

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra kybernetiky

BAKALÁŘSKÁ PRÁCE

PLZEŇ, 2012

Pavel Jedlička

TÉMA ČESKY:

Předzpracování medicínských obrazů pro následnou segmentaci

NÁZEV ANGLICKY:

Image preprocessing for further segmentation

VEDOUCÍ PRÁCE:

Ing. Tomáš Ryba

ZÁSADY PRO VYPRACOVÁNÍ

1. Prostudujte doporučenou literaturu týkající se předzpracování obrazu a jeho segmentace
2. Seznamte se s charakterem medicínských obrazových dat a formátem DICOM
3. Z prostudovaných materiálů vyberte takové metody, které podle Vás budou nejvhodnější
4. Jednotlivé metody ozkoušejte na reálných datech
5. Diskutujte získané výsledky a navrhněte možná vylepšení

SEZNAM DOPORUČENÉ LITERATURY:

- Milan Šonka, Václav Hlaváč, Roger Boyle: Image Processing, Analysis and Machine Vision
- Miloš Železný: přednášky k předmětu ZDO
- Milan Šonka, J. Michael Fitzpatrick: Handbook of Medical Imaging
- Isaac N. Bankman: Handbook of Medical Image Processing and Analysis

PROHLÁŠENÍ

Předkládám tímto k posouzení a obhajobě bakalářskou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne:

.....

vlastnoruční podpis

Anotace:

Úkolem této práce je prozkoumat a porovnat metody předzpracování digitálního obrazu. Dále pak vybrat vhodné metody pro práci s medicínskými obrazy formátu DICOM. Mezi zkoumané metody patří metody filtrace obrazu a detekce hran v obraze. Účelem je nalezení vhodné kombinace těchto metod pro následnou segmentaci obrazů a jejich další zpracování.

Klíčová slova:

Předzpracování obrazu, rozmazávání obrazu, filtrace obrazu, hranové operátory, formát DICOM.

Abstract:

Aim of this thesis is to study and compare methods of digital image pre-processing and to choose suitable methods to work with medical images in DICOM format. Researched methods are the methods of image filtration and detection of edges in the image. Purpose of this thesis is finding suitable combinations of these methods for subsequent image segmentation and its further processing.

Keywords:

Image pre-processing, image smoothing, image filtration, edge operators, DICOM format.

Obsah:

1	Úvod	1
2	Teoretická část	5
2.1	Obrazová funkce	5
2.2	Reprezentace obrazu pomocí bitmapy	6
2.3	DICOM standard	7
2.4	Metody předzpracování obrazu	8
2.4.1	Rozmazávání obrazu	8
2.4.2	Ostření obrazu	13
2.4.3	Detekce hran	13
2.4.4	Detekce čar	18
2.4.5	Detekce rohů	19
2.4.6	Tobogganing	21
3	Praktická část	22
3.1	Metody pro rozmazávání obrazu	22
3.2	Metody detekce hran	27
3.3	Hledání vhodné kombinace filtrů a detekce hran u DICOM obrazů	33
3.4	Tobogganing	35
4	Závěr	37
5	Použité zdroje	39

1. ÚVOD

U člověka je vnímání okolního světa obstaráváno smysly, které své vjemy předávají mozku, ten je dále zpracovává na informace, se kterými pak člověk může dále pracovat. V případě vidění je to pak zrak, který nám umožňuje rozpoznávat objekty v našem okolí. Počítačové vidění se snaží nějakým způsobem napodobit lidské vnímání svého okolí.

Důvodů, proč bychom měli počítače učit vidění, se nabízí hned několik. Může jít například o prostorovou orientaci automaticky se pohybujících robotů. U automatické výroby pak jde zpravidla o hledání vhodné polohy pro nástroj výrobní linky v případě, že není dopředu přesně známá poloha nebo tvar výrobku. V bezpečnosti se může jednat o sledování nějakého prostoru, například letištní haly, zda se zde nepohybují konkrétní lidé, kteří by mohli ohrozit provoz. Zde se pak bude jednat o hledání a rozpoznávání obličejů. V případě medicínských obrazů se jedná o časovou úsporu při prohlížení velkého množství obrazů a hledání mezi nimi takových, které vykazují nějaké konkrétní vlastnosti, na které je potřeba zaměřit lidské zdroje nebo naopak o jemnější detekci příznaků pro lidské oko těžko

rozpoznatelných.

U počítačového zpracování obrazů je pak důležité rozpoznávání jednotlivých objektů, které se na obraze nacházejí, a porozumění jim. Zde je velmi důležité najít na obraze u jednotlivých objektů okraje pro jejich správnou identifikaci. Ty však nejsou vždy zcela ostré. Může být například problematické dobře najít okraje objektu, jehož část bude ležet ve stínu. Dalším problémem je zatížení fotografií šumem. Například nedokonalostí čočky fotoaparátu nebo špatnými světelnými podmínkami, vlivy počasí jako déšť, mlha a další.

Předzpracování medicínských obrazů pro následnou segmentaci se zabývá operacemi na snímcích z medicínského prostředí, které mají za úkol předpřipravit tyto snímky pro následné rozpoznávání jednotlivých objektů, které se na těchto snímcích nacházejí. Jde o operace, které mají za úkol například zbavit tyto obrazy nežádoucího šumu nebo zvýraznit hrany objektů, které jsou na snímcích zobrazovány, pro jejich následnou segmentaci. Předzpracování se dále zabývá například opravováním nežádoucího pootočení obrazu nebo různými prostorovými deformacemi. Segmentací jsou pak míněny takové operace, které umožní rozdělení obrazu na jednotlivé oblasti, které spolu svými vlastnostmi nějak souvisí. Tyto oblasti pak mají význam při lokalizaci objektů, které se snažíme přiřadit objektům reálného světa. Tedy snažíme se jednotlivé části obrazu přiřadit jednotlivým částem snímaného objektu.

V medicíně má čtení snímků velký význam při určování diagnózy nebo lokalizování případného zákroku. Mezi zobrazovací metody patří například magnetická rezonance, počítačová tomografie, scintigrafie nebo pozitron emisní tomografie. Například magnetická rezonance slouží k zobrazování orgánů lidského těla. Touto metodou získáme řezy snímané části těla. To znamená soubor snímků, kde každý odpovídá jednotlivému řezu. Na jednotlivých snímcích pak musíme lokalizovat orgány a zkoumat, zda se na nich nenachází například nádory. Při velkém

množství snímků to může být časově náročné a nabízí se zde automatické zpracování. Snímky jsou však zatíženy šumem, který může vznikat například malou rozlišovací schopností přístroje, šumem prostředí nebo nedokonalostí stínění vodičů. Pro počítačové zpracování je tedy vhodné snímky zbavit tohoto šumu, aby byla možná lokalizace jednotlivých částí obrazu, v tomto případě jednotlivých orgánů nebo nádorů v nich.

