

**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

**Fakulta strojního inženýrství**

**Doc. RNDr. Miloslav Druckmüller, CSc.**

**ADAPTIVNÍ NUMERICKÉ METODY  
ZPRACOVÁNÍ OBRAZŮ**

(Teze přednášky k profesorskému jmenovacímu řízení)

BRNO 2001

ISBN 80-214-1851-6

© 2001 M. Druckmüller

**Miloslav Druckmüller** se narodil 24. 9. 1954 v Brně. V letech 1970–1974 studoval na přírodovědném gymnáziu se zaměřením na matematiku v Brně, tř. kpt. Jaroše 14. Studium zakončil maturitní zkouškou s vyznamenáním v roce 1974. V letech 1974–1979 studoval na Přírodovědecké fakultě Univerzity J. E. Purkyně v Brně, obor odborná matematika. Studium zakončil s vyznamenáním, obhajobou diplomové práce na téma Eulerova čísla a státní závěrečnou zkouškou. V letech 1979–1982 byl zaměstnán na Fakultě strojní Vysokého učení technického v Brně ve funkci asistenta. V roce 1980 obhájil rigorózní práci na téma E-irregulární prvočísla na Přírodovědecké fakultě UJEP Brno a získal titul doktora přírodních věd. V letech 1983–1995 pracoval ve funkci odborného asistenta na katedře matematiky a deskriptivní geometrie FS VUT, dnes Ústavu matematiky FSI VUT v Brně. V roce 1988 obhájil dizertační práci na téma Systém zpracování dat postupy fuzzy matematiky v inženýrských disciplínách na FS VUT Brno a získal vědeckou hodnost kandidáta věd. V roce 1995 obhájil habilitační práci na téma Vícehodnotové logické systémy pro technické aplikace a byl jmenován docentem pro obor matematika na FS VUT. Od roku 1995 do současnosti pracuje jako docent na Ústavu matematiky FSI VUT.

Je autorem nebo spoluautorem 42 publikací v časopisech a sbornících konferencí, 6 vysokoškolských skript, 3 oponovaných výzkumných zpráv a 6 rozsáhlých vědeckých softwarových systémů chráněných autorskými právy. Byl řešitelem nebo spoluřešitelem 9 výzkumných projektů a grantů.

Jeho vědecko-výzkumnou činnost lze rozdělit do dvou oblastí. První oblastí jsou vícehodnotová logika, teorie fuzzy množin a technické aplikace těchto disciplín. Je autorem matematické teorie vícehodnotového logického systému LMPS, který dosáhl značného rozšíření i praktického využití (řízení cementářské pece, medicínské aplikace v oblasti transkutánní oxymetrie aj.). Druhou oblastí jsou numerické metody analýzy obrazů. Je autorem matematické teorie obrazových analyzátorů DIPS a ACC. Oba systémy patří mezi nejrozšířenější vědecké obrazové analyzátory (celkově asi 100 instalací) u nás a jsou užívány i v zahraničí (Rakousko, SRN, Francie).

Jeho pedagogická činnost je spjata s FSI VUT. Za své dvaadvacetileté pedagogické činnosti připravil a zavedl celkem 9 nových předmětů z oblasti aplikované matematiky. Na FSI VUT zavedl výuku numerických metod analýzy obrazů, která je dnes součástí učebních plánů na několika specializacích. V postgraduálním a doktorském studiu připravil celkem 8 předmětů. Na Ústavu matematiky FSI VUT se věnuje vědecké přípravě doktorandů. Dva z jeho doktorandů, věnujících se numerickým metodám analýzy obrazů, úspěšně ukončili studium v roce 2000, další čtyři, pracující na uvedené problematice, vede jako školitel v současnosti.

Mezi jeho osobní zájmy patří především fotografie, astronomie, pěstování kaktusů, turistika a horolezectví.

## 1. Úvod

Lidský zrak je nesmírně dokonalý a komplikovaný systém, kterým člověk získává převážnou většinu informací o světě, ve kterém žije. Současné technické možnosti umožňují sestavit snímací systémy, které v mnoha směrech překonávají schopnosti lidského zraku. Příkladem mohou být současné chlazené CCD kamery, které mají vyšší citlivost ke světlu než lidské oko a umožňují pracovat v daleko širším rozsahu vlnových délek. Při praktickém využití obrazu však vždy nakonec nastupuje lidský zrak, který pozoruje a hodnotí pořízený obraz. Se vzrůstající kvalitou snímacích zařízení stále více vyvstává závažný problém spočívající v tom, že obraz může obsahovat řadu informací pro oko neviditelných. Souvisí to s dynamickým rozsahem obrazu a metodami jeho rekonstrukce.

Lidské oko můžeme chápat jako diferenciální analyzátor, který má vynikající schopnosti vyhodnocovat změny jasu v závislosti na prostorových souřadnicích, avšak má jen velmi malou přesnost určení absolutního jasu. Proto má zásadní vliv na vnímání obrazů jejich **kontrast**, který vyjadřuje rozdíly v jasu mezi jednotlivými částmi obrazu. Při maximálním kontrastu, který jsou v současné době schopné poskytnout běžně používané technické systémy rekonstrukce obrazů (počítačové monitory, tiskové metody, fotografické chemické procesy, aj.), je lidské oko schopné rozlišit maximálně několik set úrovní jasu. Za optimálních pozorovacích podmínek je to asi 100 až 300 úrovní jasu (viz [1]). S touto skutečností počítají většinou běžné snímací digitální systémy, které používají osmibitovou reprezentaci jasu, tj. pracují s  $2^8 = 256$  úrovněmi jasu. Počet bitů použitých k reprezentaci úrovní jasu budeme dále nazývat **dynamickým rozsahem obrazu**. Současné zobrazovací systémy používané pro vědecké účely však běžně pracují s dvanáctibitovým ( $2^{12} = 4096$  úrovní jasu), kvalitnější systémy i s šestnáctibitovým dynamickým rozsahem ( $2^{16} = 65\,536$  úrovní jasu). Obrazy s tímto vysokým dynamickým rozsahem nutně obsahují informace pro oko neviditelné, neboť oko není schopno rozlišit tak vysoký počet úrovní jasu. Navíc ani systémy rekonstrukce obrazu nejsou schopny takový počet úrovní jasu reprodukovat. K vizualizaci obrazu s vysokým dynamickým rozsahem (více než osm bitů) je nutné užít vhodných numerických metod zpracování obrazu, jinak většina informací obsažených v obraze zůstane lidskému zraku skryta.

S popsáním problémem se lze setkat v mnoha vědních oborech pracujících s digitálními zobrazovacími metodami a ve většině případů je to problém velmi vážný. Z mnoha různých oborů uvedme například výzkum materiálů (vizualizace obtížně rozpoznatelných materiálových struktur), defektoskopii (hledání nekontrastních struktur ve velmi kontrastních obrazech), fluorescenční mikroskopii (zpracování obrazů s extrémním kontrastem), medicínu (analýza obrazů z počítačového tomografu s vysokým dynamickým rozsahem), letecký a kosmický výzkum (vizualizace nekontrastních objektů a struktur v leteckých snímcích a snímcích kosmických sond), kriminalistiku (hledání obtížně rozpoznatelných stop a příznaků v obrazech), astronomii (analýza extrémně kontrastních obrazů s nekontrastními strukturami jako jsou sluneční korona, galaxie apod.).

