

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

ZLEPŠENIE KVALITY OBRAZOV Z
BEZPEČNOSNÝCH KAMIER
BAKALÁRSKA PRÁCA

2023
ONDREJ BUBLAVÝ

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

ZLEPŠENIE KVALITY OBRAZOV Z
BEZPEČNOSNÝCH KAMIER
BAKALÁRSKA PRÁCA

Študijný program: Aplikovaná informatika
Študijný odbor: Informatika
Školiace pracovisko: Katedra informatiky
Školiteľ: RNDr. Zuzana Černeková, PhD

Bratislava, 2023
Ondrej Bublavý



Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta:

Študijný program:

Študijný odbor:

Typ záverečnej práce:

Jazyk záverečnej práce:

Sekundárny jazyk:

Názov:

Anotácia:

Vedúci:

Katedra:

Vedúci katedry:

Dátum zadania:

Dátum schválenia:

garant študijného programu

.....
študent

.....
vedúci práce

PodĎakovanie: Tu môžete poďakovať školiteľovi, prípadne ďalším osobám, ktoré vám s prácou nejako pomohli, poradili, poskytli dáta a podobne.

Abstrakt

Slovenský abstrakt v rozsahu 100-500 slov, jeden odstavec. Abstrakt stručne sumarizuje výsledky práce. Mal by byť pochopiteľný pre bežného informatika. Nemal by teda využívať skratky, termíny alebo označenie zavedené v práci, okrem tých, ktoré sú všeobecne známe.

Kľúčové slová: jedno, druhé, tretie (prípadne štvrté, piate)

Abstract

Abstract in the English language (translation of the abstract in the Slovak language).

Keywords:

Obsah

Úvod	1
1 Výzvy a riešenia kvality obrazu bezpečnostných kamier	3
1.1 Atribúty kvality záznamu	3
1.1.1 Všeobecne relevantné atribúty kvality videa	3
1.1.2 Atribúty kvality osobitých bezpečnostných kamerám	5
1.2 Existujúce prístupy a riešenia	6
1.2.1 Zvýšenie rozlíšenia na základe databázy blokov vysokej kvality	6
1.2.2 Zvýšenie rozlíšenia prevzorkovaním	7
1.2.3 Zlepšenie separovania odtieňov	9
1.2.4 Kontextová fúzia	11
1.3 Súhrn východísk	12
2 Ciele a metodika práce	13
2.1 Čas nasadenia algoritmu	13
2.2 Testovacie dáta	14
2.3 Návrh testovacieho programu	17
2.3.1 Voľba programovacieho jazyka a knižníc	18
2.3.2 Porovnávanie výsledkov	18
2.3.3 Aplikácia algoritmov	19
2.4 Testované algoritmy	19
2.4.1 Zaostrenie obrazu	20
2.4.2 Odstránenie šumu	20
2.4.3 Zlepšenie kontrastu	21
2.4.4 Odstránenie rozmazania	22
2.4.5 Zvýšenie rozlíšenia	22
2.4.6 Rekolorizácia	22
2.4.7 Detekcia pohybu pomocou IR/Termo spektra	22
Záver	23

Príloha A	29
Príloha B	31

Zoznam obrázkov

1.1	Porovnanie záberu zachytávajúceho scénu vo vysokom (naľavo) a v nízkom (napravo) dynamickom rozsahu [10]	5
1.2	Myšlienka ukladania každého k-teho záberu v pôvodnom rozlíšení z článku [2]	7
1.3	Výsledok (napravo) aplikácie prístupu [20] na rozmazaný záber (naľavo)	9
2.1	Ukážky testovacieho záznamu z kamery Annke T200	15
2.2	Ukážka videa Hikvision_dark_close	15
2.3	Ukážka videa Hikvision_dark_distant	16
2.4	Ukážka videa student_street	16
2.5	Ukážka videa parking	17
2.6	Ukážka výsledku odstraňovania šumu nelokálnym priemerovaním z článku [3]. Naľavo je pôvodný obraz, uprostred obraz zašumený Gaussovským šumom a napravo je obraz po aplikácii algoritmu. Všimnime si, že táto fotografia je veľmi vhodná na jeho nasadenie, pretože obsahuje veľa opakujúcich sa častí, priemerovaním medzi ktorými možno spoľahlivo odstrániť šum.	21

Zoznam tabuliek

Úvod

Cieľom tejto práce je poskytnúť študentom posledného ročníka bakalárskeho štúdia informatiky kostru práce v systéme LaTeX a ukážku užitočných príkazov, ktoré pri písaní práce môžu potrebovať. Začneme stručnou charakteristikou úvodu práce podľa smernice o záverečných prácach [29], ktorú uvádzame ako doslovný citát.

Úvod je prvou komplexnou informáciou o práci, jej celi, obsahu a štruktúre. Úvod sa vzťahuje na spracovanú tému konkrétne, obsahuje stručný a výstižný opis problematiky, charakterizuje stav poznania alebo praxe v oblasti, ktorá je predmetom školského diela a oboznamuje s významom, cieľmi a zámermi školského diela. Autor v úvode zdôrazňuje, prečo je práca dôležitá a prečo sa rozhodol spracovať danú tému. Úvod ako názov kapitoly sa nečísluje a jeho rozsah je spravidla 1 až 2 strany.

V nasledujúcej kapitole nájdete ukážku členenia kapitoly na menšie časti a v kapitole ?? nájdete príkazy na prácu s tabuľkami, obrázkami a matematickými výrazmi. V kapitole ?? uvádzame klasický text Lorem Ipsum a na koniec sa budeme venovať záležitostiam záveru bakalárskej práce.

Kapitola 1

Výzvy a riešenia kvality obrazu bezpečnostných kamier

Aby bol záznam z bezpečnostnej kamery čo najnápomocnejší pri predchádzaní, odhaľovaní a vyšetrovaní škodnej či priamo kriminálnej činnosti, musí byť pri jeho vyhotovovaní, prípadnom ukladaní a zobrazovaní kladený dôraz na určité atribúty jeho kvality. Aktuálne neexistuje žiadna norma ani štandard definujúci tieto atribúty, avšak v rozsahu našej práce si ich definujeme, aby sme si vedeli stanoviť metriky, zlepšenie v ktorých vedie zároveň k zlepšeniu v praktickom nasadení. Pozrime sa teda na aspekty, ktoré budeme sledovať.

1.1 Atribúty kvality záznamu


Kontext kvality obrazu systémov bezpečnostných kamier je podmnožinou oblasti kvality videozáznamu, ktorý je podmnožinou oblasti kvality digitálneho obrazu. Preto niektoré atribúty, ktorými sa budeme zaoberať sú zároveň predmetom záujmu zmienených nadmnožín, a niektoré naberajú osobitý dôraz v odvetví bezpečnostných kamier.

1.1.1 Všeobecne relevantné atribúty kvality videa

- Jednou zo základných metrík kvality digitálneho obrazu je rozlíšenie. V dnešnej dobe už sú dostupné senzory vysokých rozlíšení za relatívne nízke ceny, za čo vďačíme aj takzvanej honbe za megapixelmi. Samotné rozlíšenie je pri bezpečnostných kamerách výzvou v dvoch hlavných prípadoch. Jeden z prípadov, kedy potrebujeme vyššie rozlíšenie než je priemyselným štandardom (najčastejšie 720p a 1080p), je keď je kamera umiestnená tak, aby pozorovala rozsiahly priestor (napríklad veľké parkovisko), a teda veľkosť detailov ako ľudské tváre či evidenčné čísla vozidiel v pomere k celému záberu je nepostačujúca. Algoritmy spoľahlivo dopočítavajúce pixely obrazu, škálujúc ho na vyššie rozlíšenie, tak aby

došlo k zlepšeniu rozoznateľnosti detailu a nie len k pocitu, že obraz ako celok je kvalitnejší, no neobsahuje viac informácií, sú stále v plienkach, hoci vzostup umelej inteligencie to môže v najbližších rokoch zmeniť. Jedným z prípadov, kedy si však vysoké rozlíšenie na druhú stranu nemôžeme dovoliť, je, keď je záznam z bezpečnostnej kamery ukladajú na pamäťové médium. To má totiž v praxi obvykle obmedzenú kapacitu, a zvýšenie rozlíšenia ukladaneho obrazu bude mať za následok zníženie dĺžky záznamu, ktorú dokážeme na pamäťovom médiu uchovať. Zaujímavým prístupom v tejto oblasti je udalosťami riadená adaptácia, kedy sa systém snaží rozlišovať časové úseky s nízkou či neexistujúcou aktivitou (zmenou na zábere), ktoré nie je nutné ukladať vo vysokej kvalite, a časové úseky, kedy potenciálne dochádza k udalosti – zmene pozorovaného stavu – ktorú môžeme mať záujem zachovať v zázname vysokej kvality pre prípad budúceho prešetrenia [23].