V předzpracování jsou využívány metody, které pracují obecně s obrazem a nezaměřují se na konkrétní objekty na snímku. Snažíme se zde využít informace o jasu, potlačit šum nebo naopak zostřit obraz, vyhledat hrany nebo výrazné body v obrazu. Obecně se pak může jednat i o posunutí snímku nebo jeho natočení. Při hledání hran se můžeme snažit o získání oblasti, která je ohraničená touto hranou nebo oblastí se stejným jasem. U hledání významných bodů jde například o hledání ostré hrany objektu nebo míst kde na sebe dva objekty navazují nebo se překrývají. Apriorní znalost toho, co se na obrazu nachází nebo za jakých podmínek byl pořízen a jakým druhem poruch je obraz zatížen, usnadní volbu metody předzpracování. Důležité je brát na vědomí, že nejvíce informací obsahuje původní obraz a metody předzpracování tyto informace vždy nějakým způsobem zkreslují a ztrácí se vždy část informace, která je na původním snímku.

Nejjednodušší metody zabývající se jasem vycházejí z histogramu. Histogram je funkce, která vyjadřuje četnost jednotlivých stupňů jasu na daném obrazu. Počet stupňů jasu pak záleží na rozlišení, v jakém je obraz pořízen. Zvýšený výskyt jednoho stupně jasu pak poukazuje na přítomnost nějakého objektu na snímku, naopak nízké výskyty mohou znamenat místa, kde nějaký objekt přechází v jiný.

Dále jsou využívány metody geometrické, které umožňují různé transformace obrazu (např. otočení, zvětšení, zmenšení...), a to za předpokladu, že transformaci známe, například pokud známe zkreslující vadu čočky nebo když potřebujeme srovnat rozdílnou velikost objektu na obrazu způsobenou například změnou

vzdálenosti snímaného objektu.

Metody, které snižují kontrast, mají za účel především potlačit nežádoucí šum, mají ovšem tu vlastnost, že snižují ostrost hran a objekty na snímku tak mohou splynout. Obraz je po úpravě takovou metodou více či méně rozmazaný. Naopak metody, které obraz zостřují, zvýrazňují přechody jasu. To umožňuje zvýraznit například hranice objektu a jejich lepší hledání. Případný šum je ovšem zvýrazněn a může působit problémy při následné segmentaci.

2. TEORETICKÁ ČÁST


2.1. Obrazová funkce

Obraz získáme z reálného prostředí pomocí čidel, která jsou zdrojem zpravidla spojitého signálu. Pro zpracování na počítači musíme tento obraz digitalizovat. Protože se jedná o obraz dvojrozměrný, používá se vzorkování do matice bodů a kvantování jasu každého vzorku.

Interval vzorkování určuje kvalitu zpracovávaného obrazu. Vzorkovací frekvence se řídí Shannonovou větou, která říká, že vzorkovací frekvence musí být alespoň dvakrát větší než nejmenší frekvence na vzorkovaném signálu. To u obrazů znamená, že vzdálenost dvou vzorků musí být menší, než nejmenší zkoumané objekty na obraze.

Vzorkovací mřížka je geometrické uspořádání bodů, na kterých se vzorkování provádí. Tato mřížka bývá nejčastěji pravidelná. Aby byla pokryta celá plocha obrazu, lze použít jen tři různé pravidelné mnohoúhelníky, a to trojúhelník, čtverec nebo šestiúhelník (viz obr. 2.1.). Nejčastěji se používá čtvercová síť. Informace ke kapitole

byly čerpány z [1], [2].



Obr. 2.1: Příklady tvaru rastrové sítě (čtvercová, trojúhelníková, šestiúhelníková).

2.2 Reprezentace obrazu v PC pomocí bitmapy


Bitmapa neboli rastr je základní typ zobrazení, kde je obraz rozdělen do čtvercové sítě, kde každému poli této sítě (pixelu) je přiřazena hodnota určující jeho barvu. Tato skutečnost je reprezentována maticí, jejíž rozměry odpovídají rozměrům této sítě. Barva je v matici reprezentována číselnou hodnotou na odpovídající pozici matice. Pokud se jedná o černobílý obraz hodnota v matici odpovídá úrovni jasu v daném bodě, obvyklý rozsah bývá 256 úrovní (0-255), kde 0 odpovídá černé, a naopak 255 odpovídá bílé barvě.

Obrazy, které získáváme pomocí medicínských zobrazovacích metod, vznikají zpracováním signálu na základě míry útlumu nebo naměřeného indukovaného napětí a dalších parametrů. Ty se pomocí matematických transformací převedou na číselnou hodnotu. Tyto hodnoty uspořádané do matice se dají reprodukovat jako bitmapa v černobílém spektru. Rozlišovací schopnost měřícího přístroje pak ovlivní rozměry obrazu (počet pixelů) a hloubku jasu (počet úrovní šedé). Informace byly

čerpány z [1].

2.3 DICOM standard

Zkratka DICOM pochází z anglického „Digital imaging and communications in medicine“. Jedná se o datový standard pro přenos a ukládání medicínských obrazových dat vyvíjený organizacemi ACR (American College of Radiology) a NEMA (the National Electrical Manufacturers Association). Tento standard má za úkol sjednotit formát ukládání medicínských obrazových dat a usnadnit jejich přenos. Pro přenos dat je využíván síťový protokol TCP/IP. Standard DICOM definuje kromě samotných obrazových dat také informace o způsobu jejich pořízení a další informace o pacientech, studiích, reportech a dalších skupinách dat.



Obr. 2.2: Příklad obrazu DICOM (řez trupem), zdroj [8].



Obr. 2.3: Příklad obrazu DICOM (řez hlavou), zdroj [4].

Standardní rozlišení obrazů DICOM je 12 bitové. Vzhledem ke standardní rozlišovací schopnosti vizualizačních nástrojů 8 bitů je třeba tento fakt zohlednit, protože by při zobrazování mohlo dojít k zaokrouhlení na 8 bitů nebo ke zkreslení informace. Zdrojem informací jsou [3], [5].

2.4 Metody předzpracování obrazu

Předzpracováním obrazu jsou myšleny metody, které pracují s obrazem bez předchozí znalosti o jeho obsahu. Mohou to být geometrické transformace, jasové korekce, patří mezi ně například rozmazávání a ostření obrazu, dále pak detektory hran, rohů a čar nebo další, např. Tobogganing. Další kapitoly se zabývají konkrétními metodami.

2.4.1 Rozmazávání obrazu

Reálné obrazy bývají často poškozeny různými náhodnými chybami, tyto chyby se nazývají šumem. Ten vzniká v různých částech procesu pořízení fotografie, ať už během pořizování nebo jejím následných přenosem ve formě elektrického signálu. Tento šum může i nemusí být závislý na obsahu obrazu. Často se popisuje pomocí pravděpodobnostního rozdělení. Pro tento popis se často využívá bílý šum. Bílý šum je idealizovaný šum s rovnoměrnou spektrální hustotou, to znamená, že tento šum má stejný výkon v libovolném frekvenčním spektru o stejném rozsahu. Speciální případ bílého šumu je gaussovský šum.

Šum se může vyskytovat často také v podobě bílých nebo černých bodů rozestých po ploše obrazu. Tento šum vzniká nejčastěji vnitřní vadou záznamového zařízení a je nazýván „salt and pepper noise“.

Rozmazávání obrazu má za úkol se těchto šumů zbavit, přičemž apriorní znalost druhu šumu může určit vhodnou metodu jeho odstranění. Má ovšem tu nevýhodu, že rozmazává i hrany a potlačuje přechody mezi jednotlivými objekty zachycenými na obraze. Pokud jsou hrany nebo významné body v obraze příliš tenké, mohou být procesem přerušeny nebo úplně vymazány, protože v šumu zaniknou. Čerpáno z [1], [2].

