



# METODY PŘEDZPRACOVÁNÍ OBRAZU PRO AUTOMATICKOU DETEKCI ÚČASTNÍKŮ SILNIČNÍHO PROVOZU

## IMAGE PRE-PROCESSING METHODS USED FOR AUTOMATIC DETECTION OF ROAD USERS

Jan Berg<sup>1,\*</sup>, Petr Jilek<sup>2</sup>, Jan Pokorný<sup>3</sup> a Jan Krmela<sup>4</sup>

**Abstrakt** *Hlavním cílem tohoto článku je provést analýzu metod předzpracování obrazu a uvést jednotlivé autory a publikace, které se jimi zabývají. Za účelem získání systematického přehledu je v článku navržena metodika pro vyhledávání jednotlivých relevantních zdrojů. Metody předzpracování obrazu předcházejí automatické detekci účastníků silničního provozu. Díky vhodně zvolenému postupu předzpracování obrazu je automatická detekce přesnější a rychlejší stejně jako následující klasifikace detekovaných objektů a jejich trasování. Vhodné předzpracování obrazu se využívá jak u standardní metody detekce odečítání pozadí, tak u moderních metod pracujících na principu neuronových sítí jako CNN, YOLO, SSD a další. Obsahem článku je přehled jednotlivých nejčastěji využívaných metod předzpracování obrazu a publikací, ve kterých je jednotliví autoři využívají pro přípravu obrazu před různými metodami automatické detekce. Následuje vyhodnocení výsledků a na závěr jsou navrženy směry dalšího výzkumu v této oblasti.*

**Klíčová slova** *předzpracování obrazu, filtrování obrazu, denoising, matematická morfologie, thresholding, automatická detekce*

**Abstract** The main objective of this paper is to conduct an analysis of image pre-processing methods and to state individual authors and publications dealing with them. In order to obtain a systematic review, a methodology of relevant sources' searching is proposed in the article. The methods of image pre-processing precede the automatic detection of road users. Thank to suitably chosen image pre-processing process is the automatic detection more accurate and faster as well as consequent classification of the detected objects and their tracking. Suitable image pre-processing is used by the standard background subtraction method and by modern methods working on the principle of neural networks like CNN, YOLO, SSD etc. The content of this article is a review of individual most commonly used pre-processing methods and publications, where individual authors use them to prepare frames prior to various automatic detection methods. An evaluation of results follows and in the conclusion ways for further research are proposed based on the analysis.

**Keywords** image pre-processing, filtering, denoising, mathematical morphology, thresholding, automatic detection

---

<sup>1, 3, 4</sup> Univerzita Pardubice, Dopravní Fakulta Jana Pernera, Katedra dopravních prostředků a diagnostiky, Studentská 95, 532 10 Pardubice, Česká republika.

<sup>2</sup> Univerzita Pardubice, Dopravní Fakulta Jana Pernera, Výukové a výzkumné centrum v dopravě, Studentská 95, 532 10 Pardubice, Česká republika.

\*Korespondenční autor, email: [jan.berg@upce.cz](mailto:jan.berg@upce.cz)

## 1 ÚVOD

Analýza provozu na pozemních komunikacích je klíčovým procesem pro získání dat z reálného provozu, získání povědomí o charakteru provozu v konkrétních dopravních uzlech, pro získání povědomí o chování řidičů v konkrétních situacích, čímž významně přispívá k zabezpečení maximální možné míry bezpečnosti na pozemních komunikacích. Možnosti, které nabízí automatická detekce účastníků silničního provozu, mohou být využity pro neustálou a důkladnou analýzu provozu jak ze záznamu, tak v reálném čase v jakýchkoli dopravních uzlech bez potřeby zásahu a práce člověka. V současnosti existují systémy, které automaticky shromažďují a vyhodnocují vybrané dopravní veličiny, jako např. systémy LIDAR, které dosahují vysoké přesnosti. Nicméně, jejich použití je relativně drahé oproti využití standardních dohledových dopravních kamer. Pokud se kamerový záznam z dopravního uzlu využije jako vstup do specializovaného programu, který jej předzpracuje, detekuje účastníky silničního provozu, klasifikuje je a trasuje a dokáže vyhodnotit požadované veličiny s předem definovanou přesností, pak se tato metoda stává velmi efektivním nástrojem v oblasti analýzy a řízení provozu na pozemních komunikacích. Navíc, použití dopravních kamer není ve srovnání s jejich potenciálem nákladné, jsou již velmi rozšířené, nevyžadují žádnou náročnou a drahou údržbu a snadno se integrují do dopravní infrastruktury. Účelem tohoto článku je poskytnout přehled metod předzpracování dopravních kamerových záznamů, které se dále využívají pro automatickou detekci účastníků silničního provozu.

Hlavní motivací k provedení tohoto přehledu byla skutečnost, že existuje mnoho článků, které podrobně popisují jednotlivé metody automatické detekce účastníků silničního provozu, ať už standardní metody založené na odečítání pozadí nebo moderní metody jako YOLO, CNN, SSD a další, jejich klasifikaci a sledování. Navíc je k dispozici množství přehledů, průzkumů a analýz týkajících se metod automatické detekce, ale téměř žádný z nich není zaměřen na přípravu videozáznamů ve formě použití vhodných metod předzpracování, přestože se jedná o důležitý krok před samotnou automatickou detekcí a dalšími funkcemi.

## 2 METODIKA VYHLEDÁVÁNÍ RELEVANTNÍCH ZDROJŮ

Oblast obecně automatické detekce objektů a v našem případě její podmnožina automatická detekce účastníků silničního provozu se rozvíjí již poměrně dlouhou dobu, za kterou bylo nashromážděno a publikováno velké množství zdrojů, přičemž vývoj v této oblasti postupuje velmi rychle. Z tohoto důvodu bylo potřeba definovat kritéria pro provedení filtrovaného vyhledávání. Relevantní zdroje byly vyhledávány v databázích „*Web of Science*“ a „*Scopus*“ a poté filtrovány podle tří kritérií: stáří článku, množství citací a celková relevance. Byly vyhledány zdroje mladší než 5 let, starší byly přípustné pouze tehdy, když měly relevantní obsah a vyšší počet citací. Dalším kritériem bylo, že článek musel být přístupný jako Open Access.

