



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV RADIOELEKTRONIKY

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF RADIO ELECTRONICS

HODNOCENÍ KVALITY SNÍMKŮ SÍTNICE

QUALITY ASSESSMENT OF RETINAL IMAGES

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

MAREK TVARŮŽEK

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. RADIM KOLÁŘ, Ph.D.

BRNO 2011



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav radioelektroniky

Bakalářská práce

bakalářský studijní obor
Elektronika a sdělovací technika

Student: Marek Tvarůžek

ID: 70017

Ročník: 3

Akademický rok: 2010/2011

NÁZEV TÉMATU:

Hodnocení kvality snímků sítnice

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s vlastnostmi barevných snímků sítnice pořízených digitální fundus kamerou a s principem funkce těchto kamer. Dále prostudujte základy zpracování obrazů včetně bodových a lokálních operací a spektrální analýzy.

Navrhněte a realizujte v programovém prostředí MATLAB algoritmus pro kvantitativní hodnocení kvality snímků sítnice (především z hlediska zaostření). Algoritmus otestujte na modelových i reálných datech. Proveďte diskusi a zhodnocení dosažených výsledků. K implementovaným algoritmům vytvořte dokumentaci.

DOPORUČENÁ LITERATURA:

[1] JAN, J. Medical Image Processing, Reconstruction and Restoration - Concepts and Methods. CRC New York 2006.

[2] FLEMING, A.D., PHILLIP, S., GOATMAN, K.A., OLSON, J.A., SHART, P.F. et al.: Automated assessment of diabetic retinal image quality based on clarity and field definition, Invest Ophthalmol Vis Sci., 2006, vol. 47, no. 3, p. 1120-1125.

Termín zadání: 7.2.1011

Termín odevzdání: 27.5.2011

Vedoucí práce: doc. Ing. Radim Kolář, Ph.D.

prof. Dr. Ing. Zbyněk Raida
Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Tato práce se zabývá vlastnostmi barevných snímků sítnice, které jsou pořízeny digitální fundus kamerou a principem funkce těchto kamer. Podrobněji jsou zde popsány základní operace pro předzpracování nejen snímku sítnice, ale i pro ostatní biomedicínské obrazy. Teoretické poznatky z těchto základních operací pro zpracování obrazu jsou využity k vytvoření algoritmu v programovém prostředí Matlab pro kvantitativní hodnocení kvality snímku sítnice i modelových dat z hlediska zaostření. Zjištěné výsledky jsou porovnány a zaneseny do grafických závislostí.

Klíčová slova

Fundus kamera, sítnice, histogram, entropie, těžiště histogramu, kvalita hran, konvoluce, prahování

Abstract

This thesis deals with the properties of retinal images, which are taken with a digital fundus camera. The basic image processing operations are described and applied on biomedical images. Based on these operations, the algorithm for image quality assessment is designed and implemented in Matlab. The quality metrics quantify the focusing. The proposed methods are tested on two datasets and the results are presented and discussed.

Keywords

Fundus camera, retina, histogram, entropy, center of histogram, quality edge, convolution, thresholding

TVARŮŽEK, M. Hodnocení kvality snímků sítnice. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 44 s. Vedoucí bakalářské práce doc. Ing. Radim Kolář, Ph.D.

Prohlášení

Prohlašuji, že svou bakalářskou práci na téma Hodnocení kvality snímků sítnice jsem vypracoval samostatně pod vedením vedoucího bakalářské práce s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestně právních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce doc. Ing. Radimu Kolářovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce

V Brně dne

.....

podpis autor

Obsah

Úvod.....	6
1. Anatomie oka	7
1.1. Stavba oka.....	7
2. Zobrazení snímku sítnice fundus kamerou	8
2.1 Fundus kamera	8
2.2 Vlastnosti snímků sítnice	9
3. Základní operace pro předzpracování snímku sítnice.....	11
3.1 Bodové operace.....	11
3.1.1 Příklad bodové operace	12
3.2 Lokální operace.....	13
3.2.1 Vyhlazování.....	13
3.2.2 Detekce hran.....	14
3.3 Segmentace	16
3.3.1 Prahování	17
4. Charakteristiky obrazu	20
4.1 Histogram	20
4.2 Entropie obrazu	22
4.3 Těžiště histogramu	24
5. Experimentální část.....	26
5.1 Naměřená data	26
5.2 Popis algoritmu pro výpočet parametrů	28
5.2.1 Předzpracování	29
5.2.2 Výpočet parametru <i>Kvalita Hran</i>	30
5.2.3 Výpočet entropie a těžiště histogramu	30
6. Hodnocení kvality.....	31
6.1. Hodnocení kvality pro modelová data	31
6.2. Hodnocení kvality pro snímky sítnice.....	37
7. Závěr.....	42
8. Literatura.....	43
Seznam Příloh	44

Úvod

Snímky sítnice pořízené digitální fundus kamerou jsou velice užitečné pro lékařskou diagnostiku řady onemocnění. Proto digitální zpracování obrazu, či analýza je nezbytnou součástí tohoto procesu. Na snímcích lze pozorovat mnohé strukturální změny různých částí sítnice, které mohou poukazovat o výskytu některých onemocnění.

Cílem této práce je navrhnout a realizovat algoritmus pro kvantitativní hodnocení kvality snímků sítnice, a to především z hlediska zaostření.

Počáteční část práce je zaměřena na stručné shrnutí anatomie oka a funkce fundus kamery. Další část práce je věnovaná základním operacím pro zpracování obrazu, a poslední část teoretické části se zabývá charakteristikami obrazu, podle nichž můžeme ostrost jednotlivých snímků posuzovat.


V experimentální části jsou popsána naměřená data, na kterých se algoritmus testoval, a dále popis vytvořeného algoritmu. Poslední, zásadní část práce je věnována samotnému hodnocení kvality. Na dalších snímcích jsou vyzkoušeny parametry pro posouzení ostrosti, které jsou zaneseny do grafických závislostí, a je provedena diskuze.

1. Anatomie oka

Pro člověka je oko jedním z pěti nejdůležitějších smyslových orgánů. Pomocí oka vnímáme většinu podmětů, a proto je pro nás nepostradatelným prostředkem pro kontakt s okolním světem. Jedná se o párový smyslový orgán, který zpracováním proudu fotonů viditelného světla, tj. elektromagnetického záření o vlnových délkách 380 – 780 nm, dává člověku informace o stavu jeho okolí, umožňuje vnímání tvarů, velikostí, vzdálenost objektů, jejich pohybu a také o jejich barvě. Světlo, které prochází optickou soustavou oka promítá na sítnici obraz, který je zmenšený a převrácený. Tento obraz je pak následně zpracováván mozkiem [1].

1.1. Stavba oka

Vlastním zrakovým orgánem je oční koule. Je uložena v očnici, přesněji v tukové tkáni a její pohyb umožňují okohybné svaly. Těchto svalů je šest, jsou příčně pruhované a lze je ovládat vůlí. Z těchto svalů jsou čtyři přímé a dva šikmé. Vzájemné antagonistické působení těchto svalů umožňuje přesné pohyby očí. Průměr oční koule bývá okolo 24mm. Oční koule je složena ze tří vrstev. Povrchová vrstva se skládá z bělimy a rohovky. Střední vrstvu obsahuje cévnatka, řasnaté těleso a duhovka. Vnitřní vrstvu zastává světločivá sítnice. Uvnitř oční koule se nachází sklivec, čočka a komorový mok. Ten vyplňuje přední a zadní oční komoru. Všechny tyto uvedené části tvoří vhodné optické prostředí pro průchod světelných paprsků.



Obr. 1.1 Anatomie oka [2]

2. Zobrazení snímku sítnice fundus kamerou

K vyšetření očního pozadí se dnes používá mimo klasického oftalmoskopu i digitální fundus kamera. Tato kamera snímá oční pozadí a umožňuje archivaci snímků, které vyšetření oftalmoskopem nedokáže. Navíc dokáže korigovat i vysoké hodnoty ametropie.

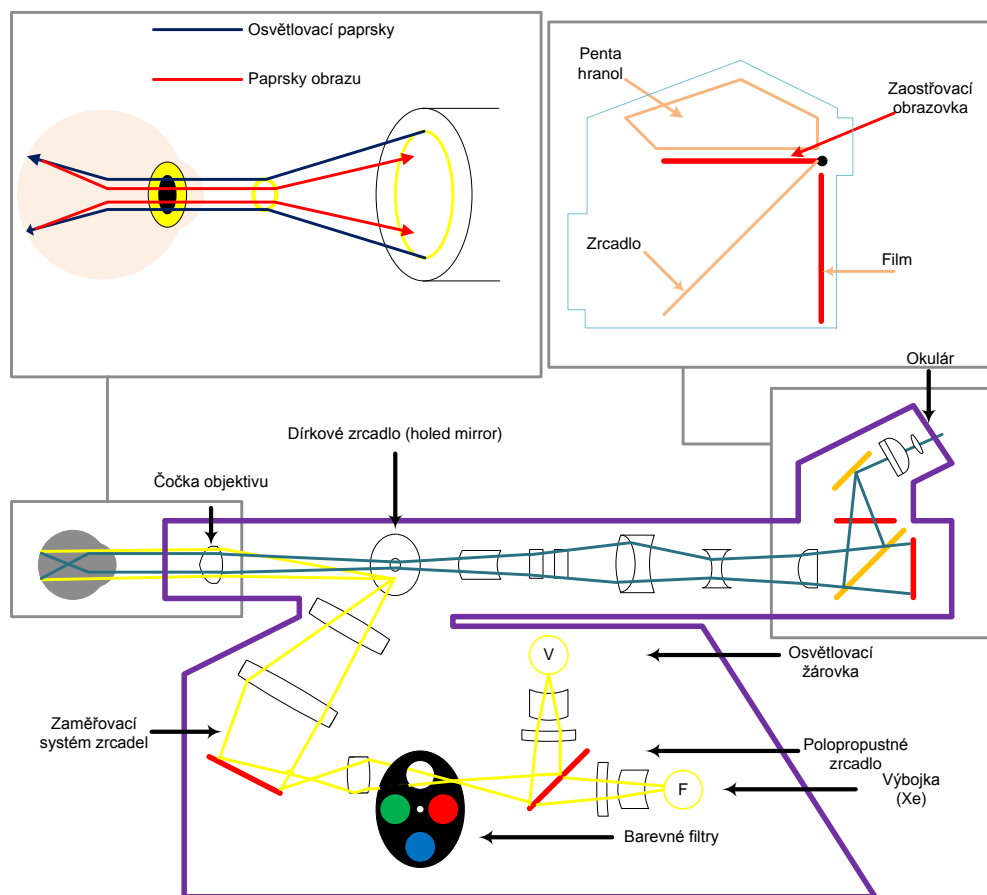
Fundus kamery obsahují mechanický systém, optický systém, zdroj světla a především CCD prvek, který převádí světelnou informaci na elektrický signál.

2.1 Fundus kamera

Jedná se o speciální nízkoenergetický mikroskop s přidruženým fotoaparátem. Fundus kamery se skládají ze tří základních částí. Jsou to mechanická, optická a elektrická část.

Část mechanická slouží k fixaci pacienta. Je tvořena čelní a bradovou opěrkou. Tato část je důležitá pro zaostření snímku. Správné zaostření snímku je docíleno jemnými pohyby ramene kamery, které je ovládáno joystickem.

Optický subsystém je znázorněn na Obr. 2.1. Tento systém je nezbytný pro správný přenos obrazu na CCD prvek. Optická část fundus kamery vede světlo ze světelného zdroje do oka na sítnici, skrz zornici, a od sítnice odražené světlo vede na snímač kamery [1].



Obr. 2.1 Optický systém fundus kamery [1]

Elektrický subsystém zajišťuje napájení žárovky a blesku. Žárovka poskytuje zdroj kontinuálního osvětlení, které se používá se pro správné zaměření sítnice. Blesk vyzáří světlo vysoké intenzity při snímání fotografie sítnice. Pokud je jako zdroj kontinuálního osvětlení použita žárovka, která způsobí stažení zornice, je nutností použít mydriatické kapky, které slouží k rozšíření zornice.

Kamery využívající tohoto osvětlení se nazývají mydriatické. Tento přístup je však pro pacienta poněkud nepohodlný. Lepším typem fundus kamer jsou ty, které používají k zaměření sítnice osvětlení světlem z infračervené oblasti spektra. Rozšíření zornic je pak docíleno prostou adaptací na tmou v neosvětlené místnosti. Tyto kamery se nazývají nemydriatické [1].