2.4.1.1. Klouzavý průměr

V této metodě jde o prosté průměrování hodnoty každého pixelu a hodnot jeho sousedních pixelů. Matematicky lze toto vyjádřit jako diskrétní konvoluci původní obrazové funkce $f(x, y)$ a tzv. masky $h(i, j)$, výsledkem je funkce $g(x, y)$:

$$g(x, y) = f(x, y) * h(x, y) = \sum_{i=-k}^k \sum_{j=-k}^k f(x-i, y-j) \cdot h(i, j) \quad (2.1)$$

Funkci $h(i, j)$ zpravidla volíme čtvercovou s lichým počtem prvků v řádce

i sloupci s tím, že uprostřed se nachází centrální prvek, který umožňuje určení středu této masky. U klouzavého průměru volíme masku tak, že každý prvek matice h je roven $\frac{1}{N}$, kde N je celkový počet prvků v matici. Matice h může vypadat například takto:

$$h = \frac{1}{9} \cdot \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \quad h = \frac{1}{27} \cdot \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}. \quad (2.2)$$

Takto vzniklý obraz bude rozmazaný tím více, čím větší okolí do průměru zahrneme. V takto vzniklém obrazu dojde k potlačení šumu, ale bude zde těžší detekce významných bodů a hran, což jsou prvky, které nesou nejvíce informací o objektech, které se snažíme identifikovat. Tato metoda je vhodná, pokud máme jen velmi málo apriorních informací o tom, jaký druh šumu se v obraze nachází a jaké objekty se v obraze vyskytují. Velikost masky $h(i, j)$ volíme tak, aby nebyla větší než nejmenší prvky v původním obrazu, tím by došlo k jejich degradaci. Na okrajových pixelech obrazu dojde ke zkreslení, protože zde bude průměrováno méně prvků než na zbytku obrazu. Informace čerpány z [1], [2].

2.4.1.2 Mediánový filtr

Tato metoda je vhodná, pokud se v obraze nachází šum s velkými rozdíly v jasu, tzv. „salt and pepper noise“. Jedná se v podstatě o velmi jasné nebo velmi tmavé body náhodně rozetuté po obraze. Tento filtr je realizován tak, že se uvažuje čtvercové okolí každého pixelu, stejně jako u klouzavého průměru je vhodné použít lichý počet prvků, a hodnoty jasu vybraného pixelu i okolních pixelů se seřadí

vzestupně a vybere se hodnota prostředního z nich. V případě sudého počtu prvků se vezme průměrná hodnota prostředních dvou prvků. Tento filtr je nelineární a nerozmazává hrany, pokud nejsou příliš tenké. Je zde možné použít relativně velké okolí filtrovaného pixelu. U tenkých hran nebo rohů lze využít například alternativního tvaru filtru, kde se nebere okolí čtvercové, ale vybírají se okolní prvky pouze v řádku a sloupci filtrovaného pixelu.

Příklad mediánového filtru:

$$f(i, j) = \begin{bmatrix} 95 & 93 & 103 \\ 89 & 92 & 100 \\ 156 & 113 & 95 \end{bmatrix}. \quad (2.3)$$

Prvky matice (2.3) seřadíme vzestupně: [89, 92, 93, 95, 95, 100, 103, 113, 156]
a vybereme prostřední z nich: $g(i, j) = [95]$. Čerpáno z [1], [2].

2.4.1.3 Maximální zastoupení

Tato nelineární metoda přiřazuje vybranému pixelu hodnotu jasu, která je v jeho okolí nejčastěji zastoupená. Opět volíme nejčastěji čtvercové okolí bodu a pro každou hodnotu jasu zastoupenou v okolí nasčítáme její výskyt. Vybraný pixel pak nastavíme na hodnotu jasu s nejčastějším výskytem. Příklad tohoto filtru:

$$f(i, j) = \begin{bmatrix} 95 & 93 & 103 \\ 93 & 92 & 100 \\ 95 & 113 & 95 \end{bmatrix} . \quad (2.4)$$

Pro případ (2.4) bude pak řešením $g(i, j) = [95]$. Problém u této metody nastává, pokud žádný prvek nemá vyšší četnost než 1, nebo naopak pokud má více prvků četnost stejnou. V prvním případě je tedy vhodné uvažovat buď větší okolí centrálního pixelu nebo lze tento problém odstranit převedením na řešení pomocí jiného například mediánového filtru. V druhém případě, pokud je více hodnot s nejvyšší četností, je možné tyto hodnoty například průměrovat. Tento filtr bude vhodný pro obrazy s oblastmi se stejným jasem a s šumem soustředěným bodově. Nevhodný bude naopak pro obrazy s tenkými čarami a rohy, protože dojde k jejich porušení. Informace čerpány z [2].

2.4.1.4 Triangulace

Metoda triangulace počítá vážený průměr hodnot jasu v okolí centrálního pixelu, kde váha je funkcí vzdálenosti od tohoto centrálního bodu. Příklad pro lineární závislost může být následující:

$$h_{3 \times 3} = \frac{1}{10} \cdot \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, h_{5 \times 5} = \frac{1}{35} \cdot \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 2 & 2 & 2 & 1 \\ 1 & 2 & 3 & 2 & 1 \\ 1 & 2 & 2 & 2 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}. \quad (2.5)$$

Zdrojem informací je [2].

2.4.1.5 Gaussovský filtr

Tato asi nepoužívanější metoda využívá vážený průměr pixelů ve čtvercovém okolí centrálního pixelu, přičemž váhy pixelů odpovídají exponenciální vzdálenosti od centrálního pixelu. Výsledná obrazová funkce $g(x, y)$ bude diskrétní konvolucí původní obrazové funkce $f(x, y)$ a váhové funkce $h(i, j)$, neboli masky. Viz rovnice (2.6).

$$g(x, y) = \sum_{i=-k}^k \sum_{j=-k}^k f(x-i, y-j) \cdot h(i, j). \quad (2.6)$$

Příklad masky h , pro matici 3x3 se standardní odchylkou $\sigma^2=0,5$ (2.7):

$$h = \begin{bmatrix} 0,0113 & 0,0838 & 0,0113 \\ 0,0838 & 0,6193 & 0,0838 \\ 0,0113 & 0,0838 & 0,0113 \end{bmatrix}. \quad (2.7)$$

Gaussovský filtr je generován podle rovnice gaussovského rozdělení a jeho koeficienty jsou normovány, aby měly celkový součet roven jedné. Tento filtr je vhodný pro odstranění tzv. gaussovského šumu, který je považován za nejčastěji se vyskytující v praktických případech. Čím větší rozměr masky použijeme při zachování směrodatné odchylky, tím dostaneme rozmazanější obraz a dojde tím k většímu

potlačení šumu, ale i hran a rohů. Směrodatná odchylka má pak vliv na váhu, kterou jsou zohledňovány okolní pixely. Čím vyšší je hodnota směrodatné odchylky, tím více závislost váhy na vzdálenosti od centrálního pixelu klesá a to způsobuje rovněž větší rozmazání hran a rohů. Informace pro kapitolu čerpány z [1], [2].

