

Ľudmila Maceková  
Stanislav Marchevský

**Vybrané problémy číslicovej filtrácie  
poškodených obrazových sekvencií  
a vyhodnocovania ich kvality**

TECHNICKÁ UNIVERZITA v KOŠICIACH



Ľudmila Maceková  
Stanislav Marchevský

**Vybrané problémy číslicovej filtrácie  
poškodených obrazových sekvencií  
a vyhodnocovania ich kvality**

recenzenti: prof. Ing. Dušan Repčík, PhD.  
doc . Ing. Václav Moucha, CSc.

Neprešlo jazykovou úpravou.

© 2013, Ing. Ľudmila Maceková, PhD., prof. Ing. Stanislav Marchevský, CSc.

Vydanie prvé  
Náklad: 100 ks.  
Rozsah: 90 strán

ISBN: 978-80-553-1449-5

## OBSAH

<b>ZOZNAM SKRATIEK A SYMBOLOV .....</b>	<b>6</b>
<b>ÚVOD.....</b>	<b>8</b>
<b>1 MODEL OBRAZU A OBRAZOVEJ SEKVENCIE .....</b>	<b>10</b>
1.1 Vyjadrenie farby a farebné obrazy .....	11
1.1.1 Zložková reprezentácia farebného obrazu .....	12
1.1.2 Vektorová reprezentácia farebného obrazu.....	13
1.1.3 Stručný opis niektorých vybraných štandardných farebných priestorov .....	14
<b>2 MODEL Y ZNEHODNOTENIA OBRAZOV A OBRAZOVÝCH SEKVENCÍ.....</b>	<b>16</b>
2.1 Aditívny a impulzový šum.....	16
2.2 Škvŕny .....	19
<b>3 DETEKCIA POŠKODENIA .....</b>	<b>20</b>
3.1 SDV detektor impulzov.....	20
3.2 Detekcia škvŕn v poškodenom archívnom filme .....	21
3.2.1 Heuristický detektor škvŕn.....	22
3.2.2 Detektor SDI.....	22
<b>4 FILTRAČNÉ METÓDY MEDIÁNOVÉHO TYPY PRE OPRAVU A ZLEPŠOVANIE OBRAZOV A OBRAZOVÝCH SEKVENCÍ .....</b>	<b>23</b>
4.1 Mediánová filtrácia obrazu.....	23
4.1.1 Definícia .....	23
4.1.2 Vlastnosti mediánových filtrov .....	24
4.2 Rôzne modifikácie štandardného mediánu, resp. kombinácia iných operácií s mediánom vo viacstupňových filtroch .....	27
4.2.1 Vážený medián .....	27
4.2.2 FIR mediánová hybridná operácia .....	28
4.2.3 Separovateľný mediánový filter.....	28
4.2.4 Rekurzívny mediánový filter .....	29
4.2.5 Filter „max-median“ a viacstupňový mediánový filter .....	29
4.3 Mediánová filtrácia v oblasti farebného zobrazovania .....	30
4.3.1 Zložková versus vektorová filtrácia.....	30
4.3.2 Vektorová a váhová vektorová mediánová operácia.....	31
4.3.3 Vektorové smerové filtre a sférický medián pre spracovanie farebných obrazov .....	31
4.4 Mediánové filtre pre opravu dynamických obrazových sekvencií.....	34
4.4.1 Psycho-vizuálne hľadiská návrhu filtra .....	34
4.4.2 Priestorová, časová filtrácia a ich kombinácie .....	35
4.4.3 Viacstupňové mediánové filtre.....	36

<b>5</b>	<b>PROCES REŠTAURÁCIE OBRAZOVÝCH SEKVENCÍ POŠKODENÝCH ŠKVRNAMI POMOCOU MEDIÁNOVÝCH FILTROV - VIAC PRAKTICKY .....</b>	<b>39</b>
5.1	Detekcia škvŕn v obrazových sekvenciách .....	39
5.1.1	Voľba vhodného prahu detektora.....	40
5.2	Oprava škvŕn - hľadanie vhodnej filtračnej štruktúry .....	42
5.2.1	Časový filter .....	42
5.2.2	Priestorovo-časové filtre .....	43
5.3	Oprava škvŕn – experimenty, výsledky.....	45
5.4	Oprava škvŕn - záver .....	47
<b>6</b>	<b>MYRIADOVÉ FILTRE PRE POTLÁČANIE ŠUMU .....</b>	<b>48</b>
6.1	Definícia.....	49
6.2	Vážený myriadový filter .....	50
6.2.1	Vlastnosti výstupnej hodnoty váženého myriadového filtra .....	51
6.2.2	Optimalizácia váh váženého myriadového filtra.....	52
6.3	Myriadové filtre - experimenty .....	53
6.4	Myriadové filtre - záver .....	54
<b>7</b>	<b>ČÍSELNÉ KRITÉRIÁ KVALITY OBRAZU A OBRAZOVEJ SEKVENCIE.....</b>	<b>56</b>
7.1	MAE .....	56
7.2	MSE.....	57
7.3	SNR .....	57
7.4	MAER, NR, PSNR .....	57
7.5	Farebný rozdiel .....	58
7.6	Vyhodnocovanie miery pohybu a zachovania pohybu v obrazových sekvenciách .....	59
7.7	Štrukturálne kritérium pre posúdenie kvality obrazov a videa, približujúce sa subjektívnemu vnímaniu kvality.....	60
7.7.1	Definícia kritéria štrukturálnej podobnosti obrazov .....	63
7.7.2	Praktické vyhodnotenie kritéria štrukturálnej podobnosti pre obrazy.....	64
7.7.3	SSIM-kritérium pre farebné obrazy.....	65
7.7.4	Vyhodnotenie kvality videosekvencie.....	65
7.7.5	SSIM-kritérium v experimentoch .....	67
7.7.6	SSIM kritérium kvality – zhrnutie .....	69
<b>ZÁVER .....</b>	<b>71</b>	
<b>ZOZNAM BIBLIOGRAFICKÝCH ODKAZOV.....</b>	<b>72</b>	
<b>REGISTER.....</b>	<b>77</b>	

---

<b>PRÍLOHA .....</b>	<b>79</b>
<b>PRÍLOHA 1 VÝSLEDKY FILTRÁCIE JEDNOTLIVÝCH SEKVENCIÍ FILTRAMI BEZ DETEKCIE A S DETEKCIOU ŠKVRN.....</b>	<b>80</b>
<b>PRÍLOHA 2 POROVNANIE HODNÔT KRITÉRIA ŠRUKTURÁLNEJ PODOBNOSTI S HODNOTAMI MAE A MSE PRE NIEKTORÉ TYPY OBRAZOV, ŠUMOV A FILTROV</b>	<b>88</b>

## ZOZNAM SKRATIEK A SYMBOLOV

### Zoznam skratiek

1-D, 2-D, 3-D	jednorozmerný / dvojrozmerný / trojrozmerný
BVDF	basic VDF - základný VDF
bw10	impulzový šum s hodnotou jasu 0 alebo 255 („čierno-biely“); 10% pixelov
CD	color difference - farebný rozdiel (číselné kritérium)
ci10	korelovaný impulzový šum vo farebnom obraze; 10% poškodených pixelov s hodnotou jasu od 0 do 255
CIE	Comission Internationale de l'Eclairage - Medzinárodná komisia pre osvetľovanie
Cross	filter s oknom v tvare "+" vo všetkých časových úrovniach
CRT	cathode ray tube - obrazovka (vákuová)
CWM	central weighted median - centrálnne vážený medián
ČB	čierno-biely
FIR	finite impulse response - konečná impulzová odpoveď
FMH	FIR mediánové hybridné filtre
g10, g20	aditívny Gaussov šum, $\mu = 0$ , $\sigma = 10$ , resp. $\sigma=20$
GVDF	generalized VDF - zovšeobecnený VDF
HDTV	High Definition TV - televízia s vysokým rozlíšením
HVS	human visual system - ľudský zrakový systém / zrak
i10	impulzový šum s premenlivou hodnotou jasu („šedý“); 10% pixelov
LUM	Median of a Lower statistic, an Upper statistic, and of the Medium samples - medián z najmenšej, najväčšej a aktuálnej vzorky v okne
MAE	mean absolute error - stredná absolútna chyba
MAER	redukcia MAE
MCL	miss classification - percentuálny podiel falošnej detekcie impulzov
MF	mediánový filter
MF2	2-stupňový mediánový rozšírený filter
MKO	Medzinárodná komisia pre osvetľovanie
ML	maximal likelihood - maximálna vierohodnosť
MMF	multilevel median filter - viacstupňový mediánový filter
MMSE	minimal mean absolute error - min. stredná absolútna chyba
MOS	multistage order statistic - viacstupňový poriadkový štatistický
MSE	mean square error - stredná kvadratická chyba
MSSIM	priemerné SSIM vypočítané metódou lokálnych okien
$N(\mu, \sigma^2)$	označenie pre Gaussovo rozdelenie
nbw20	nekorelovaný impulzový šum vo farebnom obraze; ďalej pozri bw10
NR	noise reduction - redukcia šumu
OP	obrazový prvok
OWMyF	optimalizovaný vážený myriadový filter
PSNR	vrcholový pomer signál / šum
RM	rekurzívny medián
SCL	success classification - vyhodnotenie úspešne detekovaných impulzov
SDI	spike detection index - index špičkovej detekcie
SDM	steepest descent method - metóda najstrmšieho zostupu
SM	sférický medián
SNR	pomer signál/šum



---

SSIM	structural similarity index - kritérium štruktúrálnej podobnosti
TV	televízia / televízny
TWM	vážený medián z časového okna
VDF	vector directed filter - vektorový smerový filter
VM	vektorový medián
VQEG	Video Quality Experts Group - medzinárodná skupina expertov pre vyhodnocovanie kvality videa
WM	weighted median - vážený medián
WVM	vážený vektorový medián

## Zoznam symbolov

$(i,j,n)$	pozícia obrazového prvku v riadku, stĺpci a snímke
$c$ v označení obrazu	korelovaný šum
$e$	odchýlka, chyba, rezíduum estimácie / hodnota aditívneho šumu
$E$	odhad štatistickej strednej hodnoty
$G_n$	intenzita jasu poškodeného/zašumeného obrazového prvku
$I_n$	intenzita jasu nepoškodeného obrazového prvku
$L$ v označení obrazu	obraz Lena
$med$	medián
$My$	súvisiaci s myriadovým filtrom
$n$ v označení obrazu	nekorelovaný šum
$R$	priemerná korelácia sekvencie
$r, g, b$ alebo RGB	zložky farebného svetla: červená, zelená, modrá
$std$	štandardná odchýlka
$w$	váha
$W$ v označení okna	spolu so symbolickým označením tvaru, súčasť označenia filtra
$x$	vstupná vzorka / jedna zo vstupných vzoriek filtra
$x^*$	aktuálna obrazová vzorka
$y$	výstupná hodnota filtra
$z$	výstup zo subfiltra
$\alpha^{(i)}, x^{(i)}$	$i$ -te poradie prvku $\alpha$ resp. $x$
$\beta$	maximálne pravdepodobná hodnota daného rozdelenia (minimalizujúca chybu)
$\Delta$	rozdiel, diferencia, zmena (chyba)
$\mu$	štatistická stredná hodnota
$o$	originálny obrazový prvok
$\sigma$	štandardná odchýlka
$\sigma^2$	štatistický rozptyl
$\sigma_{xy}$	kovariancia signálov $x, y$
$\Delta R$	zmena priemernej korelácie sekvencie (na vyhodnotenie zmeny pohybu)

Ostatné skratky sú vysvetlené v texte a majú svoj význam len v danej časti textu.

## ÚVOD

Spracovanie obrazov a obrazových postupností v číslicovej forme je predmetom aktívneho výskumu a vývoja už asi tri desiatky rokov, no na prelome 20. a 21. storočia sa toto spracovanie stalo dokonca do istej miery prístupným aj širokej „počítačovej“ verejnosti. Vďaka číslicovému spracovaniu obrazov bolo možné spustiť a rozširovať tiež vysielanie digitálnej televízie, a prenos, predtým ešte nepredstaviteľného množstva a druhov obrazových informácií cez počítačovú sieť. Práve kvôli spomínaným, teda aj, a hlavne komerčným účelom sa obrátila znovu pozornosť aj na archívne, staré filmové materiály. Pri týchto materiáloch prívlastok „starý“ znamená, že „sa na nich podpísal zub času“, že sú poškodené a ich opätovná projekcia by bola sprevádzaná veľkým znížením kvality zážitku. K široko skúmanej filtrácii impulzového a Gaussovho šumu takto pribudol problém ďalších typov poškodenia. Po vizuálnej stránke sú to najčastejšie škvrny s maximálnym alebo minimálnym jasom („iskrenie a špina“), čiary, vzniknuté mechanickým poškriabaním alebo pokrčením pri skladovaní, opakovanej projekcii, a ďalších manipuláciách s filmovými kópiami. Dnes je možné aj takýto starý filmový materiál opraviť tak, že pri jeho sledovaní má divák pocit, že ide o nový film. Oprava filmových kópií, čo sú vlastne postupnosti veľkého množstva snímok, však musí byť z dôvodu rozsiahlosti súborov dát realizovaná automaticky a čo najefektívnejšie, čo je úlohou ešte stále prebiehajúceho ďalšieho výskumu [40], [41], [42].

Pri návrhu metód na spracovanie obrazových sekvencií sa vychádzalo najprv z rekonštrukcie poškodených, alebo už aj pôvodne zašumených alebo inak zle „čitateľných“ statických obrazov. Metód vyvinutých pre tento účel je mnoho, a všeobecne platí, že voľba metódy rekonštrukcie obrazu závisí okrem účelu, aj od charakteristiky poškodenia, resp. od typu šumu, od štatistických vlastností obrazu a od toho, či ide o obraz farebný alebo šedý. To všetko naznačuje vetvenie problému rekonštrukcie, ktoré však ešte ďalej pokračuje. Pomerne široko preskúmané metódy mediánovej filtrácie je možné použiť aj pre tento účel. Sú tu samozrejme aj ďalšie možnosti. Jedna z nich - myriadová filtrácia – umožňujúca pomerne flexibilne nastaviť robustnosť/jemnosť bude opísaná v tejto publikácii.

Filtrácia sa používa bez detekcie alebo s detekciou šumu, resp. poškodenia. Spôsob zistenia znehodnotenia úzko súvisiaci so spôsobom zistenia charakteru obrazu, bol predmetom a výsledkom rozsiahlych prác. Predpokladalo sa, a experimenty to potvrdili, že filtrácia aplikovaná kompletne na celý obraz, celú snímku a každú snímku, je neefektívna, a dokonca nežiaduca, pretože určitým spôsobom ovplyvní aj tie obrazové body a celé plochy, ktoré neboli poškodené. Výsledkom môže byť potom nie zlepšenie, ale skôr určité zhoršenie, skreslenie obrazovej informácie, čomu má detekcia znehodnotenia predísť.

Z oblasti obrazovej a filmovej techniky je aj problém vyhodnocovania kvality obrazového materiálu. Najčastejšie používané číselné parametre ako stredná absolútna, stredná relatívna chyba a pod. niekedy nezodpovedajú kvalite vnímanej ľudským zrakom. Medzinárodná skupina expertov VQEG [89], ale aj ďalší výskumníci [84], [95], [96] pracujú na vývoji čo najefektívnejšej metódy, ktorá by sa subjektívnemu vnímaniu kvality čo najviac približovala. Štandard ITU-T Recommendation 500\* [65a] bol síce vypracovaný práve kvôli tomu, no vyžaduje splnenie množstva náročných podmienok v podobe technického vybavenia a zariadenia testovacích miestností, nutnej prítomnosti viacerých testovacích osôb a samozrejme veľkého časového objemu, čo sa výskumníci prípadnými novými kritériami snažia odľahčiť.

---

Opis spomínaných problémov spracovania obrazových dát je vypracovaný aj s cieľom poskytnúť začiatočníkovi potrebné základy pre prácu v tejto špecifickej oblasti.

V jednotlivých kapitolách sú postupne opísané zdrojové digitálne modely čierneho a farebného obrazu a obrazovej sekvencie, modely ich znehodnotenia, detektory znehodnotenia, filtračné metódy na báze mediánu a princíp myriadovej filtrácie. Jedna z kapitol podrobne opisuje praktický postup realizácie experimentov v oblasti opravy škvŕn v dynamickej obrazovej sekvencii: detekciu škvŕn, výber vhodného mediánového filtra, filtráciu a jej výsledky. V posledných častiach knihy sú vysvetlené najčastejšie kvalitatívne kritériá, používané pre číselné vyhodnotenie úspešnosti filtrácie a vysvetlený je aj možný prístup k vyhodnoteniu približujúcemu sa vyhodnoteniu ľudským zrakom.

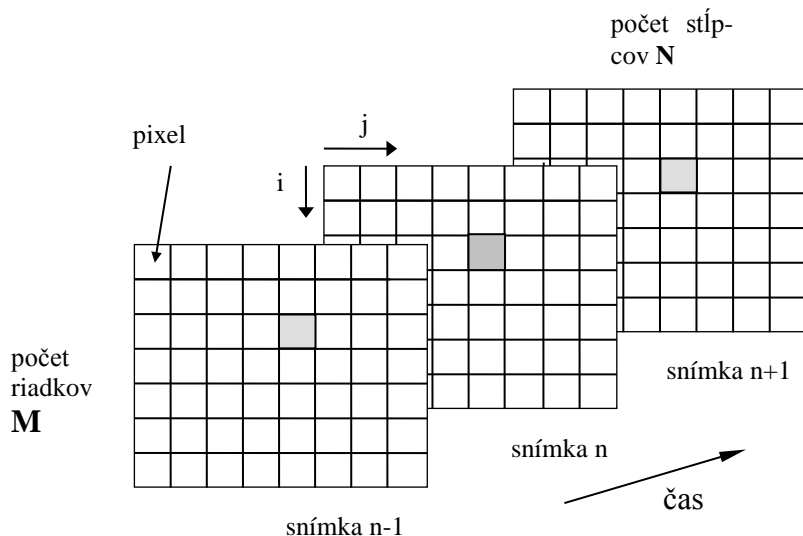
## 1 Model obrazu a obrazovej sekvencie

V oblasti číslicového spracovania obrazov a dynamických obrazových sekvencií sú už zaužívané niektoré východzie kroky a postupy, ktoré pomáhajú rýchlejšie prikročiť k riešeniu nového alebo ďalšieho problému. K týmto „stereotypom“ patria modely obrazov a obrazových sekvencií, modely poškodení, celé skupiny filtrov a filtračných metód. To všetko bude stručne opísané v nasledujúcom texte.

Číslicové spracovanie obrazových sekvencií je spracovaním postupnosti čísel z určitého číselného rozsahu. Tento rozsah korešponduje s rozsahom elektrickej veličiny zodpovedajúcej jas, alebo niektorej zložke farebného obrazového signálu. Spomínaná diskretná postupnosť, určená na spracovanie (filtráciu), môže byť produktom známeho postupu digitalizácie analógového signálu [napr. 51], alebo je priamo generovaná digitálnym snímacím reťazcom, prípadne ďalším, za ním nasledujúcim transformačným zariadením.

*Statický obraz* si budeme predstavovať rozložený na elementárne obrazové prvky – *pixely* (pixel = picture element), usporiadané podľa pravouhlej mriežky do  $M$  riadkov a  $N$  stĺpcov (obr.1.1). Pri číselných operáciách ho potom môžeme uvažovať ako číselnú maticu, vyjadrujúcu hodnotu niektorého z obrazových parametrov v každom obrazovom prvku.

*Obrazovú sekvenciu*, čiže postupnosť obrazov zaznamenávajúcich zmenu na scéne, pohyb, pri číslicovom spracovaní potom reprezentuje množina matic, ktoré zodpovedajú snímkam, zobrazujúcim scénu snímanú v pravidelných časových intervaloch (obr.1.1). Napríklad v televíznom štandarde PAL má tento časový interval dĺžku  $1/25$  sekundy.



Obr.1.1 Číslicový – maticový model obrazovej sekvencie

Pre testovanie a porovnávanie vlastností navrhovaných číslicových filtrov a filtračných metód sa opakovane používajú tie isté – štandardné - obrazy a obrazové sekvencie. Štandardné obrazové objekty sa volia tak, aby obsahovali charakteristické obrazové štruktúry: veľké hladké plochy, ostré zvislé jasové prechody, drobné štruktúry a čiary, pri sekvenciách k tomu pribudnú pomaly a rýchlo sa pohybujúce predmety na scéne, alebo snímky získané pomaly a rýchlo sa pohybujúcou kamerou. V tejto knihe sa vý-

sledky budú vzťahovať k čierno-bielym (ČB) obrazom *Lena* a *Most (Bridge)*. Ich veľkosť je 256 x 256 pixelov a rozsah jasových úrovní 0 až 255, vyjadrených 8 bitmi. Roz-



(a) Lena



(b) Most

Obr.1.2 Štandardné čierno-biele obrazy

diel štruktúry ich obrazových plôch je zjavný (obr.1.2).

Z ČB sekvencií boli pre účely tejto publikácie ako testovacie použité sekvencie, ktorých reprezentatívne snímky sú uvedené na obr. 1.3: *People* (rýchlo sa pohybujúce osoby na pozadí mestského prostredia s drobno členitou štruktúrou), *Trevor* (rozprávajúci muž sediaci za stolom, málo ostrých detailov, monotónne plochy, pohyb najmenej výrazný), *Salesman* (gestikulujúci muž sediaci za stolom, viac detailov a málo monotónnych plôch), *Susie* (telefonujúca žena málo detailov, veľký podiel monotónnych plôch, relatívne málo pohybu).



(a) People



(b) Trevor



(c) Salesman



(d) Susie

Obr.1.3 Štandardné čierno-biele obrazové sekvencie použité pri experimentoch

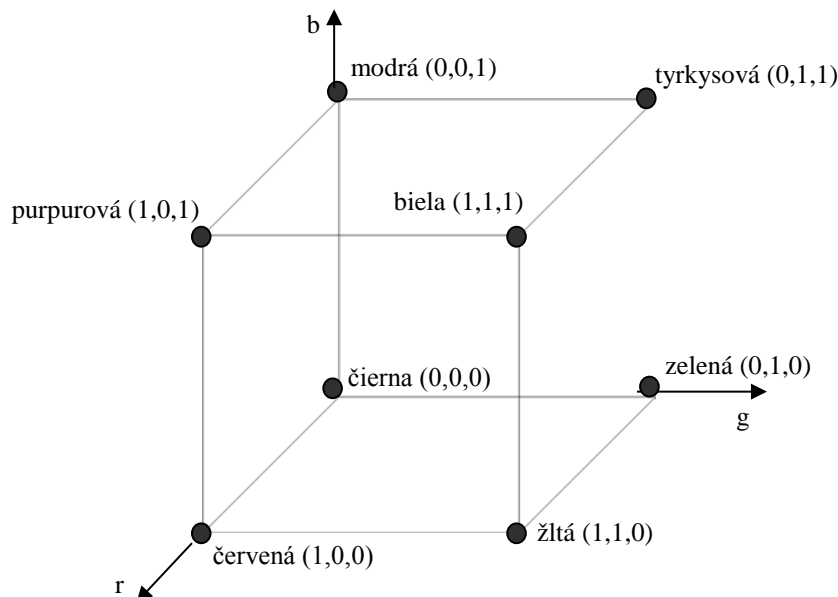
## 1.1 Vyjadrenie farby a farebné obrazy

Svetlo je elektromagnetické vlnenie v rámci rozsahu vlnových dĺžok približne 400 až 700nm. Jeho farba zodpovedá niektorej konkrétnej časti tohto rozsahu alebo je kombináciou jeho viacerých zložiek. Digitálne vyjadrenie farby korešponduje so spôsobom fyziologického vnímania farby (svetla) ľudským okom a so spôsobom jej elektronicko-optickej realizácie (pomocou súčtových zložiek R,G,B vo farebných elektronických obrazovkách), alebo sa ďalej transformuje do rôznych farebných sústav a štandardov, vhodných pre prenos (napr. vo farebnej televízii), číslicové kódovanie a pre farebnú tlač.

O vnímaní farby ľudským zrakom, o rôznych *farebných priestoroch*, čiže o metódach vyjadrenia farby, a o konverzii medzi týmito priestormi existuje dosť literatúry, napr. [82], [65], a veľa veľmi pekného a prehľadného materiálu možno nájsť aj na internetových stránkach (v súčasnosti napr. [20], [55], [64]). Na tomto mieste bude preto uvedená len malá časť zo spomínaných informácií, ktorá je potrebná pre uvedenie do problematiky metód filtrácie farebných obrazov a sekvencií, predstavených v tejto publikácii.

*CIE* (*Comission Internationale de l'Eclairage* = Medzinárodná komisia pre osvetľovanie, v česko-slovenskej literatúre označovaná aj skratkou MKO) definovala systém pre výpočet trojice číselných zložiek, ktoré môžu byť osami farebného priestoru, a pomocou ktorých je teoretická špecifikácia každej možnej farby veľmi presná [64]. Kódovacie systémy sa však, pochopiteľne, z praktických dôvodov neusilujú o bezhraničnú presnosť, a využívajú farebné priestory, ktoré nie sú úzko späté so systémom CIE. Pritom pre každý špecifický účel, ako už bolo naznačené, je väčšinou vhodný iný farebný priestor. Takže škála farebných priestorov je pomerne široká. Sú trojfarebné priestory, chromaticko-jasové, zjednotené so subjektívnym vnímaním, orientované na odtiene, niektoré farebné priestory sú lineárne, iné nelineárne. Niektoré sú intuitívne (prirodzené) na použitie, a je pre používateľa jednoduché orientovať a „pohybovať sa“ v nich, iné sú ťažko ovládateľné, s parametrami, ktorých vzťah k farbe je veľmi abstraktný. Niektoré farebné modely sú založené na pravouhlom, iné na polárnom súradnicovom systéme. A nakoniec, niektoré farebné priestory sú úzko späté s používanými zariadeniami (sú závislé od použitého zariadenia), kým iné sú rovnako platné na každom zariadení, kde sú použité. Transformácie medzi týmito priestormi môžu byť lineárne alebo nelineárne.

### 1.1.1 Zložková reprezentácia farebného obrazu



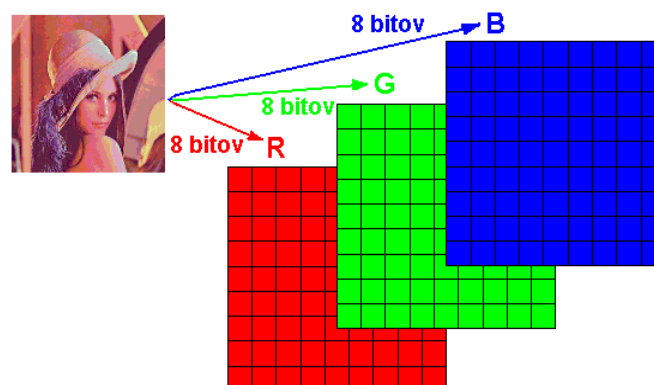
Obr.1.4 Pravouhlý (aditívny) farebný model RGB v podobe normovanej kocky. Pomocou súčtu zložiek  $r, g, b$  možno vyjadriť ktorúkoľvek z farieb a sýtosť zobraziteľných systémom CRT. Ďalšie z vrcholov kocky predstavujú ďalšie základné farebné tóny v televíznej technike; odtiene ležiace na spojnici medzi čiernou a bielou zodpovedajú odtieňom šedej.

*Ludské videnie* okolitého sveta je umožnené transformáciou svetla, dopadajúceho na citlivé bunky sietnice v ľudskom oku. Nervové vzruchy, ktoré takto vznikajú, sú potom vyhodnocované v mozgu. Bunky sietnice sú citlivé na niektorú z troch úzkopásmových svetelných spektrálnych zložiek (farebných odtieňov) – červenú, zelenú, a modrú (čapíky) alebo na intenzitu svetla (tyčinky). Z týchto zložkových informácií sa v mozgu vytvára súhrnná informácia o odtieni, sýtosti a jase pozorovaného svetla [20].

Ľudskému zrakovému systému podobný – *súčtový (aditívny) trichromatický* - princíp je využitý v elektronických *zobrazovacích zariadeniach*. Farebný priestor, v ktorom možno každú (takmer) farbu vyjadriť *pomocou lineárnej kombinácie troch základných farebných zložiek* (napr. jednoduchý pravouhlý *RGB-model* - obr. 1.4 [19a]), sa aj najviac približuje ľudskému chápaniu a je najjednoduchší z hľadiska číslicového spracovania.

*Farebný obraz* potom možno uvažovať ako trojicu rovnako veľkých matic, predstavujúcich jednotlivé zložky *r, g, b* (obr. 1.5), ktoré môžu byť, každá zvlášť, spracované identickým (alebo takmer identickým) spôsobom.

Dokonalosť vyjadrenia farieb, ako bolo naznačené, nikdy nie je stopercentná, a rovnako ani schopnosť konkrétneho farebného priestoru splniť požadovaný účel, čo bolo dôvodom vzniku ďalších, aj pomerne komplikovaných modelov. Často sa namiesto kombinácie 3 základných farieb používa kombinácia *jasovej zložky a dvoch chrominančných*, napr. farebné priestory  $Y'U'V'$ , alebo  $Y'I'Q'$ , ktoré sú súčasťou prenosových televíznych farebných štandardov (napr. PAL, resp. NTSC, a ďalších). Chrominančné zložky



Obr.1.5 Zložková trichromatická (r,g,b) reprezentácia digitálneho farebného obrazu

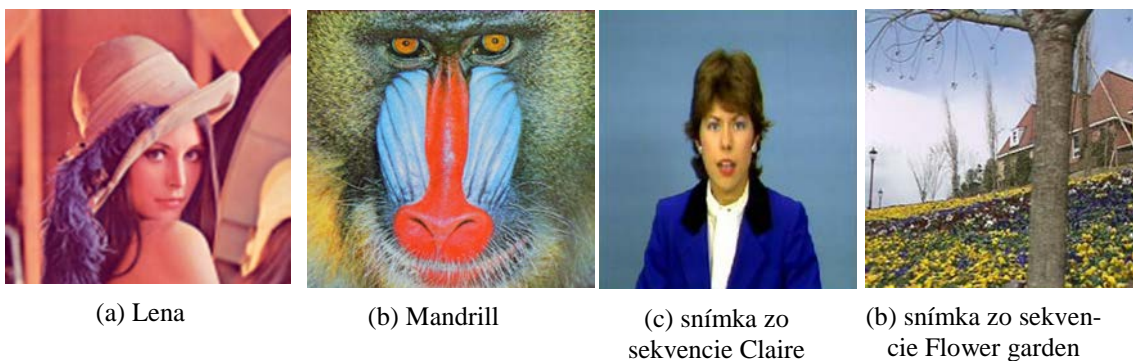
sú výsledkom matematickej a elektronickej realizovanej transformácie jasu a základných farieb. Použitie týchto farebných priestorov pri tvorbe farebného prenosového TV signálu má svoje ďalšie zvláštnosti a výhody. Fakt, že oko je viac citlivé na jasové zmeny a chyby, než na zmeny farby sa tu využíva pri odlišnej, menej náročnej modulácii, kódovaní a spracovaní chrominančných zložiek, než v jasovom TV-kanáli.

