálenosti řidiče od kamery. Limitem je detekce obličeje pomocí frameworku MediaPipe. Pokud obličej není detekován, tak nelze určit směr pohledu. To omezuje přesné určení pokud je třeba řidič otočený dozadu.

### 4.3 Rozpoznání zón

Pro rozpoznání zóny, do které se řidič dívá, jsem použil metodu založenou na kombinaci vektoru pohledu a vzdálenosti od kamery. Každou zónu definuji jejím středem. Pro každý snímek získám vektor pohledu a vzdálenost od kamery. Následně spočítám úhel mezi vektorem pohledu a vektorem, který míří do středů jednotlivých zón. Zóna, která má nejmenší úhel, je zóna, do které se řidič dívá.

Střed zóny je definován v 3D prostoru a je statický. Hlava řidiče se může pohybovat a podle toho je třeba kompenzovat vektor do středu zóny. Kompenzují pohyb v podélném směru, to kompenzuje předklánění hlavy a posun sedačky dopředu nebo dozadu.

Pro každou zónu jsem provedl záznam dvou vektorů, jeden v předkloněné pozici a druhý v základní pozici. Pro oba mám i záznam vzdálenosti od kamery. Z těchto hodnot jsem vytvořil afinní funkci pro převod vzdálenosti od kamery na vektor do středu zóny. Výsledný úhel počítám, tedy mezi

Pro práci s periferním viděním používám metodu, kdy zónám přiřazuji skóre podle velikosti úhlu od středu zóny. Matematická funkce pro výpočet skóre je následující:

$$s = \begin{cases} 1 - \frac{|\phi|}{\phi_{max}} & \text{pro } |\phi| \leq \phi_{max}, \\ 0 & \text{pro } |\phi| > \phi_{max}. \end{cases} \quad (4)$$

kde  $\phi$  je úhel mezi vektorem pohledu a středem zóny a  $\phi_{max}$  je limitní velikost úhlu pro periferní vidění.

Zvláštní případ je zóna, která míří dozadu, protože se ve skutečnosti jedná o více zón. Pracuji tedy s vektorem pro každou jednotlivou část zóny a následně vyberu tu, která má nejmenší úhel. Další výjimkou je, že ne vždy je možné použít všechny části. Tím se myslí situace, že při couvání je zapnutá parkovací kamera a její obraz je promítán na obrazovku. Při jízdě dopředu je ale obraz vypnutý a tím pádem nelze použít tuto část zóny.

## 4.4 Otočení dozadu

V případě, kdy se řidič otočí kvůli výhledu dozadu, tak nelze tuto použít, protože MediaPipe nedetekuje obličej. V takovém případě je třeba použít jiný způsob rozpoznání zóny. Je použitý jiný model od MediaPipe, který detekuje pózu těla.

Na obrázku 4.4 je zobrazen model klíčových bodů těla. Pro detekci otočení hlavy dozadu jsou použity klíčové body koutků úst a ramen.


Detekce otočení je provedena pomocí výpočtu poměru vzdálenosti mezi koutky úst a ramen. Pokud je tento poměr větší než určitá hodnota, tak je řidič otočený dozadu. V takovém případě je zóna, do které se řidič dívá, nastavena na zónu, která je za vozidlem.

## 4.5 Kalibrace kamery

Kalibrací kamery se rozumí proces, kdy se získávají parametry kamery, které jsou důležité pro převod mezi 3D světovými souřadnicemi a 2D obrazovými souřadnicemi. Tyto parametry jsou uloženy v matici kamery. Pro kalibraci kamery jsem použil OpenCV.


Bylo nafoceno deset snímků šachovnicového vzoru. Šachovnicový vzor je ideální pro kalibraci kamery, protože obsahuje mnoho rohů, které lze snadno detekovat a OpenCV má přímo metody pro získání parametrů kamery ze sady takovýchto obrázků. Na obrázku 4.5 je zobrazen šachovnicový vzor, který jsem použil pro kalibraci kamery. Vzorek byl umístěn na zem a kamera se pohybovala kolem něj. Je důležité, že se kamera pohybovala v různých vzdálenostech a úhlech, aby bylo možné získat co nejvíce informací pro kalibraci.

OpenCV proces kalibrace kamery zahrnuje několik kroků. Prvním krokem je detekce rohů šachovnicového vzoru. Pro detekci rohů jsem použil metodu *findChessboardCorners*. Tato metoda vrací souřadnice nalezených rohů. Následně jsem zavolał metodu *calibrateCamera*, která vrací matici kamery a další parametry, jako jsou parametry distorze čočky.



**Obrázek 4.4.** Ukázka klíčových bodů těla [43].





**Obrázek 4.5.** Kalibrace kamery pomocí šachovnicového vzoru.

# Kapitola 5

## Interakce s vozem a získání dat

V této kapitole si ukážeme, získání provozních dat z vozu. Tyto data jsou použita k rozpoznání jízdních úkonů, manuálních distrakcí a nároků na pozornost. Jedná se o data z CAN sběrnice, která je standardní součástí moderních vozů.

### 5.1 Získání dat z vozu

Data jsou čtena přímo pomocí utility *cantools* a následně zpracována. Data nejsou v lidsky čitelné podobě, proto je třeba je dekodovat pomocí dekodovací matice. Touto dekodovací maticí je *DBC* soubor, který obsahuje informace o jednotlivých CAN zprávách. V souboru jsou definovány jednotlivé zprávy, které obsahují jednotlivé signály. Tyto signály jsou následně dekodovány do lidsky čitelné podoby.

V souboru jsem hledal všechny zprávy, které obsahují informace o interakci řidiče s vozem a potřebné informace pro výpočty, jako je rychlost vozu, maximální povolená rychlost a další. Jednotlivé zprávy obsahují více signálů, je třeba vybrat pouze ty, které jsou potřebné. Jedná se o signály na větvi komfort CAN sběrnice. Ta obsahuje nekritické informace, které nejsou dále chráněny. Výběr signálů je zobrazen v tabulce 5.1, jsou zde použity zkratky, které vysvětlují použití signálu. NÁR znamená nárok na pozornost, SIT znamená situace a MAN znamená manuální distrakce.

Význam	Využití
Rychlost vozu	NÁR + SIT
Maximální povolená rychlost	NÁR
Levý blinkr	SIT
Pravý blinkr	SIT
Jízdní režim	SIT
Ovládání všech okének	MAN
Ovládání vnitřních světel	MAN
Vytápění volantů	MAN
Přítomnost řidiče a spolujezdce	ostatní

**Tabulka 5.1.** Vybrané signály ze sběrnice a jejich využití.

Zprávy jsou určeny pro realtime zpracování, chodí v pravidelných intervalech nezávisle na změnách hodnot. Manuální použití se rozpozná na náběžnou hranu signálu, která znamená změnu hodnoty. Jízdní režim, rychlost vozu a maximální povolená rychlost jsou zpracovány přímo na základě hodnot signálů.