- Okrem rozlíšenia hrá v rovnici kvality záznamu a dostupného úložiska rolu aj ďalšia premenná – počet snímok za sekundu. Aj na tento parameter vieme aplikovať udalosťami riadenú adaptáciu. Okrem toho sú na vzostupe algoritmy dopočítavajúce snímky medzi dvojicami skutočne zaznamenaných záberov, tu však opäť platí, že je veľmi obtiažne a v praxi obvykle nemožné dopočítavať informáciu tam, kde nám na originálnom zázname chýba. Tieto algoritmy len zvyšujú vnímanú plynulosť záznamu, no nedokážu pomôcť odhaliť skutočnosti, ktoré sa na pôvodnom zázname neobjavili.
- Bitová hĺbka nám hovorí o rozsahu farieb a ich jasov, ktorými dokážeme reprezentovať obraz v digitálnej podobe. Väčší význam v aplikácii bezpečnostných kamier však má dynamický rozsah. Ten nám hovorí o schopnosti samotnej kamery a jej spracúvajúceho softvéru zachytiť čo najširšie spektrum jasností. Dynamický rozsah v reálnych prostrediach presahuje rozsah reprezentovaný v 8-bitových textúrnych mapách [21][1]. Je veľmi dôležitý pri práci s prirodzeným osvetlením, kedy jasnosť prostredia dosahuje od rádovo niekoľkých nitov po rádovo desaťtisíce nitov [18].
- Pomer signálu a šumu je významný pre subjektívne vnímanú kvalitu obrazu. Značne zašumený obraz komplikuje ľudskému pozorovateľovi, a o to viac prípadne nasadeným rozpoznávacím algoritmom, schopnosť identifikovať objekty, ich hranice a črty, no aj ich pohyb. Metódy na odstraňovanie šumu pomáhajú zvýrazneniu správnej informácie, nedotvárajú však stratenú informáciu.
- Ostrosť je veľmi dôležitá metrika v kontexte bezpečnostných kamier, keďže určuje výraznosť (kontrast) hrán v obraze, a teda aj separovateľnosť a identifikovateľnosť črt a objektov.



Obr. 1.1: Porovnanie záberu zachytávajúceho scénu vo vysokom (naľavo) a v nízkom (napravo) dynamickom rozsahu [10]

1.1.2 Atribúty kvality osobitě bezpečnostným kamerám

- Zorný uhol v praxi hovorí o tom, aký rozsiahly a prípadne zakrivený priestor dokážeme pokryť jednou kamerou. Táto metrika je však určená dostupným hardvérom, od softvéru závisí až následné spracovanie zakrivenia, prípadne rozmazania a skreslenia na krajoch obrazu.
- Vlastnosti pri nízkej hladine osvetlenia naberajú obzvlášť veľký význam pri bezpečnostných kamerách, nakoľko značná časť záznamu bude pri väčšine aplikácii vyhotovovaná za tmy. Ako veľmi záleží na schopnostiach kamery a obraz spracovávajúceho softvéru pri nízkom osvetlení závisí od prostredia, v ktorom je kamera použitá. Kamery, ktoré sú umiestnené v konštantne osvetlených priestoroch – najčastejšie interiéroch, alebo priestoroch kde je osvetlenie automaticky aktivované senzorom pohybu, môžu zanedbať aspekt použiteľnosti pri najnižších hladinách ambientného jasú. Dôraz na schopnosti v tme nemusia klásť ani kamery inštalované za účelom sledovania priestoru v čase, kedy sa v ňom očakáva zvýšená aktivita ľudí, ak je to len za denného svetla. Väčšina aplikácii je však spätá s nepretržitým záznamom a ak nie je kamerovému systému nápomocné automatické osvetľovanie priestoru v prípade aktivity detekovanej iným senzorom, sú schopnosti sprostredkovať črtovo a informačne čitateľný obraz za tmy minimálne rovnako dôležité, a často dôležitejšie, než vlastnosti obrazu cez deň – čo nie vždy platí pri posudzovaní kvality kamerového záznamu pre všeobecnejšie aplikácie.

Z tohto prehľadu nám vyplýva, že väčšina atribútov kvality je zhodná s všeobecnejšími aplikáciami kamerových záznamov a teda mnohé algoritmy pôvodne nezamerané špecificky na bezpečnostné kamery budú mať značný prínos aj v tejto podoblasti.

1.2 Existujúce prístupy a riešenia

Zhrnuli sme si hlavné oblasti, v ktorých vieme dosahovať zlepšenie pre celkovú kvalitu videozáznamu z bezpečnostných kamier. Predstavme si teraz myšlienky niektorých z najsoľnejších prístupov venujúcich sa týmto oblastiam.


1.2.1 Zvýšenie rozlíšenia na základe databázy blokov vysokej kvality

Ako bolo zmienené v prvej časti kapitoly, môžeme mať k dispozícii kameru s vysokým rozlíšením, avšak nemať kapacitu ukladať snímky vo vysokom rozlíšení po dostatočne dlhú dobu. Predstavme si, že by sme chceli vyhotovovať 8K záznam s frekvenciou 30 snímok za sekundu a uchovávať ho po dobu 48 hodín, napríklad pre prípad vyšetrovania kriminálnej činnosti. Museli by sme ukladať $30 \text{ fps} \times 3600 \text{ sekúnd} \times 48 \text{ hodín} = 4147200$ snímok, pričom každá by bola o rozmere 7680×4320 pixelov, a na reprezentáciu každého pixelu by sme použili 24 bitov – 8 bitov pre každý farebný kanál. Potrebovali by sme tak minimálne $(4147200 \times 7680 \times 4320 \times 24) / 8 \text{ bitov} \approx 28840 \text{ GB}$, teda skoro 30 TB. Toto číslo vieme niekoľkonásobne znížiť kompresiou videa, no stále budeme záznamom okupovať pamäť rádovo minimálne v pár terabajtoch. A čo ak by sme chceli záznam uchovávať nie dva dni, ale dva týždne¹? Ako vieme výrazne ušetriť požiadavky na pamäť bez toho, aby sme sa vzdali množstva podstatných informácií vo videu? Jedným z možných riešení je uložiť všetky, alebo väčšinu snímok v zníženom rozlíšení. Na rekonštrukciu detailov v snímkach nižšieho rozlíšenia sa najčastejšie využíva databáza, v ktorej sa hľadá blok pixelov vo vysokom rozlíšení najpodobnejší danému zaostrovanému bloku po interpolácii. Na základe skladby databázy blokov vo vysokom rozlíšení, sú najčastejšie nasledujúce dva prístupy:

1.2.1.1 Ukladanie kľúčových snímok

Môžeme v originálnom rozlíšení ukladať každý k-ty (alebo iným vzorcom pravidelne zvolený) záber, alebo statické snímky [14] a následne využiť tieto kľúčové zábery v pôvodnej kvalite k dopočítaniu nezachovaných detailov na ostatných snímkach. Tento koncept ilustruje obrázok 1.2 z článku [2]. Majme pri tom na vedomí, že všetky zábery, vrátane kľúčových, sa ukladajú komprimované. Avšak zábery, ktoré nie sú kľúčovými, sa navyše ukladajú v zníženom rozlíšení. Pri popisovanom prístupe, je databáza tvorená blokmi kľúčových snímok. V článku [2] sa ako prístup pri následnom dopočítavaní využíva parameter energie, ktorú daný blok nesie, predstavujúcej hustotu detailu, a

¹Kým do roku 2018 bolo na Slovensku legálne uschovávať kamerové záznamy z bezpečnostných kamier po dobu maximálne 15 dní, v súčasnosti už je to len 72 hodín.



