



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ÚSTAV AUTOMOBILNÍHO A DOPRAVNÍHO INŽENÝRSTVÍ

INSTITUTE OF AUTOMOTIVE ENGINEERING

NEURONOVÉ SÍTĚ VYUŽITÉ V AUTONOMNÍCH VOZIDLECH

NEURAL NETWORKS USED IN AUTONOMOUS VEHICLES

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jan Ryšavý

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Pavel Kučera, Ph.D.

BRNO 2023

Zadání bakalářské práce

Ústav: Ústav automobilního a dopravního inženýrství
Student: **Jan Ryšavý**
Studijní program: Základy strojního inženýrství
Studijní obor: Základy strojního inženýrství
Vedoucí práce: **doc. Ing. Pavel Kučera, Ph.D.**
Akademický rok: 2022/23

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma bakalářské práce:

Neuronové sítě využité v autonomních vozidlech

Stručná charakteristika problematiky úkolu:

Vypracujte rešerši popisující využití neuronových sítí pro řízení autonomních vozidel.

Cíle bakalářské práce:

Neuronové sítě.

Autonomní vozidla.

Implementace do ECU a aplikace.

Seznam doporučené literatury:

DIETSCHKE, Karl-Heinz a Konrad REIF, 2022. Automotive Handbook. 11. Karlsruhe: Robert Bosch. ISBN 978-1-119-91190-6.

CHOLLET, François a Rudolf PECINOVSKÝ, 2019. Deep learning v jazyku Python: Knihovny Keras, Tensorflow. 1. Praha: Grada Publishing. Knihovna programátora (Grada). ISBN 978-80-247-3100-1.

TUČKOVÁ, Jana. Vybrané aplikace umělých neuronových sítí při zpracování signálů. 1. Praha: České vysoké učení technické v Praze, 2009. ISBN 978-80-01-04229-8.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2022/23

V Brně, dne

L. S.

prof. Ing. Josef Štětina, Ph.D.
ředitel ústavu

doc. Ing. Jiří Hlinka, Ph.D. děkan
fakulty

ABSTRAKT

Bakalářská práce se zabývá využitím neuronových sítí v autonomních vozidlech. První část práce představuje základní principy neuronových sítí a metody učení, které jsou využívány v autonomních vozidlech. Dále práce popisuje architekturu a funkce neuronových sítí. V druhé části práce jsou také popsány různé typy autonomních vozidel, jejich dělení a přehled senzorů, které autonomní vozidla využívají. Poslední část práce se zabývá implementací neuronových sítí do ECU pomocí programových jazyků a knihoven a dále aplikacemi, jako jsou například detekce objektů nebo rozpoznávání značek.

KLÍČOVÁ SLOVA

Neuronová síť, autonomní vozidlo, implementace, detekce objektů, hluboké učení

ABSTRACT

This bachelor thesis deals with the use of neural networks in autonomous vehicles. The first part of the thesis presents the basic principles of neural networks and learning methods that are used in autonomous vehicles. Then the thesis describes the architecture and functions of neural networks. The second part of the thesis also describes the different types of autonomous vehicles, their classifications and an overview of the sensors used by autonomous vehicles. The last part of the thesis deals with the implementation of neural networks in ECUs using programming languages and libraries, and applications such as object detection and marker recognition.

KEYWORDS

Neural network, autonomous vehicles, implementation, object detection, deep learning

BIBLIOGRAFICKÁ CITACE

RYŠAVÝ, Jan. *Neuronové sítě využité v autonomních vozidlech* [online]. Brno, 2023 [cit. 2023-05-26]. Dostupné také z: <https://www.vut.cz/studenti/zav-prace/detail/149140>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav automobilního a dopravního inženýrství. Vedoucí bakalářské práce PAVEL KUČERA.



ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že tato práce je mým původním dílem, zpracoval jsem ji samostatně pod vedením Pavla Kučery a s použitím informačních zdrojů uvedených v seznamu.

V Brně dne 26. května 2023

.....

Jan Ryšavý

PODĚKOVÁNÍ

Rád bych poděkoval svému vedoucímu doc. Ing. Pavlovi Kučerovi PhD. za vedení mé bakalářské práce, cenné rady a rychlou odezvu při komunikaci. Dále bych chtěl poděkovat své rodině a přátelům za podporu během studia.

OBSAH

| | |
|--|-----------|
| Úvod..... | 11 |
| 1 Neuronové sítě | 12 |
| 1.1 Umělá inteligence a učení neuronové sítě..... | 12 |
| 1.1.1 Umělá inteligence | 12 |
| 1.1.2 Strojové učení (Machine learning – ML)..... | 13 |
| 1.1.3 Hluboké učení (Deep learning – DL) | 13 |
| 1.2 Struktura neuronové sítě | 14 |
| 1.3 Aktivační funkce..... | 14 |
| 1.4 Vícevrstvé neuronové sítě | 17 |
| 1.5 Využití neuronových sítí | 17 |
| 1.6 Konvoluční neuronové sítě (CNN)..... | 18 |
| 1.6.1 Architektura CNN..... | 18 |
| 1.7 Rekurentní neuronové sítě (RNN)..... | 20 |
| 1.8 Metody hlubokého učení pro detekci objektů | 20 |
| 1.8.1 R-CNN | 20 |
| 1.8.2 Fast R-CNN..... | 21 |
| 1.8.3 Faster R-CNN..... | 21 |
| 1.8.4 SSD | 21 |
| 1.8.5 YOLO | 21 |
| 2 Autonomní vozidla | 23 |
| 2.1 Úrovně autonomního řízení..... | 23 |
| 2.1.1 Úrovně podle SAE | 24 |
| 2.2 Režimy autonomního řízení | 24 |
| 2.3 Fungování autonomních vozidel | 25 |
| 2.4 Historie autonomních vozidel..... | 26 |
| 2.5 Současnost autonomních vozidel..... | 27 |
| 2.6 Výhody a nevýhody autonomních vozidel..... | 27 |
| 2.6.1 Výhody..... | 27 |
| 2.6.2 Nevýhody | 28 |
| 2.7 Přehled senzorů a snímačů používaných v autonomních vozidlech..... | 28 |
| 2.7.1 Kamery..... | 29 |
| 2.7.2 Radar | 30 |
| 2.7.3 LiDAR..... | 30 |
| 2.7.4 Ultrazvukové senzory | 31 |
| 2.7.5 GPS | 32 |
| 2.7.6 IMU..... | 32 |
| 3 Implementace do ECU a aplikace..... | 33 |
| 3.1 Hardware pro autonomní vozidla | 34 |
| 3.1.1 DRIVE AGX Orin | 34 |
| 3.2 Software pro autonomní vozidla..... | 34 |
| 3.2.1 DRIVE OS..... | 35 |
| 3.2.2 DriveWORKS..... | 35 |
| 3.2.3 DRIVE AV | 35 |
| 3.3 Přehled programovacích jazyků a knihoven | 35 |

| | | |
|--|--|-----------|
| 3.3.1 | Python | 35 |
| 3.3.2 | C a C++ | 36 |
| 3.4 | Aplikace autonomních vozidel využívající neuronové sítě..... | 37 |
| 3.4.1 | Klasifikace dopravního značení..... | 37 |
| 3.4.2 | Detekce silničního značení..... | 38 |
| 3.4.3 | Parkování vozidla | 39 |
| 3.4.4 | Vidění vozidla | 40 |
| Závěr..... | | 42 |
| Použité informační zdroje..... | | 43 |
| Seznam použitých zkratk a symbolů | | 48 |

ÚVOD

V posledních letech se autonomní vozidla stávají stále větší realitou a představují přelomovou technologii v oblasti dopravy. Schopnost těchto vozidel samostatně navigovat a provádět složité řídicí úkoly bez lidského řidiče otevírá nové možnosti pro efektivní a bezpečnou dopravu. Jedním z klíčových faktorů umožňujících těmto vozidlům dosahovat takové úrovně autonomie jsou neuronové sítě.

Pokud jde o technologii automatizovaných vozidel, asi nejznámější společností je Tesla. Společnost Tesla se proslavila různými autonomními automobily, přičemž mezi nejznámější vozy Tesla patří například Model S a Model Y. Další známou firmou, která se zabývá autonomním řízením je společnost Google se svým projektem Waymo, jehož cílem je rozvoj technologie automobilů se samo navigačním systémem bez řidiče.

Neuronové sítě jsou matematické modely inspirované strukturou a fungováním lidského mozku. Tyto sítě jsou schopny zpracovávat velké množství dat a učit se z nich, což je zásadní vlastnost při využití v autonomních vozidlech. Díky své schopnosti automatického učení a adaptace jsou neuronové sítě schopny rozpoznávat vzorce a složité vztahy v datech a na základě těchto informací provádět rozhodnutí.

Tyto sítě se musí implementovat do elektronických řídicích jednotek (ECU), které fungují jako počítače autonomního vozidla. Proces implementování je velice složitý a k jeho vyřešení je potřeba znát mnoho informací v oblasti programování a automobilového průmyslu.

Cílem této bakalářské práce je prozkoumat a analyzovat využití neuronových sítí v autonomních vozidlech. Práce se zaměří na různé typy neuronových sítí, jako jsou konvoluční sítě, rekurentní sítě a jejich aplikace v různých aspektech autonomního řízení. Bude zkoumáno, jak neuronové sítě přispívají k detekci objektů, rozpoznávání dopravního značení a rozpoznávání překážek.

1 NEURONOVÉ SÍŤ

Neuronové síť, nebo také umělé neuronové síť jsou počítačové systémy, které jsou navrženy tak, aby napodobovaly lidský mozek. Síť vytváří rámec pro více algoritmů, které spolupracují na dosažení celkového cíle. Neuronové síť jsou v podstatě navrženy tak, aby přemýšlely mnoha způsoby, protože berou velký soubor dat a zpracovávají jej prostřednictvím různých procesů. I přes zdání nedávného vynálezu se původ neuronových sítí datuje až do roku 1943, kdy Warren S. McCulloch a Walter Pitts publikovali studii, která se zabývala funkcemi lidského mozku a jeho schopností vytvářet složité vzory pomocí propojených buněk, nazývaných neurony. Od té doby se tento výzkum stal základem pro mnoho dalších studií a postupně se neuronové síť zdokonalovaly a vylepšovaly. [1]

V poslední dekádě se neuronové síť rozšířily do všech oblastí a staly se téměř všudypřítomnými. Jejich potenciál je téměř neomezený. Podobně jako lidský mozek jsou schopny identifikovat a kategorizovat objekty ve svém okolí. Jsou využívány jako vyhledávací algoritmy, rozpoznávače řeči a obrazů a samozřejmě i v autonomních vozidlech. [2]

1.1 UMĚLÁ INTELIGENCE A UČENÍ NEURONOVÉ SÍŤ

V rámci neuronových sítí se často setkáváme s pojmy, které je důležité pochopit a lze je zjednodušeně vnímat jako vzájemně se prolínající kategorie (viz Obr. 1). Hluboké učení je jedním z typů strojového učení, které se zaměřuje především na využití neuronových sítí, zejména pokud jsou tyto síť složeny z několika vrstev.



Obrázek 1: Vztah mezi umělou inteligencí, strojovým a hlubokém učení a neuronovou sítí [18]

1.1.1 UMĚLÁ INTELIGENCE

Umělá inteligence, běžně označovaná jako AI (Artificial Intelligence), je proces předávání dat, informací a lidské inteligence strojům. Hlavním cílem umělé inteligence je vyvinout soběstačné stroje, které dokáží myslet a jednat jako lidé. Tyto stroje mohou napodobovat lidské chování a plnit úkoly pomocí učení a řešení problémů. Většina systémů umělé inteligence simuluje přirozenou inteligenci a řeší složité problémy. [3]

1.1.2 STROJOVÉ UČENÍ (MACHINE LEARNING – ML)

Strojové učení se skládá z různých typů modelů strojového učení, které využívají různé algoritmické techniky. V závislosti na povaze dat a požadovaném výsledku lze použít jeden ze čtyř modelů učení: s učitelem, bez učitele, s částečným učitelem nebo s posilováním. V rámci každého z těchto modelů lze použít jednu nebo více algoritmických technik - v závislosti na použitých souborech dat a zamýšlených výsledcích. Algoritmy strojového učení jsou v zásadě určeny ke klasifikaci věcí, hledání vzorů, předpovídání výsledků a přijímání informovaných rozhodnutí. Algoritmy lze používat po jednom nebo je kombinovat, aby se dosáhlo co největší přesnosti, pokud se jedná o složitá a nepředvídatelnější data. [4]

UČENÍ S UČITELEM (SUPERVISED LEARNING)

Strojové učení s učitelem je postaveno na jasně definovaných vstupních a výstupních parametrech, kde učitel nebo vědec identifikuje konkrétní objekt a ukazuje, jak s ním pracovat. Výstup je poté porovnán s očekávaným výstupem. Tento přístup využívá rozsáhlé datové sady, které často obsahují různé varianty objektu, aby stroj dokázal samostatně rozpoznat a provést příslušnou akci. Při použití tohoto přístupu strojové učení upravuje existující informace na základě stanovených parametrů, ale omezuje se pouze na to, co bylo předem definováno. Pokud se setká s novými daty, není schopen provést činnosti, které nebyly předem naučeny. [4]

UČENÍ BEZ UČITELE (UNSUPERVISED LEARNING)

Algoritmus v metodě strojového učení bez učitele určuje postup, řešení a výsledek pomocí pokusu a omylu na základě vstupních dat, aniž by potřeboval explicitní návody od učitele. Tato metoda hledá podobnosti a spojitosti mezi objekty a přiřazuje jim vlastní označení. [4]

