

Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky

Ing. Miroslav Hagara

Autoreferát dizertačnej práce

NOVÁ METÓDA DETEKCIE HRÁN V 1-D OBRAZOCH
SO ZVÝŠENOU PRESNOSŤOU

NEW METHOD FOR EDGE DETECTION IN 1-D IMAGES
WITH SUB-PIXEL ACCURACY

na získanie akademického titulu **philosophiae doctor, PhD.**
v odbore doktorandského štúdia: **5.2.13 Elektronika**
študijný program: **Rádioelektronika**

Bratislava, november 2012

Dizertačná práca bola vypracovaná v externej forme doktorandského štúdia na Ústave elektroniky a fotoniky Fakulty elektrotechniky a informatiky STU v Bratislave.

Predkladateľ: Ing. Miroslav Hagara
Ústav elektroniky a fotoniky FEI STU
Ilkovičova 3, 812 19 Bratislava

Školiteľ: doc. Ing. Peter Kulla, PhD.
Ústav elektroniky a fotoniky FEI STU
Ilkovičova 3, 812 19 Bratislava

Oponenti: prof. Ing. Miloš Klíma, CSc.
Katedra rádioelektroniky FEL ČVUT
Technická 2, 166 27 Praha 6

doc. Ing. Miroslav Hrianka, PhD.
Katedra mechatroniky a elektroniky FE ŽU
Univerzitná 8215/1, 010 26 Žilina

Autoreferát bol rozoslaný :

Obhajoba dizertačnej práce sa koná : o h .

na FEI STU, Ilkovičova 3, 812 19 Bratislava, v zasadačke dekana (blok A, 1.posch. vpravo)

prof. RNDr. Gabriel Juhás, PhD.
dekan FEI STU Bratislava

OBSAH

1 ÚVOD	4
2 PREHĽAD SÚČASNÉHO STAVU PROBLEMATIKY	5
3 CIELE DIZERTAČNEJ PRÁCE.....	9
4 ZVOLENÉ METÓDY SPRACOVANIA.....	10
4.1 Odhad počiatočnej hodnoty l_0 parametra l aproximačnej funkcie	11
4.2 Odhady počiatočných hodnôt h_0, k_0, σ_0 parametrov h, k, σ aproximačnej funkcie	11
5 VÝSLEDKY SIMULÁCIÍ A EXPERIMENTOV	14
5.1 Simulácie s nezašumeným signálom	14
5.2 Simulácie so zašumeným signálom.....	15
5.3 Experimenty	17
6 ZÁVER – VYHODNOTENIE A PRÍNOSY DIZERTAČNEJ PRÁCE.....	23
Literatúra.....	24
Zoznam vlastných publikácií	25
SUMMARY	26

1 ÚVOD

Väčšinu informácií získava človek svojím zrakom, preto je obraz najčastejšie spracovávanou informáciou. Spočiatku to bolo výhradne analógové spracovanie, v súčasnosti jednoznačne prevažuje číslicové spracovanie obrazu. Keďže je priama súvislosť medzi hranami v obraze a fyzickými vlastnosťami scény (hrany v obraze väčšinou reprezentujú obrisy objektov scény), dá sa veľa informácií o scéne získať práve z obrazu hrán. Preto je detekcia hrán jednou z kľúčových operácií, napr. v systémoch počítačového videnia. Detektory hrán konvertujú šedotónový alebo farebný obraz na binárny obraz – mapu hrán, ktorá zachováva veľkú časť informačného obsahu pôvodného obrazu. Detekcia hrán pomáha pri vyhodnocovaní diagnostických snímok v medicíne, pri spracovaní radarových a družicových snímok v meteorológii ale môžeme sa s ňou stretnúť aj prakticky na každom kroku v bežne používaných zariadeniach, napr. v mobilných telefónoch, televíznych prijímačoch, fotoaparátoch, kamerách, atď. V spomínaných aplikáciách sa používa detekcia hrán s presnosťou jeden obrazový bod, vyššia presnosť pri nich ani nie je potrebná. Pri niektorých špecifických aplikáciách, ako je napríklad bezkontaktné meranie rozmerov alebo analýza pohybu, je vhodné lokalizovať hranu s presnosťou väčšou ako len jeden obrazový bod. Práve problematike presnej lokalizácie hrán a návrhu novej metódy pre detekciu hrán so zvýšenou presnosťou v 1-D obrazoch sa venujem vo svojej dizertačnej práci.

V práci sú najprv opísané metódy na detekciu hrán s presnosťou jeden obrazový bod a tiež metódy na presnú lokalizáciu hrany v 1-D a 2-D obrazoch. Potom nasleduje návrh novej metódy umožňujúcej určiť pozíciu hrany so zvýšenou presnosťou. Hľadaná presná pozícia hrany je vlastne jedným z výsledných parametrov aproximačnej funkcie, ktoré sa získajú minimalizovaním účelovej funkcie. Dôležitou časťou návrhu novej metódy je odhad počiatočných hodnôt parametrov aproximačnej funkcie, ktoré sú potrebné pri iteračnej metóde hľadania minima účelovej funkcie.

Navrhnutá metóda je pomocou simulácií a experimentov porovnávaná s tromi najpresnejšími a najčastejšie používanými metódami presnej lokalizácie hrany v 1-D obrazoch: s metódou založenou na momentoch obrazovej funkcie, metódou využívajúcou priestorové momenty obrazovej funkcie a metódou založenou na waveletovej transformácii obrazovej funkcie. Metódy sú porovnávané z hľadiska presnosti, kritériom presnosti je smerodajná odchýlka chyby lokalizácie hrany. Pri porovnávaní sa hlavne sleduje, ako sa mení smerodajná odchýlka chyby lokalizácie hrany so zmenou parametra rozostrenia hrany σ a ako je ovplyvnená počtom vzoriek použitých pri výpočte presnej pozície hrany. Ukázalo sa, že hlavnou výhodou navrhutej metódy presnej lokalizácie hrany v porovnaní s doteraz používanými metódami je jej väčšia presnosť v prípade rozostreného obrazu.

V závere práce sú uvedené pôvodné prínosy dizertačnej práce spolu s použitou literatúrou a vlastnými publikáciami, ktoré súvisia s prácou.

2 PREHĽAD SÚČASNÉHO STAVU PROBLEMATIKY

Najjednoduchší spôsob [1] ako zvýšiť presnosť detekcie hrán je prevzorkovať obraz smerom hore (up-sampling) a potom použiť niektorý hranový detektor s presnosťou jeden obrazový bod. Presnosť detekcie hrany je v tomto prípade podmienená mierou prevzorkovania a jej kvalitou.

Tabatabai a Mitchell navrhli momentový hranový detektor [2] založený na prvých troch momentoch vzoriek obrazu

$$m_i = \frac{1}{n} \sum_{j=1}^n x_j^i \quad \dots i = 1, 2, 3 \quad , \quad (1)$$

kde x_1, x_2, \dots, x_n sú vzorky obrazu. Predpokladajme, že ide o vzorky ideálnej skokovej hrany (obr.1) s parametrami: pozícia hrany l , jas pozadia h a zmena jasu k (výška hrany). Ak p_h je počet vzoriek majúci hodnotu h (sú to vzorky naľavo od hrany), potom definujeme relatívne početnosti p_1 a p_2 ako

$$p_1 = \frac{p_h}{n} \quad (2)$$

$$p_2 = \frac{n - p_h}{n} = 1 - p_1 \quad (3)$$

a riešením troch rovníc

$$m_1 = (1 - p_2)h + p_2(h + k) \quad (4)$$

$$m_2 = (1 - p_2)h^2 + p_2(h + k)^2 \quad (5)$$

$$m_3 = (1 - p_2)h^3 + p_2(h + k)^3 \quad (6)$$

o troch neznámých h, k, p_2 dostaneme [2]

$$p_2 = \frac{1}{2} \left(1 + s \sqrt{\frac{1}{4 + s^2}} \right) \quad (7)$$

$$h = m_1 - \sigma \sqrt{\frac{p_2}{p_1}} \quad (8)$$

$$k = 2\sigma \sqrt{\frac{p_2}{p_1}} \quad (9)$$

kde

$$s = \frac{m_3 + 2m_1^3 - 3m_1m_2}{\sigma^3} \quad (10)$$


$$\sigma^2 = m_2 - m_1^2 \quad (11)$$

V prípade, že sa pri výpočte použijú vzorky reálnej obrazovej funkcie, nebude $p_h = n.p_1$ celé číslo a bude to vlastne lokalizácia hrany so zvýšenou presnosťou.

Ďalší hranový detektor s presnosťou lepšou ako jeden obrazový bod (ďalej len SPA detektor) [3] je založený na priestorovom momente (spatial moment) funkcie. Spojitá funkcia $f(x)$ má priestorový moment p -teho rádu definovaný ako [3]

$$M_p = \int x^p f(x) dx . \quad (12)$$

Nech $f(x)$ je spojitá 1-D obrazová funkcia zodpovedajúca skokovej hrane a je (pre zjednodušenie výpočtu) ohraničená od -1 do 1 (obr.1)



Obr. 1: Skoková hrana – 1-D model.

Potom vzťah (12) môžeme pre $p = 0, 1$ a 2 napísať ako

$$M_0 = h \int_{-1}^l dx + k \int_l^1 dx = 2h + k(1-l) \quad (13)$$

$$M_1 = h \int_{-1}^l x dx + k \int_l^1 x dx = \frac{1}{2} k(1-l^2) \quad (14)$$

$$M_2 = h \int_{-1}^l x^2 dx + k \int_l^1 x^2 dx = \frac{2}{3} h + \frac{1}{3} k(1-l^3) . \quad (15)$$

Riešením týchto rovníc dostaneme [3]

$$l = \frac{3M_2 - M_0}{2M_1} \quad (16)$$

$$k = \frac{2M_1}{(1-l^2)} \quad (17)$$

$$h = \frac{1}{2} [M_0 - k(1-l)] . \quad (18)$$

Zo vzoriek reálnej obrazovej funkcie vieme vypočítať odhady momentov M_0, M_1 a M_2 a pomocou nich sa dá vypočítať odhad parametra l (16), čiže pozícia hrany.

Kisworo, Venkatesh a West založili svoju metódu SPA detekcie hrán na porovnaní lokálnych energií reálnej obrazovej funkcie a funkcie modelu hrany. Funkciu lokálnej energie (local energy function) definovali [4] ako komplexnú funkciu $len(x)$

$$len(x) = f(x) + if_{im}(x) , \quad (19)$$

kde

$$f_{im}(x) = \sum a_n \sin(n\omega_n x + \varphi_n) . \quad (20)$$

Parametre a_n , ω_n a φ_n sa získajú zo zlúčeného tvaru Fourierovho radu funkcie $f(x)$

$$f(x) = \sum a_n \cos(n\omega_n x + \varphi_n) . \quad (21)$$

Podľa odozvy filtrov extrahujúcich zo vstupného signálu lokálnu energiu [4] sa najprv určí, ktorý model hrany, skoková hrana alebo šikmá hrana, sa použije na aproximáciu reálneho 1-D obrazu. Pomocou metódy najmenších štvorcov (porovnáva sa funkcia lokálnej energie modelu a reálneho obrazu) sa iteráciou nájdu optimálne parametre zvoleného modelu hrany, z ktorého sa potom určí presné miesto hrany.