### 1.1.2 Vektorová reprezentácia farebného obrazu

Spomínaný zložkový - *marginálny* [62] – prístup, či už trichromatický alebo chrominančno-jasový, však nie je vždy výhodný. Ako bude uvedené neskôr, nevýhoda sa prejaví v prípadoch, keď sa pri filtrácii poruší (nezohľadní) úzka korelácia medzi zložkami a dôjde tak ku zmene farebného tónu (výslednej farby). Výsledným efektom tejto zmeny farebného tónu sú rušivo neprirodzené farby (najmä farba ľudskej tváre) a tiež chvenie farebných hrán pri riadkovom rozklade obrazu, tzv. *jitter effect* [7], [59].

Keď si však uvedomíme, že viaczložkový signál je vlastne vektorový, môžeme aj *farebné svetlo, ako vektor* vyjadriť pomocou polárnych súradníc, t.j. pomocou *farebného priestorového uhla* (v zložkovom – viacrozmernom priestore, napr. v priestore r,g,b) a *vektorovej dĺžky*. Uhol bude informovať o tóne farby a dĺžka tohto vektora bude informovať o jase. Pri takomto vyjadrení budú jednotlivé pixely vstupovať do filtračného procesu v podobe *farebných vektorov*, a je jasné, že farebný tón zachovávajú a budú preferované tie operácie, ktoré nemenia uhol farebných vektorov.

Určitou kombináciou týchto poznatkov o vektorovom a zložkovom vyjadrení farby je už vyššie spomínaný štandard PAL, s jasovou Y' a chrominančnými U',V' zložkami. Pri jeho kódovaní sa práve so zámerom vyhnúť sa fázovej chybe - chybe farebného tónu - používa princíp kvadráturnej amplitúdovej modulácie nosnej farby s medziriadkovým prepínaním fázy chrominančnej zložky U', zodpovedajúcej rozdielu R - Y, o 180° [65].



Obr.1.6 Štandardné farebné obrazy a sekvencie

Aj pre výskumné práce s farebnými obrazmi a sekvenciami sa používajú charakteristické *-štandardné farebné obrazy*, resp. sekvencie. Niektoré z nich sú znázornené na obrázku 1.6. Prvý z nich, "farebná Lena", podobne ako v ČB verzii, obsahuje väčšinou veľké monotónne plochy na rozdiel od druhého - "Mandrill", ktorý je výrazne farebne pestrejší a plný drobných detailov a čiar.

Podobným spôsobom sú odlišné snímky farebných sekvencií "Claire" a "Flower garden" - obr. 1.6 - c,d. Navyiac, keďže ide o dynamické obrazové sekvencie, líšia sa aj typom pohybu. Claire je žena rozprávajúca a sediaca za stolom, Flower garden je lúka posiatá pestrofarebnými kvetmi s domom v pozadí, snímaná pomaly sa pohybujúcou kamerou.

### 1.1.3 Stručný opis niektorých vybraných štandardných farebných priestorov

**RGB** je trichromatický *aditívny* systém, používa sa v **CRT**-systémoch, t. zn. vo vákuových obrazovkách monitorov a televízorov. Je prístrojovo závislý, jednoducho implementovateľný, no nemožno ho dať do lineárnej súvislosti so zrakovým vnímaním farby.

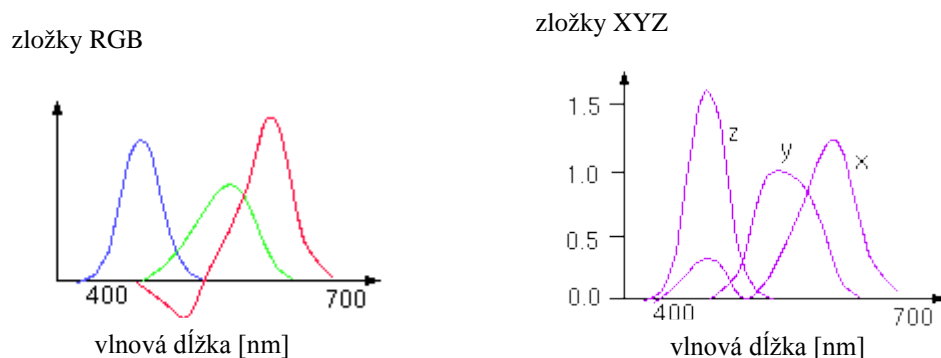
**CMY(K)** - Cyan (tyrkysová), Magenta (purpurová), Yellow (žltá), black (čierna) - je *subtraktívny* farebný model používaný hlavne vo farebných tlačiarňach a kopírkach. Je jednoducho implementovateľný, intuitívny, prístrojovo závislý, nelineárne závislý na subjektívnom vnímaní. Jeho presná transformácia do priestoru RGB je zložitá.



**YIQ, YUV, YCbCr, Kodak Foto YCC** (jas a chrominančné zložky) - farebné priestory pre prenosový televízny signál. YIQ je pre farebný **televízny štandard** NTSC, YUV pre PAL, YCbCr, YCC sú digitálne štandardy pre televíziu, a fotografiu / televíziu. V týchto farebných priestoroch je oddelená jasová zložka od chrominančnej, čo je užitočné pre kompresiu v digitálnej aj v analógovej oblasti. Sú prístrojovo závislé a úzko viazané na typ kódovacieho a dekódovacieho zariadenia. Sú intuitívne pre špecialistov a ľudí pracujúcich alebo dobre zorientovaných v oblasti televíznej techniky.

### CIE XYZ

CIE tento systém definovala pre *určenie farby v súlade so subjektívnym vnímaním*. Definícia farieb v tomto systéme je veľmi presná. Základom kolorimetrie podľa CIE je farebný priestor **CIE XYZ (1931)** definovaný v roku 1931. V ňom sú všetky viditeľné farby definované len pomocou kladných súradnicových poloosí. Takže samotné základné trichromatické zložky x,y,z nepatria do viditeľnej oblasti. Bez zohľadnenia jas platí vzťah  $x+y+z = 1$ , čo znamená jednotkovú rovinu CIE, do ktorej možno premietnuť všetky farebné tóny (všetky vektory farebných svetiel ňou prechádzajú), a potom pre vyjadrenie farby v tejto 2-D rovine postačia len dva údaje. Tretí je nadbytočný, pretože ho možno určiť z vyššie uvedeného vťahu. Často sa uvádzajú len trichromatické súradnice x, y a priemet jednotkovej roviny CIE do roviny XY (preto aj označenie **Yxy**, kde Y je jas). *Krivka spektrálnych farieb* vo vnútri tohto premietnutého trojuholníka je v kolorimetrii známa pod názvom *diagram CIE (diagram MKO)*, a slúži pre dobré znázornenie a vysvetlenie rôznych manipulácií s farebnými svetlami [65].



Obr.1.7 Pomerné trichromatické členitele farebného svetla v sústavách RGB a CIE XYZ

Ďalšími transformáciami CIE ZXY alebo Yxy vznikli neskôr nové farebné priestory.

**CIE YUV** (1960) vznikol lineárnou transformáciou Yxy alebo XYZ [20], nazýva sa tiež diagramom rovnakých farebných rozdielov.

**CIE YU\*V\*** je zdokonalením CIE YUV; zohľadňuje aj jas.

## 2 Modely znehodnotenia obrazov a obrazových sekvencií

V praxi sa možno stretnúť s viacerými typmi znehodnotenia obrazových materiálov. Filtračné metódy sú väčšinou viazané na konkrétny typ znehodnotenia, a jeho správny odhad je preto predpokladom úspešnosti filtrácie. V tejto časti bude opísané znehodnotenie statických obrazov a obrazových sekvencií šumom, a tiež ďalší častý prípad veľmi rušivého poškodenia, vyskytujúci sa na archívnych filmových pásoch – škvrny rôzneho pôvodu a všeobecne s rôznou intenzitou jasu. Všetky spomínané typy vizuálneho rušenia majú charakter náhodnej veličiny, ovplyvňujúcej priebeh užitočného (obrazového) signálu, no po vyhodnotení ich štatistických parametrov ich možno viac alebo menej zložitým spôsobom dosť verne simulovať. Na simuláciu znehodnotenia už dnes existujú dobré nástroje v podobe programových prostriedkov, napr. v prostredí MATLAB, ale v prípade špeciálnych požiadaviek nie je veľký problém realizovať simuláciu aj pomocou vlastných počítačových programov.

V prípade digitálneho videa, ktoré býva realizované v podobe niektorého z kompresných video-formátov, sa väčšinou pred simuláciou poškodenia, ktoré je viazané na jednoduchý, nekomprimovaný maticový tvar snímok, uskutoční najprv dekódovanie a rozloženie video-súboru na jednotlivé snímky.

### 2.1 Aditívny a impulzový šum

Charakteristické pre statické obrazy bývajú šumy, prejavujúce sa celoplošne, prakticky na každom obrazovom pixeli (*aditívny* alebo *multiplikatívny šum*), alebo len ojedinele, v podobe obrazových bodov, svojím jasom alebo zafarbením výrazne odlišných od ostatných v blízkom okolí (*impulzový šum*).

**Aditívny šum** a multiplikatívny šum majú väčšinou rovnomerný charakter rozdelenia alebo častejšie blízky *Gaussovmu rozdeleniu* hustoty pravdepodobnosti (obr.2.1). V takom prípade ak hodnotu šumu v obrazovom bode  $x$  označíme  $e(x)$ , potom pravdepodobnosť jej výskytu vyjadruje vzťah (2.1). Ten možno graficky znázorniť v podobe



Obr.2.1 Lena (Lg20) – ilustrácia znehodnotenia Gaussovým aditívnym šumom  $\mathcal{N}(\mu, \sigma^2) = \mathcal{N}(0, 20^2)$

známej krivky zvonovitého tvaru (obr.6.1) a slovne vysvetliť ako malý výskyt hodnôt príliš odlišných od najpravdepodobnejšej (strednej) hodnoty a veľký výskyt hodnôt blízkych strednej hodnote.

$$p(e) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(e-\mu)^2}{2\sigma^2}\right) \quad (2.1)$$

V (2.1) namiesto  $e(x)$  bol použitý skrátenejší zápis  $e$ ,  $\mu$  je stredná hodnota rozdelenia,  $\sigma^2$  je rozptyl šumových hodnôt. Skrátene sa zvykne uvádzať označenie Gaussovho rozdelenia pomocou zápisu  $\mathcal{N}(\mu, \sigma^2)$ , ktorý bude využitý aj v tejto publikácii.

Aditívny typ šumu sa prakticky vo väčšej alebo v menšej miere vyskytuje vždy. Pridružuje sa k obrazovému signálu už v okamihu snímania a tiež pri prechode elektronickým

spracovateľským reťazcom, pretože je prejavom tepelných kmitov všetkých fyzikálnych častíc. Vzniká tiež degradáciou fotografických obrazových materiálov (filmov a fotografií) ako dôsledok starnutia.

Prejav zrnitosti papierového fotografického materiálu má charakter multiplikatívneho rušenia. Pretože tento vizuálny efekt je často požadovaný, pojem šum alebo rušenie v takom prípade ani nie je na mieste.

Číslcová (počítačová) *simulácia znehodnotenia* obrazov alebo obrazových sekvencií aditívnym šumom sa môže realizovať podľa vzťahu (2.2), t.j. pripočítaním vždy inej náhodnej hodnoty  $e$  z Gaussovho rozdelenia (napr.  $\mu=0, \sigma = 20$ ) ku hodnote každého obrazového prvku v obraze alebo v digitálnom videu.

$$G_n(x) = I_n(x) + e(x) \quad (2.2)$$

$I_n(x)$  – intenzita neznehodnoteného pixelu na pozícii  $x$  v snímke  $n$

$G_n(x)$  – intenzita znehodnoteného pixelu

S využitím uvedeného matematického aparátu možno navrhnúť generátor aditívneho šumu, alebo využiť funkcie napr. prostredia MATLAB, ktorých činnosť tiež zodpovedá tejto filozofii.

Na potlačenie nežiadúcej úrovne šumov aditívneho typu sú vhodné lineárne filtre; najlepšie *adaptívne*, s doladovaním výsledku na základe vopred stanovenej maximálnej hodnoty chybového kritéria. Z nich veľmi rozšírené sú napr. Kalmanove, Wienerove filtre a trieda L-filtrov [napr.34].

Ďalší, veľmi rozšírený typ šumu – **impulzový šum** – sa na signál „naviaže“ v dôsledku rôznych priemyselných elektromagnetických impulzových rušení, a môže byť tiež produktom atmosferických výbojov. Výskyt rušivých impulzov je náhodný, preto sa hovorí o nelineárnom charaktere impulzového šumu. Intenzita impulzového rušenia takéhoto pôvodu býva veľmi veľká, a preto sa impulzový šum v digitálnom signáli prejaví väčšinou v podobe veľmi krátkych impulzov, ktoré majú maximálnu, alebo naopak nulovú (minimálnu) hodnotu – v obraze potom v podobe bodov s maximálnym alebo minimálnym jasom. Ak sa jedná o ČB obraz, alebo o časovo korelované rušenie vo všetkých 3 farebných kanáloch farebného obrazu, tieto rušivé body sú buď čierne alebo biele, a pre rušenie je preto vhodný názov *ČB-impulzový šum* (v anglickej terminológii pojem *salt-and-pepper noise*) - obr.2.2a,b.

Takýto šum možno simulovať výmenou originálnej hodnoty náhodne vybraného pixelu za hodnotu maximálnu (hodnota 255 v prípade 8 bitových úrovní, s pravdepodobnosťou  $p_{255}$ ) alebo za hodnotu minimálnu (0 s pravdepodobnosťou  $p_0$ ). Pravdepodobnosť výskytu impulzu pritom môže mať rovnomerné alebo Gaussovo rozdelenie a možno ju nastaviť v požadovaných percentách zašumenia. Na obrázkoch 2.2a,b je 20% obrazových pixelov nahradených bielym alebo čiernym podľa predpisu:

$$N_n(x) = \begin{cases} I_n(x) & \text{s pravdepodobnosťou } 1 - (p_0 + p_{255}) \\ 0 & p_0 \\ 255 & p_{255} \end{cases} \quad (2.3)$$

kde  $N_n(x)$  je nová hodnota pixelu na výstupe generátora šumu.

*Rušivé impulzy* v niektorých prípadoch nemusia dosahovať len medzné hodnoty, ale môžu nadobúdať hodnoty z *celého jasového rozsahu* 0 až 255. Generátor šumu (zápis 2.4), simulujúci túto situáciu, môže nahrádzať určité percento náhodne vybraných obrazových pixelov náhodnou hodnotou  $v$  od 0 do 255 z rovnomerného rozdelenia.


$$N_n(x) = \begin{cases} I_n(x) & \text{s pravdepodobnosťou } 1 - p_v \\ v & p_v \end{cases} \quad (2.4)$$

Tieto pixely sa v obraze, alebo v digitálnom videu prejavujú v podobe tmavších alebo svetlejších šedých bodov – obr.2.2c. Rovnaký efekt vzniká, ak sa taký šum vyskytne korelované (súčasne) vo všetkých troch farebných kanáloch farebného obrazu (obr.2.2d).

V prípade zobrazovania šedého („čierno-bieleho“) obrazu, resp. sekvencie farebným zobrazovacím systémom, alebo v prípade farebných obrazov a sekvencií, môže k rušeniu v jednotlivých farebných kanáloch z rôznych dôvodov dochádzať *nekorelované*. Výsledkom sú snímky rušené bodmi rôznych farebných odtieňov - obr. 2.2e.




(a) ČB impulzový šum 20% (Lbw20)




(b) korelovaný ČB impulzový šum 20% (Lcbw20)



(c) šedý impulzový šum 10% (Li10)



(d) korelovaný šedý impulzový šum vo farebnom obraze 10% (Lci10)



(e) nekorelovaný „ČB“ impulzový šum 20% (Lnbw20)

Obr.2.2 Obrazy Lena v ČB a vo farebnej verzii, znehodnotené niekoľkými typmi simulovaného impulzového šumu

Na spomínanom obrázku 2.2 sú jednotlivé zašumené fotografie ČB alebo farebnej Leny uvedené aj so skráteným označením, pod ktorým sa budú uvádzať ďalej.

Keďže impulzový šum má charakter nelineárneho rušenia v obraze, je možné ho odstrániť iba nelineárnymi filtermi. Zatiaľ najväčšie úspechy v tejto oblasti filtrácie boli dosahované využitím filtračných algoritmov na báze výberu poriadkových štatistik – hlavne mediánu, a rôznych kombinácií mediánu s inými štatistikami (s priemerom, maximom, minimom). Tu sa problematika filtrácie impulzového šumu, ktorej je venovaná aj podstatná časť tejto knihy, začína široko rozvetvovať.

V prípade impulzového šumu celoplošné pôsobenie filtračného procesu síce môže tento šum potlačiť, no zároveň ovplyvní aj pixely pôvodne neporušené, a tak sa celkom kľudne môže stať, že namiesto zníženia celkovej chyby obrazu alebo sekvencie sa dosiahne jej zvýšenie. Preto by sa filtrácia impulzového šumu mala uskutočňovať v súčinnosti s *detekciou šumových impulzov*, čím je možné vyššie spomínaný problém úspešne vyriešiť.

## 2.2 Škvvrny

Vďaka číslicovému spracovaniu obrazov bolo možné spustiť a rozširovať tiež vysielačie digitálnej televízie, a do popredia záujmu sa znova dostali aj staré, archívne filmy. Staré filmové kópie však samotným vplyvom času (chemické zmeny, usadený prach), ale aj opakovanou projekciou a ďalšou mechanickou manipuláciou výrazne utrpeli na kvalite, čím záujem o ich sledovanie klesol. Digitálnym spracovaním tohto materiálu však je možné vrátiť mu niekdajšiu vizuálnu kvalitu, a tým aj aspoň časť starej slávy (a komerčného záujmu). Najčastejšími typmi poškodenia po vizuálnej stránke sú známe **škvvrny s maximálnym alebo minimálnym jasom („iskrenie a špina“)** a čiary, vzniknuté mechanickým poškriabaním alebo pokrčením.

V jednej z častí tejto knihy budú opísané možnosti opravy škvŕn, vyskytujúcich sa na starých filmových kópiách. V digitálnej podobe tieto škvvrny predstavujú väčšie skupiny pixelov (teda nie jeden osamotený pixel, ale približne 10 až niekoľko desiatok tesne susediacich, tvoriacich oblasť náhodného nepravidelného tvaru), úrovňou jasu výrazne odlišných od ostatných okolitých neporušených pixelov. Sú buď omnoho svetlejšie, až biele, alebo omnoho tmavšie, až čierne. Pri takýchto zhlukoch poškodených pixelov sa hovorí o chýbajúcich dátach a o strate informácie.

Keďže však často ide o snímky, ktoré sú z postupnosti snímok im podobných, je možné tieto dáta znova doplniť, resp. nahradiť pomocou interpolácie z dát okolitých snímok. Ešte samozrejmejšie než v prípade impulzového šumu tejto interpolácii musí predchádzať *detekcia chýbajúcich dát*, resp. pozitívny výsledok tejto detekcie (kapitola 3).

*Simulácia škvŕn* v našich experimentoch sa realizovala aplikáciou naprogramovaného generátora náhodných skupín pixelov náhodných tvarov, pričom použitie farby čiernej alebo bielej bolo tiež náhodné. Počet škvŕn a ich veľkosti, a tým aj percentuálne poškodenie danej snímky boli nastaviteľné (ukážky sú na obr.2.3).




Obr.2.3 Ukážky simulovaného poškodenia obrazových sekvencií People a Susie – 22. snímka, 1%-né poškodenie (10-, 65- a 100-pixelové čierne a biele škvvrny).

Vybrané filtračné metódy pre odstránenie alebo potlačenie spomínaných znehodnotení budú uvedené v časti nasledujúcej po opise detekcie poškodenia.

### 3 Detekcia poškodenia

Cieľom opravy poškodeného obrazu alebo obrazovej sekvencie je potlačiť šum alebo nahradiť rozsiahlejšie miesta poškodenia. No pri aplikácii filtra bod po bode by nevyhnutne dochádzalo aj k skresleniu pôvodnej štruktúry obrazu, resp. snímok v dynamickej obrazovej sekvencii. Účinnnejšie je preto opravovať iba skutočne poškodené body alebo miesta. Nájsť takéto miesta je úlohou detektorov.



Obr.3.1 Filtrácia s využitím detektora poškodenia

Detekcia poškodenia logicky predchádza proces filtrácie/opravy, no úspešnosť detekcie v súčinnosti s opravou možno vyhodnotiť až po uskutočnení opravy. Preto niektoré výsledky v tejto kapitole je možné úplne pochopiť až po prečítaní častí o filtrácii a tiež o číselných kritériách kvality.

V prípade impulzového rušenia tomuto nežiadúcemu efektu možno zabrániť alebo ho aspoň výrazne potlačiť aplikáciou aj pomerne jednoduchého bloku detektora impulzov. Detektor (obr. 3.1) na základe porovnania lokálnych štatistických vlastností obrazu s vopred danými (alebo *adaptívne vypočítanými*) prahovými hodnotami rozhodne o prítomnosti, resp. neprítomnosti rušivého impulzu, a následne o filtrácii, alebo pokračovaní ďalej bez zmeny. Všeobecne, detektory s adaptívnym prahom môžu byť robustnejšie, no sú zároveň aj zložitejšie, než detektory s pevným prahom.

V [52], [72] a v ďalších článkoch sú uvedené návrhy aj výsledky experimentov viacerých typov detektorov impulzov. Ako vzťažnú hodnotu v prahovej diferencii využívajú lokálnu strednú hodnotu, smerodajnú odchýlku, lokálny kontrast, alebo entropiu, pričom do ich výpočtov niektoré zahŕňajú aktuálny prvok, niektoré nie, náročnejšie využívajú LUM-vyhladzovač, napr. [45] až [49] alebo fuzzy-logiku [75]. Zhrnutím výsledkov spomínaných mnohých experimentov by mohlo byť vyzdvihnutie pomernej jednoduchosti a účinnosti detektora SDV.

#### 3.1 SDV detektor impulzov

Tento detektor, ktorý možno zaradiť k adaptívnym, využíva smerodajnú odchýlku  $\sigma$  (Standard Deviation) hodnôt prvkov filtračného okna:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}, \quad \text{kde} \quad \mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.1)$$

Symbol  $n$  predstavuje počet prvkov v okne a  $\mu$  je stredná hodnota vypočítaná z týchto prvkov.

Keď aktuálne filtrovaný prvok označíme  $x^*$  a absolútnu hodnotu jeho rozdielu od strednej hodnoty  $\mu$  označíme  $C$ :

$$C = |x^* - \mu|,$$

potom rozhodnutie SDV detektora, či filtrovať ("1"), alebo nie ("0"), môžeme opísať pomocou nasledujúcej relácie:

$$\text{Ak } C \geq \sigma, \text{ potom "1"} \\ \text{inak "0"} \quad (3.2)$$

V prípade využitia detektora rušivých impulzov je namieste zaviesť aj parametre na posúdenie úspešnosti detekcie. Zvykne sa posudzovať percentuálny *podiel "falošných poplachov"*, alebo falošnej detekcie **MCL** (Miss Classification), a tiež percentuálny *podiel správne detekovaných impulzov* **SCL** (Success Classification) [73]. Ich matematická definícia je nasledovná:

$$MCL = \frac{\varepsilon_m}{MN - \eta} \cdot 100\% \quad (3.3)$$

$$SCL = \frac{\eta - \varepsilon_c}{\eta} \cdot 100\% \quad (3.4)$$

kde symbol  $\varepsilon_m$  znamená počet pixelov mylne vyhodnotených detektorom ako rušivé impulzy,  $\varepsilon_c$  je počet neobjavených impulzov,  $\eta$  je celkový počet rušivých impulzov a  $M, N$  sú rozmery obrazu.

V tabuľke 3.1 sú uvedené hodnoty chybových parametrov a parametrov *MCL, SCL*, ktoré ilustrujú účinnosť, resp. úspešnosť SDV detektora zaradeného pred mediánový filter s oknom 3 x 3, aplikovaný na ČB obrazy so simulovaným šumom [52].

Tab. 3.1 Účinnosť mediánového filtra 3 x 3 pracujúceho v spolupráci s SDV detektorom impulzov a úspešnosť detekcie charakterizovaná parametrami MCL (falošná detekcia), SCL (správna detekcia). i10 je šedý impulzový šum s 10-percentným výskytom, bw20 je ČB impulzový šum s 20-percentným výskytom, MAE je stredná absolútna chyba a MSE stredná kvadratická chyba.

Typ obrazu	Typ šumu	MF 3x3 bez detektora		MF 3x3 s detektorom SDV		MCL [%]	SCL [%]
		MAE	MSE	MAE	MSE		
Lena	i10	4,888	94,3	2,318	71,7	11,656	79,996
	bw20	5,580	147,0	2,676	120,2	4,953	93,736
Most	i10	8,042	173,7	3,876	123,4	13,565	76,726
	bw20	8,897	235,9	3,937	161,4	6,014	92,844

Využiť možnosť detekcie poškodenia impulzovým šumom je vždy dobrým riešením, a to aj v prípade viacrozmerých obrazových dát, teda vo farebných obrazoch a v obrazových sekvenciách.

**Vo farebných obrazoch a snímkach** možno pre detekciu impulzov využiť vektorovú reprezentáciu obrazových bodov, a z nej vyplývajúcu euklidovskú vzdialenosť medzi aktuálnym farebným vektorom  $x^*$  a vektorovým priemerom okna. Rozhodnutie o filtrácii, alebo "nefiltrácii" sa uskutoční na základe porovnania s vopred stanovenou prahovou hodnotou vzdialenosti. V [50] je naznačený takýto postup s prahom  $t = 50$  pre farebnú sekvenciu s 24 bitovou reprezentáciou farieb (8 bitov na farebný kanál).

### 3.2 Detekcia škvŕn v poškodenom archívnom filme

V prípade znehodnotenia snímkov vo videosekvencii väčšími zhlukmi pixelov, t. j. škvŕnami, je ich detekcia pred opravou dokonca nevyhnutná.

V tejto časti budú uvedené dva spôsoby detekcie poškodených miest v starých filmoch, zamerané na poškodenie typu "špina a iskrenie" [41]. Ide o škvŕny, ktoré z rôznych dôvodov prekryli alebo úplne zničili pôvodnú obrazovú informáciu na ploche väčšieho počtu pixelov (môže to byť aj niekoľko desiatok pixelov). Takéto poškodenie sa môže

označiť ako *chýbajúce dáta*, a filtrácia zameraná na reštauráciu filmu s cieľom opraviť spomínané miesta, ako *interpolácia chýbajúcich dát*.

Filtrácia, ktorá by do procesu spracovania zahrnula všetky – poškodené aj nepoškodené dáta bez rozdielu, by v tomto prípade ovplyvnila celkovú chybu ešte výraznejšie k horšiemu, než filtrácia impulzového šumu bez detektora. Preto je nutné poškodené miesta vopred detekovať, a opravovať len v prípade pozitívneho výsledku detekcie.

Detektory škvŕn využívajú fakt, že intenzita jasu poškodených miest je výrazne odlišná od jasu pixelov z blízkeho plošného aj časového okolia.

V [39a], [40], [41], [67] a v ďalšej literatúre je možné oboznámiť sa aj s niekoľkými ďalšími metódami detekcie. Zahŕňajú kompenzáciu pohybu, prípadne model Markovových náhodných polí [11], alebo 3-D autoregresívny model obrazovej sekvencie, a preto sú pomerne zložité.

### 3.2.1 Heuristický detektor škvŕn

Tento detektor [41] bol uvedený už v [70], [71] a **nepoužíva pohybovú estimáciu**, iba prahovú funkciu rozdielov aktuálnej snímky voči predchádzajúcej a voči nasledujúcej snímke:

$$e_b = I_n(\vec{r}) - I_{n-1}(\vec{r}) \quad (3.5)$$

$$e_f = I_n(\vec{r}) - I_{n+1}(\vec{r}) \quad (3.6)$$

$$D_{BBC} = \begin{cases} 1, \text{ if } (|e_b| > e_t) \text{ AND } (|e_f| > e_t) \text{ AND } (\text{sgn}(e_b) == \text{sgn}(e_f)) \\ 0, \text{ ináč} \end{cases} \quad (3.7)$$

Symbole  $I_n$ ,  $I_{n-1}$ ,  $I_{n+1}$  predstavujú jasové úrovne pixelov na rovnakých pozíciách v aktuálnej, predchádzajúcej a nasledujúcej snímke.  $e_t$  je chybový prah detektora, nastavený tak, aby odlíšil normálne úrovne jasu, "zapadajúce" do obrazu, od predpokladanej výrazne tmavšej, alebo výrazne svetlejšej úrovne škvŕn. Zhodné znamienko oboch rozdielov sa požaduje, aby nebol ako škvŕna falošne vyhodnotený prípad odkrývania alebo pohlcovania objektu. V prípade rýchleho pohybu môže dôjsť k falošnej detekcii, počíta sa však so zriedkavosťou týchto prípadov.

### 3.2.2 Detektor SDI

V [42] bol predstavený detektor impulzov SDI (*spike detection index*), ktorý je **pohybovo kompenzovaný**, to znamená, že jeho aplikácii predchádza estimácia pohybu v podobe pohybových vektorov  $\vec{v}_{n,n+1}(\vec{r})$ ,  $\vec{v}_{n,n-1}(\vec{r})$ , kde  $\vec{r}$  je aktuálna pozícia filtra. Pohybové vektory mapujú aktuálny obrazový prvok v predchádzajúcej ( $n-1$ ) a v nasledujúcej ( $n+1$ ) snímke. Potom definícia detektora SDI vyzerá takto:

$$e_1 = (I(\vec{r}, n) - I(\vec{r} + \vec{v}_{n,n-1}(\vec{r})))^2 \quad (3.8)$$

$$e_2 = (I(\vec{r}, n) - I(\vec{r} + \vec{v}_{n,n+1}(\vec{r})))^2 \quad (3.9)$$

$$D_{SDI} = \begin{cases} 1 & \text{pre } e_1 > t_1 \text{ AND } e_2 > t_1 \\ 0 & \text{ináč} \end{cases}, \quad (3.10)$$

kde  $t_1$  je prah. Pôsobenie tohto detektora na rozdiel od predchádzajúceho nezávisí od znamienka výsledku vyhodnocujúcich operácií (3.8), (3.9).

Na báze detektorov uvedených v tejto podkapitole bol navrhnutý detektor škvŕn realizovaný v súčinnosti s vybranými filtermi pre reštauráciu obrazových sekvencií, opísaný neskoršie v tejto knihe.



## 4 Filtračné metódy mediánového typu pre opravu a zlepšovanie obrazov a obrazových sekvencií

Táto publikácia je orientovaná na oblasť filtrácie s cieľom potlačiť rušenia impulzového typu v obrazoch a v dynamických obrazových sekvenciách. K impulzovému šumu možno v určitom zmysle (pri pohľade z časovej osi) prirovnať aj rušenie náhodnými škvrnami v snímkach archívnych filmových materiálov. Tieto znehodnotenia majú nelineárny charakter, a tomu zodpovedajú aj filtračné - nelineárne - techniky. Ako už bolo spomenuté, bude tu bližšie opísaná snaha obrazový materiál nielen čo možno najlepšie opraviť, ale aj čo možno najmenej ovplyvniť tie originálne miesta, ktoré sú neporušené. Druhú zo spomínaných úloh budú plniť *detektory impulzového šumu a škvŕn*, ktoré zabezpečia, že filtráciou (opravou) prejdú len tie miesta v obraze, ktoré sú skutočne poškodené.