#### 5.1.1 Infotainment

Zvláštní případ je infotainment, protože informace o interakci s ním se nacházejí jiné sběrnici. K dekodování těchto dat je třeba použít jiný *DBC* soubor, který nebyl k

dispozici. Bylo třeba tedy pracovat s daty v surovém stavu, což znamená, že data nebyla dekodována a byla zpracována pouze na základě jejich hodnot. Zachycovány jsou tedy zprávy s požadovaným identifikátorem a zpracovány na základě jejich hodnot.

Zpráva obsahuje informace o tom kolika prsty byl proveden dotykna obrazovku a kde byl dotyk proveden. Pro detekce manuální nepozornosti stačí sledovat, zda byl proveden alespoň nějaký dotyk. To je řešeno tak, že z pozorování jsem zjistil, že při dotyku se určité byty nastaví na vždy stejnou hodnotu. Tuto hodnotu jsem použil k detekci dotyku.

Už při přiblížení k obrazovce se hodnoty začnou měnit až při skutečném dotyku se ustálí, toto bylo potřeba odfiltrovat. To jsem provedl tak, že jsem zavedl časový limit, který musí být dodržen mezi dvěma dotyky. Aktuální limit je 0.3 sekundy, což je dostatečný čas na to, aby se hodnoty ustálily.

V případě, že se v autě nachází i spolujezdec je možné, že display ovládá on. Je možné pracovat s předpokladem, že když se v autě nachází spolujezdec, tak doteky nejsou od řidiče. Tento předpoklad lze realizovat zpracovaným signálem o připnutí bezpečnostního pásu spolujezdce. Systém je na to připraven, ale je třeba mít na paměti, že tento předpoklad nemusí být vždy pravdivý. V konečné verzi s tímto omezením nepracuji.

# Kapitola 6

## Rozpoznání jízdních situací

V této kapitole se zaměříme na rozpoznání specifických jízdních situací, které řidič řeší během řízení vozidla. Pojem situace zde chápeme jako konkrétní jízdní úkol, kterým se řidič v daném okamžiku zabývá. Tyto situace mohou být velmi rozmanité, sahající od jednoduché jízdy v pruhu, přes složité manévrování v hustém městském provozu, až po navigaci v neznámém terénu.

Každá jízdní situace klade specifické požadavky na pozornost řidiče a vyžaduje odlišnou reakci systému. To znamená, že detekční systém musí být schopen rozpoznat a přizpůsobit se různorodým podmínkám, aby mohl efektivně asistovat řidiči. To zaručuje multizónový přístup, který sleduje pozornost řidiče na jeho okolí, každá zóna má své specifické požadavky a parametry, které se podle situace mění. V této kapitole se zaměříme na rozpoznání tří základních jízdních situací, se kterými v implementaci systém pracuje.

### 6.1 Typy situací

V reálném provozu se řidiči setkávají s velkým množstvím různě komplexních situací, kde každá si vyžaduje pozornost jinde. V rámci této práce pracují se třemi respektive čtyřmi fundamentálními situacemi. Jedná se o jízdu v pruhu, přejíždění mezi pruhy a couvání. Tyto situace byly vybrány, kvůli častému výskytu a kvůli rozdílným požadavkům, které každá situace přináší.

Pro rozpoznání situací jsou použita data zachycená ze sítě CAN. Konkrétně se jedná o informaci o jízdním režimu, rychlosti a o ovládní blinkrů. Pro vůz s manuální převodovkou by stav jízdního režimu byl nahrazen informací o zvoleném převodu. Tyto informace jsou dostatečné pro rozpoznání základních situací.

Pro každou situaci je třeba nastavit parametry, pro rozpoznání a pro důležitost každé zóny v dané situaci. Parametry důležitosti zóny se myslí rychlost snižování a doplňování sledované hodnoty pozornosti.

#### 6.1.1 Jízda v pruhu

Jízda v pruhu je jízdní úkon, který je nejčastější a zabírá většinu času jízdy. V této situaci je řidič zaměřen na sledování vozovky, udržení odstupu od kraje pruhu a odstup od vozidel jedoucích před ním. Nejdůležitější zónou je tedy přední zóna. Ostatní zóny jsou méně důležité, ale ne zanedbatelné. V tabulce 6.1 jsou uvedeny parametry pro jednotlivé zóny.

Situaci určí když zvolený jízdní režim je *Drive*, neprobíhá signalizace změny směru blinkry a rychlost je vyšší než minimální hodnota rychlosti. Ta je nastavená na 5 km/h, aby se odfiltrovaly situace, kdy je vůz v klidu nebo se pohybuje velmi pomalu což je zpravidla při parkování a tam by požadavky byly jiné.

Zóna	Rychlost snižování [1/s]	Rychlost doplňování [1/s]
Přední	0.5	0.5
Zadní	0.005	0.5
Levá	0.05	0.5
Pravá	0.05	0.5

**Tabulka 6.1.** Parametry zón při jízdě v pruhu.

### 6.1.2 Přejíždění mezi pruhy

Přejíždění mezi pruhy je situace, kdy řidič za jízdy po vícepruhové silnici mění pruh. Byla zvolena, protože se jedná o doplněk k jízdě v pruhu a je také velmi častá. V této situaci je řidič zaměřen na sledování vozovky a na kontrolu odstupů od vozidel v sousedních pruzích. Rozlišuje se přejíždění doleva a doprava, ale obě situace jsou symetrické. V tabulce 6.2 jsou uvedeny parametry pro jednotlivé zóny.

Situaci určím když zvolený jízdní režim je *Drive*, proběhla signalizace změny směru blinkry a rychlost je vyšší než minimální hodnota rychlosti. Situace je platná až 5 sekund po skončení signalizace, tím se získává čas na přejíždění i po použití tzv. trojblíku. Předpokládá se, že řidič podle pravidel provozu řádně signalizuje změnu pruhu pomocí blinkrů.

Zóna	Rychlost snižování [Hz]	Rychlost doplňování [Hz]
Přední	0.005	1
Zadní	0.08	1
Levá/Pravá	0.17	0.5
Pravá/Levá	0.025	1

**Tabulka 6.2.** Parametry zón při přejíždění mezi pruhy.

### 6.1.3 Couvání na parkovišti

Couvání na parkovišti zahrnuje nejen samotný pohyb vozidla vzad, ale také nutnost přehledně sledovat zadní a boční zóny. Jedná se o situaci, kdy je řidič zaměřen na sledování prostoru za vozidlem a na kontrolu odstupů od překážek. Specifickou výzvou pro tuto situaci je, že řidič má mnoho možností jak sledovat prostor kolem sebe a za sebou. Využije se tedy pohled do všech částí zón za vozidlem, včetně možnosti otočení hlavy. V tabulce 6.3 jsou uvedeny parametry pro jednotlivé zóny.