2.4.2 Ostření obrazu

Jedním z přístupů, jak rozpoznávat objekty v obraze je, že se zaměříme na výrazné body nebo hrany a snažíme se sledovat jejich tvar, ten pak porovnáváme s tvary objektů, které se na obraze mohou vyskytovat. Ostření obrazu je takový proces, jehož cílem je zvýraznit jasové přechody tam, kde je jejich změna největší. V tomto případě nejde o získání realistického obrazu pro člověka, ale o snahu získat hrany, které slouží k následné segmentaci obrazu. Další možností je například sčítání hodnot jasu původního obrazu a obrazu filtrovaného, například gaussovským filtrem. Výsledkem je pak obraz s výraznějšími jasovými přechody. Zdrojem dat je [2].

2.4.3 Detekce hran

Hrana je místo, kde dochází k velké změně jasu. Při vnímání obrazu jsou tyto místa nejdůležitější a pokud budeme uvažovat v obraze pouze místa s velkou změnou jasu a ostatní zanedbáme, ve většině případů to nemění chápání obsahu obrazu. Bude se jednat o obraz vzniklý pouze z obrysů objektů. Výhodou je, že tím rapidně ubývá množství dat, které je v takovém zjednodušeném obraze obsaženo.

Takto získané hranové obrazy jsou pak základem pro další zpracování. Je třeba si uvědomit, že hrany mohou vznikat i na jiných místech, než je prostorový přechod dvou různých objektů na obraze, ale například i změnou barvy v jednom objektu, odlesky způsobenými nasvícením nebo šumem, který je v obraze přítomen.

Pixel hrany má ve svém okolí další pixely, které jsou pokračováním této hrany a pixely, které do hrany nepatří. K hledání směru pokračování hrany se používají metody využívající gradient jasové funkce. Směr gradientu odpovídá směru největšího nárůstu hodnoty směrem od černé $f(x,y)=0$ k bílé $f(x,y)=255$, pokud budeme předpokládat rozsah 256 úrovní jasu. Směr hrany pak bude ve směru normály, což je směr, kde dochází k nejmenší změně. Máme tři základní typy gradientních operátorů:

- 1) Operátory využívající aproximace první derivace pomocí diference. Orientace hrany je odvozována podle masky, která při konvoluci s jasovou funkcí má nejvyšší hodnotu.
- 2) Metody srovnávající obrazovou funkci s parametrickými modely hran.
- 3) Metody využívající průchody nulou druhé derivace obrazové funkce. Příkladem tohoto operátoru je Laplaceův operátor (viz kapitola 2.2.3.6)

Informace čerpány z [1], [2].

2.4.3.1. Robertsův operátor

Je jedním z nejstarších operátorů a patří mezi nejjednodušší. Je jednoduché ho spočítat, protože využívá jenom okolí dvou pixelů. Jeho maska má následující tvar:

$$h_1 = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}. \quad (2.8)$$

Hodnota hrany se počítá ze vztahu:

$$|g(i, j) - g(i+1, j+1)| + |g(i, j+1) - g(i+1, j)|. \quad (2.9)$$

Hlavní nevýhodou Robertsova operátoru je, že je velmi citlivý na šum, protože

využívá jen velmi malého okolí pro odhad gradientu. Čerpáno z [1], [2].

2.4.3.2 Operátor Prewittové

Tento operátor aproximuje první derivaci. Základní varianta počítá s maskou se třemi řádky a sloupci, lze ovšem použít i větší počty. Gradient je definován jedním z osmi směrů podle toho, se kterou maskou vrací konvoluce obrazové funkce vyšší hodnotu v daném bodě. Masky operátoru Prewittové:

$$\begin{aligned}
 h_1 &= \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, h_4 = \begin{bmatrix} -1 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix}, \\
 h_5 &= \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}, h_6 = \begin{bmatrix} 0 & -1 & -1 \\ 1 & 0 & -1 \\ 1 & 1 & 0 \end{bmatrix}, h_7 = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}, h_8 = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -1 \end{bmatrix}.
 \end{aligned} \tag{2.15}$$

Zdrojem informací byly [1], [2].

2.4.3.3 Sobelův operátor

Sobelův operátor se také používá jako detektor horizontálních a vertikálních hran. V tomto případě se použijí jen masky h_3 pro osu x a h_1 pro osu y. Sílu hrany d pak získáme ze vztahu:

$$d = \sqrt{x^2 + y^2} \text{ nebo } d = |x| + |y|, \tag{2.16}$$

směr hrany s je pak:

$$s = \arctg(y/x). \tag{2.17}$$

$$\begin{aligned}
h_1 &= \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, h_4 = \begin{bmatrix} -2 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 2 \end{bmatrix}, \\
h_5 &= \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}, h_6 = \begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix}, h_7 = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}, h_8 = \begin{bmatrix} 2 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -2 \end{bmatrix}.
\end{aligned} \tag{2.18}$$

Informace pro kapitolu čerpány z [1], [2].

2.4.3.4 Robinsonův operátor

$$\begin{aligned}
h_1 &= \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{bmatrix}, h_4 = \begin{bmatrix} -1 & -1 & 1 \\ -1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \\
h_5 &= \begin{bmatrix} -1 & -1 & -1 \\ 1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, h_6 = \begin{bmatrix} 1 & -1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & 1 \end{bmatrix}, h_7 = \begin{bmatrix} 1 & 1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & -1 \end{bmatrix}, h_8 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & -1 \\ 1 & -1 & -1 \end{bmatrix}.
\end{aligned} \tag{2.19}$$

Zdrojem je [2].

2.4.3.5 Kirschův operátor

$$\begin{aligned}
h_1 &= \begin{bmatrix} 3 & 3 & 3 \\ 3 & 0 & 3 \\ -5 & -5 & -5 \end{bmatrix}, h_2 = \begin{bmatrix} 3 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & -5 & 3 \end{bmatrix}, h_3 = \begin{bmatrix} -5 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & 3 & 3 \end{bmatrix}, h_4 = \begin{bmatrix} -5 & -5 & 3 \\ -5 & 0 & 3 \\ 3 & 3 & 3 \end{bmatrix}, \\
h_5 &= \begin{bmatrix} -5 & -5 & -5 \\ 3 & 0 & 3 \\ 3 & 3 & 3 \end{bmatrix}, h_6 = \begin{bmatrix} 3 & -5 & -5 \\ 3 & 0 & -5 \\ 3 & 3 & 3 \end{bmatrix}, h_7 = \begin{bmatrix} 3 & 3 & -5 \\ 3 & 0 & -5 \\ 3 & 3 & -5 \end{bmatrix}, h_8 = \begin{bmatrix} 3 & 3 & 3 \\ 3 & 0 & -5 \\ 3 & -5 & -5 \end{bmatrix}.
\end{aligned} \tag{2.20}$$

Zdrojem je [2].