Xu [5] využíva pri svojej metóde SPA detekcie hrán waveletovú transformáciu $W_s f(x)$ (s mierkou s) obrazovej funkcie $f(x)$. Vychádza z vlastnosti waveletovej transformácie, že lokálnemu maximu $W_s f(x)$ zodpovedá hrana v 1-D obraze. Ak x_1, x_2, \dots, x_n sú vzorky obrazu a $W_s(x_i)$ hodnoty waveletovej transformácie, potom p_i definované vzťahom [5]

$$p_i = \frac{W_s(x_i)}{\sum_{j=1}^n W_s(x_j)} \quad (22)$$

predstavuje pravdepodobnosť, že vzorka waveletovej transformácie $W_s(x_i)$ je lokálnym maximom. Pozícia hrany l sa vypočíta pomocou vzťahu

$$l = \sum_{i=1}^n i \cdot p_i \quad (23)$$

Vyššie spomínané metódy sú pomerne náročné na výpočtový čas a nie sú vhodné pre aplikácie pracujúce v reálnom čase. Preto boli navrhnuté postupy [6,7], ktoré sa dajú aplikovať v rýchlych číslicových obvodoch a zvyšujú presnosť lokalizácie hrany, aj keď nie tak výrazne. Hussmann a Ho [7] aproximujú obrazovú funkciu v okolí hrany pomocou dvoch lineárnych funkcií $f_1(x)$ a $f_2(x)$. Parametre prvej funkcie sa nájdu pomocou obrazových bodov z blízkeho okolia lokálneho maxima prvej derivácie obrazovej funkcie. Táto funkcia aproximuje úsek modelu šikmej hrany medzi bodmi l_1 a l_2 . Druhá funkcia je vodorovná a aproximuje časť modelu šikmej hrany naľavo od bodu l_1 . Miesto, kde sa tieto dve funkcie pretnú, zodpovedá bodu l_1 . Podrobnejšie je situácia popísaná na obr.2.

Pre vzorky $I(i)$ obrazu sa vypočíta diferenciacia $D_e(i)$

$$D_e(i) = \frac{I(i+2) - I(i)}{2} , \quad (24)$$

potom sa nájde jej maximum D_{emax} a označí sa index i_{max} , pre ktorý platí $D_e(i_{max}) = D_{emax}$. Funkcia $f_1(x)$, ktorá aproximuje obrazovú funkciu v okolí i_{max} sa dá popísať vzťahom

$$f_1(x) = I(i_{max}) + (x - i_{max})D_{emax} \quad (25)$$

Funkcia $f_2(x)$ je rovná hodnote obrazu I_a (obr.2)


$$f_2(x) = I_a \quad (26)$$

Pre pozíciu hrany musí platiť

$$f_1(l_1) = f_2(l_1) \quad (27)$$

a riešením je

$$l_1 = i_{max} - \frac{I(i_{max}) - I_a}{D_{emax}} \quad (28)$$



Obr.2: Aproximácia obrazovej funkcie pomocou dvoch lineárnych funkcií $f_1(x)$ a $f_2(x)$.

Trochu netradičný prístup zvolili pre svoju metódu SPA detekcie hrán Baba a Ohtani [6]. Najprv realizujú prvú deriváciu signálovej formy obrazovej funkcie pomocou analógového derivačného obvodu, jeho výstup navzorkujú a v okolí lokálneho maxima aproximujú polynómom druhého stupňa. Lokálne maximum tohto polynómu predstavuje spresnenú pozíciu hrany.

V poslednej dobe sa pozornosť sústreďuje hlavne na SPA hranové detektory pre 2-D obrázky, pričom dominantnú skupinu tvoria momentové metódy. Sú založené na priestorových momentoch [3,8], Zernikovych momentoch [9-13] alebo Fourier-Mellinových momentoch [14-16] obrazovej funkcie. Všetky spomenuté detektory vychádzajú z 2-D modelu hrany, ktorý je vlastne 2-D rozšírením 1-D modelu z obr.1 a vyznačujú sa približne rovnakou presnosťou lokalizácie hrany v obraze [8] – 0.1 obrazového bodu.

3 CIELE DIZERTAČNEJ PRÁCE

Na základe analýzy súčasného stavu problematiky detekcie hrán v obrazoch rozhodol som sa formulovať ciele svojej dizertačnej práce do 4 bodov:

1. **Navrhnuť novú metódu detekcie hrán so zvýšenou presnosťou pre 1-D obrázky založenú na aproximácii obrazu v okolí hrany vhodnou aproximačnou funkciou (modelom hrany).**
2. **Pre zvolenú aproximačnú funkciu (model hrany) vybrať vhodnú účelovú funkciu a navrhnuť spôsob odhadu počiatočných hodnôt parametrov aproximačnej funkcie, ktoré sú potrebné pri iteračnej metóde hľadania minima alebo maxima účelovej funkcie.** Parametre aproximačnej funkcie, s ktorými účelová funkcia dosahuje minimum (maximum), predstavujú hľadané parametre aproximačnej funkcie, pri ktorých aproximačná funkcia najpresnejšie vystihuje navzorkované hodnoty obrazu. Spravidla, čím sú počiatočné hodnoty parametrov bližšie k hľadaným, tým kratší je čas iteračného výpočtu (menší počet iterácií) a tým kratší je čas celkového výpočtu.
3. **Pomocou simulácie a experimentov porovnať navrhnutú metódu detekcie hrán so zvýšenou presnosťou pre 1-D obrázky s doteraz najčastejšie používanými metódami.**
4. **Určiť aký počet vzoriek obrazovej funkcie je optimálny z hľadiska presnosti detekcie hrany.** Malý počet vzoriek je pre presnú lokalizáciu hrany nedostačujúci. Príliš veľký počet vzoriek však tiež môže mať za následok zníženie presnosti, pretože osvetlenie scény nie je rovnomerné.


4 ZVOLENÉ METÓDY SPRACOVANIA

Vychádzajúc zo skúseností, ktoré som v minulých rokoch získal v oblasti detekcie hrán, navrhol som novú metódu pre detekciu hrán v 1-D obrazoch so zvýšenou presnosťou založenú na aproximácii obrazovej funkcie v okolí hrany vhodnou aproximačnou funkciou.

Na aproximáciu obrazovej funkcie v okolí hrany je možné použiť širokú škálu funkcií. Môže to byť niektorá z funkcií opisujúcich model hrany, môže to byť polynóm tretieho a vyššieho stupňa, môže to byť aj B-spline, prípadne iná vhodná aproximačná funkcia. Použitie B-spline funkcie ako aj polynómov tretieho a vyššieho stupňa na aproximáciu obrazovej funkcie v okolí hrany má jeden nedostatok [17] a síce, že je možné pomocou nich aproximovať 1-D obraz len v tesnom okolí hrany, kde obrazová funkcia ešte nedosahuje hodnoty pozadia (obr.1 a obr.3: úroveň h) alebo popredia (obr.1 a obr.3: úroveň $h+k$). Rozhodol som sa preto pri aproximácii obrazovej funkcie vychádzať z modelu rozostrenej hrany

$$f(x) = \frac{k}{2} \left(\operatorname{erf} \left(\frac{x-l}{\sqrt{2}\sigma} \right) + 1 \right) + h . \quad (29)$$

Model rozostrenej hrany (obr.3) má štyri parametre: pozíciu hrany l , jas pozadia h , zmenu jasu k (výška hrany) a rozostrenie σ . Tento model zohľadňuje vlastnosti optickej sústavy snímacieho systému.



Obr.3: Rozostrená hrana.

Navrhnutá aproximačnú funkcia bude

$$f_a(x) = \frac{k}{2} \left(\operatorname{erf} \left(\frac{x-l}{\sqrt{2}\sigma} \right) + 1 \right) + h . \quad (30)$$

kde $\operatorname{erf}(x)$ je definovaná ako [18]

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt . \quad (31)$$

Pre konkrétne reálne hodnoty $f_r(i)$ obrazovej funkcie v okolí hrany sa vypočítajú hodnoty parametrov l , h , k , σ aproximačnej funkcie pomocou metódy najmenších štvorcov, čiže sa iteračnou metódou nájde minimum účelovej funkcie $E(l,h,k,\sigma)$

$$E(h, k, l, \sigma) = \sum_{i=1}^N (f_r(i) - f_a(i))^2, \quad (32)$$

kde N je počet použitých vzoriek obrazovej funkcie. Parameter l predstavuje hľadanú spresnenú pozíciu hrany.

Navrhovaná metóda pre detekciu hrán v 1-D obrazoch so zvýšenou presnosťou založená na aproximácii obrazovej funkcie v okolí hrany funkciou $f_a(x)$ pozostáva z troch krokov:

- detekcia hrany s presnosťou jeden obrazový bod \rightarrow odhad počiatkovej hodnoty l_0 parametra l aproximačnej funkcie $f_a(x)$
- odhad počiatkových hodnôt h_0, k_0, σ_0 parametrov h, k, σ aproximačnej funkcie $f_a(x)$
- nájdenie minima účelovej funkcie $E(l, h, k, \sigma) \rightarrow$ nájdenie optimálnych hodnôt l_s, h_s, k_s, σ_s parametrov l, h, k, σ aproximačnej funkcie $f_a(x)$, pri ktorých aproximačná funkcia najpresnejšie vystihuje navzorkované hodnoty $f_r(i)$ obrazovej funkcie v okolí hrany

4.1 Odhad počiatkovej hodnoty l_0 parametra l aproximačnej funkcie

Pre odhad počiatkovej hodnoty l_0 parametra l (pozícia hrany) aproximačnej funkcie $f_a(x)$ je možné použiť prakticky ľubovoľnú metódu detekcie hrany v 1-D obraze s presnosťou jeden obrazový bod. Pre jednoduchosť som sa rozhodol odhadovať pozíciu hrany pomocou diferencnej funkcie $df_r(i)$, ktorej hodnoty sa vypočítajú zo vzoriek $\{f_r(i)\}$ reálnej obrazovej funkcie nasledovne

$$df_r(i) = f_r(i+1) - f_r(i), \quad i = 1, 2, \dots, N-1, \quad (33)$$

kde N je počet vzoriek obrazovej funkcie v okolí hrany.

Počiatková hodnota parametra l_0 aproximačnej funkcie bude potom rovná pozícii i_{\max} , kde diferencná funkcia $df_r(i)$ nadobúda maximum, t.j kde platí

$$df_r(i_{\max}) = \max\left(\{df_r(i)\}_{i=1}^{N-1}\right). \quad (34)$$

Vyššie opísaná detekcia hrany pre bežný obraz postačuje, pre silne zašumený obraz alebo pre obraz obsahujúci aj impulzný šum (šum typu „sol’ a korenie“) by bolo vhodnejšie použiť niektorú z robustnejších metód detekcie hrán.