Situaci určím když zvolený jízdní režim je *Reverse*. Zde nejsou žádné požadavky na rychlost, protože couvání je obvykle pomalé a rychlost je omezena.

Zóna	Rychlost snižování [Hz]	Rychlost doplňování [Hz]
Přední	0.005	1
Zadní	0.5	0.5
Levá	0.12	0.5
Pravá	0.12	0.5

**Tabulka 6.3.** Parametry zón při couvání.

#### ■ 6.1.4 Nastavení parametrů

Nastavení parametrů je zásadní pro funkci systému. Podle obecných doporučení pro bezpečnou jízdu by řidič neměl ztrácet silnici z očí déle než 2 sekundy. To by platilo pro jízdu dopředu v pruhu, tento čas je základem pro nastavení hodnot. Ostatní parametry jsou odvozeny z tohoto času. Pro jiné případy žádné takovéto obecné doporučení neexistuje, proto jsou parametry zvoleny experimentálně tak aby odpovídali zkušenosti. Nejpodstatnější zóny v daných situacích mají podobné parametry u všech situací a ostatní zóny jsou odvozeny z nich.

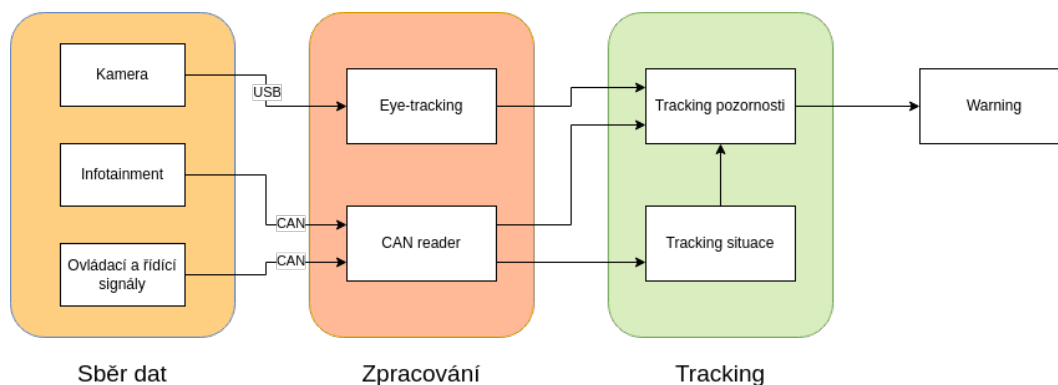
# Kapitola 7

## Implementace systému

V této kapitole je podrobně popsána implementace systému pro monitorování pozornosti řidiče. Představuji jednotlivé komponenty systému, použité technologie a postupy, které byly aplikovány během implementace.

### 7.1 Architektura systému

Systém je rozdělen do čtyřech hlavních částí: sběr dat, zpracování dat, tracking situace a pozornosti a výstupní modul. Na obrázku 7.1 je schéma architektury systému. Každý blok na obrázku představuje jednu z částí systému.



Obrázek 7.1. Architektura systému

#### 7.1.1 Sběr dat

Sběr dat představuje výčet CAN zpráv z vozidla a obrazových dat z kamery. Kamera je k počítači připojena přes USB rozhraní. Z CANu se používají dvě sítě, jedna pro infotainment a druhá pro všechny ostatní data.

#### 7.1.2 Zpracování dat

Zpracování dat zahrnuje zpracování obrazových dat z kamery a zpracování CAN zpráv z vozidla.

Obraz z kamery se zpracovává pomocí algoritmů popsaných v kapitole 4.1. Postupně se zpracovává každý snímek a výsledkem je skóre pro každou zónu. K tomu je využito frameworku pro získání rozpoznání postav a obličejových rysů. Z těchto dat se vytváří skóre pro každou zónu. To odpovídá úhlu mezi vektorem odpovídajícím pohledu řidiče a referenčním vektorem pro danou zónu. Skóre je normalizováno na interval 0 až 1.

Zpracování CAN zpráv zahrnuje překlad zpráv do srozumitelné podoby. Hledá se v nich za prvé využití určitých mechanických prvků, které může řidič při jízdě používat. Zprávy jsou zpracovány a výsledkem je signalizace o použití mechanických prvků. Dále se získávají podstatné informace o stavu vozidla, ze kterých je určena jízdní situace. Tyto informace se předávají do trackingu situace a pozornosti.

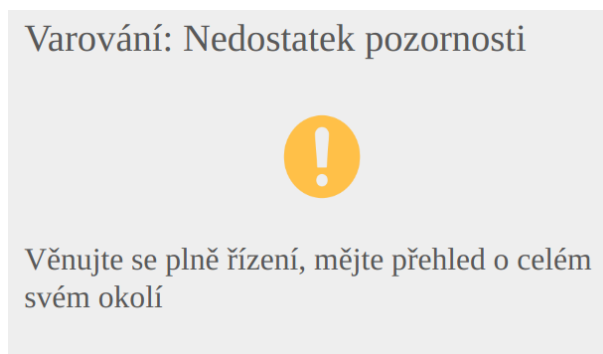
### 7.1.3 Tracking situace a pozornosti

Tracking pozornosti je jádrem systému. Vstupují do něj zpracovaná data z kamery, které už přímo představují skóre pro každou zónu. Dále do něj vstupuje signalizace o detekci použití mechanických prvků z bloku zpracovávajícího CAN zprávy. Systém s každým novým snímkem, nebo detekcí použití mechanických prvků aktualizuje skóre pro každou zónu. Pokud hodnota dosáhne 0, systém vyhodnotí, že řidič je v dané zóně dostatečně dlouho a upozorní ho.

Tracking situace nastavuje parametry, trackingu pozornosti. Vstupují do něj přeložené informace o stavu vozidla z bloku zpracovávajícího CAN zprávy.

### 7.1.4 Výstupní modul

Výstupem je notifikace, která vyzívá řidiče ke zvýšení pozornosti. Notifikace se objeví v případě, že u některé zóny dosáhne skóre 0. Jedná se pouze o vizuální upozornění, které se zobrazí na obrazovce. Další možností je haptická zpětná vazba z volantu nebo zvuková výzva. Tyto možnosti implementovány nebyly, ale měli by výhodu v tom, že mají větší pravděpodobnost, že řidiče upozorní.



**Obrázek 7.2.** Notifikace při nedostatku pozornosti.



# Kapitola 8

## Realizace ve vozidle

V této kapitole se budu věnovat realizaci systému ve vozidle. Realizace navazuje na dřívější práci studentů Nejtka a Pinkavi, kteří se věnovali realizaci systému v autě [44, 5]. Celý systém funguje v testovacím vozidle Škoda Enyaq iV, které je na fakultě k dispozici. Na obrázku 8.1 je vidět foto auta.