Veľmi obľúbenými, široko rozpracovanými, rozvetvenými a pomerne vysoko účinnými technikami, zameranými na spomenuté ciele sa už dávnejšie stali filtračné metódy využívajúce poriadkové štatistiky obrazu (štatistiky jasových dát, resp. dát jednotlivých zložkových kanálov farebných obrazov a videí). Z poriadkových štatistík sa zatiaľ zrejme najväčšiemu záujmu teší *medián*, ktorý má, a to hlavne v spojení s ďalšími vylepšeniami, veľmi dobré filtračné vlastnosti práve v oblasti potlačania príliš "vyčnievajúcich" hodnôt, akými rušivé impulzy aj škvrny v snímkach sekvencie sú (v anglických odborných textoch z tejto oblasti dali týmto hodnotám priliehavý názov – *outliers*). Mediánové filtre boli štartovacou čiarou našej práce a spočiatku aj hlavným predmetom nášho záujmu v tejto oblasti. Ich vlastnostiam bude preto patriť niekoľko ďalších častí tejto kapitoly.

### 4.1 Mediánová filtrácia obrazu

Prvýkrát sa mediánová operácia na 1-rozmernom signáli, nazvaná „*bežiaci medián*“, objavila v publikáciách J.W.Tukeya [80], [79] z rokov 1974, 1977, ako *prostriedok na vyhladzovanie diskrétnych dát*. Odvtedy jej použitie bolo široko preskúmané a rozpracované mnohými autormi, z ktorých niektorí budú citovaní ďalej. Mediánový filter možno tiež nájsť v množstve praktických aplikácií - okrem kompozičných filtrov pre reštauráciu obrazov a obrazových sekvencií, aj vo vektorových mediánových filtroch pre potlačenie impulzového šumu vo farebných obrazoch, a pre odstránenie jasových a farebných presluchov v TV obrazoch, a tiež vo filtroch mediánového typu pri kódovaní obrazových sekvencií alebo pri konverzii medzi rozkladom v systéme klasickej televízie a HDTV.

Podrobný opis mediánových filtrov a filtrov mediánového typu, metód ich analýzy a opis ich vlastností možno nájsť vo viacerých odborných literárnych zdrojoch, napr. v [22], [63]. Tu bude uvedený len pomerne skrátenej prehľad pojmov, základných definícií a vlastností.

#### 4.1.1 Definícia

*Mediánový filter* pre spracovanie obrazu uskutočňuje nelineárnu filtračnú operáciu, pri ktorej *okno* s počtom vzoriek rovným nepárnemu celému číslu  $n = 2K + 1$  sa „posúva“ po vstupnom obrazovom signáli s krokom rovným jednej vzorke. Na každej pozícii sa vzorky z okna usporiadajú podľa veľkosti a centrálna hodnota, t.j. *medián*, sa stáva výstupom filtra na danej pozícii. Posun sa uskutočňuje obyčajne v rasti každej snímky zľava doprava v každom riadku, a vo vertikálnom smere zhora nadol. Filtrácia *okrajo-*

vých prvkov obrazu sa môže vyriešiť niekoľkými spôsobmi (doplniť chýbajúce vzorky v okne nulovými hodnotami, začať filtrovať až od vzorky, na ktorej je filtračné okno úplné, a pod.), v každom prípade však okraje po filtrácii nemožno zahrnúť do vyhodnocovania výsledku (*okrajový efekt*). V našich experimentoch sa okrajové pixely vynechávali z filtrácie aj z výpočtu kvalitatívnych kritérií.

Ak v okne máme  $n$  vzoriek  $x_1, x_2, \dots, x_n$ , potom mediánovú operáciu označíme

$$y = \text{med}[x_1, x_2, \dots, x_n] \quad (4.1)$$

kde  $y$  je výstupná hodnota mediánového filtra na aktuálnej pozícii.

*Medián* možno tiež chápať ako odhad centra distribúcie náhodnej veličiny  $x$ , vypočítaný na základe minimálnej sumy absolútnych odchýliek [22], [6], ako je uvedené v nasledujúcich riadkoch:

Majme veličinu  $\Phi(\beta)$ , ktorá je definovaná výrazom

$$\Phi(\beta) = \sum_{i=1}^n |x_i - \beta|^\gamma \quad (4.2)$$

Potom hodnota  $\beta$  minimalizujúca  $\Phi(\beta)$  pre  $\gamma=1$  je medián množiny  $x_1, x_2, \dots, x_n$ .

Účinnosť mediánu sa zvykne porovnávať so vzorkovým priemerom: *Vzorkový priemer*  $\bar{\beta} = \sum x_i/n$  pre  $i$  od 1 do  $n$  (minimalizuje  $\Phi(\beta)$ , keď  $\gamma=2$ ) je maximálne pravdepodobný odhad hodnoty veličiny  $x$  pre normálnu distribúciu (Gaussovu, alebo tiež distribúciu s krátkym koncom). Na rozdiel od priemeru *medián udáva maximálne pravdepodobný odhad v prípade Laplaceovej distribúcie* (distribúcie s dlhým alebo ťažkým koncom) [63], [6].

## 4.1.2 Vlastnosti mediánových filtrov

### a) Koreňový signál

V mediánovej filtrácii je výstupom vždy jedna zo vstupných vzoriek. Vďaka tejto skutočnosti výstup *opakovanej mediánovej filtrácie* pomerne rýchlo konverguje ku tzv. *koreňovému signálu*, t.j. signálu, ktorý je invariantný voči ďalšej filtrácii. V [88] je odvodený vzťah pre hornú hranicu konvergenencie ľubovoľného *1-D signálu dĺžky  $L$*  ku koreňovému signálu pri dĺžke okna  $2K+1$ ; takýto signál bude konvergovať ku koreňovému po maximálne

$$3 \left[ \frac{(L-2)}{2(K+2)} \right] \quad (4.3)$$

prechodoch mediánovým filtrom.

*Koreňovým signálom 1-D mediánových filtrov je 1-D signál zložený z lokálne monotónnych úsekov - hran, a z konštantných úsekov* (konštantného okolia). Konštantným okolím je úsek zložený z najmenej  $K+1$  bodov s identickou hodnotou pri dĺžke filtračného okna  $2K+1$ ; hranou je monotónna oblasť medzi dvoma konštantnými úsekmi, ktoré majú rôzne hodnoty.

Analýza koreňových signálov v 2-D a 3-D prípade je omnoho zložitejšia než v prípade 1-D signálov. V [17], [22], [21] je uvedený štruktúrny prístup pri návrhu a vyšetrení mediánových filtrov a filtrov mediánového typu s cieľom určiť typ a počet koreňových signálov, či každý signál je vyfiltrovaný na koreňový a ktoré štruktúry obrazu sú filtermi mediánového typu zachované, vytvárané, modifikované alebo zničené.

Praktickým výsledkom týchto analýz, potvrdených experimentmi, je poznanie, že *mediánový filter*

- odstraňuje impulzový šum
- pri nízkej úrovni vysokofrekvenčného šumu zachováva a tiež obnovuje hrany
- produkuje oblasti konštantnej alebo približne konštantnej intenzity, čo znamená vyhladzovanie detailov menších ako rozmer okna
- pri nízkom pomere signál/šum štandardný medián nie je schopný obnoviť hranu

Posledné dve vlastnosti sú nedostatkom štandardného mediánového filtra. S cieľom nezničiť užitočnú drobnú štruktúru obrazov, a s cieľom využiť jeho dobré vlastnosti aj pri vysokej úrovni šumu vznikalo ďalej veľa prác, a ako ich výsledky - rôzne modifikácie štandardného mediánu: mediánové filtre s detektormi impulzov [72], [73], [50], FIR mediánové hybridné filtre (FMH) s nízkou výpočtovou náročnosťou a s využitím lineárnych filtračných subštruktúr [9], rekurzívne mediány (RM) s koreňovým signálom po jedinom prechode [58], lokálne opakovaná FMH filtrácia [91] pre efektívne odstránenie šumu a zachovanie hrán aj pri nízkom pomere signál / šum, a ďalšie.

### **b) Prahová dekompozícia a vlastnosť nakladania**

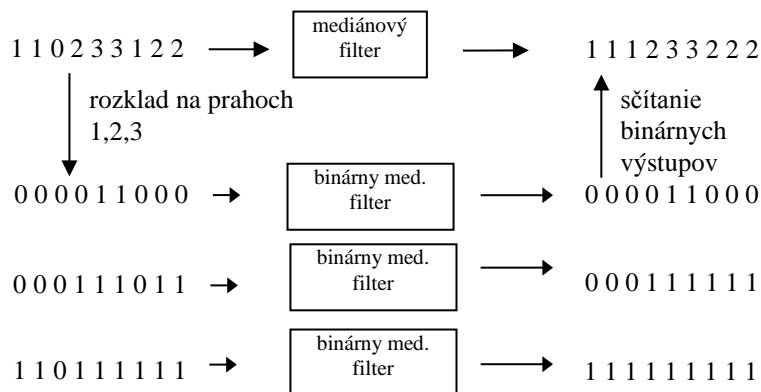
Mediánové filtre sú nelineárne, a tento fakt komplikuje ich matematickú analýzu. Vlastnosť superpozície, ktorá pri lineárnych filtroch umožňuje ich veľmi detailnú analýzu, pri mediánových filtroch neplatí. Preto pôsobenie filtra na signál a na šum nemôže byť skúmané oddelene ako u lineárnych filtrov. Štatistické vlastnosti mediánových (ale aj všeobecne rádových poriadkových štatistických) filtrov boli uvedené v mnohých prameňoch, napr. [63], [92], [43]. Zaujímavou (a pre návrh veľkej triedy *kompozičných filtrov* podstatnou) sa stala predovšetkým *prahová dekompozícia* ako metóda a ako „slabá superpozičná vlastnosť“, a na ňu naväzujúca vlastnosť „nakladania“ alebo stohovania (v angl.: *stacking property*).

*Prahová dekompozícia* [napr. 63] je rozklad viachodnotového číslicového signálu, s rozsahom hodnôt 0 až H, „prahovaním“ na H binárnych zložkových signálov (obr. 4.1). Každý z týchto signálov sa potom môže spracovať zvlášť, identickými štatistickými (*binárnymi*) filtermi, a po filtrácii, sčítaním jednotlivých zložiek opäť dostaneme viachodnotový, už vyfiltrovaný signál. Pri filtrácii ČB obrazu, alebo obrazu zodpovedajúceho jednej farebnej zložke, to znamená rozloženie obrazu na množinu binárnych obrazov, ich filtráciu a nakoniec ich sčítanie, kompozíciu. Pritom *výpočet mediánu v okne s binárnymi vzorkami možno zjednodušiť na zistenie počtu „1“*. Ak je tento počet väčší alebo rovný  $K+1$  (v okne s dĺžkou  $2K+1$ ), potom medián = 1, ináč je výstup rovný „0“.

*Vlastnosť nakladania*, súvisiaca s prahovou dekompozíciou, znamená, že pri pohľade na rozložený signál vždy nad stĺpcom jednotiek (stĺpec zodpovedá jednej vzorke signálu, rozloženej prahovaním) sa nachádza stĺpec samých núl (obr. 4.1).

Využitím prahovej dekompozície možno vlastnosti mediánových filtrov analyzovať v binárnej oblasti, čo je všeobecne jednoduchšie, pretože signál tu môže nadobudnúť iba dve hodnoty, a mediánová, resp. iné rádové-poriadkové operácie môžu byť uvažované ako logické operácie. Ľubovoľný mediánový, rádový-poriadkový alebo kompozičný filter je v binárnej oblasti opísaný pozitívnymi Booleovými funkciami a obsahuje len operácie AND a OR [63], [93]. Túto poslednú podobu spomínaných filtrov možno vý-


hodne využiť na ich realizáciu pomocou obvodov VLSI, napr. aj pomocou programovateľných hradlových polí [19].



Obr4.1 Ilustrácia mediánovej filtrácie s využitím prahovej dekompozície. V hornom riadku je vstupný 4-hodnotový signál filtrovaný obyčajným mediánom s 3-prvkovým oknom. Nižšie je vstupný signál rozložený na 3 binárne kanály, filtrované binárnymi mediánmi, ktorých výstupy po sčítaní dávajú opäť 4-hodnotový vyfiltrovaný signál.

### c) Vplyv filtračného okna

S tvarmi okien „bežiacieho mediánu“ sa už veľa experimentovalo a vo všeobecnosti možno uzavrieť, že čím viac prvkov filtračné okno obsahuje, tým sa dosahuje väčší vyhladzujúci efekt. Pri malom počte prvkov okna a vysokom stupni poškodenia (zašumenia) je však väčšie riziko, že sa na výstup dostane zašumená vzorka (impulz). Na filtráciu obrazov sa väčšinou používajú 2-rozmerné okná, najčastejšie v tvaroch +, × a v tvare úplného štvorca. Z dôvodu uvedeného vyššie, najväčší rozmer týchto 2-D okien býva rovný 3 prvkom (obr.4.2). Spomínané tvary sú výhodné kvôli zachovaniu hrán orientovaných v hlavných smeroch, na ktoré je ľudské oko najviac citlivé, a to v nasledujúcom poradí dôležitosti: vo vertikálnom, horizontálnom, prípadne vo dvoch hlavných diagonálnych smeroch.



Obr.4.2 Najčastejšie používané tvary filtračných okien mediánových fitrov

Porovnanie účinnosti rôznych tvarov a veľkostí filtračných okien použitých pri filtrácii, pri rôznom type obrazov a rôznej úrovni zašumenia možno nájsť napr. v tabuľkách uvedených v [52].

Uvedené poznatky z filtrácie statických obrazov sa uplatňujú aj pri voľbe filtračného okna pri filtrácii dynamických obrazových sekvencií.

## 4.2 Rôzne modifikácie štandardného mediánu, resp. kombinácia iných operácií s mediánom vo viacstupňových filtroch

V nasledujúcich odstavcoch budú uvedení zástupcovia alebo všeobecné formy niekoľkých vybraných veľkých skupín filtrov mediánového typu.

### 4.2.1 Vážený medián

Vo váhovej mediánovej (Weighted Median - WM) operácii je každej vstupnej vzorke  $x_i$  priradená nezáporná váha  $w_i$  z oboru celých čísel, pričom  $i=1,2,\dots,n$ , a súčet všetkých váh  $S_w = \sum_{i=1}^n w_i$  je obyčajne nepárny. (Výstup WM operácie nie je jednoznačne definovaný, ak suma všetkých váh je párne číslo.) Každá vstupná vzorka  $x_i$  je v množine vzoriek okna  $w_i$ -krát zopakovaná, a potom, po následnom usporiadaní vzoriek podľa veľkosti, sa vyberie medián. Operáciu opakovania (duplikácie) pritom môžeme symbolicky vyjadriť nasledovne:

$$w \diamond x = \underbrace{x, x, \dots, x}_{w\text{-krát}} \quad (4.4)$$

Váhová mediánová operácia potom bude:

$$y = \text{med}[w_1 \diamond x_1, w_2 \diamond x_2, \dots, w_n \diamond x_n] \quad (4.5)$$

Váhová mediánová operácia sa môže uskutočniť aj s pozitívnymi *reálnymi váhami* [88]. V takom prípade sa výstup vypočíta nasledujúcim spôsobom: Počnúc z ktoréhokolvek konca množiny vzoriek usporiadaných podľa veľkosti sa sčítavajú ich príslušné váhy až do sumy

$$S_w \geq \sum w_i / 2 \quad (4.6)$$

Potom váženým mediánom sa stáva vzorka zodpovedajúca poslednej váhe.

Ak

$$S_w = \sum w_i / 2 \quad (4.7)$$

potom WM nie je jednoznačný; výstupnou hodnotou filtra môže byť priemer dvoch vzoriek, pre ktoré platí (4.7).

Váhová mediánová operácia poskytuje väčšiu návrhovú voľnosť než štandardný medián. Keď sa spracúva viacrozmerný signál, možno pomocou nej obmieňať veľkosť a tvar okna (vzorky, ktoré nemajú patriť do okna, majú nulovú váhu), aj dôležitosť (váhu) každej vstupnej vzorky v okne.

Špeciálnym prípadom WM filtrov sú napríklad *idempotentné WM filtre*, t.j. konvergujúce ku koreňovému signálu už po 1. iterácii. Platí pre nich, že  $S_w$  musí byť nepárny, a zároveň

$$\mathbf{S}_w = 2\mathbf{w}^* + \mathbf{1} \quad (4.8)$$

kde  $w^* \geq 1$  je váha aktuálnej vzorky. Tieto filtre majú dobrú schopnosť odstraňovať impulzy a pritom zachovávať štruktúru obrazu.

Vlastnosti WM operácie boli podrobne analyzované napr. v [90], [92], [94] a súhrnne opísané tiež v [52].

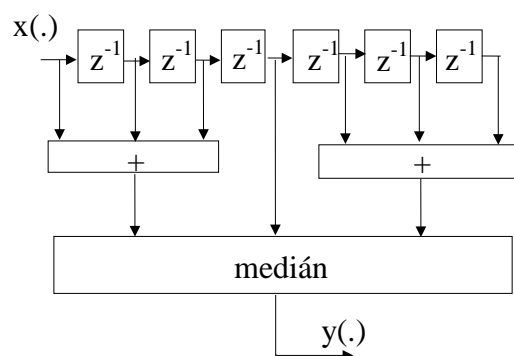
G.R.Arce vo svojom článku [6] opisuje možnosť použitia dokonca aj *záporných váh* pri váhovej mediánovej filtrácii. V tom prípade sa však medián vypočítava minimalizáciou vzťahu (4.2).

## 4.2.2 FIR mediánová hybridná operácia

Mediánová hybridná operácia typu FIR (Finite Impulse Response – konečná impulzová odpoveď) - *FMH*-filter - kombinuje požadované vlastnosti lineárnych operácií a mediánovej operácie [63], [30], [31], [32]. Filtračné okno sa rozdelí na nepárny počet subokien a v každom z týchto subokien sa použije filter FIR. Výstupom FMH operácie je medián vybraný z množiny výstupov subfiltrov (obr.4.3).

V snahe dosiahnuť dobré výsledky v rôznych aplikáciách možno postupovať tak, že sa obmieňajú typy FIR subfiltrov a celková štruktúra FMH filtra.

FMH filtre majú podobné štatistické vlastnosti a rovnaké typy koreňových signálov ako štandardný mediánový filter. Rozdiely spočívajú v počte operácií, vzhľadom ku ktorému je vo výhode operácia FMH, no táto operácia na rozdiel od štandardnej mediánovej generuje tiež nové signálové hodnoty. FMH operácia vo všeobecnosti nedokáže odstrániť impulzy tak účinne ako v rovnakom okne mediánová operácia.



Obr.4.3 Jednoduchá štruktúra FMH filtra s dĺžkou 7

Zaujímavou je skupina FMH filtrov, v ktorej sa ako subfiltre používajú priemerňujúce filtre. Tieto FMH filtre na rozdiel od mediánových v 1-D prípade nespôsobujú chvenie hrany (jitter), ak sa v jej blízkosti nachádza impulz; môžu len úroveň signálu pred hranou nepatrne posunúť.

Koreňové signály niektorých 2-D FMH filtrov boli analyzované v [56]. Dôsledným, presne zameraným návrhom FMH filtra možno docieľiť na jeho výstupe rôzne koreňové signály, napr. trojuholníkový alebo pílový priebeh [30].

## 4.2.3 Separovateľný mediánový filter

2-D separovateľný filter veľkosti  $n$  vznikne postupnou aplikáciou 1-D mediánového filtra s dĺžkou  $n$  najprv pozdĺž riadkov, a potom pozdĺž stĺpcov obrazu (alebo tiež aj v opačnom poradí):

$$\begin{aligned} z_{i,j} &= \text{med}[x_{i,j-K}, \dots, x_{i,j}, \dots, x_{i,j+K}] \\ y_{ij} &= \text{med}[z_{i-K,j}, \dots, z_{i,j}, \dots, z_{i+K,j}] \end{aligned} \quad (4.9)$$

Separovateľný mediánový filter s veľkosťou  $n$  má väčšiu výstupnú odchýlku než neseperovateľný, rozšírený na rozmer  $n \times n$ . Jeho hlavnou výhodou je jeho nízka výpočtová náročnosť v porovnaní s neseperovateľným. Usporiadáva totiž  $n$  čísel 2-krát, kým spomínaný neseperovateľný musí usporiadať  $n^2$  čísel [63].

#### 4.2.4 Rekurzívny mediánový filter

Intuitívnu modifikáciou mediánových filtrov môže byť použitie už vypočítaných hodnôt  $y_{i-K}, \dots, y_{i-1}$  pre výpočet výstupnej hodnoty  $y_i$ :

$$y_i = med[y_{i-K}, \dots, y_{i-1}, x_i, \dots, x_{i+K}] \quad (4.10)$$

Takýto filter sa nazýva *rekurzívny mediánový* (RM). Jeho výstup sa javí viac korelovaný než pri štandardnom mediáne, čo vyplýva z jeho rekurzívnosti. Rekurzívne mediánové filtre sú imúnnejšie voči impulzovému šumu než nerekurzívne [63].

Ďalšie vlastnosti rekurzívnych mediánových filtrov sú nasledovné: Signál je invariantný voči rekurzívnej mediánovej filtrácii vtedy a len vtedy, ak je invariantný aj voči štandardnej mediánovej filtrácii. Ľubovoľný signál je redukovaný na koreňový po jedinom prechode rekurzívnym mediánovým filtrom, *rekurzívne mediánové filtre sú teda idempotentné*. Získaný koreňový signál však nemusí byť rovnaký ako ten, ktorý by vznikol pri štandardnej mediánovej filtrácii.

Rekurzívne WM filtre tiež nie sú výhodou, pretože môžu poškodiť detaily v obraze.

Variáciou rekurzívneho mediánového filtra môže byť rekurzívny separovateľný mediánový filter, ktorý je účinnejší pri potláčaní impulzového šumu než nerekurzívny [18].

#### 4.2.5 Filter „max-median“ a viacstupňový mediánový filter

Snaha zachovať v obraze detaily (čiary a ostré uhly) orientované rôznymi smermi viedla k návrhu nasledujúcej štruktúry [63]:

$$y_{ij} = \max[z_1, z_2, z_3, z_4], \quad (4.11)$$

$$\text{kde } z_1 = med[x_{i,j-K}, \dots, x_{i,j}, \dots, x_{i,j+K}]$$

$$z_2 = med[x_{i-K,j}, \dots, x_{ij}, \dots, x_{i+K,j}]$$

$$z_3 = med[x_{i+K,j-K}, \dots, x_{ij}, \dots, x_{i-K,j+K}]$$

$$z_4 = med[x_{i-K,j-K}, \dots, x_{ij}, \dots, x_{i+K,j+K}] \quad (4.12)$$

Subfiltre  $z_1$  až  $z_4$  max-mediánového filtra teda zahŕňajú čiary v smere vertikálnom, horizontálnom, resp. v oboch diagonálnych smeroch, prechádzajúcich bodom  $(i, j)$ .

Operátor *max* zavádza do výstupného súboru hodnôt odchýlku smerom k vyšším jasovým úrovniam, čo možno zlepšiť jeho nahradením mediánovým operátorom. Výsledný filter potom bude *viacstupňovým mediánovým filtrom*, a ten sa pre svoju schopnosť zachovávať jemné detaily a zároveň potláčať šumy využíva, ako bude opísané ďalej, aj pri spracovaní dynamických obrazových sekvencií.

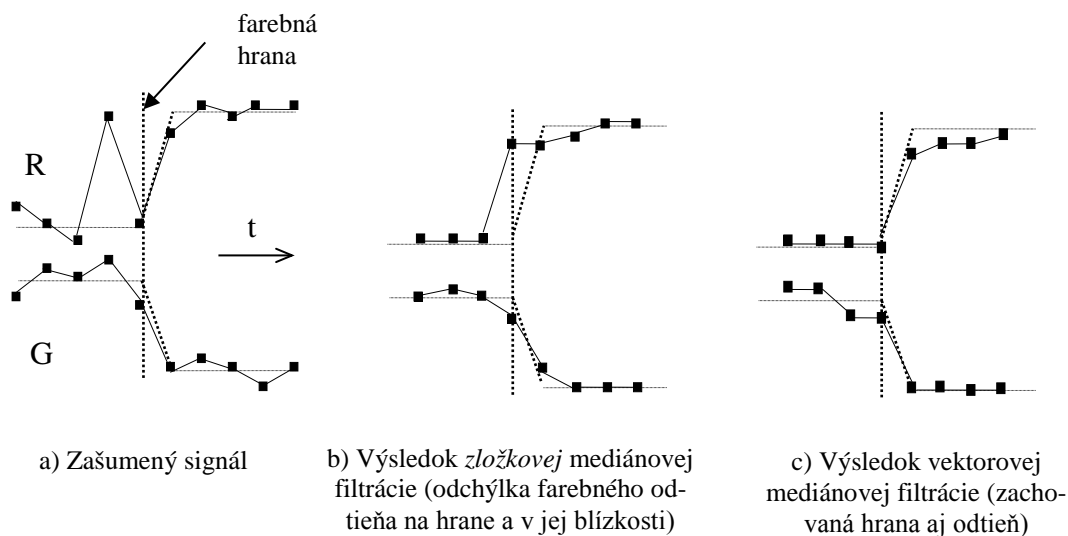
## 4.3 Mediánová filtrácia v oblasti farebného zobrazovania

### 4.3.1 Zložková versus vektorová filtrácia

Farebný obraz a obrazová sekvencia predstavujú *viaczložkový signál*, nazývaný tiež *vektorovým signálom*. Tento fakt poskytuje široké možnosti ich spracovania. Ich reprezentácia v priestore trichromatických zložiek, napr. RGB (viac pozri v kapitole 1), umožňuje spracovať každú ich zložku osobitne, identickými skalárnymi filtermi v každom kanáli (*zložkové*, nazývané tiež *marginálne filtre*). Pri vyjadrení v *polárnych súradniciach* ich zase možno spracovať ako postupnosti vektorov pomocou *vektorových filtrov*. Každý z menovaných spôsobov má svoje prednosti aj nedostatky.

Prirodzeným prístupom pri spracovaní farebných obrazov je *zložková filtrácia*. Bolo navrhnutých veľa filtrov mediánového typu pre potlačenie šumov v skalárnych (ČB) obrazoch a sekvenciách, a jednou z možností, ako filtrovať farebné obrazové materiály, je použiť *skalárne filtre* pre každú farebnú zložku signálu zvlášť [62], [61].

*Zložky farebného signálu sú však všeobecne korelované*, čo sa v zložkových filtroch nevyužíva ani nerešpektuje. Zložkové spracovanie farebnej obrazovej sekvencie preto spôsobuje problémy v blízkosti hrán (farebných prechodov) v obraze [7], [59]. Príkladom týchto problémov sú *nesprávne farby*, zapríčinené nezhodným posunom hrán v jednotlivých farebných kanáloch (obr.4.4), a *chvenie hrán (jitter)*.



Obr. 4.4 Porovnanie účinku zložkového mediánového a vektorového mediánového filtra s dĺžkou 3 v blízkosti zašumeného farebného prechodu. R - červená zložka, G - zelená zložka farebného signálu.

V oblasti reštaurácie a zlepšovania multispektrálnych obrazov sa ako výhodné ukázalo využitie korelácie medzi spektrálnymi zložkami [7], [2], [23], a začal sa výskum a experimenty s *vektorovými filtermi pre farebné obrazy, ktoré koreláciu medzi chromatickými zložkami zohľadňujú*.

V nasledujúcich podkapitolách budú uvedené definície a vlastnosti vektorových filtrov, a tiež vysvetlenie, prečo rozhodnutie medzi použitím zložkového alebo vektorového filtra nie je jednoznačné.



### 4.3.2 Vektorová a váhová vektorová mediánová operácia

*Vektorový mediánový (VM) filter* [7] uskutočňuje nelineárnu filtračnú operáciu, v ktorej sa filtračné okno „posúva“ po signáli, a na každej pozícii sa na výstupe filtra objaví jeden vektor, vybraný zo vstupnej množiny vektorov  $x_1, x_2, \dots, x_n$  podľa nasledujúcej definície:

*Vektorový medián*  $VM_{L_p}$  množiny vektorov  $x_1, x_2, \dots, x_n$  je vektor  $x_{vm}$ , ktorý spĺňa nasledovné:

$x_{vm} \in (x_i; i = 1, 2, \dots, n)$ , a pre všetky  $j = 1, 2, \dots, n$  platí:

$$\sum_{i=1}^N \|x_{vm} - x_i\|_p \leq \sum_{i=1}^N \|x_j - x_i\|_p \quad (4.13)$$

Symbol  $\|\cdot\|_p$  predstavuje všeobecne normu  $L_p$ , najčastejšie normu  $L_1$  alebo  $L_2$ .

Z uvedenej definície vidno, že VM-filtre **nemôžu** zaviesť do obrazu novú farbu, ktorá tam predtým nebola, čo je v niektorých aplikáciách dôležité (rušivo pôsobí, napríklad, zmenený, neprirodzený odtieň ľudskej pleti, a pod.).

Na základe vyššie uvedeného možno pokračovať, a definovať *váhový vektorový mediánový* (Weighted Vector Median - **WVM**) *filter* nasledujúcim spôsobom:

Ak máme množinu vektorov  $x_1, x_2, \dots, x_n$  vo filtračnom okne a im zodpovedajúce nezáporné váhy  $w_1, w_2, \dots, w_n$  z množiny celých čísel, potom  $WVM_{L_p}$  je vektor  $x_{wvm}$  taký, že

$x_{wvm} \in (x_i; i = 1, 2, \dots, n)$ , a pre všetky  $j = 1, 2, \dots, n$  platí:

$$\sum_{i=1}^N w_i \|x_{wvm} - x_i\|_p \leq \sum_{i=1}^N w_i \|x_j - x_i\|_p \quad (4.14)$$

kde  $\|\cdot\|_p$  predstavuje normu  $L_1$  alebo  $L_2$ .

Podľa definície je výstupom WVM filtra opäť jeden zo vstupných vektorov. Ako už bolo uvedené, má to svoju výhodu z hľadiska vernosti reprodukcie farieb. No z hľadiska účinnosti potlačania šumu sa práve táto „obmedzenosť“ výberu javí ako nevýhoda. To je následne dôvod, prečo *zložková filtrácia vo všeobecnosti lepšie potláča šum než vektorová*.

Spomínanú nevýhodu VM-operácie môžu odstrániť riešenia, ktoré kombinujú výhody VM-operácie v nezašumených oblastiach so schopnosťou iných filtračných postupov potláčať šum v prípade jeho prítomnosti. *Filtre, ktoré prispôbujú typy použitých filtračných techník charakteru obrazu a šumu*, tvoria spolu veľkú skupinu *adaptívnych filtrov*. Použitie WVM filtra s možnosťou zmeny váh tiež možno považovať za adaptívnu techniku.

Niekoľko takýchto kombinovaných riešení so zámerom potláčať šumy a zachovať, resp. zlepšiť hrany vo farebných obrazoch a obrazových sekvenciách je navrhnutých v [8], [81], [10], [12], [76].