4.2 Odhady počiatkových hodnôt h_0, k_0, σ_0 parametrov h, k, σ aproximačnej funkcie

Pri odhade počiatkovej hodnoty σ_0 parametra σ (rozostrenie hrany) aproximačnej funkcie som vychádzal z derivácie aproximačnej funkcie $f_a'(x)$, pre ktorú platí podľa [18]

$$f_a'(x) = \frac{df_a(x)}{dx} = \frac{k}{\sqrt{2\pi\sigma}} \exp\left(-\left(\frac{x-l}{\sqrt{2\sigma}}\right)^2\right). \quad (35)$$

Ak sa do (35) dosadia za x hodnoty $x_{\max}=l$, $x_d=(l-2\sigma)$ a $x_u=(l+2\sigma)$, potom bude platiť

$$f_a'(x_{\max}) = \frac{k}{\sqrt{2\pi\sigma}}, \quad (36)$$

$$f'_a(x_d) = \frac{k}{\sqrt{2\pi\sigma}} \exp\left(-\left(\frac{-2\sigma}{\sqrt{2\sigma}}\right)^2\right) = \frac{k}{\sqrt{2\pi\sigma}} \exp(-2), \quad (37)$$

$$f'_a(x_u) = \frac{k}{\sqrt{2\pi\sigma}} \exp\left(-\left(\frac{2\sigma}{\sqrt{2\sigma}}\right)^2\right) = \frac{k}{\sqrt{2\pi\sigma}} \exp(-2). \quad (38)$$

respektíve

$$\frac{f'_a(x_d)}{f'_a(x_{\max})} = \frac{f'_a(x_u)}{f'_a(x_{\max})} = \exp(-2) \approx 0.135. \quad (39)$$

Je zrejmé, že platí

$$x_u - x_d = 4\sigma. \quad (40)$$

Z vyššie uvedeného vyplýva, že ak pre reálnu obrazovú funkciu $f_r(i)$, jej diferencnú funkciu $df_r(i)$ a odhad pozície hrany $l_0 = i_{\max}$ (pozri predošlú kapitolu) nájdeme také $i_d < i_{\max}$ a $i_u > i_{\max}$, pre ktoré bude platiť

$$\left(\frac{df_r(i_d - 1)}{df_r(i_{\max})} < 0.135\right) \wedge \left(\frac{df_r(i_d)}{df_r(i_{\max})} \geq 0.135\right) \quad (41)$$

a

$$\left(\frac{df_r(i_u - 1)}{df_r(i_{\max})} > 0.135\right) \wedge \left(\frac{df_r(i_u + 1)}{df_r(i_{\max})} \leq 0.135\right), \quad (42)$$

potom odhad počiatocnej hodnoty σ_0 parametra σ aproximačnej funkcie môžeme vypočítať

$$\sigma_0 = \frac{1}{4}(i_u - i_d). \quad (43)$$

Počiatocné hodnoty parametrov h a k aproximačnej funkcie je možné určiť ako

$$h_0 = f_r(i_d) \quad (44)$$

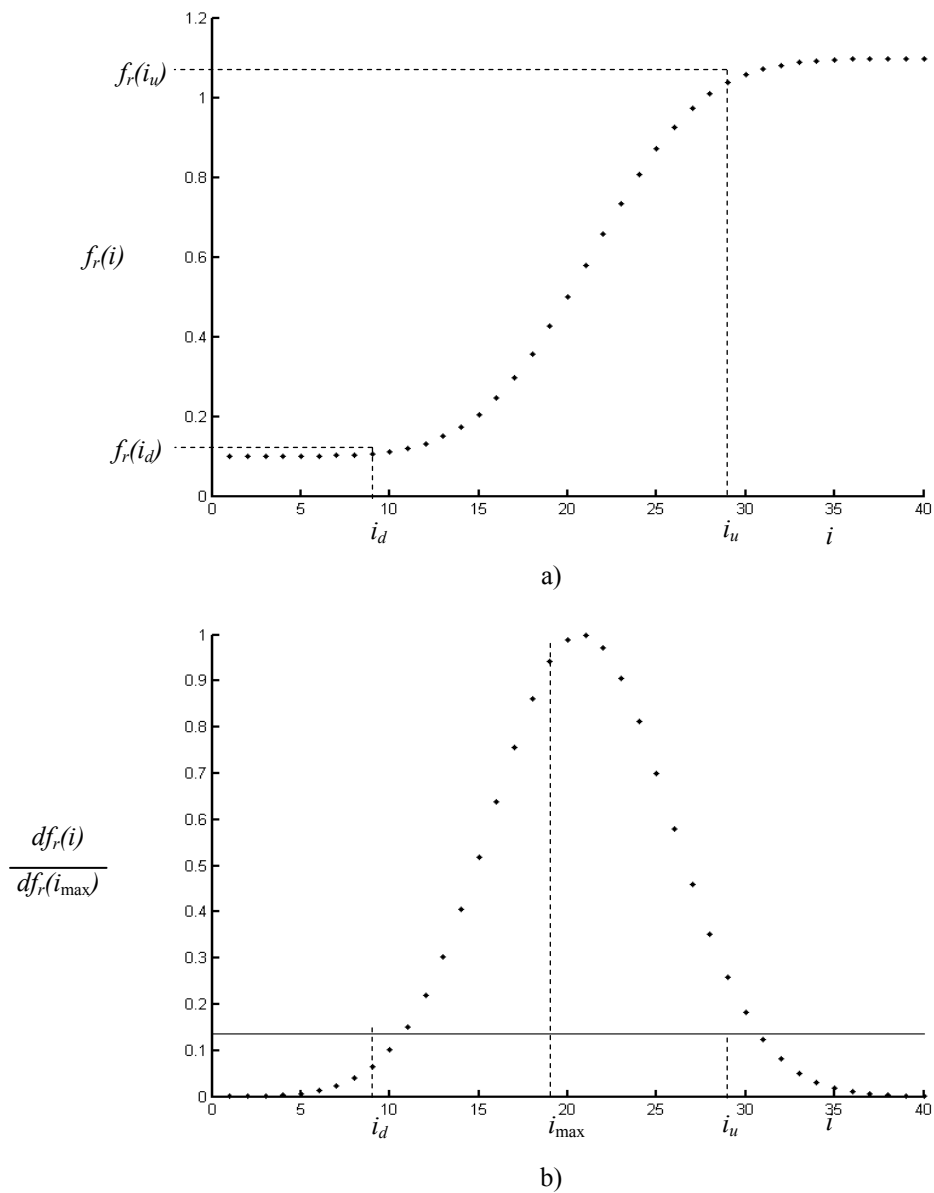
$$k_0 = f_r(i_u) - f_r(i_d). \quad (45)$$

Obr.4 ilustruje postup odhadu počiatocných hodnôt parametrov l, h, k, σ aproximačnej funkcie. Na obr.4a je obrazová funkcia reprezentovaná vzorkami spojitej funkcie - modelu rozostrenej hrany (29) s parametrami $l = 20.25$, $h = 0.1$, $k = 1$ a $\sigma = 5$. Vypočítame hodnoty diferencnej funkcie $df_r(i)$ a nájdeme jej maximum, v našom príklade dosahuje diferencná funkcia $df_r(i)$ maximum pre $i = i_{\max} = 21$. Počiatocná hodnota parametra l bude teda $l_0 = 21$. Na obr.4b sú hodnoty funkcie $df_r(i)/df_r(i_{\max})$ a tiež vyznačená úroveň 0.135.

Hodnoty i_d a i_u , pre ktoré platia vzťahy (41) a (42) sú $i_d = 11$ a $i_u = 31$, z ktorých vypočítame počiatocnú hodnotu parametra σ , $\sigma_0 = 0.25 \cdot (31 - 11) = 5$. Z hodnôt $f_r(i_d) = 0.12$ a $f_r(i_u) = 1.07$ vypočítame počiatocné hodnoty parametrov h a k , $h_0 = f_r(i_d) = 0.12$ a $k_0 = (f_r(i_u) - f_r(i_d)) = 0.95$.

V uvedenom príklade som použil namiesto reálnej obrazovej funkcie navzorkovaný model, ktorý je prakticky zhodný s aproximačnou funkciou. Vypočítané odhady počiatocných hodnôt parametrov l, h, k, σ aproximačnej funkcie sú preto veľmi blízke parametrom modelu. Experimenty potvrdili, že aj v prípade reálneho obrazu sa odhady počiatocných hodnôt parametrov vypočítané

podľa vyššie uvedeného postupu výrazne nelíšia od výsledných hodnôt parametrov aproximačnej funkcie po ukončení optimalizácie.



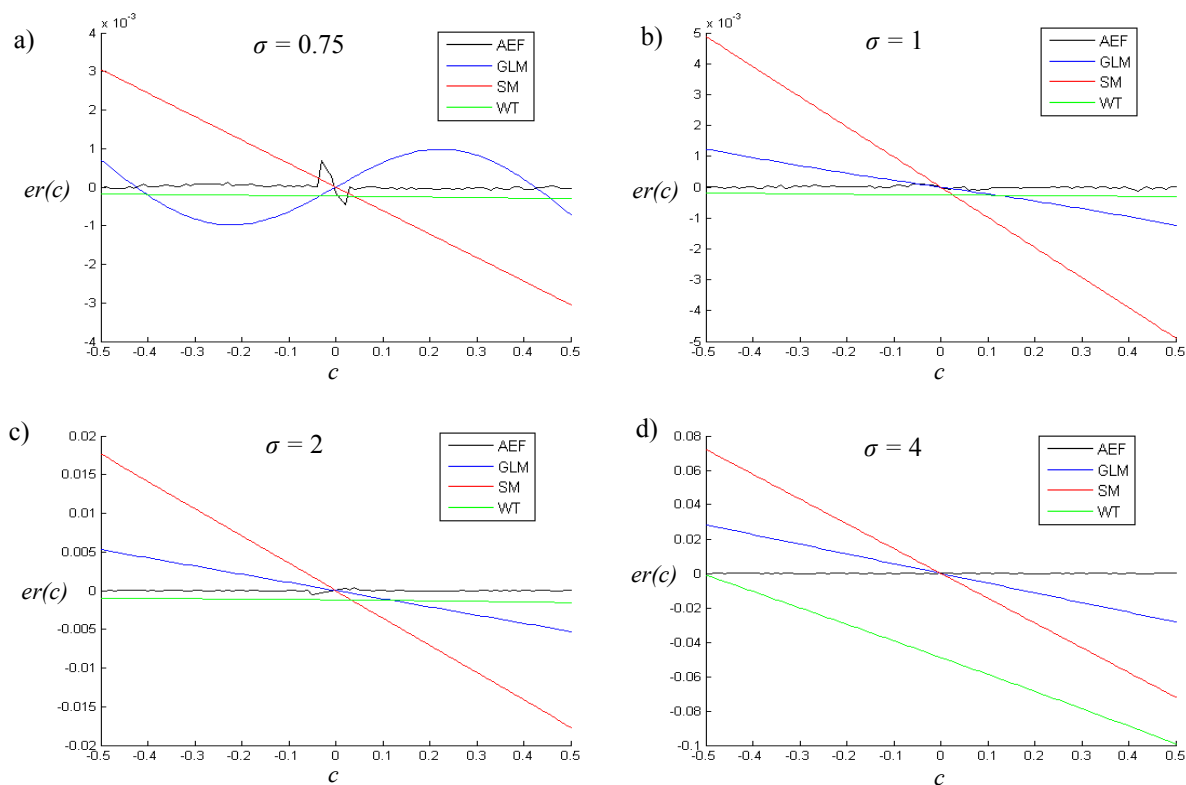
Obr.4: a) vzorky obrazovej funkcie $f_r(i)$. b) funkcia $df_r(i)/df_r(i_{\max})$.