2.4.3.6 Laplaceův operátor

Jedná se o operátor, který aproximuje druhou derivaci a dává nám pouze velikost hrany, nikoliv její směr. Masky tohoto operátoru využívá okolních čtyř nebo osmi pixelů. Tato maska slouží rovněž k hledání významných samostatně stojících bodů nebo tzv. „blobů“, což jsou oblasti se stejným jasem.

$$h_{4\text{okolí}} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}, h_{8\text{okolí}} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}. \quad (2.10)$$

Aproximace Laplaceova operátoru:

$$\nabla^2 = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} \quad (2.11)$$

$$\Delta x^2 f(i, j) = f(i, j+1) + f(i, j-1) - 2f(i, j) \quad (2.12)$$

$$\Delta y^2 f(i, j) = f(i+1, j) + f(i-1, j) - 2f(i, j)$$

$$\nabla^2 f(i, j) = \Delta x^2 f(i, j) + \Delta y^2 f(i, j) \quad (2.13)$$

$$\nabla^2 f(i, j) = f(i, j+1) + f(i, j-1) + f(i+1, j) + f(i-1, j) - 4f(i, j) \quad (2.14)$$

Informace čerpány z [1], [2].

2.4.3.7 Cannyho detektor

Tento detektor je algoritmem pro co nejlepší detekci hran, sestávajícím se z několika kroků. Optimální detekce hran byla definována třemi kritérii.

- 1) Kritérium detekce. To říká, že důležité hrany nesmí být ztraceny a naopak nesmí být detekována místa, které hranami nejsou.
- 2) Kritérium přesnosti. Mezi polohou hrany a místem, kde je hrana

detekována, musí být minimální rozdíl.

- 3) Kritérium jednoznačnosti. Na detekovanou hranu musí být právě jedna odezva. Toto kritérium řeší problém zdvojení detekovaných hran.

Tento detektor využívá pro eliminaci nežádoucího šumu v obrazu gaussovský filtr. Po filtraci je určen gradient v každém pixelu, k tomu slouží aproximace první derivace. Následuje hledání lokálních maxim (Non-maximal suppression). To znamená, že se odeberou hodnoty gradientů, které nejsou maximem ve svém okolí, ve směru kolmém na hranu (ve směru gradientu).

Následuje prahování, které má za úkol potlačit nevýznamná lokální maxima gradientů. Detektor využívá dvou úrovní prahování. Horní hranice určuje, které hodnoty jsou považovány za hranu. Dolní hranice určuje, které hodnoty jsou ještě považovány za hranu, ale pouze v případě, že tyto body leží v těsné blízkosti bodů již za hranu označených. Zdroj informací pro kapitolu je [2].

2.4.4. Detekce čar

Další skupinou operátorů jsou detektory čar, které patří obecně do hledání hran a výrazných bodů. Čáry jsou tenké křivky nebo rovné linie, které nemění svůj směr ostře. Pro detekci ostrých hran jsou pak detektory rohů nebo bodů. Dalším předpokladem je, že jejich tloušťka je o šířce přibližně jednoho až dvou pixelů. Nejjednodušší masky pro tyto detektory jsou:

$$h_1 = \begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix}, h_4 = \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix}. \quad (2.21)$$

Informace čerpány z [2].

2.4.5. Detekce rohů

Detekce rohů může být velmi důležitá, máme-li například dva obrazy, kde se nachází stejné objekty. Najdeme-li na obou těchto obrazech rohy odpovídající stejným částem objektu, můžeme pak z jejich poloh získat informace o vzájemné geometrické transformaci. Touto stejnou transformací jsou s největší pravděpodobností modifikovány všechny pixely obrazu. S využitím této informace se dá velmi dobře zjednodušit porovnávání jednotlivých objektů, protože nám stačí ke kompletnímu popisu mnohem menší množství informace. Čerpáno z [2].

2.4.5.1 Moravcův detektor

Nejjednodušším detektorem rohů je Moravcův detektor, který vrací nejvyšší hodnotu u pixelů s nejvyšším kontrastem. To jsou takové pixely, které jsou v rozích a ostrých hranách.

$$M(x, y) = \frac{1}{8} \sum_{k=x-1}^{x+1} \sum_{l=y-1}^{y+1} |f(k, l) - f(x, y)| \quad (2.22)$$

Zdrojem je [2].

2.4.5.2 Harrisův detektor

Jedná se o vylepšený Moravcův detektor, který počítá místo absolutní hodnoty sumy kvadrátů diferencí na svém okolí W .

$$H(x, y) = \begin{bmatrix} \sum_{x_i \in W} \sum_{y_i \in W} \frac{\partial^2 f(x_i, y_i)}{\partial x^2} & \sum_{x_i \in W} \sum_{y_i \in W} \frac{\partial f(x_i, y_i)}{\partial x} \cdot \frac{\partial f(x_i, y_i)}{\partial y} \\ \sum_{x_i \in W} \sum_{y_i \in W} \frac{\partial f(x_i, y_i)}{\partial x} \cdot \frac{\partial f(x_i, y_i)}{\partial y} & \sum_{x_i \in W} \sum_{y_i \in W} \frac{\partial^2 f(x_i, y_i)}{\partial y^2} \end{bmatrix}. \quad (2.23)$$

Tato Harrisova matice je symetrická a pozitivně semidefinitní. Pokud jsou obě vlastní čísla této matice malá, znamená to, že v tomto okolí nejsou žádné hrany nebo rohy. Druhá možnost, jedno vlastní číslo je malé a druhé velké, znamená, že se v okolí nachází hrana. Poslední možnost, obě vlastní čísla matice jsou velká, znamená, že dochází k významné změně v obou směrech. To odpovídá nalezení rohu. Informace čerpány ze zdroje [2].

2.4.5.3 Zuniga – Haralickův operátor

Obrazová funkce je v okolí pixelu $p(i, j)$ aproximována polynomem 3. stupně s koeficienty c_k :

$$f(i, j) = c_1 + c_2 x + c_3 y + c_4 x^2 + c_5 xy + c_6 y^2 + c_7 x^3 + c_8 x^2 y + c_9 xy^2 + c_{10} y^3. \quad (2.24)$$

Hodnota operátoru je pak:

$$Z(i, j) = \frac{-2(c_2^2 c_6 - c_2 c_3 c_5 + c_3^2 c_4)}{(c_2^2 + c_3^2)^{3/2}}. \quad (2.25)$$

Zdrojem je [2].

2.4.5.4 Kitchen – Rosenfeldův operátor

Obrazová funkce je aproximována stejným polynomem, jako u Zuniga – Haralickova operátoru (2.24), ale jeho hodnota se počítá:

$$K(i, j) = \frac{-2(c_2^2 c_6 - c_2 c_3 c_5 + c_3^2 c_4)}{(c_2^2 + c_3^2)}. \quad (2.26)$$

Informace čerpány z [2].

2.4.6 Tobogganing

Toto je metoda předzpracování obrazu, která pracuje s hranami. Princip je takový, že pro každý pixel obrazu se v jeho okolí hledá pixel s nižší hodnotou, ze kterého se postupuje dále na další pixel s nižší hodnotou až do té doby, než nalezneme lokální minimum. Označíme tento bod a všechny body, přes které jsme se do tohoto minima dostali, jednoznačnou hodnotou. Postoupíme na další pixel. Pokud se při cestě dostaneme na již označený pixel, všem předchůdcům přiřadíme nalezenou hodnotu. Získáme tak jednotlivé oblasti, které jsou označeny stejnou hodnotou a jsou oddělené hranami. Zdroj [7].