Obr. 1.2: Myšlienka ukladania každého k-teho záberu v pôvodnom rozlíšení z článku [2]

bloky, ktoré prekročia určenú hranicu, sú nahradené prislúchajúcimi interpólovanými blokmi z databázy blokov kľúčových snímok, ktorá je o ne následne aktualizovaná.

1.2.1.2 Využitie rozsiahlej existujúcej databázy

Inou možnosťou je využívať rozsiahlu databázu tréovacích záberov, podobne ako pri tréovaní umelej inteligencie, a ku každému interpólovanému bloku v nižšom rozlíšení hľadať najpodobnejší blok vo vysokom rozlíšení v celej databáze, alebo jej časti určenej predošlou skúsenosťou, pre urýchlenie procesu. Výhoda tohto prístupu je, že bez ukladania akýchkoľvek snímok v pôvodnom rozlíšení umožňuje ešte značnejšie zníženie celkovej pamäte potrebnej pre uloženie rovnako dlhého záznamu. Nevýhodou je, že napriek rýchlemu rozvoju v tejto oblasti, stále nemusí byť jednoduché dostať sa v rámci prijateľných nákladov k databáze dostatočnej robustnosti. Tento prístup je tiež náročnejší na následné prehľadávanie tejto databázy [15], čo plynie z veľmi vysokého množstva blokov vo vysokej kvalite, ktoré musí obsahovať, aby dokázala vyhovieť všetkým, alebo veľkej väčšine scenárov.

1.2.2 Zvýšenie rozlíšenia prevzorkovaním

Každý záber videa zvyčajne obsahuje silno a slabo štruktúrované regióny. Silno štruktúrované regióny sa skladajú z takmer homogénnych oblastí obrazu, ako jednofarebné steny, obloha, či akýkoľvek iný celistvý zhluk pixelov, ktorý ľudské oko považuje za jeden ucelený objekt s jedným farebným odtieňom. Medzi týmito objektmi sú v silno štruktúrovaných regiónoch veľmi jasne definované hranice (napríklad rám okna, na rozdiel od napríklad vln na vodnej hladine). Slabo štruktúrované regióny nie sú na záberoch jednoznačne definované tvarmi a farbami, dobrým príkladom sú napríklad ľudské vlasy, alebo aj črty ľudskej tváre. Existuje množstvo algoritmov, ktoré na zá-

klade týchto štruktúr a gradientov častí obrazu dopočítavajú pixely definujúce regióny vo vyššom rozlíšení. Zároveň sa osvedčilo spracúvať silno a slabo štruktúrované regióny separátne a v rôznych škálach pre rôzne priestorové štruktúry [15]. Algoritmy v tejto oblasti siahajú od jednoduchých, matematicky založených a pracujúcich v priestorovej doméne obrazu, využívajúcich napríklad interpolácie, ako [13], po prístupy založené na príkladoch a učení na základe vzoriek [8]. Obe strany spektra nesú svoje problémy a hodia sa do odlišne náročných podmienok.

1.2.2.1 Matematicky motivované metódy

Najzákladnejšími matematickými metódami určenými k prevzorkovaniu záberu, bez akejkoľvek informácie na pozadí, kontextu, a bez súvislosti s ďalšími snímkami videa, sú interpolácie. Chýbajúce pixely dopočítavajú na základe existujúcich v ich susednosti. Najpoužívanější interpolácia je bikubická, potom bilineárna, a technika najbližšieho suseda. Napriek tomu, že interpolácie sú rýchlym riešením, neprinášajú dostatočne uspokojivé výsledky v doménach, kde je najvyšší dôraz kladený na jednoznačnosť zachytenej informácie [5]. Interpolácie posudzujúce každú snímku videa individuálne sú totiž principiálne obmedzené množstvom usmerňujúcej informácie v tej danej snímke a nedokážu zúžitkovať kvantitatívnu výhodu videa oproti fotografiám. [24] Ďalším matematicky motivovaným prístupom je technika zvaná Maximum A Posteriori (MAP), založená na Bayesovskej teórii. Zvyšovanie rozlíšenia videa pomocou MAP techniky sa ukázalo úspešnejšie vo zachovávaní ostrých rohov v obraze. Táto technika podlieha ďalšiemu výskumu, keďže kombinuje odhad obrazu vo vysokom rozlíšení a aproximujúcu sústavu rovníc spájajúcu ho so záberom z videa. [5] Podľa tohto článku sa ďalej oplatí predspracúvať zábery z videa pred tým, než sa pokúsime o zvýšenie ich rozlíšenia, a to najmä odstránenie šumu a rozmazania. Rozmazanie je pre video inherentným problémom. Hoci ľudský mozog ho pri rýchlo sa striedajúcich záberoch potláča [24], pre algoritmy predstavuje značnú komplikáciu. Schopných algoritmov potláčajúcich rozmazanie bolo vyvinutých viacero [9], [20], [4].

1.2.2.2 Zvyšovanie rozlíšenia s využitím neurónových sietí

Naproti matematickým metódam stoja prístupy založené na strojovom učení, ktoré donedávna v praxi čelili problémom s dostupnosťou dostatku trénovacích vzoriek, a stále čelia je ich vhodnosť pre praktické použitie otáznou, kvôli výkonu nutnému na rýchle fungovanie takýchto algoritmov pri použití v reálnom čase. Po rozsiahлом prieskume sme došli k zisteniam, že v čase písania práce sú relevantné algoritmy dedikované zvyšovaniu rozlíšenia videa pomocou hlbokých neurónových sietí v stave tvorby zverejniteľnej implementácie [30] [11], alebo neposkytujú dostatočnú dokumentáciu k tomu, aby sme vrámci tejto práce vedeli tieto algoritmy otestovať na vlastných záznamoch z



Obr. 1.3: Výsledok (napravo) aplikácie prístupu [20] na rozmazaný záber (naľavo)

domény bezpečnostných kamier [28] [19] [26], alebo zdrojový kód vôbec nezverejňujú [12]. Veľmi sľubný, rozsiahly a pomerne nový toolkit obsahujúci množstvo algoritmov zameraných na prepojenie počítačového videnia a hlbokých neurónových sietí, ktoré obsadili popredné miesta na udalosti NTIRE (<https://cvlai.net/ntire/2024/>), vrátane zvyšovania rozlíšenia videa s využitím viacerých dedikovaných modelov a algoritmov, je MMagic [17]. Žiaľ však neposkytuje dostatočne obsiahlu dokumentáciu, a návody k použitiu metód relevantných pre našu prácu sú momentálne k dispozícii len v čínskom jazyku, z ktorého automatický, aplikáciami tretích strán sprostredkovaný preklad do angličtiny je pri odbornej terminológii veľmi nespoľahlivý.

1.2.3 Zlepšenie separovania odtieňov

Prístupy zvyšujúce rozlíšenie napomáhajú zvýrazneniu detailov na zábere, samostatný význam však nesú len za dobrých svetelných podmienok. Za zníženého osvetlenia je prvoradá objekty a tvary na zábere viditeľne separovať odtieňmi. Je ľahké presvedčiť sa s pomocou očných klamov, že zrakové centrum ľudského mozgu vníma farebné odtiene relatívne, porovnáva ich medzi sebou navzájom. Robí tak aby za ľubovoľných svetelných podmienok zachovalo schopnosť odhadnúť skutočnú farbu objektov a klasifikovať ich na základe nej. V digitálnej podobe však pixelom priradíme absolútne hodnoty z určitého diskretného rozsahu, ktorý je ešte k tomu značne menší, než rozsah odtieňov a jasností s akými vie pracovať ľudský zrakový systém [1]. V rámci tohto digitálneho rozsahu by sme sa preto chceli čo najviac priblížiť takému podaniu vizuálnej informácie, na základe ktorého dokáže mozog spoľahlivo separovať a klasifikovať objekty. Zlepšenie samotného záberu vieme robiť na základe jeho samého, alebo na základe ďalších záberov. Medzi najtradičnejšie spôsoby samozlepšenia snímku patrí zlepšenie kontrastu. Metódy zameriavajúce sa na zlepšenie kontrastu sa delia na priame – tie definujú mieru