5 VÝSLEDKY SIMULÁCIÍ A EXPERIMENTOV

Vzhľadom na charakter navrhutej metódy prakticky nie je možné matematicky odvodiť jej štatistické vlastnosti, ako napr. rozptyl vypočítaných hodnôt pozície hrany. Preto som zisťoval tieto vlastnosti pomocou simulácie obrazového signálu bez šumu a so šumom. Navrhnutá metóda (AEF) je porovnávaná s tromi najpresnejšími a najčastejšie používanými metódami presnej lokalizácie hrany v 1-D obrazoch: s metódou založenou na momentoch obrazovej funkcie (GLM), metódou využívajúcou priestorové momenty obrazovej funkcie (SM) a metódou založenou na waveletovej transformácii (WT) obrazovej funkcie. Metódy sú porovnávané z hľadiska presnosti, kritériom presnosti je smerodajná odchýlka chyby lokalizácie hrany, pričom som sledoval ako sa tieto kritéria presnosti menia so zmenou parametra rozostrenia hrany σ . Všetky výpočty pri experimentoch a tiež všetky simulácie som vykonával v programe Matlab, verzia 7.3.0.267. Pri simuláciách som uvažoval 1-D senzor so zjednodušeným geometrickým tvarom elementov, pričom svetlo dopadajúce na prvky senzora bolo reprezentované jasovou funkciou, ktorá je konštantná v čase a mení sa spojite len v smere osi x . Pri simuláciách som ako jasovú funkciu $f(x)$ použil model rozostrenej hrany (29).

5.1 Simulácie s nezašumeným signálom

Predpokladajme nezašumený výstupný signál obrazového senzora, pričom hrana sa nachádza na i_h obrazovom prvku senzora. Potom chyba pri výpočte pozície hrany bude závisieť od vzájomnej pozície hrany a stredu i_h obrazového prvku senzora. Označme posun hrany voči stredu i_h obrazového prvku ako c . Ak si zvolíme vzdialenosť stredov dvoch susedných obrazových bodov senzora rovnú 1, bude c nadobúdať hodnoty od -0.5 do 0.5.



Obr.5: Závislosť chyby lokalizácie hrany na posune hrany c voči stredu obrazového bodu.

Na obr.5 sú graficky znázornené závislosti chyby lokalizácie hrany na posune hrany c voči stredú obrazového bodu pre rôzne hodnoty rozostrenia σ získané simuláciou. Posun hrany c voči stredú obrazového bodu môžeme považovať za náhodnú premennú s rovnomerným rozdelením pravdepodobnosti na intervale $(-0.5,0.5)$, pretože nadobúda hodnoty z intervalu $(-0.5,0.5)$ s rovnakou pravdepodobnosťou. Smerodajné odchýlky chyby lokalizácie hrany môžeme vypočítať pomocou funkcie $std(\dots)$, ktorá reprezentuje vzťah

$$std(er) = STD_c(er) = \sqrt{D_c(er)} = \sqrt{\frac{1}{N} \sum_{i=1}^N (er(c_i) - E(er))^2}, \quad (46)$$

kde $D_c(er)$ predstavuje rozptyl (jeho nevychýlený odhad) chyby lokalizácie hrany. Smerodajná odchýlka sa najčastejšie označuje gréckym písmenom σ , ja som sa rozhodol v tejto práci pre označenie STD , pretože písmeno σ používam na označenie parametra hrany (rozostrenie hrany).

V tabuľke tab.1 sú smerodajné odchýlky chyby lokalizácie hrany získané simuláciou pre hodnoty σ : 0.5, 0.75, 1, 2, 3 a 4.

Tab.1: Smerodajná odchýlka chyby lokalizácie hrany STD_c

σ	0,5	0,75	1	2	3	4
AEF	0,0009	0,0001	0,0000	0,0001	0,0001	0,0000
GLM	0,0117	0,0007	0,0007	0,0031	0,0079	0,0165
SM	0,0010	0,0018	0,0028	0,0103	0,0231	0,0420
WT	0,0000	0,0000	0,0000	0,0002	0,0056	0,0286

Obrazová funkcia s rozostrením $\sigma = 0.5$ je veľmi blízka funkcii jednotkového skoku a v reálnych podmienkach sa prakticky nedá dosiahnuť tak ostrý obraz (podľa mojich skúseností). Preto výsledky pre túto hodnotu σ nebudem hodnotiť. Obrazová funkcia s parametrom rozostrenia σ o hodnotách 0.75 a 1 zodpovedá ostrému obrazu, hodnota $\sigma = 2$ je typická pre mierne rozostrený obraz a hodnoty $\sigma = 3$ a $\sigma = 4$ sú charakteristické pre výrazne až veľmi rozostrený obraz.

Smerodajná odchýlka STD_c chyby nám dáva predstavu, ako výrazne sa môže vypočítaná poloha hrany líšiť od skutočnej. Metóda s menšou hodnotou STD_c bude teda presnejšia. Z tohto pohľadu vychádza ako najlepšia navrhovaná metóda AEF, ktorá má prakticky nulovú STD_c pre všetky hodnoty σ . Pri metódach GLM, SM a WT STD_c rastie s rastúcou hodnotou σ . Z vyššie uvedených výsledkov je zrejmé, že pre nezašumený signál je poradie porovnávaných metód z hľadiska presnosti: 1.AEF, 2.GLM, 3.WT, 4.SM.

5.2 Simulácie so zašumeným signálom

Pri simuláciách so zašumeným signálom som bral do úvahy vplyv šumu s normálnym rozdelením pravdepodobnosti, pričom som uvažoval odstup signál-šum s hodnotami $SNR = 36\text{dB}$ a $SNR = 30\text{dB}$. Simulácia pozostávala z dvoch cyklov. V hlavnom cykle sa menilo rozostrenie hrany σ od hodnoty 0.75 po 4.25. Pre každú hodnotu σ sa v rámci ďalšieho cyklu 2000 krát realizoval výpočet vzoriek simulovaného zašumeného výstupu obrazového senzora tak, že sa najprv generoval náhodný posun c pomocou funkcie $rand$

$$c = rand - 0,5. \quad (47)$$

Funkcia *rand* generuje náhodné čísla s rovnomerným rozdelením pravdepodobnosti na intervale (0,1), čiže *c* nadobúdalo náhodné hodnoty s rovnomerným rozdelením pravdepodobnosti na intervale (-0.5,0.5). Vygenerovaná náhodná hodnota posunu *c* sa použila pre výpočet nezašumeného výstupu obrazového senzora, k nezašumeným hodnotám sa potom pripočítali náhodné čísla generované v Matlabe funkciou *randn(...)*. Táto funkcia generuje náhodné čísla s normálnym rozdelením pravdepodobnosti so smerodajnou odchýlkou rovnou 1. Preto sa náhodne generované čísla vynásobili číslom 0.008 pre signál so *SNR* = 36dB, respektíve číslom 0.016 pre signál so *SNR* = 30dB. Pre každú metódu sa vypočítali pozície hrany, chyby lokalizácie hrany a na záver sa vypočítali smerodajnej odchýlky STD_{cn} chyby lokalizácie hrany pre každú hodnotu rozostrenia hrany σ . STD_{cn} sa vypočítala podľa nasledujúceho vzťahu

$$STD_{cn} = \sqrt{\frac{1}{2000} \sum_{i=1}^{2000} (er_i - E_{cn})^2} , \quad (48)$$

kde er_i je chyba lokalizácie hrany pri *i*-tom výpočte a E_{cn} je stredná hodnota chyby vypočítaná ako

$$E_{cn} = \frac{1}{2000} \sum_{i=1}^{2000} er_i . \quad (49)$$

Vypočítané hodnoty STD_{cn} sú v tabuľkách tab.2 a tab.3. Závislosť smerodajnej odchýlky STD_{cn} chyby lokalizácie hrany na rozostrení hrany σ pre štyri porovnávané metódy presnej lokalizácie hrany je na obr.6.

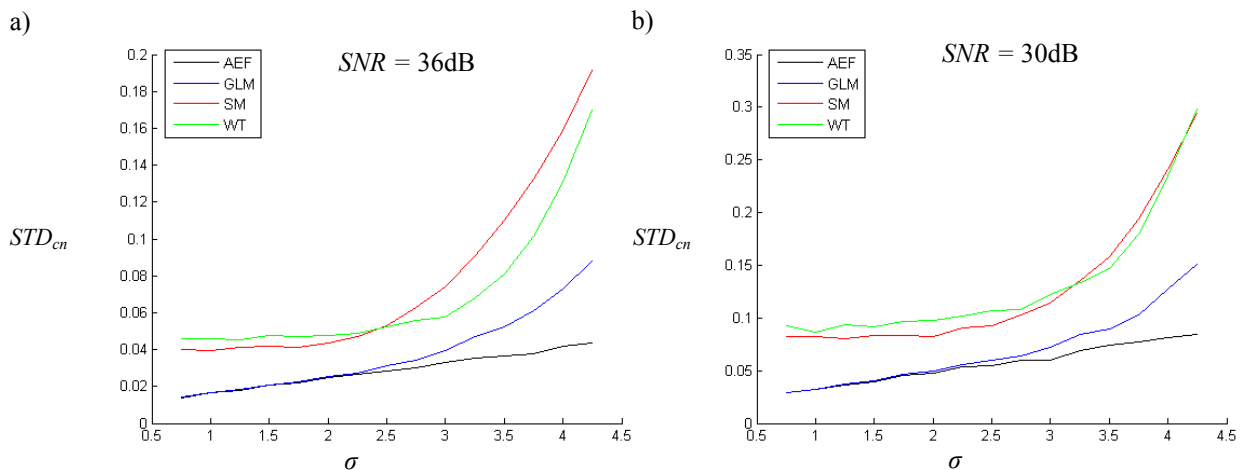
Tab.2. Smerodajné odchýlky STD_{cn} chyby lokalizácie hrany v závislosti na rozostrení hrany σ (*SNR*=36dB)

σ	0,75	1	1,5	2	2,5	3	3,5	4
AEF	0,0139	0,0166	0,0206	0,0246	0,0284	0,0331	0,0364	0,0417
GLM	0,0141	0,0167	0,0208	0,0253	0,0313	0,0396	0,0523	0,0728
SM	0,0399	0,0396	0,0419	0,0435	0,0532	0,0742	0,1103	0,1586
WT	0,0458	0,0456	0,0478	0,0478	0,0525	0,0575	0,0809	0,1305

Tab.3. Smerodajné odchýlky STD_{cn} chyby lokalizácie hrany v závislosti na rozostrení hrany σ (*SNR*=30dB)

σ	0,75	1	1,5	2	2,5	3	3,5	4
AEF	0,0288	0,0319	0,0395	0,0477	0,0543	0,0602	0,0745	0,0818
GLM	0,0295	0,0325	0,0405	0,0495	0,0602	0,0719	0,0897	0,1272
SM	0,0826	0,0822	0,0834	0,0819	0,0922	0,1145	0,1582	0,2410
WT	0,0928	0,0862	0,0917	0,0974	0,1069	0,1224	0,1471	0,2344

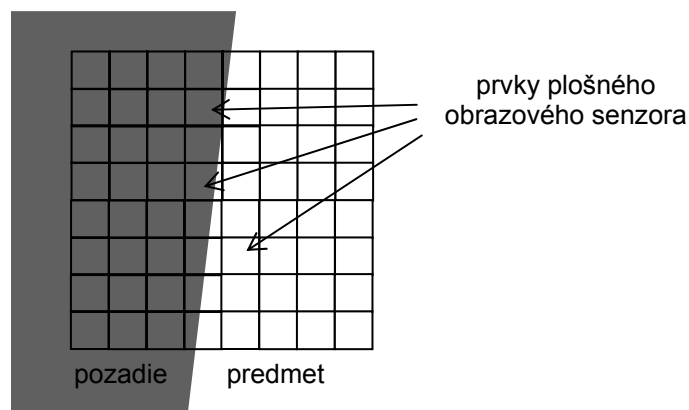
Pre porovnanie metód presnej lokalizácie hrany z hľadiska presnosti určenia pozície hrany je rozhodujúcim parametrom hodnota smerodajnej odchýlky STD_{cn} chyby lokalizácie hrany. Z uvedených výsledkov simulácie reálnych podmienok je zrejmé, že metódy AEF a GLM sú výrazne presnejšie ako SM a WT. Pri vzájomnom porovnaní metód AEF a GLM je možné konštatovať, že sú rovnako presné pre ostrý obraz ($\sigma = 0.75$ a $\sigma = 1$) a tiež pre mierne rozostrený obraz (do $\sigma = 1.75$). Pre obraz výraznejšie ($\sigma = 2 \div 3$) a veľmi rozostrený ($\sigma > 3$) sa javí metóda AEF (navrhnutá v tejto práci) ako najpresnejšia. Toto tvrdenie, založené na simulácií reálnych podmienok, treba potvrdiť aj experimentálne pomocou reálnych obrazov.