Z Obr. 2.2 je vidět, že oba zdroje světla sdílejí stejnou optickou cestu, která je oddělena poloprůhledným zrcadlem. Zde lze také postavit do cesty světelných paprsků barevné filtry. Ty jsou používány pro zvýraznění některých struktur.

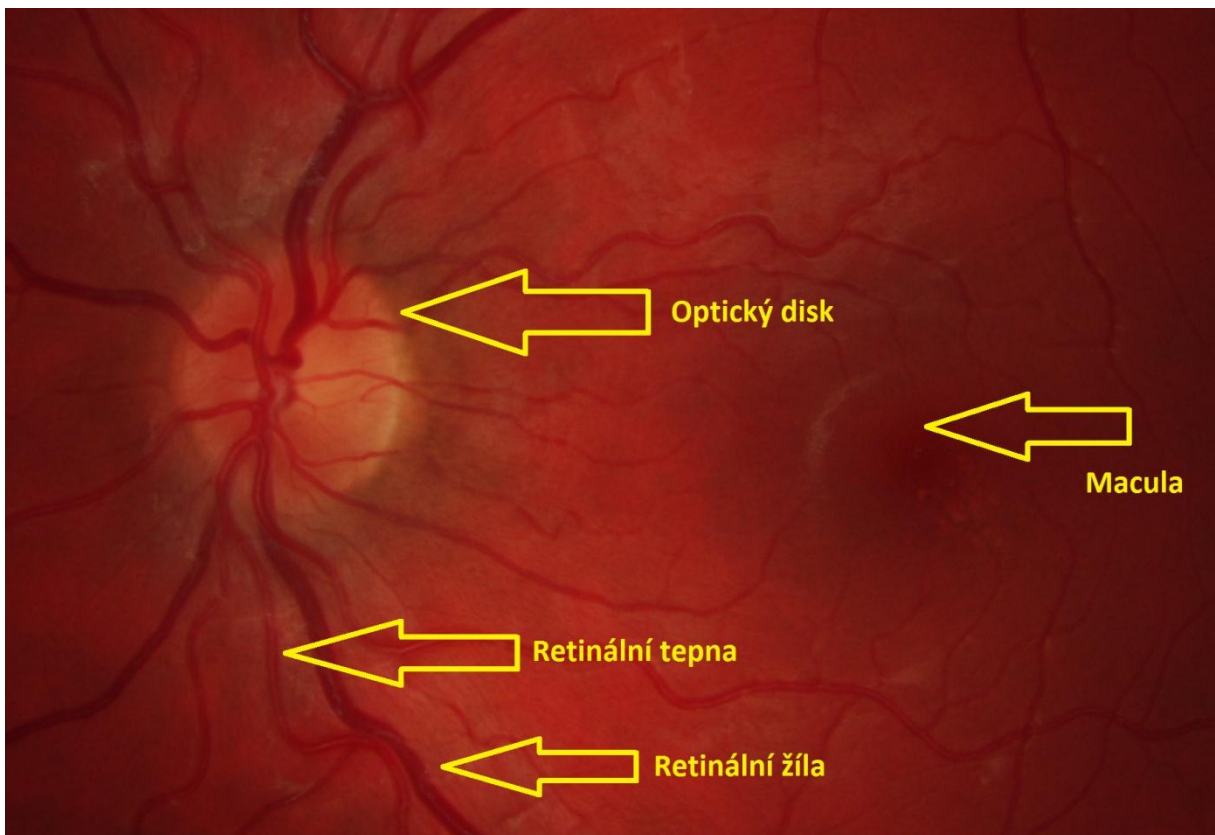


Obr. 2.2 Ukázka nemydriatické fundus kamery [2]

2.2 Vlastnosti snímků sítnice

Na retinálních snímcích sítnice můžeme pozorovat některé základní struktury. Zejména pak nervová vlákna, retinální cévy, žlutou skvrnu a optický disk. Ten je tvořený miliony axonů a vystupují z něj retinální cévy. Retinální cévy můžeme rozčlenit na čtyři základní svazky: horní a dolní temporální, horní a dolní nasální. Každý svazek obsahuje tepnu i žílu. Ty se pak s odstupem od optického disku stále více rozvětvují a vyživují tak sítnici. Venuly se od arteriol odlišují svým tmavším namodralým zbarvením, které je způsobeno tmavším zbarvením odkysličené krve. Dále můžeme také pozorovat žlutou skvrnu, která je

místem nejostřejšího vidění. Zbarvení pozadí snímku je způsobeno prosvítáním cévnatky skrz retinální pigmentový epitel. Toto zbarvení bývá spojeno s barvou pleti jedince.



Obr. 2.3 Snímek sítnice z fundus kamery [převzato z archívu ÚBMI]

Na Obr. 2.3 můžeme pozorovat snímek sítnice pořízený fundus kamerou. Jedná se o zdravou sítnici bez patologických nálezů. Struktura sítnicového pozadí se jeví normálně a sítnicové cévy mají na první pohled normální tvar a šířku.

3. Základní operace pro předzpracování snímku sítnice

Po úspěšném pořízení obrazu sítnice pomocí fundus kamery je k dispozici obraz RGB pozorované scény. Cílem předzpracování je snaha potlačit šum a zkreslení, vzniklé při snímání obrazu nebo nevhodnými podmínkami při jeho průběhu. U snímku papíru je také jedním z cílů potlačit i stejnosměrnou složku. Velmi důležitým aspektem při předzpracování je i zvýraznění rysů obrazu, které jsou dále podstatné pro další zpracování.


Mezi základní operace používané pro zpracování obrazu jsou : filtrace, prahování.

3.1 Bodové operace

Nezákladnější operace, které se používají při zpracování obrazu se nazývají bodové operace. Pomocí těchto operací dosáhneme zlepšení vizuálních vlastností snímků. Jedná se o transformaci hodnoty každého pixelu na novou hodnotu pixelu z informací původního pixelu. Tato hodnota je nezávislá na hodnotách ostatních pixelů [3].

$$g(x,y) = T[f(x,y)]. \quad (3.1)$$

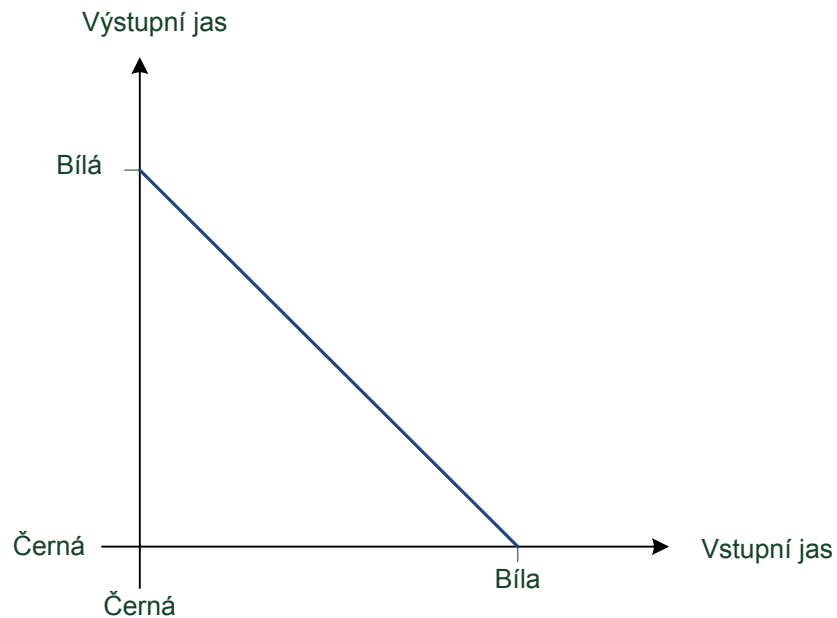
Vztah 3.1 popisuje nezávislost těchto pixelů, kde $f(x,y)$ vyjadřuje vstupní obraz a $g(x,y)$ výstupní obraz a T má význam transformace operátoru aplikovaného na obraz. Transformační funkce je závislá na vlastnostech známých předem nebo určena během zpracování obrazu (např. minimum nebo maximum jasové hodnoty). Jasová složka je určena jako reálné číslo v rozsahu $\langle 0, 1 \rangle$. Uvedený rozsah se přepočítává na interval $\langle 0, L-1 \rangle$, kde L udává počet jasových úrovní v obrazu [3].



Obr. 3.1 Princip bodové operace

3.1.1 Příklad bodové operace

Typem bodové operace může být lineární mapování, kde nejjednodušší aplikací je operace invertování obrazových hodnot. Tyto tmavé části obrazu se stávají jasnějšími hodnotami => negativ.



Obr. 3.2 Jasová inverze


Praktickým příkladem mapování inverzních hodnot je vytvoření negativu pomocí skriptu v Matlabu, kde výsledný negativ je zobrazen na Obr. 3.3.



Obr. 3.3 Praktický příklad převodu obrazu na negativ v Matlabu [vstupní obraz z archívu ÚBMI]

3.2 Lokální operace

U lokálních operací se počítá nová hodnota pixelu z okolí původního pixelu. Pro lokální operace se obvykle používá výraz *konvoluce s maskou*, kde maska se skládá z váhovaných koeficientů. Pomocí lokálních operací lze docílit vyhlazení obrazu, zaostření obrazu, detekci hran a atd.



Obr. 3.4 Princip lokální operace

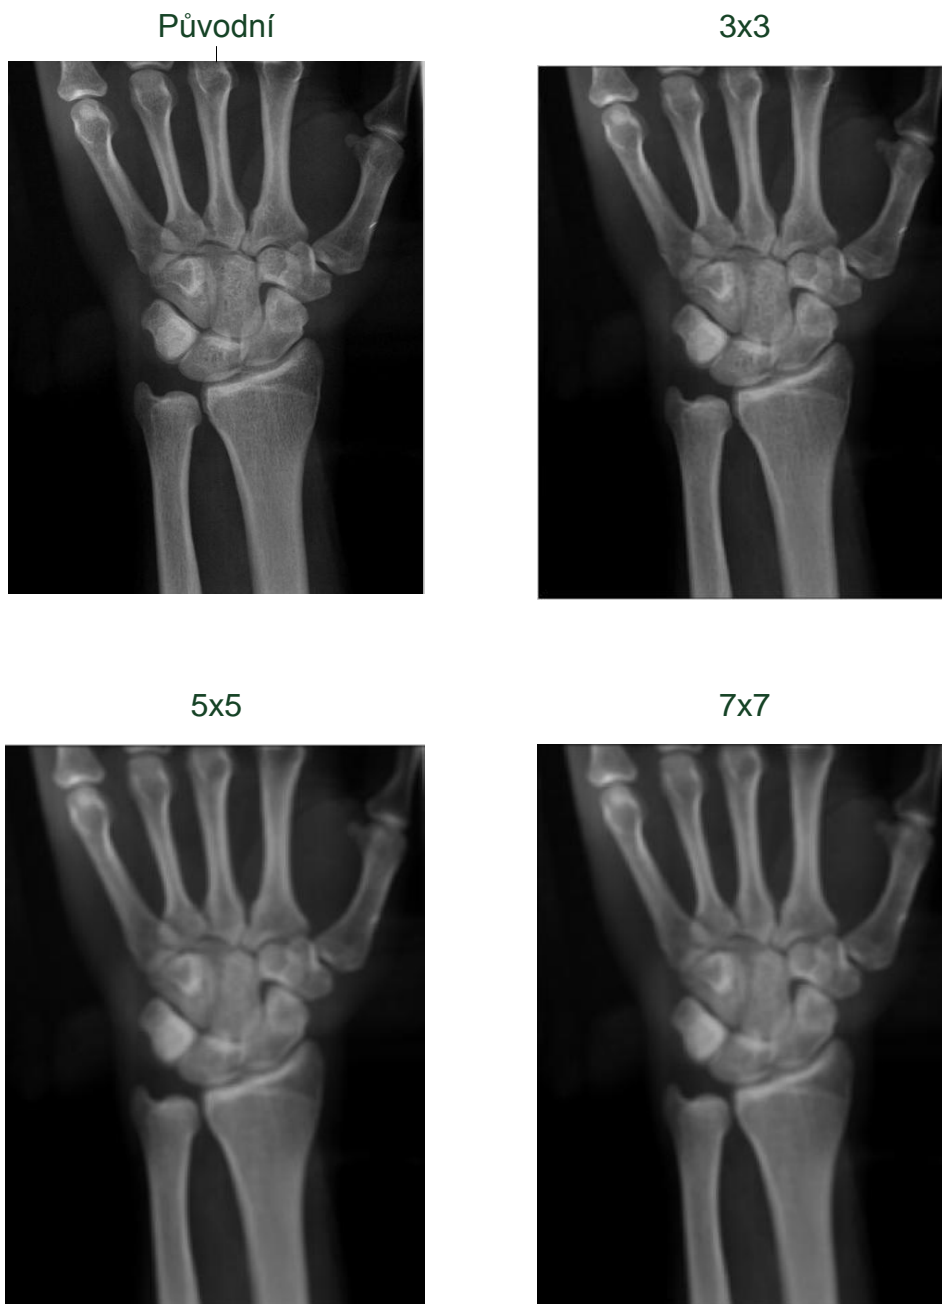
3.2.1 Vyhlazování

Vyhlazování obrazu můžeme docílit pomocí konvoluce s maskou. Touto operací lze eliminovat nežádoucí šum a artefakty v obrázku. Jedním z nejjednodušších způsobů je vyhlazování pomocí průměrujícího filtru.