3. PRAKTICKÁ ČÁST

3.1. Metody pro rozmazávání obrazu

3.1.1. Klouzavý průměr

Na obr. 3.1 je vidět, jaký vliv má na původní obraz prosté průměrování okolních pixelů. Je zde vidět, že čím je maska většího rozměru, k tím většímu dojde zkreslení původního obrazu. Viditelné je rovněž vyhlazení šumu, ale i rozmazání ostrých hran. Původní obraz je rozměrů 512 x 512 pixelů a použité masky 5x5 a 9x9 pixelů. U masky 9x9 již dochází ke značné ztrátě informace. Na okraji obrazu, kde je použita maska 9x9, lze pozorovat větší zkreslení, které je způsobeno tím, že se maska dostává mimo obraz a do průměru se započítává méně pixelů, než v částech uvnitř obrazu.



Obr. 3.1: Původní obraz (vlevo), aplikovaný klouzavý průměr s maskou 5x5 (uprostřed) a maskou 9x9 (vpravo).

3.1.2. Mediánový filtr

Jedná se o filtr nelineární a tudíž dochází k nerovnoměrnému zkreslení, to se jeví jako nerovnoměrné „rozpíjení“ obrazu. Tento filtr je vhodnější spíše na odstraňování šumu s extrémně vysokými nebo nízkými hodnotami. Takový šum se nazývá „salt & pepper noise“. Na obr. 3.3 je příklad obrazu zatíženého právě takovým šumem a jeho odstranění pomocí mediánového filtru. Na odstranění šumu se jeví být postačující již maska o rozměrech 3x3 pixely.



Obr. 3.2: Původní obraz (vlevo), aplikovaný mediánový filtr s maskou 5x5 (uprostřed) a maskou 9x9 (vpravo).




Obr. 3.3: Původní obraz zatížený šumem salt & pepper (vlevo), šum odstraněný mediánovým filtrem s maskou 3x3 (uprostřed) a 5x5 (vpravo).

3.1.3. Gaussovský filtr

Tento filtr využívá váženého průměru okolí pixelu podle velikosti masky s tím, že váha je definována podle vzdálenosti od centrálního pixelu normálním (gaussovským) rozdělením. Parametry tohoto filtru jsou velikost masky a směrodatná odchylka. Pokud budeme zvětšovat velikost masky při stejné směrodatné odchylce, musíme rozlišit dva případy:

- 1) Směrodatná odchylka je malá, například $\sigma=0,5$, pak zvětšování masky na více než 3x3 prakticky výsledek neovlivní (viz obr. 3.4), protože váha pixelů na vzdálenějších pozicích od středu je velmi malá (viz matice 3.1). V matici $h_{5 \times 5}$ je na pozici (1,1) hodnota přibližně $7 \cdot 10^{-8}$ a na pozici (2,1) resp. (1,2) hodnota přibližně $2,8 \cdot 10^{-5}$. To znamená, že vliv hodnoty těchto pixelů na výsledek je téměř zanedbatelný.



Obr. 3.4: Původní obraz (vlevo), Obraz po aplikaci gaussovského filtru s maskou 3x3 a $\sigma=0,5$ (uprostřed), a maskou 5x5 a $\sigma=0,5$ (vpravo).

$$h_{3 \times 3} = \begin{bmatrix} 0,0113 & 0,0838 & 0,0113 \\ 0,0838 & 0,6193 & 0,0838 \\ 0,0113 & 0,0838 & 0,0113 \end{bmatrix}, h_{5 \times 5} = \begin{bmatrix} 0,0000 & 0,0000 & 0,0002 & 0,0000 & 0,0000 \\ 0,0000 & 0,0113 & 0,0837 & 0,0113 & 0,0000 \\ 0,0002 & 0,0837 & 0,6187 & 0,0837 & 0,0002 \\ 0,0000 & 0,0113 & 0,0837 & 0,0113 & 0,0000 \\ 0,0000 & 0,0000 & 0,0002 & 0,0000 & 0,0000 \end{bmatrix}. \quad (3.1)$$

- 2) Budeme-li však uvažovat vyšší hodnotu směrodatné odchylky, například $\sigma=2$, bude mít velikost masky větší vliv na výsledný obraz (viz obr. 3.5). Z matic (3.2) je zřejmé, že při vyšší směrodatné odchylce se snižuje vliv centrálního prvku a roste význam prvků dále od středu masky. A proto roste vliv velikosti masky. V limitním případě se při zvětšování směrodatné odchylky dostáváme k hodnotám $1/N$ pro každý prvek masky, kde N je počet prvků matice, což odpovídá hodnotám masky u klouzavého průměru (kapitola 3.1.1), kde velikost masky je jediným parametrem.



Obr. 3.5: Původní obraz (vlevo), obraz po aplikaci gaussovského filtru s maskou 3x3 a $\sigma=2$ (uprostřed) a maskou 7x7 a $\sigma=2$ (vpravo).

$$h_{3 \times 3} = \begin{bmatrix} 0,1019 & 0,1154 & 0,1019 \\ 0,1154 & 0,1308 & 0,1154 \\ 0,1019 & 0,1154 & 0,1019 \end{bmatrix}, h_{5 \times 5} = \begin{bmatrix} 0,0232 & 0,0338 & 0,0383 & 0,0338 & 0,0232 \\ 0,0338 & 0,0492 & 0,0558 & 0,0492 & 0,0338 \\ 0,0383 & 0,0558 & 0,0632 & 0,0558 & 0,0383 \\ 0,0338 & 0,0492 & 0,0558 & 0,0492 & 0,0338 \\ 0,0232 & 0,0338 & 0,0383 & 0,0338 & 0,0232 \end{bmatrix}. \quad (3.2)$$

Budeme-li zvětšovat směrodatnou odchylku, při stejné velikosti masky, bude docházet k většímu rozmazávání. Tedy k většímu potlačení šumu, ale i hran a dalších informací v obrazu (viz obr. 3.6).




Obr. 3.6: Obrázek po aplikaci gaussovského filtru s maskou 7×7 a $\sigma=1$ (vlevo) a maskou 7×7 a $\sigma=5$ (vpravo). Původní obrázek je stejný jako u obrázku na obr. 3.5.

3.2. Metody detekce hran

3.2.1 Robertsův operátor

Jak již bylo řečeno v teoretické části (kapitola 2.2.3.1), tento detektor hran zohledňuje jen malé okolí zkoumaného pixelu, tudíž je velmi citlivý na šum v obraze. Při detekci hran je důležité nastavení prahování, které definuje, jak velký rozdíl v jasu je považován za hranu. Výsledkem operátoru jsou hodnoty gradientu v každém pixelu obrazu. Podle nastavené úrovně prahování jsou vybrány takové hodnoty, které překračují zadanou hodnotu a ty jsou považovány za body hrany. Z nich je pak sestaven binární obraz, tzn. že obsahuje pouze černou a bílou barvu. Bílá reprezentuje hranu, černá všechny ostatní body. Díky tomu je množství informace, která je obsažena v obraze, velice redukováno. Pro rozpoznání obsahu obrazu by to však při správném nastavení prahu nemělo způsobit problém.



Obr. 3.7: Originální obraz (vlevo), Robertsův operátor použitý na obraz s prahem 5% (uprostřed), hranový obraz s prahem 20% (vlevo).