### 4.3.3 Vektorové smerové filtre a sférický medián pre spracovanie farebných obrazov

Špeciálnou triedou vektorových filtrov sú *filtre smerové a sférické*. Pri týchto sa informácia o jase nezohľadňuje (spracúva sa oddelene); dôraz sa kladie na farebný odtieň, ktorý je spätý s uhlom vektora vo farebnom priestore, a všetky farebné vektory sa uva-

žujú s rovnakou dĺžkou. To teda znamená, že filtrovanými dátami sú buď uhly farebných vektorov (*vektorové smerové filtre*) alebo sférické súradnice bodov guľovej plochy (*sférické filtre*).

### Vektorové smerové filtre

Trieda vektorových smerových filtrov (**VDF** - vector directional filter) bola uvedená v [76], a potom v [77], [78], [38].

Základný VDF možno definovať nasledovným spôsobom:

Ak signál  $x$  je multikanálový (vektorový), t.zn. že je definovaný na  $c$ -rozmernom priestore  $Z_c$  (napr. trichromatický na 3-rozmernom priestore RGB), každej jeho vektorovej vzorke  $x_i$  vo filtračnom okne možno priradiť hodnotu  $\alpha_i$ , ktorá je daná:

$$\alpha_i = \sum_{j=1}^n A(\mathbf{x}_i, \mathbf{x}_j), \text{ pre } i \neq j \quad (4.15)$$

kde  $n$  je počet obrazových vzoriek vo filtračnom okne,  $A$  je uhol medzi farebnými vektormi  $x_i, x_j$  taký, že  $0 \leq A \leq \pi/2$ .

Potom usporiadaniu  $\alpha^{(1)} \leq \alpha^{(2)} \leq \alpha^{(3)} \leq \dots \leq \alpha^{(n)}$  zodpovedá usporiadanie  $\{x^{(1)}, x^{(2)}, x^{(3)}, \dots, x^{(n)}\}$ , a prvá z týchto vzoriek,  $x^{(1)}$ , ktorej zodpovedá najmenšie  $\alpha^{(1)}$ , je *smerovým mediánom*.

Teda, na aktuálnej pozícii vo farebnej snímke sa na výstupe *základného VDF* (basic VDF - **BVDF**) objaví ten zo vstupných vektorov, ktorý minimalizuje sumu uhlov, ktoré zvierajú so všetkými ostatnými vektormi v okne.

Užitočnou aplikáciou VDF môže byť tiež *zovšeobecnený VDF* (generalized VDF - **GVDF**), ktorého výstupom je množina prvých  $r$  vektorov s najmenšími sumami, teda  $\alpha^{(1)}$  až  $\alpha^{(r)}$ . Výstup GVDF možno následne spracovať ďalším filtrom, aby sme dostali jediný výstupný vektor. Tento ďalší krok by potom uvažoval už iba veľkosti vektorov  $x^{(1)}, x^{(2)}, \dots, x^{(r)}$ , pretože po spracovaní v GVDF tieto vektory majú vo vektorovom priestore približne rovnaký smer [77].

### Sférický medián

*Sférický medián* (**SM**) je definovaný ako bod na guľovej ploche (plocha konštantného jasú vo farebnom priestore), *pre ktorý suma dĺžok oblúkov ku ostatným bodom je minimálna* [78]. Vstupnými dátami SM-filtra sú dvojice sférických súradníc  $(\theta, \phi)$  zodpovedajúce jednotlivým bodom na sférickej ploche ("azimut a elevácia"). Dĺžky oblúkov medzi bodmi sa z týchto súradníc vypočítajú využitím matematických goniometrických výrazov:

Ak použijeme označenie  $(\lambda_i, \mu_i, \nu_i)$  pre usporiadanú trojicu  $(\sin\theta_i \cos\phi_i, \sin\theta_i \sin\phi_i, \cos\theta_i)$  zodpovedajúcu  $i$ -temu bodu na guľovej ploche, potom pre sumu dĺžok oblúkov (vzdialeností na povrchu gule) od bodu  $i$  ku všetkým ostatným  $j$ -tým bodom ( $j = 1, 2, \dots, n$ ) platí:

$$D(\lambda_i, \mu_i, \nu_i) = \sum_{j=1}^n \cos^{-1}(\lambda_i \lambda_j + \mu_i \mu_j + \nu_i \nu_j) \quad (4.16)$$

**Sférický medián teda zodpovedá výstupu filtra BVDF pre vektory s jednotnou veľkosťou. (Stále pritom platí, že výstupom musí byť jedna zo vstupných vzoriek.)**

Vektorové smerové filtre a sférické filtre teda na rozdiel od VMF, ktoré spracúvajú vzdialenosti medzi vektormi, pracujú s uhlami medzi vektormi. Z toho vyplýva, že výstup základného smerového aj sférického mediánového filtra leží uprostred vyhodno-

---

covanej množiny vzoriek (farebných odtieňov), zatiaľ čo pre výstup VMF to platiť nemusí.

Súhrn vlastností vektorových smerových filtrov je teda nasledovný:

- vektorové smerové filtre zachovávajú farebný odtieň
- VDF zachovávajú hrany (farebné prechody), pretože skoková funkcia je pre nekoreňovým signálom
- opakované použitie VDF konverguje ku koreňovému signálu
- VDF sú invariantné voči zmene mierky aj voči rotácii, t. zn., že tieto zmeny nemajú vplyv na uhol medzi dvoma vektormi. VDF však nie sú invariantné voči odchýlke.

## 4.4 Mediánové filtre pre opravu dynamických obrazových sekvencií

Rozšírenie digitalizácie do techniky videozáznamu, t. j. záznamu pohybu v snímanej scéne, rozšírenie množstva aplikácií videozáznamov v rôznych odborných oblastiach, aj v oblastiach laického (spotrebného) záujmu, znamenalo nárast objemu výskumu aj v oblasti digitálneho potlačania šumov, rušení a ďalších typov poškodenia v pôvodne digitálnych, ale aj v zdigitalizovaných dynamických obrazových záznamoch. Dôvody sú prirodzené - kvalita subjektívneho vizuálneho zážitku a možnosti pozorovania, no nie menej dôležité sú aj ďalšie dôvody - z nich najmä požiadavky na vstupné (nezašumené) dáta pre komprimačné a iné kódovacie metódy.

V tejto časti budú opísané metódy potlačania nelineárnych rušení v digitálnych dynamických obrazových sekvenciách, pričom uvedené filtračné techniky budú opäť založené na výhodných vlastnostiach výberu poriadkových štatistík, a nebudú obsahovať detekciu ani kompenzáciu pohybu.

### 4.4.1 Psycho-vizuálne hľadiská návrhu filtra

Ľudský zrak (*Human Visual System - HVS*), pre ktorý je väčšinou obrazová informácia určená, je zložitý systém, ťažko napodobiteľný nejakým efektívnym modelom. Má však svoje špecifické vlastnosti a schopnosti, odhadnuteľné pomocou číselných parametrov, a ich znalosť umožňuje niektoré zjednodušenia pri návrhu filtrov.

Je známa skutočnosť, že HVS má charakter dolnopásmového priepustu, a to v priestorovom aj v časovom rozmere. Pri detailnejšej analýze bolo zistené, že obe charakteristiky, priestorovo-frekvenčná aj časovo-frekvenčná majú duálnu povahu dolnopásmového, resp. pásmového priepustu. Priestorové frekvenčné charakteristiky sú čisto dolnopásmové pre časové frekvencie okolo 6 Hz alebo vyššie, a časové frekvenčné charakteristiky sú čisto dolnopásmové pre priestorové frekvencie okolo 6 cyklov/deg alebo vyššie. Preto, keď ľudský zrak nesleduje pohybujúci sa objekt v obrazovej sekvencii, javí sa tento objekt ako rozmazaný. Situácia je trochu odlišná, keď HVS sleduje pohybujúci sa objekt. HVS toleruje znížený pokles priestorového rozlíšenia pohybujúcich sa objektov, ak ich pohyb trvá krátko a neopakuje sa.

V prípade snímania scény pomaly sa otáčajúcou kamerou je viditeľnosť rozmazania približne rovnaká ako u nehybných obrázkov [69], [53], [26].

S výhodou sa pri návrhu filtrov využíva často aj fakt, že HVS je citlivejší na detaily v horizontálnom a vo vertikálnom smere než v iných smeroch, a preto sa dbá, aby spomínané detaily boli filtráciou zachované, resp. obnovené.

V súvislosti s farbou v obrazových sekvenciách tiež možno využiť vlastnosti HVS. Z toho pohľadu sa atraktívnou stále javí filtrácia v trichromatickom farebnom priestore, ktorý je podobný priestoru ľudského farebného vnímania, a kde je jednoduchšie zachovávať tie vlastnosti farebných obrazov, ktoré sú pre naše vnímanie dôležité. Zjednodušenie farebného priestoru predstavuje lineárny priestor CIE RGB [68], [81], no pre vyhodnocovanie farebných rozdielov, približujúce sa vnímaniu rozdielov ľudským okom, je potrebné použiť taký farebný priestor, v ktorom euklidovské vzdialenosti (- farieb) túto požiadavku spĺňajú. Viac o problematike farebných priestorov, ich vzájomných vzťahoch, ich vzťahoch k subjektívnemu vnímaniu a viaceré odkazy na zdrojovú literatúru sú uvedené v časti 1.

Filtre uvedené ďalej sú navrhnuté s cieľom úplne zachovať v obrazovej sekvencii stacionárne oblasti. V pohybujúcich sa oblastiach smú filtre spôsobiť malé znehodnotenie detailov, a to v prospech účinného potlačenia impulzového šumu.


#### 4.4.2 Priestorová, časová filtrácia a ich kombinácie

Mediánová filtrácia a všetky rádové poriadkové operácie umožňujú navrhnúť veľmi zaujímavé a výkonné metódy spracovania 1-D signálu. Rozšírenie počtu rozmerov signálu umožňuje rozšíriť aj možnosti riešenia jeho filtrácie.

Jednoduchá aplikácia mediánovej operácie s 3-D oknom však nie je veľmi výhodná. Takýto filter má rovnaké štatistické vlastnosti ako 1-D filter, avšak do určitej miery deformuje pohybujúce sa objekty [4], a pri vyššom počte vzoriek v okne treba počítať s tým, že rozmazáva detaily v štruktúre snímok. Preto sa hľadali iné metódy.

Možnosť použiť *priestorové filtre* - navrhnuté pre statické obrazy - je užitočná pri požiadavke kvalitných jednotlivých snímok. No tieto filtre, samozrejme, nezohľadňujú časovú koreláciu medzi snímkami, a pohyb, ktorý je jej prejavom, môžu poškodiť.

**Časový filter** (*temporal*) pôsobí kolmo na plochu snímky; jeho filtračná maska obsahuje obrazové body iba v smere časovom (tmavé políčka reprezentujúce pixely filtračného okna na obr.4.5). Jednoduchý mediánový časový filter potom vyberá medián z týchto prvkov.



Obr. 4.5 Filtračné okno a rovnica časového filtra

Zlepšenie vlastností časového filtra možno dosiahnuť zvýšením váhy aktuálneho prvku. Takýto WM časový filter (TWM) pri splnení podmienok (4.1), (4.2) patrí k idempotentným mediánovým filtrom, t.j. k takým, ktoré po jedinej aplikácii dávajú koreňový signál [52], [44]. Napr. filter TWM7 (4.17) je tiež *idempotentný*.

$$y_{i,j,n} = \text{med}\{x_{i,j,n-2}, x_{i,j,n-1}, 3 \diamond x_{i,j,n}, x_{i,j,n+1}, x_{i,j,n+2}\} \quad (4.17)$$

Časové filtre všeobecne dobre pracujú v smere, v ktorom sú orientované ich filtračné masky. T.zn. zachovávajú, prípadne vyhladzujú pohyb, no sú málo účinné pri potlačaní impulzového šumu. Ďalšou ich nevýhodou je, že zavádzajú značné deformácie do tých pohybujúcich sa oblastí, ktoré obsahujú čiary a iné jemné štruktúry [52], [5], [44].

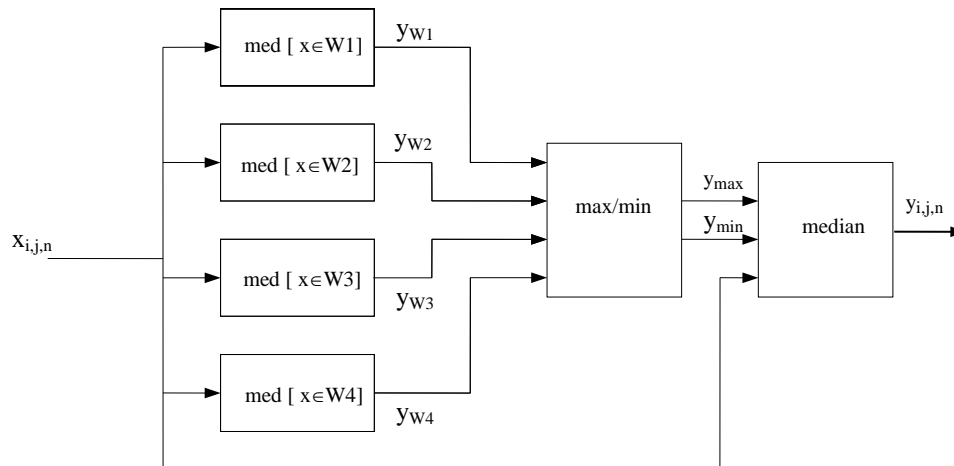
Takýto filter bol aplikovaný pri reštaurácii reálnej televíznej obrazovej sekvencie prijímanej zo satelitného vysielania [54].

Po nie veľkých úspechoch priestorových a časových filtrov sa úspešnou ukázala až ich kombinácia, orientovaná na zachovanie čiar (detailov) vo významných smeroch a zároveň úspešne potláčajúca impulzový šum. Týmito vlastnosťami sa vyznačujú filtre na-

zvané *viacstupňovými poriadkovými štatistickými filtermi MOS* (Multistage Order Statistic).

#### 4.4.3 Viacstupňové mediánové filtre


*Viacstupňová mediánová filtrácia* (Multistage Median Filtering - **MMF**) je metóda kombinácie výstupu základných subfiltrův, ktoré pracujú na prvom stupni kaskádovej filtračnej štruktúry (obr.4.6).



Obr.4.6 Viacstupňový poriadkový štatistický (MOS) filter

Tieto subfiltre sú navrhnuté tak, aby pôsobili na určitý druh štruktúry obsiahnutej vo filtračnom okne. V priestorovo-časovom chápaní každý subfilter je určený pre zachovanie vlastností jasových úrovní (úrovní šedej) len v jednom smere. Celý filter potom môže uchovať nejakú základnú vlastnosť dynamickej obrazovej sekvencie v ľubovoľnom smere, ak obsahuje všetky príslušné požadované subfiltre.

Podľa tvaru filtračných okien subfiltrův na prvom stupni možno vytvoriť dva rozdielne typy MOS-filtrův - jednosmerové, ak sú filtračné okná orientované len v jednom zo základných smerov, alebo dvojsmerové, ak sú orientované vo dvoch smeroch, z toho jedným je čas (obr.4.7). Túto myšlienku by bolo možné v podstate rozšíriť na definovanie podtried filterův, ktoré by uchovávali aj zložitejšie vlastnosti, no bolo zistené, že tieto rozšírenia znižujú schopnosť filtra potláčať impulzový šum [3], [56].



Obr.4.7 Filtračné okná viacstupňového poriadkového štatistického filtra jednosmerového - (a), a dvojsmerového - (b)

Filtrácia - výber výstupnej vzorky filtra  $y(x)$  na každej pozícii MOS-filtra v danej snímke - sa uskutočňuje podľa nasledujúcich vzťahov:

$$y(x) = \text{med}(y_{\max}, y_{\min}, x), \quad (4.18)$$

kde  $x$  je hodnota obrazovej veličiny na aktuálnej pozícii filtra,  $y_{\max}$ ,  $y_{\min}$  sú maximálna, resp. minimálna hodnota z výstupov všetkých subfiltrov na prvom stupni, čo sú mediány príslušných smerových filtračných okien  $W_i$ :

$$y_{\max} = \max(y_{W_i}, i = 1, \dots, l), \quad y_{\min} = \min(y_{W_i}, i = 1, \dots, l), \quad y_{W_i} = \text{med}(\text{všetky } x \in W_i) \quad (4.19)$$

V každom z týchto uvedených filtrov sa z príľahlých snímok do výberu použije vždy len jeden obrazový bod (na rovnakej plošnej pozícii, akú má aktuálny pixel), a to z dôvodu snahy vyhnúť sa prípadnému poškodeniu pohybu.

Na základe experimentov s využitím skúšobných obrazcov (s postupne rastúcou horizontálnou a vertikálnou priestorovou frekvenciou, a s rýchlosťami pohybu 1pixel/snímka a 4 pixely/snímka) a z porovnania parametrov MAE a MSE bolo zistené, že schopnosť potláčať šum a zachovávať horizontálne a vertikálne detaily majú jednodaj dvojsmerové MOS-filtre približne rovnakú, lepšiu než časové alebo priestorové filtre. Tendenciu zavádzať nové artefakty do obrazovej štruktúry však majú jednosmerové MOS-filtre výrazne najlepšiu (najmenšiu) [5].

Iným typom MMF sú *centrálne vážené mediánové MOS filtre (CWM-filtre)* (4.20) s nastaviteľnou celočíselnou váhou (opakovaním) aktuálnej vzorky  $x_{i,j,n}$  [39].

$$W_l[x_{i,j,n}] = \left\{ W[x_{i,j,n}] \cup \overbrace{x_{i,j,n} \cup x_{i,j,n} \cup \dots \cup x_{i,j,n}}^{2l\text{-krát}} \right\} \quad (4.20)$$

kde  $W_l$  je vážené a  $W$  nevážené okno na pozícii  $(i,j,n)$ .

Filtrácia sa potom uskutočňuje ako výber mediánu z najnižšej poriadkovej štatistiky, najvyššej poriadkovej štatistiky a z aktuálnej vzorky (centrálnej vzorky filtračného okna). Zmenou váhy je možné nastaviť stupeň vyhladenia filtra.

Ďalším, a veľmi úspešným typom MMF sú MOS filtre, ktoré na 2. stupni filtračnej kaskády vyberajú medián z aktuálnej vzorky a zo vzoriek na  $k$ -tom najnižšom a na  $k$ -tom najvyššom mieste v rade usporiadanom podľa veľkosti (4.21) [52], [47]. Výber  $k$ -tej a  $(m-k+1)$ -tej vzorky z usporiadaného radu  $m$  vzoriek v okne sa uskutočňuje na 1. stupni filtra.

$$y_{i,j,n} = \text{med}\{x_{(k)}, x_{i,j,n}, x_{(m-k+1)}\} \quad (4.21)$$

kde  $1 \leq k \leq m/2 + 1$ .

Tieto filtre sú známe pod názvom **LUM-filtre** (Median of a Lower statistic, an Upper statistic, and of the Medium samples). Vyššie uvedené CWM-filtre sú teda ich špeciálnym prípadom, keď  $k = m/2 + 1$ . Prvýkrát boli LUM-filtre uvedené v [39], [14]. Ladením parametra  $k$  tiež (ako u CWM -filtrov) možno nastaviť rôznu stupeň vyhladenia - od najväčšieho ( $k=1$ , pri počte  $m$  vzoriek vstupujúcich do výberu; dostaneme prakticky štandardný MMF), až po najmenšie ( $k=m/2+1$ ), keď sa jedná o identický filter.

---

Pomerne rozsiahlo sú spracované rôzne spôsoby zdokonalenia filtrácie statických obrazov pomocou LUM filtrov v prácach [45], [46], [47], [48], kde sú navrhnuté a experimentálne otestované LUM filtre s *adaptívnou* zmenou úrovne vyhladenia, ktorá sa prispôbuje lokálnym vlastnostiam obrazu. Riadenie úrovne vyhladenia sa podľa spomínaných návrhov môže uskutočniť pomocou neurónovej siete, využitím detektora impulzov spolu s neurónovou sieťou, alebo prahovaním.



## 5 Proces reštaurácie obrazových sekvencií poškodených škvrnami pomocou mediánových filtrov - viac prakticky

V súvislosti s archivovanými filmovými kópiami vystupujú okrem šumov do popredia aj škvrny výrazne tmavšej alebo výrazne svetlejšej intenzity jasú než susedné, pôvodné obrazové prvky (OP). Zvyknú sa nazývať "špinou a iskrením", čo ich vizuálny efekt dobre vystihuje. Ich pôvod je rôzny; môžu byť skutočne dôsledkom usadenej nečistoty, prachu, ale aj dôsledkom opakovanej manipulácie a premietania, tiež strihovými operáciami, a nakoniec aj starnutím, t.j. chemickými zmenami prebiehajúcimi bez akéhokoľvek zásahu človeka. Poškodenie typu "špina a iskrenie" je samozrejme často sprevádzané aj ďalšími vizuálne rušivými efektmi - väčšinou čiarami rôznych pôvodov a rôznych smerov.

V tejto časti bude uvedená metóda, ktorú sme navrhli pre elimináciu škvrn, ako aj jej vyhodnotenie na základe výsledkov experimentov.

V prípade vyššie uvedených typov poškodenia je ešte viac než pri potláčaní impulzového šumu dôležité najprv detekovať poškodené oblasti, až potom (v prípade pozitívneho výsledku detekcie) pristúpiť k ich oprave. Komplexná filtrácia celých snímok bez detekcie by mohla spôsobiť ešte väčšiu výslednú chybu, než bola pôvodná, čo nie je ťažké si predstaviť ani zdôvodniť.

### 5.1 Detekcia škvŕn v obrazových sekvenciách

Pre detekciu škvŕn v poškodenej archívnej dynamickej obrazovej sekvencii bolo vyvinutých viac metód spomenutých v kapitole 3.

V rámci našej metódy opravy poškodených ČB sekvencií, ktorá je predmetom tejto časti práce, bol vypracovaný pomerne jednoduchý a účinný postup detekcie pomocou *prahového detektora*. Pri jeho realizácii sa počíta s tým, že poškodené miesta (škvrny) predstavujú výraznú diskontinuitu nielen v plošnom, ale aj v časovom pohľade. To znamená, že jasová úroveň v tomto mieste je výrazne odlišná od tej, ktorá jej v čase predchádzala, aj od nasledujúcej, a to rovnako v prípade obrazu statickej scény, ako v prípade pohybujúceho sa objektu. Identifikovať túto odlišnosť je úlohou detektora, ktorého princíp činnosti možno opísať pomocou nasledujúcich relácií:

$$\text{AK } |x_{i,j,n} - x_{i,j,n-1}| > e_t \quad \text{A ZÁROVEŇ} \quad |x_{i,j,n} - x_{i,j,n+1}| > e_t, \quad (5.1)$$

POTOM filtrovať,


INÁČ ponechať bez filtrácie.

Vo vzťahoch (5.1) symbol  $e_t$  predstavuje hodnotu prahu, ktorá musí byť určená vopred. Princíp prahovej detekcie škvrn teda spočíva v matematickom porovnaní hodnoty jasú aktuálneho OP  $x_{i,j,n}$  s jasom OP na rovnakej pozícii v predchádzajúcej a nasledujúcej snímke. Ak rozdiel v absolútnej hodnote presahuje zvolenú prahovú hodnotu, je veľmi pravdepodobné, že daný pixel je súčasťou škvrny, a preto musí byť filtrovaný. Inak sa ponechá bezo zmeny a filtračné okno sa posunie na ďalší pixel.

Na rozdiel od detekcie v časti 3, netestuje sa znamienko rozdielu, čím je čiastočne ošetrený aj prípad zakrývania a odkrývania, keď objekt nemá príliš odlišnú jasovú hodnotu od okolia [41]. Pri väčšej odlišnosti ho detektor môže identifikovať ako škvrnu, no počíta sa s malou pravdepodobnosťou tohto posledne spomínaného javu.

V znehodnotených videosekvenciách (škvryni veľmi nízkej alebo veľmi vysokej jasovej úrovne) teda možno uvažovať tieto prípady:

- Škvryna (na obr. 5.1 čierna) je na pozícii  $x_{i,j,n}$  v aktuálnej snímke v rámci statického, alebo normálne (nie príliš rýchlo) sa pohybujúceho objektu (obr.5.1 - a,b). Obidva rozdiely  $|x_{i,j,n} - x_{i,j,n-1}|$  a  $|x_{i,j,n} - x_{i,j,n+1}|$  vo vzťahu (5.1) budú približne rovnaké a budú väčšie ako  $e_t$ . Detektor vyhodnotí prítomnosť škvryny.



(a)



(b) škvryna v prípade normálneho alebo žiadneho pohybu objektu (obr.a)

(c) škvryna v prípade pohlcovania alebo odkrývania objektu

Obr.5.1 Prípady detekovateľnej škvryny; biela farba - pozadie, sivá - objekt, čierna - škvryna, x - ten istý pixel v troch za sebou nasledujúcich snímkach

- Škvryna sa nachádza na mieste objektu, ktorý je postupne odkrývaný, alebo zakrývaný (obr.5.1 - c). Uvedené rozdiely budú rôzne, a detektor vyhodnotí škvrynu, len keď oba budú väčšie než nastavená úroveň prahu detektora. Je to problematický prípad. Čiastočne ho vyrieši doladenie prahu detektora, ale prípadný negatívny výsledok detekcie je vizuálne málo rušivý.
- Nedetekovateľný prípad, keď v predchádzajúcej alebo nasledujúcej snímke sa na rovnakej pozícii tiež nachádza pixel škvryny približne rovnakej intenzity. V takom prípade budú potlačené aspoň neprekrývajúce sa časti plôch škvŕn a zvyšné časti škvŕn ostanú nevyfiltrované.
- Prípad príliš rýchleho pohybu a prípad hrán pri normálnom pohybe. Detektor s filtrom vyrieši aspoň časť škvryny a výsledok je menej rušivý než pôvodná škvryna (obr.P1.3-d v prílohe -označená oblasť).

Efektivita uvedeného spôsobu detekcie aj s jeho nedostatkami je vyhodnotená na základe ďalej uvedených experimentov.

### 5.1.1 Voľba vhodného prahu detektora

Veľkosť prahovej hodnoty, na základe ktorej detektor vyhodnocuje prítomnosť, resp. neprítomnosť škvryny, súvisí so štatistickými charakteristikami jasovej úrovne v postupnosti snímkov. Uvažuje sa, že škvryny majú výrazne odlišnú úroveň jasov v porovnaní s jasom väčšiny obrazových bodov.

Určenie vhodnej veľkosti prahu môže vychádzať z nasledovného experimentálne-adaptívneho postupu, pri ktorom sa využije menšia časť sekvencie s tým predpokladom, že všetky snímky v danej sekvencii majú približne rovnaké štatistické parametre, t.j. priemerný jas a štandardnú odchýlku korešpondujúcu s kontrastom snímok.

Počiatočná úroveň prahu, ktorá sa použije pre detekciu pri filtrácii malej skupiny snímok, sa určí napríklad na základe vypočítanej štandardnej odchýlky (*std*) jasu danej sekvencie. Po filtrácii s detektorom realizovanej napr. najjednoduchším - časovým filtrom (obr.4.5) s nízkou počiatočnou hodnotou prahu sa vyhodnotia chybové parametre (MAE, MSE, prípadne aj "chyba pohybu"  $\Delta R$  – definícia všetkých sa nachádza v 7. kapitole). Prah detektora sa potom po malých krokoch zvyšuje, zakaždým sa filtruje a vyhodnocujú sa chybové parametre. Priebeh hodnôt chybových parametrov má najprv klesajúci, a po dosiahnutí určitej minimálnej hodnoty opäť stúpajúci charakter. Prah  $e_t$  zodpovedajúci minimálnym chybám môže byť použitý pre detekciu škvŕn v súčinnosti s ľubovoľným filtrom zvoleným pre filtráciu celej sekvencie.

V tabuľke 5.1 je zaznamenaná postupnosť hodnôt prahu detektora pre detekciu škvŕn v sekvencii Salesman, získaná testovaním v súčinnosti s časovým filtrom. Zvýraznená je najvyhovujúcejšia hodnota  $e_t = 40$ , pričom sa jedná o ČB sekvenciu s 256 úrovňovou jasovou škálou, priemernou hodnotou jasu približne  $\mu = 80$  a štandardnou odchýlkou približne  $std = 37$ .

Tab.5.1 Optimalizácia prahu detektora škvŕn na základe chybových kritérií časového filtra. Aplikované na ČB sekvenciu Salesman.

SALESMAN (8bit, $\mu=80$ , $std=37$ )				
Druh filtra	Prah $e_t$	MAE	MSE	$\Delta R$
Temporal+detektor	30	0.120	7..81	0.002
	35	0.114	7.66	0.002
	40	0.113	7.66	0.002
	45	0.116	7.87	0.003
	50	0.125	8.40	0.003

V prípade prechodu na inú obrazovú sekvenciu je potrebné urobiť nové nastavenie prahu.

Usudzovať o jednoznačnom priradení vhodnej úrovne prahu vzhľadom ku hodnotám spomínaných štatistických parametrov nie je možné, ako vidno z tabuľky 5.2. V rámci našich experimentov boli zvlášť nastavené úrovne prahu detektora škvŕn aj pre sekvencie Susie, Trevor a People.

Tab.5.2 Veľkosť prahu detekcie škvŕn pre ČB sekvencie s rôznymi štatistickými vlastnosťmi

sekvencia	Susie	Trevor	People	Salesman
$\mu$	111	77	96	80
<i>std</i>	37,5	39,5	39,3	36,7
prah $e_t$	55	30	70	40

Po pozitívnom výsledku detekcie škvŕn na danom mieste sa môže uskutočniť filtrácia – oprava škvŕn zvoleným filtrom.

## 5.2 Oprava škvŕn - hľadanie vhodnej filtračnej štruktúry

Škvŕny vyskytujúce sa v snímkach starých archívnych filmov a pôsobiace nie menej rušivo než impulzový, alebo aditívny Gaussov šum, možno označiť ako chýbajúce obrazové dáta. Tvoria ich skupiny viacerých (aj niekoľkých desiatok) obrazových prvkov OP, ktoré je potrebné nahradiť odhadom skutočných dát. Odhad sa môže uskutočniť viacerými zložitými rekurzívnymi alebo nerekurzívnymi estimačnými metódami, ale aj pomerne jednoduchým interpolačným spôsobom. Interpolácia znamená, že chýbajúce dáta sa doplnia novými dátami, s hodnotou vyskytujúcou sa uprostred veľkostí hodnôt okolitých OP, o ktorých sa predpokladá, že sú nepoškodené.

Pri filtrácii dynamickej obrazovej sekvencie sa nemôže prehliadať *zobrazovaný pohyb*, ktorého hladkosť by mala zostať zachovaná, resp. by mala byť obnovená. Snaha rešpektovať spomínanú požiadavku môže viesť ku komplikovaným filtračným metódam s kompenzáciou pohybu, kde filtrácii okrem detekcie škvŕn predchádza ešte výpočtovo viac- alebo menej náročná *estimácia pohybu*. Táto publikácia však nie je orientovaná na spomínané postupy. Pri filtrácii opísanej ďalej sa použili metódy využívajúce a rozvíjajúce poznatky získané z filtrácie impulzového šumu v statických obrazoch a obrazových sekvenciách pomocou výberových poriadkových štatistických filtrov, konkrétne filtrov mediánového typu.