1	1	1
1	1	1
1	1	1

 /9



Obr. 3.5 Maska průměrujícího filtru



Obr. 3.6 Příklad použití průměrujícího filtru v Matlabu (maska 3x3, 5x5 a 7x7)

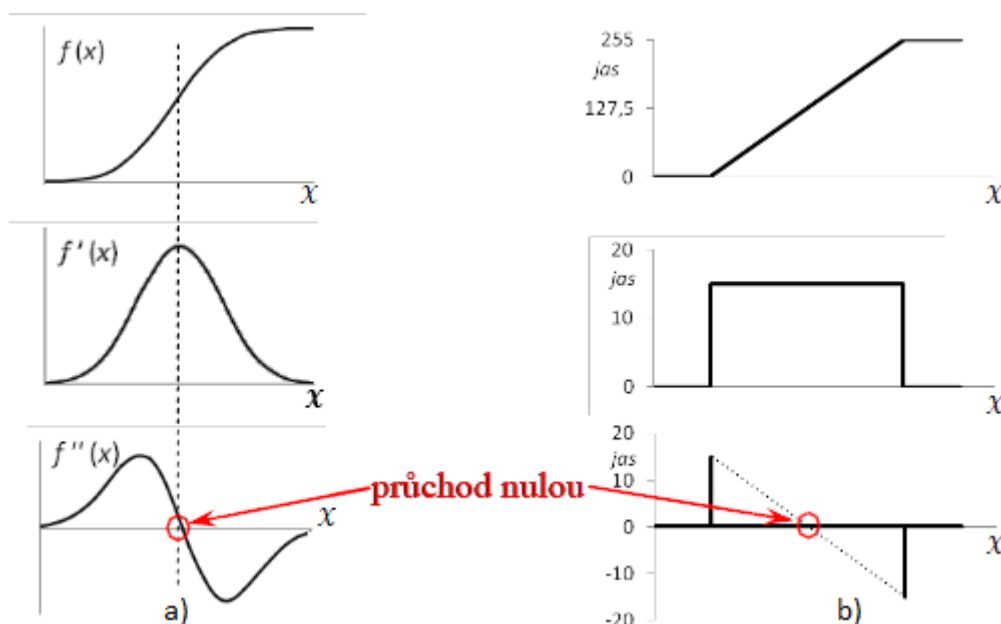
3.2.2 Detekce hran

Ideální hrana je definována skokovou změnou intenzity jasu, která separuje propojené pixely na dvě skupiny, z nichž každá má jinou intenzitu. V praxi se často stává, že přechod mezi těmito dvěma skupinami je plynulý (rozostřený). Tomuto se v praxi říká jasový přechod (Obr. 3.7).



Obr. 3.7 Příklady hran v obraze a) ideální b) neostrá - přechod

Z teorie o derivacích funkce jedné proměnné lze vyvodit princip pro základní techniku detekujících hran. Obecná spojitá jednorozměrná hrana je zobrazena s jejími derivacemi na Obr. 3.8a. Abychom mohli detekovat hranu, je důležitá diskrétní podoba této operace pro příklad obrazové hrany na Obr. 3.8b.



Obr. 3.8 Jednorozměrné hrany v obrazech a) spojité b) diskrétní [5]

V oblasti přechodu z jedné hodnoty na druhou vychází první derivace nenulová => je konstantní v oblastech, kde jas lineárně roste nebo klesá. První derivace je nulová v oblastech, kde je úroveň jasu konstantní.

V tmavé části přechodu vychází druhá derivace kladně a záporně v části, kde hrana přechází na světlou konstantní hodnotu a je nulová v oblasti, kde je jasová funkce konstantní, nebo lineárně rostoucí, či klesající. Změna znaménka výsledku druhé derivace by znamenala přechod z bílé na černou.

První derivace se používá pro určení, zda se daný bod v obrazech nachází v oblasti vykazující gradientní přírůstek. Oproti tomu druhá derivace je vhodná pro určení, zda je daný pixel na tmavé, či světlé části hrany. Druhá derivace produkuje dvě zajímavé vlastnosti:

- Produkuje pro jednu hodnotu dvě hodnoty.
- Myšlená čára spojující vrcholy kladných a záporných hodnot výsledku pro jednu hranu prochází nulou v místě, kde má hrana svůj střední bod. Tato vlastnost se používá pro detekci širokých hran.

3.3 Segmentace

Rozčlenění obrazu do části, které mají úzkou souvislost s předměty, či oblastmi reálného světa zachyceného na obraze. Toto říká teorie počítačového vidění [4].

a) Kompletní

- Jednoznačná korespondence s objekty vstupního obrazu.

- Kompletní segmentaci obrazu R nazýváme konečnou neprázdnou množinou oblastí $\{R_1, \dots, R_S\}$, pro kterou platí:

$$R = \bigcup_{i=1}^S R_i, \quad R_i \cap R_j = \emptyset \text{ pro } i \neq j \quad (3.2)$$

b) Částečná

- Vytvořené segmenty souhlasí částečně s objekty obrazu.

Algoritmy pro segmentaci:

- prahování (thresholding),
- detekce hran,
- narůstání oblasti,
- srovnání se vzorem.

3.3.1 Prahování

Prahování definuje jako transformace vstupního obrazu g na výstupní binární obraz f s prahem T .

Typy prahování:

- prosté,
- s více prahy,
- částečné / poloprahování,
- adaptivní / lokální prahování.

Způsob určení prahu:

- experimentální,
- z histogramu,
- procentní,
- ze statistik,
- z globální znalosti.

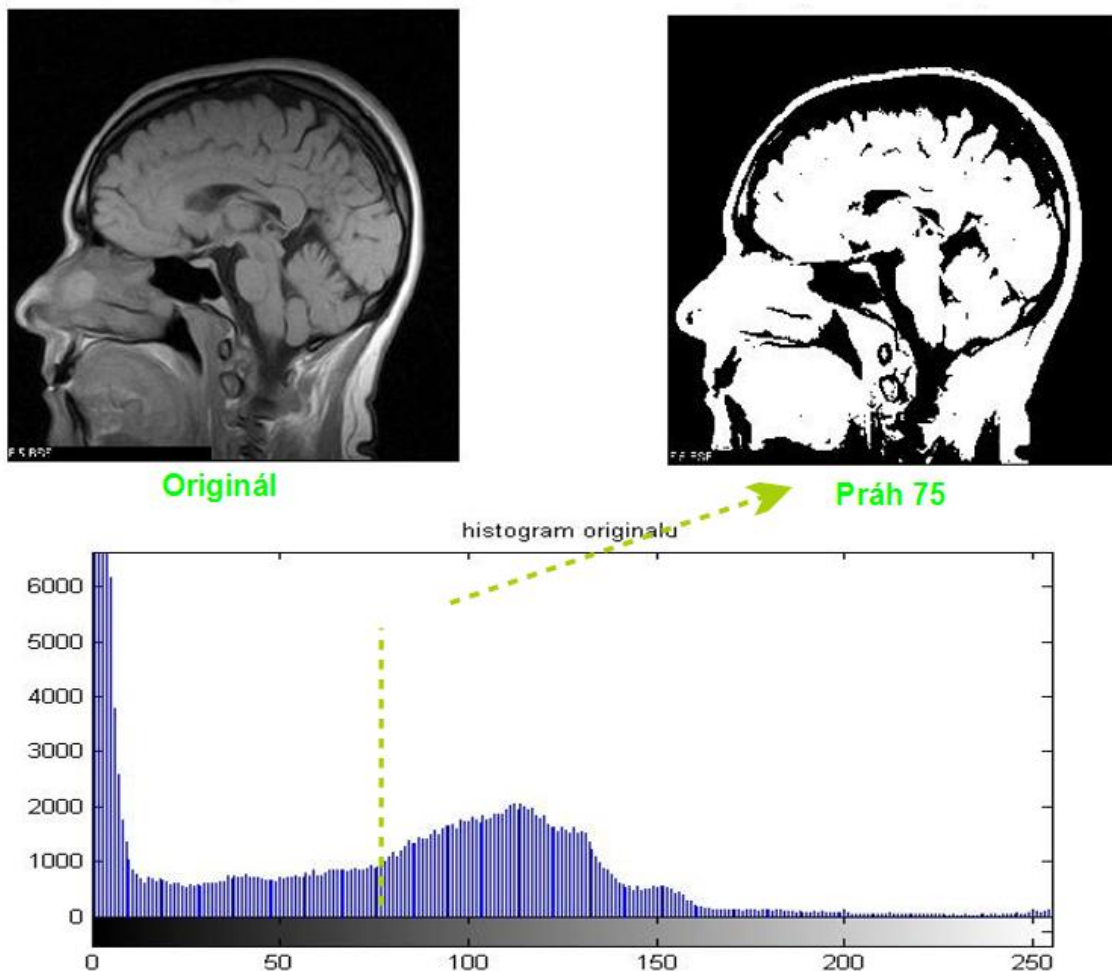
Prosté prahování

Pokud si vezmeme histogram obrazu $f(x,y)$ obsahující světlé objekty na tmavém pozadí. Z toho vyplývá, že pixely v obraze můžeme rozdělit podle jejich jasu na dvě skupiny příslušníků oblasti pozadí nebo objektů. K rozlišení objektů se používá stanovení prahu T ,

který tyto dvě skupiny odděluje. Dále pro všechny body (x,y) platí $f(x,y) > T$, označený jako objektové a všechny ostatní jako body pozadí. Pro prahovaný obraz $g(x,y)$ platí [5]

$$g(x,y) = \begin{cases} 1 & \text{pro } f(x,y) > T \\ 0 & \text{pro } f(x,y) \leq T \end{cases} \quad (3.3)$$

Výsledkem této funkce je binární obraz, kde pixely, které mají jas větší nebo roven prahu jsou označeny jako 1 neboli popředí pixely, jejichž jas je menší než práh, jsou označeny jako 0, neboli pozadí (Obr. 3.9) [9].



Obr. 3.9 Příklad prostého prahování pro práh 75 v Matlabu

Víceúrovňové prahování

Pokud zobecníme prosté prahování, je možné přejít k několika prahovým hodnotám. Máme-li n prahových úrovní T_n pro $n=1,2,\dots,N$ je možné rozdělit obraz na $N+1$ skupin objektů (pozadí) (Obr. 3.10) [5].

$$g(x, y) = \begin{cases} 0 & \text{pro } f(x, y) \leq T_0 \\ n & \text{pro } T_{n-1} < f(x, y) \leq T_n \\ N + 1 & \text{pro } T_N < f(x, y) \end{cases} \quad (3.4)$$



Obr. 3.10 Příklad víceúrovňového prahování

Částečné prahování

Pokud v prahovaném obraze je hodnota pouze funkcí jasových hodnot $f(x, y)$, mluvíme o tzv. globálním prahování. Při stanovení prahové hodnoty pro konkrétní pixel je možné nejdříve vyhodnotit situaci v okolí pixelu, kde mluvíme o tzv. globální prahování.

Adaptivní prahování

U tohoto prahování je práh funkcí polohy v obraze (určován pro část obrazu). Prahovací hodnota se stanovuje například pomocí výpočtu hodnoty v daném okolí, pomocí mediánu nebo na základě Gaussova rozložení (odezva různých filtračních jader).