Klíčová slova, která byla použita k vyhledávání zdrojů týkajících se předzpracování videozáznamů v oblasti automatické detekce vozidel, byla: „*automatic traffic analysis image pre-processing*“, „*image pre-processing vehicle detection*“ a „*pre-processing video records automatic vehicle detection*“. Vzhledem k tomu, že nebyly nalezeny žádné relevantní zdroje zabývající se výhradně předzpracováním obrazu za účelem detekce účastníků silničního provozu, byla použita klíčová slova pro vyhledávání: „*automatic vehicle tracking*“, „*automatic traffic analysis*“ a „*automatic vehicle detection*“ a vyhledány tak dokumenty týkající se automatické detekce vozidel nebo analýzy provozu a ty byly prohledány pro nalezení používaných metod předzpracování obrazu jednotlivými autory.

Po prohledání výše uvedených databází bylo nalezeno pro klíčová slova „*automatic vehicle tracking*“ dohromady 6 046 záznamů. Po vyfiltrování záznamů podle stáří a Open access přístupu jich zbylo 842. Po jejich vyfiltrování dle relevance vzhledem k požadovanému tématu byly použity 4 články, přičemž byly použity i dva články starší vzhledem k jejich relevanci a relativně vysokému počtu citací.

Pro klíčová slova „*automatic traffic analysis*“ bylo nalezeno celkem 7 398 publikací, přičemž po eliminaci zdrojů starších než 5 let a označení Open access článků zbylo 983 záznamů. Po filtrování zdrojů dle relevance bylo využito 7 článků a 1 článek starší vzhledem k jeho relevanci a počtu citací.

Po zadání klíčových slov „*automatic vehicle detection*“ bylo vyfiltrováno 10 221 záznamů. Po jejich selekci stářím a Open access jich zbylo 1 629. Z těchto zdrojů bylo použito pro účely tohoto článku 13 zdrojů, přičemž další 3 byly použity vzhledem ke své relevanci a relativně vysokému počtu citací i přes jejich stáří vyšší než 5 let.

Při analýze souhrnných zdrojů typu „*review*“, „*survey*“ nebo „*research*“ bylo po filtraci stářím a Open access nalezeno dohromady 6 relevantních zdrojů, které jsou dále analyzovány.

Jak bylo již zmíněno výše, tím, že nebyly nalezeny zdroje, u nichž by již z názvu nebo klíčových slov bylo patrné, že se zabývají předzpracováním obrazu, bylo potřeba projít relativně vysoký počet záznamů, které se týkají primárně detekce nebo trasování vozidel a automatickou analýzou provozu a z nich vybrat pouze několik zdrojů, které zmiňují hledané metody předzpracování obrazu.

## 2.1 Analýza relevantních souhrnných zdrojů

Za účelem získání přehledu, jaké shrnující publikace byly v této oblasti již publikovány a k jakým jednotliví autoři došli závěrům, bylo provedeno podrobné vyhledávání pomocí klíčových slov uvedených výše, ke kterým byla přidána slova „*review*“, „*survey*“ nebo „*research*“. Stejně jako v případě jednotlivých článků, nebyly k dispozici žádné relevantní shrnující zdroje zabývající se výhradně předzpracováním obrazu ve vztahu k automatické detekci účastníků silničního provozu. Z tohoto důvodu byly hledány tyto zdroje také v oblasti automatické detekce vozidel nebo automatické analýzy provozu na pozemních komunikacích a tyto dokumenty byly prozkoumány, aby bylo možné nalézt informace o nejčastěji používaných metodách předzpracování.

Razi et al. (2022) provedli důkladný průzkum, který se týkal počítačového vidění používaného v automatické analýze provozu. Autoři popisují a porovnávají jednotlivé metody automatické detekce a sledování vozidel, jejich klasifikaci, segmentaci obrazu a automatické rozpoznávání událostí. Obsahem tohoto článku je rovněž pasáž týkající se metod předzpracování obrazu. Autoři popisují Super Resolution jako první fázi předzpracování, kdy jsou snímky upravovány metodou založenou na učení Single Image Super-Resolution nebo Video Super-Resolution. Tyto metody obecně zvyšují rozlišení obrazu a zlepšují jeho kvalitu. V další části autoři rozdělují odrušovací metody na konvenční (vyhlazování, interpolace nebo filtrování v časové, frekvenční nebo vlnové oblasti) a novější metody založené především na hlubokém učení (deep learning). Uvádějí jednu z nevýhod konvenčních metod, kdy jejich parametry je třeba nastavit ručně, což je činí neflexibilními. Naopak high-level metody jsou obvykle založeny na neuronových sítích a jsou schopny se přizpůsobit konkrétním podmínkám v nahrávkách a učit se z historie záznamu. Posledním krokem, který autoři navrhují, je stabilizace videa. Rozlišují mezi metodami založenými na obrazových bodech – pixelech (shoda bloku, informace o fázi a optický tok) a objektově založených metodách. Většina z nich kvůli jejich složitosti musí být provedena offline, ale v dnešní době jsou metody hlubokého učení dostatečně rychlé, aby mohly být provedeny i v reálném čase. Jiní autoři jako např. Zhao et al. (2019) uvádějí výhody použití metod hlubokého učení, neboť dokáží úspěšně pracovat i s jistou úrovní šumu a překrytím detekovaných objektů.

Kumar a Singh (2018), Li et al. (2022) a Jiao et al. (2019) analyzují existující metodu detekce a sledování vozidel na základě metod odečítání pozadí, hlubokého učení, CNN nebo YOLO, ale nesumarizují metody předzpracování obrazu použité před nimi.