**Obrázek 8.1.** Foto auta [5].

### 8.1 Počítač a připojení

Systém jsem zkoušel na svém osobním laptopu, který má nainstalovaný operační systém Ubuntu 22.04. Návrh je ale určen pro průmyslový počítač ARK-3520P od společnosti Advantech. Tento počítač je vybavený stejným operačním systémem a z dřívějších prací je vybavený systémy pro komunikaci s vozem. Lze díky němu i zobrazovat vlastní grafické rozhraní, které je potřeba pro zobrazování informací řidiči. Na obrázku 8.2 je vidět počítač. CAN je připojený pomocí gatewaye, která je připojená k počítači přes USB [45].

### 8.2 Kamera

Je použita běžná webkamera, která je připojena k počítači pomocí USB. Konkrétně se jedná o model *Eternico Webcam ET201 Full HD*, viz obrázek 8.3. Při volbě byl kladen důraz především na dostupnost, hlavním požadavkem ale byla kompatibilita s operačním systémem Ubuntu 22.04, který běží na počítači v autě. V tabulce 8.1 jsou uvedeny technické parametry kamery.

Kamera je umístěna v interiéru auta pod zpětným zrcátkem a je namířena na řidiče. K umístění kamery používám držák na čelní sklo *Swissten S2*, který je připevněn pomocí přísavky. Do držáku jsem navrhnul a vytiskl nástavec, který umožňuje připevnit



**Obrázek 8.2.** Počítač ARK-3520P [46]




**Obrázek 8.3.** Použitá webkamera [47]

Rozlišení	1920 x 1080
Frekvence snímání	30 fps
Zorné pole	106.28°


**Tabulka 8.1.** Tabulka s technickými parametry kamery.

kameru. Model jsem vytvořil pomocí online nástroje *Onshape* a vytiskl na 3D tiskárně *Prusa i3 MK3S*. Tisk byl nastaven s vyhříváním podložky na 85 °C a tryskou na 285 °C. Použitý filament je PETG. PETG byl zvolen pro tuto aplikaci kvůli jeho pevnosti a vyšší teplotní odolnosti oproti druhé dostupné variantě, což bylo PLA [48].

Na obrázcích 8.4 a 8.5 je vidět nástavec zepředu a shora i s rozměry. Na obrázku 8.6 je vidět nástavec z úhlu pro lepší představu o tvaru.



Obrázek 8.4. Pohled na nástavec zepředu.




Obrázek 8.5. Pohled na nástavec shora.

### 8.3 Nastavení referenčních vektorů zón

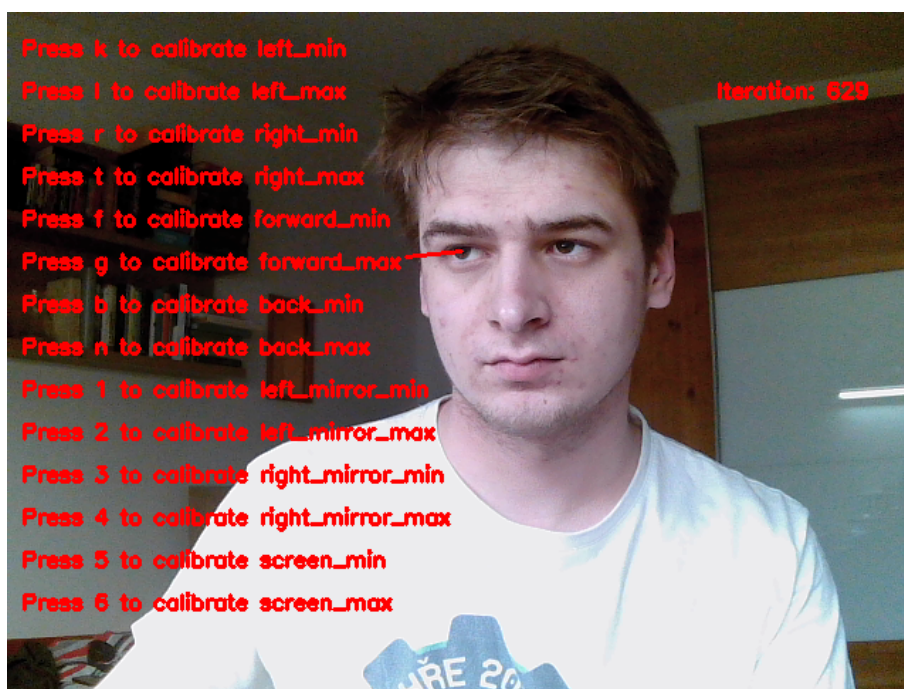
Pro určení příslušnosti pohledu k zóně se používá úhel mezi referenčním vektorem zóny a vektorem pohledu. Referenční vektor je vektor, který v dané vzdálenosti řidiče od kamery míří na střed zóny. To záleží na skutečném umístění kamery v autě.

Protože při vývoji bylo potřeba kameru opakovaně umisťovat a testovat, bylo nutné vytvořit nástroj, který umožní snadné nastavení referenčních vektorů zón a uložení pro pozdější použití. Systém si po spuštění zkontroluje existenci konfiguračního souboru s referenčními vektory zón. Pokud takový soubor neexistuje, nebo v něm nejsou validní data, spustí se nástroj pro nastavení referenčních vektorů zón. Nástroj lze spustit i manuálně při přepnutí do debugovacího režimu.

Na obrázku 8.7 je vidět nástroj pro nastavení referenčních vektorů zón. Zobrazuje se okno s obrazem z kamery a znázorněným vektorem pohledu. Nastavení referenčního vektoru proběhne tak, že řidič se podívá do středu vybrané zóny a po stisknutí tlačítka se aktuální vektor pohledu uloží do konfiguračního souboru. Pro každou zónu je třeba uložit dva vektory, jeden v předkloněné pozici a druhý opřený o opěrku hlavy. Vektory jsou uloženy v konfiguračním souboru ve formátu JSON. Na obrázku 8.8 je ukázka konfiguračního souboru s referenčními vektory zón. Po nastavení všech referenčních vektorů zón se spustí program v normálním režimu.



**Obrázek 8.6.** Nástavec na kameru.



**Obrázek 8.7.** Nástroj pro nastavení referenčních vektorů zón.

```
[  
  {  
    "name": "right_mirror_max",  
    "dist": 40.2480384522911,  
    "vector_x": 80.74187716134888,  
    "vector_y": -11.94448391581678,  
    "vector_z": 121.9181889388787  
  },  
  .  
  .  
  .  
]
```

**Obrázek 8.8.** Ukázka konfiguračního souboru s referenčními vektory zón.

# Kapitola 9

## Výsledky

V této kapitole jsou prezentovány výstupy programu. Nejprve jsou zobrazeny výstupy z eye-trackingu a následně z výstupů sledování pozornosti. Popíšu jak probíhala testování.

### 9.1 Eye-tracking

Na obrázcích 9.1 a 9.2 je ukázka výstupu eye-trackingu. Červeně je projekce vektoru pohledu řidiče na obrazovku.