Pokračovanie v rozvíjaní mediánovej filtrácie aj v oblasti potlačania škvŕn v obrazových sekvenciách má svoje logické opodstatnenie. Obrazové prvky, ktoré sú súčasťou rušenia typu "špina a iskrenie" sa totiž v smere kolmom na rovinu snímky javia ako impulzy, výrazne odlišné od hodnoty jasu *susedných pixelov*. Za susedné sa teraz považujú pixely na rovnakých pozíciách v predchádzajúcej a v nasledujúcej snímke. Predpokladá sa pritom, že zobrazovaná scéna sa príliš rýchlo nemení, a susedné pixely sú neporušené, s približne hladkým priebehom jasu. Susedné pixely teda môžu poslúžiť ako *báza* (t.j. filtračné okno vhodne zvoleného tvaru a veľkosti) pre výber mediánu nahradzujúceho rušivú hodnotu. Keďže ide vlastne o doplnenie chýbajúcich dát, dá sa hovoriť o *interpolácii*.

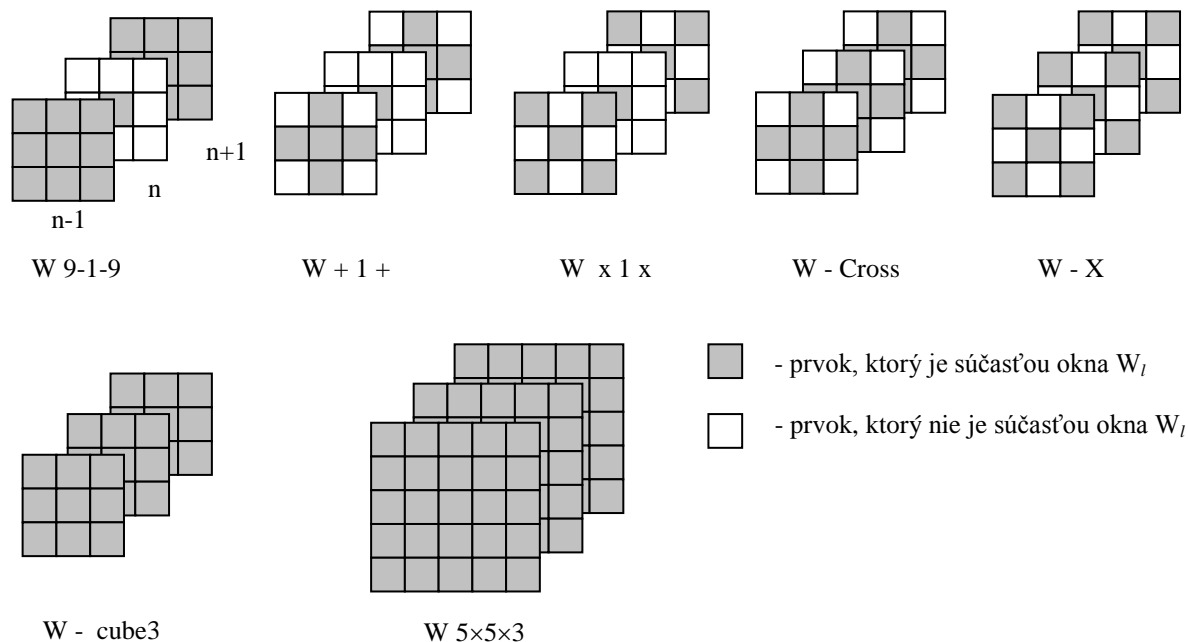
Podmienka zachovania hladkosti pohybu je v čo možno najväčšej miere rešpektovaná. Je testovaná súčasne s podmienkou odstránenia rušenia a s podmienkou zachovania hrán a detailov v snímkach.

### 5.2.1 Časový filter

Pohyb v dynamickej obrazovej sekvencii predstavuje objavenie sa rovnakej jasovej úrovne v bezprostredne susediacich snímkach na plošných pozíciách, ktoré sú navzájom vždy o niečo posunuté. Preto možno predpokladať, že mediánový filter s 1-rozmerným filtračným oknom orientovaným v smere času, t.j. kolmo na rovinu snímky - časový filter (*temporal*; obr.4.5), alebo tiež filtračná štruktúra  $W_5$  na obr. 5.4, ktorého vlastnosťou je zvýraznenie strmého prechodu úrovne signálu (pri malej dĺžke okna), by mohol odstrániť "vyčnievajúce hodnoty", t.j. pixely tvoriace škvŕnu alebo impulzové rušenie, no určite len v prípade, keby sa škvŕny v dvoch po sebe nasledujúcich snímkach neprekrývali. Zároveň však môže poškodiť štruktúru pohybujúcich sa objektov na snímkach. Z posledne uvedeného dôvodu je jednoduchý časový filter niektorými autormi zavrhaný už v úvode ich prác. Napriek tomuto argumentu bol aj tento filter zaradený do našich experimentov. Je jednoduchý, a mohol poslúžiť aspoň ako testovací pri návrhu pravej úrovne detektora škvŕn (časť 5.1).

## 5.2.2 Priestorovo-časové filtre

Priestorové<sup>1</sup> štruktúry filtračných okien v tvare "×" a "+", alebo v tvare niektorého zo segmentov ×, +, umožňujú zachovať alebo obnoviť hrany v snímke, orientované v príslušnom smere v prípade filtrácie impulzového šumu v statickom obraze. Dobré vlastnosti vykazovali v prípade impulzmi zašumených obrazových sekvencií, ako bolo



Obr.5.2 Filtračné okná základných priestorovo-časových mediánových filtrov

uvedené v časti 4.4. Preto sa zdalo zaujímavé zistiť ich správanie v prípade prítomnosti škvŕn v obrazovej sekvencii.

Podľa tvaru filtračných okien, tiež podľa realizovanej metódy a kvôli prehľadnosti možno testované filtre zdeliť do štyroch odlišných typov:

- a) základné priestorovo-časové (jednostupňové) mediánové filtre: Okná majú tvar podľa obr.5.2; medián sa vyberie zo všetkých prvkov vstupujúcich do okna:

$$y_{i,j,n} = \text{med}[x \in W_l] \quad (5.2)$$

kde  $W_l$  (pozn.<sup>2</sup>) je niektoré z priestorovo-časových filtračných okien a  $\text{med}[\cdot]$  je symbol pre operáciu výberu mediánu z prvkov vektora  $[\cdot]$ .

Názvy jednotlivých filtrov v ďalšom texte aj vo výsledkoch budú zhodné s označením filtračných masiek na obrázkoch.

<sup>1</sup>Pozn.: Pri špecifikácii filtra sa v anglickej terminológii používa slovo 'space' pre vyjadrenie priestoru v rámci jednej snímky. Preto aj do slovenčiny boli prevzaté názvy "priestorové" a "priestorovo-časové" filtre, ktoré sú už zaužívané.


<sup>2</sup>Pozn.: Relatívne pozície všetkých prvkov v príslušných filtračných maskách vzhľadom k aktuálnemu sú jasné z obrázkov. Ich uvádzanie vo vzťahoch pomocou zložitých indexov v tvare  $x_{i-1,j-1,n-1}$  a pod. by opis filtrov urobilo dosť neprehľadným, preto sa od neho v tejto publikácii upustilo.

- b) 2-stupňové mediánové priestorovo-časové filtre typu "1-okno-1". Symbol uvedené typu znamená, že z predchádzajúcej a nasledujúcej snímky sa do filtra berie len po jednom pixeli, a to  $x_{i,j,n-1}$ ,  $x_{i,j,n+1}$ , teda z plošnej pozície zhodnej s aktuálnou. Z aktuálnej snímky sa vyberú prvky niektorého typu plošného okna  $WS_{l,n}$  (obr.5.3). Výstupom  $y_{i,j,n}$  filtra je medián z mediánu "okna" a z prvkov  $x_{i,j,n-1}$ ,  $x_{i,j,n+1}$ :

$$z_{i,j,n} = \text{med}(x \in WS_{l,n})$$

$$y_{i,j,n} = \text{med}(z_{i,j,n}, x_{i,j,n-1}, x_{i,j,n+1})$$

(5.3)



Obr.5.3 Filtračné masky dvojstupňových časovo-priestorových mediánových filtrov typu "1-okno-1"


- c) 2-stupňový mediánový rozšírený filter(MF2): Výstupom filtra sa stáva medián z mediánov jednotlivých okien  $W_1$  až  $W_5$ , ktorých tvar je uvedený na obr.5.4:

$$y_{i,j,n} = \text{med}[med_i],$$

kde

$$med_i = \text{med}[x \in W_i] \quad \text{pre } i = 1, \dots, 5$$

(5.4)



Obr.5.4 Filtračné masky pre 2-stupňový rozšírený (MF2) a viacstupňový (MMF) mediánový filter

- d) viacstupňový mediánový filter (MMF). Je to vlastne filter mediánového typu, pretože okrem výberu mediánu, sa v ňom na nižších stupňoch uskutočňuje aj operácia výberu maxima a minima podľa algoritmu:

$$\begin{aligned}
 x_{\max} &= \max(\text{med}_1, \text{med}_2, \text{med}_3, \text{med}_4, \text{med}_5), \\
 x_{\min} &= \min(\text{med}_1, \text{med}_2, \text{med}_3, \text{med}_4, \text{med}_5), \\
 y_{i,j,n} &= \text{med}(x_{\max}, x_{\min}, x_{i,j,n}),
 \end{aligned}
 \tag{5.5}$$

kde  $\text{med}_i = \text{med}[x \in W_i]$ , pričom filtračné masky  $W_i$  sú rovnaké ako v prípade c (obr.5.4).

### 5.3 Oprava škvŕn – experimenty, výsledky

Všetky vyššie uvedené filtračné štruktúry sme testovali na štandardných ČB obrazových sekvenciách People, Salesman, Susie a Trevor (30 snímok,  $256 \times 256$  pixelov, 256 úrovni jasu), napr. [50b]. Ich poškodenie (snímka po snímke) bolo simulované softvé-



(a) Ilustrácia poškodenia sekvencie People

(b) Tá istá snímka po filtrácii najúspešnejšími filterami bez detekcie (vľavo) a s detekciou škvŕn

Obr.5.5 Ilustrácia k procesu simulovaného poškodenia a filtrácie sekvencie bez- a s detekciou škvŕn

rovým generátorom škvŕn navrhnutým v jazyku C, pričom, ako vidno z ukázkových obrázkov (napr. obr.5.5-a), simulované poškodenie bolo možno až trochu nadsadené. Znehodnotené bolo 1% pixelov každej snímky, pričom boli použité tri veľkosti škvŕn (10, 65, 100 pixelov) s maximálnou alebo minimálnou úrovňou jasu. Pozícia každej škvŕny, jas, veľkosť aj tvar boli náhodné; vopred bol zvolený počet jednotlivých typov škvŕn.

Filtrácia sa uskutočnila pre porovnanie bez detekcie aj s detekciou škvŕn. Filtrovalo sa so všetkými filtračnými štruktúrami uvedenými v časti 5.2.2. Detektor pracoval na princípe uvedenom v časti 5.1.

Odstánenie rušivých efektov a zachovanie štruktúry snímok sa vyhodnocovalo vizuálne a na základe strednej absolútnej a strednej kvadratickej chyby pre celú sekvenciu. Definičné týchto chybových parametrov sú uvedené v 7. kapitole. Podľa kritéria  $\Delta R$  (vzťah 7.15) sa vyhodnocovalo zachovanie / nezachovanie pohybu v sekvencii, pričom menšia hodnota  $\Delta R$  predstavovala z tohto hľadiska "šetrnejšiu" metódu.

Hodnoty spomínaných číselných parametrov všetkých uvedených experimentov sú usporiadané v tabuľkách v prílohe.

Do nižšie uvedenej tabuľky 5.3 boli vybrané výsledky najúspešnejších filtrov bez detektora škvŕn a s detektorom, čo umožňuje ich najrýchlejšie porovnanie a tiež vyvodenie záverečných vyhlásení. Tučným písmom sú zvýraznené hodnoty najmenších chýb

MAE, MSE,  $\Delta R$  pre danú sekvenciu, zvlášť pre filtre bez detektorov a zvlášť s detektormi škvŕn. Za najúspešnejšie boli určené filtre, ktoré mali aspoň dva z troch kvalitatívnych parametrov najnižšie v porovnaní s ostatnými filtrami.

Prah detekcie bol nájdený procesom opísaným v časti 5.1 pre každú sekvenciu osobitne. Podrobné tabuľky s výsledkami všetkých filtrov a ukážky jednej snímky originálnej, poškodenej a filtrovanej bez- a s detekciou pre všetky sekvencie sa nachádzajú v prílohe 1.

Ako je možné vidieť už z tab.5.3, predpokladaný neúspešný **časový filter (temporal) bez detekcie** v porovnaní s ostatnými nebol najhorší. Bez detekcie škvŕn pri hodnotení zachovania pohybu mal relatívne najmenšiu chybu (najmenšiu v dvoch zo štyroch sekvencií, pri ostatných dvoch bol na druhom alebo treťom mieste), v hodnotách MAE, MSE bol na druhom mieste (príloha 1).

Podľa očakávania, **bez detekcie** škvŕn bol relatívne najlepší filter viacúrovňový mediánový (MMF), a to pri vyhodnotení parametrov MAE, MSE bez konkurencie. Pri vyhodnotení pohybu boli tieto filtre trochu menej úspešné, čo sa tiež dalo očakávať, pretože ich filtračné masky boli pôvodne navrhnuté hlavne so zameraním na zachovanie plošnej štruktúry snímok.

No výsledok filtrácie bez detekcie škvŕn asi nemožno vôbec považovať za skutočne úspešný pri žiadnom z uvedených filtrov (napr. obr. 5.5-b).

Tab.5.3 Komplexné porovnanie filtrácie sekvencií najúspešnejšími filtrami bez detekcie a s detekciou škvŕn

		Sekvencia (prah detekcie)											
		People (70)			Salesman (40)			Susie (55)			Trevor(30)		
		MAE	MSE	$\Delta R$ [.10 <sup>-3</sup> ]	MAE	MSE	$\Delta R$ [.10 <sup>-3</sup> ]	MAE	MSE	$\Delta R$ [.10 <sup>-3</sup> ]	MAE	MSE	$\Delta R$ [.10 <sup>-3</sup> ]
Typ filtra bez det.	MMF	<b>3,507</b>	<b>69,3</b>	69,20	<b>1,223</b>	<b>14,7</b>	7,09	<b>1,289</b>	<b>18,6</b>	<b>12,50</b>	<b>0,801</b>	<b>6,8</b>	2,66
	Temporal	4,214	86,5	<b>68,56</b>	1,982	20,5	<b>5,63</b>	1,607	22,0	12,67	1,113	8,5	<b>2,54</b>
	W5×5×3	8,232	162,4	95,94	6,468	133,0	13,06	4,345	55,0	19,08	4,737	62,0	6,26
	Cross	5,817	96,0	83,45	2,571	24,5	9,73	2,902	30,7	16,28	2,270	16,6	4,52
Typ filtra s det.	MMF+det.	0,329	20,50	3,68	0,119	7,66	2,34	0,132	8,62	3,88	0,067	3,53	1,19
	Temp.+det.	0,335	21,44	3,64	<b>0,113</b>	7,66	2,30	0,133	9,14	3,93	<b>0,061</b>	3,65	1,27
	W5×5×3+d.	<b>0,302</b>	<b>17,84</b>	<b>3,22</b>	0,139	7,66	2,45	<b>0,120</b>	<b>6,31</b>	<b>3,56</b>	0,101	4,67	1,20
	Cross+det.	0,310	19,22	3,51	0,114	<b>7,25</b>	<b>2,20</b>	0,123	7,75	3,80	0,071	<b>3,35</b>	<b>1,10</b>

Všeobecne možno skonštatovať, že **po zaradení detektora škvŕn** pred filtre sa efektívnosť každého z nich výrazne zlepšila. V prípade MAE to znamená rádovo 10<sup>1</sup> a v prípade MSE rádovo 10<sup>0</sup>. V prípade parametra  $\Delta R$ , ktorým bola vyhodnocovaná zmena pohybu, sa zlepšenie tiež prejavilo, ale relatívne v trochu menšej miere.

Ako sa dalo predpokladať, detekcia najviac pomohla plošne najčlenitejšej a najdynamickejšej sekvencii People (obr. 5.5b).

Keď sa porovnajú výsledky jednotlivých filtračných štruktúr v súčinnosti s detektorom škvŕn, sú prekvapivo navzájom pomerne málo odlišné, menej než pri filtroch bez detekcie. Predsa však - najlepšie výsledky (s detekciou škvŕn) dosahovali striedavo filtre **Cross** (tvar okna "+" vo všetkých troch časových úrovniach) a **W5×5×3**. Úspešnosť posledného z menovaných filtrov je menším prekvapením, keďže sa očakával prevažujúci nepriaznivý vplyv jeho vyhladzujúcich účinkov. Zrejme plošné okno 5 × 5 nie je "až také veľké", ako sa predpokladalo, a v prípade skutočných sekvencií s väčším počtom pixelov už vôbec nie.



Pri **vizuálnom posúdení účinnosti filtrácie s detekciou** vyzerajú snímky takmer neporušené, na rozdiel od neprijateľného degradačného efektu filtrácie bez detekcie. No na snímkach, aj pri ich postupnej projekcii, vidno ešte zbytky škvŕn. Pri dôkladnej vizuálnej analýze sa zistilo, že v niektorých prípadoch išlo o tie najväčšie škvŕny, v niektorých o škvŕny, ktoré sa svojím jasom príliš nelíšili od svojho okolia, a nakoniec o prípad škvŕny pokrývajúcej čiary s podobným jasom v obraze scény.

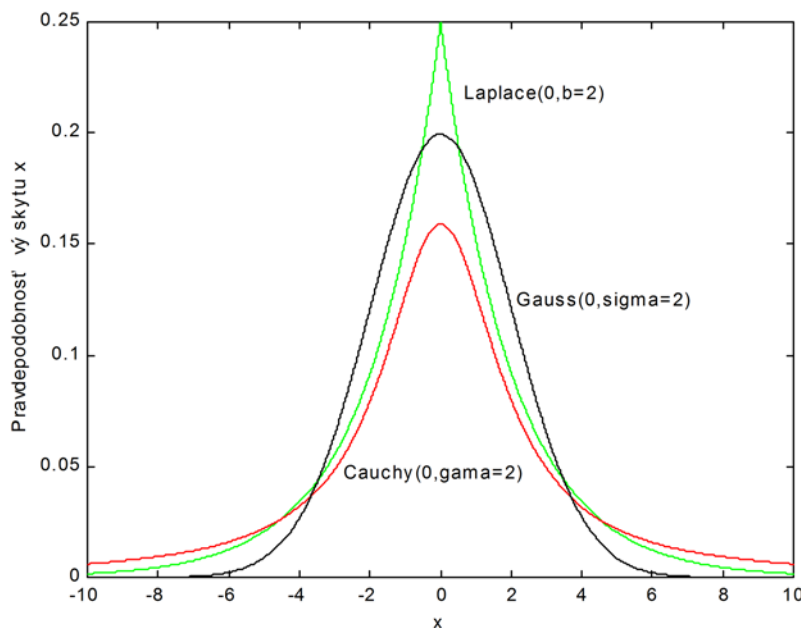
#### **5.4 Oprava škvŕn - záver**

Z uvedených poznatkov vyplýva niekoľko záverov:

- Filtrácia bez detekcie nemá zmysel, čo je potvrdením už pomerne známej skutočnosti.
  - Niektoré zvyšné škvŕny je zrejme potrebné odstrániť individuálne, špeciálnym prístupom.
  - V prípade použitých štandardných sekvencií sa absencia zložitejšieho odhadu pohybu neprejavila, t.zn. že v tomto smere bol filtračný proces s detekciou škvŕn celkom uspokojivý.
- Nie je možné jednoznačne rozhodnúť o najlepšej filtračnej štruktúre v spojitosti s vyššie uvedenou metódou rekonštrukcie** (príloha 1). Časový filter s detektorom naozaj v súlade s predpokladom mal najhoršie, alebo relatívne zlé výsledky. V prípade sekvencií s výrazným pohybom hrán a drobnou štruktúrou v ploche snímok bol najhorší, a v týchto prípadoch bol najlepší filter **W5×5×3 s detektorom** (okno filtra obsahuje najviac pixelov zo všetkých troch zúčastnených snímok v porovnaní s ostatnými filtračnými oknami). Pri priemerných sekvenciách, čo sa týka pohybu a množstva detailov, má relatívne najlepšie výsledky filter **Cross s detektorom**.

## 6 Myriadové filtre pre potláčanie šumu

V predchádzajúcich častiach opisované mediánové filtre s ich pomerne dobrou účinnosťou pri potláčaní impulzového šumu, sú najvhodnejšie pre predpokladané Laplaceovo rozdelenie hodnôt náhodnej premennej. Toto rozdelenie (obr.6.1) so svojím "špicatým" priebehom je však pravdepodobne len fikciou reálneho rozdelenia. Pre opis rozdelenia šumových dát v bezdrôtových komunikačných kanáloch, s impulzovým typom rušenia, sa zdajú vhodnejšie - prirodzenejšie - rozdelenia s priebehom v tvare zvona [27], [28]. Z



Obr.6.1 Porovnanie Cauchyho, Gaussovho a Laplaceovho rozdelenia pravdepodobnosti

nich konkrétne Cauchyho rozdelenie, ktoré má podobne ako Laplaceovo, tzv. „široké krídla“, alebo „ťažké konce“ (t.zn. ešte dosť výraznú početnosť okrajových hodnôt štatistického súboru, vid' obr.6.1).

Skupina týchto symetrických rozdelení, do ktorej patrí aj Gaussovo rozdelenie, má spoločný názov - *alfa stabilné rozdelenia*, a matematickú definíciu charakteristickej funkcie [28], [25]:

$$\phi(\omega) = e^{-\gamma|\omega|^\alpha} \quad (6.1)$$

Parameter  $\gamma > 0$ , sa zvykne označovať ako *disperzia* (rozptyl) - súvisí so škálou rozdelenia ( $\gamma^{1/\alpha}$  je parametrom škály) - a parameter  $\alpha$  je *charakteristický exponent* funkcie rozdelenia hustoty.

Alfa je z intervalu 0 až 2 a určuje úroveň obsahu impulzov v signáli, alebo tiež váhu okrajových častí rozdelenia, od najväčšej po najmenšiu. Pri hodnote  $\alpha = 2$ , ide o Gaussovo rozdelenie s nulovou strednou hodnotou a smerodajnou odchýlkou  $2\gamma$ , o ktorom je známe, že šumy s týmto rozdelením možno účinne potlačiť pomocou lineárnych filtrov. Pre hodnoty  $\alpha < 2$ , ide o rozdelenia s nekonečnou smerodajnou odchýlkou, ktoré sú rozdeleniami impulzových rušení (a pre ktoré sú už lineárne filtre nevhodné).

Pre hodnotu  $\alpha = 1$  je charakteristická funkcia rozdelením vhodným pre aproximáciu impulzmi veľmi znehodnoteného signálu, a zodpovedá *Cauchyho rozdeleniu* okolo strednej hodnoty  $\beta$  (čiže okolo parametra lokalizácie, alebo najpravdepodobnejšej hodnoty premennej):

$$f(x) = \frac{\gamma}{\pi} \cdot \frac{1}{\gamma^2 + (x - \beta)^2} \quad (6.2)$$

Pre hodnoty  $\alpha \neq 1$ ,  $\alpha \neq 2$ , nie je definované žiadne známe rozdelenie.

Teda všetky alfa-stabilné rozdelenia majú niekoľko spoločných vlastností: sú hladké, unimodálne, symetrické okolo modusu a majú zvonový tvar. Využitie alfa-stabilných rozdelení sa už v posledných rokoch uplatnilo vo viacerých vedných oblastiach - v hydrológii, ekonómii, fyzike, strojárstve, a v poslednej dobe sa mu venuje pozornosť aj v oblasti komunikácií a spracovania signálov [28].

Filtrácia signálu s impulzovým šumom by sa takto mohla realizovať prostredníctvom optimalizácie Cauchyho pravdepodobnostnej funkcie dostal názov *myriadový filter* z dôvodu, ktorý vyplynie z nasledujúceho textu, na konci tejto podkapitoly.

## 6.1 Definícia

Estimátor založený na využití Cauchyho pravdepodobnostnej funkcie dostal názov *myriadový filter* z dôvodu, ktorý vyplynie z nasledujúceho textu, na konci tejto podkapitoly.

Ak uvažujeme množinu  $N$  nezávislých identicky distribuovaných (*i.i.d.*) vzoriek veličiny  $x$ , ktoré označíme  $\{x_1, x_2, \dots, x_N\}$ , potom všeobecný vzorec pre hustotu pravdepodobnosti *Cauchyho rozdelenia*  $x$  je:

$$f(x; \beta) = \frac{1}{\pi} \frac{K}{K^2 + (x - \beta)^2} \quad (6.3)$$

kde  $\beta$  je parameter polohy (na stupnici  $x$ ) a  $K > 0$  je škálový - riadiaci parameter.

Potom výstup *myriadového filtra* je hodnota  $\beta = \beta_{MyK}$ , ktorá na základe teórie pravdepodobnosti [66] *maximalizuje funkciu vierohodnosti* (likelihood function)  $L(x, \beta)$  odpovedajúcu vyššie uvedenej  $f(x, \beta)$ . Funkcia  $L(x, \beta)$  má tvar podľa súčinového vzťahu:

$$L(x_1, x_2, \dots, x_N; \beta) = \prod_{i=1}^N f(x_i; \beta) \quad (6.4)$$

Keď sa zohľadní (6.3), potom hľadanie maxima funkcie  $L$  je ekvivalentné minimalizácii výrazu, ktorý je vhodné nazvať *objektívnou funkciou myriadového filtra*:

$$G_K(\beta) = \prod_{i=1}^N [K^2 + (x_i - \beta)^2] \quad (6.5)$$

To všetko za predpokladu, že  $K > 0$ .

S ohľadom na (6.5) možno teda výstup myriadového filtra  $\beta_{MyK}$  (pre okno s  $N$  vzorkami) definovať tiež ako

$$\beta_{MyK} = \arg \min_{\beta} G_K(\beta) \quad (6.6)$$

Riešenie (6.6) je extrémom objektívnej funkcie  $G_K$ , a preto ho možno nájsť známym spôsobom, pomocou prvej derivácie  $G_K$  podľa  $\beta$ :

$$\partial G(\beta) / \partial \beta = 0$$

Keby sme hneď v úvode maximalizácie funkcie vierohodnosti  $L$  použili metódu jej hľadania pomocou maximalizácie jej logaritmu, čo neovplyvňuje výsledok [66], dostali by sme podmienku:

$$\beta_{MyK} = \arg \min_{\beta} \sum_{i=1}^N \ln[K^2 + (x_i - \beta)^2] \quad (6.7)$$

Z (6.7) vyplýva, že výstup myriadového filtra minimalizuje súčet „logaritmickej štvorcov“, a takáto estimácia by mala výraznejšie potláčať vplyv chýb spôsobených impulzmi, než metóda najmenších štvorcov (lineárna), čo je už známe, ale aj než metóda najmenšieho súčtu absolútnych odchýliek (výber mediánu), ako vyplynie z ďalšieho textu.

## 6.2 Vážený myriadový filter


Robustnosť filtra sa dosiahne, ak sa všetkým vzorkám  $x$  vo filtračnom okne priradia vhodné váhy  $w_1, w_2, \dots, w_N$ . Definícia *váženého myriadového filtra* je potom založená na parametri  $\beta_{MyK,w}$ , ktorý minimalizuje objektívnu funkciu  $G_K(\beta, w, x)$  definovanú podobne ako v (6.5). Takže

$$\beta_{MyK,w} = \text{myriad}\{K, w_1 \circ x_1, w_2 \circ x_2, \dots, w_n \circ x_N\} = \arg \min_{\beta} G_K(\beta, w, x) \quad (6.8)$$

pričom váhová objektívna funkcia  $G_K(\beta, w, x)$  vyzerá takto:

$$G_K(\beta, w, x) = \prod_{i=1}^N [K^2 + w_i (x_i - \beta)^2] \quad (6.9)$$

Vo výraze (6.8) zápis  $w_i \circ x_i$  pre  $i = 1, 2, \dots, N$  predstavuje aplikáciu váhy  $w_i$  na vzorku  $x_i$ . Váhy musia byť nezáporné; záporné by viedli k potenciálnej nestabilite filtra.



Obr.6.2 Typický priebeh myriadovej objektívnej váhovej funkcie (6.9) pre 7 vážených hodnôt  $x$  a pre tri rôzne hodnoty linearizačného parametra  $K$

S týmito predpokladmi môže grafická reprezentácia funkcie  $G_K(\beta, w, x)$  (v logaritmickej mierke) pre  $N = 7$  a pre rôzne hodnoty  $K$  vyzerat' napr. podľa obr.6.2.

Riešenie (6.8) opäť (ako v prípade základného myriadového filtra) možno nájsť v podobe koreňa rovnice:

$$\frac{\partial G_K(\beta, w, x)}{\partial \beta} = \dots = 2G_K(\beta) \sum_{j=1}^N \frac{w_j(\beta - x_j)}{K^2 + w_j(\beta - x_j)^2} = 0 \quad (6.10)$$

z čoho vyplýva, že výstup váženého myriadového filtra  $\beta_{MyKw}$ , musí spĺňať rovnosť

$$\sum_{j=1}^N \frac{w_j(\beta_{MyKw} - x_j)}{K^2 + w_j(\beta_{MyKw} - x_j)^2} = 0 \quad (6.11)$$

Zaoberať sa riešením (6.11) má zmysel len pre  $0 < K < \infty$ , ako vidno aj z obr. 6.2, teda mimo limitných prípadov. V limitnom prípade pre veľké hodnoty  $K$  sa vlastnosti váženého myriadového filtra približujú k váženému priemeru, a teda k lineárnemu FIR-filtru.

Pre  $K=0$  sa filter stáva estimátorom modusu, čiže jednej z najviac opakovaných vzoriek. Názov filtra – *myriadový* – pochádza práve z tejto poslednej spomínanej vlastnosti.

### 6.2.1 Vlastnosti výstupnej hodnoty váženého myriadového filtra

Dá sa dokázať, že hodnota  $\beta$ , ktorá vyhovuje rovnici (6.8), má nasledujúce vlastnosti:

- Pre  $K \rightarrow \infty$

$$\beta_{My\infty, w} = \frac{\sum_{j=1}^N w_j x_j}{\sum_{j=1}^N w_j} \quad (6.12)$$

čo znamená, že ide o vážený spriemerňujúci FIR (teda lineárny) filter. Preto sa parameter  $K$  označuje ako *parameter lineárnosti*.

- $G(\beta)$  má  $M$  lokálnych maxím a  $(M-1)$  lokálnych miním medzi hodnotami  $x_{(1)}$  a  $x_{(N)}$ , kde  $\{x_{(m)}\}$  pre  $m = 1, 2, \dots, N$  sú vzorky  $x$  zoradené podľa vzostupnej veľkosti, pričom  $1 \leq M \leq N$ .
- Pre pozitívne váhy platí:

$$x_{(1)} < \beta_{My} < x_{(N)} \quad (6.13)$$

- S rastúcim  $K$  počet miním klesá. Ak

$$K > \sqrt{\max\{w_j\}_{j=1}^N} (x_{(N)} - x_{(1)}) \quad (6.14)$$

potom  $G(\beta)$  je konvexná, a preto má jediné lokálne minimum, ktoré je zároveň globálnym minimom.