Addala (2020) popisuje jednotlivé výzkumné týmy pracující na tomto tématu a poznatky a metody, které používají. V jedné kapitole uvádí také popis metod předzpracování, které se používají k přípravě záznamu pro automatickou detekci a přečtení registrační značky. Autoři nejdříve provedou binarizaci obrazu, změně

jeho velikost a poté pomocí Houghovy transformace detekují hrany. Po detekci hran provádějí na snímcích morfologické operace a poté provádí operace nastavení prahových hodnot (thresholding).

Autoři Waykole et al. (2021) uvádějí metody předzpracování obrazu používané k detekci jízdních pruhů, kdy obvykle odruší řešený snímek, pak nastaví vhodné prahové hodnoty (thresholding) pro získání binárního obrazu a pak následuje detekce jízdního pruhu – detektor hran (např. pomocí Canny Edge algoritmu nebo Houghovy transformace).

Podmnožinou oblasti detekce vozidla je také rozpoznávání registračních značek, protože mohou být s výhodou použity vzhledem k jejich kontrastu, umístění a zřetelných hran pro identifikaci, sledování vozidla a také pro automatickou kalibraci kamer na základě jejich normalizovaných rozměrů. V publikacích zabývajících se tímto tématem Shashirangana et al. (2021), Arafat et al. (2019), Yao et al. (2019) a Kaur et al. (2022) není bohužel od autorů žádná zmínka o použitých metodách předzpracování obrazu, ale pouze v Arafat et al. (2019) autoři stručně popisují metody předzpracování, které používají k rozpoznání SPZ. V jejich případě se jedná o binarizaci snímku a následně morfologické operace k extrakci a strojovou čitelnost jednotlivých znaků z registrační značky. V Yao et al. (2019) byl autory proveden návrh nové metody založené na SSD, ale autoři rovněž neposkytují informace o používaných metodách předzpracování.

### 3 METODY PŘEDZPRACOVÁNÍ OBRAZU PŘEDCHÁZEJÍCÍ AUTOMATICKÉ DETEKCI ÚČASTNÍKŮ SILNIČNÍHO PROVOZU

Díky použití vhodně nastavených a navržených metod nebo kombinací metod předzpracování obrazu je možné dosáhnout zlepšení automatické detekce účastníků silničního provozu a také ušetřit čas výpočtu. Ať už se jedná o standardní metodu detekce odečítání pozadí nebo o moderní metody YOLO, SSD, CNN a další, je žádoucí před aplikací samotné detekce odstranit ze snímků nízko- a vysokofrekvenční šum, upravit kontrast, histogram, vylepšit kontury a definovat oblasti zájmu (ROIs).

Každý digitální záznam lze chápat jako sekvenci jednotlivých snímků, které jsou definovány jako matice bodů (pixelů). Každý pixel obsahuje informace o své pozici a barvě. Pomocí správných algoritmů lze hodnoty pixelů upravit tak, aby odstranily nadměrný šum ze snímků, takže lze snadno detekovat okraje objektů, odstranit stíny a minimalizovat vliv pohybujícího se statického pozadí na detekci a sledování objektů zájmu. Následuje přehled nejčastěji používaných metod předzpracování snímků spolu s autory, kteří je používají.

#### 3.1 Filtrování

Nedokonalosti snímacího řetězce spolu s možnými nepříznivými okolními podmínkami expozice vytváří v obraze nežádoucí šum. Obecně rozlišujeme dva typy šumu: nízkofrekvenční, který je výsledkem nedokonalostí snímače nebo nečistot na objektivu a Gaussův, který je vysokofrekvenční a je výsledkem vysoké citlivosti snímače. Vlivem šumu v obraze se zhoršuje kvalita automatické detekce a z tohoto důvodu je žádoucí potlačit šum v obraze jednou z následujících metod filtrování.

##### Průměrové filtrování

Průměrové filtrování je základní metodou filtrování, kdy je hodnota každého pixelu vypočtena jako průměrná hodnota pixelů okolních. (Vácha 2016 a Kříž 2013).

##### Mediánové filtrování

Řešený pixel zde obdrží střední hodnotu (medián) vybraných seřazených obrazových bodů v jeho okolí. Metoda je využita například autory Guo et al. (2021), Crouzil et al. (2016), Kříž (2013) a Truchlík (2013).

## Gaussovské vyhlazení

Gaussovské vyhlazování je velmi často využívanou metodou používanou k odstranění šumu v obraze. Gaussův filtr (rovnice 1) je definován diskretní aproximací Gaussovy funkce a využívají ji například autoři Guo et al. (2021), Crouzil et al. (2016), Zhuang et al. (2016) nebo Vašička (2018).

$$F_G(a, b) = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{(a-\mu)^2+(b-\mu)^2}{2\sigma^2}} \quad (1)$$

kdy v použité veličiny v rovnici značí:  $\mu$  – střední hodnota,  $\sigma^2$  – rozptyl a  $a, b$  – poloha pixelu.

V tomto filtru hodnoty, které se vyskytují v masce zřídka, mají pouze nízkou váhu a naopak nejčastěji se vyskytující hodnoty mají váhu vysokou. Po aplikaci dojde ke zdatelnému vyhlazení obrazu s eliminací tzv. Gaussovského, tedy vysokofrekvenčního šumu. Tento filtr je potřeba správně nastavit, neboť přílišné vyhlazení snímků může rozostřit hrany objektů, které mají být detekovány (Truchlík 2013).