Výsledky jsou limitovány kvalitou kamery a frameworkem pro získání pozice obličejových rysů. Limity frameworku jsou následující: musí být vidět alespoň 50 procent obličeje, samotný obraz obličeje musí být kvalitní po přeškálování na 192x192 pixelů, takže kamera nesmí být příliš daleko, obličej by neměl být odkloněný více než 80 stupňů nebo nakloněný ve vertikální rovině více než 8 stupňů [49]. Dále jsem narazil na problémy při silném osvětlení, kdy byl obraz přesycený. Výstup je tedy omezen na situace, kdy je obličej dobře vidět a kdy je obraz kvalitní.

Detekce obličejových bodů probíhá i v případě, že řidič nosí sluneční brýle, ale protože nejsou oči reálně vidět, framework jejich pozici pouze odhaduje. Nelze tedy zaručit, že výstup bude správný.

Pro získání transformace ze souřadnicového systému obličeje do souřadnicového systému kamery používám funkci `estimateAffine3D` z knihovny OpenCV. Jedním vstupem jsou klíčové body z frameworku a druhým je předem definovaná sada klíčových bodů obličeje s jejich reálnými pozicemi. Tato transformace také může selhat, například v případě, že řidič používá výraznou mimiku při mluvení. Klíčové body z předem definované sady se pak neshodují s tvarem obličeje řidiče.

Systém byl testován v různých podmínkách. Při testování uvnitř bodovy pod umělým osvětlením byl výstup stabilní a přesný na téměř 100 procent. Selhání nastalo pouze v případě otočení se od kamery. Při testování v reálných podmínkách za denního světla byl výstup stabilní a přesný na 80 procent. Dále byl systém testován za jízdy v tunelu, kde chování bylo podobné jako v reálných podmínkách za denního světla. S tím že nastal vteřinový výpadek kvůli přesycení při výjezdu z tunelu.



**Obrázek 9.1.** Výstup sledování pohledu při pohledu do strany.



**Obrázek 9.2.** Výstup sledování pohledu při pohledu dopředu.


## 9.2 Tracking pozornosti

Na obrázku 9.3 je zobrazen výstup sledování pozornosti v čase. Na ose x je čas v sekundách a na ose y je skóre pro zóny zkoušené v daném běhu. Barevné pruhy značí anotované snímky, kdy byl odvrácen zrak jinam. Růžové pruhy značí snímky, kdy byl odvrácen zrak doleva. Zelené pruhy značí snímky, kdy byl odvrácen zrak doprava.

Hodnoty jsou z logu z běhu programu, kdy byly sledovány zóny v laboratorních podmínkách. Jízdní situace byla napevno nastavena na jízdu v pruhu a zóny byly nastaveny tak, aby odpovídali rozložení zón v reálném vozidle. Koeficient náročnosti podle rychlosti byl nastaven na 1. Zároveň bylo z kamery zaznamenáno video, které jsem prošel a anotoval přesné snímky, kdy byl odvrácen zrak jinam.

Když hodnota skóre dosáhne 0, systém vyhodnotí, že řidič je v dané zóně dostatečně dlouho a upozorní ho. Upozornění prošlo v tomto běhu ve třech časech. První v čase 8.7 s, 2.1s po odvrácení zraku. Druhý je zvláštní v tom, že nešlo jen o dlouhé odvrácení zraku, ale o sekvenci 2 kratších odhlédnutí za sebou. Vyznačuje se krátkým, částečným doplněním kolem času 47 s. První odhlédnutí začalo v čase 46.3 s a vyhlášení upozornění nastalo v čase 49.2 s, to je 2.9 s po prvním odvrácení zraku. Třetí upozornění bylo v čase 59.8 s, 2.1s po odvrácení zraku. Je vidět, že se ve vyznačených časech doplňovala hodnota pro danou postranní zónu a pro ostatní zóny se hodnota snižovala.

Mezi časem 14 a 21 s jsem zkoušel zastínit kameru rukou. To způsobilo falešné detekce.



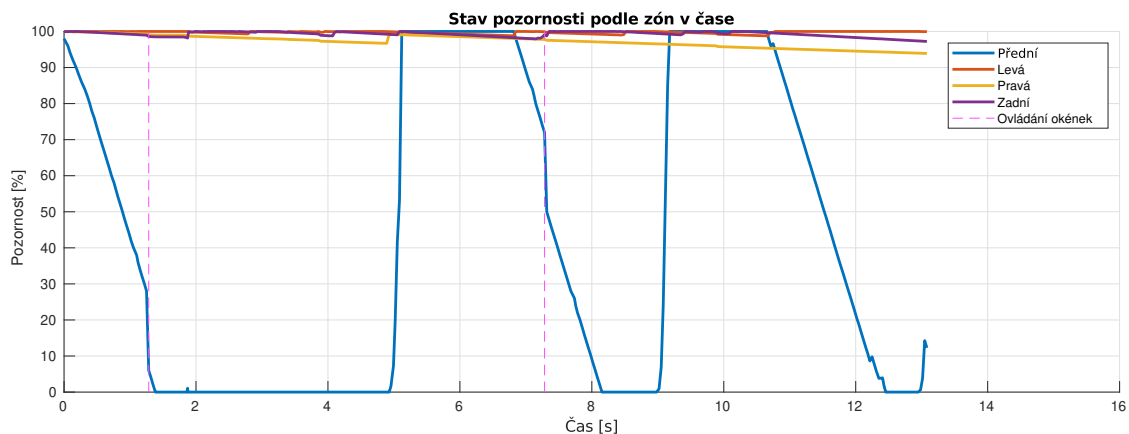
**Obrázek 9.3.** Výstup sledování pozornosti v čase, laboratorní podmínky

Na obrázku 9.4 je zobrazen výstup sledování pozornosti v reálných podmínkách za stání. Na ose x je čas v sekundách a na ose y je skóre pro zóny zkoušené v daném běhu. V časech 1.3 s a 6.3 s se projevuje vliv manuálního ovládání okének. Tento vliv se propisuje do všech zón, ale je nejvíce vidět přední zóně modrý graf. Jedná se o okamžitý skok v hodnotě. Projevuje se zde i efekt spojení vizuální a manuální nepozornosti, kdy se řidič soustředí na ovládání okének a zároveň se odvrací zrakem od cesty.