4. Charakteristiky obrazu

4.1 Histogram

Histogram digitálního obrazu s jasovými úrovněmi v rozsahu $\langle 0, L - 1 \rangle$ je diskrétní funkcí

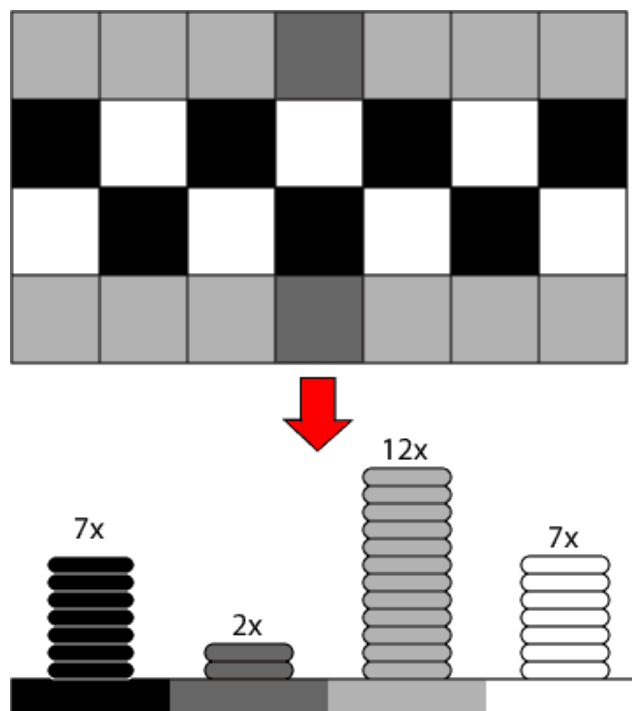
$$h(r_K) = n_K, \quad (4.1)$$

kde r_K je k -tá úroveň šedi a n_K je počet pixelů v obraze majících úroveň šedi r_K . Z praktického hlediska je vhodné histogram normalizovat dělením každé z jeho hodnot celkovým počtem pixelů v obraze n . Pro normalizovaný histogram tedy platí

$$p(r_K) = \frac{n_K}{n}. \quad (4.2)$$

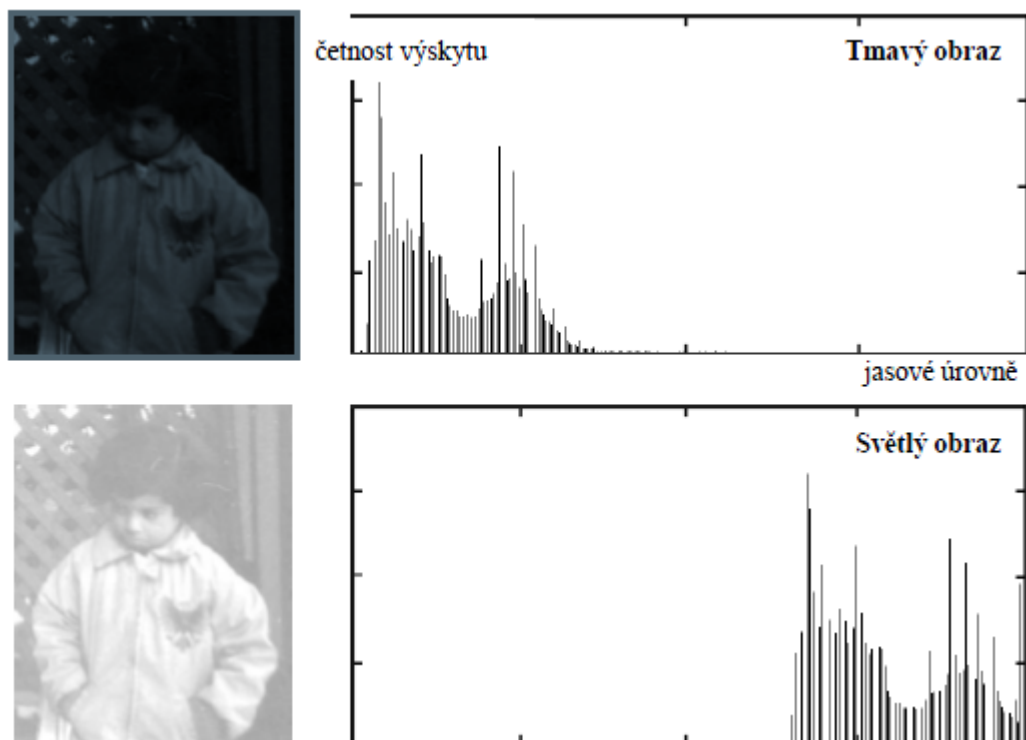
Pro $k = 0, 1, \dots, L - 1$. $p(r_K)$ platí, že udává pravděpodobnost výskytu úrovně šedi r_K . Z toho vyplývá, že součet všech prvků normalizovaného histogramu je roven 1.

Pro zpracování obrazu je práce s histogramem základním stavebním kamenem pro zlepšení vlastností obrazu. Histogram obsahuje statistické údaje, které jsou velice užitečné pro další techniky zpracování, jako např.: komprese, či segmentace. Histogramy jsou jednoduché na výpočet, tím pádem je jednoduché je hardwarově implementovat, a proto bývají v řadě zařízení, které pracují s digitálními obrazy v reálném čase [5].



Obr. 4.1 Princip funkce histogramu [převzato z 6]

Příklady grafického vyjádření histogramu jsou uvedeny na Obr. 4.2. Histogram bývá vyneseno do sloupcového grafu, kde svislé ose jsou buď světlé hodnoty $h(r_K)$ a na vodorovné ose jsou vyneseny diskrétní hodnoty časových úrovní. Na obr. 16 je vidět, že ve tmavém obraze jsou sloupce soustředěny do oblasti nízkých jasových úrovní. Je logické, že histogram světlého obrazu má složky v oblasti vysokých kmitočtů [5].



Obr. 4.2 Příklad tmavého a světlého obrázku a jejich histogramy [5]

4.2 Entropie obrázu

Entropie ve fyzice je měrou energie soustavy, která není k dispozici k vykonání práce. Jelikož práci lze získat “z řádu soustavy”, je entropie měrou neuspořádanosti soustavy. Souvisí s druhou termodynamickou větou [8].

Entropie pro šedotónový obraz

Nechť obraz má G jasových úrovní, $k = 0 \dots G - 1$ s pravděpodobnostmi $P(k)$

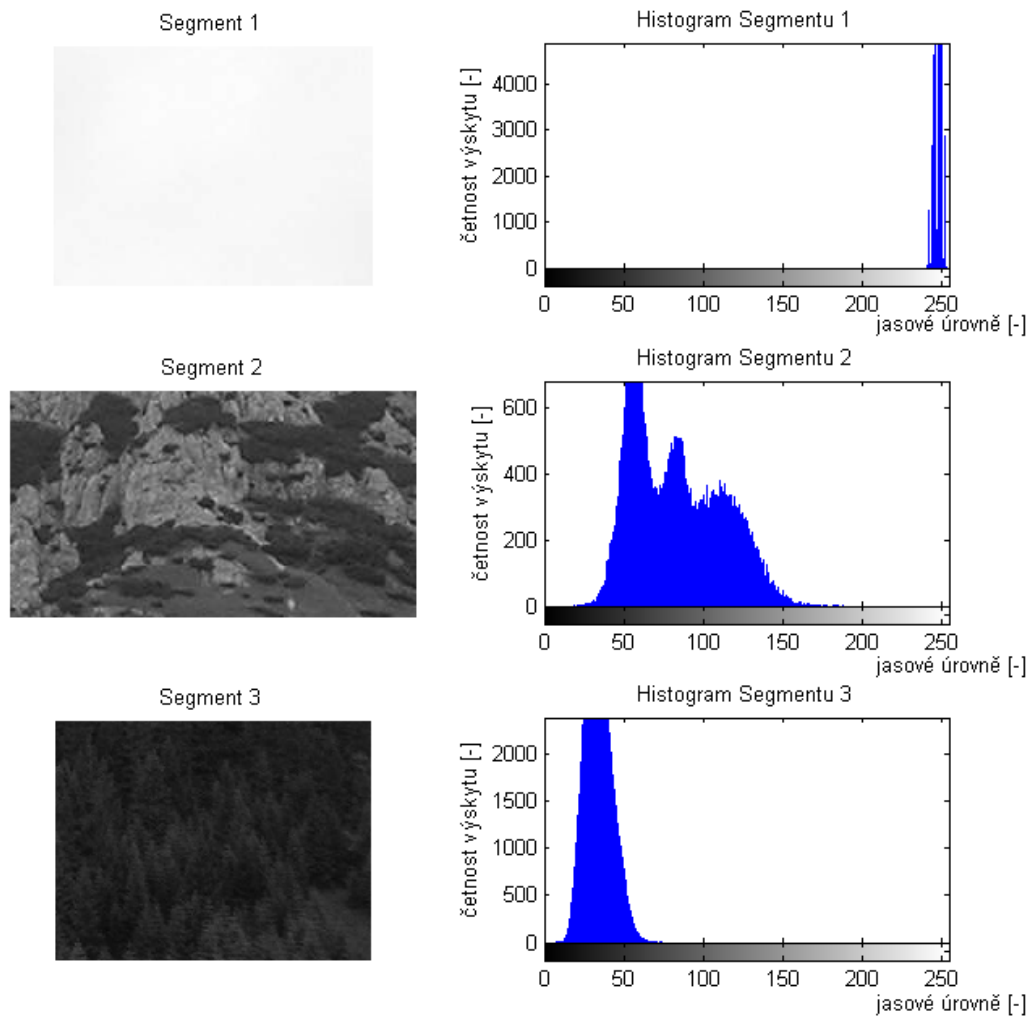
$$H_e = \sum_{k=1}^L P(k) \log_2 P(k) \quad [\text{bitů}]. \quad (4.3)$$

Příklad výpočtu entropie pro různé segmenty obrázu

Pro názornou ukázkou výpočtu entropie byly vybrány z Obr. 4.3 tři segmenty. Segment 1 zahrnuje oblast nebe, kde po převodu na šedotónový obraz převažuje bílá barva. Segment 2 zahrnuje oblast skalnatého pahorku, kde je obsaženo nejvíce odstínů šedi a nakonec segment 3, který ohraničuje oblast lesů, kde dominují tmavší odstíny. Ovšem výpočet entropie nezávisí na odstínu šedi, nýbrž na pravděpodobnosti výskytu jednotlivých odstínů.



Obr. 4.3 Testovací obrázek pro výpočet entropie



Obr. 4.4 Ukázka Segmentů testovacího obrázku a jejich histogramy pro výpočet entropie v Matlabu

Vypočet entropie pomocí Matlabu vycházel ze vztahu (4.3) a pro různé segmenty vyšly hodnoty následně:

Segment 1 : $H_e = 2.6115$

Segment 2 : $H_e = 6.6758$

Segment 3 : $H_e = 5.1176$

4.3 Těžiště histogramu

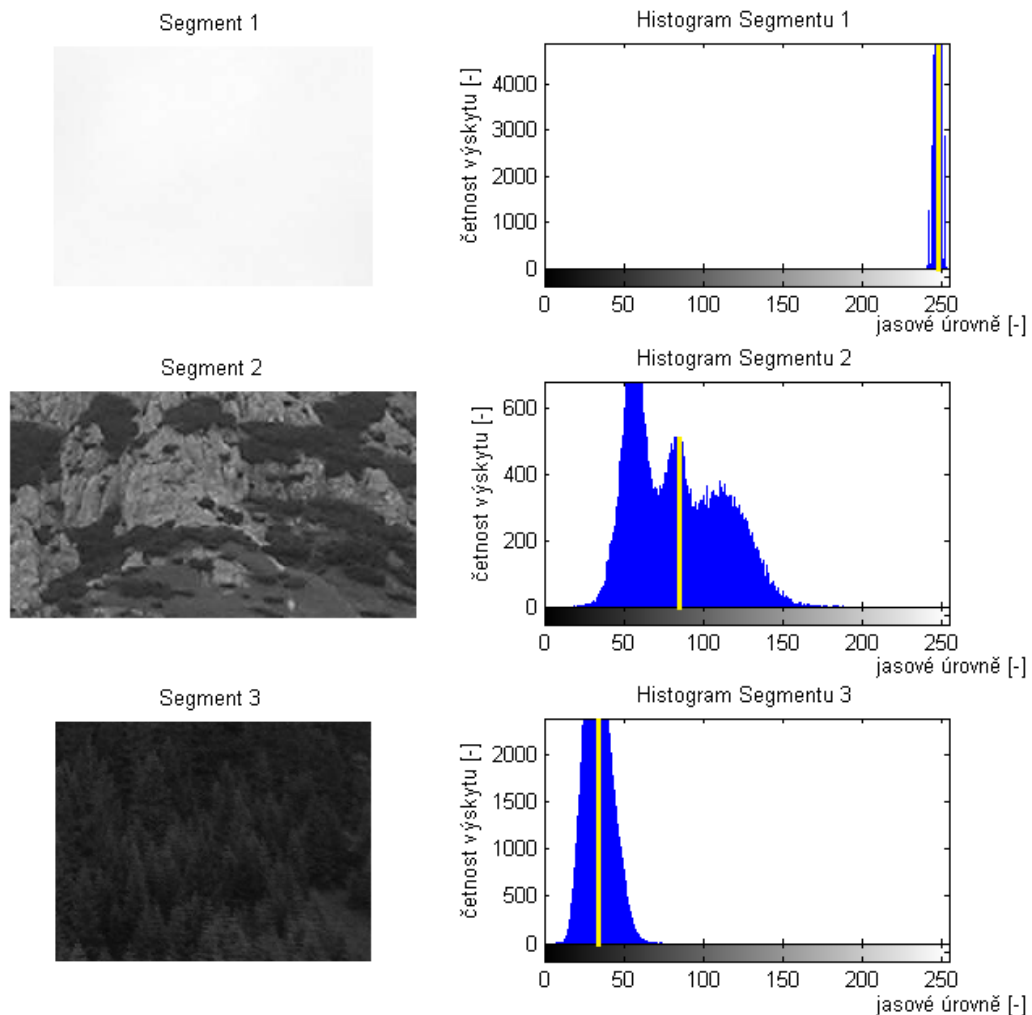
Výpočet těžiště histogramu je definováno rovnicí: [7]

$$T_h = \sum_{k=1}^L g(k)P(k), \quad (4.4)$$

kde $g(k)$ je jasová úroveň pixelu a $P(k)$ je pravděpodobnost výskytu jednotlivého pixelu.