## 2. Analýza obrazu po částech

Důvod, proč lidský zrak nemůže využít veškeré informace obsažené v obraze s velkým dynamickým rozsahem, spočívá v tom, že jednotlivé diskrétní úrovně jasu se liší tak málo, že lidský zrak je není schopen rozlišit. Nejjednodušším řešením se

jeví zvětšení rozdílu mezi jednotlivými úrovněmi jasu, které se projeví jako zvětšení kontrastu obrazu. Toto řešení má však velmi omezené použití, neboť se vzrůstajícím rozdílem mezi jednotlivými diskrétními hladinami jasu rostou požadavky na kontrast, který musí daný zobrazovací systém reprodukovat. Pokud překročíme maximální kontrast, který je schopen systém reprodukovat, dojde k degradaci obrazu – ztrátě informace v tmavé nebo světlé části obrazu. Ovšem i takto degradovaný obraz lze využít. Různým nastavením celkového jasu obrazu lze měnit část zobrazenou bez degradace s vysokým kontrastem a postupně si prohlédnout celý obraz. Musíme pak ovšem spoléhat na schopnost člověka představit si obraz, který vidí postupně po částech. Tato velmi jednoduchá metoda byla používána v době, kdy výkonnost počítačů neumožňovala jiná řešení, a je často používána i dnes. Příkladem může být práce s obrazy pořízenými počítačovým tomografem pro lékařské účely, kde je to většinou základní metoda vizualizace obrazů s vysokým dynamickým rozsahem.

Z matematického hlediska můžeme popsání postup chápat jako transformaci hodnot obrazových bodů (pixelů) ve tvaru:

$$b_{i,j} = \begin{cases} m & \text{pro } a_{i,j} < \frac{m-q}{k} \\ [k a_{i,j}] + q & \text{pro } \frac{m-q}{k} \leq a_{i,j} \leq \frac{n-q}{k} \\ n & \text{pro } a_{i,j} > \frac{n-q}{k} \end{cases}, \quad (2.1)$$

kde  $a_{i,j}$  jsou obrazové body (pixely) původního obrazu s velkým dynamickým rozsahem reprezentované celými čísly (např. u šestnáctibitového obrazu celými čísly z intervalu  $\langle 0, 65\,535 \rangle$ ),  $b_{i,j}$  jsou obrazové body výsledného zpracovaného obrazu s dynamickým rozsahem (nejčastěji osm bitů), který je možné plně reprodukovat na daném zobrazovacím zařízení, a navíc je oko schopné rozlišit všechny úrovně jasu tohoto obrazu,  $k > 0$  je (multiplikativní) reálná konstanta určující kontrast výsledného obrazu,  $q$  je (aditivní) reálná konstanta určující jas výsledného obrazu, interval  $\langle m, n \rangle$  určuje rozsah hodnot pixelů, který je schopno reprodukovat zobrazovací zařízení (při osmibitové reprezentaci obrazu je to interval  $\langle 0, 255 \rangle$ ) a  $[ ]$  značí celočíselné zaokrouhlení reálného čísla. Pokud ve vztahu (2.1) nastane první případ, nastane degradace obrazu, kterou budeme nazývat **podtečení** (obrazový bod je černý), nastane-li případ třetí, nastane degradace obrazu zvaná **přetečení** (obrazový bod je bílý).

### 3. Metody založené na transformaci histogramu obrazu

Pokud nejsme ochotni připustit degradaci obrazu podtečením nebo přetečením, musíme postupovat poněkud jinak než v 2. kapitole. Označme  $D$  množinu všech jasových úrovní obrazu s vysokým dynamickým rozsahem a označme  $H$  množinu všech jasových úrovní zpracovaného obrazu s dynamickým rozsahem, který je schopné reprodukovat zobrazovací zařízení a které je schopno rozpoznat lidské oko. Hledejme neklesající funkci  $f : D \rightarrow H$  tak, aby došlo k "minimální ztrátě informací" obsažených v obraze. Uvozovky v předešlé větě mají naznačit, že se jedná o požadavek velice vágní a že může existovat řada kritérií, podle kterých budeme "ztrátu informace" posuzovat. V praxi se poměrně dobře osvědčila kritéria založená na analýze histogramu četností výskytu jednotlivých jasových úrovní ve výsledném obraze (viz [2], [4]). V praxi nejužívanější kritérium vychází z hypotézy, že optimální obraz má rovnoměrné rozložení četností výskytu jednotlivých jasových úrovní. Aplikujeme-li tuto hypotézu, dostaneme následující postup pro zpracování obrazu s velkým dynamickým rozsahem.

Nechť  $D$  je množina všech celých čísel ležících v intervalu  $\langle k, l \rangle$ , nechť  $H$  je množina všech celých čísel ležících v intervalu  $\langle m, n \rangle$ . Nechť  $A = [a_{i,j}]$ ,  $a_{i,j} \in D$  je obrazová matice (matice pixelů) původního obrazu a  $B = [b_{i,j}]$ ,  $b_{i,j} \in H$  je obrazová matice výsledného obrazu. Hledejme neklesající funkci  $f : D \rightarrow H$  tak, aby četnost výskytu prvků z množiny  $H$  v obrazové matici  $B$  měla rovnoměrné rozložení.

Výše popsaná úloha není obecně řešitelná, stane se však řešitelnou v případě, že budeme předpokládat, že náhodná veličina, jejíž realizací jsou prvky matice  $A$ , je spojitá. Tento předpoklad sice není splněn, ale vzhledem k tomu, že obraz s velkým dynamickým rozsahem má obvykle několik desítek tisíc diskrétních úrovní jasu, je chyba, které se záměnou diskrétní náhodné veličiny za spojitou náhodnou veličinu dopustíme, většinou zanedbatelná. Hledaná funkce  $y = f(x)$ ,  $x \in D$ ,  $y \in H$  má pak tvar

$$f(x) = \begin{cases} \text{trunc}(m + (n - m + 1) \Phi(x)) & \text{pro } x < l \\ n & \text{pro } x = l \end{cases}, \quad (3.1)$$

kde  $\Phi(x)$  je distribuční funkce náhodné veličiny, jejíž realizací jsou prvky matice  $A$ . Tuto funkci v praxi nahradíme normovaným kumulativním histogramem četností výskytu jasových úrovní z  $D$  v obrazové matici  $A$ .

Popsaná metoda nazývaná **vyrovnání (ekvalizace) histogramu** zajistí optimální (dle výše uvedeného kritéria) využití všech okem rozlišitelných jasových úrovní v obraze  $B$ , tím však ještě zdaleka nemusí být dosaženo toho, že oko je schopno rozpoznat veškeré objekty a struktury obsažené v původním obraze  $A$ . Výše uvedené kritérium definující optimální výsledný obraz můžeme nahradit řadou dalších kritérií (např. požadovat jiné rozložení četností jasových úrovní), a tím se pokusit o zviditelnění specifických objektů či struktur, avšak zásadního zlepšení oproti (3.1) obvykle nelze dosáhnout. Metody popsané v 2. a 3. kapitole v podstatě vyčerpávají možnosti vizualizace obrazů s vysokým dynamickým rozsahem založené na transformaci jasových úrovní. Pro úplnost je nutné ještě dodat, že existují metody, které pracují s funkcí  $f : D \rightarrow H$ , která není monotónní, tj. některé části obrazu jsou zobrazeny pozitivně a jiné negativně. Tyto metody však mají jen velmi omezené využití a mohou vést k mylné interpretaci obrazu (viz [4]).