Z obrazu (3.7) vyplývá, že 5% práh je zřejmě příliš nízký pro rozpoznání objektů v obraze, naopak práh 20% je příliš vysoký. Vzhledem k citlivosti Robertsova hranového detektoru na šum se nabízí možnost napřed tento šum odstranit některou z metod pro filtrování obrazu a až následně použít hranový detektor. Na obrazu (3.8) je demonstrován vliv filtrace „salt and pepper“ šumu na výsledek hranového detektoru. Na obrazy je použit detektor se stejným prahem (8%) pro detekci hran, na obraz vpravo je nejprve použit mediánový filtr na odstranění šumu.



Obr. 3.8: Původní "zašuměný" obraz (vlevo), detekce hran na původním obrazu (uprostřed), obraz nejprve zbaven šumu mediánovým filtrem (vpravo).

3.2.2 Operátor Prewittové

Operátor Prewittové využívá k detekci hrany okolí pixelu o velikosti 3x3, proto je méně citlivý na šum než Robertsův (kapitola 3.2.1). To umožňuje detekování hran

v obrazu, který je předtím vyhlazován s menší intenzitou. Jelikož každé vyhlazení zmenšuje množství informace, která je v obrazu obsažena, je žádoucí, aby bylo vyhlazení co nejmenší. Pro detekci hran je naopak žádoucí, aby obraz obsahoval co nejméně šumu a to zase znamená vyhlazení větší. Úkolem je tedy najít kompromis. Hranový detektor Prewittové je výhodnější než Robertsův právě proto, že vyžaduje zpravidla menší vyhlazení pro stejný nebo i lepší výsledek hranové detekce. Pokud použijeme masky:


$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}, \quad h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, \quad (3.3)$$

můžeme tak získat detektor horizontálních nebo vertikálních hran (obr. 3.9).



Obr. 3.9: Původní obraz (vlevo), detekce horizontálních (uprostřed) a vertikálních (vpravo) hran operátorem Prewittové.

I zde je samozřejmě důležité nastavení prahu pro správnou detekci hran. Navíc pokud je obraz předem filtrován, můžeme získat lepší výsledky s vyšším prahem. Nízký práh bude opět reprodukovat šum jako možnou hranu. (obr. 3.10)



Obr. 3.10: Původní obraz (vlevo), detektor Prewittové s prahem 5% (uprostřed) a s prahem 10% (vpravo).

3.2.3 Sobelův operátor

Sobelův operátor je velmi podobný operátoru Prewittové (kapitola 3.2.2) Opět se jedná o metodu detekce hran založenou na aproximaci gradientu prvního řádu, liší se pouze ve váze pixelů v bezprostřední blízkosti centrálního pixelu. Stejně jako u operátoru Prewittové rovněž zohledňuje okolí 3x3 pixely. I tento hranový detektor umožňuje detekci horizontálních a vertikálních hran.



Obr. 3.11: Původní obraz (vlevo), hranová detekce pomocí Sobelova operátoru s prahem 5% (uprostřed) a prahem 10% (vpravo).

Z obrazu (3.11) je opět zřejmé, že je stále dobře poznat obsah obrazu. I přes to, že je co do množství informace obsažené v obraze velice redukován.


3.2.4 Aproximace druhé derivace

Filtry založené na aproximaci první derivace hledají maximum nebo minimum v derivaci obrazové funkce, kde je předpokládána hrana v obrazu. U druhé derivace se bude tudíž jednat o místa, kde funkce prochází nulou. Principiálně je jednodušší hledat průsečíky s nulou než lokální extrémy. Problémem ovšem je, jak obstarat robustnost výpočtu druhé derivace. Jednou z možností je na obraz aplikovat vyhlazovací filtr před výpočtem druhé derivace, aby se odstranil šum v obraze. Nejvhodnějším je Gaussův filtr. Pro získání druhé derivace lze použít Laplaceův operátor, který je nezávislý na orientaci. Detektor hran, který využívá Laplaceův operátor obrazové funkce po vyhlazení Gaussovým filtrem, za použití konvoluce (viz rovnice 3.4), je znám pod názvem „Laplacian of Gaussian“ (LoG).


$$L_{oG} = \nabla^2 [G(x, y, \sigma) * f(x, y)]. \quad (3.4)$$

Vzhledem k linearitě lze prohodit pořadí operací konvoluce a diferenciací:

$$L_{oG} = [\nabla^2 G(x, y, \sigma)] * f(x, y). \quad (3.5)$$



Obr. 3.12: Původní obraz (vlevo), hledání hran pomocí LoG s nižším prahem (uprostřed) a s vyšším prahem (vpravo).





Obr. 3.13: Původní obraz (vlevo), hledání hran pomocí LoG s nižší směrodatnou odchylkou při filtrování šumu (uprostřed) a s vyšší směrodatnou odchylkou (vpravo).

Z obrazu (3.13) je zřejmé, že výsledek je velmi závislý na nastavení parametrů. Pokud použijeme filtr, který bude méně redukovat šum, může se pak tento šum zobrazovat jako hrana. V opačném případě můžeme potlačit hrany, které chceme zobrazit. Dalším parametrem je úroveň prahování, které ovlivní, jak silná hrana bude zobrazena (obr. 3.12). Informace čerpány z [2].


3.2.5 Cannyho detektor

V teoretické části bylo zmíněno, že tento detektor využívá dvou úrovní prahování pro detekci hran (kapitola 2.2.3.7). Na obraze (3.15) je vidět, že při nastavení nižších úrovní prahování je za hranu považováno více bodů a rovněž jsou tyto hrany delší, protože dolní práh, který určuje, že se jedná stále ještě o hranu, je

nižší (viz obr. 3.15). Rovněž je patrné, že čím je obraz více rozmazaný filtrováním šumu, tím méně obsahuje detekovatelných hran (viz obr. 3.14).



Obr. 3.14: Původní obraz (vlevo), Cannyho hranový detektor s použitím menší filtrace (uprostřed) a větší filtrace (vpravo).



Obr. 3.15: Původní obraz (vlevo), Cannyho hranový detektor s nižšími úrovněmi prahování (uprostřed), s vyššími úrovněmi prahování (vpravo).

3.3 Hledání vhodné kombinace filtrů a detekce hran u DICOM obrazů

V předchozích kapitolách byly popsány jednotlivé metody a jejich vliv na původní obraz. Tato kapitola bude zaměřena na hledání vhodné kombinace filtrů a hranových detektorů. Cílem je nalézt vhodnou kombinaci pro následné zpracování obrazu formátu DICOM na daném vzorku dat. K dispozici jsou obrazy z počítačové tomografie axiálních řezů trupem s hloubkou 16 bitů (využito jen 12 bitů) a rozměrech 512 x 512 pixelů. Zdrojem dat je [8].

Jak je již uvedeno výše v popisu obrazových dat formátu DICOM, tato data mají hloubku dat 12 bitů na pixel. Zobrazit na PC je možné pouze 8 bitů, což je 256 úrovní šedé. Musíme tedy upravit zdrojová data tak, abychom je dokázali zobrazit v rozsahu 8 bitů. Jednou z možností je vybrat jen takové pásmo, které obsahuje data, která chceme zkoumat. Převédeme tedy původní rozsah dat rovnoměrně na šířku 8 bitů. Zde dojde ke ztrátě dat úměrné šířce zkoumaného pásma.