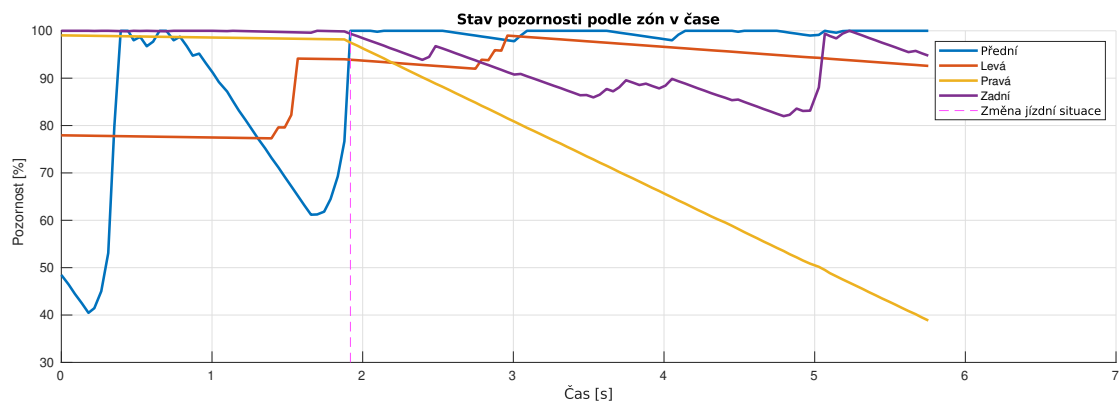
Na obrázku 9.5 je zobrazen výstup sledování pozornosti v reálných podmínkách za jízdy. Jedná se o jízdu tunelem, při které se mění pruh. V čase 1.9 s se sepnul blinkr. Je vidět změna strmosti úbytku pozornosti na pravé zóně a kontrola pravého zpětného zrcátka na zadní zóně.

Na obrázku 9.6 je zobrazen výstup sledování pozornosti pro situaci couvání. Zde jsou vyzkoušeny všechny možnosti spojené s kontrolou zadní zóny. Postupně jsem vyzkoušel všechny zrcátka, obrazovku se zpětným obrazem a přímo pohled dozadu při otočení.

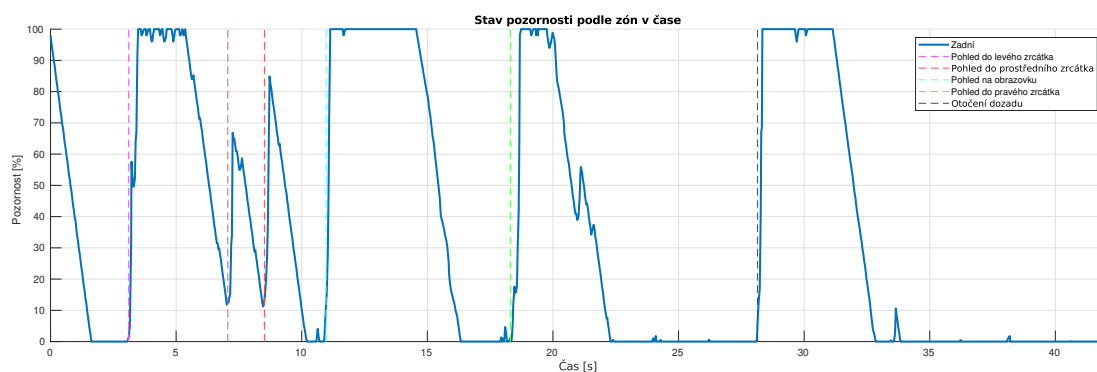




**Obrázek 9.4.** Výstup sledování pozornosti v čase, reálné podmínky za stání.



**Obrázek 9.5.** Výstup sledování pozornosti v čase, reálné podmínky za jízdy.



**Obrázek 9.6.** Výstup sledování pozornosti v čase při couvání, laboratorní podmínky.

## 9.3 Shrnutí

Výstupy jsem získal z testování v laboratorních podmínkách a v reálných podmínkách. Z běhu programu jsem natočil video záznam, který jsem prošel a anotoval. Zároveň jsem logoval výstupní hodnoty z programu.

Systém reaguje v rámci očekávání na všechny situace, které byly testovány. Odezva na změnu je v řádu jednotek snímků. Přesnost sledování pohledu je závislá na kvalitě

obrazu a na kvalitě detekce obličejových rysů. I s touto limitací je systém schopný rozeznat od sebe jednotlivé zóny.

S nastavenými hodnotami je systém poměrně přísný jednotlivé parametry lze upravit podle potřeby. V grafech je vidět, že systém reaguje na všechny požadované vstupy.

# Kapitola 10

## Závěr

V této práci jsem se zabýval pozorností řidiče, což je klíčový aspekt pro zajištění bezpečnosti na silnicích. Navíc je podle nejnovějších směrnic EU povinností výrobců automobilů monitorovat pozornost řidiče a v případě detekce nepozornosti zasáhnout. V úvodní části práce jsem prostudoval dostupné informace o pozornosti řidiče a způsobech jejího měření, abych získal komplexní přehled o této problematice.

Nejprve jsem se věnoval teoretickým základům pozornosti, včetně její definice a významu v kontextu řízení vozidla. Prozkoumal jsem různé faktory ovlivňující pozornost řidiče, jako jsou fyzická únava, kognitivní zatížení a intoxikace. Dále jsem se zaměřil na způsoby měření pozornosti, kde jsem analyzoval několik přístupů, EEG, analýzy stylu jízdy, a použití kamerových systémů pro sledování pohybů očí a hlavy.

Ze získaných metod jsem vybral metodu zaměřenou primárně na sledování očí a pohybu hlavy, kterou jsem považoval za nejefektivnější pro praktické použití v reálném čase. Tato metoda využívá kamerové systémy umístěné v interiéru vozidla, které monitorují pohyby očí a hlavy řidiče, což umožňuje detekovat vizuální nepozornost. Výhodou tohoto přístupu je jeho neinvazivnost a schopnost poskytovat přesná data o směru pohledu a poloze hlavy řidiče.

Jako inovaci jsem navrhl kombinovat tuto metodu s možnostmi, které poskytuje platforma Inteligentního auta. Tímto způsobem lze využít informace ze senzorů přímo zabudovaných ve vozidle, se kterými při řídič skutečně interaguje, a tím získat komplexnější pohled na jeho pozornost. Výsledkem je systém, který je schopen detekovat vizuální nepozornost řidiče a zároveň poskytovat informace o jeho interakci s vozidlem.

Další možnosti co tato metoda přináší je možnost využití informací o stavu vozu, jako je rychlost a podle různých informací lze sestavit i jízdní situaci, kterou řidič řeší. S pomocí těchto informací lze lépe nastavit parametry systému, aby reagoval na skutečné jízdní požadavky.

Metoda je založena na multizónovém systému, který požaduje po řidiči, aby kontroloval celý prostor kolem vozu. Systém kontroluje zda se řidič věnuje všem klíčovým oblastem, které jsou důležité pro bezpečnou jízdu. V případě, že systém detekuje, že řidič není dostatečně pozorný, vyvolá varování, které má za cíl upozornit řidiče na jeho nepozornost a zvýšit jeho pozornost. Pro reálné nasazení by bylo vhodné rozšířit varování i o vibrace volantu a zvukové signály.