## 4. Metody založené na Fourierově transformaci

Integrální transformace (Fourierova, sinová, kosinová, Walshova-Hadamardova, ...) patří mezi základní matematické nástroje pro analýzu a zpracování digitálních obrazů (viz [2], [3]). Lze je využít i k vizualizaci obrazů s velkým dynamickým rozsahem. Za klasické lze dnes považovat především užití Fourierovy transformace. Pro zjednodušení zpočátku předpokládejme, že obraz není diskrétní, ale že je spojitý, a že je určen spojitou periodickou funkcí  $f(x, y)$  s periodou  $p_x$  ve směru souřadnicové osy  $x$  a periodou  $p_y$  ve směru souřadnicové osy  $y$ . Pak definujeme (dvourozměrnou) Fourierovu transformaci  $f(x, y)$  vztahem

$$F(\omega_x, \omega_y) = \frac{1}{p_x p_y} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-i \left( \frac{\omega_x x}{p_x} + \frac{\omega_y y}{p_y} \right)} dx dy, \quad (4.1)$$

kde  $F(\omega_x, \omega_y)$  je **Fourierovo spektrum** a  $\omega_x$ ,  $\omega_y$  jsou **prostorové frekvence**.  $|F(\omega_x, \omega_y)|$  nazýváme **amplitudovým spektrem** a  $\arg F(\omega_x, \omega_y)$  nazýváme **fázovým**

**spektrém.** Existence zpětné Fourierovy transformace, která převede Fourierovo spektrum  $F$  zpět na funkci (obraz)  $f$ , umožňuje provádět různé úpravy spektra a zkoumat jejich vliv na obraz pozorovaný lidským okem. Zatímco libovolný zásah do fázového spektra obrazu se projeví znatelnou degradací obrazu (posuny objektů, deformace tvarů objektů), jsou zásahy amplitudového spektra méně patrné a za jistých okolností mohou subjektivně výrazně zlepšit kvalitu obrazu. Toho lze úspěšně využít k vizualizaci obrazů s velkým dynamickým rozsahem.

V praxi je situace poněkud složitější, protože obraz není reprezentován ani spojitou ani periodickou funkcí. Proto musíme nahradit Fourierovu transformaci **diskrétní Fourierovou transformací** a formálně dodefinovat obraz tak, aby byl periodickou funkcí v obou souřadnicových směrech. Transformace pak bude mít tvar:

$$F(n_1, n_2) = \frac{1}{N_1 N_2} \sum_{k_1=0}^{N_1-1} \sum_{k_2=0}^{N_2-1} f(k_1, k_2) e^{-i\left(\frac{2\pi n_1 k_1}{N_1} + \frac{2\pi n_2 k_2}{N_2}\right)}, \quad (4.2)$$

kde funkce  $f(k_1, k_2) = a_{k_1, k_2}$  je definována obrazovou maticí  $A = [a_{k_1, k_2}]$  typu  $N_1 \times N_2$ . Prostorové frekvence jsou pak určeny vztahy:

$$\omega_x = \frac{2\pi n_1}{N_1}, \quad \omega_y = \frac{2\pi n_2}{N_2}. \quad (4.3)$$

Postupy vizualizace obrazů s vysokým dynamickým rozsahem založené na Fourierově transformaci vycházejí ze skutečnosti, že u většiny reálných obrazů klesá kontrast se vzrůstající prostorovou frekvencí, tj. jemné detaily mají v obraze malý kontrast. Zvýšíme-li kontrast na vysokých prostorových frekvencích a pak obraz transformujeme některým z postupů popsaných v kapitolách 2. a 3., dostaneme obraz, který umožňuje oku rozpoznat větší množství detailů než obrazy získané pouze využitím metod z výše uvedených kapitol. Praktická realizace sestává z následujících kroků:

1. Výpočet diskrétní Fourierovy transformace obrazu s velkým dynamickým rozsahem dle (4.2).
2. Modifikace Fourierova spektra  $F(n_1, n_2)$  tak, aby nedošlo ke změně fázového spektra. K tomuto účelu použijeme nezápornou reálnou funkci  $M(n_1, n_2)$ , kterou budeme nazývat **frekvenční filtr**. Modifikované spektrum  $F^*(n_1, n_2)$  má tvar

$$F^*(n_1, n_2) = F(n_1, n_2) M(n_1, n_2), \quad (4.4)$$

přičemž frekvenční filtr musí být volen tak, aby zvýrazňoval vysoké prostorové frekvence a zachovával nebo mírně potlačoval nízké prostorové frekvence. Konkrétní volba filtru může být provedena na základě řady kritérií, která by měl splňovat výsledný obraz. Dvě z těchto kritérií jsou v praxi nejdůležitější. První kritérium požaduje, aby obraz po zpětné Fourierově transformaci nebyl zdegradován podtečením a přetečením, tj. hodnoty pixelů nesmí překročit dynamický rozsah obrazu. Druhé kritérium obvykle požaduje, aby směrodatná odchylka aditivního šumu (charakteristika míry degradace obrazu šumem) nepřekročila definovanou hraniční hodnotu. Vzhledem k tomu, že aditivní šum se vyskytuje především na vysokých prostorových frekvencích (viz [2]), vede použití výše uvedeného frekvenčního filtru vždy ke zvýraznění aditivního šumu. Mírné zvýraznění nemusí být z hlediska vnímání

obrazu na závadu, při překročení určité hranice však zhorší schopnost oka vnímat objekty a struktury v obraze.

3. Zpětná diskretní Fourierova transformace modifikovaného spektra  $F^*(n_1, n_2)$  dle vztahu

$$f^*(k_1, k_2) = \sum_{n_1=0}^{N_1-1} \sum_{n_2=0}^{N_2-1} F^*(n_1, n_2) e^{i(\frac{2\pi n_1 k_1}{N_1} + \frac{2\pi n_2 k_2}{N_2})} \quad (4.5)$$

a vytvoření modifikovaného obrazu s vysokým dynamickým rozsahem, jehož obrazová matice  $A^* = [a_{k_1, k_2}^*]$  je určena vztahem  $a_{k_1, k_2}^* = \text{round}(f^*(k_1, k_2))$ .

4. Transformace obrazu s vysokým dynamickým rozsahem  $A^*$  na obraz  $B$ , jehož všechny jasové úrovně je lidské oko schopno rozlišit. K tomuto účelu lze užít např. (3.1), lze však použít i prostou lineární transformaci jasových úrovní.

Největším problémem celého popsaného postupu je nalezení vhodného frekvenčního filtru, a to především s ohledem na krok 3. Tento filtr se musí obvykle navrhnout individuálně pro každý obraz. Návrh takového filtru je téměř vždy kompromisem, zvláště u obrazů, které se skládají z výrazně odlišných částí co do struktury nebo jasu. Je zjevné, že by bylo vhodné vytvořit filtr, který by se choval různě v různých částech obrazu. Totéž ovšem platí pro metody založené na transformaci histogramu obrazu, jako je například (3.1). I zde platí, že transformace odvozená na základě znalosti histogramu celého obrazu nemusí být vyhovující v těch částech obrazu, jejichž histogram je výrazně odlišný od histogramu obrazu celého. Tyto úvahy nakonec vedly ke vzniku algoritmů pro zpracování obrazů, které se mění na základě lokálních vlastností obrazů, pro které se vžil název **adaptivní filtry**.

## 5. Adaptivní filtry

### 5.1 Lidský zrak jako motivace pro studium adaptivních filtrů

Lidský zrak je obdařen schopností pozorovat a vnímat obrazy s extrémně vysokým kontrastem (více než 1 : 1 000 000) a přitom v nich rozpoznávat velmi nekонтastní struktury a objekty. Tím zdánlivě značně překonává možnosti současných snímacích systémů. Ve skutečnosti je možné zaznamenat obraz s takto vysokým kontrastem, avšak nelze jej rekonstruovat tak, aby oko bylo schopno rozlišit veškeré informace v obraze obsažené. Platí to nejen o digitálním záznamu obrazu, ale dokonce i o klasické fotografii. Současné barevné negativní filmy využívají takzvané DIR (Developer Inhibitor Release) komponenty, které umožnily zvýšit dynamický rozsah filmů tak, že je možné zaznamenat obrazy s kontrastem více než 1 : 1 000 000.