Obr.6: Závislosť smerodajnej odchýlky STD_{cn} chyby lokalizácie hrany na rozostrení hrany σ .

5.3 Experimenty

Po viacerých úvahách, akým spôsobom by sa dali experimentálne porovnať jednotlivé metódy presnej lokalizácie hrany, dospel som k návrhu nasledovnej koncepcie experimentu. Predstavme si svetlý predmet na tmavom pozadí (alebo tmavý predmet na svetlom pozadí), ktorý má dokonale rovnú hranu. Keď takýto predmet odfotografujeme, bude obraz hrany predmetu prechádzať cez jednotlivé prvky plošného obrazového snímača podobne, ako je to na obr.7.



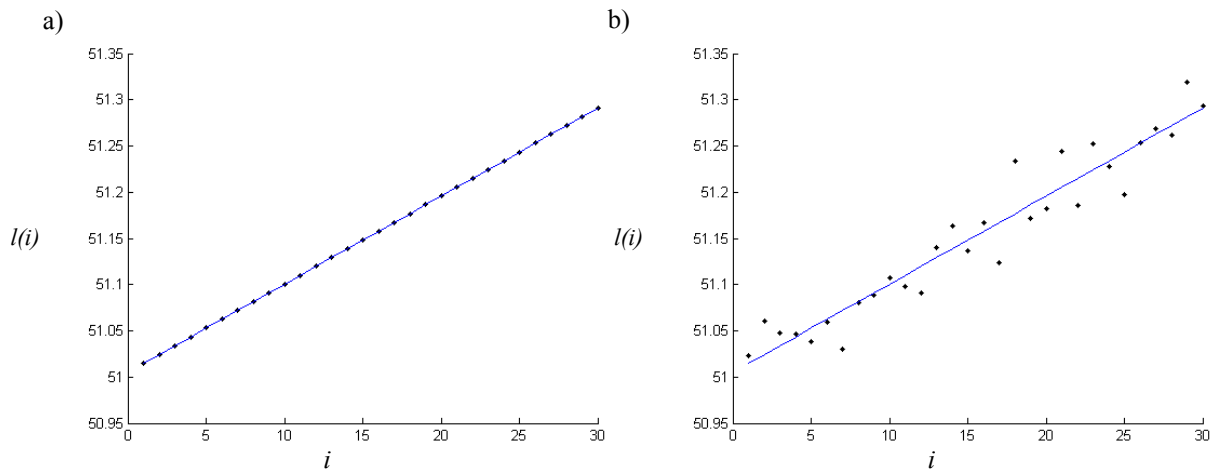
Obr.7: Obraz hrany na plošnom obrazovom snímači.

Ak na každom riadku určíme presnú pozíciu hrany a graficky znázorníme závislosť pozície hrany $l(i)$ na čísle riadku i , mali by body grafu v ideálnom prípade ležať na priamke (pozri obr.8a), ktorej smernicová rovnica bude


$$l(i) = a.i + b, \quad (50)$$

kde a je smernica priamky. To platí, ak je obraz ideálny, bez šumu a použili sme ideálnu metódu na presné určenie pozície hrany. V prípade reálneho obrazu a reálnej metódy presnej lokalizácie hrany, budú body v grafe rozptýlené okolo priamky (pozri obr.8b), ktorej parametre a a b sa dajú vypočítať pomocou metódy najmenších štvorcov.

Ako predmet pre experimenty som zvolil ventil do spaľovacieho motora (obr.9a), ktorý je dokonale rovný, súosý a jeho povrch je dokonale hladký. Ventil bol fotený zo vzdialenosti približne 75 cm fotoaparátom Nikon D300 s rozlíšením 12 miliónov obrazových bodov.

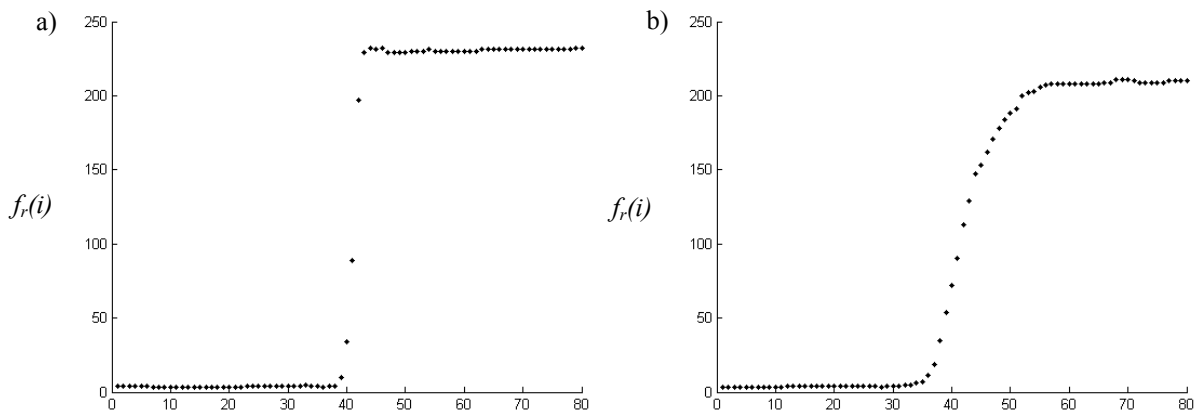


Obr.8: Závislosť presnej pozície hrany na čísle riadku plošného obrazového senzora.
 a) ideálny prípad b) reálny prípad



Obr.9: a) predmet pre experimenty, b) c) d) – obrázky pre experimenty.

Experimenty som robil pomocou šiestich obrázkov (tri z nich sú na obr.9), *test1.tif* a *test2.tif* reprezentujú zaostrény obraz, *test3.tif* a *test4.tif* mierne rozostrený obraz, *test5.tif* a *test6.tif* výrazne rozostrený obraz. Pre ilustráciu sú na obr.10 graficky znázornené hodnoty jasu $f_r(i)$ (8-bitový formát) v rámci jedného riadku (približne zo stredu obrazu) testovacích obrázkov *test1.tif* a *test6.tif*.



Obr.10: Hodnoty jasu $f_r(i)$ jedného riadku – a) *test1.tif*, b) *test6.tif*

Pre každý riadok testovacieho obrázku sa vypočíta diferenčná funkcia $df_r(i)$, nájde sa jej maximum a urobí sa odhad počiatkovej hodnoty l_0 pozície hrany (pozri kap.4.1). Nájdu sa (pozri kap.4.2) odhady počiatkových hodnôt rozostrenia hrany σ_0 (43), jas napravo od hrany l_{l_0} ($= h_0$) – jas predmetu, jas napravo od hrany l_{r_0} ($= h_0 + k_0$) – jas pozadia. Hodnoty h_0 a k_0 sa určia podľa (44) a (45). 31 vzoriek z okolia odhadnutej pozície hrany sa použije na výpočet presnej pozície hrany

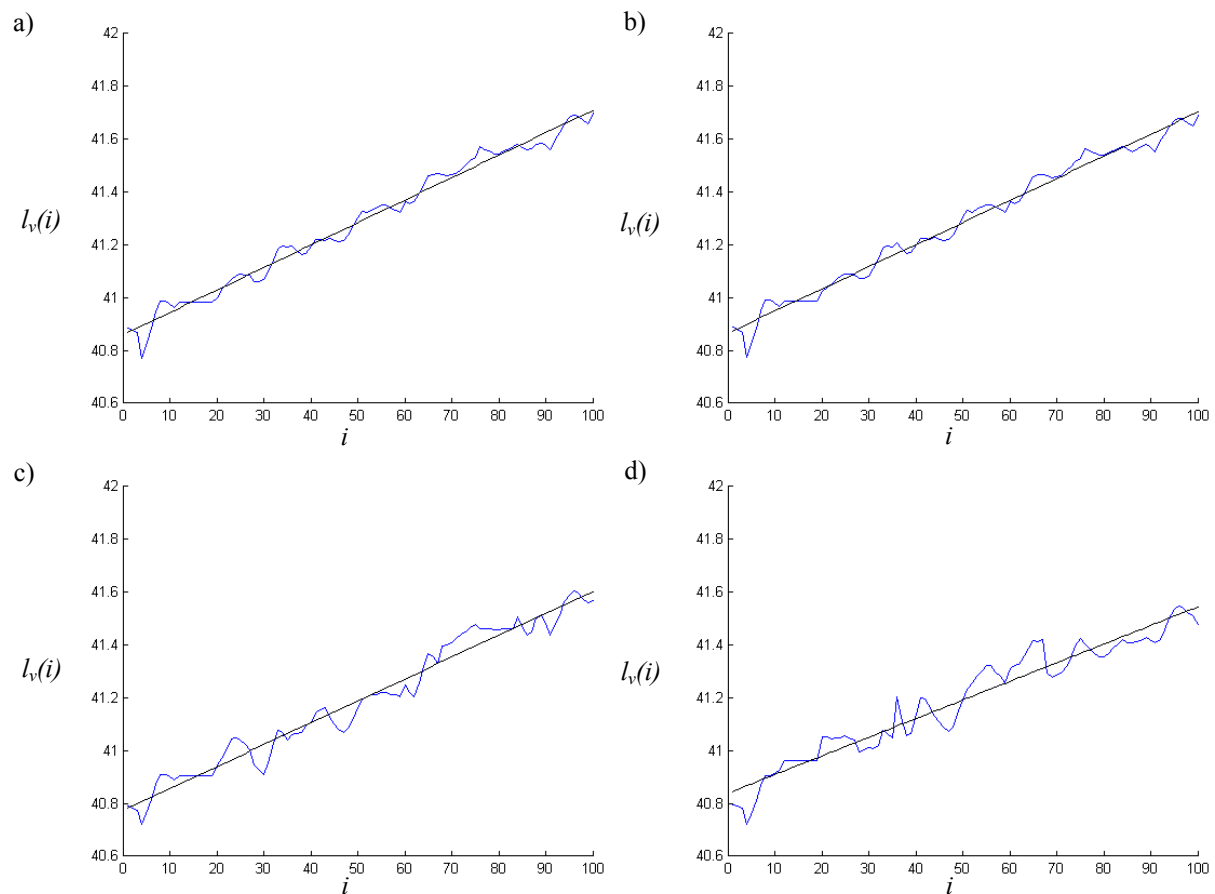
$l_v(i)$ pomocou metód AEF, GLM, SM a WT. Zvolil som hodnotu 31, pretože sa domnievam, že 31 vzoriek pri všetkých použitých testovacích obrázkoch zahŕňa nielen celú oblasť hrany (prechod z nízkych hodnôt jasu do vysokých) ale aj body s už ustáleným jasom.