V průběhu testování navrženého systému byly provedeny simulace různých jízdních scénářů, aby byla ověřena jeho schopnost efektivně detekovat nepozornost řidiče. Výsledky ukázaly, že systém je schopen rychle a přesně identifikovat vizuální nepozornost a zároveň poskytovat relevantní data o interakci řidiče s vozidlem. Tímto způsobem může systém pomoci řidiči udržet vysokou úroveň pozornosti a tím snížit riziko nehody.

Systém byl navržen s ohledem na omezení, které přináší prototypování v reálném prostředí. Příkladem je možnost redefinování zón z důvodu pohybu kamery, toto omezení by v sériové výrobě nebylo přítomné. Dalším limitem je kamera, jedná se o obyčejnou volně dostupnou webkameru. V reálném nasazení by bylo třeba použít kameru, která

zaručí kvalitní obraz za všech světelných podmínek. Další možností je specializace AI modelu pro detekci obličeje, a tím získat lepší chování systému v různých světelných podmínkách.

Celkově mě tato práce zaujala, protože jsem si vyzkoušel kompletní návrh systému od teoretického základu až po jeho implementaci a testování. Využil jsem znalosti ze studia a zároveň jsem se naučil nové dovednosti třeba v oblasti zpracování obrazu.

## Literatura

- [1] New rules to improve road safety and enable fully driverless vehicles in the EU. Accessed: 2023-05-18.
- [2] *Distracted driving*. <https://www.nhtsa.gov/risky-driving/distracted-driving>. Accessed: 2023-05-15.
- [3] European Commission. *Road Safety Thematic Report: Advanced Driver Assistance Systems (ADAS) and Their Impact on Road Safety*. 2021. [https://road-safety.transport.ec.europa.eu/system/files/2022-04/Road\\_Safety\\_Thematic\\_Report\\_ADAS\\_2021.pdf](https://road-safety.transport.ec.europa.eu/system/files/2022-04/Road_Safety_Thematic_Report_ADAS_2021.pdf). Accessed: 2023-05-15.
- [4] REGULATION (EU) 2019/2144 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL. Accessed: 2023-05-18.
- [5] Bc. Jiří Pinkava. *Implementace nových scénářů pro platformu inteligentního vozu, Diplomová práce ČVUT FEL*. 2023.
- [6] Alexey Kashevnik, Roman Shchedrin, Christian Kaiser a Alexander Stocker. Driver Distraction Detection Methods: A Literature Review and Framework. *IEEE Access*. 2021, 9 60063-60076. DOI 10.1109/ACCESS.2021.3073599.
- [7] You Qu, Hongyu Hu, Jiarui Liu, Zhengguang Zhang, Yechen Li a Xiaojun Ge. Driver state monitoring technology for conditionally automated vehicles: Review and future prospects. *IEEE Transactions on Instrumentation and Measurement*. 2023,
- [8] Guofa Li, Weiquan Yan, Shen Li, Xingda Qu, Wenbo Chu a Dongpu Cao. A temporal spatial deep learning approach for driver distraction detection based on EEG signals. *IEEE Transactions on Automation Science and Engineering*. 2021, 19 (4), 2665–2677.
- [9] Xin Zuo, Chi Zhang, Fengyu Cong, Jian Zhao a Timo Hamalainen. Driver distraction detection using bidirectional long short-term network based on multiscale entropy of EEG. *IEEE Transactions on Intelligent Transportation Systems*. 2022, 23 (10), 19309–19322.
- [10] Fridulv Sagberg, Selpi, Giulio Francesco Bianchi Piccinini a Johan Engstrom. A review of research on driving styles and road safety. *Human factors*. 2015, 57 (7), 1248–1275.
- [11] Letizia Marchegiani a Ingmar Posner. *Long-term driving behaviour modelling for driver identification*. In: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*. 2018. 913–919.
- [12] Li Li, Boxuan Zhong, Clayton Hutmacher Jr, Yulan Liang, William J Horrey a Xu Xu. Detection of driver manual distraction via image-based hand and ear recognition. *Accident Analysis & Prevention*. 2020, 137 105432.

- [13] Qunfang Xiong, Jun Lin, Wei Yue, Shiwang Liu, Yue Liu a Chi Ding. *A deep learning approach to driver distraction detection of using mobile phone*. In: *2019 IEEE Vehicle Power and Propulsion Conference (VPPC)*. 2019. 1–5.
- [14] Mohammed S Majdi, Sundaresh Ram, Jonathan T Gill a Jeffrey J Rodriguez. *Drive-net: Convolutional network for driver distraction detection*. In: *2018 IEEE Southwest Symposium on Image Analysis and Interpretation (SSIAI)*. 2018. 1–4.
- [15] Harry Zhang, Matthew RH Smith a Gerald J Witt. Identification of real-time diagnostic measures of visual distraction with an automatic eye-tracking system. *Human factors*. 2006, 48 (4), 805–821.
- [16] Yulan Liang a John D Lee. Combining cognitive and visual distraction: Less than the sum of its parts. *Accident Analysis & Prevention*. 2010, 42 (3), 881–890.
- [17] Arun Ulahannan, Paul Jennings, Luis Oliveira a Stewart Birrell. Designing an adaptive interface: Using eye tracking to classify how information usage changes over time in partially automated vehicles. *IEEE Access*. 2020, 8 16865–16875.
- [18] Sebastian Zepf, Javier Hernandez, Alexander Schmitt, Wolfgang Minker a Rosalind W Picard. Driver emotion recognition for intelligent vehicles: A survey. *ACM Computing Surveys (CSUR)*. 2020, 53 (3), 1–30.
- [19] Ashish Tawari a Mohan Manubhai Trivedi. Speech emotion analysis: Exploring the role of context. *IEEE Transactions on multimedia*. 2010, 12 (6), 502–509.
- [20] Jonathan Shi Khai Ooi, Siti Anom Ahmad, Yu Zheng Chong, Sawal Hamid Md Ali, Guangyi Ai a Hiroaki Wagatsuma. *Driver emotion recognition framework based on electrodermal activity measurements during simulated driving conditions*. In: *2016 IEEE EMBS conference on biomedical engineering and sciences (IECBES)*. 2016. 365–369.
- [21] Amir Benloucif, Anh-Tu Nguyen, Chouki Sentouh a Jean-Christophe Popieul. Co-operative trajectory planning for haptic shared control between driver and automation in highway driving. *IEEE Transactions on Industrial Electronics*. 2019, 66 (12), 9846–9857.
- [22] Christer Ahlstrom a Katja Kircher. *Review of real-time visual driver distraction detection algorithms*. In: *Proceedings of the 7th international conference on methods and techniques in behavioral research*. 2010. 1–4.
- [23] John D Lee, Kristie L Young a Michael A Regan. Defining driver distraction. *Driver distraction: Theory, effects, and mitigation*. 2008, 13 (4), 31–40.
- [24] Mélanie Née, Benjamin Contrand, Ludivine Orriols, Cédric Gil-Jardiné, Cédric Galéra a Emmanuel Lagarde. Road safety and distraction, results from a responsibility case-control study among a sample of road users interviewed at the emergency room. *Accident Analysis & Prevention*. 2019, 122 19–24. DOI <https://doi.org/10.1016/j.aap.2018.09.032>.
- [25] Katja Kircher a Christer Ahlstrom. Minimum required attention: A human-centered approach to driver inattention. *Human factors*. 2017, 59 (3), 471–484.
- [26] Martin Baumann, Josef Krems a Luisa K. Heinrich. *Automation, Situation Awareness and Mental Workload*. In: Andreas Riener, Myoungsoon Jeon a Ignacio Alvarez, eds. *User Experience Design in the Era of Automated Driving*. Cham: Springer International Publishing, 2022. 3 – 27. [https://doi.org/10.1007/978-3-030-77726-5\\_1](https://doi.org/10.1007/978-3-030-77726-5_1).