Vstupní data nemají předem známý výstup a není jasné, zda daná úloha má řešení, zda je objekt známý nebo zda spadá do existující skupiny. Stejně tak není známo, zda existují vzájemné vztahy mezi proměnnými, které charakterizují daný případ nebo situaci. Tento přístup je často využíván v různých automatizovaných zařízeních, která vyžadují rychlou reakci na nepředvídatelné situace. [3]

UČENÍ S ČÁSTEČNÝM UČITELEM (SEMI-SUPERVISED LEARNING)

Výrazně často se využívá kombinace obou přístupů pomocí metody nazývané semi-supervised learning. V této metodě je k dispozici část vstupních dat s předem známým výstupem, zatímco další data nemají známý výstup. Analytické algoritmy jsou "trénovány" na trénovacích datech, která obsahují známé výstupy. [3]

UČENÍ S POSILOVÁNÍM (REINFORCEMENT LEARNING)

Zpětnovazební učení používá algoritmy, které se učí z výsledků a rozhodují, jakou akci provést příště. Po každé akci algoritmus obdrží zpětnou vazbu, která pomůže určit, zda byla zvolená volba správná, neutrální, nebo nesprávná. Jedná se o dobrou techniku k použití pro automatizované systémy, které musí dělat velká množství malých rozhodnutí bez lidského vedení. [3]

1.1.3 HLUBOKÉ UČENÍ (DEEP LEARNING – DL)


Hluboké učení je podmnožinou strojového učení, která se zabývá algoritmy inspirovanými strukturou a funkcí lidského mozku. Algoritmy hlubokého učení mohou pracovat s obrovským množstvím strukturovaných i nestrukturovaných dat. Základní koncept hlubokého učení

spočívá v umělých neuronových sítích, které umožňují strojům činit rozhodnutí. Hlavní rozdíl mezi hlubokým učením a strojovým učením spočívá ve způsobu, jakým jsou data stroji předkládána. Algoritmy strojového učení obvykle vyžadují strukturovaná data, zatímco síť hlubokého učení pracuje s více vrstvami umělých neuronových sítí. [3]

1.2 STRUKTURA NEURONOVÉ SÍŤE

Přestože nervová soustava člověka je stále předmětem zkoumání, základní neurofyzilogické principy jsou dostatečné pro formulaci matematického modelu neuronové sítě. Neuron, který je základním stavebním funkčním prvkem nervové soustavy, je samostatnou specializovanou buňkou určenou k přenosu, zpracování a uchování informací nezbytných pro životní funkce organismu. [5]

Matematický model neuronové sítě je založen na umělém neuronu. Obecně formální neuron Y disponuje n reálnými vstupy, což odpovídá dendritům, a určuje se pomocí vstupního vektoru $x = (x_1, \dots, x_n)$, kde každý vstup je ohodnocen reálnou synaptickou vahou, tvořící vektor $w = (w_1, \dots, w_n)$. [5]



Obrázek 2: Matematický neuron se vstupy a váhami [5]


Výstupní hodnota neuronu prochází transformací aktivačními funkcemi. Tyto aktivační funkce neboli přenosové funkce aplikuje transformaci na vážená vstupní data (maticové násobení mezi vstupními daty a váhami). Funkce může být lineární nebo nelineární. Jednotka se od přenosových funkcí liší zvýšenou mírou složitosti. Jednotka může mít více přenosových funkcí nebo složitější strukturu. [6]

1.3 AKTIVAČNÍ FUNKCE

Aktivační funkce se používají speciálně v umělých neuronových systémech, k transformaci vstupního signálu na výstupní signál, který je následně přiveden jako vstup do další vrstvy v zásobníku. V umělé neuronové síti počítáme součet hodnot součinů vstupů a jim odpovídajících vah a nakonec použijeme aktivační funkci, abychom získali výstupní hodnotu této konkrétní vrstvy, a dodáme ji jako vstup do další vrstvy. [7]

SKOKOVÁ (BINÁRNÍ) FUNKCE

Skoková funkce, která je nespojitá a binární, závisí na prahové hodnotě, která rozhoduje o tom, zda má být neuron aktivován, či nikoli. Vstup přiváděný do aktivační funkce se porovnává s určitou prahovou hodnotou; pokud je vstup větší než 0 a menší než 1 (v tomto případě), neuron je aktivován, jinak je deaktivován, což znamená, že jeho výstup není předán do další skryté vrstvy. [7]




Obrázek 3: Skoková (binární) aktivační funkce [5]

Matematicky lze vyjádřit:

$$f(x) = \begin{cases} 0 & \text{když } x < 0 \\ 1 & \text{když } x \geq 0 \end{cases} \quad (1)$$

REKTIFIKOVANÁ LINEÁRNÍ FUNKCE (RELU - RECTIFIED LINEAR UNIT)

Ačkoli ReLU působí dojmem lineární funkce, má derivační funkci a umožňuje zpětné šíření a zároveň je výpočetně efektivní. Hlavní háček spočívá v tom, že funkce ReLU neaktivuje všechny neurony současně. Neurony se deaktivují pouze v případě, že výstup lineární transformace je menší než 0. [7]




Obrázek 4: Rektifikovaná lineární aktivační funkce [5]

Matematicky lze vyjádřit:

$$f(x) = \max(0, x) \quad (2)$$

SIGMOID (LOGISTICKÁ) FUNKCE

Tato funkce přijímá na vstupu libovolnou reálnou hodnotu a na výstupu má hodnoty v rozsahu 0 až 1. Čím větší je vstup (kladnější), tím blíže bude výstupní hodnota k 1, zatímco čím menší je vstup (zápornější), tím blíže bude výstup k 0, jak je znázorněno níže. [7]




Obrázek 5: Sigmoid (logistická) aktivační funkce [5]

Matematicky lze vyjádřit:

$$f(x) = \frac{1}{1+e^{-x}} \quad (3)$$

HYPERBOLICKÝ TANGENS

Tato funkce je velmi podobná logistické aktivační funkci a má dokonce stejný tvar písmene S, s rozdílem ve výstupním rozsahu -1 až 1. U této funkce platí, že čím větší vstup (kladnější), tím blíže bude výstupní hodnota k hodnotě 1, zatímco čím menší vstup (zápornější), tím blíže bude výstup k hodnotě -1. [7]




Obrázek 6: Aktivační funkce hyperbolický tangens [5]

Matematicky lze vyjádřit:

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (4)$$

1.4 VÍCEVRSTVÉ NEURONOVÉ SÍŤE

Neuronové sítě využívají vrstvy jako stavební prvky, přičemž vstupní, skrytá a výstupní vrstva se nacházejí na počátku, uprostřed a na konci sítě, resp. skrytá vrstva je pojmenována podle toho, že její výstup není přímo viditelný, ale slouží jako vstup pro další vrstvy sítě. Třívrstvá síť obsahuje jednu skrytou vrstvu, zatímco v hlubokých neuronových sítích se nachází více skrytých vrstev. Každá vrstva se skládá z uzlů propojených s uzly v další vrstvě prostřednictvím spojení s váhami, které jsou upravovány pomocí optimalizačních algoritmů, aby se minimalizovala nákladová funkce, což je míra rozdílu mezi očekávaným a skutečným výstupem neuronové sítě. Optimalizace se provádí pomocí algoritmů jako stochastický gradientní sestup, který využívá statistickou aproximaci optimální změny gradientu. Rychlost učení, tj. rychlost změny vah ve směru gradientu, ovlivňuje spolehlivost tréninku neuronové sítě a její schopnost konvergovat k optimálnímu řešení. Vrstva v neuronové síti je obvykle uniformní a obsahuje pouze jeden typ aktivační funkce, aby bylo možné ji snadno porovnat s ostatními vrstvami sítě. [6]



Obrázek 7: Uspořádání neuronů do vrstev [20]

Moderní neuronové sítě mohou obsahovat až více než jednu miliardu parametrů, které lze upravovat pomocí zpětného šíření, a pro dosažení vysoké přesnosti vyžadují velké množství trénovacích dat. Kvůli paralelní povaze neuronových sítí jsou grafické procesory přirozenou volbou pro jejich trénování, což umožňuje výrazné zrychlení výpočtů, oproti trénování na CPU (centrální procesorová jednotka - central processing unit). Společnost NVIDIA nabízí knihovnu primitiv cuDNN (CUDA deep neural network), která usnadňuje dosažení špičkového výkonu s hlubokými neuronovými sítěmi, a akcelerátor inferenční platformy a runtime TensorRT, který umožňuje inferenci s nízkou latencí a vysokou propustností na různých GPU (grafický procesor - graphics processing unit). S rostoucím významem neuronových sítí v průmyslu i na akademické půdě se GPU staly preferovanou platformou pro trénování velkých a složitých systémů založených na těchto sítích. [6]

1.5 VYUŽITÍ NEURONOVÝCH SÍTÍ

Neuronové sítě jsou využívány napříč různými odvětvími, díky rozšíření strojového učení. Tyto sítě umožňují klasifikaci informací, logické seskupování dat a předpovídání výsledků na základě dostupných dat. V oblasti financí jsou neuronové sítě navrženy tak, aby se vypořádaly s vysokým objemem informací a s vysokou přesností je třídily. Google používá neuronové sítě s hloubkou 30 vrstev pro zlepšení výsledků vyhledávání. Neuronové sítě jsou také hojně využívány při vývoji autonomních vozidel, jejichž úspěch a bezpečnost závisí na analytických a prediktivních schopnostech. Hluboké neuronové sítě (DNN) jsou v každém autonomním

vozidle klíčové, protože shromažďují vstupní data ze senzorů, zpracovávají je a následně vytvářejí správné chování vozidla. Tato data jsou shromažďována skupinou vozidel vybavených mnoha senzory, které denně jezdí několik hodin a generují velké množství dat. Tato data musí být následně anotována a zpracována pro komplexní vývoj, testování a ověřování. [8]

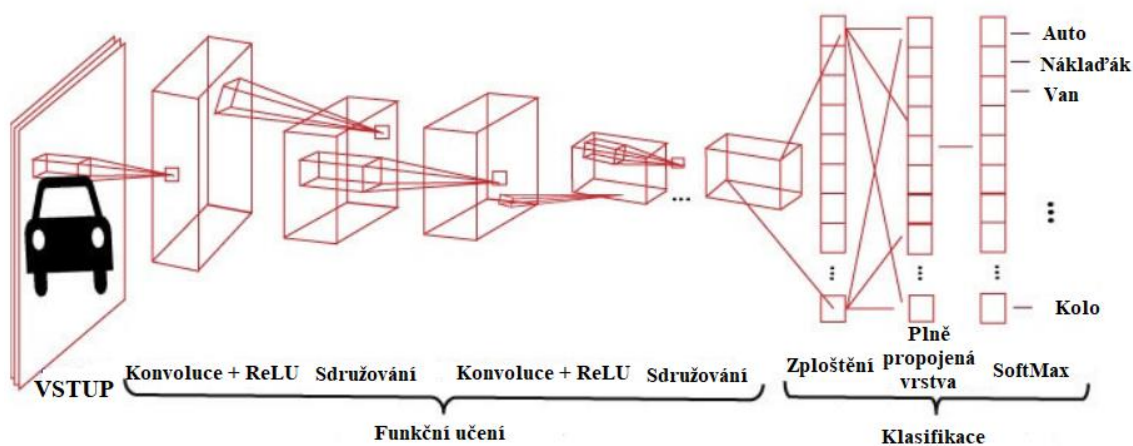
V automobilovém průmyslu se používají dva hlavní typy neuronových sítí: Konvoluční neuronové sítě a rekurentní neuronové sítě. [9]

1.6 KONVOLUČNÍ NEURONOVÉ SÍŤE (CNN)

Konvoluční neuronové sítě se používají k modelování prostorových informací, například obrázků. CNN jsou velmi dobré při extrakci funkcí z obrázků a často jsou považovány za univerzální nelineární aproximátory funkcí. S rostoucí hloubkou sítě mohou CNN zachycovat různé vzory. Například vrstvy na začátku sítě budou zachycovat hrany, zatímco hluboké vrstvy budou zachycovat složitější rysy, jako je tvar objektů (pneumatiky na vozidle). To je důvod, proč jsou sítě CNN hlavním algoritmem v autonomních automobilech. [10]