kontrastu a snažia sa ju zlepšiť, a nepriame – tie zlepšujú kontrast využitím nevyužitých častí dynamického rozsahu bez toho, aby definovali nejakú špecifickú mieru kontrastu [21]. Algoritmy zlepšujúce kontrast využívajú dva základné prístupy. Prvým je ekvalizácia histogramu, kedy sa obvykle snažíme čo najrovnomernejšie rozprestrieť početnosti pixelov jednotlivých intenzít po celom spektre. Nemusíme sa však snažiť len o rovnomerné rozdelenie, využíva sa aj logaritmický prístup, alebo power-law pravidlo [27]. K zachovaniu úrovni vstupných jasov bolo navrhnutých viacero metód založených na ekvalizácii histogramu: Stred zachovávajúca bi-histogramová ekvalizácia (BBHE - mean preserving bi-histogram equalization), rovno-obsahová dualistická podobrazová ekvalizácia (DSIHE - equal area dualistic sub-image histogram equalization), bi-histogramová ekvalizácia minimalizujúca strednú jasovú odchýlku (MMBEBHE - minimum mean brightness error bi-histogram equalization), rekurzívna stredno-rozptylová histogramová ekvalizácia (RMSHE - recursive mean-spread histogram equalization) a multi-histogramová ekvalizácia [21]. Druhým zo základných prístupov, ktoré využívajú algoritmy zlepšujúce kontrast záberov, je mapovanie odtieňov. Jeho cieľ je v podstate rovnaký, ako pri ekvalizácii histogramu – komprimovať alebo premapovať dynamický rozsah HDR obrazov do rozsahu vhodného pre zobrazenie na zariadeniach so štandardným dynamickým rozsahom (SDR) [1], zachovajúc pri tom čo najviac detailov a vizuálnej informácie a pokiaľ možno pôsobiac prirodzene – hoci prirodzený vzhľad obrazu nemusí byť pri bezpečnostných kamerách prioritou (ale má význam napríklad aj pre redukciu zrakovej a kognitívnej únavy v prípade, že za monitormi systému bezpečnostných kamier dlhodobo sedí poverený pracovník). Medzi algoritmy premapovania odtieňov patria napríklad nasledovné techniky:

- Reinhardove mapovanie odtieňov sa snaží napodobniť spôsob akým sa ľudský zrak adaptuje na rozličné svetelné podmienky. Komprimuje dynamický rozsah obrazu tak, aby zachovalo lokálny kontrast a saturáciu. Pôvodne išlo o asistovaný proces - vyžadoval od zhotoviteľa snímky vyznačenie najsvetlejšieho, najtmavšieho a stredne tmavého (referenčného) miesta v obraze k vypočítaniu dynamického rozsahu. Neskôr Reinhard a kolektív automatizoval tento proces využívajúc kruhový Gaussov operátor v rôznych škálach aplikovaný na celý záber opravujúc presvetlené a tmavé regióny. [22]
- Fattalove mapovanie odtieňov taktiež prioritizuje lokálny kontrast a snaží sa ho zlepšiť, zatiaľ čo zábery si zachovávajú prirodzene pôsobiaci vzhľad. Komprimuje gradient jasového komponentu obrazu a riešením jeho Poissonovej rovnice konštruuje prislúchajúci obraz v zobraziteľnom dynamickom rozsahu. [7]
- Dragove mapovanie odtieňov sa opäť zameriava na lokálny kontrast, a taktiež na potlačenie halo efektov, ktoré sú bežným nežiaducim sprievodným javom prema-

povávaní odtieňov. Pracuje s adaptívnym upravovaním logaritmických základov, na základe ktorých sa komprimujú hodnoty jasnosti v obraze. Na zlepšenie tmavých oblastí používa zvyšovanie kontrastu. [6]

- Mantiukove mapovanie odtieňov modeluje generický operátor, ktorý aproximuje lokálne a globálne operátory využité v iných algoritmoch výpočtovo nenáročnými operáciami. Jeho výsledky sú často vizuálne neodlíšiteľné od algoritmov na mapovanie odtieňov vyžadujúcich značné množstvá strojového času. [16]

Ukázalo sa, že exponenciálne operátory mapovania odtieňov prinášajú vyššie subjektívne vnímané zlepšenie dynamického rozsahu než logaritmické [1]. Mapovanie odtieňov sa obvykle vykonáva len v kanáli iluminácie a na logaritmickú škálu, pričom mapa žiarenia vo floatovej reprezentácii sa konvertuje do 8-bitovej reprezentácie použiteľnej k renderovaniu [21]. Vyšší dynamický rozsah možno taktiež dosiahnuť kombináciou viacerých obrázkov z rovnakej scény s rôznymi časmi expozície. Relatívne intenzity presvetlených častí sú kvalitne zachytené pri krátkej uzábere objektívu, zatiaľ čo pri dlhej stihne na šošovku dopadnúť dostatok svetla na to, aby vynikli aj rozdiely medzi intenzitami v tmavej časti záberu. [1] Výsledkom je mapa floatov reprezentujúcich hodnoty žiarenia s hodnotami proporčnými tomu v skutočnej scéne. Tento spôsob je však v kontexte bezpečnostných kamier prakticky takmer nepoužiteľný, keďže je nutná podpora zo strany samotnej kamery, ktorá nie je u väčšiny produktov samozrejmosťou, a to z logického dôvodu že luxus vyhotovovania jedného záberu niekoľko krát sa veľmi ťažko zmysluplne realizuje v rámci videa, kde obvykle prioritizujeme počet snímok za sekundu, nehovoriac o výpočtovej náročnosti okamžitého kombinovania a ladenia týchto záberov, ktoré je výzvou napríklad aj pre najmodernejšie vlnkové lode medzi modernými smartfónmi využívajúce vysokovýkonné čipy, akými bezpečnostné kamery v praxi nedisponujú, a z ekonomických dôvodov pravdepodobne ešte dlho disponovať nebudú.

1.2.4 Kontextová fúzia

[pridať figure z A novel method for video enhancement - RGB local context-based fusion] Algoritmy zlepšujúce všeobecné videá zvyčajne venujú zvýšenú pozornosť odstraňovaniu zahmlenia, šumu, oparu a atmosférických javov. Neprodukujú však uspokojivé výsledky pri nočných záznamoch z bezpečnostných kamier, pretože sú závislé od jasnosti pixelov [Self-organized night video enhancement for surveillance systems]. Výhodou domény bezpečnostných kamier, ktorú uchopili niektoré algoritmy, je, že kamery sú obvykle umiestnené staticky pred tú istú scénu po celý čas – teda cez deň aj v noci. Tým pádom si dokážeme ukladať referenčné zábery, na ktorých je značná časť scény zhodná so zábermi vyhotovenými v ľubovoľnú fázu dňa, za ideálnych svetelných podmienok, a použiť tieto na dopĺňanie informácií vysokej kvality za zníženej viditeľnosti.

Tomuto procesu sa najčastejšie hovorí kontextová fúzia a algoritmus kombinuje snímky z rôznych častí dňa automaticky. Algoritmy na fúziu možno rozdeliť do kategórií na spodnú, strednú a vysokú úroveň. Tieto sa tiež označujú ako úroveň pixelov, úroveň črt a symbolická úroveň [A survey of Video Enhancement Techniques]. Za základný môžeme považovať prístup, kedy detekujeme hrany v obraze a na základe nich ho rozdelíme do segmentov, pre ktoré sa snažíme určiť správny odtieň spárovaním s prislúchajúcimi segmentmi v záberoch za lepších svetelných podmienok. Veľkým prínosom pre detekciu hrán postáv, ktoré patria obvykle medzi najzaujímavejšie informácie vo videu, vie byť infračervené spektrum. Mnohé bezpečnostné kamery disponujú aj týmito infračervenými senzormi. Očakávateľne však nastáva značná komplikácia pri rekonštrukcii odtieňov objektov, ktoré sa za svetla pred kamerou nevyskytovali, a odhad ich farby, ktorá je relatívna voči objektom, ktoré sa nachádzali aj na svetlom aj na tmavom zábere, je výzvou. Ďalším stávajúcim problémom je ako sa vysporiadať s neuniformným osvetlením. Mnohé z algoritmov sú založené na uniformnej iluminácii a nevedú si dobre ak máme viacero rôznorodých zdrojov svetla. Tými sú zvyčajne jeho umelé zdroje ako lampy, reflektory, ich odrazy a podobne. V takýchto podmienkach je esenciálna správna klasifikácia osvetlených a tmavých regiónov [25]. Najslubnejšie sa v tomto ohľade javí nasadenie neurónových sietí, napríklad v podobe samo-organizujúcich sa máp.