Příklad výpočtu těžiště

K ukázce výpočtu těžiště byly použity stejné segmenty z Obr. 4.3.



Obr. 4.5 Ukázka Segmentů testovacího obrázku a jejich histogramy pro výpočet těžiště v Matlabu

Vztah (4.4) byl použit pro výpočet těžiště segmentů 1 – 3 a hodnoty těžiště vyšly následně:

Segment 1 : $T_h = 247.7584$

Segment 2 : $T_h = 82.6951$

Segment 3 : $T_h = 33.9914$


Hodnota je v Obr. 4.5 zvýrazněna žlutou přímkou.

5. Experimentální část


V této kapitole bude seznámeno s naměřenými reálnými a modelovými daty. Všechny testovací snímky jsou uvedeny v [Příloha 1]. Snímky byly pořízeny za účelem vytvoření algoritmu pro výpočet parametrů. Reálná data reprezentují 3 dvojice snímku sítnice pořízené digitální fundus kamerou, jedná se o snímek levé a pravé sítnice zaostřené, a další dvojice je záměrně rozostřená tak, že rovina zaostření leží před a za sítnicí. Modelová data reprezentuje 7 snímků papíru, opět různě zaostřené. Dále se tato kapitola zabývá popisem algoritmu, který slouží k výpočtu parametrů pro kvantitativní hodnocení. Jedná se o parametry: *kvalita hran*, entropie a těžiště.

5.1 Naměřená data

Pro hodnocení ostrosti snímku sítnice byly pořízeny digitální fundus kamerou tři dvojice snímků. Jedna dvojice snímků je ostrá, a další dvě dvojice jsou různě rozostřené.




Obr. 5.1 Oblast testovacího obrázku L_ostry.JPG



Obr. 5.2 Oblast testovacího obrázku L_dozadu.JPG


Pro názornou ukázkou je výše na obrázcích uvedeno pouze okolí optického disku a to ostrého snímku Obr. 5.1 a rozostřeného snímku Obr. 5.2.

Za účelem otestování algoritmu pro výpočet parametrů na modelových datech bylo nafoceno 7 různě zaostřených snímků papíru. Snímek představuje papír s černými a bílými proužky, kde vlevo se mění uspořádání proužku s malou prostorovou frekvencí a postupně směrem doprava se frekvence zvyšuje. První snímek *ost.JPG* je snímek zaostřený a objektiv byl ve vzdálenosti 1,2m. Postupně se snímky posouvaly o 10cm dopředu a dozadu. Princip je znázorněn na Obr. 5.3.



Obr. 5.3 Princip pořízení snímků papíru

Pro názorné zobrazení je zde uvedený zaostřený snímek *ost* (Obr. 5.4) a dále snímek *dz3*, který je velmi rozmazaný (Obr. 5.5).



Obr. 5.4 Zaostřený snímek papíru



Obr. 5.5 Rozmazaný snímek papíru

5.2 Popis algoritmu pro výpočet parametrů

Tato práce se zabývá hodnocením kvality snímků sítnic, zejména z hlediska zaostření. Za tímto účelem byl vytvořen algoritmus v jazyce Matlab, který slouží k výpočtu parametrů, podle kterých můžeme snímek hodnotit. Z praktického hlediska nemá smysl hodnotit celý snímek, ale pouze jeho určité oblasti. U snímku sítnice to může být oblast optického disku, nebo oblast s velkým výskytem cév, kde můžeme najít i výrazné hrany. Proto byl kladen důraz na univerzálnost algoritmu (funkce), kterému stačí zadat oblast, zadáním souřadnic a funkce vypíše do konzole výsledky parametrů. Popis vytvořené funkce je popsán v následující kapitole.

5.2.1 Předzpracování

Prvním krokem při předzpracování obrázku je výběr oblasti, se kterou bude funkce pracovat, a dále výběr složky z RGB. Funkce je navržena tak, že oblast, která bude určena k výpočtu parametrů, si zadá uživatel při volání funkce. Co se týče výběru barevné složky, algoritmus počítá pouze se zeleným kanálem, ve kterém je největší kontrast mezi cévami, či optickým diskem a pozadím sítnice. U červené složky dochází vlivem vysokého jasu ke snížení kontrastu. Modrá složka má také špatný kontrast, většina snímku k testování byla téměř černá. To platí ovšem výhradně pro snímky sítnice. Druhým krokem při předzpracování bylo vyhlazení. Vyhlazování se provádí konvolucí s maskou, která je znázorněna na

Obr. 3.5. Cílem filtrace je eliminovat šum a nežádoucí artefakty v obrázku. V následném kroku se provádí konvoluce s maskou, která by měla potlačit stejnosměrnou složku. Maska je znázorněna na Obr. 5.6.

0	-1	0
-1	4	-1
0	-1	0

Obr. 5.6 Maska použitá při filtraci pro potlačení SS

Poslední ze tří filtrací, které byly použity v algoritmu je konvoluce s maskou, která je znázorněna na Obr. 5.7. Maska má součet 1 a jejím cílem je zvýraznit hrany ve všech směrech. Pro testování bylo použito více masek. Například maska, která zvýraznila hrany pouze ve vertikálním a horizontálním směru, ovšem takové masky by se nejlépe využilo pouze u zlomku snímků, např. u snímku papíru, který byl nafocen za účelem testování.

-1	-1	-1
-1	9	-1
-1	-1	-1

Obr. 5.7 Maska použitá pro zvýraznění hran


Při finální úpravě bylo potřeba ještě z vybraných oblastí vyloučit tzv. okraje obrázku, kde se mohou nacházet nežádoucí artefakty, a jejich přítomnost by měla vliv na výpočet parametrů. Vzhledem k tomu, že v algoritmu dochází ke konvoluci, bylo nutné převést vstupní obraz do formátu double, tohle mělo za následek, že odstíny šedi se nezobrazují ve škále (0,255) nýbrž ve škále (0,1). Ve stejné škále se zobrazují výsledky parametru těžiště histogramu.

5.2.2 Výpočet parametru *Kvalita Hran*

Výpočet kvality hran vychází z blokového schématu, které je zobrazeno na Obr. 5.8. V prvních dvou blocích je provedeno předzpracování, které je popsáno v předchozí podkapitole. V dalším kroku podle blokového schématu je prahování, jehož výsledek je binární hodnota. Pro určení prahu existuje celá řada metod. Na pořízených datech byly testovány tři metody prahování, nicméně v algoritmu je použita metoda Funkce *graythresh*, která vykazovala při testování nejlepší výsledky. V poslední řadě je zde výpočet čísla, které udává kvalitu Hran. Číslo je definováno vztahem:

$$H = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N B(i,j). \quad (5.1)$$

Ve vztahu 5.1 platí, že M , N udávají rozměr matice a $B(i,j)$ je výsledné binární číslo po prahování.



Obr. 5.8 Blokové schéma pro výpočet kvality hran

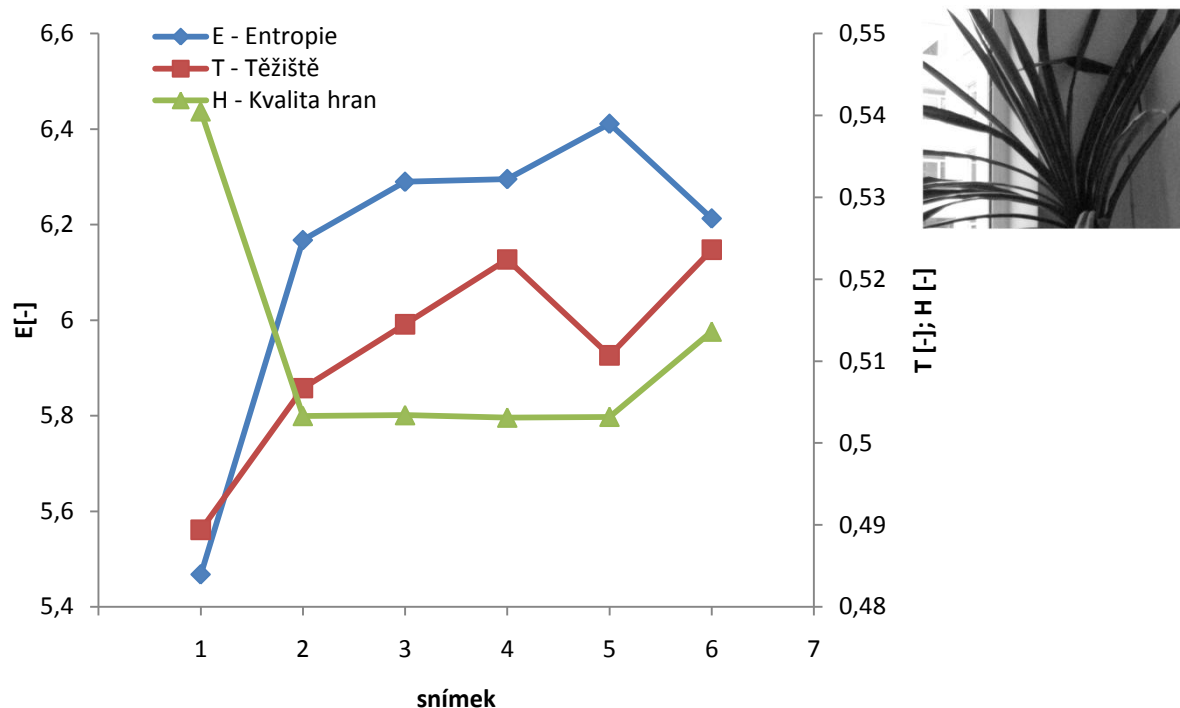
5.2.3 Výpočet entropie a těžiště histogramu

Předzpracování je využito při výpočtu všech parametrů. Definice entropie je uvedena v kapitole 4.2. Pro implementaci v Matlabu bylo nutné tento vzorec ošetřit. Např.: Pokud by byla hodnota entropie 0 => log 0 neexistuje. Vzorec pro výpočet těžiště histogramu je uvedený v kapitole 4.3, a pro implementaci v Matlabu zde není žádný problém.