V tabuľke tab.4 sú stredné hodnoty počiatkových hodnôt σ_0 , Il_0 , Ir_0 parametrov aproximačnej funkcie $f_a(x)$ pred optimalizáciou a stredné hodnoty σ_s , Il_s , Ir_s po optimalizácii pre všetky testovacie obrázky (pri metóde AEF). Z uvedených hodnôt je vidno, že počiatkové odhady sa nelíšia výrazne od hodnôt po optimalizácii. To potvrdzuje správnosť navrhnutého spôsobu odhadu počiatkových parametrov, ktorý je uvedený v kap.4.1 a kap.4.2.

Tab.4. Stredné hodnoty σ_0 , Il_0 , Ir_0 parametrov aproximačnej funkcie $f_a(x)$ pred optimalizáciou a stredné hodnoty σ_s , Il_s , Ir_s po optimalizácii

	<i>test1.tif</i>	<i>test2.tif</i>	<i>test3.tif</i>	<i>test4.tif</i>	<i>test5.tif</i>	<i>test6.tif</i>
σ_0	0,925	1,120	1,550	2,303	3,185	4,422
σ_s	0,840	0,947	1,543	2,175	3,253	4,251
Il_0	0,028	0,018	0,020	0,019	0,024	0,027
Il_s	0,019	0,017	0,012	0,011	0,008	0,007
Ir_0	0,892	0,872	0,795	0,825	0,843	0,790
Ir_s	0,904	0,892	0,816	0,829	0,848	0,778

Na obr.11 sú zobrazené vypočítané pozície hrany $l_v(i)$ pre jednotlivé riadky testovacieho obrázku *test1.tif* a regresná priamka.

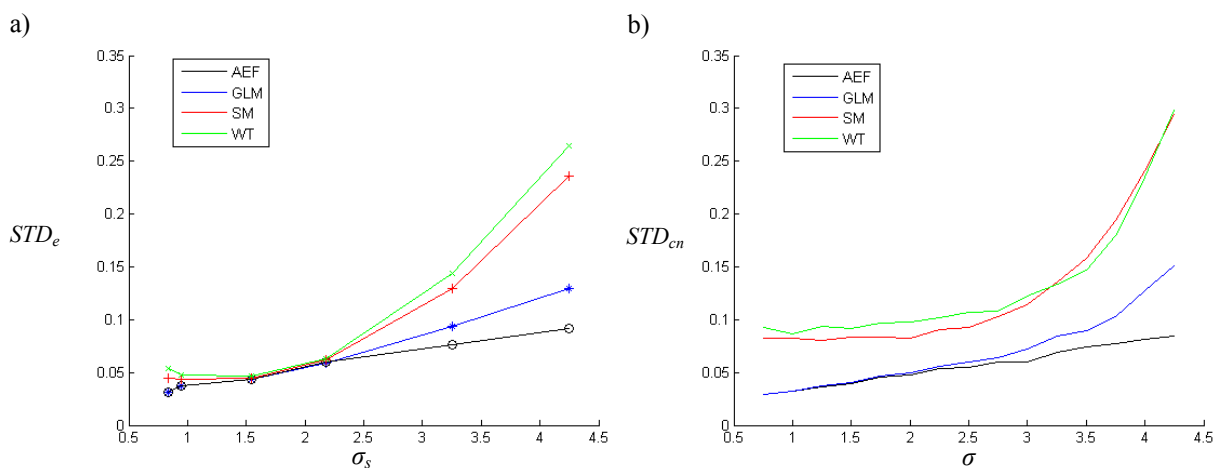


Obr.11: Pozície hrany $l_v(i)$ pre jednotlivé riadky obrázku *test1.tif* a regresná priamka
a) AEF b) GLM c) SM d) WT

V tabuľke tab.5 sú uvedené hodnoty smerodajných odchýliek STD_e chyby lokalizácie hrany pre všetky porovnávané metódy a pre všetky testovacie obrázky. V tabuľke tiež uvádzam vypočítaný parameter rozostrenia hrany σ_s , aby bol zrejмый vzťah medzi rozostrením hrany a veľkosťou smerodajnej odchýlky STD_e . Výsledky sú graficky interpretované na obr.12a.

Tab.5. Smerodajná odchýlka STD_e chyby lokalizácie hrany

	<i>test1.tif</i>	<i>test2.tif</i>	<i>test3.tif</i>	<i>test4.tif</i>	<i>test5.tif</i>	<i>test6.tif</i>
σ_s	0,840	0,947	1,543	2,175	3,253	4,251
AEF	0,031	0,037	0,043	0,060	0,075	0,092
GLM	0,031	0,037	0,043	0,059	0,094	0,129
SM	0,045	0,044	0,045	0,062	0,129	0,236
WT	0,054	0,048	0,047	0,063	0,144	0,265



Obr.12: a) Závislosť smerodajnej odchýlky STD_e na rozostrení hrany σ_s (experiment)
 b) Závislosť smerodajnej odchýlky STD_{cn} na rozostrení hrany σ (simulácia)

Pre porovnanie výsledkov experimentov a simulácií uvádzam na obr.12b závislosť smerodajnej odchýlky STD_{cn} chyby lokalizácie hrany na rozostrení hrany σ pri simulácii s náhodným posunom hrany c voči stredu obrazového bodu a so zašumeným signálom so $SNR=30\text{dB}$ (pozri obr.6b). Pri metódach AEF a GLM som v rámci experimentov dospel k podobným výsledkom ako pri simulácii, pri metódach SM a WT boli hodnoty získané z experimentov lepšie ako poskytli simulácie pre rozostrenie hrany $\sigma < 2.5$. Pre väčšie hodnoty rozostrenia hrany boli výsledky experimentov a simulácií viac-menej rovnaké aj pri týchto metódach.

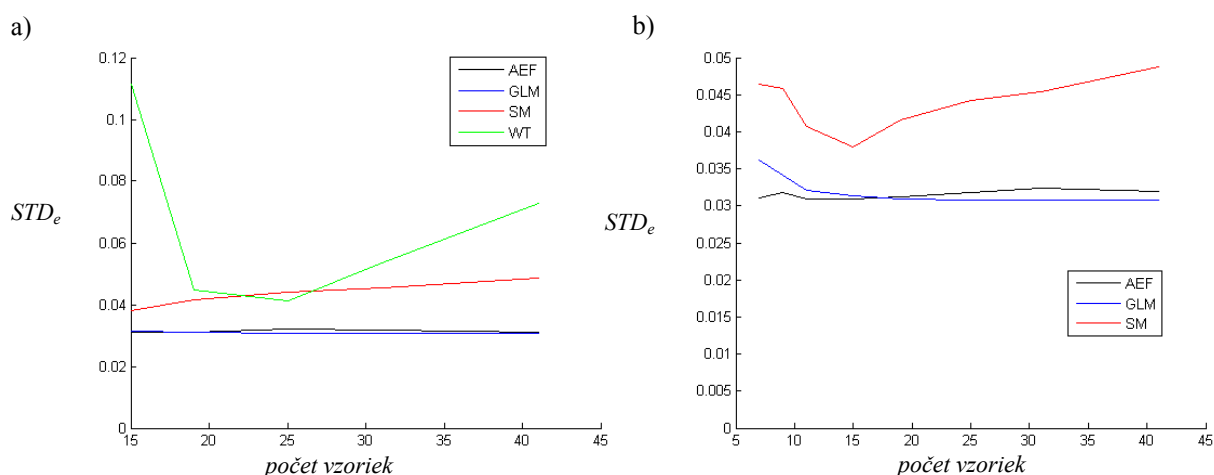
Na základe výsledkov prezentovaných v tab.5 a na obr.12a je možné tiež konštatovať, že pre zvolený počet 31 vzoriek použitých pri výpočte presnej pozície hrany, sú pri ostrom obraze ($\sigma < 1$) najpresnejšie metódy AEF a GLM, majú prakticky rovnaké výsledky. Pri mierne rozostrenom obraze ($1 \leq \sigma < 2.5$) sú všetky štyri metódy rovnocenné a pri výrazne rozostrenom obraze ($2.5 \leq \sigma$) je najpresnejšia navrhnutá metóda AEF, potom GLM a najmenej presné sú SM a WT.

V predchádzajúcich experimentoch som pri výpočte používal 31 vzoriek z okolia odhadovanej pozície hrany. Tento počet som považoval za postačujúci pre presný výpočet pozície hrany. Niekedy by však väčší počet vzoriek mohol zlepšiť (ale aj zhoršiť) výsledky. Na druhej

strane sa môže vyskytnúť situácia, kedy nie je toľko vzoriek k dispozícii, napríklad keď detegujeme hrany pruhov, ktoré sú blízko seba. Rozhodol som sa preto pomocou testovacích obrázkov zistiť závislosť veľkosti smerodajnej odchýlky STD_e chyby lokalizácie hrany od použitého počtu vzoriek pri výpočte presnej pozície hrany. Výsledky výpočtov pre testovacie obrázky s rôznym rozostrením hrany sú v tab.6 až tab.10 a na obr.13 až obr.15. Testovací obrázok test2.tif som pri tomto experimente vynechal, keďže je svojim charakterom blízky obrázku test1.tif, obidva reprezentujú zaostrený obraz a majú skoro rovnaký parameter rozostrenia hrany σ_s .