1.6.1 ARCHITEKTURA CNN

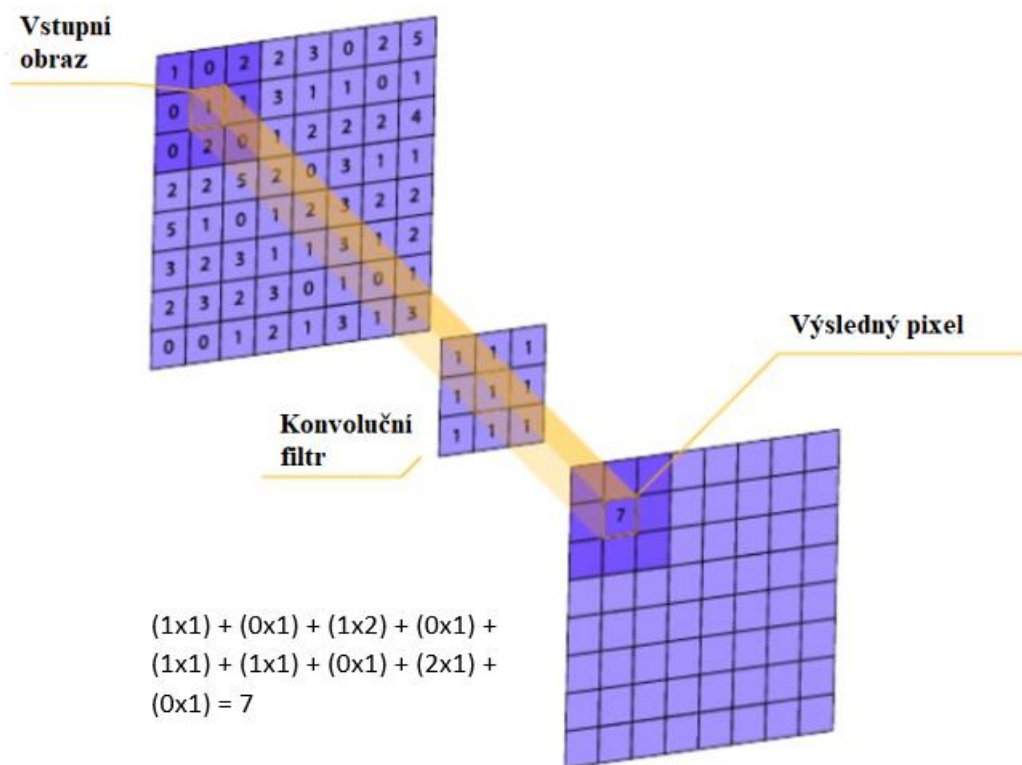
CNN se skládá ze tří typů vrstev: konvolučních vrstev, sdružených vrstev a plně propojených vrstev. Když se tyto vrstvy poskládají na sebe, vznikne architektura CNN. Kromě těchto tří vrstev existují ještě dva důležité parametry, kterými jsou dropout vrstva a aktivační funkce. [10]



Obrázek 8: Architektura konvoluční neuronové sítě [22]

KONVOLUČNÍ VRSTVA


Tato vrstva je první vrstvou, která se používá k extrakci různých rysů ze vstupních obrázků. V této vrstvě se provádí matematická operace konvoluce mezi vstupním obrazem a filtrem určité velikosti (většinou 3x3, nebo 5x5). Posunutím filtru po vstupním obrazu se provede bodový součin mezi filtrem a částmi vstupního obrazu vzhledem k velikosti filtru (3x3). Výstup se označuje jako mapa vlastností (feature map), která nám poskytuje informace o obrázku, jako jsou rohy a hrany. Později se tato mapa rysů přivádí do dalších vrstev, aby se naučila několik dalších rysů vstupního obrazu. Konvoluční vrstva v CNN předává výsledek další vrstvě po použití operace konvoluce na vstupu. Konvoluční vrstvy v CNN jsou velmi přínosné, protože zajišťují zachování prostorového vztahu mezi pixely. [10]



Obrázek 9: Konvoluce vstupního obrazu pomocí konvolučního filtru [24]

SDRUŽOVACÍ (POOLING) VRSTVA

Ve většině případů po konvoluční vrstvě následuje pooling vrstva. Hlavním cílem této vrstvy je zmenšit velikost konvolvované mapy prvků, aby se snížily výpočetní náklady. To se provádí zmenšením spojení mezi vrstvami a nezávisle pracuje s každou mapou prvků. V závislosti na použité metodě existuje několik typů operací Pooling. V podstatě shrnuje rysy generované konvoluční vrstvou. Při Max Pooling se z mapy prvků vybere největší prvek. Average Pooling počítá průměr prvků v předem definované velikosti výseku obrazu. Pooling vrstva obvykle slouží jako most mezi konvoluční vrstvou a plně propojenou vrstvou. Tento model CNN zobecňuje prvky extrahované konvoluční vrstvou a pomáhá sítím rozpoznávat prvky samostatně. S jeho pomocí se v síti také snižuje počet výpočtů. [10]



Obrázek 10: Operace sdrůžování [26]

PLNĚ PROPOJENÁ VRSTVA (FULLY CONNECTED LAYER – FC)

Plně propojená vrstva se skládá z vah a posunů spolu s neurony a slouží k propojení neuronů mezi dvěma různými vrstvami. Tyto vrstvy jsou obvykle umístěny před výstupní vrstvou a tvoří několik posledních vrstev architektury CNN. V ní se vstupní obraz z předchozích vrstev zploští a přivede do vrstvy FC. Zploštělý vektor pak prochází několika dalšími vrstvami FC, kde obvykle probíhají operace s matematickými funkcemi. V této fázi začíná proces klasifikace. Důvodem zapojení dvou vrstev je to, že dvě plně zapojené vrstvy budou mít lepší výkon než jedna zapojená vrstva. [10]

DROPOUT VRSTVA

Jedna z charakteristických vlastností CNN je použití Dropout vrstvy, která slouží k prevenci přeučení sítě. Tato vrstva náhodně vypíná některé neurony a tím omezuje jejich příspěvek k dalším vrstvám, zatímco ostatní neurony ponechává beze změny. Dropout lze aplikovat na vstupní vektor, což může znehodnotit některé jeho vlastnosti, nebo na skrytou vrstvu, kde ovlivňuje některé skryté neurony. Použití Dropout vrstev během trénování CNN je důležité, protože předchází přizpůsobení sítě tréninkovým datům. Pokud nejsou použity, první tréninková dávka může vést k neúměrně vysokému učení. [11]

1.7 REKURENTNÍ NEURONOVÉ SÍŤE (RNN)

Rekurentní neuronové sítě jsou speciálním typem neuronových sítí, které jsou navrženy pro zpracování sekvencí dat, jako jsou řetězce, časové řady nebo věty. Oproti standardním neuronovým sítím jsou RNN schopny uchovávat stav nebo kontext mezi jednotlivými vstupy v sekvenci, což umožňuje modelovat závislosti a vztahy mezi jednotlivými částmi sekvence. Pokud jde o automobily, v autonomních vozidlech se RNN používají ke sledování pohybujícího se objektu a určování potenciálních kolizí. V průběhu času se RNN stanou schopnými předvídat nejpravděpodobnější cestu pohybujícího se objektu, například chodce blížícího se k přechodu, a učinit inteligentní rozhodnutí o tom, co by vozidlo mělo udělat, aby se vyhnulo možné nebezpečné situaci. [12]

1.8 METODY HLUBOKÉHO UČENÍ PRO DETEKCI OBJEKTŮ

Detekce objektu se skládá ze dvou dílčích úkolů: lokalizace, která zahrnuje určení polohy objektu v prostoru (nebo snímku videa) a klasifikace, která zahrnuje přiřazení třídy (např. "chodec", "vozidlo", "světelná signalizace") tohoto objektu. [13]

Každý objekt má určité vlastnosti. Tyto vlastnosti určují třídu objektu. Běžně známé metody hlubokého učení řeší problém detekce objektů extrakcí rysů objektu, který se nazývá mapa rysů. V této části jsou vysvětleny algoritmy detekce objektů založené na CNN. [14]

1.8.1 R-CNN

Při zadání vstupního obrázku začíná R-CNN (region-based convolutional neural network) použitím mechanismu zvaného selektivní vyhledávání pro extrakci oblastí zájmu. V závislosti na scénáři může existovat až dva tisíce návrhů oblastí. Těchto 2000 návrhů kandidátních oblastí je deformováno do čtverce a vloženo do konvoluční neuronové sítě, která na výstupu vytvoří 4096tirozměrný vektor příznaků. CNN funguje jako extraktor příznaků a výstupní hustá vrstva se skládá z příznaků extrahovaných z obrazu a extrahované příznaky jsou přivedeny do SVM (Support vector machines), aby klasifikovaly přítomnost objektu v daném návrhu kandidátské oblasti. [15]

1.8.2 FAST R-CNN

Nedostatky R-CNN byly vyřešeny ve Fast R-CNN. Na rozdíl od R-CNN, kde bylo do CNN vloženo 2000 návrhů oblastí, byl v rychlém R-CNN celý obraz s oblastí zájmu (RoI – Region of Interest) vložen do mnoha konvolučních a sdružovacích vrstev pro vytvoření mapy rysů. Poté byl pro každý návrh oblasti z mapy příznaků extrahován vektor příznaků pevné délky pomocí vrstvy sdružování ROI. Nakonec plně propojená vrstva zpracuje každý vektor příznaků a vytvoří dvě vrstvy jako výstupní větve. V jedné větvi vrstva softmax předpovídá třídu objektu. Druhá větev generuje čtyři čísla souřadnic pro každou třídu objektů. Tato čísla odhadují ohraničující rámeček pro každou třídu objektů. [14]

1.8.3 FASTER R-CNN

Oba výše uvedené algoritmy (R-CNN a Fast R-CNN) používají k nalezení návrhů oblastí selektivní vyhledávání. Selektivní vyhledávání je pomalý a časově náročný proces, který ovlivňuje výkonost sítě. [15]

Podobně jako v případě Fast R-CNN je obraz poskytnut jako vstup konvoluční síti, která poskytuje konvoluční mapu příznaků. Namísto použití algoritmu selektivního vyhledávání na mapě příznaků k identifikaci návrhů oblastí se k předvídání návrhů oblastí používá samostatná síť. Předpovězené návrhy oblastí jsou poté přetvořeny pomocí vrstvy RoI pooling, která je poté použita ke klasifikaci obrazu v rámci navržené oblasti a k předpovědi hodnot posunu pro ohraničující rámečky. [15]

1.8.4 SSD

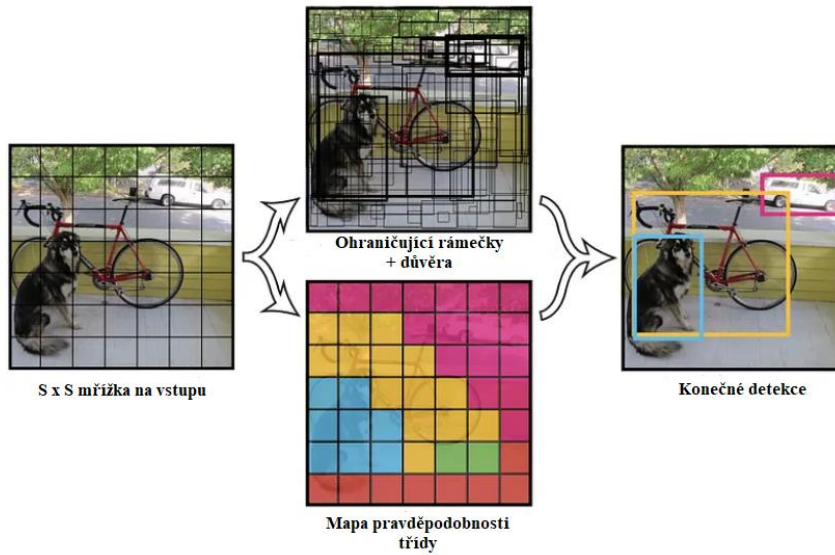
Neuronová síť SSD (single-shot detector) je určena k detekci objektů v reálném čase. Faster R-CNN používá síť návrhu regionu k vytvoření hraničních polí a využívá tato pole ke klasifikaci objektů. Ačkoli je považována za špičku v přesnosti, celý proces běží rychlostí 7 snímků za sekundu. To je mnohem méně, než kolik potřebuje zpracování v reálném čase. SSD urychluje proces tím, že eliminuje potřebu sítě návrhu regionů. Aby se obnovil pokles přesnosti, SSD používá několik vylepšení, včetně více měřítkových prvků a výchozích rámečků. Tato vylepšení umožňují SSD vyrovnat se přesnosti Faster R-CNN při použití snímků s nižším rozlišením, což dále zvyšuje rychlost. Podle následujícího srovnání dosahuje rychlosti zpracování v reálném čase a dokonce překonává přesnost Faster R-CNN. [16]

1.8.5 YOLO

Síť neprohlíží celý obraz. Namísto toho se zaměřuje na části obrazu, u nichž je vysoká pravděpodobnost, že obsahují objekt. YOLO (You Only Look Once) je algoritmus detekce objektů, který se značně liší od výše uvedených algoritmů založených na regionech. V YOLO předpovídá jediná konvoluční síť ohraničující rámečky a pravděpodobnosti tříd pro tyto rámečky. [15]

YOLO funguje tak, že vezmeme obrázek a rozdělíme jej na mřížku $S \times S$, v rámci každé mřížky vezmeme m ohraničujících rámečků. Pro každý z ohraničujících rámečků síť vypočítá pravděpodobnost třídy a hodnoty posunu pro daný ohraničující rámeček. Ohraničující rámečky, jejichž pravděpodobnost třídy je vyšší než prahová hodnota, jsou vybrány a použity k lokalizaci objektu v rámci obrazu. [15]

YOLO je řádově rychlejší (45 snímků za sekundu) než jiné algoritmy detekce objektů. Omezení algoritmu YOLO spočívá v tom, že má problémy s malými objekty v obraze, například může mít potíže s detekcí hejna ptáků. To je způsobeno prostorovými omezeními algoritmu. [15]



Obrázek 11: Metoda YOLO [14]

2 AUTONOMNÍ VOZIDLA

Autonomní automobil je vozidlo, které je schopné vnímat své okolí a fungovat bez zásahu člověka, a to díky schopnosti vnímat své okolí. Lidský pasažér nemusí v žádném okamžiku převzít kontrolu nad vozidlem, ani nemusí být ve vozidle vůbec přítomen. Autonomní vůz může jet kamkoli, kam jede tradiční vůz, a využívá plně automatizovaný systém řízení, aby vozidlo mohlo reagovat na vnější podmínky, které by zvládl lidský řidič. [17, 19]



Obrázek 12: Autonomní vozidlo [30]