## Mix Gaussiánů

Tato metoda se rovněž velmi často používá a jedná se o nastavbu té předchozí, kdy se k popisu pixelu využívá hned několika Gaussovských funkcí. Za pozadí jsou označeny pixely s nízkým rozptylem a vysokou frekvencí, a naopak hodnoty, které neleží pod Gaussovou křivkou, představují popředí. Vzhledem k tomu, že hodnoty obrazových bodů prostředí jsou méně frekventované, jsou klasifikovány jako Gaussovy s nejvyšším rozptylem a ovlivňují hodnotu řešeného pixelu nejméně. Jedná se o velmi robustní metodu, která dokáže odfiltrout nežádoucí pohyb pozadí v obraze (např. pohyb vlajek nebo větví stromů ve větru), ale vyžaduje vyšší výpočetní výkon (Karim 2018, Vácha 2016, Song et al. 2019, Moutakki et al. 2018, Zhuang et al. 2016, Yaghoobi et al. 2018 a Crouzil et al. 2016) k jejímu použití.

## High-level metody

V současné době dochází k rozvoji metod založených na hlubokém učení (deep learning). Tyto metody jsou založeny na neuronových sítích a mohou se naučit automaticky se přizpůsobit individuálním podmínkám ve snímcích (Chakraborty et al. 2019 a Yuan et al. 2014), díky čemuž je jejich účinnost velmi vysoká. V tomto případě autoři Plötz a Roth (2017) a Abdelhamed et al. (2018) dokonce vytvořili model syntetického aditivního bílého Gaussova šumu, který simuluje šum ve snímku. Díky tomu lze opakovaně testovat vliv odstranění šumu na jednotlivé metody automatické detekce i samotné odrušovací algoritmy a vzájemně je porovnávat. Schopnost učit se těchto metod může pomoci autorům např. odstranit šum způsobený deštěm nebo poškrábáním skla objektivu kamery, což jsou příklady dvou vzájemně odlišných typů šumu (Razi et al. 2022). Na obrázku 1 je příklad pokročilého odrušení obrazu u málo osvětleného přiblíženého snímku.



Obrázek 1 – příklad odrušení obrazu za slabého osvětlení (levý horní – šumový snímek za slabého osvětlení, pravý horní – zvětšená oblast z prvního snímku, levý dolní – zprůměrovaný obraz s vadnými pixely, pravý dolní – opravené vadné pixely) (Abdelhamed et al. 2018)

### 3.2 Nastavení prahových hodnot (thresholding)

Nastavení prahových hodnot obecně na základě stanovené podmínky převádí obraz na binární. Klíčová je zde definovaná hranice, která od sebe odděluje pixely, jimž bude přiřazeno 0 (bude zobrazeno jako černá a bude reprezentovat pozadí) a pixely, jimž bude přiřazeno 255 (zobrazí se jako bílá a představuje popředí). Častou praxí je použití metod matematické morfologie po provedení prahování z důvodu eliminace residuů nebo naopak vyplnění děr v detekovaných objektech.

Tato metoda se převážně používá u metody detekce odečítání pozadí. Příklad binárního obrazu je také znázorněn na obrázku 2. Metoda stanovení prahových hodnot je uvedena a použita v autory Guo et al. (2021), kde usnadňuje automatickou detekci uzávěru nádrže jeho obrysem. Dále autoři Vácha (2016), Beaupré et al. (2018), Najm a Ali (2020), Kříž (2013), Karim (2018), Seenouvang et al. (2016), Vašička (2018), Crouzil et al. (2016) a Chen et al. (2018) používají prahování pro vytvoření masky popředí obsahující detekovaná vozidla. V publikaci (Truchlík 2013) se používá převážně k odstranění stínů a Shahnaj et al. (2021) používá dvojí prahování jako segmentační metodu k extrakci čelních a koncových světel vozidel v noci.

### 3.3 Matematická morfologie

Matematická morfologie představuje sadu metod, které se používají při automatickém zpracování obrazu převážně na binárních obrazech. Tyto operace v kombinaci s jinými metodami předzpracování snímků usnadňují a zpřesňují automatickou detekci účastníků silničního provozu. Jejich hlavní funkcí je získávání úplných a přesných obrysů a jejich výplně detekovaných objektů. K operacím matematické morfologie se řadí:

- dilatace,
- eroze,
- otevření snímku,

- uzavření snímku.

Binární dilatace je základní morfologická operace, kdy dochází ke zvětšení obrysů objektu (na úkor pozadí) a vyplnění děr v detekovaných objektech. Používají se jako součást složitějších morfologických operací, ale může být také použita samostatně (Zhuang et al. 2016, Beaupré et al. 2018, Najm a Ali 2020 a Crouzil et al. 2016). Individuálně rovněž používá dilataci Shahnaj et al. (2021) pro zvýraznění čelních nebo koncových světel vozidel v nočních hodinách.

Binární eroze je duální operace pro binární dilataci a je založena na vektorovém rozdílu dvou sad bodů. Tato metoda oslabuje obrysy a je užitečná pro odstranění residuů v obraze. U eroze se tato operace častěji používá u složitějších morfologických operací, jako je otevírání nebo zavírání, ale samostatně se používá např. v (Najm a Ali 2020 nebo Crouzil et al. 2016).