Přímý pohled okem tedy zatím neumíme nahradit žádným zobrazovacím technickým systémem. Mimořádné schopnosti lidského zraku jsou pozoruhodné především proto, že oko není z optického hlediska příliš dokonalé (chápáno při současném stavu techniky) a ani sítnice lidského oka není příliš dokonalý snímací prvek (značná nehomogenita, existence slepé skvrny, rozdílná spektrální citlivost v různé vzdálenosti od optické osy apod.). Navíc zrak pracuje jako diferenciální analyzátor (jak již bylo uvedeno výše) a umí tedy porovnávat jas jen velmi blízkých oblastí. Nemá schopnost absolutního určení jasu ani porovnávání jasu oblastí v obraze velmi vzdálených. Je tedy zřejmé, že součástí lidského vnímání musí být velmi dokonalý systém následného zpracování pozorovaného obrazu, který, pokud jej alespoň částečně pochopíme, může být motivací pro vývoj numerických metod zpracování obrazů.



Lidské oko nepozoruje obraz jako celek, ale analyzuje jej po částech. K jednotlivým částem obrazu přistupuje rozdílně. Mění zaostření, citlivost, světelnost optické soustavy a jiné parametry. Každý obrazový element analyzuje tak, že jej srovnává ze jeho okolí. Toto okolí je navíc proměnné co do velikosti i tvaru. Velikost okolí závisí na velikosti zkoumaných objektů a struktur, ale též na intenzitě světla. Tvar okolí je proměnný proto, že oko respektuje významná rozhraní jasu v obraze a srovnává obrazový element vždy s tou částí obrazu, která je v nějakém smyslu příbuzná s vyhodnocovaným obrazovým elementem. Výsledný zrakový vjem pak vzniká celkovou syntézou jednotlivých pozorování. Výsledný obraz, který vnímáme, je tedy jakási "virtuální realita", která je stále modifikována na základě nových dat.

Výše uvedený model lidského zraku je sice značně zjednodušený (například nezabývá se vůbec biologickou stránkou problému), ale obsahuje důležité motivace pro metody vizualizace obrazů s velkým dynamickým rozsahem. Má-li být obraz s vysokým dynamickým rozsahem transformován na podstatně nižší dynamický rozsah, který jsme technicky schopni reprodukovat, a má-li obraz co nejvíce odpovídat reálnému pohledu lidským okem, je nutné napodobit algoritmy, které užívá lidský zrak. Podstatným rysem těchto algoritmů musí být schopnost adaptace algoritmu na měnící se vlastnosti obrazu. Proto se pro numerické metody zpracování obrazů užívající těchto principů používá název **adaptivní filtry**.

## 5.2 Adaptivní transformace kontrastu

Pokusme se nyní aplikovat úvahy o principech lidského vnímání na metody vizualizace obrazů založené na transformaci histogramu (kapitola 3.). Největší nedostatek těchto metod, jako je například metoda vyrovnání (ekvalizace) histogramu (3.1), spočívá v tom, že funkce  $f$  použitá k transformaci jasu obrazu a určující kontrast detailů v obraze je odvozena z relativního kumulativního histogramu celého obrazu. Z hlediska celého obrazu je optimální (dle kritéria uvedeného v 3.1), avšak v některých částech obrazu může být zcela nevyhovující, protože histogram této části obrazu může být velmi rozdílný od histogramu obrazu celého. Podstatného zlepšení dosáhneme, pokud vzorec (3.1) nahradíme vzorcem

$$b_{i,j} = \begin{cases} \text{trunc}(m + (n - m + 1) \Phi_{O_{i,j}}(a_{i,j})) & \text{pro } a_{i,j} < l \\ n & \text{pro } a_{i,j} = l \end{cases}, \quad (5.2.1)$$


kde  $\Phi_{O_{i,j}}$  značí histogram relativních kumulativních četností hodnot pixelů v okolí  $O_{i,j}$  pixelu  $a_{i,j}$ . Ostatní označení je stejné jako v kap. 3. Okolí  $O_{i,j}$  se většinou volí čtvercové, protože pak lze použít rekurentní algoritmus výpočtu  $\Phi_{O_{i,j}}$  (viz [2]). Volba jiného typu okolí podstatně zpomalí výpočet, neboť kumulativní histogram je nutné pro každé okolí  $O_{i,j}$  počítat samostatně. Metoda užívající pro zpracování obrazu vzorce (5.2.1) se nazývá **adaptivní vyrovnání (ekvalizace) histogramu**.

Metoda adaptivní ekvalizace obvykle umožní dokonalou vizualizaci malých objektů a struktur, jejichž velikost je podstatně menší než velikost použitého okolí  $O_{i,j}$ . Velké objekty a struktury však mohou být zobrazeny tak, že je nemusí být možné rozpoznat (viz [4]). Navíc se v obraze zcela ztratí informace o absolutním jasu pixelů, protože po provedení adaptivní ekvalizace (5.2.1) je jas pixelů vždy už jen relativní vzhledem k okolí  $O_{i,j}$ . Dobrým řešením je obvykle kompromis mezi postupy (3.1) a (5.2.1). Obraz se zpracuje oběma postupy a poté se vytvoří vážený průměr obou výsledných

obrazů s vhodně volenými váhami. Tato metoda se nazývá **adaptivní semiekvalizace histogramu** (viz [4]). Tato metoda je poměrně velkým pokrokem v možnostech zpracování obrazů s velkým dynamickým rozsahem, avšak stále je poměrně vzdálena schopností lidského oka. Je to způsobeno použitím jediného pevně zvoleného typu okolí  $O_{i,j}$  pro celý obraz. To se projeví zvláště negativně v místech výrazných hranic mezi oblastmi s velmi rozdílným jasnem nebo velice rozdílným typem rozložení hodnot pixelů. Pokud  $O_{i,j}$  zasahuje do obou oblastí, je metoda (5.2.1) velmi vzdálena od optimální transformace jasu pro obě oblasti. Jediným řešením je použití proměnného typu (tvaru) okolí, který "respektuje hranice" mezi oblastmi s výrazně rozdílným rozložením hodnot pixelů.

### 5.3 Adaptivní okolí, $V_{d,w}$ -okolí, $A_{k,w}$ -okolí

Řešení výše popsaného problému spočívá v použití okolí  $O_{i,j}$ , které má proměnný tvar v závislosti na lokálních vlastnostech obrazu. Takový typ okolí budeme nazývat **adaptivní okolí**. Abychom však mohli takové okolí sestrojít, potřebujeme informace o lokálních vlastnostech obrazu. Ty však získáme opět jedině analýzou vhodného okolí pixelu  $a_{i,j}$ . Proto má tvorba adaptivního okolí vždy minimálně dva kroky. Prvním je sestrojení okolí  $O_{i,j}^*$  pevného předem zadaného typu (např. čtvercové okolí). Na základě analýzy vlastností obrazu v tomto okolí (nejčastěji analýza histogramu) sestrojíme nové okolí  $O_{i,j}$  takové, že  $O_{i,j} \subset O_{i,j}^*$ . Následující dva typy adaptivních okolí dávají při vizualizaci obrazů s velkým dynamickým rozsahem velmi dobré výsledky (viz [4]).