2.1 ÚROVNĚ AUTONOMNÍHO ŘÍZENÍ

Pro stanovení dohodnutých standardů na počátku přechodu k autonomním vozidlům vyvinula Society of Automotive Engineers (SAE) klasifikační systém, který definuje stupeň automatizace řízení, který může vozidlo a jeho vybavení nabízet. Spektrum automatizace jízdy, které se pohybuje od nultého do pátého stupně, začíná u vozidel bez této technologie a končí u zcela samořídících vozidel. [21]



Obrázek 13: Úrovně automatizace podle SAE [33]

2.1.1 ÚROVNĚ PODLE SAE

SAE od roku 2016 definuje 6 úrovní automatizace řízení od úrovně 0 (plně manuální) po úroveň 5 (plně autonomní). Tyto úrovně byly přijaty americkým ministerstvem dopravy. [21]

ÚROVEŇ 0 – ŽÁDNÁ AUTOMATIZACE

Úroveň 0 se spoléhá výhradně na řidiče, který vykonává všechny podélné a příčné funkce, jako je zrychlování a řízení, jak naznačuje název. Řízení je zcela pod kontrolou řidiče a na jeho odpovědnost. [21]

ÚROVEŇ 1 – ASISTENCE ŘIDIČE

Na této úrovni vozidlo řídí nebo zasahuje pouze do řízení nebo rychlosti vozidla, ale ne do obou současně. Řidič se sice nemůže vzdát kontroly nad vozidlem, ale technologie úrovně 1 mu může pomáhat při některých úkonech řízení. [21]

ÚROVEŇ 2 – ČÁSTEČNÁ AUTOMATIZACE

Při přechodu na úroveň 2 se o řízení dělí vozidlo a řidič. Dvě základní funkce řízení, příčné a podélné, často přebírá vozidlo. Toho lze dosáhnout například integrací adaptivního tempomatu s udržováním jízdního pruhu. V tomto případě může řidič na krátkou dobu sundat ruce z volantu. Řidič si však musí udržovat neustálý přehled o situaci a sledovat okolí. [21]

ÚROVEŇ 3 – PODMÍNĚNÁ AUTOMATIZACE

Na úrovni 3 může vozidlo zrychlovat kolem pomalu jedoucího vozidla, sledovat okolí, měnit jízdní pruhy a ovládat řízení, plyn a brzdění. Řidič musí jen dávat pozor a být připraven převzít zpět kontrolu, když ho o to vozidlo požádá. [21]

ÚROVEŇ 4 – VYSOKÁ AUTOMATIZACE

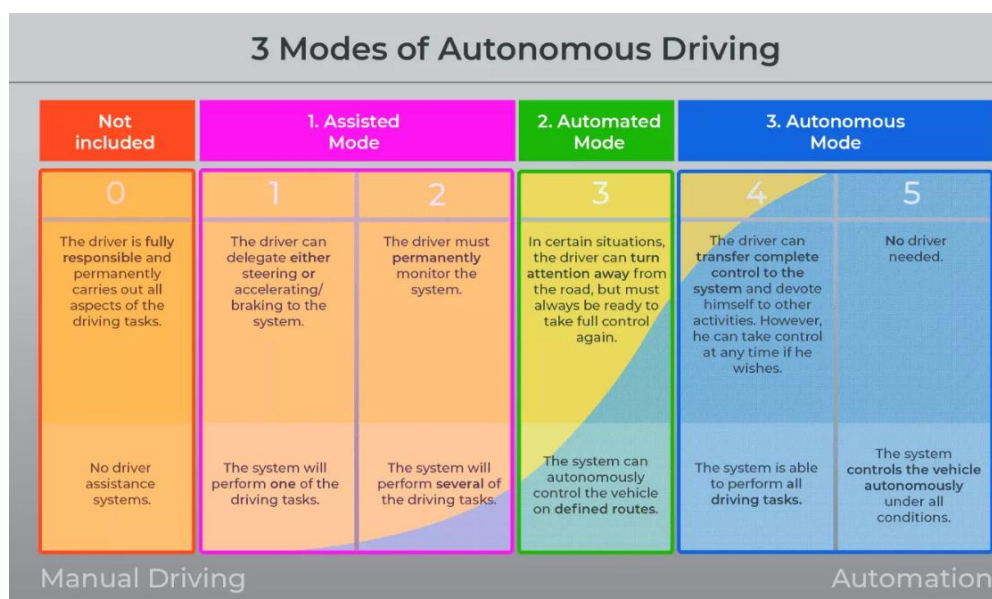
Dalším krokem po počáteční automatizaci určitých jízdních situací je automatizace všech jízdních situací, tj. plně automatizovaná jízda na úrovni 4, kdy vozidlo řídí kompletní jízdy na dálnici i v městském provozu převážně samostatně. Řidič se může po delší dobu věnovat i jiným činnostem, například práci, zabavení dětí na zadním sedadle nebo dokonce spánku. [21]

ÚROVEŇ 5 – ÚPLNÁ AUTOMATIZACE

Autonomie úrovně 5 nezahrnuje žádný lidský zásah. V tomto vozidle není potřeba volant, brzdy ani pedály. Veškeré jízdní úkony, včetně sledování prostředí a detekce komplikovaných jízdních podmínek, jako jsou například rušné přechody pro chodce, jsou za všech podmínek řízeny autonomním vozidlem. To také znamená, že vozidlo zvládne všechny dopravní situace na všech silnicích. [21]

2.2 REŽIMY AUTONOMNÍHO ŘÍZENÍ

Dlouhou dobu byl standard SAE 5 úrovní autonomního řízení normou. Přestože jsou tyto úrovně velmi propracované a komplexní, je stále důležité se ptát, zda má rozlišování mezi nimi smysl. Aby se diskuse o technologii autonomního řízení zpřehlednila, představil nedávno německý Spolkový ústav pro výzkum dálnic (Bundesanstalt für Straßenwesen oder BASt) alternativu. Navrhli přejít z pěti úrovní na tři režimy, což by pomohlo zjednodušit diskusi kolem autonomních vozidel. [23]



Obrázek 14: Režimy autonomního řízení podle BAST [36]

První režim kombinuje úrovně SAE 1 a 2 "asistovaného režimu", kdy je řidič podporován vozidlem, ale musí zůstat neustále ve střehu a připraven zasáhnout. [23]

Druhý režim by zahrnoval úroveň 3 podle SAE a nazýval by se "automatizovaný režim". Řidič dočasně předá volant počítači a může po delší dobu vykonávat jiné činnosti. [23]

V neposlední řadě "autonomní režim" kombinuje úrovně SAE 4 a 5, a jak je znázorněno na výše uvedeném grafu, dává vozidlu úplnou pravomoc řídit. [23]

Zajímavé je, že s úrovní 0 se v nové terminologii neuvažuje a tato úroveň popisuje plně analogovou jízdu bez jakéhokoli doprovodného asistenčního systému. [23]


Nové označení BAST je vítanou změnou, neboť slibuje zjednodušení terminologie při zachování kompatibility se systémem SAE. To znamená, že úrovně autonomního řízení podle SAE mohou být nadále používány v odbornějších a technických kruzích. Zároveň lze pomocí těchto vyšších režimů snadno vést obecnou konverzaci a politické diskuse. [23]

2.3 FUNGOVÁNÍ AUTONOMNÍCH VOZIDEL

Rozhodující krok k vyšším úrovním autonomního řízení je do značné míry podmíněn rozvojem technologie vnímání, tj. sensorové techniky. Autonomní automobily využívají k provádění softwaru senzory, akční členy, složité algoritmy, systémy strojového učení a výkonné procesory. Autonomní vozidla vytvářejí a udržují mapu svého okolí na základě různých senzorů umístěných v různých částech vozidla. Radarové senzory sledují polohu okolních vozidel. Videokamery detekují světelnou signalizaci, čtou dopravní značky, sledují ostatní vozidla a hledají chodce. Senzory LiDAR (detekce světla a dálkoměr) díky svému vysokému rozlišení a spolehlivým možnostem 3D měření odrážejí světelné impulsy od okolí vozidla a měří vzdálenosti, zjišťují okraje vozovky a identifikují značení jízdních pruhů. Ultrazvukové senzory v kolech detekují obrubníky a ostatní vozidla při parkování. Sofistikovaný software pak zpracovává všechny tyto sensorické vstupy, plánuje dráhu a vysílá pokyny do akčních členů vozu, které ovládají zrychlení, brzdění a řízení. Pevně zakódovaná pravidla, algoritmy pro

vyhýbání se překážkám, prediktivní modelování a rozpoznávání objektů pomáhají softwaru dodržovat pravidla silničního provozu a překonávat překážky. [17, 19]


Funkce automatizovaného řízení od úrovně 3 výše jsou možné pouze tehdy, pokud jsou vozidla schopna spolehlivě detekovat celé své okolí a podle toho odvozovat pokyny pro činnost. [25]



Obrázek 15: Vizualizace senzorů v autonomním vozidle [39]

2.4 HISTORIE AUTONOMNÍCH VOZIDEL

V roce 1925 předvedl vynálezce Francis Houdina rádiem řízené auto v ulicích Manhattanu, aniž by kdokoli seděl za volantem. Rádio dokázalo nastartovat motor, řídit rychlosti a troubit. Toto auto nabídlo pohled do budoucnosti autonomie, ale bylo rychle odstaveno, když obsluha během jízdy dvakrát ztratila kontrolu a narazila do jiného vozidla. Navzdory této rané nehodě se průmysl nevzdal naděje na dálkově ovládaná auta. [27]



Obrázek 16: Vozidlo na dálkové ovládání [27]

V roce 1977 Japonci tento nápad zdokonalili a použili kamerový systém, který přenášel data do počítače a zpracovával obraz vozovky. Toto vozidlo však mohlo jezdit pouze rychlostí nižší než 20 mil za hodinu. Zlepšení přišlo od Němců o deset let později v podobě vozidla VaMoRs,

vybaveného kamerami, které dokázalo samo bezpečně jet rychlostí 56 km/h. Se zdokonalováním technologií se zlepšovala i schopnost samořízených vozidel detekovat a reagovat na své okolí. V roce 1990 začala univerzita Carnegie Mellon stavět samořídící automobily a do zpracování obrazu a řízení integrovala neuronové sítě. V roce 1995 vyjeli výzkumníci z Carnegie Mellon se svým samořídícím vozem nazvaným NavLab 5 na silnici a ujeli 2797 mil z Pittsburghu do San Diega. Řídili rychlost a brzdění, ale jinak byl vůz autonomní. [27]

2.5 SOUČASNOST AUTONOMNÍCH VOZIDEL

V současné době je mnoho vozidel na silnicích považováno za částečně autonomní díky bezpečnostním prvkům, jako jsou asistenční parkovací a brzdové systémy, a některá z nich jsou schopna sama řídit, zatáčet, brzdit a parkovat. Technologie autonomních vozidel se opírá o funkce GPS a také o pokročilé snímací systémy, které dokáží detekovat hranice jízdních pruhů, značky a signály a neočekávané překážky. Přestože tato technologie ještě není dokonalá, očekává se, že se s jejím zdokonalováním bude stále více rozšiřovat, přičemž podle některých předpovědí bude do roku 2025 až polovina automobilů sjíždějících z montážních linek po celém světě autonomní. Desítky států již mají legislativu týkající se používání autonomních vozidel v rámci příprav na dobu, kdy bude tato technologie běžná. [28]

Avšak výrobci automobilů a technologické společnosti jsou stále ještě daleko za uvedením plně autonomních automobilů na trh. Ačkoli dnes nejsou k dispozici žádné komerčně dostupné samořídící automobily pro individuální kupce, některá vozidla v současné době nabízejí pokročilé asistenční funkce pro řidiče. Panují určité nejasnosti ohledně toho, čeho jsou dnešní automobily schopny, a zda se dnešní aktivní asistenční systémy, které za určitých podmínek automaticky řídí, brzdí a zrychlují, považují za samořídící. Mnoho společností již provádí rozsáhlé testování soukromých autonomních automobilů. [29]

Navíc než bude tato technologie plně komerčně využita, musí být otestována na mnoha milionech kilometrů. Aby autonomní automobil dosáhl 95% ekvivalence s lidským řidičem, musí ujet přibližně 291 milionů kilometrů, aniž by způsobil smrtelné nehody. K první smrtelné nehodě došlo například v březnu 2018, kdy se prototyp Uberu Level-4 srazil s osobou přecházející ulici. [29]

2.6 VÝHODY A NEVÝHODY AUTONOMNÍCH VOZIDEL

Podívejme se na hlavní výhody a nevýhody, které autonomní vozidla přinášejí.

2.6.1 VÝHODY

360° VIDĚNÍ

Díky vysoce přesným technologiím mají autonomní vozidla schopnost vidět okolí v rozsahu 360°, což je dvakrát více než lidé, kteří mají úhel pohledu pouze 180° horizontálně. [31]

SNÍŽENÍ POČTU NEHOD

Díky 360° vidění a vzájemnému propojení a neustálé komunikaci vozidel se výrazně sníží počet nehod. Ačkoli (alespoň zpočátku) se nehody nesníží na nulu, bude jich mnohem méně než nehod způsobených lidským řízením. [31]

VYŠŠÍ EFEKTIVITA PROVOZU

I když se odhaduje, že jejich rychlost ve velkých městech bude nižší, jejich dopravní účinnost bude vyšší. [31]

PŘÍSTUP PRO ZDRAVOTNĚ POSTIŽENÉ A OSOBY SE SNÍŽENOU POHYBLIVOSTÍ

Díky tomu, že automobil bude autonomní a nebude ke svému provozu prakticky vyžadovat lidskou interakci, budou jej moci mít i lidé se zrakovým či sluchovým postižením, tj. stane se inkluzivním. [31]

UDRŽITELNÁ VOZIDLA

Předpokládá se, že tato vozidla budou fungovat na bázi čisté energie, takže emise uhlíku a skleníkových plynů budou prakticky nulové. [31]

2.6.2 NEVÝHODY

Nyní se podíváme na hlavní nevýhody autonomních vozidel.