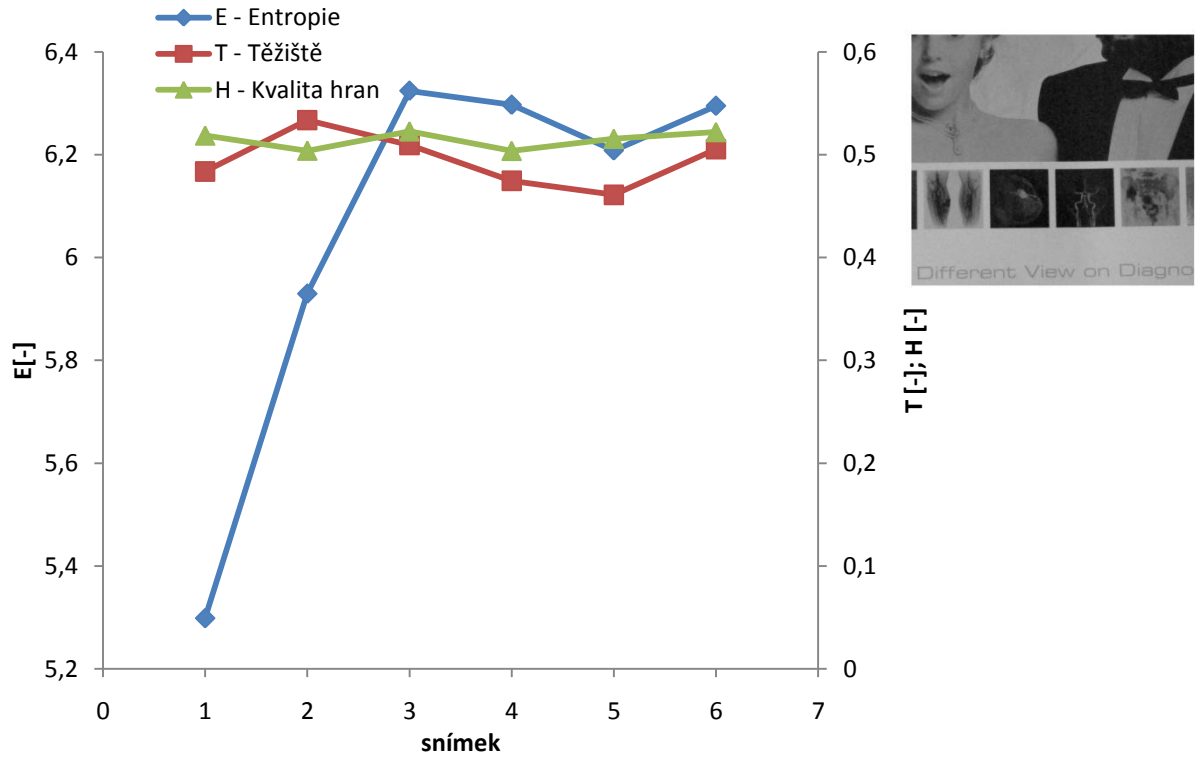
6. Hodnocení kvality

Za účelem otestování algoritmu pro výpočet parametrů pro hodnocení kvality bylo pořízeno dalších 10 scén tzv. modelových dat. Každá scéna je vyfocena celkem 6x. V grafických závislostích (viz níže), jsou snímky subjektivně seřazeny zleva doprava od ostrého po nejvíce rozmazaný (např. 1 – ostrý; 6 – nejvíce rozmazaný). Dále byly pořízeny další dvě sady snímků sítnice. Jedna dvojice snímků zaostřená, další dvě dvojice snímků, jedna rozostřená dozadu další dopředu. Všechny snímky jsou uvedeny v [Příloha 1] a Hodnoty parametrů použité k vytvoření grafických závislostí jsou uvedeny v [Příloha 2] *parametry_vyhodnocení.xlsx*


6.1. Hodnocení kvality pro modelová data




Obr. 6.1 Grafické závislosti parametrů pro snímek kytky1




Obr. 6.2 Grafické závislosti parametrů pro snímek plakát




Obr. 6.3 Grafické závislosti parametrů pro snímek stůl



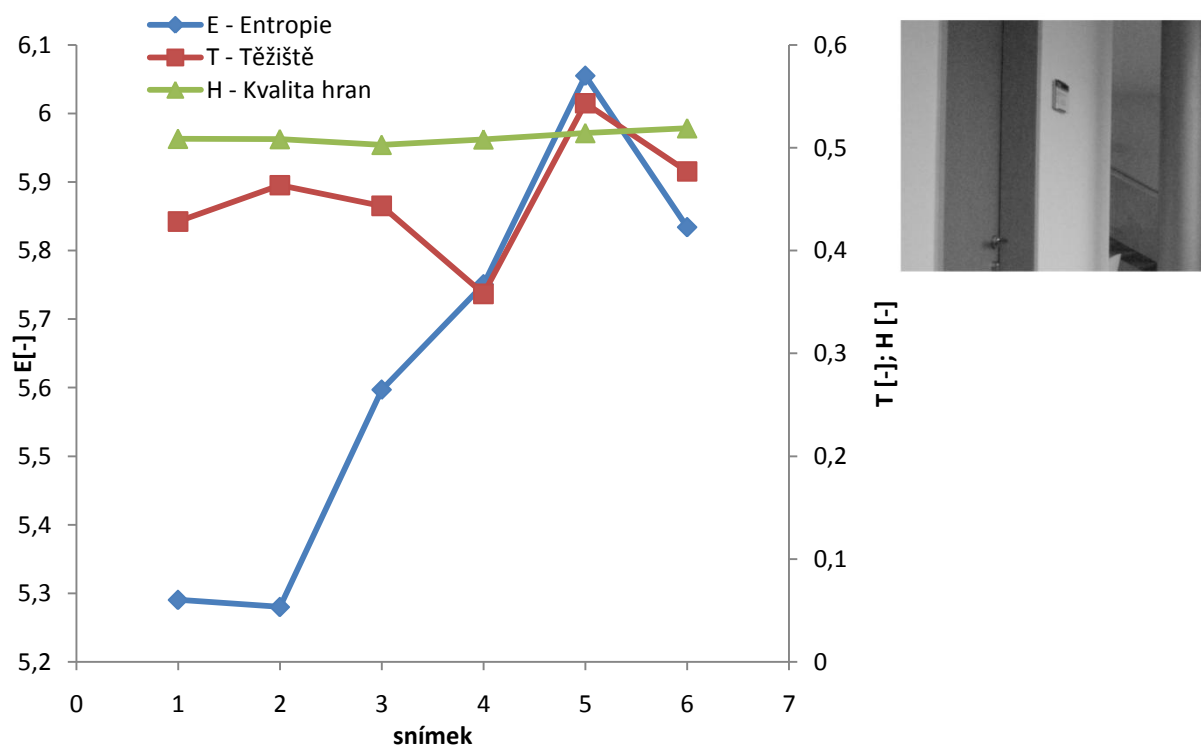
Obr. 6.4 Grafické závislosti parametrů pro snímek schody1



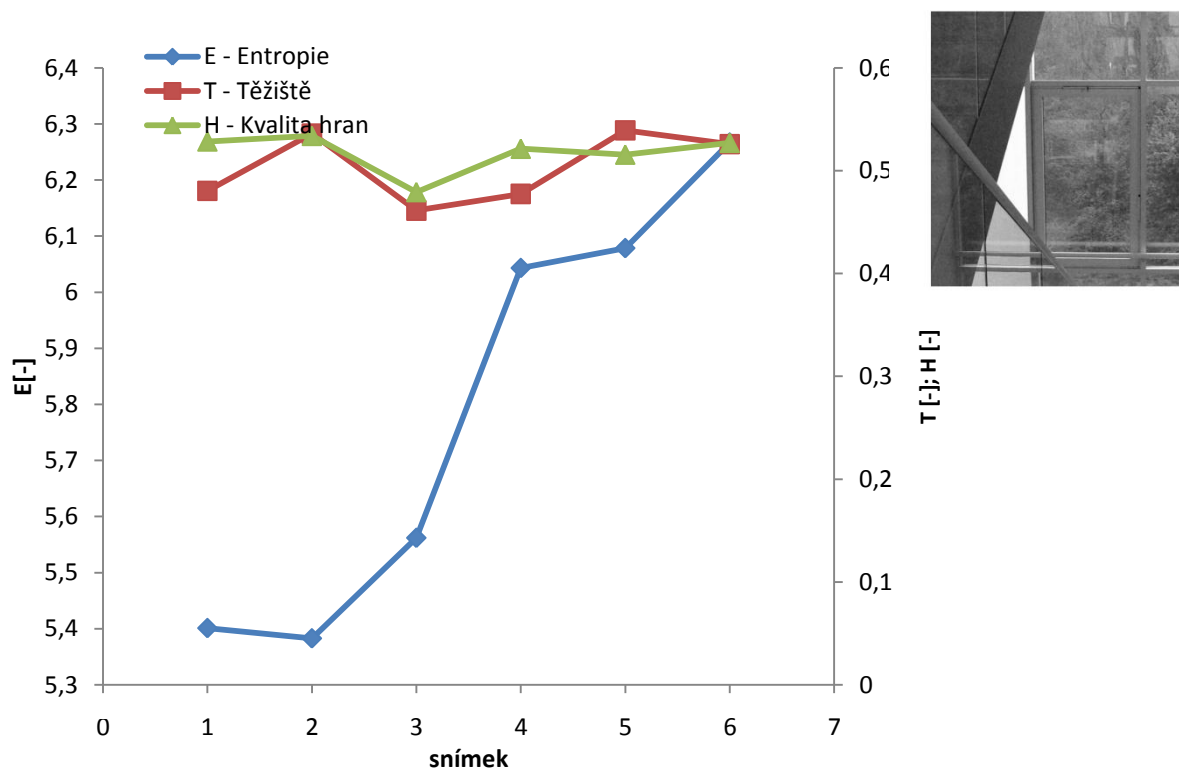
Obr. 6.5 Grafické závislosti parametrů pro snímek hasící přístroj




Obr. 6.6 Grafické závislosti parametrů pro snímek okno



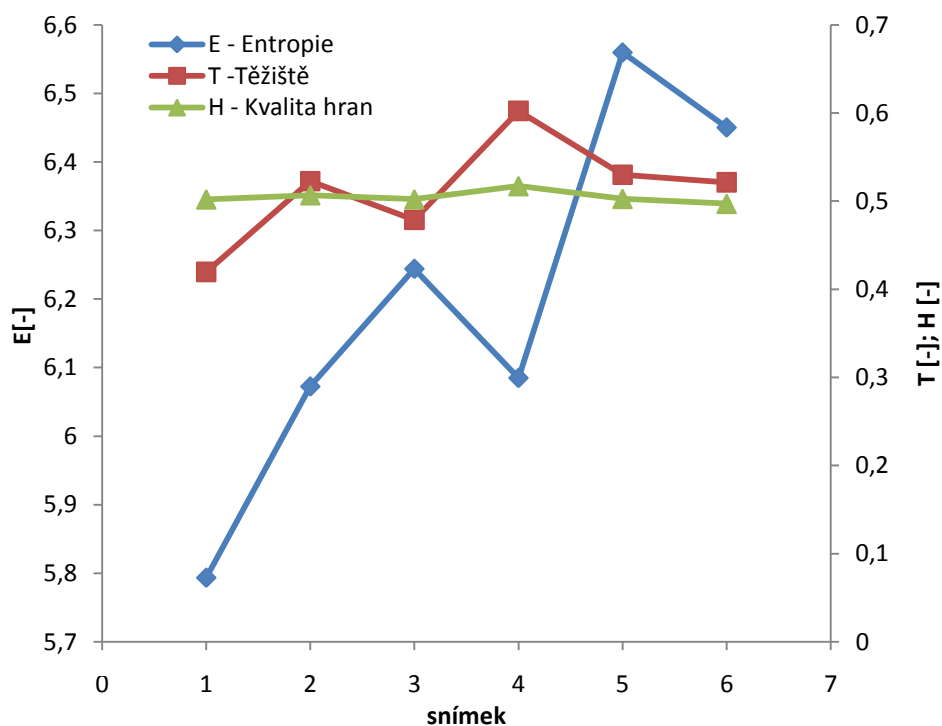
Obr. 6.7 Grafické závislosti parametrů pro snímek chodba



Obr. 6.8 Grafické závislosti parametrů pro snímek schody2



Obr. 6.9 Grafické závislosti parametrů pro snímek židle



Obr. 6.10 Grafické závislosti parametrů pro snímek kytka2

U grafických závislostí je přiložen pouze ostrý segment scény pro názornost. Celá fotografie je přiložena v [Příloha 1].