- [27] Paul M Salmon, Neville A Stanton a Kristie Lee Young. Situation awareness on the road: review, theoretical and methodological issues, and future directions. *Theoretical Issues in Ergonomics Science*. 2012, 13 (4), 472–492.
- [28] Peter A Hancock, Mustapha Mouloua a John W Senders. On the philosophical foundations of the distracted driver and driving distraction. *Driver distraction: Theory, effects, and mitigation*. 2009, 11–30.
- [29] Joel M Cooper, Ivana Vladisavljevic, Nathan Medeiros-Ward, Peter T Martin a David L Strayer. An investigation of driver distraction near the tipping point of traffic flow stability. *Human factors*. 2009, 51 (2), 261–268.
- [30] Oscar Oviedo-Trespalacios, Md Mazharul Haque, Mark King a Simon Washington. “Mate! I’m running 10 min late”: An investigation into the self-regulation of mobile phone tasks while driving. *Accident Analysis & Prevention*. 2019, 122 134–142.
- [31] Ruijia Feng, Guangyuan Zhang a Bo Cheng. *An on-board system for detecting driver drowsiness based on multi-sensor data fusion using Dempster-Shafer theory*. In: *2009 international conference on networking, sensing and control*. 2009. 897–902.
- [32] Jarek Krajewski, David Sommer, Udo Trutschel, Dave Edwards a Martin Golz. *Steering wheel behavior based estimation of fatigue*. In: *Driving assessment conference*. 2009.
- [33] Ali Moradi, Seyed Saeed Hashemi Nazari a Khaled Rahmani. Sleepiness and the risk of road traffic accidents: A systematic review and meta-analysis of previous studies. *Transportation research part F: traffic psychology and behaviour*. 2019, 65 620–629.
- [34] Timothy Roehrs, Eleni Burduvali, Alicia Bonahoom, Christopher Drake a Thomas Roth. Ethanol and sleep loss: a “dose” comparison of impairing effects. *Sleep*. 2003, 26 (8), 981–985.
- [35] *Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems*. 2018.
- [36] John Gaspar a Cher Carney. The effect of partial automation on driver attention: A naturalistic driving study. *Human factors*. 2019, 61 (8), 1261–1276.
- [37] Iuliia Kotseruba a John K Tsotsos. Attention for vision-based assistive and automated driving: A review of algorithms and datasets. *IEEE transactions on intelligent transportation systems*. 2022, 23 (11), 19907–19928.
- [38] Filippo Santoni de Sio, Giulio Mecacci, Simeon Calvert, Daniel Heikoop, Marjan Hagenzieker a Bart van Arem. Realising meaningful human control over automated driving systems: a multidisciplinary approach. *Minds and machines*. 2022, 1–25.
- [39] Simeon C Calvert, Daniel D Heikoop, Giulio Mecacci a Bart Van Arem. A human centric framework for the analysis of automated driving systems based on meaningful human control. *Theoretical issues in ergonomics science*. 2020, 21 (4), 478–506.
- [40] Christer Ahlstrom, George Georgoulas a Katja Kircher. Towards a context-dependent multi-buffer driver distraction detection algorithm. *IEEE transactions on intelligent transportation systems*. 2021, 23 (5), 4778–4790.
- [41] Neil A. Dodgson. *Variation and extrema of human interpupillary distance*. In: Mark T. Bolas, Andrew J. Woods, John O. Merritt a Stephen A. Benton, eds. *Stereoscopic Displays and Virtual Reality Systems XI*. SPIE, 2004. 36 – 46. <https://doi.org/10.1117/12.529999>.

- [42] *Eye gaze estimation using a webcam. 100 lines of code.*  
<https://medium.com/amit.aflalo2/eye-gaze-estimation-using-a-webcam-in-100-lines-of-code-570d4683fe23>. Accessed: 2023-04-06.
- [43] *Pose landmark detection guide.*  
[https://developers.google.com/mediapipe/solutions/vision/pose\\_landmarker](https://developers.google.com/mediapipe/solutions/vision/pose_landmarker). Accessed: 2023-04-26.
- [44] Bc. Jan Nejtek. *Framework pro sběr dat a řízení inteligentního vozu, Diplomová práce ČVUT FEL.* 2022.
- [45] Srinath Rangarajan. *CAN FD Gateway, Diplomová práce ČVUT FEL.* 2020.
- [46] *ARK-3520P.*  
[https://www.advantech.com/en/products/1-2jkd2d/ark-3520p/mod\\_6666bf1e-af4f-47b6-8006-1a0a89eb3c93](https://www.advantech.com/en/products/1-2jkd2d/ark-3520p/mod_6666bf1e-af4f-47b6-8006-1a0a89eb3c93). Accessed: 2023-05-23.
- [47] *Eternico Webcam ET201 Full HD.*  
<https://webkamery.heureka.cz/eternico-webcam-et201-full-hd/#specifikace/>. Accessed: 2023-05-23.
- [48] *Prusament PETG.*  
<https://prusament.com/cs/materials/prusament-petg/>. Accessed: 2023-04-05.
- [49] Ivan Grischenko Geng Yan. *Model Card MediaPipe Face Mesh V2.*  
<https://storage.googleapis.com/mediapipe-assets/Model%20Card%20MediaPipe%20Face%20Mesh%20V2.pdf>. Accessed: 2023-05-23.



# Příloha **A**

## Seznam použitých zkratk

ADAS	■	Advanced Driver Assistance Systems
CAN	■	Controller Area Network
ČVUT	■	České vysoké učení technické v Praze
FEL	■	Fakulta elektrotechnická ČVUT
HMI	■	Human Machine Interface
MiRA	■	Minimal Required Attention
NDRA	■	Non-driving Related Activity
NHTSA	■	Americký Národní úřad pro bezpečnost silničního provozu
PETG	■	Polyethylentereftalát modifikovaný glykolem
PLA	■	Kyselina polyléčná
SA	■	Situation Awareness



## **Příloha B**

### **Přiložené soubory**

V příloze jsou dvě komprimované složky. Jedna se zdrojovými kódy a druhá s modelem k nastavení.