OTÁZKY OCHRANY ÚDAJŮ

První problém, který vzniká, spočívá v tom, že vzhledem k neustálému propojení s celým prostředím se může stát kybernetickým problémem ochrana dat. Dokonce i správná manipulace se silničními sítěmi může být ohrožena. [31]

VYSOKÉ NÁKLADY NA IMPLEMENTACI

Infrastruktura autonomních vozidel se točí kolem pokrytí sítěmi 5G, které je zatím drahé, takže vládám může trvat značnou dobu, než investují do dostatečné infrastruktury pro optimální výkon autonomních vozidel. [31]

VYSOKÉ NÁKLADY NA VOZIDLA


Přestože bylo dosaženo významného pokroku ve snižování nákladů na výrobu jejich náradí, nejsou tyto škrty dostatečně nízké na to, aby se staly finančně přijatelnou alternativou pro průměrnou rodinu. Bude trvat několik let, než se stanou každodenní realitou v dosahu střední třídy. [31]

2.7 PŘEHLED SENZORŮ A SNÍMAČŮ POUŽÍVANÝCH V AUTONOMNÍCH VOZIDLECH

V autonomních vozidlech existují různé kategorie senzorických systémů: 1) navigační a naváděcí senzory, které určují, kde se nacházíte a jak se dostat do cíle; 2) jízdní a bezpečnostní senzory, jako jsou kamery, které zajišťují, aby se vozidlo chovalo správně za všech okolností a dodržovalo pravidla silničního provozu; a 3) výkonové senzory, které řídí vnitřní systémy vozidla, jako je řízení výkonu, celková spotřeba a tepelný rozptyl. [32]

I když se systémy autonomních vozidel mohou mezi sebou mírně lišit, základní software obecně zahrnuje lokalizaci, vnímání, plánování a řízení. Systém vnímání snímá, chápe a vytváří si úplné povědomí o prostředí a objektech kolem sebe pomocí kamer, senzorů LiDAR a radarů. Plánovací software je zodpovědný za plánování cesty, vyhodnocování rizik, řízení úkolů a generování cesty. Techniky strojového učení (ML) a hlubokého učení (DL) se široce používají pro lokalizaci a mapování, fúzi senzorů a porozumění scéně, navigaci a plánování pohybu, vyhodnocování stavu řidiče a rozpoznávání vzorců chování řidiče a učení inteligence pro vnímání a plánování. Mapovací software lze použít k vytváření a aktualizaci mapových dat

s vysokým rozlišením na úrovni jízdních pruhů prostřednictvím shromážděných dat ze snímačů a zpracování posterů. [32]



Obrázek 17: Umístění senzorů na autonomním vozidle [46]

2.7.1 KAMERY

Vnímání v autonomních vozidlech se dosahuje pomocí mnoha senzorů a sensorových systémů, kamery však byly jedním z prvních typů senzorů, které se ve vozidlech bez řidiče začaly používat, a v současné době jsou pro výrobce automobilů hlavní volbou. Nová vozidla mají na vozidlech namontovány desítky různých kamer. Kamery umožňují autonomnímu vozidlu doslova vizualizovat své okolí. [32]

Jsou velmi účinné při klasifikaci interpretace textur, jsou široce dostupné a cenově dostupnější než radar nebo lidar. Nevýhodou kamery je výpočetní výkon potřebný pro zpracování dat. Nejnovější kamery s vysokým rozlišením mohou produkovat miliony pixelů na snímek, přičemž 30 až 60 snímků za sekundu umožňuje vyvinout složité zobrazení. To vede k tomu, že je třeba zpracovat v reálném čase několik megabajtů dat. [32]

Vzhledem k tomu, že kamera je nepostradatelným snímačem při autonomním řízení, jsou aplikace využití kamery v samořízených vozidlech nekonečné. Oblast použití zahrnuje vnímání, sémantickou segmentaci, komplexní autonomní řízení a mnoho dalších. Kamery lze použít také uvnitř vozidla pro interakci člověka se strojem. [32]

Přestože kamery poskytují přesný obraz, mají svá omezení. Dokážou rozlišit detaily okolního prostředí, je však třeba vypočítat vzdálenosti těchto objektů, aby bylo možné přesně zjistit, kde se nacházejí. Pro senzory založené na kamerách je také obtížnější detekovat objekty za snížené viditelnosti, jako je mlha, déšť nebo noc. [34]




Obrázek 18: Kamera pro autonomní řízení od společnosti Sekonix [34]

2.7.2 RADAR

Radar (Radio Detection and Ranging) je klíčovým prvkem pro celkovou funkci autonomního řízení: vysílá rádiové vlny, které detekují objekty a v reálném čase měří jejich vzdálenost a rychlost ve vztahu k vozidlu. Funguje na principu elektromagnetického záření, které lze využít v několika frekvenčních pásmech. (např. 24 GHz, 77 GHz, 79 GHz). Vyšší frekvence poskytují vyšší rozlišení, které umožňuje radarovému sensorovému systému rozlišit více objektů v reálném čase. [34, 35]

Radarové senzory krátkého i dlouhého dosahu jsou obvykle rozmístěny po celém vozidle a každý z nich má své odlišné funkce. Zatímco aplikace radarů krátkého a středního dosahu (50 - 100 m) umožňují sledování mrtvého úhlu, ideální asistenci při udržování vozidla v jízdním pruhu a pomoc při parkování, k úlohám radarových senzorů dlouhého dosahu (více než 150 m) patří automatická kontrola vzdálenosti a asistence při brzdění. Na rozdíl od kamerových senzorů nemají radarové systémy obvykle žádné problémy s identifikací objektů za mlhy nebo deště. [35]


Ačkoli údaje poskytované okolními radary a kamerami jsou pro nižší úroveň autonomie dostatečné, nepokryjí všechny situace bez lidského řidiče. Proto přichází na řadu lidar. [34]



Obrázek 19: Technologie radarového snímání [34]

2.7.3 LIDAR

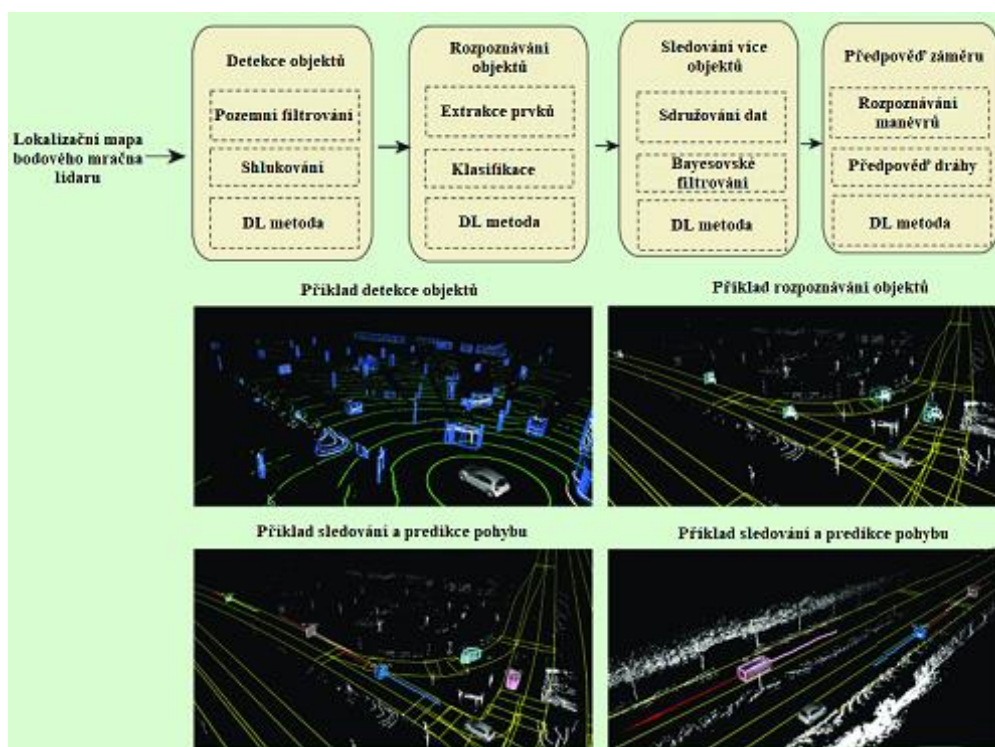
Lidar (Light Detection and Ranging) funguje podobně jako radar, jen s tím rozdílem, že místo rádiových vln používá lasery. Lidar umožňuje samořiditelným vozům 3D zobrazení jejich okolí. Poskytuje informace o tvaru a hloubce okolních automobilů a chodců, stejně jako o geografii silnice. A stejně jako radar funguje stejně dobře i za zhoršených světelných podmínek. Díky vysílání neviditelných laserů neuvěřitelnou rychlostí jsou lidar senzory schopny vytvořit detailní 3D obraz ze signálů, které se okamžitě odrážejí zpět. Tyto signály vytvářejí "mračna bodů", která představují okolní prostředí vozidla a zvyšují tak bezpečnost a rozmanitost údajů ze senzorů. [34, 35]



Obrázek 20: Senzor LiDAR [39]

Dnešní senzory LiDAR jsou schopny měřit vzdálenosti rychlostí vyšší než 150 kilohertzů (150 000 pulzů za sekundu) a byly by klasifikovány jako senzory s dlouhým dosahem přes 250 m. [35]

Velkou nevýhodou těchto senzorů je až desetkrát dražší implementace než u kamer a radarů. [34]



Obrázek 21: Příklad detekce a rozpoznávání objektů a sledování a predikce pohybu pomocí LiDARU

2.7.4 ULTRAZVUKOVÉ SENZORY

Ultrazvukový senzor využívá zvukové vlny k určení vzdálenosti od objektu. Tyto vlny jsou vysílány k objektu a na základě doby návratu je vypočtena vzdálenost. Ultrazvukové senzory jsou cenově dostupné a odolné v nepříznivých podmínkách, což z nich činí oblíbenou volbu pro parkovací senzory v automobilech. Tyto senzory jsou také považovány za nejpřesnější

v těsné blízkosti. Nicméně, rušivé zvukové vlny mohou ovlivnit výkon senzoru a změny v prostředí, jako je teplota a vlhkost, mohou mít vliv na jeho schopnosti. Algoritmus používaný většinou senzorů přizpůsobuje údaje v závislosti na aktuální teplotě, aby se minimalizovalo ovlivnění prostředím. [35]

2.7.5 GPS

GPS je systém, který umožňuje přijímači získávat informace o své zeměpisné poloze a čase na Zemi, pokud má volnou viditelnost na čtyři nebo více družic GPS. Přijímač vypočítává svoji polohu na základě signálů z družic pomocí trilaterace, což je proces měření vzdáleností pomocí geometrie kružnic, trojúhelníků nebo koulí. GPS se často používá jako senzor pro navigaci a lokalizaci v autonomních vozidlech kvůli své schopnosti určit polohu. Přijímače GPS mohou dosáhnout přesnosti přibližně 3 metry pro ruční použití, zatímco přijímače komerční třídy mohou dosáhnout přesnosti přibližně jednoho metru. Nicméně, jednotky GPS pro průzkumné účely s dvěma frekvencemi dosahují přesnosti v rozmezí několika centimetrů, ale jsou velmi drahé. Nevýhodou použití technologie GPS pro autonomní navigaci je, že mnoho faktorů může snížit přesnost určení polohy. GPS vyžaduje přímou viditelnost na satelity a signály mohou být rušeny překážkami, jako jsou budovy, stromy, tunely atd. Proto se navigace ve vnitřních nebo podzemních prostředích nespolehá na systémy GPS. [35]

2.7.6 IMU

IMU (Inertial Measurement Unit) jsou elektronická zařízení, která slouží k určení síly, úhlové rychlosti a magnetického pole objektu. Jsou složeny ze tří akcelerometrů, gyroskopů a magnetometrů, přičemž každý z těchto senzorů je orientován podél os X, Y a Z. IMU se často využívají při autonomním řízení a navigaci vozidel a bývají integrovány do inerciálních navigačních systémů (INS - Inertial Navigation System), které zpracovávají data z IMU a vypočítávají lineární rychlost, polohu a úhlovou polohu vzhledem ke globálnímu souřadnicovému systému. Jako jedna z nevýhod IMU je omezení v poskytování přesných informací o poloze vozidla, protože mohou měřit pouze pohyb. To vyžaduje využití alternativního zdroje, jako je například GPS. Navíc IMU jsou náchylné k akumulaci chyb, které mohou vést k driftu. Tento drift se často koriguje začleněním polohového sledovacího systému, například GPS, který průběžně koriguje chyby driftu. [35]