1.3 Súhrn východísk

Vzhľadom na rozsiahlosť oblastí v ktorých sa žiada zlepšovať kvalitu digitálneho obrazu, a ich individuálnu komplexnosť, nebol doposiaľ vyvinutý algoritmus, ktorý by kombinovane cielil k zlepšeniu každej alebo väčšiny zo zmysluplných metrík kvality. Cieľom tejto práce je preskúmať možnosť vytvorenia takéhoto algoritmu pre subdoménu bezpečnostných kamier s využitím doterajších poznatkov v problematikách s touto úzko súvisiacich, a prístupov zameraných na jednotlivé oblasti zlepšenia.

Kapitola 2

Ciele a metodika práce

V tejto kapitole sa pozrieme na to, ako budeme postupovať pri aplikovaní rôznych prístupov a algoritmov na konkrétne testovacie kamerové záznamy.

2.1 Čas nasadenia algoritmu

Vzhľadom na nezanedbateľnú časovú náročnosť niektorých operácií nad snímkami hrá rozdielovú rolu kedy v procese zaznamenania, spracovania, prípadného uloženia a zobrazovania záberu sa aplikuje zlepšovací algoritmus.

- Pri systémoch, ktoré vyhotovovaný záznam ukladajú bez toho, aby bol v reálnom čase sledovaný ľudským strážnikom, alebo nejakým algoritmom vyhodnocujúcim kontext a potenciálnu nežiaducu aktivitu v priestore, a teda tento záznam bude vždy prehliadaný až po tom čo došlo k aktivite ktorú máme záujem na ňom preskúmať, nie sme obmedzený časom na spracovanie videa. Aspoň nie do značnej miery. Môžeme si teda dovoliť napríklad 10 sekundový úsek videa, povedzme že tvorený $10 \text{ sekúnd} \times 30 \text{ fps} = 300$ snímkami, spracúvať kľudne niekoľko minút. Nie je problematické spracúvať jednu snímku aj rádovo v desatinách sekundy. Zároveň nechceme žiadnym kompromisom v prípade nasadenia algoritmu, ktorý na zlepšení záberu v čase t používa informácie zo záberu v čase $t + 1$ alebo neskoršieho.
- Ak naopak zábery zobrazujeme v reálnom čase, je žiadúce, aby tieto zábery už boli zlepšené, a teda zvyrazňovali informácie dôležité pre strážnika (či už v roli fyzickej osoby alebo softvéru). V takom prípade čas na zlepšenie snímky je limitovaný počtom záberov snímaných za sekundu. V prípade algoritmov využívajúcich neskoršie zábery na zlepšenie predošlých sa musíme zmieriť s oneskorením, to je však pri vhodne zvolenom algoritme konštantné a nemusí presahovať rádovo desiatky sekúnd, ktoré málokedy predstavujú rozdiel medzi dovolením a predídením

nežiaducej udalosti (ale existujú aj také prípady nasadenia, kedy o účinku aktivácie bezpečnostných opatrení - obvykle na diaľku - rozhodujú tieto potenciálne desiatky sekúnd).


V tejto práci sa pri testovaní a posudzovaní algoritmov najprv zameriame na prvý prípad a teda nebudeme brať v úvahu časovú limitáciu na zlepšenie záberov. Následne pri prístupoch, ktoré sa ukážu ako efektívne otestujeme, či by bolo možné ich (poprípade v nejakej odľahčenej, kompromisnej forme) aplikovať aj na druhý prípad a zlepšovať nimi video v reálnom čase.

2.2 Testovacie dáta

Hoci mnohé z algoritmov budú nezávislé od kontextu videa a záberov iných než toho, ktorý bude práve spracúvaný, nebudeme ich testovať na individuálne stojacich snímkoch ale rovno na videách. Tieto videá zaobstaráme z niekoľkých zdrojov, aby sme pokryli čo najviac realistických situácií:

- Za pomoci reálnych bezpečnostných kamier zapožičaných školou sme nahrali niekoľko vlastných záznamov v relevantých prostrediach a za rôznych svetelných podmienok, z rôznych vzdialeností. Aby nedošlo k porušeniu niečej ochrany súkromia, postavou pohybujúcou sa na záberoch bol autor tejto práce. Prvá z kamier je Annke T200. Táto kamera popri RGB zázname vyhotovuje aj termálny záznam, ten však nie je v rovnakom rozlíšení, ani nezaberá rovnaký výsek obrazu ako ten z RGB senzoru, preto bude nutné k jeho využitiu na zlepšenie príslúchajúceho RGB videa nájsť zodpovedajúcu homografiu [referencovať kapitolu]. Kvôli nutnosti pripojenia kamery k internetu a provizórne podmienky na škole po prerábke pavilónu informatiky, sme záznam touto kamerou vyhotovovali z druhého poschodia pavilónu matematiky. Vzhľadom na obmedzený čas dostupnosti miestnosti, a čas roka kedy sa stmieva až po šiestej večer, sme ale mohli testovacie video natáčať len cez deň. Na tomto videu v rozlíšení 1920×1080 pixelov na RGB zázname (interne nazvanom "Annke_RGB"), a v rozlíšení 320×240 pixelov na termo zázname (interne nazvanom "Annke_thermo"), sa prechádza autor vo vzdialenosti asi 20 až 50 metrov od objektívu kamery, na trávniku, za slnečného svitu (viď ukážky 2.1a a 2.1b).

Druhá z kamier je Hikvision DS-2CD2025FWD s infračerveným prísvecovaním. Túto kameru bolo obtiažnejšie spojazdniť, nakoniec sme prišli na to, že elektrický zdroj (v balení originálny dodaný nebol) mal nepatrne väčší priemer konektoru než kamera, a teda kamera ním nebola napájaná. Problém bol provizórne vyriešený vsunutím drôtika a kameru sme uchytili k doske, ktorú sme pripevnili k



Obr. 2.1: Ukážky testovacieho záznamu z kamery Annke T200



Obr. 2.2: Ukážka videa Hikvision_dark_close

zábradliu na balkóne u autora práce doma, na druhom poschodí. Ten sa následne bol poprechádzať v zornom poli kamery a to najprv vo vzdialenosti asi 8 metrov vzdušnou čiarou pri pohľade kamery takmer kolmo dole vo večernej tme na videu Hikvision_dark_close v rozlíšení 640×360 pixelov 2.2, a potom vo vzdialenosti zhruba 25 až 40 metrov od objektívu kamery v priestore prisietenom pouličnou lampou na videu Hikvision_dark_distant 2.3 v rozlíšení orezanom z pôvodných 640×360 pixelov na 480×360 pixelov.

- K prekvapivému zisteniu sa na základe nášho prieskumu na internete nenachádza verejne dostupný dataset záberov z bezpečnostných kamier. Takýto mal byť k dispozícii zdarma na stránke <https://viratdata.org/>, avšak prístup k nemu už zjavne neexistuje. Na stránke sú však dve ukážkové videá, ktoré mal dataset obsahovať. Prvé video, pre účely práce pomenované "student_street", je v rozlíšení 1280×720 pixelov a zachytáva zhruba z výšky prvého nadzemného podlažia verejné vonkajšie priestory pred budovami patriacimi univerzite v Spojených Štátoch Amerických, v ktorých sa pohybujú ľudia za polooblačného počasia počas dňa, vo vzdialenosti asi 10 až 50 metrov od objektívu kamery, po dobu 24 sekúnd (viď ukážku 2.4).

Druhé video, pre účely práce pomenované "parking", je v rozlíšení 1920×1080



Obr. 2.3: Ukážka videa Hikvision_dark_distant



Obr. 2.4: Ukážka videa student_street



Obr. 2.5: Ukážka videa parking

pixelov a zaznamenáva parkovisko v zadných priestoroch rozmernej budovy so zaparkovanými vozidlami, v daždi počas dňa, z výšky asi tretieho až štvrtého nadzemného podlažia (viď ukážku 2.5). Na 53 sekúnd trvajúcim zázname sa prejde 5 ľudí s dáždnikmi vo vzdialenosti odhadom 20 až 60 metrov od objektívu kamery. Kamera vykazuje mierne pohyby následkom prítomného vetra.