Tab.6. Závislosť STD_e od počtu použitých vzoriek pre *test1.tif* ($\sigma_s=0.84$)

počet vzoriek	7	9	11	15	19	25	31	41
AEF	0,031	0,032	0,031	0,031	0,031	0,032	0,032	0,031
GLM	0,036	0,034	0,032	0,031	0,031	0,031	0,031	0,031
SM	0,046	0,046	0,041	0,038	0,042	0,044	0,045	0,049
WT	-	-	-	0,112	0,045	0,041	0,054	0,073



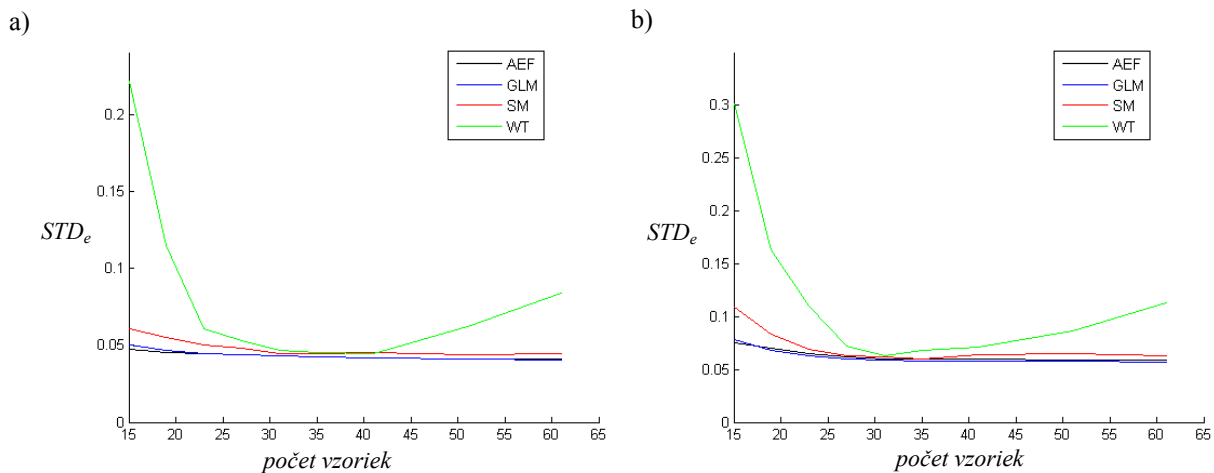
Obr.13: a) Závislosť STD_e od počtu použitých vzoriek pre *test1.tif* ($\sigma_s = 0.84$)
b) Detail bez uvažovania metódy WT

Tab.7. Závislosť STD_e od počtu použitých vzoriek pre *test3.tif* ($\sigma_s=1.54$)

počet vzoriek	9	11	15	19	23	27	31	35	41	51	61
AEF	0,077	0,057	0,047	0,045	0,044	0,044	0,043	0,042	0,042	0,041	0,041
GLM	0,091	0,067	0,050	0,047	0,045	0,044	0,043	0,042	0,042	0,041	0,041
SM	0,122	0,091	0,061	0,055	0,050	0,048	0,045	0,045	0,045	0,044	0,045
WT	-	-	0,223	0,115	0,061	0,053	0,047	0,045	0,045	0,062	0,084

Tab.8. Závislosť STD_e od počtu použitých vzoriek pre *test4.tif* ($\sigma_s=2.18$)

počet vzoriek	11	15	19	23	27	31	35	41	51	61
AEF	0,095	0,075	0,070	0,065	0,062	0,060	0,060	0,060	0,059	0,059
GLM	0,115	0,078	0,068	0,063	0,060	0,059	0,058	0,058	0,058	0,057
SM	0,154	0,110	0,084	0,069	0,063	0,062	0,060	0,064	0,065	0,063
WT	-	0,304	0,164	0,110	0,072	0,063	0,068	0,071	0,087	0,114



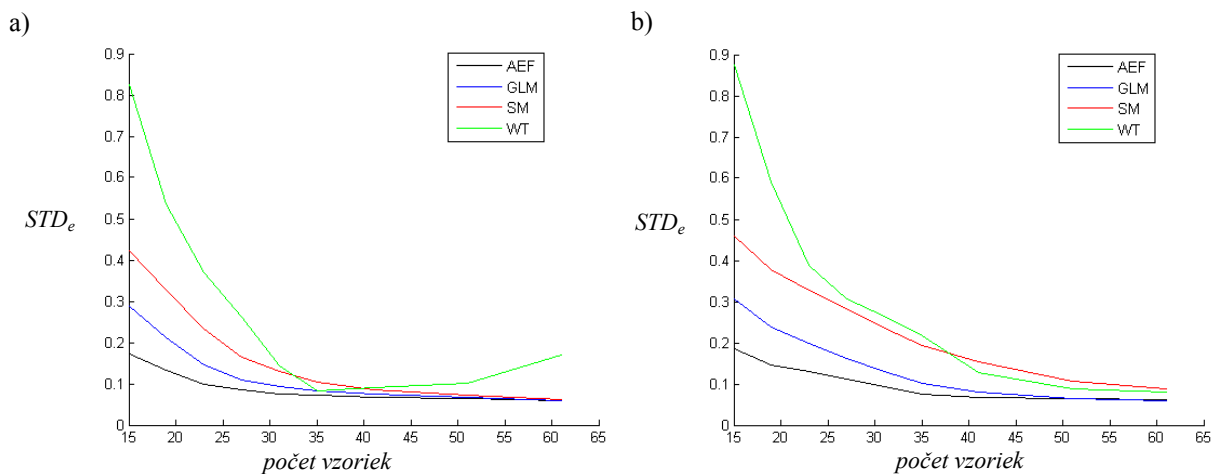
Obr.14: a) Závislosť STD_e od počtu použitých vzoriek pre *test3.tif* ($\sigma_s = 1.54$)
 b) Závislosť STD_e od počtu použitých vzoriek pre *test4.tif* ($\sigma_s = 2.18$)

Tab.9. Závislosť STD_e od počtu použitých vzoriek pre *test5.tif* ($\sigma_s=3.25$)

počet vzoriek	15	19	23	27	31	35	41	51	61
AEF	0,172	0,133	0,098	0,085	0,076	0,073	0,067	0,065	0,058
GLM	0,290	0,212	0,146	0,110	0,094	0,083	0,074	0,066	0,059
SM	0,423	0,328	0,233	0,165	0,129	0,104	0,085	0,073	0,061
WT	0,829	0,535	0,371	0,262	0,144	0,084	0,090	0,101	0,170

Tab.10. Závislosť STD_e od počtu použitých vzoriek pre *test6.tif* ($\sigma_s=4.25$)

počet vzoriek	15	19	23	27	31	35	41	51	61
AEF	0,186	0,147	0,130	0,111	0,092	0,075	0,067	0,063	0,061
GLM	0,309	0,239	0,198	0,162	0,129	0,102	0,081	0,065	0,060
SM	0,460	0,377	0,327	0,283	0,236	0,195	0,154	0,108	0,089
WT	0,879	0,592	0,388	0,306	0,265	0,218	0,129	0,087	0,080



Obr.15: a) Závislosť STD_e od počtu použitých vzoriek pre *test5.tif* ($\sigma_s = 3.25$)
 b) Závislosť STD_e od počtu použitých vzoriek pre *test6.tif* ($\sigma_s = 4.25$)

6 ZÁVER – VYHODNOTENIE A PRÍNOSY DIZERTAČNEJ PRÁCE

V tejto práci je predstavená nová metóda detekcie hrán so zvýšenou presnosťou pre 1-D obrázky založená na aproximácii obrazu v okolí hrany vhodnou aproximačnou funkciou (modelom hrany). Hľadaná presná pozícia hrany je vlastne jedným z parametrov aproximačnej funkcie, ktoré sa získajú minimalizovaním účelovej funkcie. Hlavnou výhodou tejto metódy v porovnaní s doteraz používanými metódami je jej väčšia presnosť v prípade rozostreného obrazu.

Za základ aproximačnej funkcie som zvolil erf funkciu. Ďalej som navrhol účelovú funkciu a tiež spôsob odhadu počiatočných hodnôt parametrov aproximačnej funkcie, ktoré sú potrebné pri iteračnej metóde hľadania minima účelovej funkcie. Experimenty potvrdili, že odhady počiatočných hodnôt parametrov vypočítané navrhnutým postupom sa výrazne nelíšia od výsledných hodnôt parametrov aproximačnej funkcie po ukončení optimalizácie.

V rámci svojej dizertačnej práce som pomocou simulácií a experimentov porovnal navrhnutú metódu presnej lokalizácie hrany založenú na aproximácii hrany erf funkciou (AEF) s metódou založenou na momentoch obrazovej funkcie (GLM), metódou využívajúcou priestorové momenty obrazovej funkcie (SM) a metódou založenou na waveletovej transformácii obrazovej funkcie (WT). Metódy som porovnával z hľadiska presnosti, pričom som ako kritérium presnosti uvažoval smerodajnú odchýlku chyby lokalizácie hrany. Pri porovnávaní som hlavne sledoval, ako sa mení smerodajná odchýlka chyby lokalizácie hrany so zmenou parametra rozostrenia hrany σ a ako je ovplyvnená počtom vzoriek použitých pri výpočte presnej pozície hrany. Na základe výsledkov simulácií a hlavne experimentov je možné konštatovať, že WT je z porovnávaných metód najmenej vhodná na presnú lokalizáciu hrany. Je vždy nepresnejšia ako AEF a GLM a len za určitých okolností je o trochu presnejšia ako SM. Pre zaostrý obraz (rozostrenie hrany $\sigma < 1$) sa ako najpresnejšia javí metóda GLM, má najmenšiu smerodajnú odchýlku chyby lokalizácie hrany. Takmer rovnaké výsledky dosahuje AEF, no vyžaduje podstatne väčší čas výpočtu. SM je výrazne nepresnejšia, pričom sa jej presnosť zhoršuje s rastúcim počtom vzoriek. Pre mierne rozostrený obraz ($1 \leq \sigma < 2.5$) je presnosť AEF, GLM a SM približne rovnaká, ak sa použije dostatočný počet vzoriek. Pri SM je potrebných o niečo viac vzoriek (asi 1.5-násobok) pre presnú lokalizáciu hrany ako pri AEF a GLM. Pre výrazne rozostrený obraz ($2.5 \leq \sigma$) je najpresnejšia metóda AEF. S rastúcim počtom vzoriek sa k nej svojou presnosťou blížia GLM a SM.

Prínosy tejto dizertačnej práce sa dajú zhrnúť do nasledovných bodov:

- a) Bola navrhnutá a verifikovaná nová metóda detekcie hrán so zvýšenou presnosťou pre 1-D obrázky, ktorá je v prípade nezaostreného obrazu presnejšia ako metódy doteraz používané.
- b) Bol navrhnutý a verifikovaný spôsob odhadu parametrov modelu rozostrenej hrany. Tieto odhady sa používajú v rámci navrhutej metódy presnej lokalizácie hrany ako počiatočné hodnoty parametrov aproximačnej funkcie, ktoré sú potrebné pri iteračnej metóde hľadania minima účelovej funkcie aproximačnej funkcie. Okrem toho, odhad rozostrenia hrany σ môže slúžiť na určenie počtu vzoriek potrebných pre presný výpočet pozície hrany aj pri iných metódach presnej lokalizácie hrany.
- c) Pomocou simulácií a experimentov boli analyzované možnosti presnej lokalizácie hrany v nezaostrených obrazoch. Pokiaľ mi je známe, problematika detekcie hrán so zvýšenou presnosťou v nezaostrených obrazoch nebola dosiaľ nikde publikovaná.

V budúcnosti by bolo vhodné pracovať na možnosti využiť navrhnutú metódu presnej lokalizácie hrany na selektívnu detekciu hrán. To znamená, že v obraze by sa hľadala presná pozícia len tých hrán, ktoré by svojimi parametrami (jas pozadia, zmenu jasu a rozostrenie) spĺňali definované podmienky.