3 IMPLEMENTACE DO ECU A APLIKACE

Autonomní vozidla se rodí v datovém centru. Aby mohla fungovat bez člověka za volantem, vyžadují kombinaci senzorů, vysoce výkonného hardwaru, softwaru a mapování ve vysokém rozlišení. Ačkoli koncept této technologie existuje již desítky let, produkční samořídící systémy se staly možnými teprve nedávno díky průlomům v oblasti umělé inteligence a výpočetní techniky. Hluboké neuronové sítě, které pracují ve vozidle, jsou trénovány na obrovském množství jízdních dat. Musí se naučit identifikovat objekty v reálném světě a reagovat na ně - což je neuvěřitelně časově a finančně náročný proces. Testovací flotila 50 vozidel generuje každý den přibližně 1,6 petabajtů dat, která musí být přijata, zakódována a uložena před dalším zpracováním. Poté je třeba data projít a najít scénáře užitečné pro trénink, například nové situace nebo situace nedostatečně zastoupené v aktuálním souboru dat. Tyto užitečné snímky obvykle tvoří pouhých 10 % z celkového objemu shromážděných dat. Poté je třeba označit každý objekt ve scéně, včetně semaforů a dopravních značek, vozidel, chodců a zvířat, aby se je DNN mohly naučit identifikovat a také zkontrolovat jejich přesnost. V současné době existuje mnoho programovacích jazyků, které lze využít pro implementaci neuronových sítí. Je důležité si uvědomit, že implementace nového řídicího algoritmu do ECU může být složitý proces, který vyžaduje zkušenosti v oblasti programování a automobilového průmyslu. Proto se doporučuje, aby byl proces prováděn odborníky s potřebnými zkušenostmi a znalostmi. [37]



Obrázek 22: Architektura fungování autonomního vozidla od společnosti NVIDIA [51]

3.1 HARDWARE PRO AUTONOMNÍ VOZIDLA

Hardwarem pro autonomní vozidla je Elektronická řídicí jednotka, což je v podstatě vestavěný počítač, který provádí dohled nad řízením vozidla na základě velkého množství informací o okolním prostředí získaných pomocí stereo kamer, radarů a dalších senzorů. V moderních vozidlech mohou být ECU propojeny a komunikovat mezi sebou. Příkladem elektronické řídicí jednotky může být například DRIVE AGX Orin DevKit od společnosti NVIDIA. Tato elektronická řídicí jednotka využívá platformu DRIVE AGX Orin, která zvládne zpracovat data při současném běhu několika DNN. [38]

3.1.1 DRIVE AGX ORIN

DRIVE AGX Orin je vysoce pokročilou softwarově definovanou platformu pro autonomní vozidla a roboty. Platforma je poháněna novým systémem SoC (system-on-a-chip) pod názvem Orin, který se skládá ze 17 miliard tranzistorů. SoC Orin integruje novou generaci architektury grafických procesorů NVIDIA nové akcelerátory hlubokého učení a počítačového vidění, které v souhrnu poskytují 200 bilionů operací za sekundu - téměř 7x vyšší výkon než předchozí generace SoC NVIDIA Xavier. Orin je navržen tak, aby zvládl velké množství aplikací a hlubokých neuronových sítí, které běží současně v autonomních vozidlech, a zároveň dosáhl systematických bezpečnostních standardů. DRIVE AGX Orin, vytvořený jako softwarově definovaná platforma, je vyvinutý tak, aby umožňoval architektonicky kompatibilní platformy, které se škálují od úrovně 2 až po plně samořízené vozidlo úrovně 5. [40]



Obrázek 23: Elektronická řídicí jednotka DRIVE AGX Orin DevKit [53]

3.2 SOFTWARE PRO AUTONOMNÍ VOZIDLA

Software je to, co z vozidla dělá inteligentní stroj. Otevřená sada NVIDIA DRIVE SDK poskytuje vývojářům všechny stavební prvky a algoritmické balíčky potřebné pro autonomní řízení. Umožňuje vývojářům efektivně vytvářet a efektivněji nasazovat různé nejmodernější aplikace autonomních vozidel, včetně vnímání, lokalizace a mapování, plánování, řízení a monitorování řidiče. [41]

3.2.1 DRIVE OS

NVIDIA DRIVE OS je referenční operační systém a související softwarový balík navržený speciálně pro vývoj a nasazení aplikací pro autonomní vozidla na hardwaru DRIVE AGX. NVIDIA DRIVE OS poskytuje bezpečné a zabezpečené prostředí pro spouštění aplikací kritických z hlediska bezpečnosti. [42]

Tento základní softwarový balík pro autonomní vozidla se skládá z vestavěného operačního systému reálného času, hypervizoru NVIDIA, knihoven NVIDIA (CUDA a Tensor RT) a dalších komponent optimalizovaných tak, aby poskytovaly přímý přístup k hardwarovým akceleračtorům DRIVE AGX. [42]

3.2.2 DRIVETWORKS

NVIDIA DriveWorks SDK je middleware (software, který funguje jako most mezi operačním systémem nebo databází a aplikacemi, zejména v síti) pro vývoj softwaru pro autonomní vozidla. Součástí každé verze je soubor modulů pro běžné případy použití softwaru pro AV, jako je propojení se senzory vozidla, zpracování dat ze senzorů, která se použijí jako vstup pro algoritmy vnímání, a provádění inference DNN na předem natrénovaných sítích. Součástí je také sada nástrojů, které podporují vývoj softwaru autonomních vozidel, jako je záznam dat ze senzorů, kalibrace senzorů a optimalizace DNN. DriveWorks abstrahuje od detailů základní platformy DRIVE AGX a zároveň odhaluje její výkon, čímž zkracuje dobu vývoje složitých a zrychlených aplikací autonomních vozidel. [43]

3.2.3 DRIVE AV

NVIDIA DRIVE AV poskytuje moduly vnímání, mapování a plánování pomocí DriveWorks SDK. [44]

DRIVE PERCEPTION

Detekuje, sleduje a odhaduje vzdálenosti pomocí různých DNN a heterogenních dat ze senzorů pro vnímání překážek, cest a podmínek zastavení (například značka STOP). [44]

DRIVE MAPPING

Je multimodální mapovací platforma, která kombinuje pozemní a letecké mapové podklady pro dosažení přesnosti a měřítka. Slouží jako základní datová sada pro označování, ověřování a rekonstrukci 3D prostředí pro simulace. [44]

DRIVE PLANNING

NVIDIA DRIVE Planning plánuje a řídí pohyb vozidla, včetně chování vozidla během trasy v jízdnicích pruzích. [44]

3.3 PŘEHLED PROGRAMOVACÍCH JAZYKŮ A KNIHOVEN

3.3.1 PYTHON

Python je při vývoji autonomních vozidel hojně používaným kódovacím jazykem. Je to programovací jazyk, který se snadno učí a lze v něm rychle vytvářet efektivní algoritmy. Jazyk Python je všestranný, což jej předurčuje k hloubkové analýze dat, umělé inteligenci a algoritmům strojového učení. [45]

Python lze použít ke zpracování velkých souborů dat a snadné automatizaci opakujících se úloh. Nabízí také řadu výkonných knihoven, které mohou pomoci rychle a efektivně vytvářet aplikace. Díky těmto vlastnostem hraje Python důležitou roli při vývoji autonomních vozidel, protože umožňuje vývojářům rychle experimentovat s novými nápady, aniž by museli kód několikrát přepisovat. [45]

Použití jazyka Python navíc umožňuje vývojářům psát kód při zachování vysoké úrovně čitelnosti, což zjednodušuje proces ladění. To zvyšuje spolehlivost a přesnost vozidel při jejich testování na veřejných komunikacích a zajišťuje, že budou vždy jezdit bezpečně. [45]

TENSORFLOW

TensorFlow je všeobecně považován za jednu z nejlepších knihoven Pythonu pro aplikace hlubokého učení. Vyvinul ji tým Google Brain a poskytuje širokou škálu flexibilních nástrojů, knihoven a komunitních zdrojů. Začátečníci i profesionálové mohou TensorFlow používat ke konstrukci modelů hlubokého učení i neuronových sítí. [47]

TensorFlow má flexibilní architekturu a rámec, které umožňují jeho provoz na různých výpočetních platformách, jako jsou CPU a GPU. S ohledem na to je jeho výkon nejlepší, pokud je provozován na tensor processing unit (TPU). Knihovna se často používá k implementaci posilovacího učení v modelech hlubokého učení a modely strojového učení můžete přímo vizualizovat. [47]

PYTORCH

Další z nejoblíbenějších knihoven Pythonu pro hluboké učení je PyTorch, což je otevřená knihovna vytvořená výzkumným týmem AI společnosti Facebook v roce 2016. Název knihovny je odvozen od Torch, což je framework pro hluboké učení napsaný v programovacím jazyce Lua. PyTorch umožňuje provádět mnoho úloh a je užitečný zejména pro aplikace hlubokého učení, jako je NLP a počítačové vidění. [47]

Mezi nejlepší aspekty PyTorch patří vysoká rychlost provádění, které dosahuje i při zpracování těžkých grafů. Je to také flexibilní knihovna, která dokáže pracovat na zjednodušených procesorech, nebo CPU a GPU. PyTorch má výkonné rozhraní API (Application programming interface), které umožňuje knihovnu rozšiřovat, a také sadu nástrojů pro práci s přirozeným jazykem. [47]

KERAS

Keras je další významná otevřená knihovna pro Python používaná pro úlohy hlubokého učení, která umožňuje rychlé testování hlubokých neuronových sítí. Keras poskytuje nástroje potřebné ke konstrukci modelů, vizualizaci grafů a analýze souborů dat. Kromě toho obsahuje také předem označené datové sady, které lze přímo importovat a načíst. [47]

Knihovna Keras je často upřednostňována díky tomu, že je modulární, rozšiřitelná a flexibilní. Díky tomu je uživatelsky přívětivou volbou pro začátečníky. Lze ji také integrovat s cíli, vrstvami, optimalizátory a aktivačními funkcemi. Keras pracuje v různých prostředích a může běžet na CPU i GPU. Nabízí také jeden z nejširších rozsahů pro datové typy. [47]

3.3.2 C A C++

C a C++ jsou dva nejčastěji používané kódovací jazyky při vývoji autonomních vozidel, a to díky své rychlosti, přenositelnosti, spolehlivosti a jednoduché syntaxi. Výrobci OEM je proto

často používají k vývoji asistenčních systémů pro řidiče, které často tvoří základ složitějších systémů, jako je adaptivní tempomat a systémy pro jízdu v jízdním pruhu. Kromě toho se často vyskytují v systému řízení platformy autonomního vozidla, který se skládá z vysokoúrovňových softwarových aplikací umožňujících rozhodování o vstupech do plynu, brzd a úhlu natočení volantu. Kromě toho se jazyk C/C++ hojně využívá také pro algoritmy, jako jsou neuronové sítě s hlubokým učením pro autonomní vozidla. [45]

Tyto jazyky se snadno čtou a udržují, protože mají strukturovaná pravidla syntaxe, která umožňují jasné členění při odkazování na proměnné nebo definování funkcí. Jazyk C/C++ navíc obsahuje širokou škálu výkonných knihoven, takže vývojáři mohou do svého systému snadno zapojit existující nástroje, aniž by museli psát kód od začátku. Spolu s možnostmi optimalizace kódu, které zkracují dobu vývoje ve vysoké rozšířené míře ve srovnání s jinými jazyky, jako je Python nebo Java; to činí tento jazyk jedním z nejvhodnějších pro použití v projektech autonomního řízení. [45]

3.4 APLIKACE AUTONOMNÍCH VOZIDEL VYUŽÍVAJÍCÍ NEURONOVÉ SÍTĚ

A nyní se podíváme na vybrané aplikace autonomních vozidel.

3.4.1 KLASIFIKACE DOPRAVNÍHO ZNAČENÍ

Velmi důležitou úlohou, kde se autonomní vozidla musí naučit stejné zásady, stejně jako přesně rozpoznávat a reagovat na dopravní značky a světla v jakémkoli prostředí, ve kterém se pohybují je detekovat dopravní značení a následně na ně reagovat, kde zelená znamená jet, červená znamená zastavit. [48]

K dosažení tohoto cíle se firma NVIDIA spoléhá na kombinaci DNN, které detekují a klasifikují dopravní značky a světla. Konkrétně využívají WaitNet DNN pro detekci křižovatek, detekci semaforů a detekci dopravních značek. Jejich síť LightNet DNN pak klasifikuje tvar semaforu (například plná nebo šipka) a stav (barva nebo červená, žlutá nebo zelená), zatímco síť SignNet DNN identifikuje typ dopravní značky. Dohromady tyto tři sítě DNN tvoří jádro softwaru pro vnímání čekacích podmínek, který je určen k detekci dopravních podmínek, při nichž musí autonomní vozidlo zpomalit a počkat, než bude pokračovat v jízdě. [48]

K provádění klasifikace typu dopravních značek je síť SignNet navržena jako konvoluční DNN, která hierarchickým způsobem klasifikuje typ dopravních značek z celého světa. V plochém konvolučním modelu DNN natrénovaném pro klasifikaci by musely být všechny různé potenciální výstupní třídy definovány předem a pro každý snímek by musel být vybrán jeden klasifikační výstup. Vzhledem ke složitosti typů dopravních značek, které se vyskytují po celém světě, by bylo škálování takového modelu, aby pokryl všechny možné třídy se silným výkonem přesnosti, neúměrně obtížné. Aby se tato složitost zvládla a optimalizoval výkon, využívá se hierarchický konvoluční model DNN, ve kterém nejsou předem definovány přesné výstupní třídy. SignNet je vycvičen k nezávislé detekci klíčových rysů, které jsou pak na základě analýzy výstupních výsledků kombinovány do výstupních tříd. Současný model SignNet DNN pokrývá 300 typů dopravních značek v USA a 200 evropských dopravních značek (údaj k datu 7. 8. 2019). Tyto značky zahrnují dálniční značky, jako jsou rychlostní omezení a vymezení dálničních zón, a také značky potřebné pro autonomní jízdu ve městech (například značky "dej přednost v jízdě", "právo přednostní jízdy" a "kruhový objezd"). [48]




Obrázek 24: Klasifikace dopravního značení pomocí SighnNet DNN [48]