- Existuje množstvo verejných kamier dohľadového alebo podobného typu, záznamy z ktorých sú naživo zdieľané na internete, zadarmo a dostupne pre širokú verejnosť. IP adresy týchto kamier možno získať zo zdrojových kódov webových stránok, na ktorých sa nachádzajú, a napojiť sa na ne cez HTTP, alebo iný protokol pomocou programu. Z týchto záznamov možno uložiť ich časť, alebo na ne aplikovať algoritmy naživo počas streamovania. Kvalita týchto videí je rôzna, väčšinou však trpí na nízky počet snímkov za sekundu nízke rozlíšenie, a vysokú mieru šumu najmä v noci. Tieto zábery sú tak dobrou výzvou pre algoritmus, napriek tomu, že sú spravidla horšej kvality, než tie z väčšiny trhovo úspešných moderných bezpečnostných kamier. Ich výhoda je, že sú zbierané z kamier umiestnených naprieč celým svetom, a teda v rôznych časových pásmach a za rôznych poveternostných podmienok. Obvykle ale sledujú prostredie z väčšej vzdialenosti, než je bežné pre bezpečnostné kamery, a niekedy ide o prostredia, v ktorých by nasadenie bezpečnostných kamier ani nebolo opodstatnené.

2.3 Návrh testovacieho programu

Implementačným jadrom tejto práce bude program, pomocou ktorého budeme môcť na testovacie videá aplikovať rôzne zlepšovacie algoritmy, kombinovať ich, a porovnať ich výsledky v subjektívnych (napr. vizuálny posudok) a objektívnych (napr. čas aplikácie prepočítaný na jednu snímku v závislosti od jej rozlíšenia, prípadne iných metrík) mierach.

2.3.1 Voľba programovacieho jazyka a knižníc

Tento program bude napísaný v programovacom jazyku Python, verzia 3.12. Rozhodli sme sa tak preto, lebo pre Python existuje solídna paleta open-source knižníc, ktoré ponúkajú rozsiahle schopnosti v oblasti práce s obrazom a digitálnou informáciou, a majú efektívne implementovaných množstvo funkcií a algoritmov relevantných pre našu prácu. Medzi použité knižnice bude patriť:

- OpenCV, verzia 4.9, je Intelom vyvíjaná open-source knižnica obsahujúca viac než 2500 algoritmov v oblasti počítačového videnia.
- NumPy, verzia 1.26, poskytuje infraštruktúra pre prácu s vektormi a maticami (ktorými je digitálny obraz reprezentovaný), a funkciami nad nimi definovanými.

Napriek tomu, že jazyk C++, s ktorým taktiež funguje knižnica OpenCV, je všeobecne rýchlejší než Python, keďže je kompilovaný, a teda transformovaný priamo do strojového kódu, OpenCV v pythone je len wrapperom nad originálnym kódom v C++. Kombinuje tak rýchlosť C++ a jednoduchosť Pythonu. Rozdiel v rýchlosti behu OpenCV algoritmov medzi C++ a Pythonom je obvykle menej ako 1%, a v najhoršom prípade pre základné funkcie je uvádzaný ako menej než 4%. Táto úvaha je dôležitá kvôli tomu, že práca s obrazom je všeobecne veľmi výpočtovo náročná, o to viac, keď sa pozrieme napríklad na hlboké neurónové siete nad obrazovými dátami a budeme ich chcieť využiť na zlepšovanie kvality záberov vo videu.

2.3.2 Porovnávanie výsledkov

- Pri algoritmoch neporovnávajúcich rozlíšenie pôvodného a upraveného záznamu si tieto videá zobrazíme paralelne v jednom rozdelenom okne, interpoláciou naškálované tak, aby toto okno zaberalo celú obrazovku monitora.
- Pri algoritmoch zameraných (aj) na rozlíšenie sa zameriame na takú časť obrazu, ktorá po preškálovaní zhruba zaberie polovicu monitora, aby bolo možné porovnať výsledok s preškálovaním rovnakého výseku na rovnakú veľkosť inou formou.

Na zobrazovanie videí vytvoríme prehrávač, ktorý dokáže prehrať jedno až štyri videá na jednom monitore naraz a to tak, aby maximalizoval priestor ktorý tieto videá vyplňajú, v prospech jednoduchšieho vizuálneho porovnania kvality. Toto škálovanie sa bude dať vypnúť ak ním nechceme dodatočne video prevzorkovať. Zároveň by tento prehrávač mal umožňovať tieto koláže paralelne bežiacich videí ukladať v nejakom zo štandardných formátov ako mp4 alebo avi.

Zároveň do programu zahrnieme checkpointy v ktorých bude zaznamenaný čas od spustenia programu, aby sme vedeli vyhodnotiť a porovnať časovú náročnosť jednotlivých procedúr. Na záver sa pokúsime dostatočne rýchle procedúry aplikovať v reálnom

čase na streamované záznamy naživo z online kamier, k čomu bude taktiež v testovacom programe zabudovaná infraštruktúra.

2.3.3 Aplikácia algoritmov

Každý z testovaných algoritmov bude implementovaný v samostatnej metóde, ktorá bude umožňovať nastavenie jeho parametrov (ak nejakými disponuje) pri jej volaní. Vstupom do týchto metód aj výstupom z nich bude vždy video, takže bude možné takto aplikáciou algoritmov reťaziť. Okrem toho pre algoritmy aplikované na zábery samostatne, väčšinou tie, špecializujúce sa všeobecne na zlepšovanie nejakej z metrík kvality digitálneho obrazu, ktoré sme si zaviedli v prvej kapitole, vytvoríme metódy, ktoré budú tieto procedúry aplikovať len na jeden vstupný záber a vracať tento záber upravený. To sa nám bude hodiť, keď budeme chcieť aplikovať kombináciu zlepšovacích algoritmov záber po zábere, napríklad pri spracúvaní videa v reálnom čase. Nastavenia parametrov týchto algoritmov budú mať globálnu pôsobnosť a meniteľnosť.

2.4 Testované algoritmy

Otestujeme relevantné algoritmy, ktoré sú obsiahnuté v open-source knižniciach, alebo kód ktorých je zverejnený na internete. Pokiaľ je nasadenie algoritmu komplikované, budeme pracovať len s takými kódmi a knižnicami, ktoré majú prehľadnú dokumentáciu v angličtine. Ťažiskom tejto práce nie je vývoj a zavádzanie procedúr na základe teoretických základov, je ním použitie a porovnanie širokého množstva metód v doméne bezpečnostných kamier. Taktiež tým pádom opomenieme experimentálne návrhy algoritmov testovaných len na akademickej pôde, bez implementácie použiteľnej v reálnej prevádzke na vlastné účely, napriek tomu, že sme takéto algoritmy spomenuli v prvej kapitole, keďže predstavujú zaujímavé nové možnosti, ktoré pri rýchlosti vývoja technológií digitálneho obrazu môžu byť už v dohľadnej dobe jedného až pár rokov zavádzané do prevádzky.