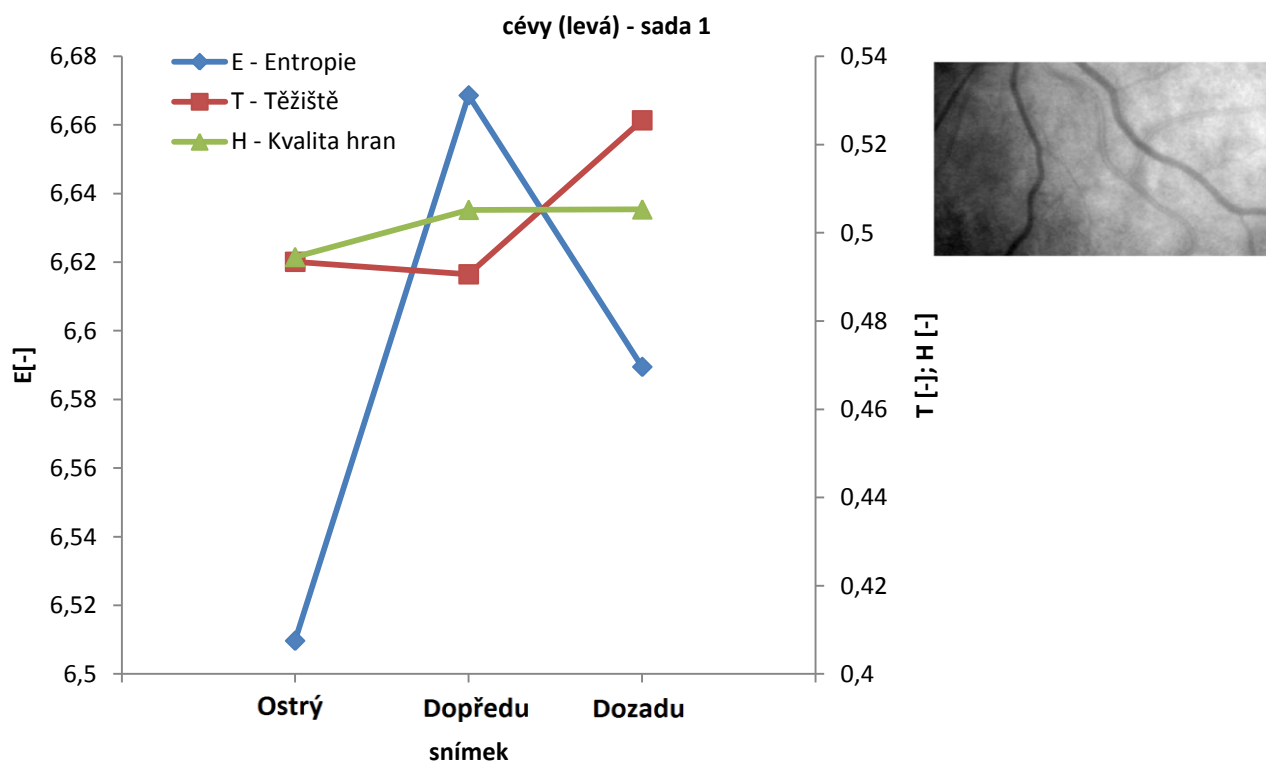
Pro hodnocení kvality snímků byla *entropie* zvolena jako hlavní posuzovací parametr. Dalšími, dá se říci, pomocnými parametry byla *kvalita Hran* a *těžiště histogramu*. Podle předpokladů by měla hodnota entropie vycházet nejmenší pro nejvíce ostrý snímek. Z grafických závislostí je patrné, že tento předpoklad nebyl vždy dosažen. Jak bylo již zmíněno na začátku kapitoly, snímky jsou subjektivně seřazeny ve stupnici od 1 do 6 podle ostroty. To znamená, že předpoklad nejmenšího čísla entropie pro subjektivně jevící se nejostřejší snímek vyšel u snímků: kytka1, plakát, stůl, schody1, okno, kytka2. U snímku *chodba* může být nepřesnost způsobena hloubkou scény, kde bude bližší část více zaostřená, než vzdálenější. Stejně vysvětlení by se dalo použít i pro snímky *schody2*. Ve snímku *židle* můžeme pozorovat největší nepřesnost. Tohle může způsobovat velké množství textury a malý počet hran.

Parametr *Kvalita hran* je na rozdíl od entropie závislý na prahování, čili na to, jak se jednotlivé hrany detekují. Pro kvalitu hran se předpokládá, že u ostrého snímku by mělo být číslo nejvyšší. Tento předpoklad platí pouze u některých snímků. To může být způsobeno právě závislostí na ostatních parametrech.

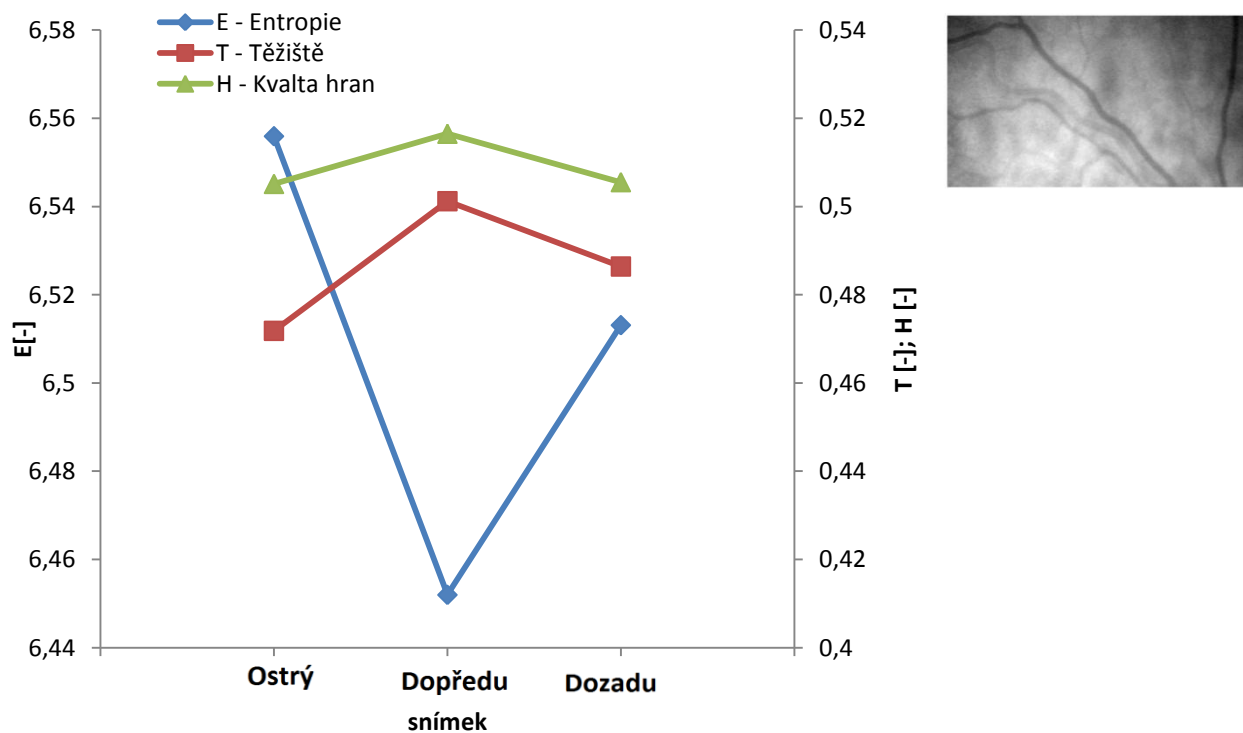
Parametr *těžiště histogramu* je spíše pomocný parametr. Jeho výsledné číslo je zpravidla závislé na charakteru scény, tudíž z něho nelze vyvozovat žádné předpoklady.

Ještě nutno podotknout, že jisté nepřesnosti mohly vzniknout při pořizování snímků, zejména u rozostřeného snímku se mohl objektiv lehce posunout a tím zabrat scénu mírně pozměněnou.


6.2. Hodnocení kvality pro snímky sítnice



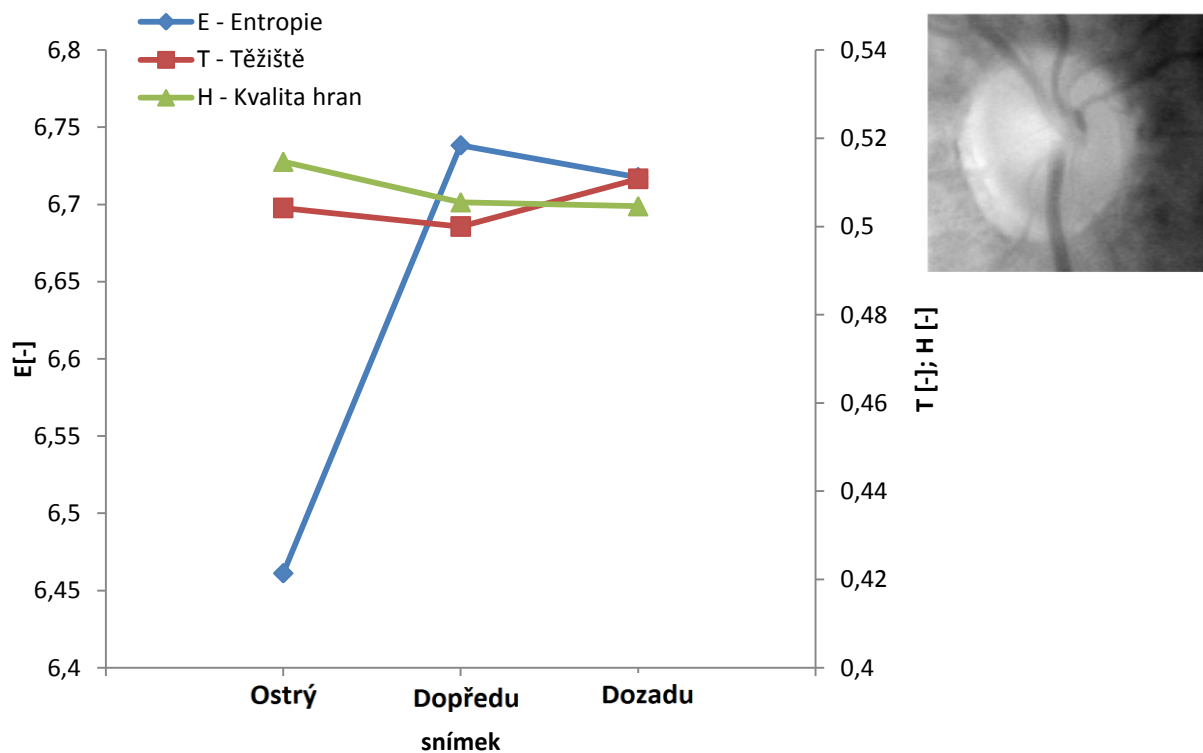
Obr. 6.11 Grafické závislosti parametrů pro snímek cév (levá) – sada 1



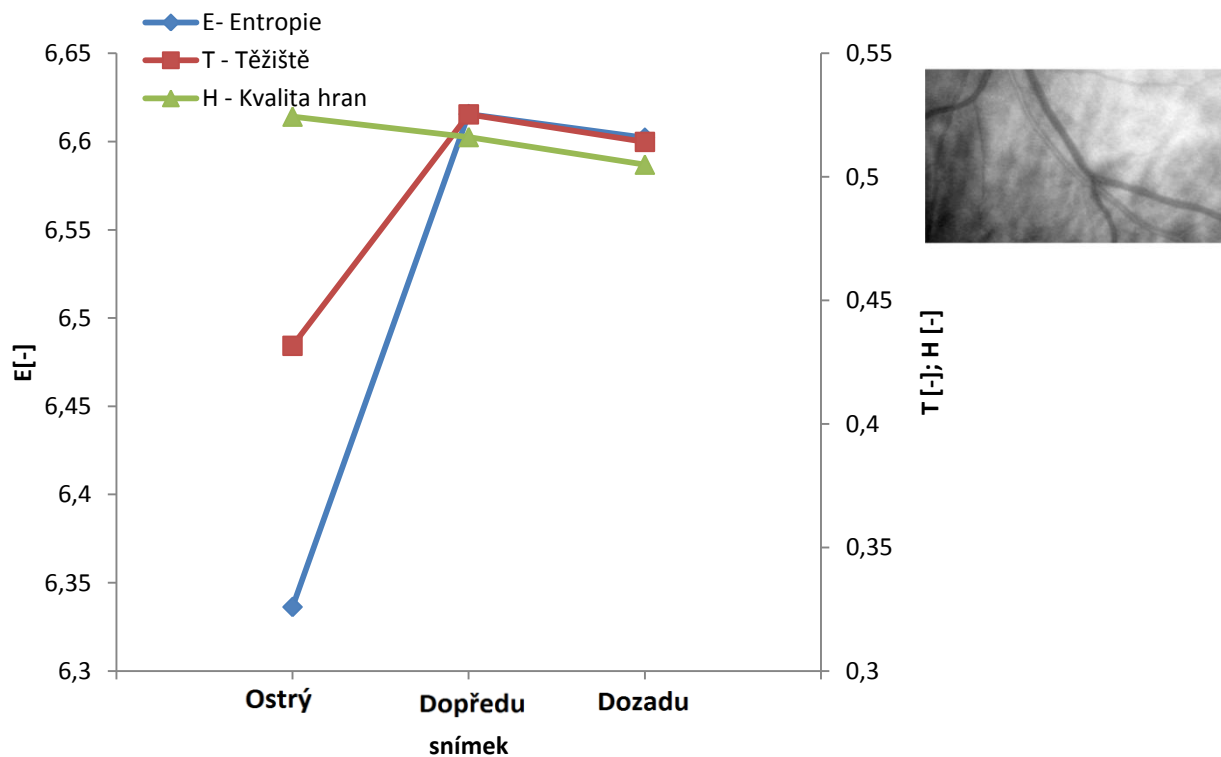
Obr. 6.12 Grafické závislosti parametrů pro snímek cév (pravá) – sada 1