3.4.2 DETEKCE SILNIČNÍHO ZNAČENÍ

Další klíčovou rolí autonomních vozidel je rozpoznávání jízdních pruhů a okrajů vozovky. Rozpoznávání jízdních pruhů podporuje systémy, jako je varování před vybočením z jízdního pruhu, které pomáhají řidičům zabránit odchýlení z jízdního pruhu. Kromě detekce informací o jízdních pruzích musí autonomní vozidla detekovat také další silniční značení (například šipky nebo text STOP) a také svislé orientační body, které pomáhají přesně lokalizovat vozidlo na mapě s vysokým rozlišením. [49]

Pro tento účel využívá firma NVIDIA síť LaneNet DNN, která poskytuje vysoce přesnou a stabilní detekci namalovaných čar jízdních pruhů na silnici, pro vysoce přesnou síť MapNet DNN. Tato evoluce zahrnuje rozšíření detekčních tříd, aby kromě detekce čar jízdních pruhů pokrývaly také silniční značení a svislé orientační body (např. sloupy). Zahrnuje také zvýšení efektivity zpracování prostřednictvím detekce od konce ke konci, která poskytuje rychlejší odvozování v autě. Model MapNet DNN je schopen detekovat malované značení čar jízdních pruhů (plné čáry/přerušované čáry, čáry vjezdu/výjezdu z křižovatky, okraje vozovky), malované silniční značení (například šipky, text STOP a značení jízdních pruhů pro vozidla s vysokou obsazeností) a také svislé sloupy (například dopravní značky a sloupy veřejného osvětlení). [49]

Vysoce přesná síť MapNet je schopna zajistit přesnou detekci tvaru dopravního značení i v přítomnosti částečně chybějících značek barvy. V případech, kdy se na stejném místě nachází současně plné a přerušované značení čáry jízdního pruhu, systém MapNet záměrně považuje čáru jízdního pruhu za plnou, aby podpořil bezpečnou jízdu. MapNet detekuje také okraje vozovky, což je užitečné zejména v případech, kdy neexistuje jasné malované značení jízdních pruhů, a důsledně detekuje přechody z plného na přerušované značení čáry jízdního pruhu. Dále stabilně detekuje čáry jízdních pruhů a okrajů vozovky i v přítomnosti vizuálních problémů, včetně prasklin na vozovce, skvrn od asfaltu a ostrých stínů vrhaných stromy nebo svíslými orientačními body. MapNet navíc detekuje textové dopravní značení v různých jazycích. [49]



Obrázek 25: Detekce silničního značení pomocí LaneNet DNN [49]

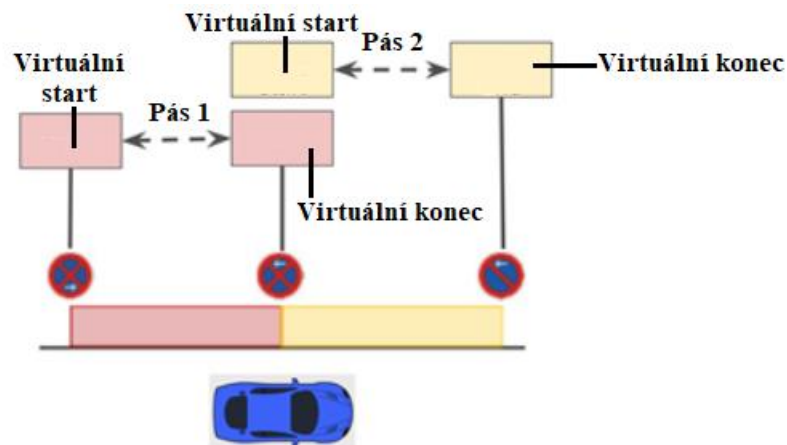
3.4.3 PARKOVÁNÍ VOZIDLA

Autonomní parkování zahrnuje řadu složitých algoritmů pro vnímání a rozhodování a tradičně se při získávání informací o parkování spoléhá na mapy s vysokým rozlišením (HD). Pokrytí mapami a nedostatečné nebo zastaralé lokalizační informace však mohou takové systémy omezovat. Ke složitosti se přidává i to, že systém musí rozumět pravidlům parkování, která se v jednotlivých regionech liší, a interpretovat je. [50]

Pochopení a výklad pravidel parkování může být složitější, než se zdá. Různá pravidla parkování v rámci platného regionu mohou být nadřazena. Kromě toho mohou značky nesouvisející s parkováním vyvozovat pravidla parkování. Například v Německu je parkování zakázáno v okruhu 15 metrů od jakýchkoli značek autobusových zastávek. V USA je parkování zakázáno ve vzdálenosti 30 metrů před značkou zastávky. A konečně, kromě explicitních vodítek, jako je fyzická značka, existují i implicitní značky, které nesou informace o parkování. V mnoha oblastech například křižovatka označuje konec předchozího pravidla aktivního parkování. [50]

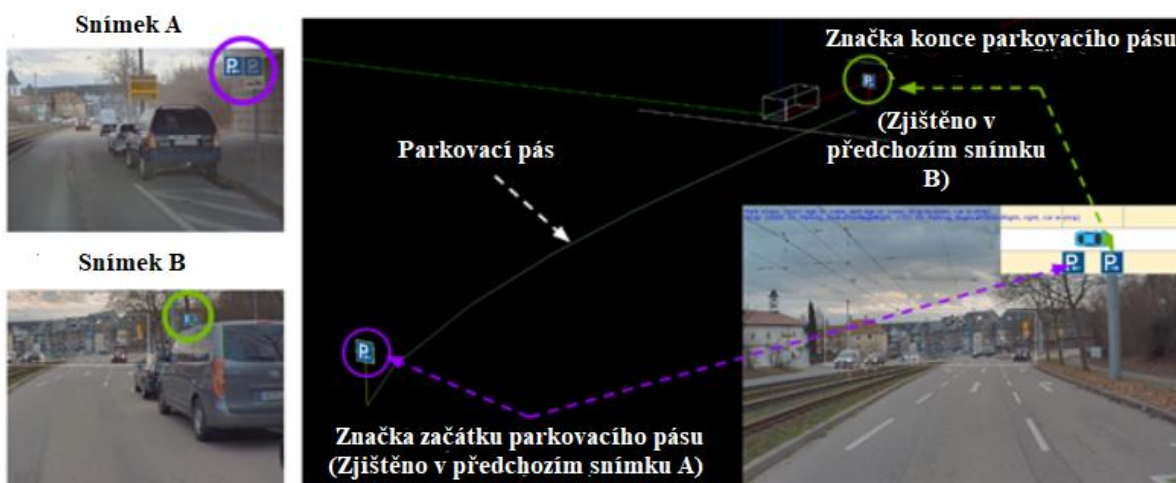
Pokročilý systém asistence při parkování (PSA-parking sign assist) je pro autonomní vozidla zásadní, aby porozuměla složitosti pravidel parkování a mohla podle nich reagovat. Tradiční systémy PSA se spoléhají pouze na vstupní údaje z HD map. Avšak firma NVIDIA využívá nejmodernější hluboké neuronové sítě (DNN) a algoritmy počítačového vidění, aby zlepšily pokrytí a robustnost autonomního parkování v reálných scénářích. Tyto techniky dokáží v reálném čase detekovat, sledovat a klasifikovat širokou škálu dopravních značek a křižovatek pro parkování. Používají se sítě WaitNet DNN a SignNet DNN, které byly vysvětleny v kapitole klasifikace dopravního značení. Výsledky z těchto modulů jsou následně přivedeny do systému PSA, který na základě těchto dat určí, zda se vůz nachází v parkovacím pásu, jaká jsou omezení a zda může vůz v dané oblasti zastavit nebo zaparkovat. [50]

Poté, co systém PSA obdrží detekované parkovací značky a křižovatky, zobecní objekt na značku „Začátek parkování“ nebo „Konec parkování“. Tato úroveň zobecnění umožňuje, aby se systém rozšířil do celého světa. Značka „Začátek parkování“ označuje potenciální začátek nového parkovacího pásu a značka „Konec parkování“ může uzavřít jeden nebo více stávajících parkovacích pásů. [50]



Obrázek 26: Příklad tvarování parkovacích pásů [50]

Kromě vytvoření parkovacího pásu využívá systém PSA sémantický význam značek ke klasifikaci parkovacího pásu na stavy zákazu stání, zákazu zastavení, povoleného stání a neznámého stavu. Tyto informace pak může poskytnout řidiči nebo jakémukoli autonomnímu parkovacímu systému. Nakonec systém PSA uloží všechny aktivní parkovací pásy do své paměti a signalizuje řidiči aktuální stav parkování na základě pravidel silničního provozu vyplývajících z platného parkovacího pásu. [50]



Obrázek 27: Fungování PSA na vysoké úrovni [50]

3.4.4 VIDĚNÍ VOZIDLA

Autonomní vozidla se spoléhají na kamery, aby viděla své okolí. Viditelnost kamer však mohou ovlivnit faktory prostředí, jako je déšť, sníh nebo jiné překážky. Kromě schopnosti vnímat své okolí by měl být každý robustní systém vnímání schopen uvažovat o platnosti dat přicházejících ze sensorů. Za tímto účelem je nutné odhalit neplatnost dat ze sensorů co nejdříve v procesu zpracování, ještě předtím, než jsou data spotřebována navazujícími moduly. [52]

Proto firma NVIDIA vyvinula hlubokou neuronovou síť ClearSightNet, která je vycvičena k vyhodnocování schopnosti kamer jasně vidět a pomáhající určit hlavní příčiny zákrytů, blokad a snížení viditelnosti. [52]

ClearSightNet rozděljuje obrazy z kamery na oblasti odpovídající dvěma typům slepoty: okluze a snížená viditelnost. Segmentace podle okluze odpovídá oblastem zorného pole kamery, které jsou buď zakryty neprůhlednou překážkou, jako je prach, bláto nebo sníh, nebo neobsahují žádné informace, například pixely nasycené sluncem. V takových oblastech je vnímání obecně zcela narušeno. [52]

Segmentace se sníženou viditelností odpovídá oblastem, které nejsou zcela blokovány, ale mají zhoršenou viditelnost v důsledku silného deště, vodních kapek, oslnění, mlhy atd. V těchto oblastech je vnímání často částečně zhoršeno a měly by být považovány za oblasti s nižší důvěryhodností. [52]

Výstupem sítě je maska, kterou lze pro vizualizaci překrýt na vstupní obrázek, kde jsou zcela zakryté oblasti označeny červenou barvou a oblasti se sníženou viditelností nebo částečně zakryté oblasti jsou označeny zeleně. Kromě toho síť ClearSightNet vypisuje poměr nebo procento, které udává podíl vstupního obrazu, který je ovlivněn okluzí nebo sníženou viditelností. [52]



Obrázek 28: Vidění autonomního vozidla pomocí ClearSightNet DNN [52]

ZÁVĚR

V první části mé bakalářské práce je shrnutí a popis neuronových sítí. Byla zde vysvětlena struktura neuronové sítě, metody učení, její využití a rozdělení. Především jsem se zabýval konvoluční neuronovou sítí a rekurentní neuronovou sítí, které se často využívají v autonomním řízení.

V následující části mé práce se zaměřuji na autonomní vozidla a provedl jsem analýzu v této oblasti. Dále jsem se zabýval klasifikací autonomních vozidel na základě stupně jejich automatizace. Autonomní vozidla jsou rozdělena do 6 úrovní podle SAE, přičemž úrovně 0 až 2 stále závisí převážně na lidském řidiči, zatímco úrovně 3 až 5 popisují vozidla, která jsou řízena automatizovaným systémem. Další dělení, které se zdá přehlednější je dělení podle BASt. Dále jsem vytvořil komplexní přehled senzorů a snímačů, které jsou využívány autonomními vozidly.

V poslední kapitole jsem se věnoval implementaci neuronových sítí do ECU a především aplikacemi. Následně jsem vytvořil přehled softwarového a hardwarového vybavení pro autonomní vozidla, především vynalezeny firmou NVIDIA a dále přehled programových jazyků a knihoven, které se k implementaci využívají a vysvětlil různé aplikace, které využívají neuronové sítě a to zejména detekci objektů.

Závěrem této bakalářské práce lze konstatovat, že neuronové sítě jsou klíčovým prvkem pro dosažení autonomie v oblasti řízení vozidel. Tyto sítě jsou schopny se učit a přizpůsobovat se novým situacím, což umožňuje vozidlům reagovat na nepředvídatelné situace v reálném čase. Díky tomu mohou autonomní vozidla zlepšit bezpečnost na silnicích, snížit dopravní zácpy a zlepšit efektivitu přepravy.

Přestože jsou neuronové sítě velmi mocné, existují i určité výzvy, které je třeba překonat. Jednou z hlavních výzev je neustálé zlepšování a vylepšování sítí, aby byly schopné reagovat na stále složitější situace a prostředí. Další výzvou je také zajištění bezpečnosti a spolehlivosti autonomních vozidel, což vyžaduje neustálé testování a ověřování sítí a jejich funkčnosti.

Vzhledem k vysokému potenciálu, který neuronové sítě přinášejí, je pravděpodobné, že budou hrát klíčovou roli v dalším vývoji autonomních vozidel. Avšak výzkum a vývoj v této oblasti bude pokračovat, aby bylo dosaženo větší spolehlivosti a bezpečnosti a aby se autonomní vozidla mohla šířit do většího množství oblastí a prostředí.