- Ak sú váhy vhodne nastavené, výstup myriadového filtra sa nemení pri zmene hodnoty  $K$ , čo sa dá vyjadriť podmienkou:

$$\text{ak } \frac{w_1}{K_1^2} = \frac{w_2}{K_2^2}, \quad \text{potom } \beta_{MyK1}(w_1, x) = \beta_{MyK2}(w_2, x) \quad (6.15)$$

a teda výstup filtra závisí len na  $w/K^2$ .

Dobrou ilustráciou týchto vlastností je obr.6.2.

### 6.2.2 Optimalizácia váh váženého myriadového filtra

Hľadanie optimálnych váh  $w_i$  pre daný vstupný vektor filtra  $\{x_i\}$  pre  $i = 1, \dots, N$  je úlohou optimalizačného procesu, kde pri predpokladanom výstupe filtra  $y = \beta_{MyKw}$ , pre ktorý platí

$$y \equiv y(\mathbf{w}, \mathbf{x}) = \arg \min_{\beta} G(\beta, \mathbf{w}, \mathbf{x}) \quad (6.16)$$

je nutné dosiahnuť minimálnu chybu  $e = y - d$ , ako odchýlku od želanej hodnoty  $d$ .

Keď sa využije kritérium minimálnej strednej absolútnej chyby (MAE), pričom pre chybovú funkciu možno použiť skrátené označenie  $J(\mathbf{w})$ , vyjadrujúce jej závislosť na váhach (vlastnosť 6.15) takto:

$$J(\mathbf{w}) = E\{|d|\} = E\{|y(\mathbf{w}, \mathbf{x}) - d|\} \quad (6.17)$$

potom je potrebné minimalizovať  $J(\mathbf{w})$  s ohľadom na  $w_i \geq 0$ , pre  $i = 1, 2, \dots, N$ . Operátor  $E$  predstavuje štatistické očakávanie (strednú hodnotu). To znamená vyriešiť rovnicu grad  $J(\mathbf{w}) = 0$ ,

pričom

$$\frac{\partial J}{\partial w_i} = \frac{\partial E\{|y-d|\}}{\partial w_i} = \dots = E\left\{ \text{sign}(y-d) \frac{\partial y}{\partial w_i} \right\}, \quad i = 1, \dots, N \quad (6.18)$$

Keďže výstup filtra  $y$  bude našim hľadaným  $\beta_{MyKw}$ , pre ktoré platí (6.10), potom možno pre prvú deriváciu  $G$  napísať:

$$G'(y) = \sum_{j=1}^N \frac{w_j (y - x_j)}{K^2 + w_j (y - x_j)^2} = 0 \quad (6.19)$$

A keďže  $y$  má minimalizovať charakteristickú funkciu  $G'(y)$ , musí zároveň pre druhú deriváciu  $G$  platiť  $G''(y) > 0$ .

Po zahrnutí všetkých uvedených predpokladov a rovností nakoniec z (6.18) vyjde podmienka pre výstup  $y$  optimalizovaného váženého myriadového filtra:

$$\frac{\partial J}{\partial w_i} = -E \left\{ \text{sign}(y-d) \frac{\frac{(y-x_i)}{\left(1 + \frac{w_i}{K^2} (y-x_i)^2\right)^2}}{\sum_{j=1}^N w_j \frac{\left(1 - \frac{w_j}{K^2} (y-x_j)^2\right)}{\left(1 + \frac{w_j}{K^2} (y-x_j)^2\right)^2}} \right\} = 0 \quad \text{pre } w_i \geq 0, i=1, \dots, N \quad (6.20)$$

kde výstup filtra  $y$  je tiež závislý na váhach  $w_i$  a vstupnej množine prvkov  $x_i$  pre  $i = 1, \dots, N$ .

Riešiť (6.20) s ohľadom na optimálne váhy je náročná úloha, vhodná skôr pre numerické metódy. Pre adaptáciu váh možno použiť metódu najstrmšieho zostupu (SDM - steepest descent method). Táto metóda patrí ku gradientným numerickým metódam hľadania minima funkcie [15], [87]. Možno tu teda využiť gradient chybovej funkcie uvedený vyššie.

**Metóda SDM** v krátkosti znamená, že pri hľadaní minima funkcie  $f(X)$ , sa z náhodne zvoleného bodu  $X_0$  postupnými iteráciami (väčším alebo menším počtom iterácií; niekedy je ten postup veľmi pomalý) dospeje až do bodu minima, alebo do jeho tesnej blízkosti. Krok iterácie (aktualizácie  $X_i$  na  $X_{i+1}$ ) môže byť konštantný alebo premenlivý, postupuje sa v smere klesajúceho lokálneho gradientu funkcie, t.j.  $-\nabla f(X_i)$ , až po tzv. fixný bod (výsledok) podľa predpisu:

$$x_i = x_{i-1} - \mu f'(x_{i-1}) \quad (6.21)$$

čo je predpis pre hľadanie minima funkcie jednej premennej.

Aplikácia SDM pre hľadanie minima chybovej funkcie (6.17), resp. (6.20) s ohľadom na váhy  $w_i$  znamená nasledovné prispôsobenie predpisu pre aktualizáciu váh:

$$w_i(n+1) = w_i(n) - \mu \cdot \frac{\partial J}{\partial w_i}(n) \quad (6.22)$$

kde  $w_i(n)$  je  $i$ -ta váha na  $n$ -tej iterácii,  $\mu > 0$  je krok aktualizácie váh. Aktualizácia váh sa opakuje dovtedy, kým výraz na pravej strane rovnice (6.22) nemá nulovú, alebo malú hodnotu.

Pri praktickom postupe možno vzťah (6.20) pre grad  $J$  zjednodušiť odstránením menovateľa so sumou, keďže ten je vždy  $> 0$ , a znamienko gradientu neovplyvní. Ďalej, z dôvodu zjednodušenia sa nepoužije operátor  $E$ , ale iba okamžitý odhad gradientu grad  $J$ . Pre iteračný postup to teda znamená:

$$w_i(n+1) = w_i(n) + \mu \cdot \text{sign}(e(n)) \frac{(y(n) - x_i(n))}{\left(1 + \frac{w_i(n)}{K^2} (y(n) - x_i(n))^2\right)^2} \quad (6.23)$$

Zo vzťahu (6.23) vyplýva, že ak na aktuálnej iterácii je  $e(n) > 0$ , znamená to, že  $d(n) < y(n)$ , a potom pre všetky  $x_i(n) < y(n)$  (čo znamená, že sa nachádzajú na rovnakej strane vzhľadom k aktuálnemu odhadu, ako želaný signál) sa váhy zväčšujú, ostatné sa zmenšujú, a výstup filtra sa blíži k želanému výsledku. Ďalej: čím väčšia je vzdialenosť vzoriek  $x_i$  od aktuálneho odhadu, tým pomalšie narastá ich váha, a eliminuje sa tak ich vplyv na výstupnú hodnotu filtra - inými slovami - **ide o odstránenie impulzov**.

Poznámka:

Iný, jednoduchší - suboptimálny- prístup ("myriadizácia"), opísaný v [29], je založený na fakte, že pre veľké hodnoty  $K$  sa vážené myriadové filtre správajú ako lineárne. Navrhne sa najprv lineárny filter, pričom jeho váhy sa použijú vo váženom myriadovom filtri. Hodnota  $K$  sa potom znižuje až do dosiahnutia želaného výsledku. Takýto filter sa potom podobá lineárnemu normalizovanému FIR-filtru, je však robustnejší. No vhodný je len pre niektoré aplikácie.

### 6.3 Myriadové filtre - experimenty

Na experimenty s cieľom overiť vlastnosti vyššie uvedenej robustnej metódy potlačania impulzového rušenia boli použité štandardné farebné obrazové sekvencie „Claire“ a „Flower garden“ (obr.6.3), napr. [50c], ktoré sa navzájom výrazne líšia podielom monotónnych plôch a pestrej drobnej štruktúry v snímkach. Líšia sa tiež veľkosťou aj druhom pohybu – prvá predstavuje rozprávajúcu ženu na modrom pozadí, druhá rozkvitnutú líšku s domom v pozadí, snímanú pomaly sa pohybujúcou kamerou.

Snímky sekvencie boli znehodnotené 10%-ným a 20%-ným impulzovým šumom (obr. 6.3). Potom boli filtrované *optimalizovaným váženým myriadovým filtrom (OWMyF)* typu W1+1 (obr.5.3), a pre porovnanie aj mediánovým filtrom (MF) s rovnakým typom okna. Spomínaný typ okna bol vybraný ako najúspešnejší po testovaní viacerých okien.

Testované okná mali tri alebo päť obrazových prvkov v ľubovoľnom z troch smerov 3-rozmerného (plošno-časového) priestoru. Išlo o kombinácie hlavných smerov (horizontálneho, vertikálneho, diagonálnych a časového). Pre linearizačný parameter  $K$  bola použitá hodnota  $K = 2$ .

OWMyF odstránil impulzy 10%-ného zašumenia v jednoduchších snímkach sekvencie Claire takmer bezo zbytku, **no nie lepšie ako porovnávaný mediánový**. Pri sekvencii Flower garden s drobnejšou, zložitejšou štruktúrou plochy snímok museli byť váhy OWMyF aktualizované s podstatne menším krokom, ako pri sekvencii Claire. Napriek tomu výsledok filtrácie bol o niečo horší. V prípade 20%-ného zašumenia sa výsledky filtrácie pomocou OWMyF zhoršili výrazne (tab.6.1) a úplne neprijateľne.

Filtrácia zašumenia normálnym aditívnym, alebo zmiešaným (aditívnym + impulzovým) dopadla podľa očakávania - neuspokojivo, čo potvrdilo nevhodnosť tohto filtra pre iný, než impulzový šum.

Naše experimenty preukázali, že tento filter takisto nie je vhodný ani na filtráciu simulovaného poškrabania a škvŕn na snímkach.

V každom prípade výsledky potvrdzujú, že starostlivo navrhnutý myriadový filter je vhodný na odstránenie impulzového šumu, no nepotvrdzujú, že by bol výrazne vhodnejší než referenčný mediánový (na rozdiel od očakávania). Vizuálny efekt sa zdal rovnaký, a v číselných hodnotiacich parametroch dokonca mediánové filtre vykazovali nepatrne lepšie výsledky (tab.6.1). Definície číselných chybových parametrov MAE a MSE sú uvedené v 7. kapitole.

Uvedené závery súhlasia s výsledkami v [37], kde boli testované iné sekvencie.

Tab.6.1 Hlavné výsledky experimentov s optimálnymi váženými myriadovými filtermi (OWMyF) typu  $W1+1$  a ich porovnanie s účinnosťou mediánového filtra rovnakého typu pri potláčaní impulzového šumu.

Sekvencia	Typ šumu	Poškodená sekvencia		Filtrovaná sekvencia			
		MAE	MSE	Mediánový filter ( $W1+1$ )		OWMyF( $W1+1$ )	
				MAE	MSE	MAE	MSE
Claire	i10	12,74	2015,03	0,92	14,84	2,04	22,98
	i20	25,49	4022,18	1,83	127,60	3,28	156,68
Flower garden	i10	12,70	2033,76	8,53	278,06	9,84	296,99
	i20	25,48	4086,30	10,32	457,26	11,93	529,48

## 6.4 Myriadové filtre - záver

Myriadové filtre, a hlavne vážené myriadové filtre patria k nelineárnym filtrom, určeným pre odstraňovanie impulzového šumu. Tiež, ako mediánové filtre, využívajú štatistické vlastnosti obrazových dát, no na rozdiel od mediánových filtrov, nepatria do triedy selektívnych poriadkových štatistických filtrov. Sú účinné v prípade Cauchyho modelu rozdelenia dát, ktoré je vhodnejšou aproximačnou funkciou pre impulzový typ rušenia, vyskytujúci sa v bezdrôtových komunikačných kanáloch. (Lineárne filtre sú účinné v prípade Gaussovho rozdelenia a mediánové v prípade Laplaceovho rozdelenia.)

Trieda myriadových filtrov, vďaka ladiacemu parametru  $K$ , zahŕňa veľmi rozmanitú skupinu filtračných operácií. Účinnosť vážených myriadových filtrov sa môže meniť od vysokej robustnosti selektívnych filtrov pre  $K \rightarrow 0$  po výkonnú triedu lineárnych FIR filtrov pri  $K \rightarrow \infty$ .

Výsledky experimentov a väčšia zložitosť týchto filtrov **však stoja za zváženie pri ich prípadnom uprednostnení pred mediánovými** v oblasti filtrácie obrazových signálov s impulzovým rušením.





Obr.6.3 Snímky č. 2 zo sekvencií Claire (horná polovica obrázka) a Flower garden (dolná polovica) - originálne, zašumené 10%-ným impulzovým šumom, a vyfiltrované optimalizovaným váženým myriadovým filtrom (okno  $W1+1$ , linearizačný parameter  $K=2$ )

## 7 Číselné kritériá kvality obrazu a obrazovej sekvencie

Väčšinou sa úprava obrazov a obrazových sekvencií robí pre lepší vizuálny efekt, no ten je veľmi závislý od pozorovateľa a od podmienok pozorovania, a známky ako dobrý, prijateľný, neprijateľný, sú veľmi nepresné. Preto okrem vizuálneho je nutné používať aj matematicky definované číselné kritériá. Využitie matematickej štatistiky je pri tom úplne samozrejmé, keďže pri spracovaní digitálneho materiálu ide o súbory čísel. Základné štatistické parametre sa pritom využívajú v ich pôvodnej podobe (stredná absolútna chyba, stredná kvadratická chyba, rozptyl, koeficient korelácie, atď.) alebo slúžia na definovanie ďalších, špeciálnych parametrov, potrebných a navrhnutých pre oblasť zobrazovania.

Vyššie spomenuté chybové kritériá sa používajú často, sú však pre nezasväteného človeka nič nehovoriacimi a ťažko vysvetliteľnými číslami, a navyše, ako sa dodatočne zistilo, nekorelujú dostatočne s úrovňou kvality vnímanou zrakom. V mnohých, nielen komerčných oblastiach je pritom subjektívne vnímaná úroveň kvality dôležitá. To viedlo k ďalšiemu výskumu s cieľom definovať kvalitatívne kritérium približujúce sa ľudskému vnímaniu kvality, a zároveň oslobodiť proces jeho vyhodnocovania od nutnosti splnenia náročných požiadaviek, aké sú teraz definované napr. ITU štandardami (ITU-R 500\*, ITU-T-P.910). ITU štandardy boli zavedené kvôli zjednoteniu, hodnovernosti a opakovateľnosti vyhodnocovacích procesov s účasťou hodnotiacich osôb v konkrétnom, špeciálne upravenom a technicky vybavenom prostredí. Výskum v tomto smere prebieha doteraz, a jednému typu kritéria kvality približujúcemu sa ľudskému vizuálnemu vyhodnoteniu bude zvlášť venovaná posledná časť tejto kapitoly.

Poškodenie statických obrazov, videosekvencií, a účinnosť filtračných techník sa vyhodnocuje tak, že sa porovnávajú dva kvalitatívne odlišné objekty (obrazy, resp. sekvencie). Rôzne chybové kritériá, vyhodnotenú na základe takéhoto porovnania, sú uvedené v nasledujúcich podkapitolách.

### 7.1 MAE

Definícia *strednej absolútnej chyby* **MAE** (Mean Absolute Error) pre porovnanie originálu so zašumeným, resp. vyfiltrovaným obrazom s rozmermi  $M \times N$  pixelov:

$$MAE = \frac{1}{(M - 2m)(N - 2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} |y_{i,j} - o_{i,j}| \quad (7.1)$$

Vo výraze (7.1) sú symbolom  $y_{i,j}$  označené pixely vyšetřovaného obrazu s indexom riadka  $i$  a stĺpca  $j$ , symbolom  $o_{i,j}$  pixely originálu,  $m$  je počet bodov tvoriacich šírku okraja obrazu, ktorý sa väčšinou nefiltruje, a preto nie je zahrnutý ani do výpočtu chyby. (Na okrajoch obrazov, resp. snímok, filtračné okno šírky  $2m+1$  nemá definovaných  $m$  okrajových pixelov pre každý okraj, a akékoľvek riešenie tejto situácie by skreslilo celkový číselný výsledok účinku filtrácie - „okrajový efekt“.)

Vzorec (7.1) zahŕňa jednu maticu, čiže obraz v šedej škále. Pre farebný – trichromatický obraz, napr. RGB, sa MAE vypočíta pre každý farebný kanál zvlášť, a výsledná chyba je daná aritmetickým priemerom chýb jednotlivých kanálov.

Podobne ako pri 3-kanálovom obraze, *MAE obrazovej sekvencie* bude priemernou absolútnou chybou vypočítanou zo všetkých snímok okrem „okrajových“ -  $l$  prvých a  $l$  posledných snímok:

$$MAE_{seq} = \frac{1}{F - 2l} \sum_{n=l+1}^{F-l} MAE_n \quad (7.2)$$

$F$  – počet snímkov v sekvencii,  $n$  – index snímky.

Na základe porovnania MAE sa zvykne usudzovať o zmene (rozmazaní) hrán a detailov v obraze v dôsledku filtračných procesov [52].

## 7.2 MSE

Účinnosť potlačenia šumov v obraze po realizácii filtrácie sa najčastejšie vyhodnocuje na základe *strednej kvadratickej chyby* **MSE** (Mean Square Error). Pri experimentoch sa táto chyba vyhodnocuje podľa vzťahu:

$$MSE = \frac{1}{(M - 2m)(N - 2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} (y_{i,j} - o_{i,j})^2 \quad (7.3)$$

Podobne ako MAE, v prípade trichromatických obrazov a v prípade obrazovej sekvencie sa vypočítava priemerná MSE zo všetkých dielčích – zložkových (r,g,b) obrazov, resp. zo všetkých snímkov; okrajové body (parameter  $m$ ) a snímky (parameter  $l$ ) sa vynechávajú.

## 7.3 SNR

Z oblasti telekomunikácií je známy logaritmický parameter definujúci v dB *odstup signálu od šumu*, pre ktorý sa zvykne používať aj slovenský ekvivalent k anglickému názvu – „pomer signál / šum“, t.j. **SNR** (*signal-to-noise ratio*). Toto kritérium kvality je aplikovateľné aj pri číslicovom spracovaní obrazových signálov [52]. V nižšie uvedenom vzorci energiu šumu v menovateli predstavuje chyba MSE:

$$SNR = 10 \log_{10} \frac{\frac{1}{(M - 2m)(N - 2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} y_{i,j}^2}{\frac{1}{(M - 2m)(N - 2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} (y_{i,j} - o_{i,j})^2} \quad [\text{dB}] \quad (7.4)$$

V tabuľke 7.1 sú ako príklad uvedené vypočítané hodnoty kvalitatívnych kritérií MAE, MSE a SNR pre niektoré vybrané zašumené verzie testovacieho ČB-obrazu Lena. Symbolika označenia šumov je známa z predchádzajúcich kapitol. Pri výpočte kritérií sa vynechávali 15-bodové okraje obrazov [52].

Tab.7.1 Hodnoty kvalitatívnych kritérií vypočítané z ČB-obrazu Lena (256 x 256; 256 jasových úrovní), zašumeného Gaussovým aditívnym šumom a 10%-ným impulzovým šumom s rovnomerným rozdelením hodnôt (i10), resp. 20%-ným impulzovým šumom s medznými hodnotami 0 a 255(bw20).

Typ šumu	Gaussov šum $N(0,20^2)$			i10		bw20	
Kritérium	MAE	MSE	SNR	MAE	MSE	MAE	MSE
	15.425	381.987	16.725	7.018	759.1	23.402	3438.1

## 7.4 MAER, NR, PSNR

Niekedy je zaujímavé posúdenie zmeny úrovne chyby, resp. šumu po filtrácii, a tiež vrcholový pomer signál / šum. Je možné vypočítať a uviesť tieto zmeny v decibeloch – vzťahy (7.5) až (7.7) [52]:

$$MAER = 20 \log_{10} \frac{\frac{1}{(M - 2m)(N - 2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} |y_{i,j} - o_{i,j}|}{\frac{1}{(M - 2m)(N - 2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} |n_{i,j} - o_{i,j}|} \quad [\text{dB}] \quad (7.5)$$

Vzťah (7.5) definuje *redukciiu strednej absolútnej chyby*;  $n_{i,j}$  v ňom predstavuje hodnotu pixelu zašumeného obrazu pred filtráciou,  $y_{i,j}$  po filtrácii.

Ďalší vzťah (7.6) definuje *redukciiu šumu (NR)*, ako pomer stredného výkonu šumu na výstupe ku strednému výkonu šumu na vstupe filtra:

$$NR = 10 \log_{10} \frac{\frac{1}{(M-2m)(N-2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} (y_{i,j} - o_{i,j})^2}{\frac{1}{(M-2m)(N-2m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} (n_{i,j} - o_{i,j})^2} \quad [\text{dB}] \quad (7.6)$$

$$PSNR = 10 \log_{10} \frac{y_{\max}^2}{MSE} \quad [\text{dB}] \quad (7.7)$$

Vzťah (7.7) definuje *vrcholový pomer signál / šum*, kde  $y_{\max}$  predstavuje maximálnu hodnotu jasnosti vyšetřovaného obrazu; pri 8-bitovej úrovni bude  $y_{\max} = 255$ .

## 7.5 Farebný rozdiel

V súvislosti s farebnými obrazmi bol v časti 4.3 opísaný problém zmeny farebných od-tieňov v obraze po jeho manipulácii. Preto okrem vyššie spomínaných kvalitatívnych kritérií je pri spracovaní farebných obrazov vhodné uvádzať parameter, ktorý túto zme-nu vyhodnocuje, a ktorý by mal korešpondovať s farebným rozdielom vnímaným ľud-ským zrakom. Takýto parameter bol definovaný konferenciou CIE ako *farebné skresle-nie (color difference – CD)* s označením  $\Delta E_{uv}^*$  (vzťah 7.8), pričom bol v roku 1976 zavedený aj tzv. *prah farebného rozdielu (JND)* ako minimálna zrakom postrehnuteľná hodnota farebného rozdielu ( $\Delta E_{uv}^* \text{ JND} \cong 2,9$ ).

$$\Delta E_{uv}^* = \sqrt{(\Delta L^*)^2 + (\Delta u^*)^2 + (\Delta v^*)^2} \quad (7.8)$$

$\Delta E_{uv}^*$  vyjadruje euklidovskú vzdialenosť dvoch farebných vektorov v priestore CIE  $L^*u^*v^*$ .

Výpočet farebného rozdielu pri číslicovej filtrácii v súlade s definíciami CIE je zložitý, pretože ku zložkám  $L^*, u^*, v^*$  sa dá dopracovať od lineárnej trichromatickej sústavy R,G,B až po niekoľkých postupných transformáciách [20], [68], [74] :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412 & 0.358 & 0.180 \\ 0.213 & 0.715 & 0.072 \\ 0.019 & 0.119 & 0.950 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (7.9)$$

čo je transformácia medzi lineárnymi, primárnymi signálmi RGB a XYZ, platná pre štúdióvu produkciu HDTV (1988).

Ďalej, cez transformáciu CIE XYZ do jednotkovej roviny  $x+y+z=1$ , a potom do priesto-ru CIE  $YU^*V^*$ , sa vypočítajú súradnice  $u', v'$ :

$$u' = \frac{4X}{X + 15Y + 3Z}, \quad v' = \frac{9Y}{X + 15Y + 3Z} \quad (7.10)$$

Pre biele svetlo D65 (v 24 bitovom RGB-priestore to predstavuje maximálne hodnoty R, G, B, t.j. hodnoty 255, 255, 255) vypočítame hodnoty X, Y, Z a  $u', v'$  s indexom  $n$ :

$$u_n' = \frac{4X_n}{X_n + 15Y_n + 3Z_n}, \quad v_n' = \frac{9Y_n}{X_n + 15Y_n + 3Z_n} \quad (7.11)$$

Na priestore CIE YU'V' je založený priestor CIE L\*u\*v\*, podobne ako Yu'v' - tiež v snahe linearizovať vnímateľnosť jednotkového vektorového farebného rozdielu pre všetky farby [20]:

$$L^* = \begin{cases} 116 * \sqrt[3]{\frac{Y}{Y_n}} - 16 & \text{pre } \frac{Y}{Y_n} > 0.008856 \\ 903.3 * \frac{Y}{Y_n} & \text{pre } \frac{Y}{Y_n} \leq 0.008856 \end{cases} \quad (7.12)$$

$$u^* = 13L^*(u' - u_n'), \quad v^* = 13L^*(v' - v_n') \quad (7.13)$$

Nakoniec teda možno použiť vzťah (7.8) pre výpočet  $CD_{i,j}$  každého pixelu daného farebného obrazu porovnávaného s iným obrazom, a priemerné CD pre celý obraz<sup>2</sup>:

$$CD_{i,j} = \Delta E_{uv}^*_{i,j}, \quad CD = \frac{1}{(M-m)(N-m)} \sum_{i=m+1}^{M-m} \sum_{j=m+1}^{N-m} CD_{i,j} \quad (7.14)$$

Pri aplikácii uvedených vzťahov na **dáta získané z obrazových súborov** je nutné zohľadniť skutočnosť, že väčšina obrazových formátov (napr. aj formát .ppm) obsahuje čísla zodpovedajúce budiacemu napätiu CRT obrazoviek. Tieto napätia sú práve kvôli spomínanému účelu (nelineárna prevodová charakteristika obrazoviek), transformované korekciou *gamma* (viac napr. v literatúre [20] alebo [68]). Ich stupnica teda nie je lineárna, ako sa požaduje pri transformácii CIE R,G,B – CIE X,Y,Z, a je potrebné ich pred výpočtami (7.8) až (7.14) najprv spätne transformovať do lineárneho priestoru R,G,B (operácia inverzná ku korekcii *gamma*).

Vyhodnocovať farebný rozdiel v súlade so zrakovým vnímaním si, ako vidieť, žiada komplexnejší prístup. V skutočnosti sa mu venuje celá, široká vedná oblasť, na čele s organizáciou CIE. V tejto publikácii sa výsledky experimentov s farebnými obrazmi a obrazovými sekvenciami zatiaľ obmedzia na chyby vypočítané priemernením MAE, resp. MSE jednotlivých kanálov R,G,B.

## 7.6 Vyhodnocovanie miery pohybu a zachovania pohybu v obrazových sekvenciách

Keďže dynamická obrazová sekvencia je postupnosť snímok, kde susedné snímky sú si väčšinou navzájom dosť podobné (keď ide o snímky pohybu, nie však o kompiláciu zostrihaného filmového materiálu), túto podobnosť medzi snímkami s časovými indexami  $n$  a  $n+1$  vyjadruje koeficient medzisnímkovej korelácie  $R_n$  [52], [66], a pre celú sekvenciu sa môže vypočítať priemerná korelácia  $R_0$ . Ak sa pri filtrácii poruší hladkosť pohybu (zmení - zmenší sa korelovanosť medzi susednými snímkami), na korelácii  $R_y$  celej sekvencie sa to tiež prejaví, a možno to jednoducho vyhodnotiť v podobe rozdielu

<sup>2</sup> Podobne je možné vypočítať farebný rozdiel využitím farebnej sústavy CIE L\*a\*b\* [20].

$\Delta R = |R_o - R_y|$ , (7.15)  
ktorý možno nazvať tiež *chybou pohybu* a v ktorom  $R_o$  predstavuje priemernú koreláciu pôvodnej sekvencie.

V matematickej podobe uvedené vyhodnotenie vyzerá takto:  
Stredná hodnota jasnosti snímky  $n$  označená  $\mu_n$  je

$$\mu_n = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N y_{i,j,n}, \quad (7.16)$$

kde  $n$  je časový index snímky,  $M, N$  sú jej rastrové rozmery v pixeloch, a  $y_{i,j}$  je symbol pre hodnotu pixelu v  $i$ -tom riadku,  $j$ -tom stĺpci.

Smerodajná odchýlka  $n$ -tej snímky označená  $\sigma_n$  je

$$\sigma_n = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (y_{i,j,n} - \mu_n)^2} \quad (7.17)$$

Potom korelácia  $R_n$  medzi snímkami  $n$  a  $n+1$  sa vypočíta:

$$R_n = \frac{\left\{ \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N y_{i,j,n} y_{i,j,n+1} \right\} - \mu_n \mu_{n+1}}{\sigma_n \sigma_{n+1}} \quad (7.18)$$

a priemerná korelácia celej obrazovej sekvencie bude

$$R_o = \frac{1}{F} \sum_{n=1}^F R_n \quad (7.19)$$

Čím viac sa hodnota korelačného koeficientu líši od 1 (čím je menšia), tým väčšia je odlišnosť medzi snímkami [66], a tým dynamickejšia je aj celá sekvencia. V 1. kapitole boli opisne uvedené dynamické vlastnosti vybraných štandardných sekvencií; nižšie uvedená tabuľka 7.2 [52] tento opis potvrdzuje.

Tab. 7.2 Príklady hodnôt korelačného koeficienta  $R_o$  vybraných originálnych štandardných sekvencií ako ukazovateľa ich dynamickosti (pestrosti z hľadiska časových zmien)

Sekvencia	Salesman	Susie	People
$R_o$	0.979	0.983	0.878

Pri vyhodnocovaní zmien v obrazovej sekvencii v dôsledku filtrácie pomocou parametra  $\Delta R$  (7.15) je však znova potrebné, tak ako v prípade predchádzajúcich porovnávacích kritérií, **vylúčiť z výpočtu okrajové body snímok aj celé snímky zo začiatku a z konca sekvencie.**

## 7.7 Štruktúrne kritérium pre posúdenie kvality obrazov a videa, približujúce sa subjektívnemu vnímaniu kvality

Úspešnosť ktorejkoľvek metódy možno často posúdiť aj opticky, no z pochopiteľných dôvodov sú tu dôležité aj číselné parametre. Čím viac sa číslo, vyjadrujúce kvalitu obrazu alebo videa, približuje ľudskému optickému vnímaniu kvality, tým lepšie.

Chybové a pomerové kritériá uvedené v predchádzajúcich podkapitolách, používané na posúdenie kvality obrazového materiálu a tiež na posúdenie úspešnosti filtračného procesu, majú pomerne malú vypovedaciu schopnosť, ak ich hodnoty v danom prípade nemáme práve s čím porovnať.


Ďalší problém je, že obrazy s približne rovnakou numerickou chybou, napr. MSE, majú už aj pri zbežnom pohľade výrazne odlišnú kvalitu. Tento prípad je ilustrovaný na obr.7.3. Štandardný obraz Lena je tam zmenený zvýšením kontrastu, alebo umelo znehodnotený rozmazaním a kompresiou JPEG. Ich odlišnosť je na pohľad zjavná a posledným dvom by aj nezalý pozorovateľ dal zlú známku kvality. Vypočítanú MSE vzhľadom k originálu však majú všetky tri zmenené obrazy rovnakú.



(a) Lena - originál



(b) Lena – zvýšený kontrast



(c) Lena – obraz poškodený vyhladením



(d) Lena – kompresia JPEG

Obr.7.3 Štandardný šedý obraz Lena 256 x 256 – ukážka 3 druhov zmeny kvality, pričom každý zmenený obraz bol v porovnaní s originálom vyhodnotený rovnakou chybou MSE

Tento príklad dokazuje jednak nekorelovanosť tak často používaného kritéria MSE s typom znehodnotenia, a tiež jeho nekorelovanosť s úrovňou kvality, ako ju vníma ľudský zrak. Práve posledné hľadisko sa v súčasnosti javí v rôznych oblastiach zobrazovania ako veľmi dôležité (vo vedeckej oblasti, rôznych odborných, a tiež v komerčnej). Až natoľko dôležité, že kvôli tomu vznikla expertná skupina VQEG - Video Quality Experts Group.