Nešťastným no pochopiteľným faktom, ktorý znižuje strop možností tejto práce, je, že v podstate veštky najschopnejšie moderné implementácie softvérového skvalitňovania digitálneho obrazu sú v rukách globálnych technologických spoločností, ktoré si starostlivo strážia svoje know-how, do získania ktorého na výskumnej úrovni, a následne jeho vyladenia pre praktické nasadenie, investovali milióny dolárov. Open-source algoritmy prezentované malými univerzitnými a nadšeneckými tímami teda len ťažko dokážu byť kompetitívne proti technológiám zabudovaným do zariadení od veľkých svetových výrobcov elektroniky, medzi ktorými panuje stav ostrej konkurencie a rivality, a na ktorých sa podieľalo mnohonásobne viac odborníkov s mnohonásobne väčšími dostupnými prostriedkami. Táto rivalita je v posledných rokoch najväčšia na trhu

smartfónov, kde spoločnosti ako Apple, Samsung, Huawei, Xiaomi a ďalšie dokázali vyvinúť pre svoje kamerové sety v telefónoch softvér, ktorý silou dodatočného spracovania prakticky dorovnáva dedikované digitálne fotoaparáty a zrkadlovky napriek tomu, ako veľmi sú znevýhodnené fyzikálnymi limitmi niekoľkonásobne menšej fotografickej aparatúry. Toto platí aj v porovnaní s dedikovanými kamerami, o to viac keď sa zaoberáme bezpečnostnými kamerami, ktoré sú jednak cenovo značne limitované na úrovni individuálneho zariadenia, a jednak na úrovni spoločností, keďže toto odvetvie nie je dostatočne ziskové na to, aby si výrobcovia bezpečnostných kamier mohli dovoliť vývoj softvérov dodatočného spracovania, aký si môžu dovoliť poprední výrobcovia smartfónov. To nás však neodrádza, prejdime si teda algoritmy, ktoré dokážeme implementovať v tejto práci:

2.4.1 Zaostrenie obrazu

Pri zaošťovaní obrazu využijeme dve metódy:

- Aplikáciu Laplaceovského hranového filtra, kde otestujeme rôzne matice, príkladom ktorých ku každému pixelu a jeho okoliu zvýrazníme hrany v zábere.
- Zaostrenie odčítaním rozmazaného obrazu, kedy si najprv vytvoríme kópiu záberu, tú rozostříme Gaussovským rozmazaním, a $0.X$ násobok tohto rozostreného obrazu odčítame od $1.X$ násobku pôvodného obrazu, aby sme zachovali rozsah intenzít, pričom vyskúšame rôzne hodnoty X , ako aj rôzne hodnoty okolia a strednej odchýľky pri rozmazávaní.

Obe metódy sú všeobecne dlho známe a používajú sa pri zaošťovaní digitálnych obrazov bezohľadu na doménu. Nasádzať ich teda budeme snímku po snímke a uvidíme, aký efekt budú mať na videá z bezpečnostných kamier cez deň, v noci, a v rôznych iných podkladových atribútoch kvality. Napriek tomu, že bolo navrhnutých niekoľko algoritmov špecializovaných na zaošťovanie videa [referencie], ani k jednému nebol zverejnený kód, na základe ktorého by sme ich vedeli v praxi implementovať a otestovať v našom programe.

2.4.2 Odstránenie šumu

Nežiadúcim efektom pri videu z bezpečnostnej kamery by bolo, keby sme pri snahe odstrániť šum rozmazali obraz vyhladzovaním a nevyberane ho tak zbavili informácie. V našej oblasti je totiž zachytená informácia prioritou, a uhladený vzhľad videa je až sekundárny - ani nie tak pre ľudských pozorovateľov, ako pre ďalšie algoritmy, výsledok ktorých by mohol šum znehodnotiť, ako je napríklad veľmi reálne pri metódach



Obr. 2.6: Ukážka výsledku odstraňovania šumu nelokálnym priemerovaním z článku [3]. Naľavo je pôvodný obraz, uprostred obraz zašumený Gaussovským šumom a napravo je obraz po aplikácii algoritmu. Všimnime si, že táto fotografia je veľmi vhodná na jeho nasadenie, pretože obsahuje veľa opakujúcich sa častí, priemerovaním medzi ktorými možno spoľahlivo odstrániť šum.

využívajúcich hlboké neurónové siete, ktoré v záujme lepšieho výsledku preferujú čo najmenej rušivej šumovej informácie nesúvisiacej s kontextom. Preto použijeme metódu odstraňovania šumu nelokálnym priemerovaním [3]. Jej algoritmus je implementovaný v OpenCV a pozerá sa na obraz po malých výrezoch veľkosti rádovo v pixeloch, pre ktoré hľadá výrezy rovnaké alebo takmer rovnaké inde v obraze (pre lepšiu predstavu vid' obr. ??, a následne priemeruje hodnoty ich pixelov aby tak z nich odstránil jedinečný šum. Táto metóda je značne pomalšia než jednoduché metódy vyhladzujúce obraz ako napríklad Gaussovske rozmazanie, no kompromituje informáciu obsiahnutú v zábere do podstatne nižšej miery. Jej sila zároveň rastie, ak využijeme k vyhľadávaniu podobných častí obrazu aj ďalšie snímky, ktoré máme v prípade videa k dispozícii, čo je obzvlášť prínosné v prípade bezpečnostných kamier, kde nás často zaujíma práve informácia nevyskytujúca sa nikde inde na zábere - napríklad tvár konkrétneho človeka - avšak obsiahnutá na ďalších záberoch, a to s vysokou pravdepodobnosťou nezašumená, alebo aspoň zašumená v iných bodoch inou intenzitou.

2.4.3 Zlepšenie kontrastu

O zlepšenie kontrastu v testovacích videách (tam, kde sa to bude javiť ako prínosné), sa pokúsime pomocou ekvalizácie histogramu. Budeme ich aplikovať na jednotlivé snímky individuálne. V špecifických prípadoch, napríklad pri rozsvietení reflektorov auta na inak pomerne tmavom videu môže byť z hľadiska zachovania percepcie nemennosti okolia prínosné posudzovať jasnosť vrámci rozsahu intenzít naprieč celým videom, nie len v rámci daného záberu, avšak z hľadiska rozoznania informácie, čo je pre doménu bezpečnostných kamier kľúčovým, by šlo o degradáciu. Napriek tomu ale otestujeme ek-

valizácie histogramu aj v tomto scenári. Pri prieskume súčasného využívania ekvalizácie histogramu vo videách sme sa však na internete stretli len s individuálnou aplikáciou po snímkach, a to aj pri odbornou obcou navrhovaných prístupoch [referencie].

Keďže pracujeme primárne s obrazmi reprezentovanými na úrovni farebných kanálov (RGB), a kontrast nutno posudzovať vzhľadom na globálne hladiny intenzity jednotlivých pixelov, teda uniformne bezohľadu na farebný kanál, použijeme formát, ktorý oddeľuje komponent jasnosti do separátneho kanálu, na ktorý budeme ekvalizáciu histogramu aplikovať, zatiaľ čo farbu uschováme v kanáloch ktoré nezmeníme. Takýmto formátom je napríklad YCbCr, využívajúci zložku Y na reprezentáciu jasú, a zložky Cb a Cr na reprezentáciu modrého a červeného chrominančného komponentu.

Praktickým nedostatkom základnej ekvalizácie histogramu v mnohých scenároch sú prípady, kedy pri redistribúcii síce zvýrazníme jasové rozdiely vo väčšine obrazu, no zlejeme ich v nejakej podčasti, ktorá pritom pre nás nesie veľký význam z hľadiska poskytnutej užitočnej informácie. Tento jav by sa mohol manifestovať napríklad presvetlením tváre nasvietenej automaticky sa rozsvetujúcim reflektorom, kedy by klasická ekvalizácia histogramu využila väčšinu z rozsahu zobraziteľných jasov na reprezentáciu tmavého okolia. Preto využijeme aj metódu adaptívnej ekvalizácie histogramu, ktorá posudzuje záber po blokoch (disjunktných, a to rádovo o uhlopriečke v spodných desiatkach pixelov, prípadne jednotkách pixelov) a ekvalizuje pre ne histogramy nezávisle. Viac v kapitole 3 [referencia].

2.4.4 Odstránenie rozmazania

2.4.5 Zvýšenie rozlíšenia

2.4.6 Rekolorizácia

2.4.7 Detekcia pohybu pomocou IR/Termo spektra

Záver

Na záver už len odporúčania k samotnej kapitole Záver v bakalárskej práci podľa smernice [29]: „V závere je potrebné v stručnosti zhrnúť dosiahnuté výsledky vo vzťahu k stanoveným cieľom. Rozsah záveru je minimálne dve strany. Záver ako kapitola sa nečísluje.“

Všimnite si správne písanie slovenských úvodzoviek okolo predchádzajúceho citátu, ktoré sme dosiahli príkazom \uv.

V informatických prácach niekedy býva záver kratší ako dve strany, ale stále by to mal byť rozumne dlhý text, v rozsahu aspoň jednej strany. Okrem dosiahnutých cieľov sa zvyknú rozoberať aj otvorené problémy a námety na ďalšiu prácu v oblasti.