POUŽITÉ INFORMAČNÍ ZDROJE

- [1] *What are Neural Networks? | IBM* [online]. [cit. 2023-05-22]. Dostupné z: <https://www.ibm.com/topics/neural-networks>
- [2] *What is a Neural Network? - Artificial Neural Network Explained - AWS* [online]. [cit. 2023-05-22]. Dostupné z: <https://aws.amazon.com/what-is/neural-network/>
- [3] *Differences Between AI vs. Machine Learning vs. Deep Learning | Simplilearn* [online]. [cit. 2023-05-22]. Dostupné z: <https://www.simplilearn.com/tutorials/artificial-intelligence-tutorial/ai-vs-machine-learning-vs-deep-learning>
- [4] *What is machine learning? | Definition, types, and examples | SAP Insights* [online]. [cit. 2023-05-22]. Dostupné z: <https://www.sap.com/uk/products/artificial-intelligence/what-is-machine-learning.html>
- [5] VOLNÁ, Eva. NEURONOVÉ SÍTĚ 1. 2008, Ostravská univerzita v Ostravě.
- [6] *Artificial Neural Network | NVIDIA Developer* [online]. [cit. 2023-03-13]. Dostupné z: <https://developer.nvidia.com/discover/artificial-neural-network>
- [7] SHARMA, Siddharth, Simone SHARMA a Anidhya ATHAIYA. ACTIVATION FUNCTIONS IN NEURAL NETWORKS. *International Journal of Engineering Applied Sciences and Technology* [online]. 2020, **4**, 310–316 [cit. 2023-05-26]. Dostupné z: <http://www.ijeast.com>
- [8] *Deploying a Scalable Object Detection Inference Pipeline, Part 1 | NVIDIA Technical Blog* [online]. [cit. 2023-05-23]. Dostupné z: <https://developer.nvidia.com/blog/deploying-a-scalable-object-detection-inference-pipeline/?tags=&categories=>
- [9] *Neural networks in the automotive world* [online]. [cit. 2023-05-23]. Dostupné z: <https://resources.pcb.cadence.com/blog/neural-networks-in-the-automotive-world-2>
- [10] KEBRIA, Parham M., Abbas KHOSRAVI, Syed Moshfeq SALAKEN a Saeid NAHAVANDI. Deep imitation learning for autonomous vehicles based on convolutional neural networks. *IEEE/CAA Journal of Automatica Sinica* [online]. 2020, **7**(1), 82–95 [cit. 2023-05-26]. ISSN 23299274. Dostupné z: doi:10.1109/JAS.2019.1911825
- [11] *How ReLU and Dropout Layers Work in CNNs | Baeldung on Computer Science* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.baeldung.com/cs/ml-relu-dropout-layers>
- [12] *All about Neural Network and Deep Learning in Vehicles | dubizzle* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.dubizzle.com/blog/cars/neural-network-deep-learning-in-vehicles/>

- [13] BALASUBRAMANIAM, Abhishek a Sudeep PASRICHA. Object Detection in Autonomous Vehicles: Status and Open Challenges [online]. 2022 [cit. 2023-05-26]. Dostupné z: <https://arxiv.org/abs/2201.07706v1>
- [14] JUYAL, Amit, Sachin SHARMA a Priya MATTA. Deep Learning Methods for Object Detection in Autonomous Vehicles. *Proceedings of the 5th International Conference on Trends in Electronics and Informatics, ICOEI 2021* [online]. 2021, 751–755 [cit. 2023-05-23]. Dostupné z: doi:10.1109/ICOEI51242.2021.9452932
- [15] *R-CNN, Fast R-CNN, Faster R-CNN, YOLO — Object Detection Algorithms* / by Rohith Gandhi / *Towards Data Science* [online]. [cit. 2023-05-23]. Dostupné z: <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>
- [16] *SSD object detection: Single Shot MultiBox Detector for real-time processing* / by Jonathan Hui / *Medium* [online]. [cit. 2023-05-23]. Dostupné z: <https://jonathan-hui.medium.com/ssd-object-detection-single-shot-multibox-detector-for-real-time-processing-9bd8deac0e06>
- [17] *What is an Autonomous Vehicle? - TWI* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.twi-global.com/technical-knowledge/faqs/what-is-an-autonomous-vehicle>
- [18] *Umělá inteligence vs. Homo sapiens adaptabilis* | by GUG.cz | *Medium* [online]. [cit. 2023-05-22]. Dostupné z: <https://medium.com/@GUG.cz/um%C4%9B%C3%A1-inteligence-vs-homo-sapiens-adaptabilis-6daf570ffab3>
- [19] *What is an Autonomous Car? – How Self-Driving Cars Work* / Synopsys [online]. [cit. 2023-05-23]. Dostupné z: <https://www.synopsys.com/automotive/what-is-autonomous-car.html>
- [20] *Matematická biologie učebnice: Koncept umělé neuronové sítě* [online]. [cit. 2023-05-23]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickyh-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [21] *SAE J3016 automated-driving graphic* [online]. [cit. 2023-05-26]. Dostupné z: <https://www.sae.org/news/2019/01/sae-updates-j3016-automated-driving-graphic>
- [22] *Convolutional Neural Network - javatpoint* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.javatpoint.com/pytorch-convolutional-neural-network>
- [23] *Autonome Autos: Modi statt Stufen* [online]. [cit. 2023-05-26]. Dostupné z: <https://www.next-mobility.de/autonome-autos-modi-statt-stufen-a-697aed11f6156d41e30ce3e2357fc79e/>
- [24] *Dekonvoluce a Konvoluce* | Optixs | OptiXs [online]. [cit. 2023-05-23]. Dostupné z: <https://www.optixs.cz/slovník-17/dekonvoluce-a-konvoluce-68s>
- [25] KOCIĆ, Jelena, Nenad JOVIČIĆ a Vujo DRNDAREVIĆ. An End-to-End Deep Neural Network for Autonomous Driving Designed for Embedded Automotive Platforms.

- Sensors (Basel, Switzerland)* [online]. 2019, **19**(9) [cit. 2023-05-23]. ISSN 14248220. Dostupné z: doi:10.3390/S19092064
- [26] *Convolutional Neural Networks, Explained | by Mayank Mishra | Towards Data Science* [online]. [cit. 2023-05-23]. Dostupné z: <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939>
- [27] *History of Autonomous Cars - TOMORROW'S WORLD TODAY®* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.tomorrowworldtoday.com/2021/08/09/history-of-autonomous-cars/>
- [28] *History of the Autonomous Car* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.titlemax.com/resources/history-of-the-autonomous-car/>
- [29] *Navigating the future of autonomous vehicles | Infomineo* [online]. [cit. 2023-05-26]. Dostupné z: <https://infomineo.com/navigating-the-future-of-autonomous-vehicles/>
- [30] *Autonomous vehicles at night | ADAS & Autonomous Vehicle International* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.autonomousvehicleinternational.com/opinion/autonomous-vehicles-at-night.html#prettyPhoto>
- [31] *Advantages and disadvantages of autonomous vehicles* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.bbva.ch/en/news/advantages-and-disadvantages-of-autonomous-vehicles/>
- [32] KOCIC, Jelena, Nenad JOVICIC a Vujo DRNDAREVIC. *Sensors and Sensor Fusion in Autonomous Vehicles. 2018 26th Telecommunications Forum, TELFOR 2018 - Proceedings* [online]. 2018 [cit. 2023-05-23]. Dostupné z: doi:10.1109/TELFOR.2018.8612054
- [33] *Znáte úrovně autonomních vozidel? | Auta.cz* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.auta.cz/clanek/urovne-samoridici/>
- [34] *How Does a Self-Driving Car See? | NVIDIA Blog* [online]. [cit. 2023-05-23]. Dostupné z: <https://blogs.nvidia.com/blog/2019/04/15/how-does-a-self-driving-car-see/>
- [35] CAMPBELL, Sean, Niall O'MAHONY, Lenka KRPALCOVA, Daniel RIORDAN, Joseph WALSH, Aidan MURPHY a Conor RYAN. *Sensor Technology in Autonomous Vehicles: A review. 29th Irish Signals and Systems Conference, ISSC 2018* [online]. 2018 [cit. 2023-05-23]. Dostupné z: doi:10.1109/ISSC.2018.8585340
- [36] *Can the 3 Modes of Autonomous Driving Replace the SAE 5 Levels* [online]. [cit. 2023-05-23]. Dostupné z: https://www.linkedin.com/pulse/can-3-modes-autonomous-driving-replace-sae-5-levels-florian-petit?trk=read_related_article-card_title
- [37] *Getting to Know Autonomous Vehicles | NVIDIA Technical Blog* [online]. [cit. 2023-05-26]. Dostupné z: <https://developer.nvidia.com/blog/getting-to-know-autonomous-vehicles/>

- [38] *Self-Driving Car Hardware | NVIDIA Drive* [online]. [cit. 2023-05-26]. Dostupné z: <https://www.nvidia.com/en-us/self-driving-cars/hardware/>
- [39] *How Autonomous Vehicles Sensors Fusion Helps Avoid Deaths | Intellias Blog* [online]. [cit. 2023-05-23]. Dostupné z: <https://intellias.com/sensor-fusion-autonomous-cars-helps-avoid-deaths-road/>
- [40] *NVIDIA Introduces DRIVE AGX Orin — Advanced, Software-Defined Platform for Autonomous Machines | NVIDIA Newsroom* [online]. [cit. 2023-05-26]. Dostupné z: <https://nvidianews.nvidia.com/news/nvidia-introduces-drive-agx-orin-advanced-software-defined-platform-for-autonomous-machines>
- [41] *DRIVE Software for Autonomous Vehicles | NVIDIA* [online]. [cit. 2023-05-26]. Dostupné z: <https://www.nvidia.com/en-us/self-driving-cars/software/>
- [42] *NVIDIA DRIVE OS | NVIDIA Developer* [online]. [cit. 2023-05-26]. Dostupné z: <https://developer.nvidia.com/drive/driveos>
- [43] *DriveWorks SDK | NVIDIA Developer* [online]. [cit. 2023-05-26]. Dostupné z: <https://developer.nvidia.com/drive/driveworks>
- [44] *NVIDIA DRIVE SDK | NVIDIA Developer* [online]. [cit. 2023-05-26]. Dostupné z: <https://developer.nvidia.com/drive/drive-sdk#driveav>
- [45] *What Coding Language Does Self-driving Cars Use? | Self Driving Project* [online]. [cit. 2023-05-23]. Dostupné z: <http://selfdriveproject.com/what-coding-language-does-self-driving-cars-use/>
- [46] *The Race for Self-Driving Cars - The New York Times* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.nytimes.com/interactive/2016/12/14/technology/how-self-driving-cars-work.html??mtrref=undefined&gwh=2167B6F5FE8CA1C0181F23A1F86634B3&gwt=pay&assetType=PAYWALL>
- [47] *10 Best Python Libraries for Deep Learning (2023) - Unite.AI* [online]. [cit. 2023-05-23]. Dostupné z: <https://www.unite.ai/10-best-python-libraries-for-deep-learning/>
- [48] *DRIVE Labs: Classifying Traffic Signs and Traffic Lights with SignNet and LightNet DNNs | NVIDIA Technical Blog* [online]. [cit. 2023-05-23]. Dostupné z: <https://developer.nvidia.com/blog/drive-labs-signnet-and-lighnet-dnns/>
- [49] *DRIVE Labs: Detecting Road Markings and Landmarks with High Precision | NVIDIA Technical Blog* [online]. [cit. 2023-05-23]. Dostupné z: <https://developer.nvidia.com/blog/drive-labs-detecting-road-markings-and-landmarks-with-high-precision/>
- [50] *Advancing Autonomous Valet Functionality with Parking Sign Assist | NVIDIA Technical Blog* [online]. [cit. 2023-05-23]. Dostupné z: <https://developer.nvidia.com/blog/advancing-autonomous-valet-functionality-with-parking-sign-assist/>

- [51] *Introducing DRIVE AP2X Complete Level 2+ Platform | NVIDIA Blog* [online]. [cit. 2023-05-26]. Dostupné z: <https://blogs.nvidia.com/blog/2019/03/18/drive-ap2x-worlds-most-complete-level-2-platform/>
- [52] *DRIVE Labs: Helping Cameras See Clearly with AI | NVIDIA Technical Blog* [online]. [cit. 2023-05-26]. Dostupné z: <https://developer.nvidia.com/blog/drive-labs-helping-cameras-see-clearly-with-ai/>
- [53] *DRIVE Hyperion Autonomous Vehicle Development Platform | NVIDIA Developer* [online]. [cit. 2023-05-26]. Dostupné z: <https://developer.nvidia.com/drive/hyperion>

SEZNAM POUŽITÝCH ZKRATEK A SYMBOLŮ

| | |
|-------|---|
| AI | Artificial Intelligence |
| ML | Machine Learning |
| DL | Deep Learning |
| ReLU | Rectified Linear Unit |
| CPU | Central Processing Unit |
| GPU | Graphics Processing Unit |
| CUDA | Compute Unified Device Architecture |
| DNN | Deep Neural Network |
| CNN | Convolutional Neural Network |
| RNN | Recurrent Neural Network |
| FC | Fully Connected |
| LiDAR | Light Detection And Ranging |
| 3D | Označení trojrozměrného prostoru |
| GPS | Global Positioning System |
| SAE | Society of Automotive Engineers |
| ADAS | Advanced Driver-Assistance System |
| BASt | Bundesanstalt für Straßenwesen |
| IMU | Inertial Measurement Unit |
| INS | Inertial Navigation System |
| ADAM | Adaptive Moment Estimation |
| ECU | Electronic Control Unit |
| R-CNN | Region-based Convolutional Neural Network |
| SSD | Single Shot MultiBox Detector |
| YOLO | You Only Look Once |
| HD | High Definition |
| PSA | Parking Sign Assist |