Obr. 1.

$V_{d,w}$ -okolím nebo též okolím **Cluster Value** pixelu  $a_{i,j}$  budeme nazývat množinu pixelů

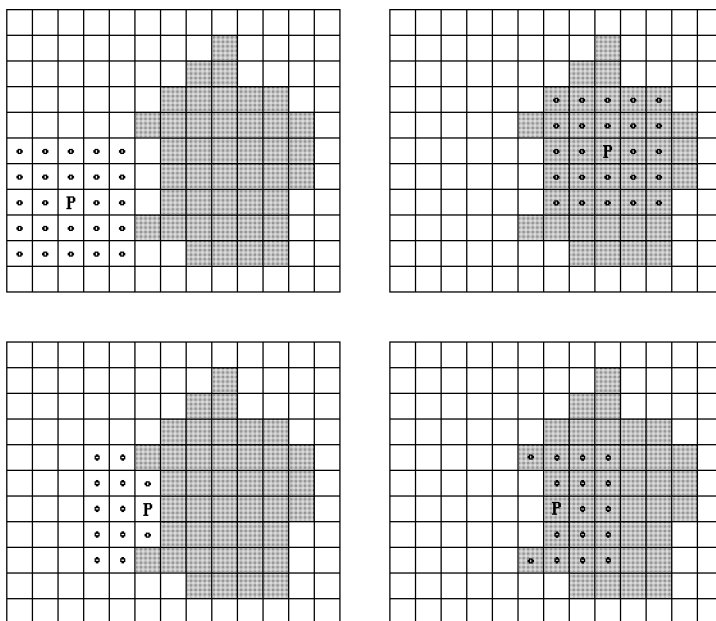
$$O_{i,j} = \{(r, s) \in S_w(i, j) : |a_{i,j} - a_{r,s}| \leq d\}, \quad (5.3.1)$$

kde  $S_w(i, j)$  je čtvercové okolí se středem v  $(i, j)$  a délkou strany  $w$  pixelů. Konstanta  $d$  určuje "míru adaptace okolí". Zvolíme-li příliš vysokou hodnotu  $d$  (blízkou dynamickému rozsahu obrazu), bude s vysokou pravděpodobností platit  $S_w(i, j) = O_{i,j}$  a adaptivní vlastnosti okolí se nijak neprojeví. Pokud zvolíme hodnotu  $d$  velmi malou,

bude okolí  $O_{i,j}$  obsahovat velmi malý počet pixelů nebo dokonce jen samotný pixel  $a_{i,j}$ , což povede k naprosté degradaci obrazu. Proto správná volba  $d$  má zásadní vliv na kvalitu výsledného obrazu. Optimální hodnota  $d$  bývá většinou blízká hodnotě  $d = w^2/2$ .

Na Obr. 1. je ukázka  $V_{d,w}$ -okolí, která ilustruje "přizpůsobení okolí" tvaru objektu. Pixely objektu jsou označeny šedě, pixely pozadí bíle. Pixely patřící do  $V_{d,w}$ -okolí pixelu  $P$  jsou vyznačeny symbolem  $\circ$ .

Při vysokém rozptylu hodnot pixelů (obraz se složitou kontrastní strukturou) se může stát, že nalezení vhodné hodnoty  $d$  není možné. Je to způsobeno tím, že při velké hodnotě  $d$  nejsou dostatečně respektována rozhraní jasu v obraze. Pokud tuto hodnotu poněkud snížíme, dojde ke skokové změně a okolí budou obsahovat vždy jen několik málo pixelů. Tento problém se dá vyřešit použitím následujícího typu okolí.



Obr. 2.

$A_{k,w}$ -okolím nebo též okolím **Cluster Area** pixelu  $a_{i,j}$  budeme nazývat množinu pixelů  $O_{i,j}$ , která splňuje následující axiomy:

- 1) Počet prvků množiny  $O_{i,j}$  je  $k$ .
- 2) Počet prvků množiny  $O_{i,j} \subset S_w(i, j)$ , kde  $S_w(i, j)$  je čtvercové okolí se středem v  $(i, j)$  a délkou strany  $w$  pixelů.
- 3) Výraz

$$\sum_{(r,s) \in V} |a_{r,s} - a_{i,j}| \quad (5.3.2)$$

nabývá svého minima pro  $V = O_{i,j}$ , přičemž  $V$  je libovolná  $k$  prvková podmnožina  $S_w(i, j)$ .

Je zřejmé, že může existovat více různých  $A_{k,w}$ -okolí téhož pixelu (na rozdíl od  $V_{d,w}$ -okolí). Při praktickém použití vybereme libovolné z těchto okolí. Jeho volba nemá žádný vliv na zpracování obrazu, neboť pro výpočet (5.2.1) použijeme  $\Phi_{O_{i,j}}$ , a to je nezávislé na volbě  $A_{k,w}$ -okolí, neboť hodnoty pixelů mají na všech těchto okolích stejný histogram.

Smysl použití  $A_{k,w}$ -okolí spočívá v tom, že okolí má zadaný (pevný) počet pixelů. Tím zabráníme negativním efektům, které mohou způsobit příliš malá  $V_{d,w}$ -okolí. Na Obr. 2. je ukázka  $A_{k,w}$ -okolí, která ilustruje "přizpůsobení okolí" tvaru objektu. Pixely objektu jsou označeny šedě, pixely pozadí bíle. Pixely patřící do  $A_{k,w}$ -okolí pixelu  $P$  jsou vyznačeny symbolem  $\circ$ .

#### 5.4 Adaptivní filtry založené na analýze šumu

Zbývá vyřešit poslední vážný problém metod založených na metodě (3.1), resp. (5.2.1). Veškeré předešlé úvahy o vizualizaci obrazů s velkým dynamickým rozsahem vycházely z předpokladu, že obraz neobsahuje žádný šum nebo že z hlediska pozorovatele lze tento šum zanedbat. V praxi však každý obraz obsahuje šum, a to především šum aditivní.

**Aditivní šum** lze definovat tak, že skutečný obraz  $A = [a_{i,j}]$  lze zapsat ve tvaru

$$A = B + S, \quad 5.4.1$$

kde  $B = [b_{i,j}]$  je dokonalý (hypotetický) obraz a  $S = [s_{i,j}]$  je obraz, jehož hodnoty pixelů  $s_{i,j}$  jsou stochasticky nezávislé realizace náhodné veličiny  $X$ . Číselné a funkční charakteristiky náhodné veličiny  $X$  (distribuční funkce, pravděpodobnostní funkce, střední hodnota, rozptyl,...) budeme nazývat **charakteristikami aditivního šumu** v obraze  $A$ . Většinou aditivní šum mívá normální (Gaussovo) rozložení a pak se nazývá **Gaussovský aditivní šum**. Pro praxi je nutné nějakým způsobem měřit "míru degradace" obrazu aditivním šumem. K tomuto účelu se většinou užívá **směrodatná odchylka**  $\sigma$  aditivního šumu. Vzhledem k tomu, že můžeme analyzovat jen obraz  $A$ , protože obrazy  $B$  a  $S$  neznáme, nemůžeme ani přímo určit  $\sigma$ . Pokud však budeme předpokládat, že aditivní šum je **nezávislý na obraze** (tj.  $A$  a  $S$  jsou stochasticky nezávislé statistické soubory hodnot pixelů), existují metody, jak hodnotu  $\sigma$  odhadnout. Nejznámější metoda je založena na analýze autokorelační funkce (viz [2]). Předpoklad o nezávislosti aditivního šumu na obraze je téměř dokonale splněn pro CCD kamery s přímým digitálním záznamem obrazu. Naopak neplatí pro televizní CCD kamery, což je způsobeno analogovým přenosem televizního signálu a s tím souvisejícím omezením šířky přenášeného frekvenčního pásma. I v tomto případě lze hodnotu  $\sigma$  statistickými metodami odhadnout, avšak s nižší přesností (větším intervalem spolehlivosti – viz [2]).