Abstrakt, úvod a záver práce obsahujú podobné informácie. Abstrakt je kratší text, ktorý má pomôcť čitateľovi sa rozhodnúť, či vôbec prácu chce čítať. Úvod má umožniť zorientovať sa v práci skôr než ju začne čítať a záver sumarizuje najdôležitejšie veci po tom, ako prácu prečítal, môže sa teda viac zamerať na detaily a využívať pojmy zavedené v práci.

Literatúra

- [1] Yasir Ali, Wazirah Md-Esa, Aamir Malik, and MOHAMAD NAUFAL MOHAMAD SAAD. Tone mapping of hdr images: A review. pages 368–373, 06 2012.
- [2] Fernanda Brandi, Ricardo de Queiroz, and Debargha Mukherjee. Super resolution of video using key frames. In *2008 IEEE International Symposium on Circuits and Systems*, pages 1608–1611, 2008.
- [3] Antoni Buades, Bartomeu Coll, and Jean-Michel Morel. Non-Local Means Denoising. *Image Processing On Line*, 1:208–212, 2011. https://doi.org/10.5201/ipol.2011.bcm_nlm.
- [4] Song Chunhe, Zhao Hai, and Jing Wei. Motion deblurring from a single image using multi-layer statistics priors. In *2011 IEEE International Conference on Consumer Electronics (ICCE)*, pages 481–482, 2011.
- [5] Federico Cristina, Sebastián H Dapoto, Claudia Cecilia Russo, and Oscar N Bria. High resolution images from low resolution video sequences. *Journal of Computer Science & Technology*, 5, 2005.
- [6] Frédéric Drago, Karol Myszkowski, Thomas Annen, and Norishige Chiba. Adaptive logarithmic mapping for displaying high contrast scenes. In *Computer graphics forum*, volume 22, pages 419–426. Wiley Online Library, 2003.
- [7] Raanan Fattal, Dani Lischinski, and Michael Werman. Gradient domain high dynamic range compression. In *Seminal Graphics Papers: Pushing the Boundaries, Volume 2*, pages 671–678. 2023.
- [8] W.T. Freeman, T.R. Jones, and E.C. Pasztor. Example-based super-resolution. *IEEE Computer Graphics and Applications*, 22(2):56–65, 2002.
- [9] Xianyu Ge, Jieqing Tan, and Li Zhang. Blind image deblurring using a non-linear channel prior based on dark and bright channels. *IEEE Transactions on Image Processing*, 30:6970–6984, 2021.

- [10] Richard Huber. Slowenien, portorose, salzlagerhalle am hafen (hdr-aufnahme vs. normalbelichtung), 2008. [Online; accessed 22-March-2023].
- [11] Xiaozhong Ji, Yun Cao, Ying Tai, Chengjie Wang, Jilin Li, and Feiyue Huang. Real-world super-resolution via kernel estimation and noise injection. In *The IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, June 2020.
- [12] Younghyun Jo, Seoung Wug Oh, Jaeyeon Kang, and Seon Joo Kim. Deep video super-resolution network using dynamic upsampling filters without explicit motion compensation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2018.
- [13] R. Keys. Cubic convolution interpolation for digital image processing. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 29(6):1153–1160, 1981.
- [14] Dan Kong, Mei Han, Wei Xu, Hai Tao, and Yihong Gong. Video super-resolution with scene-specific priors. In *BMVC*, pages 549–558, 2006.
- [15] Ying Liu, Alexander Wong, and Paul Fieguth. A structure-guided conditional sampling model for video resolution enhancement. In *2011 18th IEEE International Conference on Image Processing*, pages 1169–1172, 2011.
- [16] Rafał Mantiuk and Hans-Peter Seidel. Modeling a generic tone-mapping operator. In *Computer Graphics Forum*, volume 27, pages 699–708. Wiley Online Library, 2008.
- [17] MMagic Contributors. MMagic: OpenMMLab multimodal advanced, generative, and intelligent creation toolbox. <https://github.com/open-mmlab/mmagic>, 2023.
- [18] Mike Nilsson. Ultra high definition video formats and standardisation, 04 2015.
- [19] Jinshan Pan, Songsheng Cheng, Jiawei Zhang, and Jinhui Tang. Deep blind video super-resolution, 2020.
- [20] Jinshan Pan, Deqing Sun, Hanspeter Pfister, and Ming-Hsuan Yang. Deblurring images via dark channel prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(10):2315–2328, 2018.
- [21] Y. Rao and L. Chen. A survey of video enhancement techniques. *Journal of Information Hiding and Multimedia Signal Processing*, 3:71–99, 01 2012.

- [22] Erik Reinhard, Michael Stark, Peter Shirley, and James Ferwerda. Photographic tone reproduction for digital images. In *Seminal Graphics Papers: Pushing the Boundaries, Volume 2*, pages 661–670. 2023.
- [23] Airi Sakaushi, Kenji Kanai, Jiro Katto, and Toshitaka Tsuda. Edge-centric video surveillance system based on event-driven rate adaptation for 24-hour monitoring. In *2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pages 651–656, 2018.
- [24] R.R. Schultz and R.L. Stevenson. Extraction of high-resolution frames from video sequences. *IEEE Transactions on Image Processing*, 5(6):996–1011, 1996.
- [25] T. Soumya and Sabu Thampi. Self-organized night video enhancement for surveillance systems. *Signal, Image and Video Processing*, 11, 01 2017.
- [26] Dewei Su, Hua Wang, Longcun Jin, Xianfang Sun, and Xinyi Peng. Local-global fusion network for video super-resolution. *IEEE Access*, 8:172443–172456, 2020.
- [27] Romen Taiyenjam, Oinam Imocha Singh, Khumanthem Singh, Tejmani Sinam, and Thounaojam Singh. Image enhancement by adaptive power-law transformations. 12 2010.
- [28] Yapeng Tian, Yulun Zhang, Yun Fu, and Chenliang Xu. Tdan: Temporally-deformable alignment network for video super-resolution. In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2020.
- [29] Univerzita Komenského v Bratislave. Vnútný predpis č. 7/2018, Úplné znenie vnútorného predpisu č. 12/2013 Smernice rektora Univerzity Komenského v Bratislave o základných náležitostiach záverečných prác, rigorózných prác a habilitačných prác, kontrole ich originality, uchovávaní a sprístupňovaní na Univerzite Komenského v Bratislave v znení dodatku č. 1 a dodatku č. 2 smernica rektora Univerzity Komenského v Bratislave o základných náležitostiach záverečných prác, rigorózných prác a habilitačných prác, kontrole ich originality, uchovávaní a sprístupňovaní na Univerzite Komenského v Bratislave, 2013. [Citované 2020-10-19] Dostupné z https://uniba.sk/fileadmin/ruk/legislativa/2018/Vp_2018_07.pdf.
- [30] Xintao Wang, Kelvin C.K. Chan, Ke Yu, Chao Dong, and Chen Change Loy. Edvr: Video restoration with enhanced deformable convolutional networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, June 2019.

Príloha A: obsah elektronickej prílohy

V elektronickej prílohe priloženej k práci sa nachádza zdrojový kód programu a súbory s výsledkami experimentov. Zdrojový kód je zverejnený aj na stránke <http://mojadresa.com/>.

Ak uznáte za vhodné, môžete tu aj podrobnejšie rozpísať obsah tejto prílohy, prípadne poskytnúť návod na inštaláciu programu. Alternatívou je tieto informácie zahrnúť do samotnej prílohy, alebo ich uviesť na oboch miestach.

Príloha B: Používateľská príručka

V tejto prílohe uvádzame používateľskú príručku k nášmu softvéru. Tu by ďalej pokračoval text príručky. V práci nie je potrebné uvádzať používateľskú príručku, pokiaľ je používanie softvéru intuitívne alebo ak výsledkom práce nie je ucelený softvér určený pre používateľov.

V prílohách môžete uviesť aj ďalšie materiály, ktoré by mohli pôsobiť rušivo v hlavnom texte, ako napríklad rozsiahle tabuľky a podobne. Materiály, ktoré sú príliš dlhé na ich tlač, odovzdajte len v electronickej prílohe.