Skupina VQEG vznikla v októbri 1997 na stretnutí odborníkov zaoberajúcich sa vyhodnocovaním kvality videa. Zámerom ich pôsobenia je poskytnúť vysielacím, telekomunikačným spoločnostiam aj výskumníkom jednu alebo viac objektívnych metód vyhodnocovania kvality videa [84]. Keďže spolu s prechodom k digitalizácii obrazov a obrazových sekvencií a k bežnému využívaniu rôznych kompresných techník sa objavili aj nové typy vizuálneho rušenia, bolo nutné vyvinúť a štandardizovať aj nový spôsob vyhodnocovania tohto rušenia. Zaužívané subjektívne vyhodnocovanie kvality videa, ktoré bolo zavedené v štandarde ITU-R Recommendation 500<sup>3</sup> a používané v televíznej technike, už v súčasnosti nestačí. Spomínaný štandard určuje podmienky pre subjektívne vyhodnocovanie. K týmto podmienkam patrí technické vybavenie testovacích laboratórií, ale aj napríklad úroveň okolitého hluku, farba stien a veľkosť miestnosti, úroveň osvetlenia a pod. Bol teda zavedený nový štandard: ITU-T Recommendation P.910 určený pre vyhodnocovanie multimédií. Spomínaný štandard však tiež počíta s účasťou človeka na vyhodnocovaní, a preto sa vyvíjajú a zdokonaľujú novšie - objektívne metódy vyhodnocovania kvality [89], [83].

Subjektívne vyhodnocovanie je náročné, až nepraktické, no vnímanie kvality ľudským zrakom je neodmysliteľným kritériom vyhodnocovania. Preto hlavným snažením pri matematických metódach, na ktorých odborníci zo spomínanej VQEG a ďalší pracujú, je priblížiť sa pomocou nového kritéria čo najviac vnímaniu kvality ľudským zrakom.

Cieľom tejto podkapitoly je oboznámiť čitateľa s prístupom, ktorý bol vyvinutý s vyššie uvedeným zámerom. Kritérium, ktoré navrhli Z. Wang a C. Bovik [85] a neskôr zdokonalili Z. Wang, L. Lu, A. C. Bovik v [86], alebo Z. Wang, K. Zeng a Q. Li v [95], [86a] sa veľmi približuje vyššie uvedenému cieľu. Experimenty, ktoré sme realizovali, napr. [50a], aplikovali niektoré z poznatkov publikovaných v spomínanej literatúre. Výsledkom toho okrem vyhodnocovania kvality pomocou zaužívaných kritérií MAE a MSE [75], [49], bolo potom aj zhromaždenie hodnôt nového kritéria pre tie isté predmetné obrazové a filmové súbory.

Keď sa vrátíme na začiatok tejto podkapitoly, kde je uvedená názorná ukážka nedostatočnej vypovedacej schopnosti chybového kritéria MSE, riadiacim motívom pri vyhodnocovaní kvality statických obrazov a videa nemôže byť priemerná chyba vypočítaná zo všetkých obrazových bodov. V prípade ČB obrazov je HVS (Human Visual System – ľudský zrakový systém) citlivý na zmenu jasu, na zmenu kontrastu, ale *ako najrušivejšiu vníma zmenu ostrosti v obraze* – presnejšie nedostatočnú ostrosť vykreslenia kontúr, hrán, čiar, jedným slovom *štruktúry* obrazu. Nižšie uvedené kritérium teda zohľadní túto skutočnosť a bude vyjadrovať *štruktúrálnu podobnosť* dvoch obrazov, v ďalších častiach potom štruktúrálnu podobnosť dvoch video-sekvencií. Navyše, toto kritérium bude nadobúdať *hodnoty nepresahujúce číslo 1*, ktoré bude znamenať, že dva porovnávané obrazy (videá) sú identické, a čím viac sa hodnota nového kritéria bude líšiť od čísla 1, tým väčšiu štruktúrálnu odlišnosť skúmaných objektov bude signalizovať. Ak jedným z dvoch porovnávaných objektov bude dokonalý originál, štruktúrálnym kritériom potom bude možné vyjadriť kvalitu objektu druhého.

---

<sup>3</sup> ITU-R = International Telecommunications Union – Radiocommunication sector



### 7.7.1 Definícia kritéria štruktúrálnej podobnosti obrazov

Budeme uvažovať 2 čierno-biele digitalizované obrazy (alebo ich malé časti, vybrané z tých istých priestorových pozícií), ktoré možno vyjadriť diskretnými signálmi  $x$ ,  $y$ , a to v podobe diskretných postupností  $x_i$ ,  $y_i$ ,  $i = 1, 2, \dots, n$ ;  $n$  je počet obrazových prvkov daného obrazu (alebo fragmentu). Hodnoty, ktoré môžu tieto signály nadobúdať, budú z príslušného dynamického jasového rozsahu, napríklad 0 – 255 pre 8 bitové kódovanie jasu.

Štatistický priemer  $\mu$ , disperzia  $\sigma^2$  oboch signálov a kovariancia  $\sigma_{xy}$  budú definované nasledovne:

$$\mu_x = \frac{1}{n} \sum_{i=1}^n x_i, \quad \mu_y = \frac{1}{n} \sum_{i=1}^n y_i \quad (7.20)$$

$$\sigma_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu_x)^2, \quad \sigma_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \mu_y)^2 \quad (7.21)$$

$$\sigma_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y) \quad (7.22)$$

Pritom štatistický priemer  $\mu$  a štandardná odchýlka  $\sigma$  úzko súvisia s jasom v danej obrazovej oblasti, resp. s kontrastom. Kovariancia  $\sigma_{xy}$  je funkciou lineárnej korelácie medzi signálmi  $x$ ,  $y$ .

Na základe vyššie uvedených známych štatistických parametrov možno definovať dielčie koeficienty  $l$ ,  $c$ ,  $s$  porovnania (alebo tiež podobnosti) jasu, kontrastu, resp. štruktúry obrazových signálov  $x$ ,  $y$ :

$$l(x, y) = \frac{2\mu_x\mu_y}{\mu_x^2 + \mu_y^2}, \quad c(x, y) = \frac{2\sigma_x\sigma_y}{\sigma_x^2 + \sigma_y^2}, \quad s(x, y) = \frac{\sigma_{xy}}{\sigma_x\sigma_y} \quad (7.23)$$

Koeficient  $s$  vo vzťahu (7.23) je iného charakteru než koeficienty  $l$ ,  $c$ . Je rovný 1 vtedy a len vtedy, keď štruktúry oboch porovnávaných signálov sú úplne rovnaké.

Keď sa jednotlivé koeficienty zo vzťahov (7.23) spolu vynásobia, výsledný výraz bude vyjadrovať celkovú podobnosť 2 obrazov, alebo obrazových fragmentov, zahŕňajúcu odchýlky vo všetkých troch parametroch - v jase, kontraste a štruktúre:

$$S(x, y) = l(x, y)c(x, y)s(x, y) = \frac{4\mu_x\mu_y\sigma_{xy}}{(\mu_x^2 + \mu_y^2)(\sigma_x^2 + \sigma_y^2)} \quad (7.24)$$

V prípade „hladkých“ oblastí alebo aj v prípade veľmi nízkych úrovní jasu sa menovateľ výrazu (7.24) môže svojou hodnotou blížiť k 0 a celý výraz k nekonečnu. Aby sa tomu zabránilo, práve v spomínaných prípadoch, blízkyh ku kritickým, sa v celkovom koeficiente podobnosti uplatnia ďalšie zavedené koeficienty  $C_1$ ,  $C_2$ , ktorých veľkosť v iných prípadoch bude veľmi malá, zanedbateľná oproti ostatným členom výrazu (7.24). Veľkosť  $C_1$ ,  $C_2$  bude závisieť od dynamického jasového rozsahu obrazov  $L$  (pre 8 bitové kódovanie jasu je  $L = 255$ ) a tiež od nastavenia používateľom (konštanty  $K_1$ ,  $K_2$  s veľmi malými hodnotami):

$$C_1 = (K_1 L)^2, \quad C_2 = (K_2 L)^2 \quad (7.25)$$

Takže výslednú hodnotu kritéria štruktúrálnej podobnosti (alebo tiež *SSIM-indexu*; Structural SIMilarity) - bude určovať vzťah vzniknutý upravením (7.24):

$$SSIM(x, y) = \frac{2(\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7.26)$$

V experimentoch boli odskúšané hodnoty  $K_1 = 0,01$ ,  $K_2 = 0,03$ .

Po zhrnutí predchádzajúcich úvah možno uviesť nasledujúce vlastnosti kritéria podobnosti (SSIM) dvoch statických obrazov:

1.  $SSIM(x, y) = SSIM(y, x)$
2.  $SSIM(x, y) \leq 1$
3.  $SSIM(x, y) = 1$  vtedy a len vtedy, ak  $x = y$  (v diskkrétnej reprezentácii musí platiť  $x_i = y_i$  pre  $i = 1, 2, \dots, n$ )

A ďalej z uvedeného vyplýva že:

- ak porovnáваме dva obrazy, z ktorých jeden je dokonalej kvality (neporušený originál), potom funkcia SSIM vyjadruje vlastne kvalitu druhého obrazu
- čím viac sa bude hodnota kritéria SSIM líšiť od čísla 1 (čím bude menšia od čísla 1), tým horšiu kvalitu má daný vyhodnocovaný obraz.

### 7.7.2 Praktické vyhodnotenie kritéria štrukturálnej podobnosti pre obrazy

Z niekoľkých dôvodov nie je vhodné vypočítavať kritérium globálne, pre celý obraz v jednom výpočtovom kroku. Je to jednak z dôvodu vysokej priestorovej nestacionárnosti obrazových štatistík, jednak z dôvodu priestorovej závislosti skreslenia obrazu. Tiež preto, že HVS, vďaka stavbe oka pri typickej pozorovacej vzdialenosti nevníma obraz ako celok, ale s vysokým rozlíšením vníma vždy len jeho časť [84]. A posledný dôvod je, že niekedy je potrebná práve informácia o *priestorovej mape kvality* daného obrazu.

Preto sa vypočítavajú lokálne hodnoty SSIM-kritéria, a to v rámci malých oblastí – *lokálnych okien* (napr. 8x8 pixelov), na základe ich lokálnych štatistík  $\mu$ ,  $\sigma^2$ ,  $\sigma_{xy}$ . Lokálne okno sa potom posúva v zmysle rastrového rozkladu, pixel po pixeli, po celom obraze, čím sa získa spomínaná priestorová mapa kvality daného obrazu (obr. 7.4).



(a) vyhladený obraz



(b) mapa kvality vyhladeného obrazu (a)

Obr.7.4 Obraz Lena poškodený vyhladením a jeho mapa kvality, kde jasová úroveň pixelu zodpovedá lokálnej hodnote SSIM-kritéria

Ak je potrebná celková hodnota kritéria kvality obrazu, vypočíta sa ako priemer (MSSIM) zo všetkých lokálnych hodnôt:

$$MSSIM = \frac{\sum_{i=1}^M \sum_{j=1}^N SSIM_{ij}}{M \times N} \quad (7.27)$$

kde  $M$ ,  $N$  označujú počet riadkov, resp. počet stĺpcov matice obrazu.

Istou nevýhodou pri tvorbe mapy kvality je efekt vniku tzv. *blokových artefaktov* [85], čo vidno aj na obr. 7.4b napr. v oblasti hrán. Je to spôsobené vplyvom hoci len 1-pixelovej chyby na zmenu celého bloku v mape kvality. Dá sa to vyriešiť tak, že už pri výpočte štatistických parametrov lokálneho okna sa každý člen v sumách (7.20) až (7.22) vynásobí váhou  $w_i$  takou, že  $\sum_1^n w_i = 1$ . Váhy  $w_i$  možno získať z normalizovaného kruhovo symetrického Gaussovho dolnopásmového filtra s rozmerom lokálneho okna. Takže potom upravené vzťahy pre  $\mu_x$ ,  $\sigma_x$  a  $\sigma_{xy}$  budú vyzerat' takto:

$$\mu_x = \frac{1}{n} \sum_{i=1}^n w_i x_i, \quad \sigma_x^2 = \frac{1}{n-1} \sum_{i=1}^n w_i (x_i - \mu_x)^2, \quad \sigma_{xy} = \frac{1}{n-1} \sum_{i=1}^n w_i (x_i - \mu_x)(y_i - \mu_y) \quad (7.28)$$

kde  $n$  je počet prvkov lokálneho okna.

### 7.7.3 SSIM-kritérium pre farebné obrazy

Farebné obrazy v digitálnej podobe sú vlastne súborom niekoľkých – zložkových obrazov (jasovej a chrominančných zložiek, prípadne zložiek R,G,B a pod. – podľa zvolenej farebnej zložkovej sústavy), pričom výsledný vizuálny farebný efekt vzniká určitou matematicko-elektronicko-optickou kombináciou týchto zložiek. Odrazom tohto princípu je aj návrh kritéria kvality na báze vyššie uvedeného kritéria štrukturálnej podobnosti.

Ak máme napríklad farebnú zložkovú sústavu Y, Cr, Cb (jasová a dve chrominančné zložky používané v štandarde HDTV), aplikuje sa vyhodnotenie *lokálneho SSIM-kritéria* pre každú zložku v rámci lokálneho okna zvlášť – čiže dostaneme hodnoty  $SSIM_{ij}^Y$ ,  $SSIM_{ij}^{Cr}$ ,  $SSIM_{ij}^{Cb}$ . Výsledná hodnota kritéria  $SSIM_{ij}$  lokálneho okna bude váženou sumou týchto zložiek:

$$SSIM_{ij} = W_Y SSIM_{ij}^Y + W_{Cb} SSIM_{ij}^{Cb} + W_{Cr} SSIM_{ij}^{Cr} \quad (7.29)$$

(V experimentoch sme použili váhy  $W_Y = 0,8$ ;  $W_{Cb} = 0,1$ ;  $W_{Cr} = 0,1$  .)

### 7.7.4 Vyhodnotenie kvality videosekvencie

Pre výpočet kvality videa by bolo najjednoduchšie použiť vzťah (7.27) pre každú snímku sekvencie zvlášť, a potom vypočítať priemer zo všetkých snímok videa. *Pri veľkom objeme dát*, ktorý obrazová sekvencia predstavuje, by však aj objem výpočtov bol obrovský, čo je dôvod, ktorý vedie k snahe o nejakú výpočtovú racionalizáciu.

Ďalším dôvodom, kvôli ktorému sa výpočet kvality videa odkloní od pôvodne jednoduchšej predstavy, je opäť tzv. „nedokonalosť“ *ľudského zraku*. Našu pozornosť totiž viac priťahujú svetlejšie miesta v obraze než tmavé. To *znižuje podiel príspevkov tmavých*

*miest* ku celkovej kvalite obrazu, čo sa dá matematicky jednoducho vyjadriť váhovými koeficientmi.

Tretím dôvodom a princípom úpravy celkového kritéria kvality obrazovej sekvencie je to, že ani všetky snímky sekvencie nemajú pre HVS rovnaký význam. Kvalitu pokojných záberov (statická scéna) alebo aj pomalých zmien na snímkach posudzujeme prísnejšie (vyššia váha snímok), než kvalitu snímok s rýchlym pohybom na scéne, alebo s rýchlo sa pohybujúcou kamerou (ak sme vôbec schopní ich kvalitu posúdiť – nižšia váha).

Vyššie spomenuté hľadiská sú do matematických výrazov transformované nasledovným spôsobom. Ďalej uvedené výrazy zároveň poslúžili v experimentoch ako princíp ich algoritmu.

Eliminácia výpočtov je možná tým, že lokálne kritériá v rámci jednej snímky sa nebudú počítať pre každý pixel snímky. Experimenty v [86] dokázali, že pre výpočet kvality snímky postačí len určitý počet  $R_s$  lokálnych okien (menší než počet pixelov  $M \cdot N$ , napríklad  $R_s = 100$ ). Počtom lokálnych okien takto možno vlastne riadiť rýchlosť výpočtu. Okná (napríklad o veľkosti  $8 \times 8$ ) však nemôžu byť vyberané s pravidelným krokom, pretože jasový obsah snímok sa neustále mení. Štatisticky možno rozdelenie hodnôt jasu, ktoré sa neznalému pozorovateľovi javia ako náhodné, prirovnať ku Gaussovmu, a teda aj výber pozície *vzorkového okna* pre výpočet lokálneho SSIM-indexu sa môže riadiť rovnakým „zákonom“. (Vo vyšetrovanej a v referenčnej sekvencii sa vyberú okná na rovnakých pozíciách rovnakej  $j$ -tej snímky.)

Prisúdenie váh  $w_{ij}$  hodnotám  $SSIM_{ij}$  jednotlivých náhodných okien sa uskutoční na základe porovnania lokálnej strednej hodnoty jasu s používateľsky zvolenou prahovou hodnotou. Pre jemnejšie nastavenie váh môže byť jasový rozsah rozdelený aj na viac intervalov, z ktorých každému bude zodpovedať iná – odstupňovaná váha.

Pri experimentoch, napr. v [86] a [52] boli váhy lokálnych okien určované takto:

$$w_{ij} = \begin{cases} 0 & \mu_{ij} \leq 40 \\ (\mu_{ij} - 40)/10 & \text{pre } 40 < \mu_{ij} \leq 50 \\ 1 & \mu_{ij} > 50 \end{cases} \quad (7.30)$$

Index  $ij$  označuje  $i$ -te náhodné okno v  $j$ -tej snímke, pričom celkový počet snímok v sekvencii je  $F$ .

Potom pre kvalitu  $Q_j$   $j$ -tej snímky aplikujeme výpočet váženého priemeru podľa vzťahu

$$Q_j = \frac{\sum_{i=1}^{R_s} w_{ij} SSIM_{ij}}{\sum_{i=1}^{R_s} w_{ij}} \quad (7.31)$$

Určenie váhy danej snímky na základe „veľkosti“ zobrazovaného pohybu možno uskutočniť s využitím niektorej z metód estimácie pohybu. Napríklad využitím *metódy zhodných blokov* (block matching – BM) [napr. 39a] môžeme spomínanú „veľkosť“ celkového pohybu  $M_j$  v snímke priamo vypočítať:

$$M_j = \left( \sum_{i=1}^{R_s} m_{ij} \right) / R_s \quad (7.32)$$

kde  $m_{ij}$  je dĺžka lokálneho pohybového vektora vypočítaného pre príslušné  $ij$ -te lokálne okno porovnaním aktuálnej a nasledujúcej snímky.

Potom určíme váhu  $W_j$   $j$ -tej snímky:

$$W_j = \begin{cases} \sum_{i=1}^{R_s} w_{i,j} & M_j \leq t_M \\ 0 & M_j > t_M \end{cases} \quad (7.33)$$

kde  $t_M$  je zvolený rozhodovací prah pohybu. V (7.32) sa teda prisúdi nenulová váha iba tým snímkam v sekvencii, kde je pohyb pomalý alebo žiadny. Samozrejme, aj v prípade váh snímkov možno podobne ako u váh vzorkovacích okien zvoliť ich jemnejšie odstupňovanie [86].

Zo získaných hodnôt sa nakoniec vypočíta kvalita celej video-sekvencie s počtom snímkov  $F$ :

$$Q_v = \frac{\sum_{j=1}^F W_j Q_j}{\sum_{j=1}^F W_j} \quad (7.34)$$

Uvedený postup výpočtu štruktúrného kritéria by sa dal ešte rozšíriť o optimalizačné procesy pri nastavovaní parametrov, ktorých hodnoty boli zatiaľ vybrané iba empiricky. Na druhej strane, experimenty [86] aj [52] ukázali, že aj bez použitia váh okien a snímkov (t.j. keď sú všetky nastavené na 1), a pri váhach  $w_y=1$ ,  $w_{Cr}=w_{Cb} = 0$  majú výsledné hodnoty kvalitatívneho kritéria dostatočne uspokojujúcu vypovedaciu schopnosť. Dokonca ani zmena konštánt  $K_1$ ,  $K_2$  v (7.25) pri výpočte kvality lokálneho okna nemá na výsledok zvlášť veľký vplyv.

### 7.7.5 SSIM-kritérium v experimentoch

Úlohou našich experimentov bolo porovnať SSIM-kritérium s kritériom MSE, ktoré sa doteraz v oblasti filtrácie obrazov a obrazových sekvencií používalo najviac.

Druhou úlohou bolo vyhodnotiť pomocou SSIM-kritéria čo najviac štandardných statických obrazov a štandardných sekvencií, poškodených aj vyfiltrovaných, a získať tak novú bázu údajov o kvalite týchto dát. Nová báza mala slúžiť ako referenčná, pretože by sa v nej orientovalo ľahšie než v tabuľkách s hodnotami MSE.

Pre porovnanie kritéria SSIM a chyby MSE sa použil štandardný obraz Lena. Ten bol v prostredí MATLAB jednak zmenený zvýšením kontrastu, alebo znehodnotený rozmazaním, kompresiou JPEG, zašumením čierno-bielym šumom („salt & pepper“), aditívnym Gaussovým šumom a multiplikatívnym šumom (obr.7.4 a 7.5). Všetky zmeny boli nastavené tak, aby pri výpočte (7.3) vykazovali rovnakú chybu MSE, konkrétne okolo 225.

SSIM-kritérium sa vyhodnocovalo podľa vzťahov (7.25) až (7.27). Všetky obrazy (aj originál) boli predložené na laické posúdenie 10 osobám, ktoré mali určiť ich poradie podľa kvality, pričom prvé - najlepšie miesto v poradí bolo vopred určené pre originálny obraz.



(a) aditívny Gaussov šum



(b) čierno-biely impulzový šum



(c) multiplikatívny šum

Obr.7.5 Štandardný ČB obraz Lena 256x256 umelo poškodený tromi typmi šumu. Približná chyba MSE vzhľadom k originálu má pri všetkých hodnotu 225.

Údaje zaznamenané pri vyhodnocovaní sú usporiadané v tabuľke 7.1, a pri pohľade na ne možno konštatovať, že: **poradie kvality statických obrazov, ktoré vzniklo výpočtom podľa nového kritéria sa zhoduje s poradím, ktoré určili nezainteresované subjekty.**

Tab.7.1 Výsledky experimentov: Lena zmenená rôznym spôsobom, vždy s  $MSE \cong 225$ , vyhodnotená kritériom SSIM a tiež subjektívne – viacerými ľuďmi nezávisle a bez bližších informácií (dve posledné kritériá: čím bližšie k hodnote 1, tým lepšia známka kvality).

Typ zmeny obrazu Lena	MSE	Subjektívne hodnotenie	MSSIM
Zvýšený kontrast	226.36	1,9	0.943
ČB impulzový šum	226.23	2,47	0.786
JPEG kompresia	225.92	5,14	0.745
Vyhľadanie	225.23	5,24	0.741
Multiplikatívny šum	224.62	5,43	0.59

V ďalších experimentoch sa vypočítavala kvalita veľkého množstva štandardných obrazov a obrazových sekvencií, a to rôznym spôsobom umelo zašumených alebo poškodených, a tiež filtrovaných rôznymi typmi filtrov [75], [34]. Na tomto mieste sú pre ilustráciu uvedené len niektoré výsledky, ďalšia časť získaných údajov s komentárom je uvedená v prílohe 2.

Tabuľka 7.2 znázorňuje vyhodnotenie filtrácie farebných obrazov Lena a Mandrill (r,g,b – 256 x 256 pixelov), poškodených impulzovým korelovaným šumom v objeme 10 a 20 % obrazových prvkov. Tieto obrazy boli filtrované štandardnými mediánovými filtrami so štvorcovými oknami rôznych veľkostí a výsledky filtrácie boli vyhodnotené jednak pomocou chyby MSE, jednak pomocou kritéria SSIM (vzťahy 7.29 a 7.27). Ako je bližšie opísané v 4. kapitole, štandardný medián má vyhladzujúci efekt vzhľadom na hrany a detaily v obraze, a to tým väčší, čím je väčší rozmer filtračného okna. Tejto skutočnosti zodpovedajú aj výsledky v tabuľke 7.2, ak ich porovnáваме navzájom.

Tab.7.2 Výsledky filtrácie farebných obrazov Lena a Mandrill vyhodnotené pomocou MSE a pomocou kritéria MSSIM.

Typ obrazu	Typ šumu	Filtračné okno	MSE	MSSIM
farebná Lena	i10	3 × 3	58.57	0.905
		5 × 5	109.13	0.838
		7 × 7	159.34	0.786
	i20	3 × 3	86.8	0.874
		5 × 5	124.36	0.826
		7 × 7	175.06	0.774
Mandrill	i10	3 × 3	322.76	0.600
		5 × 5	407.17	0.457
		7 × 7	467.18	0.381
	i20	3 × 3	358.99	0.576
		5 × 5	424.31	0.448
		7 × 7	481.56	0.374

Ďalej, podľa prístupu, uvedeného v tejto podkapitole, bola vyhodnotená vyfiltrovaná štandardná obrazová sekvencia Salesman (tab. 7.3), keď predtým bola umelo poškodená škvrnami v objeme 10% obrazových prvkov. Boli vyhodnotené sekvencie po filtrácii filtrami W5×5×3, Cross, MMF, W5×5×3 s detektorom, Cross s detektorom a MMF s detektorom (časť 5.2.2). Kvalita sa vypočítavala podľa vzťahov (7.24), (7.27) a (7.34), pričom sa uplatnil náhodný výber 470 okien s veľkosťou 8 × 8 a všetky snímky sa uvažovali s rovnakou – jednotkovou váhou.

Tab. 7.3 Kritérium kvality  $Q_v$  vyhodnotené pri sekvencii Salesman, umelo poškodenej škvrnami a vyfiltrovanaj rôznymi typmi filtrov - zoradené podľa stúpajúcej hodnoty  $Q_v$ , t.j. podľa stúpajúcej kvality

Názov filtra	MSE	$Q_v$
W5×5×3	101.1200	0.5942
Cross	29.1241	0.8205
W5×5×3+det.	21.9395	0.8421
MMF	23.9046	0.8507
MMF+detektor	22.2900	0.8613
Cross+detektor	21.9802	0.8619

### 7.7.6 SSIM kritérium kvality – zhrnutie

Kritérium kvality obrazov a obrazových sekvencií, založené na štrukturálnej podobnosti posudzovaného a referenčného objektu sa zdá byť veľmi praktické a užitočné. Jeho výpočet nie je zložitý a svojimi hodnotami z intervalu od 0 po +1 umožňuje veľmi ľahko posúdiť kvalitu obrazu, či videa, keďže zahŕňa porovnanie štruktúry posudzovaných

objektov, približuje sa tým k vizuálnemu – subjektívnemu vyhodnoteniu. Pokusy s výpočtami podľa uvedených vzťahov a tiež so subjektívnym vyhodnotením obrazov osobami neznalými v tejto vedeckej oblasti potvrdili vyššie uvedené závery.

Má ešte rezervy, napr. v zohľadňovaní pohybu, alebo tiež v posudzovaní kvalitného videa s poškodenými časťami, ale inak kvalitného, a pod.



---

## Záver

Cieľom tejto monografie bolo uviesť čitateľa do problematiky spracovania digitálnych obrazových informácií ako aj naznačiť praktický prístup k uvedeným metódam spracovania.

Typmi poškodenia, ktorým sme sa venovali, boli hlavne impulzový šum a škrvny nachádzajúce sa na starých archívnych obrazových materiáloch. V tejto súvislosti boli uvedené modely týchto poškodení, umožňujúce simulovať dané poškodenia pre účely výskumu a vývoja filtračných techník.

Okrem možností opravy pomocou filtrov – väčšinou na báze mediánu, ale aj pomocou tzv. myriadových filtrov, boli uvedené aj niektoré možnosti detekcie poškodených miest, ktorá je väčšinou nutná a musí byť uskutočnená ešte pred opravou.

Komplexnosť prístupu k uvedenej problematike završila časť o vyhodnocovaní kvality obrazov a obrazových sekvencií, kde boli podrobne opísané najpoužívanejšie známe kvalitatívne kritériá, ako aj jedno z novovyvinutých kritérií zohľadňujúce ľudské vnímanie kvality.

Vo viacerých podkapitolách našej publikácie boli opísané experimenty zamerané na aplikáciu tej-ktorej techniky, ako aj výsledky týchto experimentov a záverečné vyhodnotenia.

## Zoznam bibliografických odkazov

- [1] Anděl, J.: Matematická statistika, SNTL, Praha 1985.
- [2] Angelopoulos, G. - Pitas, I.: Multichannel wiener filters in color image restoration based on AR color image modeling, Proc. IEEE Int. Conf. Acoust., Speech, Signal Processing, Toronto, May 1991, pp. 2517-2520.
- [3] Arce, G. R. - Foster, R. E.: Detail-preserving ranked-order based filters for image processing, IEEE Trans. Acoust., Speech, Signal Processing, vol. ASSP-37, No. 1, Jan. 1989, pp. 83-98.
- [4] Arce, G. R.: Multistage order statistic filters for image sequence processing, IEEE Trans. on Signal Processing, vol.39, No. 5, May 1991, pp. 1146-1163.
- [5] Arce, G.R. - Malaret, E.: Motion-preserving ranked-order filters for image sequence processing, IEEE ISCAS, 1989, pp. 983-986.
- [6] Arce, G.R.: A General Weighted Median Filter Structure Admitting Negative Weights, IEEE Trans. on Signal Processing, Vol.46, No.12, Dec.1998, pp. 3195-3205.
- [7] Astola, J. - Haavisto, P. - Neuvo, Y.: Vector median filters, Proceedings of IEEE, vol. 78, No. 4, April 1990, pp.678-689.
- [8] Alp, B. - Neuvo, Y.: 3-Dimensional Median Filters for Image Sequence Processing, Proc. IEEE Int. Conf. Acoust. Speech, Signal Processing, Toronto, May 1991, pp. 2917 – 2920.
- [9] Astola, J. - Heinonen, P. - Neuvo, Y.: On Root Structures of Median and Median-Type Filters. IEEE TRANSACTIONS ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING, VOL. ASSP-35, NO. 8, AUGUST 1987, pp. 1199-1201
- [10] Astola, J. - Neuvo, Y.: Optimal median type filters for exponential noise distributions, Signal Processing, vol. 17, No. 2, June 1989, pp. 95-104.
- [11] Barker, S.A.: Image Segmentation using Markov Random Field Models, Phd Thesis, Univ. of Cambridge, 1998.
- [12] Bednar, J. B. - Watt, T. L.: Alpha-trimmed means and their relationship to median filters, IEEE Trans. Acoust., Speech, Signal Processing, vol. ASSP-32, Feb. 1984, pp. 145-153.
- [13] Besag, J.: On the Statistical Analysis of Dirty Pictures, Journal of the Royal Statist. Society. Series B, 1986, Vol.48, No.3, pp.259-302.
- [14] Boncelet, C. G. - Hakami, R. - Warter, P. J.: Some theory of multistage order statistic filters, Proc. 32nd Midwest Symp. Circuits Syst., Urbana, IL, Aug. 1989
- [15] Buchanan, J.L., Turner, P.R.: Numerical Methods and Analysis, McGraw-Hill, Inc., 1992.
- [17] Coyle, E.J. - Lin, J.H. - Gabouj, M.: Optimal stack filtering and the estimation and structural approaches to image processing, IEEE Trans. Acoust., Speech, and Signal Processing, vol. 37, No. 12, Dec. 1989, pp. 2037-2066.
- [18] Crinon, R. J. - Arce, G.R.: Median filters: Analysis for signals with additive impulsive noise, Proc. 21st Allerton Conf., Oct. 1983.
- [19] Drutarovský, M. - Fischer, V.: Implementation of a 3-D Switching Median Filtering Scheme with an Adaptive LUM-Based Noise Detector, "Field-Programmable Logic and Applications," 14th International Conference, FPL 2004, Antwerp, Belgium, August 30-September 1, 2004, LNCS 3203, Springer, Berlin, pp.1146-1148.
- [19a] Fabian, P.: Multimediálne informačné systémy. Študijná literatúra. Vydavateľstvo Žilinskej univerzity v Žiline, 1998
- [20] Ford, A. - Roberts, A.: Colour Space Conversions, Aug. 1998, [http:// www. poynton.com/PDFs/coloureq.pdf](http://www.poynton.com/PDFs/coloureq.pdf).