Aditivní šum vnímá lidský zrak subjektivně jako "zrnitost" obrazu. Aditivní šum nijak výrazně neovlivňuje schopnost oka rozpoznávat objekty a struktury v obraze, pokud  $\sigma$  je malé (asi do 10% dynamického rozsahu obrazu). Velké hodnoty  $\sigma$  vedou však k úplné ztrátě schopnosti oka rozpoznat obsah obrazu. Označme  $\sigma_0$  maximální hodnotu  $\sigma$ , kterou jsme ochotni akceptovat z hlediska degradace obrazu.

Zvýšíme-li kontrast obrazu  $k$ -krát (násobení hodnot pixelů multiplikativní konstantou  $k > 1$ ), dojde ke zvýšení  $\sigma$  na hodnotu  $k\sigma$ . Z této skutečnosti a hodnoty  $\sigma_0$  lehce odvodíme maximální přípustné zvýšení kontrastu z hlediska degradace obrazu aditivním šumem. U adaptivních filtrů však  $k$  není konstantní, ale proměnné v závislosti na souřadnicích pixelu, na hodnotě pixelu a na použitém okolí, ze kterého byla odvozena transformace jasů. Pokud použijeme metodu (5.2.1), pak  $k$  je funkce tvaru

$$k(i,j) = (n - m + 1) \frac{d\Phi_{O_{i,j}}(a_{i,j})}{dx}, \quad (5.4.2)$$

kde proměnná  $x$  značí jas pixelů. Ostatní označení je stejné jako v kapitole 5.2.

Pokud nemá dojít k degradaci obrazu aditivním šumem o směrodatné odchylce  $\sigma$ , musí platit pro všechna  $(i, j)$

$$k(i, j) \sigma \leq \sigma_0. \quad (5.4.3)$$

V praxi lze samozřejmě připustit nesplnění podmínky (5.4.3) pro jistý "velmi malý" počet pixelů, obecně však nesplnění této podmínky povede ke zdatelné degradaci obrazu. Aby tato degradace nenastala, je nutné modifikovat (5.2.1) tak, aby podmínka (5.4.3) byla splněna pro všechny pixely obrazu.

Existuje několik možností, jak řešit uvedený problém. Jednou z možností je náhrada distribuční funkce  $\Phi_{O_{i,j}}(x)$  funkcí  $\Psi_{O_{i,j}}(x)$  tvaru

$$\Psi_{O_{i,j}}(x) = \Phi_{O_{i,j}}(x) * \Upsilon(x), \quad (5.4.4)$$

kde  $\Upsilon(x)$  je pravděpodobnostní funkce nějaké náhodné veličiny  $Y$  a  $*$  značí konvoluci. V praxi se osvědčila volba  $Y$  s normálním nebo rovnoměrným rozložením. Vzorec (5.4.4) si lze představit také tak, že distribuční funkci  $\Phi_{O_{i,j}}(x)$  odvozenou přímo z obrazu nahradíme distribuční funkcí  $\Psi_{O_{i,j}}(x)$  odvozenou z pomocného obrazu, který vznikne z původního obrazu přidáním aditivního šumu, který je realizací náhodné veličiny  $Y$  a je stochasticky nezávislý na obraze (viz [10]). Toto řešení je užito v tzv. **ACC algoritmu** (viz [5]). Jiné řešení lze nalézt např. v práci [8].

## 5.5 Obecné adaptivní filtry a vícehodnotová logika

Metody popsané v předešlých kapitolách umožňují úspěšné řešení vizualizace obrazů s vysokým dynamickým rozsahem v řadě případů, se kterými se v praxi můžeme setkat. Žádná z uvedených metod není natolik obecná, aby řešila většinu případů zcela automaticky, bez nutnosti experimentování s algoritmy a jejich parametry. Snad nejsložitější je situace ve výběru vhodného typu a velikosti adaptivního okolí (viz 5.3), neboť právě tento krok má obvykle největší vliv na kvalitu výsledného obrazu. Budoucí vývoj bude zřejmě veden snahou výběr vhodného okolí nějak algoritmizovat. Vzhledem k tomu, že neexistují žádná objektivní kritéria pro posouzení kvality výsledného obrazu, je nutné při hledání vhodných algoritmů použít matematický aparát vhodný pro práci s vágními pojmy jako je vícehodnotová logika a teorie fuzzy množin (viz [9]). V současnosti se jeví reálné vytvořit expertní systém používající vícehodnotovou (Lukasiewiczovu) logiku (viz [7]), který by vybíral vhodný typ okolí na základě histogramu obrazu a Fourierova spektra. Navíc pokud jsou k dispozici informace o objektech, které mají být v obraze nalezeny, lze využít algoritmů pro rozpoznávání objektů (viz [6]) a zajistit, aby použitá okolí "respektovala" hranice těchto objektů.

## 6. Barevné obrazy a adaptivní filtry

Veškeré úvahy o zpracování obrazů se zatím týkaly jen obrazů černobílých, tj. zabývali jsme se pouze záznamem a následnou rekonstrukcí **jasu**  $L$  (*Lighting*). Má-li oko vnímat obraz barevně, musíme pro každý obrazový element (pixel) zaznamenat kromě jasu ještě dva parametry, a to **barevný odstín**  $H$  (Hue) a **nasycení barvy**  $S$  (Saturation). K reprezentaci pixelů barevného obrazu tedy potřebujeme trojrozměrný prostor, který označíme  $LHS$ . Prostor  $LHS$  je vhodný a velice názorný pro abstraktní

úvahy o reprezentaci barev, avšak přímé pořízení obrazu, jehož pixely jsou prvky prostoru  $LHS$ , není technicky možné. Proto se používají pro záznam barevných obrazů jiné prostory. Nejpoužívanější je prostor  $RGB$ . Složky pixelů pak reprezentují jas v červené, zelené a modré části spektra. Pro převod složek pixelů z prostoru  $RGB$  do prostoru  $LHS$  platí následující vztahy.

$$L = \alpha_R R + \alpha_G G + \alpha_B B, \quad (6.1)$$

kde  $\alpha_R, \alpha_G, \alpha_B$  jsou kladné konstanty splňující podmínku  $\alpha_R + \alpha_G + \alpha_B = 1$ . V praxi se používají obvykle hodnoty  $\alpha_R = 0.299, \alpha_G = 0.587, \alpha_B = 0.114$ , které dobře odpovídají subjektivnímu vnímání jasu.

$$H = \begin{cases} \frac{2\pi(G-B)}{3(R+G-2B)} & \text{pro } B < R \text{ a } B \leq G \\ \frac{2\pi}{3} + \frac{2\pi(B-R)}{3(G+B-2R)} & \text{pro } R < G \text{ a } R \leq B \\ \frac{4\pi}{3} + \frac{2\pi(R-G)}{3(B+R-2G)} & \text{pro } G < B \text{ a } G \leq R \\ 0 & \text{pro } R = G \text{ a } G = B \end{cases} \quad (6.2)$$

Platí  $0 \leq H < 2\pi$ , přičemž  $H$  má geometrický význam úhlu. Základním barvám červené, zelené a modré odpovídají postupně úhly  $0, \frac{2\pi}{3}, \frac{4\pi}{3}$ .


$$S = \begin{cases} \frac{R+G+B-3 \min\{R,G,B\}}{R+G+B} & \text{pro } R+G+B \neq 0 \\ 0 & \text{pro } R+G+B = 0 \end{cases} \quad (6.3)$$

Platí  $0 \leq S \leq 1$ , přičemž  $0$  odpovídá neutrálně šedé barvě,  $1$  odpovídá barvě bez obsahu šedé složky.