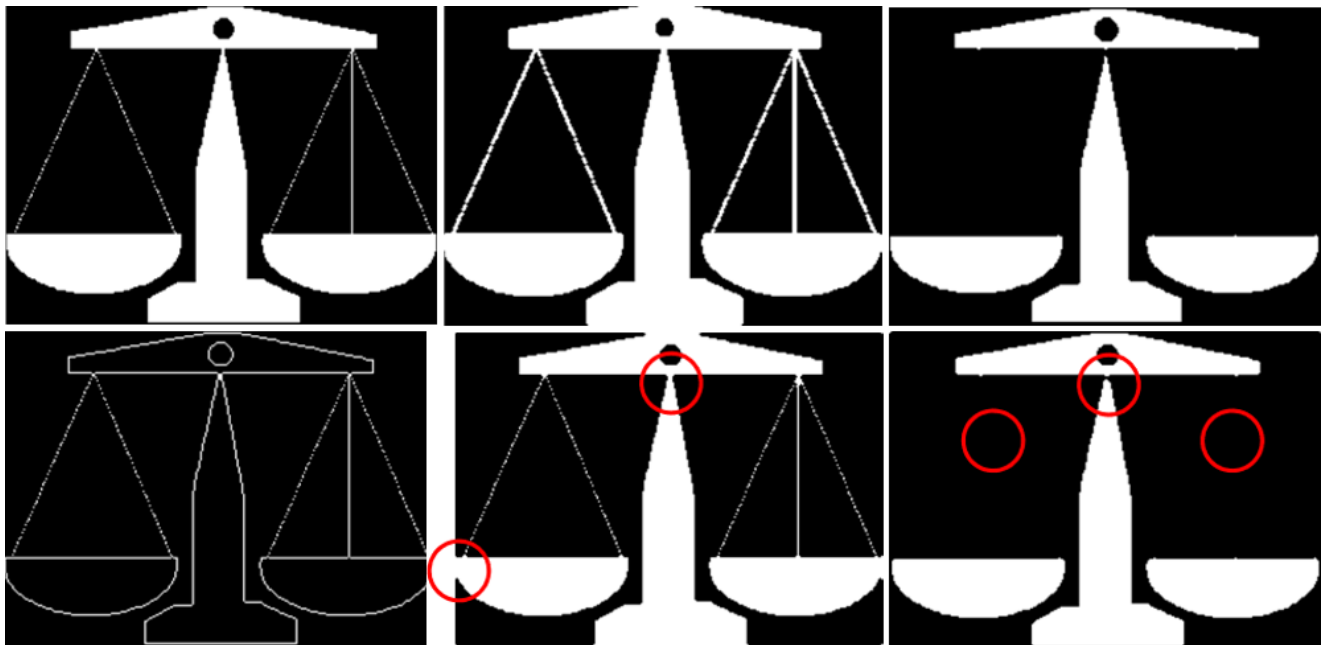
Při odečtení erodovaného snímku od původního lze získat obrys detekovaného objektu.

Otevření snímku je metoda, která kombinuje erozi a následně používá dilataci. Eroze nejprve odstraní residua, které jsou v masce popředí nežádoucí a dilatace následně obnoví původní objem obrysů objektu, které byly oslabeny erozí. (Najm a Ali 2020)

Operace zavření snímku je duální k otevření obrazu a skládá se z dilatace, kterou následuje eroze. Je vhodná pro připojení okolních objektů a plnění malých zálivů a děr (Horák, Seenouvong et al. 2016, Crouzil et al. 2016, Najm a Ali 2020, Vácha 2016 a Song et al. 2019).

Vašička (2018) používá metody matematické morfologie k odrušení snímků, dokonalejší detekci horizontálních dopravních značek a uzavření otvorů a zálivů v objektu. V publikacích (Sochor 2014, Vácha 2016 a Moutakki et al. 2018) autoři používají kombinaci morfologického otevírání a zavírání k eliminaci šumu v obraze. Pro přesnější detekci obrysu vozidla a eliminaci stínů používá Kříž (2013) erozi. Dále používá metody detekce hran a otevírání obrazu. Crouzil et al. (2016) používá funkci morfologického otevření k vyplnění dutin a k získání binární masky popředí s odstraněnými stíny.

Na následujícím obrázku 2 jsou znázorněny výše uvedené operace v binárním obraze.



Obrázek 2 – zobrazení morfologických operací; v horním řádku zleva: původní binární snímek, dilatovaný snímek, erodovaný snímek. Ve spodním řádku zleva: obrys původního snímku získaný odečtením erodovaného snímku od původního, uzavřený snímek, otevřený snímek (Horák)

## 4 PŘEVOD MEZI DEFINICEMI BAREV

### 4.1 Převod RGB na HSV

Pro účely automatického předzpracování snímku a práci se stíny a měnícím se osvětlení expozice je vhodnější použít formát, ve kterém je také přítomen jas každého pixelu. Proto se používá formát (H, S, V), kde první hodnota představuje odstín, druhá sytost a třetí hodnotu jasu. Tento model lze vizualizovat na válci nebo kuželu, kde je barevný odstín zobrazen v rozsahu 0-360°, sytost udává vzdálenost od středu v rozsahu 0-1, kdy tato vzdálenost označuje poměr šedé barvy v barevného odstínu a třetí hodnota „V“ charakterizuje vzdálenost od základny k vrcholu a její hodnota určuje jas barvy (Stratmann 2022). Tuto metodu používají například autoři Truchlík (2013) a Vašička (2018) pro efektivnější práci s odstíny, například při detekci stínů, barev semaforu nebo pro metody filtrování.

### 4.2 Převod RGB na stupně šedi

Při převodu obrazů z barevného spektra na spektrum stupňů šedi se počet hodnot definujících odstín pixelů sníží pouze na jednu, která určuje intenzitu šedi. Velmi často používanou aplikací je převod obrazu do binárního formátu pomocí nastavení prahových hodnot (thresholding). Převod barevných obrazů do stupňů šedi se používá například před použitím Houghovy transformace, která umožňuje automatické vyhledání přímek v obraze, pro snadnější detekci hran.

Tato metoda se například používá v publikaci (Kříž 2013, Crouzil et al. 2016, Najm a Ali 2020 a Truchlík 2013), kde slouží k odstranění stínů, dále v publikaci (Guo et al. 2021 a Truchlík 2013), kde autoři následně používají Houghovu transformaci.

V následující tabulce 1 je uveden přehled metod předzpracování používaných jednotlivými autory v jejich publikacích.