- 
- [21] Gabbouj, M. - Coyle, E. J.: Minimum mean absolute error stack filtering with structural constraints, *IEEE Trans. Acoust., Speech, Signal Processing*, vol. 38, No. 6, June 1990, pp. 955-968.
- [22] Gabbouj, M. - Coyle, E.J. - Gallagher, N.C., jr.: An Overview of Median and Stack Filtering, *Circuits, Systems, and Signal Processing*, vol. 11, No.1, 1992, pp. 7-46.
- [23] Galatsanos, N. P. - Chin, R. T.: Digital restoration of multichannel images, *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-37, No.3, Mar.1989, pp. 415-421.
- [25] Georgiou, P.G. - Tsakalides, P. - Kyriakakis, C.: Alpha-Stable Modeling of Noise and Robust Time-Delay Estimation in Presence of Impulsive Noise, *IEEE Transactions on Multimedia*, Vol.1, No.3, Sept. 1999.
- [26] Girod, B.: Psychovisual aspects of image communication, *Signal Processing*, vol. 28, No.3, Sept. 1992, pp. 239-251.
- [27] Gonzales, J.G. - Griffith, D.W. - Arce, G.R.: Matched Myriad Filtering for robust Communications, *Proc. of the 1996 CISS*, Princeton, New Jersey, 1996.
- [28] Gonzalez, J.G. - Arce, G.R.: Optimality of Myriad Filter in Practical Impulsive-Noise Environments, *IEEE Trans. on Sig. Processing*, Vol.49, No.2, Feb.2001. pp.438-441.
- [29] Gonzalez, J.G. - Arce, G.R.: Weighted Myriad Filters: A Robust Filtering Framework Derived from Alpha-Stable Distributions, *Proc. of the 1996 IEEE Int. Conf. on Acoustics, Speech, and Signal Processing*, Atlanta, 1996, pp.2833-2836.
- [30] Heinonen, P. - Neuvo, Y.: FIR-median hybrid filters with predictive substructures, *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-36, No.6, June 1988, pp. 892-899.
- [31] Heinonen, P. - Neuvo, Y.: FIR-median hybrid filters, *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-35, No.6, June 1987, pp. 832-838.
- [32] Heinonen, P. - Neuvo, Y.: Smoothed median filters with FIR substructures, *Proc. IEEE Int. Conf. Acoust., Speech, Signal Processing*, Tampa, FL, USA, Mar.1985, pp. 49-52.
- [34] Hudec, R.: Filtrácia obrazov zašumených zmiešaným šumom pomocou modifikovaných adaptívnych L-filtrov, *Dizertačná práca*, Technická univerzita v Košiciach, 2002.
- [36] Jaroslavskij, L.- Bajla, I.: *Metódy a systémy číslicového spracovania obrazov*, Alfa, vydavateľstvo technickej a ekonomickej literatúry, 1989.
- [37] Kalluri, S. - Arce, G.R.: Adaptive Weighted Myriad Filter Optimization for Robust Signal processing, *Proc. of 1996 CISS*, Princeton, NJ, 1996.
- [38] Ko, D. - Chang, T.: Robust M-estimators on Spheres, *Multivariate Anal.*, Vol.45, 1993, pp. 104-136.
- [39] Ko, S. - Lee, Y. H.: Detail preserving weighted median filters, *Proc. 22nd Annu. Conf. Inform. Sci. Syst.*, Princeton, NJ, Mar. 1988.
- [39a] Kokaram, A.: *Motion Picture Restoration*, Springer Verlag, 1998.
- [40] Kokaram, A.C. - Godsil, S.J.: MCMC for Joint Noise Reduction and Missing Data Treatment in Degraded Video, *IEEE Transactions on Sig. Processing*, vol.50, No.2, Feb.2002.
- [41] Kokaram, A.C. - Morris, R.D. - Fitzgerald, W.J. - Rayner, P.J.W.: Detection of Missing Data in Image Sequences, *IEEE Transactions on Image Processing*, Vol.4, No.11, Nov. 1995, pp. 1496-1508.
- [42] Kokaram, A.C. - Rayner, P.J.: A system for removal of impulsive noise in image sequences, *SPIE Visual Commun. Image Processing*, Nov.1992, pp.322-331.

- [43] Kuosmanen, P.: Statistical Analysis and Optimization of Stack Filters, Acta Polytechnica Scandinavica, El. Engineering Series No.77, The Finnish Academy of Technology, Helsinki 1994.
- [44] Lukáč, R. - Maceková, Ľ. - Marchevský, S.: Order Statistic Filters in Dynamic Image Sequences Corrupted by Impulse Noise, Proc. of 4-th. International Conf. on Dig. Sig. processing, Slovakia - Herľany, Sept.1999, pp. 50-53.
- [45] Lukáč, R. - Marchevský, S.: A Neural LUM Smoother, Radioengineering, Vol.9, No.3, Sept. 2000, pp.5-7.
- [46] Lukáč, R. - Marchevský, S.: Adaptive LUM Smoother Controlled by Adaptive Threshold System, Journal of Electrical Engineering, No.3-4, Vol.51, 2000, pp.100-104.
- [47] Lukáč, R. - Marchevský, S.: Digital Image Processing Based on LUM Filters, 3rd International Scientific Conference ELEKTRO '99, Faculty of El. Engin.of University of Žilina, Slovakia, 1999, pp.84-89.
- [48] Lukáč, R.: An Adaptive Control of LUM Smoother, Radioengineering, Vol.9, No.1, April 2000, pp.9-12.
- [49] Lukáč, R.: Nové štruktúry vyhladzovacích LUM filtrov a detektorov impulzov pre zašumené obrazy, Dizertačná práca, Technická univ. v Košiciach, 2001.
- [50] Lukáč, R.: Vector Order-Statistics for Impulse Detection in Noisy Color Image Sequences, VIPromCom-2002, 4-th EURASIP-IEEE Region 8 Intern. Symposium on Video/Image Process.and Multimedia Communications, June 2002, Zadar, pp.357-360.
- [50a] Maceková, Ľ. - Marchevský, S.: Detection and Reconstruction of Missing Data in Damaged Image Sequences. Acta Electrotechnica et Informatica No. 2, Vol. 4, 2004, pp. 15-19.
- [50b] Marchevský, S. – Maceková, Ľ.: Detection and Reconstruction of Missing Data in Damaged Image Sequences. DSP-MCOM 2001, Košice, Slovakia, Nov. 2001, pp.
- [50c] Maceková, Ľ. - Marchevský, S.: Myriad Filters for Image Sequences Processing. DSP-MCOM 2005, Košice, Slovakia, Sept.2005, pp.122-125.
- [51] Mihalík, J. - Turán, J.: Metódy číslicového spracovania signálov, Dom techniky ČSVTS Košice, 1987.
- [52] Moucha, V. - Marchevský, S. - Lukáč, R.: Číslicová filtrácia obrazových signálov, Edičné stredisko VLA gen. M.R.Štefánika v Košiciach, 2000, ISBN 80-7166-036-1.
- [53] Myiahara, M.: Analysis of perception of motion in television signals and its application to bandwidth compression, IEEE Trans. Communications, vol. COM-23, July 1975, pp. 761-768.
- [54] Naqvi, S. - Gaallagher, N. C. -Coyle, E. J.: Application of median filters to digital television, Proc. 1985 IEEE Int. Conf. Acoust, Speech, Signal Processing, Tokyo, 1986, pp. 2451-2454.
- [55] Nave, C.R.: HyperPhysics, Georgia State University: <http://hyperphysics.phy-astr.gsu.edu/hbase/vision/colcon.html#c1> , © 2000.
- [56] Nieminen, A. - Heinonen, P. - Neuvo, Y.: A new class of detail preserving filters for image processing, IEEE Trans. Pattern Analysis and Machine Intelligence, vol. PAMI-9, No.1, Jan. 1987, pp. 74-90.
- [58] Nodes, T.A. - Gallagher, N.C. jr.: Median Filters: Some Modifications and Their Properties, IEEE Trans. Acoust., Speech and Signal Processing, Vol.ASS-30, No.5. pp.739-746, Oct.1982.
- [59] Öistämö, K. - Neuvo, Y.: Video signal processing, Visual Communications and Image Processing '90, Lausanne, Switzerland, Oct. 1990, pp. 1171-1183.

- 
- [61] Pitas, I. - Tsakalides, P.: Multivariate ordering in color image filtering, *IEEE Trans. Circuits and Systems for Video Technology*, vol. 1, No. 3, Sept. 1991, pp. 247-259.
- [62] Pitas, I.: Marginal Order Statistic in Color Image Filtering, *Optical Engineering*, Vol.29, No.5, May 1990, pp.495-503.
- [63] Pitas, J. - Venetsanopoulos, A.N.: Order Statistics in Digital Image Processing, *Proceedings of IEEE*, vol.80, No.12, Dec.1992, pp.1892-1921.
- [64] Poynton, C.: A Guided Tour of Color Space, <http://www.poynton.com>
- [65] Ptáček, M.: Přenosové soustavy barevné a digitální televize, 2.přerac.a dopl. vydání, Naklad.dopravy a spojů, Praha, 1981.
- [65a] Recommendation ITU-R BT 500-11, 2002.
- [66] Riečan, B. - Lamoš, F. - Lenárt, C.: Pravdepodobnosť a matematická štatistika. Alfa Bratislava a SNTL Praha, 1984.
- [67] Ruanaidh, J.J.K.Ó - Fitzgerald, W.J.: Numerical Bayesian Methods Applied to Signal Processing. New York: Springer-Verlag, 1996.
- [68] Sharma, G. - Trussell, H.J.: Digital Color Imaging, *IEEE Transact. on Image Processing*, Vol.6, No.7, July 1997, pp.901-932.
- [69] Schreiber, W. F.: Psychophysics and the improvement of television image quality, *SMPTE Journal*, 1984, pp. 717-725.
- [70] Storey, R.: Electronic detection and concealment of film dirt, *SMPTE J.*,pp.642-647, June 1985.
- [71] Storey, R.: Electronic detection and concealment of film dirt, UK Patent Specification no. 2139039, 1984.
- [72] Stupák, C. - Lukáč, R. - Marchevský, S.: Utilization of the Impulse Detectors in Grayscale Image Filtering, *Journal of Electrical Engineering*, Vol. 51, 07-08 2000, pp. 173-181.
- [73] Stupák, C. - Lukáč, R.: Impulse Detection in Grayscale Images, *Digital Signal Processing '99*, Herľany, Slovakia, Sept. 1999, pp.96-99.
- [74] Stupák, C.: Filtering of the color images distorted by impulse noise, *Radioengineering*, Vol.10, No.3, Sept.2001, pp. 21-27.
- [75] Stupák, C: Optimalizácia kompozičných filtrov a fuzzy filtrov na báze genetických algoritmov, Dizert. práca, Technická univ. v Košiciach, Slovakia, 2000.
- [76] Tang, K. - Astola, J. - Neuvo, Y.: Multichannel edge enhancement in color image processing, *IEEE Trans. on Circ. and Syst. for Video Technology*, Vol. 4, No. 5, Oct. 1994, pp. 468-479.
- [77] Trahanias, P. E. - Venetsanopoulos, A. N.: Vector directional filters - A new class of multichannel image processing filters, *IEEE Trans. Image Processing*, vol. 2, No.4, Oct. 1993, pp. 528-534.
- [78] Trahanias, P. E. -Karakos, D. - Venetsanopoulos, A. N.: Directional processing of color images: Theory and experimental results, *IEEE Trans. on Image Processing*, vol. 5, No. 6, June 1996, pp. 868-880.
- [79] Tukey, J.W.: *Exploratory Data Analysis*, Addison-Wesly: Reading, MA, 1977.
- [80] Tukey, J.W.: Nonlinear (nonsuperposable) methods for smoothing data, *Conference Record*, 1974 EASCON.
- [81] Viero, T. - Öistämö, K. - Neuvo, Y.: Three-dimensional median-related filters for color image sequence filtering, *IEEE Trans. on Circ. and Syst. for Video Technology*, vol. 4, No. 2, Apr. 1994, pp. 129-142.
- [82] Vít, V.: *Televizní technika - přenosové barevné soustavy*, 1.vydání, BEN, Praha, 1997.
- [83] VQEG: The Video Quality Experts Group, <http://www.vqeg.org/>

- [84] Wang, Z. - Bovik, A.C. - Sheikh, H.R. - Simoncelli, E.P.: Image Quality Assessment: From Error Measurement to Structural Similarity, *IEEE Transact. on Image Proc.*, Vol.13, No.1, Jan. 2004, pp. 1-14.
- [85] Wang, Z. - Bovik, C.: A Universal Image Quality Index, *IEEE Signal Processing Letters*, Vol.9, No.3, March 2002, pp. 81-84.
- [86] Wang, Z. - Lu, L. - Bovik, A. C.: Video Quality Assessment Based on Structural Distortion Measurement, *Sig.Processing: Image Communication*, Vol. 19, No. 1, Jan. 2004, pp.1-9.
- [86a] Wang, Z. – Li, Q.: Information Content Weighting for Perceptual Image Quality Assessment. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, VOL. 20, NO. 5, MAY 2011, pp. 1185-1198.
- [87] Weisstein, E. W.: "Method of Steepest Descent." From MathWorld--A Wolfram Web Resource, <http://mathworld.wolfram.com/MethodofSteepestDescent.html>, ©1999-2003.
- [88] Wendt, P. D. - Coyle, E. J. - Gallagher, N. C.: Some convergence properties of median filters, *IEEE Trans. Circuits Syst.*, vol. 34, Mar. 1987, pp. 276-286.
- [89] [www.its.bldrdoc.gov/vqeg/](http://www.its.bldrdoc.gov/vqeg/) - stránka VQEG spravovaná A.Websterom (U.S.Dep.of Commerce, Boulder, Colorado, USA) a P.Corriveau (Intel Corp., Hillsboro, Oregon, USA).
- [90] Yin, L. - Yang, R. - Gabbouj, M. - Neuvo, T.: Weighted median Filters: A tutorial, *IEEE Transact. on Circuits and Systems - II*, Vol.43, No.3, March 1996, pp.157-192.
- [91] Yli-Harja, O. - Astola, J. - Heinonen, P. - Neuvo, Y. Performance of Edge Preserving Median Type Filters in Noisy Conditions, *Proc. IASTED Int. Symp. Appl. Control, Filt., Sig. Proc.*, pp. 68-72, Geneva, Switzerland, June 1987.
- [92] Yli-Harja, O. - Astola, J. - Neuvo, Y.: Analysis of the properties of median and weighted median filters using threshold logic and stack filter representation, *IEEE Trans. Signal Processing*, vol. 39, Feb. 1991, pp. 395-410.
- [93] Yli-Harja, O.: Median Filters: Extensions, Analysis and Design, Thesis, Lappeenranta Univ. of Technology, 1989.
- [94] Zeng, B.: Convergence Properties of Median and Weighted Median Filters, *IEEE Transact. on Signal Processing*, Vol.42, No.2, Dec. 1994, pp. 3515-3518.
- [95] Zeng, K. - Wang, Z.: 3D-SSIM for Video Quality Assesment, *ICIP 2012, IEEE*, pp. 621-624.

## Register

<b>A</b>		filter W-X	45
aditívny šum	8,18	filter Wx1x	45
<b>B</b>		filtračné okno - vplyv	29
block matching method	69	funkcia vierohodnosti	51
<b>C</b>		<b>G</b>	
Cauchyho rozdelenie	50,51	Gaussovo rozdelenie	8,18
CIE	8,14,60	<b>H</b>	
<b>D</b>		Human Visual System (HVS)	8,36,64
detekcia poškodenia	22,23	<b>CH</b>	
detekcia nesprávna - parameter	23	chrominančné zložky	15,17,67
diagram MKO	17	chyba "farebný rozdiel" (CD)	37,60
<b>F</b>		chyba pohybu	43
farebný obraz	13	chyba stredná absolútna (MAE)	58
farebný priestor	14,17	chyba stredná kvadratická (MSE)	59
farebný rozdiel	60	<b>I</b>	
farebný uhol	16	idempotentný filter	29,31,37
farebný vektor	15	i.i.d. vzorky	51
filter adaptívny	19,33,40,57	impulzový šum	19
filter Cross	45	impulzový šum čierno-biely (ČB)	19
filter časový	37	impulzový šum - detekcia	22
filter FMH	8,30	impulzový šum nekorelovaný	8,9,20
filter idempotentný	29,31,37	ITU-štandard	10,58,64
filter LUM	8,22,39	"iskrenie a špina"	10,21
filter marginálny	15,32	<b>J</b>	
filter mediánový centrálny vážený	8,39	jitter effect	15,30,32
filter max-median	31	<b>K</b>	
filter mediánový rekurzívny	8,31	korelácia medzi snímkami	37,61
filter mediánový separovateľný	30	koreňový signál	26,29,30,31,35,37
filter mediánový vektorový	9,33	krivka spektrálnych farieb	17
filter mediánový vektorový smerový	9,34	kvalita - kritérium	58,62
filter mediánový vektorový váhový	33	<b>M</b>	
filter mediánový viacstupňový (MMF)	8,31,38	mapa kvality	66
filter priestorovo-časový	38,45	marginálny prístup	15
filter priestorový	37,45	medián sférický	8,33
filter W - cube	45	medián vážený	9,29
filter W+1+	45	mediánový filter - definícia	25
filter W1+1	46	mediánový filter - vlastnosti	26
filter W1-9-1	46	mediánový filter binárny	27,28
filter W1x1	46	metóda SDM	8,55
filter W5x5x3	45	MKO	8,14
filter W9-1-9	45	myriadový filter - definícia	51

---

myriadový filter optimalizovaný	54	<b>R</b>	
myriadový filter vážený	52	<b>S</b>	
<b>O</b>		simulácia znehodnotenia	19,21
Obrazová sekvencia	12	<b>Š</b>	
okrajové prvky	26,58	škvrny	21
okrajový efekt	26,58	štandardné obrazové sekvencie	13,16
optimalizácia	54	štandardné obrazy	13,16
<b>P</b>		štruktúrálna podobnosť	65
pixel	12	<b>V</b>	
pomer signál - šum	8,59	váhy záporné	29,52
prahová dekompozícia	27	váhy optimálne	54
		vlastnosť nakladania	27



## PRÍLOHY


1. Výsledky filtrácie jednotlivých sekvencií filterami bez detekcie a s detekciou škvŕn: Salesmann, People, Susie, Trevor
2. Porovnanie hodnôt kritéria šrukturálnej podobnosti s hodnotami MAE a MSE pre niektoré typy obrazov, šumov a filtrov

## PRÍLOHA 1 Výsledky filtrácie jednotlivých sekvencií filtraми bez detekcie a s detekciou škvŕn

### Salesman

Tab.P1.1 Filtrácia sekvencie Salesman

Salesman							
č.	Typ filtra	Bez detektora			S detektorom škvŕn (prah detekcie = 40)		
		MAE	MSE	$\Delta R [ \cdot 10^{-3} ]$	MAE	MSE	$\Delta R [ \cdot 10^{-3} ]$
1.	Temporal	1,982	20,5	5,63	0,113	7,66	2,30
2.	W1-9-1	2,674	25,0	5,66	0,112	7,65	2,30
3.	W1+1	2,423	22,6	5,53	0,112	7,65	2,30
4.	W1X1	2,616	25,1	5,61	0,112	7,65	2,30
5.	W9-1-9	4,102	64,0	7,85	0,116	7,71	2,42
6.	W+1+	2,614	28,4	7,49	0,106	7,53	2,32
7.	WX1X	4,542	77,9	6,81	0,123	7,79	2,45
8.	W-Cross	2,571	24,5	9,73	0,114	7,25	2,20
9.	W-X	4,632	78,7	9,83	0,138	7,88	2,57
10.	W-cube3	4,096	60,9	10,49	0,129	7,60	2,43
11.	W5×5×3	6,468	133,0	13,06	0,139	7,66	2,45
12.	MF2	2,391	23,0	6,11	0,112	7,64	2,29
13.	MMF	1,223	14,7	7,09	0,119	7,66	2,34




(a) originál



(b) simulované škrvny (1% plochy)



(c) po filtrácii filtrom MMF bez detektora



(d) po filtrácii Cross-filtrom s detektorom škvŕn

Obr.P1.1 Salesman - 22. snímka

## People

Tab.P1.2 Výsledky filtrácie sekvencie People pomocou rôznych štruktúr priestorovo-časových filtrov

People							
č.	Typ filtra	Bez detektora			S detektorom škvŕn (prah detekcie = 70)		
		MAE	MSE	$\Delta R$ [ $\cdot 10^{-3}$ ]	MAE	MSE	$\Delta R$ [ $\cdot 10^{-3}$ ]
1.	Temporal	4,214	86,5	<b>68,56</b>	0,335	21,44	3,64
2.	W1-9-1	6,240	113,2	71,97	0,330	21,23	3,60
3.	W1+1	5,467	99,7	70,30	0,332	21,30	3,61
4.	W1X1	6,224	117,1	71,34	0,331	21,28	3,60
5.	W9-1-9	7,534	153,3	79,73	0,312	20,27	3,38
6.	W+1+	6,589	130,7	76,59	0,313	20,58	3,41
7.	WX1X	7,318	150,5	79,33	0,313	20,08	3,44
8.	W-Cross	5,817	96,0	83,45	0,310	19,22	3,51
9.	W-X	7,081	132,9	87,23	0,310	18,71	3,47
10.	W-cube3	6,789	118,8	87,92	0,307	18,70	3,46
11.	W5×5×3	8,232	162,4	95,94	<b>0,302</b>	<b>17,84</b>	<b>3,22</b>
12.	MF2	5,468	102,3	75,22	0,331	21,26	3,59
13.	MMF	<b>3,507</b>	<b>69,3</b>	69,20	0,329	20,50	3,68



(a) originál



(b) simulované škrvny (1% plochy)



(c) po filtrácii filtrom MMF bez detektora



(d) po filtrácii filtrom W5×5×3 s detektorom škvŕn

Obr.P1.2 People - 22. snímka

## Susie

Tab.P1.3 Výsledky filtrácie sekvencie Susie pomocou rôznych štruktúr priestorovo-časových filtrov

Susie							
č.	Typ filtra	Bez detektora			S detektorom škvŕn (prah detekcie = 55)		
		MAE	MSE	$\Delta R$ [ $\cdot 10^{-3}$ ]	MAE	MSE	$\Delta R$ [ $\cdot 10^{-3}$ ]
1.	Temporal	1,607	22,0	12,67	0,133	9,14	3,93
2.	W1-9-1	2,871	32,0	14,10	0,132	9,11	3,92
3.	W1+1	2,448	27,3	13,57	0,132	9,12	3,92
4.	W1X1	2,769	31,9	13,81	0,132	9,12	3,93
5.	W9-1-9	3,578	48,9	13,84	0,126	9,14	3,80
6.	W+1+	2,978	38,8	13,46	0,124	9,27	3,82
7.	WX1X	3,451	47,9	13,61	0,128	9,03	3,80
8.	W-Cross	2,902	30,7	16,28	0,123	7,75	3,80
9.	W-X	3,533	42,5	16,95	0,124	7,33	3,61
10.	W-cube3	3,486	39,5	17,28	0,121	7,18	3,62
11.	W5×5×3	4,345	55,0	19,08	<b>0,120</b>	<b>6,31</b>	<b>3,56</b>
12.	MF2	2,418	27,7	14,47	0,131	9,10	3,92
13.	MMF	<b>1,289</b>	<b>18,6</b>	<b>12,50</b>	0,132	8,62	3,88



(a) originál



(b) simulované škvŕny (1% plochy)



(c) po filtrácii filtrom MMF bez detektora



(d) po filtrácii filtrom W5×5×3 s detektorom škvŕn

**Trevor**

Tab.P1.4 Výsledky filtrácie sekvencie Trevor pomocou rôznych štruktúr priestorovo-časových filtrov

Trevor							
č.	Typ filtra	Bez detektora			S detektorom škvŕn (prah detekcie = 30)		
		MAE	MSE	$\Delta R [ \cdot 10^{-3} ]$	MAE	MSE	$\Delta R [ \cdot 10^{-3} ]$
1.	Temporal	1,113	8,5	<b>2,54</b>	<b>0,061</b>	3,65	1,27
2.	W1-9-1	2,026	14,3	2,80	0,064	3,86	1,24
3.	W1+1	1,688	11,3	2,74	0,032	3,71	1,24
4.	W1X1	1,964	14,6	2,69	0,064	3,89	1,27
5.	W9-1-9	3,159	31,3	2,97	0,075	4,09	1,24
6.	W+1+	2,218	18,7	2,85	0,066	3,92	1,27
7.	WX1X	3,168	33,4	2,90	0,078	4,16	1,27
8.	W-Cross	2,270	16,6	4,52	0,071	<b>3,35</b>	<b>1,10</b>
9.	W-X	3,449	36,0	4,99	0,088	3,91	1,20
10.	W-cube3	3,253	29,8	5,22	0,082	3,68	1,11
11.	W5×5×3	4,737	62,0	6,26	0,101	4,67	1,20
12.	MF2	1,748	12,4	2,98	0,063	3,76	1,26
13.	MMF	<b>0,801</b>	<b>6,8</b>	2,66	0,067	3,53	1,19





(a) originál



(b) simulované škrvny (1% plochy)



(c) po filtrácii filtrom MMF bez detektora



(d) po filtrácii filtrom Cross s detektorom škvín

Obr.P1.4 Trevor - 22. snímka

## PRÍLOHA 2 Porovnanie hodnôt kritéria štrukturálnej podobnosti s hodnotami MAE a MSE pre niektoré typy obrazov, šumov a filtrov

Táto príloha sa vzťahuje ku časti 7.3 v hlavnom texte.

Význam symbolov v tabuľkách je nasledovný: MF je mediánový filter, WF je Wienerov filter, ix je impulzový šum s x-percentným pokrytím plochy snímky, gx je Gaussov šum s rozptylom x. Filtračné okná sú štvorcové, trojakej veľkosti.

Tab. P2.1 Vyhodnotenie kvality obrazu ČB Lena pomocou číselných kritérií MAE, MSE, MSSIM

Názov filtrácie	Názov šumu	Filtračné okno	MAE	MSE	MSSIM
MF	i10	3 × 3	5.5614	99.2491	0.8631
		5 × 5	7.1854	160.5121	0.7939
		7 × 7	8.4763	220.1006	0.7418
	i20	3 × 3	6.2461	126.9886	0.8375
		5 × 5	7.6765	177.9087	0.7826
		7 × 7	8.9040	233.8094	0.7331
WF	g10	3 × 3	6.3347	72.3894	0.8147
		5 × 5	6.8659	93.2470	0.8057
		7 × 7	7.9353	125.6377	0.7657
	g20	3 × 3	7.7877	106.8209	0.7446
		5 × 5	7.6011	114.9377	0.7771
		7 × 7	8.4827	146.5138	0.7466

Tab.P2.2 Vyhodnotenie kvality obrazu Most pomocou číselných kritérií MAE, MSE, MSSIM

Názov filtrácie	Názov šumu	Filtračné okno	MAE	MSE	MSSIM
MF	i10	3 × 3	8.5241	176.7847	0.7550
		5 × 5	11.6466	299.7673	0.5809
		7 × 7	13.8741	410.7132	0.4675
	i20	3 × 3	9.3687	215.4441	0.7254
		5 × 5	12.1430	319.9881	0.5677
		7 × 7	14.2856	428.7137	0.4574
WF	g10	3 × 3	8.9978	137.5280	0.7662
		5 × 5	11.2890	216.2511	0.6142
		7 × 7	13.1162	289.5419	0.5145
	g20	3 × 3	9.9774	168.0413	0.7378
		5 × 5	11.7952	236.6949	0.6027
		7 × 7	13.5283	309.9768	0.5043

Tab.P2.3 Vyhodnotenie kvality obrazu Mandrill pomocou číselných kritérií MAE, MSE, MSSIM

Názov filtrácie	Názov šumu	Filtračné okno	MAE	MSE	MSSIM
MF	i10	3 × 3	11.7159	322.7556	0.6000
		5 × 5	14.0562	407.1700	0.4568
		7 × 7	15.4271	467.1823	0.3807
	i20	3 × 3	12.4544	358.9937	0.5755
		5 × 5	14.5162	424.3137	0.4475
		7 × 7	15.8380	481.5613	0.3739
WF	g10	3 × 3	10.7585	197.5574	0.7034
		5 × 5	12.7381	279.8550	0.5583
		7 × 7	14.2326	347.3426	0.4636
	g20	3 × 3	11.8075	236.0179	0.6695
		5 × 5	13.2809	303.0373	0.5435
		7 × 7	14.6524	366.0646	0.4542

Tab.P2.4 Vyhodnotenie kvality obrazu farebná Lena pomocou číselných kritérií MAE, MSE, MSSIM

Názov filtrácie	Názov šumu	Filtračné okno	MAE	MSE	MSSIM
MF	i10	3 × 3	3.7197	58.5733	0.9046
		5 × 5	5.5008	109.1301	0.8378
		7 × 7	6.8197	159.3439	0.7856
	i20	3 × 3	4.4571	86.7961	0.8737
		5 × 5	6.0109	124.3595	0.8260
		7 × 7	7.3225	175.0583	0.7739
WF	g10	3 × 3	5.6637	57.2675	0.8271
		5 × 5	6.0299	73.9732	0.8301
		7 × 7	6.9792	101.9983	0.7927
	g20	3 × 3	7.2620	92.1146	0.7445
		5 × 5	6.9218	95.5305	0.7961
		7 × 7	7.6655	122.7059	0.7706

---

ING. Ľudmila Maceková, PhD., prof. Ing. Stanislav Marchevský, CSc.

Vybrané problémy číslicovej filtrácie  
poškodených obrazových sekvencií  
a vyhodnocovania ich kvality

Vydali: Ľ.Maceková a S. Marchevský v r. 2013 v Košiciach

© 2013, Ing. Ľudmila Maceková, PhD., prof. Ing. Stanislav Marchevský, CSc.

Vydanie prvé, elektronická verzia

Náklad: 100 ks. CD nosičov

Rozsah: 90 strán

ISBN: 978-80-553-1449-5