Pokud budeme chtít vizualizovat barevný obraz s vysokým dynamickým rozsahem, jeví se jako přirozený požadavek zachovat ve výsledném obraze, určeném pro pozorování člověkem, hodnoty  $H, S$  pro všechny pixely a veškeré transformace provádět pouze s jasovou složkou  $L$ . Ze vzorců (6.1) a (6.3) je však patrné, že pokud na tomto požadavku budeme trvat, klesne teoreticky využitelný dynamický rozsah jasu na 11.4% hodnoty platné pro obraz černobílý. Maximální využitelný jas je limitován dynamickým rozsahem složky  $B$ . Hodnota 11.4% je pro praktické zobrazení (monitory, tiskové metody) nepříjemně nízká, a proto se obvykle zruší i požadavek zachování  $S$  a požaduje se pouze zachování  $H$ . To ovšem vede k podstatné změně barev v jasné části obrazu, která může být především pro náročné vědecké a technické aplikace zcela nepřijatelná. Například intenzivně zbarvený zdroj světla na černém pozadí bude ve výsledném obraze bílý (na astronomických snímcích hvězdné oblohy jsou všechny jasné hvězdy bílé, což neodpovídá skutečnosti).

Popsaný problém lze velmi často úspěšně vyřešit užitím adaptivních filtrů. Postupujeme tak, že barevný obraz s vysokým kontrastem reprezentovaný v prostoru  $RGB$  nejprve převedeme do prostoru  $LHS$ . Složku  $L$  chápeme jako černobílý obraz, na který aplikujeme postupy popsané v předešlých kapitolách. Dynamický rozsah výsledného obrazu určeného k pozorování však stanovíme nejen s ohledem na schopnost oka rozlišit jasové úrovně, ale přidáme požadavek, aby bylo možné zachovat složku  $S$  pro všechny pixely. Obrazy zpracované tímto způsobem a zobrazené na monitoru nebo reprodukováné nějakou tiskovou metodou překvapivě dobře odpovídají reálnému zrakovému

vjemu. Je to tím, že lidský zrak je velmi citlivý na změny barvy, tj. složky  $H$  a  $S$ , avšak je značně tolerantní ke změnám jasu, tj. složky  $L$ . Popsaná metoda našla již řadu použití v těch aplikacích, kde záleží na přesné reprodukci barev. Za všechny uvedme mikroskopické metody využívající barvení ke zviditelňování obtížně pozorovatelných struktur a objektů (metalografie, biologie atd.). U těchto metod nepřesné podání barev způsobené ztrátou saturace při vysokém jasu může vést k naprosto mylné interpretaci obrazu.



Zatímco zelenocitlivé buňky  $y(\lambda)$  a modrocitlivé buňky  $z(\lambda)$  mají jediné lokální maximum citlivosti, červenocitlivé buňky  $x(\lambda)$  mají lokální maxima dvě, a to hlavní maximum v dlouhovlnné části viditelného spektra a vedlejší maximum v krátkovlnné části spektra. To mimo jiné způsobuje, že nejkratší viditelné vlnové délky vnímáme jako fialovou barvu (modrá s malou příměsí červené) a nikoliv jako barvu modrou. Proto některé snímací systémy, které mají zajistit velmi přesné podání barev (např. fotografické materiály Fujicolor Reala), používají pro snímání čtyřrozměrný barevný prostor  $RGBr$ , kde čtvrtá složka reprezentuje vedlejší maximum  $x(\lambda)$ . Teoreticky je použití čtyřrozměrného prostoru zbytečné, protože by stačilo vytvořit snímač, resp. fotografickou vrstvu se spektrální citlivostí blízkou  $x(\lambda)$ . To je však technicky velmi obtížné. Zpracování obrazů s vysokým dynamickým rozsahem reprezentovaných v prostoru  $RGBr$  je značně složitější, než je tomu u prostoru  $RGB$ . Jak bylo vysvětleno v předešlých odstavcích, nelze při vysokém jasu  $L$  zachovat u obrazu v prostoru  $RGB$  nasycení barvy (saturaci)  $S$ . U obrazu v prostoru  $RGBr$  nelze však zachovat ani barevný odstín  $H$ . Použití adaptivních filtrů opět může vyřešit uvedený problém, pokud aplikujeme postup popsáný v předešlém odstavci. Musíme však při volbě výstupního dynamického rozsahu přidat další požadavek, a to zachování  $H$ . Analogický problém vznikne v prostorech ještě větší dimenze, které se často používají pro vědecké účely (tzv. multispektrální obrazy). Dnes existují systémy, které umožňují pořídít barevné obrazy s 30 i více složkami (např. za využití úzkopásmových interferenčních filtrů) a reprodukovat výsledný v prostoru  $RGB$ . Pro přesnou reprodukci barev je to sice zbytečné, avšak analýzou takového obrazu lze získat informace o spektrálním složení světla v jednotlivých částech obrazu. Při vizualizaci takového obrazu se opět s úspěchem dají využít adaptivní filtry.

\* Standardní pozorovatel  $10^\circ$  CIE 1934 a  $2^\circ$  CIE 1964

## 7. Perspektivy dalšího vývoje

Současné systémy snímání obrazů ve viditelné části spektra i v blízké ultrafialové a infračervené oblasti dosáhly značné dokonalosti. A to jak klasické fotografické materiály založené na citlivosti halogenidů stříbra ke světlu, tak moderní křemíkové snímací prvky CCD. Další zvyšování kvality těchto snímacích systémů v podstatě nemá již smysl, pokud nedojde k odpovídajícímu pokroku systémů pro rekonstrukci obrazů. Zde však je další zlepšování parametrů velmi obtížné. Vakuové obrazovky, TFT maticové zobrazovací panely, tiskové metody a chemické fotografické postupy zatím nedávají velké možnosti zvyšování prakticky využitelného kontrastu. Proto jedinou schůdnou cestou se jeví numerické metody zpracování obrazu. Zdá se, že základní principy metod umožňujících kvalitní vizualizaci obrazů s velkým dynamickým rozsahem byly již nalezeny. Jsou to adaptivní filtry. Z matematické hlediska se však pod tímto názvem skrývá velmi široká a jen velmi obtížně definovatelná třída metod. Vývoj navíc komplikuje skutečnost, že neexistují a ani nemohou existovat žádná "objektivní" kritéria kvality výsledného obrazu. Výsledný obraz vždy na závěr posuzuje zcela subjektivně člověk. Přes tyto problémy došlo v oblasti adaptivních filtrů v posledních několika málo letech k zásadnímu pokroku a velmi rychle nachází uplatnění v různých odvětvích vědy. Zásahu na tom má nejen pokrok v oblasti matematické teorie, ale i stabilní růst výkonnosti výpočetní techniky. Tento růst umožnil, že se objevily i první komerční aplikace adaptivních filtrů mimo oblast vědeckého výzkumu a technických aplikací. Příkladem může být systém Agfa Dimax používaný při zhotovování běžných amatérských fotografií z negativních barevných filmů.