Jako vhodná filtrace obrazů se nabízí filtrace mediánovým filtrem, protože obrazy jsou zatíženy šumem v podobě tmavých a světlých zrn (salt & pepper noise). Parametrem tohoto filtru je velikost jeho masky. Z testů vyplývá, že nejvhodnější se jeví maska 5x5. U masky 3x3 je sice šum mírně potlačen, ale hranové detektory stále na tento šum dosti citlivě reagují. Naopak u masky 7x7 již dochází k velkému zkreslení hran a jejich potlačení.




Obr. 3.16: Původní obraz (vlevo), mediánový filtr s maskou 5x5 (uprostřed), mediánový filtr s maskou 7x7 (vpravo).

Na obrazu (3.16) je vidět, že na obrazu filtrovaném mediánovým filtrem 5x5 nedochází ještě k významnému potlačování hran ani objektů na obrazu, ale na obrazu filtrovaném s maskou 7x7 je již zřejmé, že dochází ke ztrátě informace, například bílé linie na dolní části obrazu, která je filtrem zcela potlačena.

Když však srovnáme původní obraz a obraz filtrovaný 3x3 nebo 5x5 mediánovým filtrem, získáme určitě lepší výsledek, než když budeme detekovat hrany přímo na původním obrazu. Je tedy zřejmé, že tento filtr je vhodné použít.

U jednodušších hranových detektorů, jako je Sobelův nebo Prewittové, je vhodnější filtr s maskou 5x5, který potlačuje šum na dostatečnou úroveň. Je pak možné snížit úroveň prahování a získat tak citlivější hranový detektor, který nezobrazuje šum.



Obr. 3.17: Sobelův hranový detektor použitý na obraz po filtraci mediánovým filtrem s maskou 5x5. Úroveň prahování 4% (vlevo), 3% (uprostřed) a 2% (vpravo).

Na obrázků (3.17) je vidět, že lze použít detektor s prahováním kolem 3-4%, aniž by došlo k zaplnění obrázků hranami vzniklými šumem. U úrovně prahu kolem 2% již dochází k tomu, že jsou zobrazovány hrany, které nemají v obrázků význam a jsou způsobeny šumem.

U pokročilejších hranových detektorů, jako je například Cannyho hranový detektor, dostáváme lepších výsledků než u jednodušších, a to i když použijeme při filtraci mediánový filtr s maskou 3x3. Je to dáno tím, že tento detektor ve svém algoritmu provádí filtraci gaussovským filtrem, který šum ještě více potlačí. Nicméně i u tohoto detektoru dostáváme nejlepších výsledků při předzpracování mediánovým filtrem s maskou 5x5 (obr. 3.18).




Obr. 3.18: Cannyho hranový detektor použitý na původní obrázek bez filtrace (vlevo), po filtraci mediánovým filtrem s maskou 3x3 (uprostřed) a s maskou 5x5 (vpravo).


3.4 Tobogganing

Příklad hledání oblastí algoritmem tobogganingu. Jedná se o další možný přístup k úloze předzpracování, kde každé oblasti je přiřazena unikátní hodnota. Pokud tyto hodnoty převedeme do rozsahu 0-255, může být výsledek zobrazen jako černobílý obrázek, kde hodnotám přiřadíme jednotlivé odstíny šedé (viz obr. 3.19). V tomto případě barva oblasti neodpovídá barvě skutečné, jedná se pouze o reprezentaci hodnoty. Pro větší přehlednost se pracuje s obrázkem o rozměrech

128x128 pixelů.



obr. 3.19: Příklad tobogganingu. Původní obraz (vlevo), nalezené oblasti (vpravo).



obr. 3.20: Oblasti nalezené tobogganinem ohraničené červeně (vlevo) Původní obraz je stejný jako 3.19.

4. ZÁVĚR

Do předzpracování obrazu patří metody, které bez apriorní znalosti zlepšují možnost čtení obrazů nebo jejich následného zpracování. Mezi takové metody patří například jasové korekce nebo geometrické transformace. Dále to mohou být metody rozmazávání obrazu, které se provádí za účelem potlačení šumu, který je obsažen v obrazu. Metody, které mají za účel zostřit obraz nebo zvýraznit hrany, pak pomáhají při čtení obrazu tím, že zdůrazní jasové přechody, které obsahují největší množství informace o významu obrazu a jeho obsahu.

Výběr nejvhodnější metody pro potlačení šumu závisí na druhu šumu, který je v obrazu obsažený. Šum zapříčiněný náhodnými vlivy, který je považován za nejčastější, může být způsobován například vlivem teploty, elektromagnetického záření, dále třeba špatnými světelnými podmínkami nebo chybou přenosu informace ze senzoru apod. Nejvhodnějším filtrem odstraňujícím tento šum, jak bylo zjištěno v praktické části práce, se jeví být gaussovský filtr. Gaussovský filtr využívá normálního rozdělení, které je považováno za vhodný popis náhodně vzniklých chyb. Volba parametrů filtru pak závisí na velikosti obrazu a velikosti objektů, které je na

obrazu potřeba rozpoznat.

Příklad šumu, který je způsobený nedokonalým snímacím zařízením je tzv. „salt & pepper“ šum, což je typické zrnění způsobené velmi tmavými nebo světlými body v obrazu. Na odstranění takového šumu je podle experimentů nevhodnější mediánový filtr, který odstraňuje právě šum s extrémními hodnotami.

Z metod předzpracování detekujících hrany je podle experimentů nejlepší Cannyho hranový detektor, což je algoritmus, který spojuje filtraci a následnou detekci hran založenou na aproximaci první derivace a hledání uzavřených hran. Tento filtr je ze zkoumaných nejsložitější, ale má nejlepší výsledky, protože obsahuje kroky, které zabraňují detekci hran tam, kde nejsou a naopak dokáže najít i části hran, které nejsou tak výrazné.

Pro volbu nevhodnějších metod je důležitá informace o tom, co se na obrazech nachází za objekty a za jakých podmínek byly pořízeny. Algoritmy, které budou využívat vhodné metody předzpracování a budou využívat apriorních informací o obrazech, pak mohou poskytovat ještě lepší výsledky a další pokrok v této oblasti.

5. POUŽITÉ ZDROJE

- [1] Ing. Miloš Železný, Ph.D. : Zpracování digitalizovaného obrazu, přednášky KKY/ZDO
- [2] Milan Šonka, Václav Hlaváč, Roger Boyle : Image Processing Analysis, and Machine Vision, International student edition 2008, Third edition
- [3] Isaac H. Bankman : Handbook of medical image processing and analysis, 2009 Academic Press
- [4] Vydáno autorem („en:user:theBrain“) pod licencí GFDL (GNU Free Documentation License)
- [5] Digital Imaging and Communications in Medicine (DICOM), Part 14: Grayscale Standard Display Function, url.: <http://medical.nema.org/standard.html>
- [6] The MathWorks, Inc. : Image Processing Toolbox, User's Guide 2011
- [7] J Faireld. Toboggan contrast enhancement for contrast segmentation. 1990 Proceedings 10th International Conference on Pattern Recognition, pages 712-716, 1990.

[8] Obrazové příklady standardu DICOM byly poskytnuty Katedrou kybernetiky Fakulty aplikovaných věd Západočeské univerzity v Plzni. Data byla před použitím důkladně anonymizována.