Tabulka 1 – Přehled metod předzpracování používaných jednotlivými autory

Publikace	Autor	Použité metody předzpracování
A Video-Based System for Vehicle Speed Measurement in Urban Roadways.	Luvizon et al.	<ul style="list-style-type: none"> <li>• Binarizace,</li> <li>• vyhlazování histogramu (odrušení),</li> <li>• morfologická dilatace.</li> </ul>
Automatic Vehicles Detection, Classification and Counting Techniques / Survey.	Najm a Ali	<ul style="list-style-type: none"> <li>• Binarizace,</li> <li>• morfologické operace,</li> <li>• odrušení.</li> </ul>
Research on Vision Perception Technology of Auto Fueling Robot on opencv-based gas tank cap recognition.	Guo et al.	<ul style="list-style-type: none"> <li>• Mediánové filtrování,</li> <li>• převod na stupně šedi,</li> <li>• Gaussovo vyhlazování,</li> <li>• Canny Edge algoritmus,</li> <li>• prahování.</li> </ul>
Vision-based vehicle detection and counting system using deep learning in highway scenes.	Song et al.	<ul style="list-style-type: none"> <li>• Gaussovské vyhlazování,</li> <li>• algoritmus plnění,</li> </ul>



Real-time vehicle detection with foregroundbased cascade classifier.	Zhuang et al.	<ul style="list-style-type: none"> <li>• morfologické operace.</li> </ul>
Automatic Vehicle Counting System for Traffic Monitoring.	Crouzil et al.	<ul style="list-style-type: none"> <li>• Morfologické operace.</li> <li>• Převod na stupně šedi,</li> <li>• Canny Edge algoritmus,</li> <li>• morfologické operace.</li> </ul>
Zlepšení sledování více objektů pomocí optického toku a předzpracování hran.	Beaupré et al.	<ul style="list-style-type: none"> <li>• Canny Edge algoritmus.</li> </ul>
Construction of a Robust Background Model for Moving Object Detection in Video Sequence.	Karim	<ul style="list-style-type: none"> <li>• Převod na stupně šedi,</li> <li>• prahování.</li> </ul>
Robust vehicle detection in different weather conditions: Using MIPM.	Yaghoobi et al.	<ul style="list-style-type: none"> <li>• Převod RGB na HSI,</li> <li>• binarizace,</li> <li>• nastavení prahových hodnot,</li> <li>• morfologické operace.</li> </ul>
Real-Time System Based on Feature Extraction for Vehicle Detection and Classification.	Moutakki et al.	<ul style="list-style-type: none"> <li>• Binarizace,</li> <li>• morfologické otevírání a zavírání,</li> <li>• Canny Edge algoritmus.</li> </ul>
Vision-Based On-Road Nighttime Vehicle Detection and Tracking Using Taillight and Headlight Features.	Parvin et al.	<ul style="list-style-type: none"> <li>• Převod RGB na HSV,</li> <li>• nastavení prahových hodnot,</li> <li>• morfologické operace.</li> </ul>

Přestože by bylo vhodné nastavení a použité varianty jednotlivých metod upřesnit, podrobnější analýza a kvantifikace vlivu jednotlivých používaných metod nemohla být provedena, neboť autoři neuvádějí bližší informace o nastavení metod předzpracování nebo jejich modifikací, které používají.

## 5 DISKUZE

Jak již bylo uvedeno v předchozím textu, přestože je předzpracování obrazu významným faktorem automatické detekce účastníků silničního provozu, většina autorů jejich použití pouze zmíní a neuvádějí informace o jejich konkrétním nastavení ani o modifikaci metod, které používají. Z průzkumu literatury vyplývá, že předzpracování obrazu se nejrozsáhleji používá u metody detekce odečítání pozadí, u high-level metod jako např. YOLO, CNN a další již v menší míře (zde postačí odrušení).

Jak plyne z provedené analýzy relevantních zdrojů, nejčastěji autoři v počátku předzpracování obrazu využívají Gaussovu metodu odrušení obrazu, která odstraní z obrazu nežádoucí šum. Poté převedou pomocí prahování obraz na binární a prostřednictvím morfologických operací upraví obrys a výplň objektů, které chtějí detekovat. Tím dosáhnou relativně vysoké přesnosti detekce i přes řadu rušivých vlivů v obraze.

Dále nebylo možné srovnat úspěšnost metod detekce jednotlivých autorů, protože na celkové hodnocení přesnosti detekce má vliv nejen fáze předzpracování obrazu, ale také fáze automatické detekce, která se svým nastavením a modifikacemi u jednotlivých autorů rovněž liší. Rovněž z důvodu absence obdobných řešerší, které by se zaměřovaly nebo alespoň uváděly metody předzpracování obrazu užití jednotlivými autory, nebylo možné výsledky této studie srovnat s dalšími. Jediné obdobné studie zmiňují metody předzpracování při automatické detekci registračních značek nebo jízdních pruhů, nicméně shrnutí metod

předzpracování obrazu pro automatickou detekci účastníků silničního provozu v dostupných zdrojích chybí.

## 5.1 Návrh dalšího výzkumu

Pro optimalizaci automatické detekce účastníků silničního provozu by bylo vhodné provést systematický výzkum metod předzpracování a určit jejich optimální nastavení a sekvenci. Pro takové testování je potřeba vytvořit standardizovaný dataset, který bude obsahovat předem dané podmínky, počet vozidel různých kategorií, požití kamery, jejich vnější a vnitřní konfiguraci a další.

## 6 ZÁVĚR

V rámci tohoto článku byl proveden popis jednotlivých metod předzpracování obrazu a popis, jakým způsobem je jednotliví autoři využívají před aplikací algoritmu pro automatickou detekci účastníků silničního provozu. Nicméně, autoři často tyto metody pouze zmiňují a chybí informace o jejich konkrétní modifikaci a nastavení parametrů. Využití předzpracování obrazu značně zvyšuje přesnost automatické detekce objektů a také časové nároky proběhnutí programu. V rámci tohoto článku bylo analyzováno použití metod filtrování jednotlivými autory, které se rozdělují na:

- průměrové filtrování,
- mediánové filtrování,
- Gaussovské vyhlazení,
- směs Gaussiánů.