## Literatura

- [1] Rosenfeld, A., Kak A. C. : Digital Picture Processing, Academic Press, New York 1982
- [2] Jaroslavskij, L., Bajla, I.: Metódy a systémy číslicového spracovania obrazov, Alfa Bratislava, 1989
- [3] Pratt, W. K. : Digital Image Processing, John Wiley and Sons, New York, 1977
- [4] Druckmüller, M., Heriban, P.: Digital Image Processing System for Windows version 5.0, Scientific Image Analyser, SOFO 1996, (v češtině pp. 268 v angličtině pp. 272)
- [5] Druckmüller, M., Štarha, P.: Adaptive Contrast Control Scientific Image Structure and Object Analyser 4.0, SOFO 2000
- [6] Druckmüller, M.: Pattern recognition Methods Image Processing, Proc. Int. Conf. DIPS'96, České Budějovice, Editor: Kapoun, K., 1996, 15 - 22
- [7] Druckmüller, M. : Many-valued Logic System for Linguistic model processing, International Journal of General Systems, 20, 1, 1991, 31 - 38
- [8] Macek V. : Užití adaptivních filtrů ke zlepšení vlastností obrazů s velkým dynamickým rozsahem obrazových dat, dizertační práce, FSI VUT Brno, Brno 2000
- [9] Druckmüller, M.: Technické aplikace vícehodnotové logiky, PC-DIR, 1998
- [10] Anděl, J. : Statistické metody, Matfyzpress, Praha 1993



## Obrazová příloha

V obrazové příloze na konci publikace jsou ukázky využití adaptivních filtrů při zpracování obrazů pořízených různými zobrazovacími systémy.

### **Obr. 4., Obr. 5.**

První z obrazů je původní obraz pořízený elektronovým rastrovacím mikroskopem (vnitřek poškozené trubky teplovodního potrubí). Druhý obraz ukazuje užití adaptivního filtru využívajícího semiekvalizace a adaptivního  $V_{d,w}$ -okolí k potlačení vlivu pohlcování elektronů dutinou v materiálu.

*Originální obraz poskytl f. Tescan Brno.*

### **Obr. 6., Obr. 7.**

První z obrazů je pořízen tunelovacím mikroskopem při rozlišení  $1nm/pixel$ . Obraz má rozměry  $512 \times 512$  pixelů a ukazuje část makromolekuly latexu. Druhý obraz byl zpracován užitím adaptivního filtru ACC (viz 5.4)

*Originální obraz poskytl f. Tescan Brno.*

### **Obr. 8., Obr. 9.**

Obrazy ilustrují možnosti podstatného zlepšení kvality obrazu pořízeného fluorescenčním konfokálním mikroskopem (Olympus Fluoview). Na obrazech je prvek treпка. První obraz je originál složený konvenčním způsobem z 18 obrazů s různou rovinou ostroti. Konvenční způsob skládání obrazů používá operaci maxima (logické nebo). Každý pixel výsledného obrazu je tedy odvozen pouze z jediného vybraného obrazu. Při tomto postupu nelze zobrazit vícevrstevné struktury, kde pro jeden pixel existuje několik rovin ostroti. Druhý obraz vznikl tak, že všech 18 obrazů bylo složeno sčítáním, takže každý pixel nese informaci ze všech 18 obrazů. Takto vzniklý velmi nekонтрастní obraz s vysokým dynamickým rozsahem (16 bitů / pixel) byl pak zpracován adaptivním filtrem ACC (viz 5.4). Výsledný obraz ukazuje velmi dobře celou prostorovou strukturu.

*Originální obrazy pořídil Prof. Janisch a Doc. Reischig*

### **Obr. 10., Obr. 11.**

Na těchto dvou obrázcích, pořízených během úplného zatmění Slunce 11. 8. 1999, je sluneční korona. První obraz vznikl přesným geometrickým složením 12 snímků pořízených zrcadlovým objektivem typu Maksutov-Cassegrain 10.5/1084mm na film s extrémně vysokým dynamickým rozsahem (Fujicolor Superia 800). Snímky měly různé expozice od  $1/250$  s po  $1/4$  s. Obrazy byly digitalizovány s dynamickým rozsahem 16 bitů / pixel. Získaný obraz (*Obr. 10*) zachycuje obraz s reálným kontrastem 1 : 3 000 000 a obsahuje řadu pro oko neviditelných detailů. Druhý obraz (*Obr. 11*) byl zpracován adaptivním filtrem ACC (viz 5.4).


*Originální obrazy pořídil autor*




*Obr.4*



*Obr.5*




*Obr.6*



*Obr.7*




*Obr. 8*



*Obr. 9*



*Obr.10*



*Obr.11*

## Abstract

### Adaptive Numerical Methods for Image Processing

Human eye is the most important tool for obtaining information about the world we are living in. Several years ago it was practically impossible to construct a technical equipment which would be able to reach the ability of human eye. The great progress both in classical photography and in digital photography changed the situation mentioned above in some aspects. For example a cooled digital CCD camera is of greater sensitivity and has much wider spectral range in comparison with human eye. However, all images taken with such high quality equipment finally have to be displayed and observed by human vision. The human eye is able to distinguish 100 to 300 levels of brightness on contrast usual on nowadays display equipments (vacuum screens, TFT LCD panels, etc.) and therefore the majority of digital display equipments use the 8 bits per pixel representation of images. However, high quality cameras use 16 bits per pixel representation (65,536 levels of brightness) or even better. These images with high dynamic range contain a lot of information invisible for human eye.

There exist several, let us say, classical solutions of the mentioned problem. The most powerful are nonlinear pixel value transformations based on image histogram analysis. The best known one is the so called histogram equalization. Another solution uses the two-dimensional discrete Fourier transform. While any phase spectra manipulation causes a significant image degradation, amplitude spectra modification is for human eye generally acceptable and it may increase the subjective quality of an image. It can be successfully used in visualization of images with high dynamic range. Even if these methods are useful in many branches of scientific imaging methods their abilities are very limited.

The human vision itself gives a lot of motivation for numerical image processing. The most important feature of human vision is adaptivity. An image is by human eye not observed as the whole. It is analyzed in small elements and the parameters as sensitivity, focussing, aperture etc. are changed in order to reach optimum local view. The human eye is from technical point of view a differential analyser and it has only limited ability to measure absolute brightness. The comparison of brightness is done on a picture element neighbourhood which is of variable shape depending on the image content. Mathematical numerical methods which modify the algorithm according to local image properties as human eye does are called adaptive filters.

Adaptive filter for high dynamic range image processing must present several types of adaptivity. The first type of adaptivity is that of pixel value transformation function. The transformation function is usually derived from image histogram, so the adaptivity may be achieved by using the local histogram computed on some pixel neighbourhood instead of whole image histogram. The so called adaptive histogram equalization is one of these methods based on this principle. The creation of suitable pixel neighbourhood for histogram computing is very important. Any of fixed type neighbourhood (for example square) cannot give good results because it does not respect boundaries between areas with significantly different histograms. Therefore it is necessary to construct a neighbourhood according to local properties of image i.e. to use adaptive neighbourhood. This is the second very important type of adaptivity. The third type of adaptivity is based on additive noise analysis. The pixel value transformation function must be corrected according to local parameters, usually according to standard devia-

tion of additive noise. If the noise is independent on the image the standard deviation can be estimated by means of autocorrelation function analysis.

Adaptive filters play an important role in visualization of color images with high dynamic range, too. Adaptive filters may improve colors saturation and they may prevent the saturation loss of very bright colors. In the nearest future it can be expected that adaptive filters will be widely used not only in scientific and technical applications but in common photography as well.