Literatúra

- [1] Nalwa, V.S.: Edge-Detector Resolution Improvement by Image Interpolation. IEEE Transactions on Pattern Analysis Machine Intelligence, Vol.9, No.3, 1987, pp.446-451.
- [2] Tabatabai, A.J. - Mitchell, O.R.: Edge location to subpixel values in digital imagery. IEEE Transactions on Pattern Analysis Machine Intelligence, Vol.6, No. 2, 1984, pp. 188-201.
- [3] Lyvers, E.P. - Mitchell, O.R. - Akey, M.L. - Reeves, A.P.: Subpixel measurements using a moment-based edge operator. IEEE Transactions on Pattern Analysis Machine Intelligence, Vol.11, No.12, 1989, pp.1293-1309.
- [4] Kisworo, M. - Venkatesh, S. - West, G.: Modeling edges at subpixel accuracy using the local energy approach. IEEE Transactions on Pattern Analysis Machine Intelligence, Vol.16, No.4, 1994, pp.405-410
- [5] Xu, G.S.: Study on a Fast Method for Sub-Pixel Edge Detection. Proceedings of Third International Conference on Information and Computing, Wuxi, China, June 4-6, 2010, pp.141-144.
- [6] Baba, M. - Ohtani, K.: A novel subpixel edge detection system for dimension measurement and object localization using an analogue-based approach. Journal of Optics A: Pure and Applied Optics, Vol.3, 2001, pp.276-283.
- [7] Hussmann, S. - Ho, T. H.: A high-speed subpixel edge detector implementation inside a FPGA. Real-Time Imaging, Vol.9, No.5, 2003, pp.361-368.
- [8] Da, F. - Zhang, H.: Sub-pixel edge detection based on an improved moment. Image and Vision Computing, vol. 28 , no. 12, 2010, pp. 1645-1658.
- [9] Ghosal, S. - Mehrotra, R.: Orthogonal moment operators for subpixel edge detection. Pattern Recognition, vol. 26, no. 2, 1993, pp. 295-306.
- [10] Li, J.Q. - Wang, J.W. - Chen, S.B. - Wu, L.: Improved algorithm of subpixel edge detection using Zernike orthogonal moments. Optical Technique, 2003, vol. 29, no. 4, pp.500-504.
- [11] Qu, Y.D. - Cui, Ch.S. - Chen, S.B. - Li, J.Q.: A fast subpixel edge detection method using Sobel-Zernike moments operator. Image and Vision Computing, vol. 23, no. 1, 2005, pp.11-17.
- [12] Zheng, X.P. - Bi, Y.W.: Improved Algorithm about Subpixel Edge Detection Based on Zernike Moments and Three-Grayscale Pattern. Proceedings of the 2nd International Congress on Image and Signal Processing CISP '09, Tianjin, China, 17-19 October, 2009, pp.1-4.
- [13] Zhang, B. - Bai, L. - Zeng, X.: A novel subpixel edge detection based on the Zernike moment. Information Technology Journal, vol. 9, no. 1, 2010, pp.41-47.
- [14] Bin, T.J. - Lei, A. - Cui, J.W. - Kang, W.J. - Liu, D.D.: Subpixel edge location based on orthogonal Fourier-Mellin moments. Image and Vision Computing, vol. 26, no. 9, 2008, pp.563-569.
- [15] Hu, Z.F. - Dang, H.S. - Li, X.R.: A novel fast subpixel edge location method based on Sobel-OFMM. Proceedings of the IEEE International Conference on Automation and Logistics, Qingdao, China, 1-3 September, 2008, pp. 828–832.
- [16] Zeng, T. - Shi, G. - Zheng, H. - Wang, Z.: Fast subpixel edge extraction based on two Fourier-Mellin moments with different mask sizes. Proceedings of the International Conference on Consumer Electronics, Communications and Networks, XianNing, China, 16-18 April, 2011, pp.1293-1296.
- [17] Vanko, M. Detekcia hrán so zvýšenou presnosťou v jednorozmerných obrazoch. Bratislava : FEI STU, 2008. 24 s. Bakalárska práca.
- [18] Weisstein, E.W. Erf. [Online] citované dňa 21.2.2011. Dostupné na: <http://mathworld.wolfram.com/Erf.html>

Zoznam vlastných publikácií

Vedecké práce v zahraničných nekarentovaných časopisoch:

- [23] HAGARA, M., KULLA, P.: Edge Detection with Sub-pixel Accuracy Based on Approximation of Edge with Erf Function. Radioengineering, vol.20, no.2, 2011, pp.516-524.

Vedecké práce v domácich nekarentovaných časopisoch:

- [1] KULLA, P., ŠEVČÍK, P., HAGARA, M., et al.: Systém automatizovaného snímania a spracovania obrazovej informácie. Slaboproudý obzor, roč.49, č.7, SNTL, Praha, 1988, s.341-346.
- [12] HAGARA, M., CHMÚRNÝ, J., ŽIDEK, F., MAGDOLEN, J. : Biosignal Processing with Wavelets. In: Journal of Electrical Engineering, vol.47, 1996, n.3-4, pp. 67-73.
- [14] KULLA, P., ŠEVČÍK, P., HAGARA, M. et al.: Technické a programové prostriedky pre vybrané metódy číslicového spracovania optickej informácie. Sensor, roč.4, 1997, č.4, s.1-6.
- [21] HAGARA, M., KULLA, P.: Slow Motion Detection Based on Edge Shift. EE časopis pre elektrotechniku a energetiku, roč. 16, mimoriadne číslo, 2010, s. 67-70.
- [22] HAGARA, M., KULLA, P.: Detekcia hrán v obrazoch. EE časopis pre elektrotechniku a energetiku, roč. 16, mimoriadne číslo, 2010, s. 71-75.
- [23] HAGARA, M., KULLA, P.: Edge Detection with Sub-pixel Accuracy Based on Approximation of Edge with Erf Function. Radioengineering, vol.20, no.2, 2011, pp.516-524.
- [24] HAGARA, M., KULLA, P.: Detekcia hrán so zvýšenou presnosťou. EE časopis pre elektrotechniku a energetiku, roč. 17, mimoriadne číslo, 2011, s. 60-64.

Publikované príspevky na zahraničných vedeckých konferenciách:

- [15] KULLA, P., HAGARA, M. : The Digital Image Processing in Education at Radio and Electronics Department. Conference Proceedings of Radioelektronika '98. Brno : TU, 1998, pp. 466-469.

Publikované príspevky na domácich vedeckých konferenciách:

- [2] KULLA, P., ŠEVČÍK, P., HAGARA, M., KOTEREC, M., ŠIMKOVIČ, I.: Senzorický vizuálny systém. Zborník z celoštátneho seminára "Uplatnenie umelej inteligencie v robotike", DT ČSVTS, Košice, jún 1988, s. 83-87.
- [3] KULLA, P., ŠEVČÍK, P., HAGARA, M., KOTEREC, M.: Systém automatizovaného snímania a spracovania jednorozmerných obrazov. Zborník z Medzinárodnej konferencie POČÍTAČOVÁ GRAFIKA, JSMF, Smolenice, máj 1989.
- [4] KULLA, P., ŠEVČÍK, P., HAGARA, M., KOTEREC, M.: Systém pre digitálne snímanie a spracovanie jednorozmerných obrazov. Zborník prednášok z celoštátnej konferencie "Senzory a senzorové systémy", DT ČSVTS, Košice, Štrbské Pleso, máj 1989, s.241-245.
- [5] KULLA, P., ŠEVČÍK, P., HAGARA, M., KOTEREC, M.: Technické a programové prostriedky zariadenia pre digitálne snímanie a spracovanie obrazovej informácie. Zborník prednášok z 5. vedeckej konferencie EF VŠT, Košice, aug.1989, s.25-29.
- [6] KULLA, P., ŠEVČÍK, P., HAGARA, M., KOTEREC, M.: Architektúra a programové vybavenie systému pre digitálne snímanie a spracovanie 1D obrazov. Zborník prác z 3. vedeckej konferencie EF SVŠT so zahr. účasťou, Bratislava, jan. 1990, str.123-128
- [7] KULLA, P., ŠEVČÍK, P., HAGARA, M. et al.: Architektúra a programové vybavenie systému pre bezkontaktné meranie pričného rozmeru objektov a ich automatizované triedenie. Zborník prác z 3. vedeckej konferencie EF SVŠT so zahr. účasťou, Bratislava, jan. 1990, s.129-136

- [8] KULLA, P., ŠEVČÍK, P., HAGARA, M., et al.: Technické a programové prostriedky pre spracovanie jednorozmerných obrazov. Zborník prác z celošt. seminára "Nové smery v spracovaní signálov", VVŠT v Lipt. Mikuláši, Račkova dolina, máj 1990, s.97-100.
- [9] KULLA, P., ŠEVČÍK, P., HAGARA, M., LEHOTSKÝ, E.: Vplyv zmeny intenzity osvetlenia pozadia na presnosť merania pričného rozmeru objektov. Zborník prednášok celoštátneho seminára " Senzory pre automatizáciu '90", Košice, okt. 1990, str.79-92
- [10] KULLA, P., ŠEVČÍK, P., HAGARA, M., KOTEREC, M. : Možnosť číslicovej korekcie lineárneho amplitúdového skreslenia obrazového signálu riadkového senzora CCD. Zborník z konferencie „Číslicové spracovanie signálov 92“. Košice : EF TU, 1992, s.70-74.
- [11] HAGARA, M. : Multiscale edge detection based on Wavelets. Proceeding of International Conference on Digital Signal Processing 93. Kosice : Fac.of Electrical Eng.of Technical University, 1993, pp. 218-221.
- [13] HAGARA, M., VIDA, R. : Edge Detection Using the Three Module Strategy in Edge Pyramids. Conference Proceedings of Radioelektronika `97. Bratislava : STU, 1997, pp. 212-215.
- [16] HAGARA, M., COUDERT, F., BENOIS-PINEAU, J. : Scene Changes Detection in Video Sequences. Conference Proceedings of Radioelektronika 2000. Bratislava : FEI STU, 2000, pp.80-81.
- [17] HAGARA, M., MORAVČÍK, J. : PLUS Operator for Edge Detection in Digital Images. Conference Proceedings of Radioelektronika 2002. Bratislava : FEI STU, 2002, pp.467-470.
- [18] HAGARA, M.: Edge parameters determination with wavelets. Conference Proceedings of Radioelektronika 2006. Bratislava : FEI STU, 2006, pp.145-148.
- [19] HAGARA, M.: Sub-pixel edge detection with wavelets. Conference Proceedings of Radioelektronika 2006. Bratislava : FEI STU, 2006, pp.353-356.
- [20] HAGARA, M., HLAVATOVIČ, A.: Video Segmentation Based on Pratt's Figure of Merit. Proceeding of 19th International Scientific Conference "Radioelektronika '2009", April 22-23, 2009, Bratislava, Slovak Republic, pp.91-94.

SUMMARY

A new method for edge detection with sub-pixel accuracy in 1-D images is presented in this work. This method is worked on the approximation of the image around the edge with appropriate approximation function based on erf function.

The core of the work is the proposal of a new edge detection method with sub-pixel accuracy. The exact position of the edge is represented by one of the final parameters of approximation function, which are obtained by minimizing the objective function. An important part of the new method proposal is an estimation of the initial parameter values of approximation function that are necessary for finding minimum of objective function with some suitable iterative method.

The proposed method is through the simulations and experiments compared with the three most precise and the most commonly used methods of sub-pixel edge localization in the 1-D images: moment-based edge operator, technique using spatial moments of the image function and the method based on wavelet transform of image. The methods are compared in terms of accuracy, the standard deviation of the edge localization error is chosen as precision criterion. There is one important result of simulations and experiments, relationship between values of standard deviation of edge localization error and blurring parameter σ of the edge model. Second important conclusion is that the number of samples required to calculate sub-pixel edge position depends on blurring parameter σ . The main advantage of the method proposed in this work is the higher accuracy in the case of blurred images.