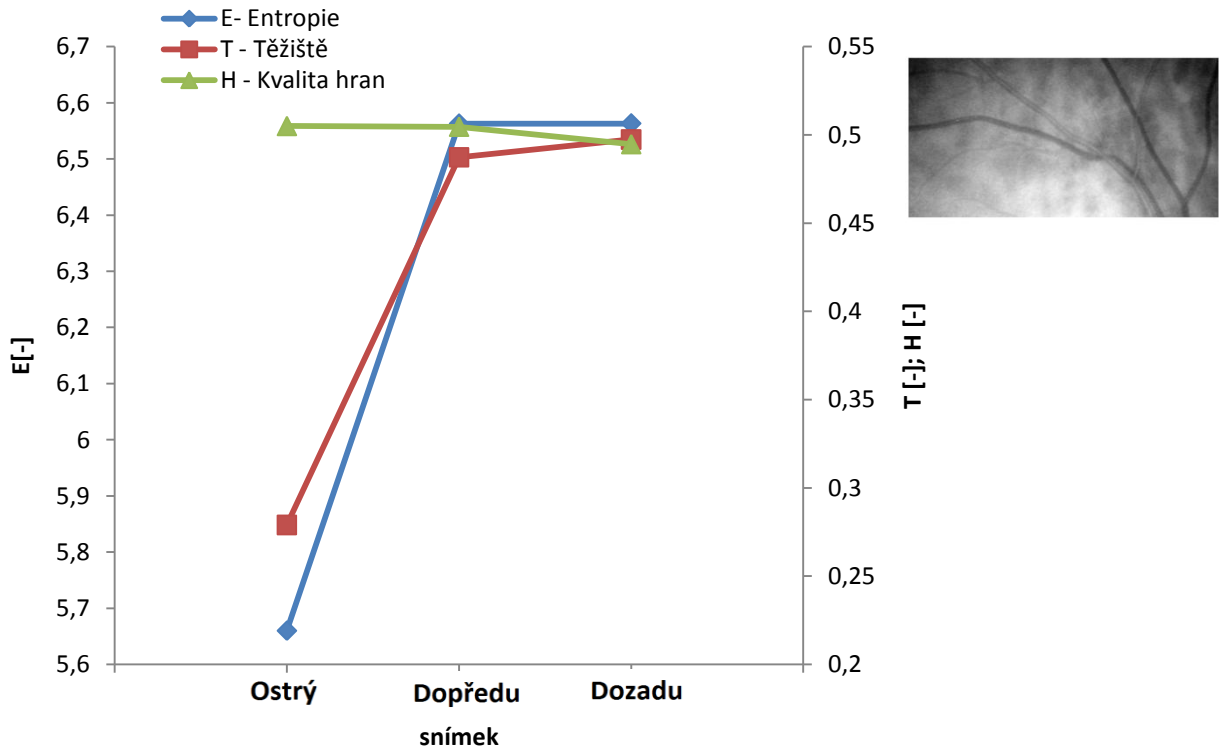
Obr. 6.13 Grafické závislosti parametrů pro snímek optického disku (levá) – sada 1




Obr. 6.14 Grafické závislosti parametrů pro snímek optického disku (pravá) – sada 1



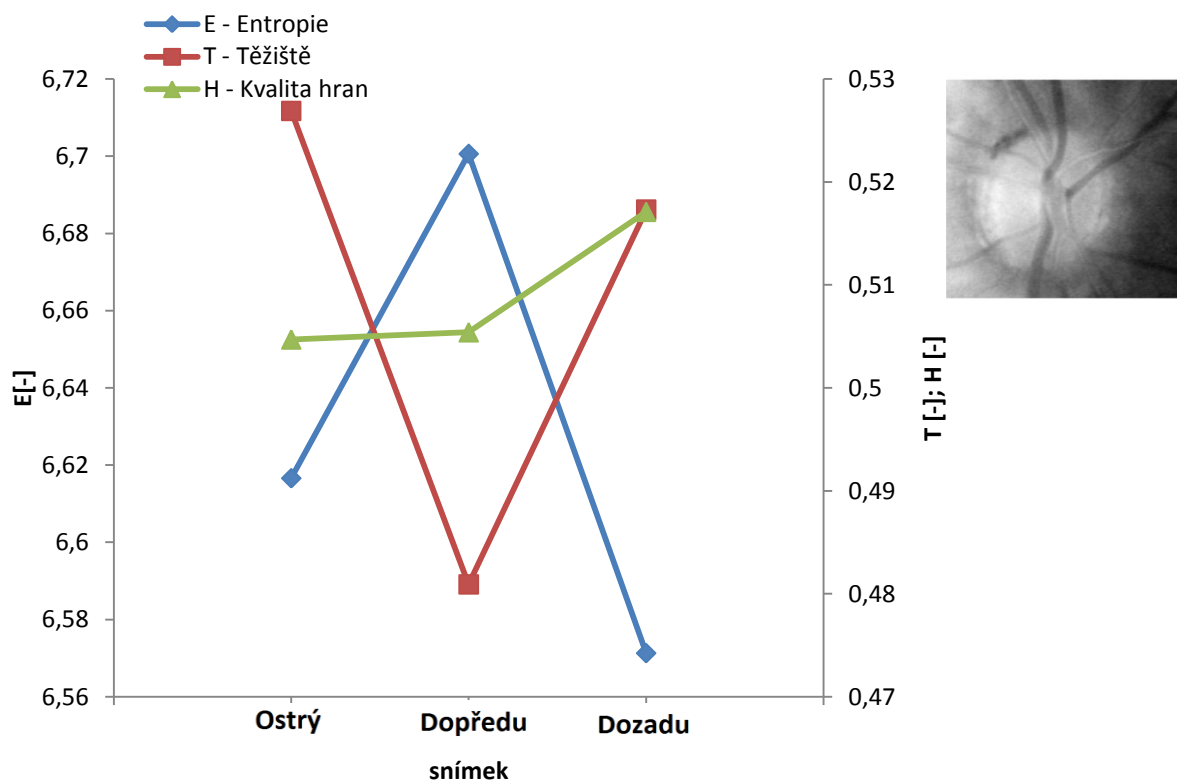
Obr. 6.15 Grafické závislosti parametrů pro snímek cév (levá) – sada 2



Obr. 6.16 Grafické závislosti parametrů pro snímek cév (pravá) – sada 2



Obr. 6.17 Grafické závislosti parametrů pro snímek optického disku (pravá) – sada 2



Obr. 6.18 Grafické závislosti parametrů pro snímek optického disku (pravá) – sada 2

Hodnocení kvality u snímku sítnice bylo vyzkoušeno na dvou sadách. U grafických závislostí odpovídá pojem *ostrý* zaostřenému snímku, pojem ‘dopředu’ odpovídá snímku zaostřenému před scénou a u ‘dozadu’ odpovídá snímku zaostřenému za scénou. Při pořizování těchto snímků je nutno počítat s jistou nepřesností při počítání parametrů z důvodu možného mírného posunutí zachycené scény.

Pro hodnocení kvality snímku sítnice platí stejné předpoklady jako pro modelová data, to znamená, že pro ostrý snímek by měla entropie vycházet co nejmenší. Z vynesení závislostí je patrné, že takto tomu bylo u většiny snímků, respektive segmentů snímků. Největší nesrovnalosti lze pozorovat na obrázku 6.18, kde u ostrého snímku vychází hodnota entropie nejvyšší. Z náhledu na scénu můžeme vypočítat, že v pravém horním i dolním rohu převažují tmavší odstíny, a tím vzniká tzv. nerovnoměrné osvětlení. Tento jev bude mít s největší pravděpodobností největší vliv na výslednou entropii. Při dalším zpracování by bylo velice vhodné tento jev potlačit.

Dále se zde může projevit šum a v tom případě by bylo vhodné ověřit, zda snímky ‘dopředu’ a ‘dozadu’ jsou opravdu méně ostré a případně je opět seřadit podle subjektivního vjemu, aby byly stejné.

7. Závěr

První část bakalářské práce je zaměřena na teoretické poznatky týkající se anatomie oka a jeho stavbou. Dále se práce soustředí na zobrazení snímků sítnice fundus kamerou a na vlastnosti těchto snímků. Znalost těchto vlastností je nezbytnou nutností pro práci s těmito snímky. Důležitou částí teoretických poznatků je kapitola o základních operacích pro předzpracování snímku sítnice. Je zde vysvětlen rozdíl mezi lokálními a bodovými operacemi, a k nim uvedené jednoduché příklady. Konec kapitoly se zabývá popisem prahování. Poslední kapitolou teoretické části je pojednání o charakteristikách obrazu. Je zde popsán princip histogramu a definovány parametry entropie a těžiště histogramu, což jsou parametry, kterými se v práci hodnotí kvalita snímků.

První kapitolu experimentální části představují naměřena data. Za účelem vytvoření algoritmu pro kvantitativní hodnocení kvality snímků sítnice byly naměřena reálná a modelová data. Reálná data samozřejmě reprezentují snímky sítnice, 3 dvojice snímků různě zaostřených. Modelová data reprezentuje 7 snímků papíru různě zaostřených, na kterém jsou černé a bílé proužky s měnící se prostorovou frekvencí. Tuto kapitolu zakončuje popis algoritmu pro výpočet parametrů pro hodnocení kvality.

Stěžejní částí bakalářské práce je poslední kapitola věnovaná hodnocení kvality. Za účelem dalšího otestování vytvořeného algoritmu bylo naměřeno dalších 10 scén modelových dat a další dvě sady snímků sítnice. V poslední kapitole jsou tyto naměřené parametry zaneseny do grafických závislostí, kde je k nim je napsaná příslušná diskuze výsledků.

Pro hodnocení kvality snímků sítnice dosahoval nejlepší výsledky parametr entropie, další dva parametry byly spíše pomocné. Pro větší využití dalších parametrů by byla vhodná úprava obrázků, na kterých vzniká nerovnoměrné osvětlení, a měl by se klást větší důraz na přesnost zachycené scény při pořizování snímků.

8. Literatura

- [1] NOVÁKOVÁ, M. Analýza časových sekvencí sítnice. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 54 s. Vedoucí semestrální práce doc. Ing. Radim Kolář, Ph.D.
- [2] DOSTÁL, V. *Předzpracování obrazů sítnice*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. 60 s. Vedoucí diplomové práce doc. Ing. Radim Kolář, Ph.D.
- [3] NIXON, Mark; AGUADO, Alberto . *Feature Extraction & Image Processing*. Oxford : Newnes, 2002. 350 s. ISBN 0750650788.
- [4] Přehled metod. Aplikace algoritmů pro registraci obrazu jako segmentační metody v angiografii mozku. SEGMENTACE OBRAZU V CT ANGIOGRAFII [online]. @))(), !, [cit. 2011-03-27]. Dostupný z WWW: <<http://cgg.mff.cuni.cz/~pepca/ref/angiografie.pdf>>.
- [5] ŘÍHA, K. Pokročilé techniky zpracování obrazu. Skripta FEKT VUT, ev.č. TKO 07-083. 2007. s. 1-105.
- [6] PIHAN, Roman. *Vše o světle - Histogram*. *Fotografovani.cz* [on-line] (29. 3. 2011) <http://www.fotografovani.cz/art/fozak_df/rom_1_13_histogram.html>
- [7] BARTSCH Hans Jochen. *Matematické vzorce*. Praha: Mladá fronta, 2002. 832 s.
- [8] KOMPRESSE OBRAZU. In HLAVÁČ, Václav. *KOMPRESSE OBRAZU* [online]. Fakulta elektrotechnická CVUT v Praze katedra kybernetiky : [s.n.], 2009 [cit. 2011-05-09]. Dostupné z WWW: <<http://cmp.felk.cvut.cz/hlavac>>.
- [9] MIKŠÍK, Ondřej. *Praktické využití metod digitálního zpracování obrazu*. Kroměříž, 2007. 43 s. Oborová práce. Gymnázium Kroměříž.
- [10] JAN, J. *Medical Image Processing, Reconstruction and Restoration - Concepts and Methods*. CRC New York 2006.
- [11] FLEMING, A.D., PHILLIP, S., GOATMAN, K.A., OLSON, J.A., SHART, P.F. et al.: Automated assessment of diabetic retinal image quality based on clarity and field definition, *Invest Ophthalmol Vis Sci.*, 2006, vol. 47, no. 3, p. 1120-1125.

Seznam Příloh

[Příloha 1] – CD s algoritmy pro výpočet parametrů s testovacími snímky

[Příloha 2] – vyhodnocení výsledků v Excelu