Dále bylo analyzováno použití metody vyrovnání histogramu, thresholding, převod mezi jednotlivými definicemi barev z RGB na HSV nebo stupně šedi a morfologické operace, které jsou hojně využívány k vylepšení kontur a výplně detekovaných objektů a zahrnují:

- dilataci,
- erozi,
- morfologické otevření
- morfologické uzavření.

Cílem příspěvku bylo uvést metodiku použitou pro vyhledávání relevantních zdrojů, analyzovat rovněž relevantní souhrnné zdroje na dané téma a poté předvést přehled jednotlivých metod předzpracování obrazu za účelem automatické detekce účastníků silničního provozu a další práce s detekovanými objekty, které používají jednotliví autoři. V příspěvku je rovněž u každé metody popsáno, jakým způsobem ovlivňuje zpracováváný obraz. Jeho hlavní přínos lze spatřovat v prezentaci systematického přehledu užívání jednotlivých metod, pořadí, v jakém se tyto metody nejčastěji využívají a nastínění možného dalšího výzkumu. Prostor pro další výzkum je spatřován zejména v možnosti provést systematický výzkum metod předzpracování, vytvořit standardizovaný dataset videí, na kterých se vliv těchto metod ve spojení s jednotlivými metodami detekce bude testovat a kvantifikovat vliv použití jednotlivých metod, jejich kombinací a nastavení parametrů na přesnost detekce a výpočetní čas.

## Reference

- Seenouvang, N., Watchareeruetai U., Nuthong C., Khongsomboon K. a Ohnishi, N. **2016**. A computer vision based vehicle detection and counting system. *8th International Conference on Knowledge and Smart Technology (KST)*. DOI: 10.1109/KST.2016.7440510.
- Zhuang, X., Kang, W. a Qiuxia, U. **2016**. Real-time vehicle detection with foregroundbased cascade classifier. *IET Image Processing*, 10(4): 289-296.
- Crouzil, A., Khoudour, L., Valiere, P. a Truong, N. **2016**. Automatic Vehicle Counting System for Traffic Monitoring. *Journal of Electronic Imaging*. 25. 051207. 10.1117/1.JEI.25.5.051207.
- Koetsier, C., Busch, S. a Sester, M. **2019**. Trajectory extraction for analysis of unsafe driving behaviour. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-2/W13. Enschede, Netherlands.
- Najm, M. a Ali, Y. H. **2020**. Automatic Vehicles Detection, Classification and Counting Techniques / Survey. *Iraqi Journal of Science*, 61(7), 1811–1822. <https://doi.org/10.24996/ij.s.2020.61.7.30>
- Chen, X-Z, Liao, K-K., Chen, Y-L., Yu, C-W. a Wang, C. **2018**. A vision-based nighttime surrounding vehicle detection system. *7th International Symposium on Next Generation Electronics (ISNE)*. pp. 1-3, doi: 10.1109/ISNE.2018.8394717.
- Ooi, H. L., Bilodeau a G. A., Saunier, N. **2020**. Supervised and unsupervised detections for multiple object tracking in traffic scenes: A comparative study. In *International conference on image analysis and recognition* (pp. 42-55). Springer, Cham.
- Yaghoobi, E. N., Menéndez J. M. a Jiménez D. **2018**. Robust vehicle detection in different weather conditions: Using MIPM. *PLOS ONE* 13(3): e0191355. <https://doi.org/10.1371/journal.pone.0191355>.
- Yang, Y. a Bilodeau, G. A. **2017**. Multiple Object Tracking with Kernelized Correlation Filters in Urban Mixed Traffic. *14th Conference on Computer and Robot Vision (CRV)*, pp. 209-216, doi: 10.1109/CRV.2017.18.
- Karim, A. A. **2018**. Construction of a Robust Background Model for Moving Object Detection in Video Sequence. *Iraqi Journal of Science*, 59(2B), 969–979.
- Waykole, S., Shiwakoti, N. a Stasinopoulos, P. **2021**. Review on Lane Detection and Tracking Algorithms of Advanced Driver Assistance System. *Sustainability*. 13, 11417. <https://doi.org/10.3390/su132011417>.
- Moutakki, Z., Ouloul, M. I., Karim, A. a Abdellah, A. **2018**. Real-Time System Based on Feature Extraction for Vehicle Detection and Classification. *Transport and Telecommunication Journal*. 19. 93-102. 10.2478/ttj-2018-0008.
- Kaur, P., Kumar, Y. a Gupta, S. **2022**. Artificial Intelligence Techniques for the Recognition of Multi-Plate Multi-vehicle Tracking Systems: A Systematic Review. *Arch Computat Methods Eng*. <https://doi.org/10.1007/s11831-022-09753-4>.
- Guo, L., Liu, K., Zhang, L., Zhang, Y., Tian, Y. a Zhang, J. **2021**. Research on Vision Perception Technology of Auto Fueling Robot on opencv-based gas tank cap recognition. In *Journal of Physics: Conference Series* (Vol. 1952, No. 2, p. 022067). IOP Publishing.
- Razi, A., Chen, X., Li, H., Russo, B.J., Chen, Y. a Yu, H. **2022**. Deep Learning Serves Traffic Safety Analysis: A Forward-looking Review. *ArXiv*, abs/2203.10939.
- Stratmann, L. **2022**. HSV [online]. Dostupné z: <http://color.lukas-stratmann.com/>. [cit. 2022-02-22].
- Yaghoobi, E. N., Menéndez, J.M. a Jiménez, D. **2018**. Robust vehicle detection in different weather conditions: Using MIPM. *PLoS ONE* 13(3): e0191355. <https://doi.org/10.1371/journal.pone.0191355>.
- Beaupré, D. A., Bilodeau a G. A., Saunier, N. **2018**. Improving multiple object tracking with optical flow and edge preprocessing. *arXiv preprint arXiv:1801.09646*.

- Horák, K. *Matematická morfologie* [online]. Brno University of Technology: Computer Vision Group. Dostupné z: [http://vision.uamt.feec.vutbr.cz/ZVS/lectures/11\\_Matematicka\\_morfologie.pdf](http://vision.uamt.feec.vutbr.cz/ZVS/lectures/11_Matematicka_morfologie.pdf). [cit. 2022-02-24].
- Shashirangana, J., Padmasiri, H., Meedeniya, D. a Perera, C. **2021**. Automated License Plate Recognition: A Survey on Methods and Techniques. *IEEE Access*, vol. 9, pp. 11203-11225. doi: 10.1109/ACCESS.2020.3047929.
- Song, H., Liang, H., Li, H., Dai, Z. a Yun, X. **2019**. Vision-based vehicle detection and counting system using deep learning in highway scenes. *Eur. Transp. Res. Rev.* 11, 51. <https://doi.org/10.1186/s12544-019-0390-4>.
- Addala, S. **2020**. Research paper on vehicle detection and recognition. 10.13140/RG.2.2.34908.82561.
- Zhao, Z. Q., Zheng, P., Xu, S. T., and Wu, X. **2019**. Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30(11), 3212-3232.
- Kumar, V. a Singh, A. **2018**. Deep Learning based Vehicle Detection and Tracking Techniques: State-of-the-Art Survey. *International Journal of Computer Science and Information Security (IJCSIS)*, Vol. 16, No. 8. ISSN 1947-5500.
- Plötz, T. a Roth, S. **2017**. Benchmarking Denoising Algorithms with Real Photographs. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, p. 2750-9.
- Arafat, M. Y., Khairuddin, A., Khairuddin, U. a Paramesran, R. **2019**. Systematic review on vehicular licence plate recognition framework in intelligent transport systems. *IET Intelligent Transport Systems*. 13. 10.1049/iet-its.2018.5151.
- Chakraborty, P., Hegde a C., Sharma, A. **2019**. Data-driven parallelizable traffic incident detection using spatio-temporally denoised robust thresholds. *Transportation research part C: emerging technologies*. 105:81-99.
- Yao, L., Zhao, Y., Fan, J., Liu, M., Jiang, J. a Wan, Y. **2019**. Research and Application of License Plate Recognition Technology Based on Deep Learning. *Journal of Physics: Conference Series*, Vol 1237, Issue 2. <https://doi.org/10.1088/1742-6596/1237/2/022155>.
- Badue, C., Guidolini, R., Carneiro, R. V., Azevedo, P., Cardoso, V. B., Forechi, A., Jesusa, L., Berriela, R., Paixao, T., Mutzc, F., Veronesea, L., Oliveira-Santosa, T. a De Souza, A. F. **2021**. Self-driving cars: A survey. *Expert Systems with Applications*, 165, 113816.
- Parvin, S., Rozario, L. a Islam, Md. **2021**. Vision-Based On-Road Nighttime Vehicle Detection and Tracking Using Taillight and Headlight Features. *Journal of Computer and Communications*. 09. 29-53. 10.4236/jcc.2021.93003.
- Luvizon, D. C., Nassu, B. T. a Minetto, R. **2017**. A Video-Based System for Vehicle Speed Measurement in Urban Roadways. *Trans. Intell. Transport. Syst.* 18, 6, 1393-1404. <https://doi.org/10.1109/TITS.2016.2606369>
- Abdelhamed, A., Lin, S. a Brown, M. S. **2018**. A High-Quality Denoising Dataset for Smartphone Cameras. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. p. 1692-700.
- Lee, Y., Lee, S.-h., Yoo, J. a Kwon, S. **2021**. Efficient Single-Shot Multi-Object Tracking for Vehicles in Traffic Scenarios. *Sensors* 21, no. 19: 6358. <https://doi.org/10.3390/s21196358>
- Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z. a Qu, R. **2019**. A Survey of Deep Learning-Based Object Detection. *IEEE Access*, vol. 7, pp. 128837-128868. doi: 10.1109/ACCESS.2019.2939201.
- Li, Y., Wang, J., Huang, J. a Li, Y. **2022**. Research on Deep Learning Automatic Vehicle Recognition Algorithm Based on RES-YOLO Model. *Sensors (Basel)*. 22(10):3783. doi: 10.3390/s22103783.

Yuan, Z., Xie, X., Hu, J. a Yao, D. **2014**. An Efficient Method for Traffic Image Denoising. *Procedia-Social and Behavioral Sciences*. 138:439-45.

Ooi, H-L., Bilodeau, G-A. a Saunier, N. **2019**. Tracking in Urban Traffic Scenes from Background Subtraction and Object Detection. In: Karray, F., Campilho, A., Yu, A. (eds) *Image Analysis and Recognition*. ICIAR 2019. Lecture Notes in Computer Science(), vol 11662. Springer, Cham. [https://doi.org/10.1007/978-3-030-27202-9\\_17](https://doi.org/10.1007/978-3-030-27202-9_17).

Vácha, L. **2016**. Detekce aut přijíždějících ke křižovatce. Diplomová práce. VUT Brno.

Truchlík, S. **2013**. Detekcia motorových vozidiel v 2D obraze. Diplomová práce. VŠB – Technická univerzita Ostrava.

Kříž, K. **2013**. Detekce dopravních prostředků a vyhodnocování jejich stavů z videozáznamů křižovatek. Diplomová práce. Masarykova univerzita Brno.

Vašička, A. **2018**. Detekce a klasifikace objektů v obraze z kamery. Diplomová práce. Univerzita Tomáše Bati ve Zlíně.

Sochor J. **2014**. Fully Automated Real-Time Vehicles Detection and Tracking with Lanes Analysis. In: *Proceedings of CESC 2014*. Smolenice: Technische Universität Wien s. 59-66. ISBN 978-3-9502533-6-8.