

# Předzpracování obrazu v lokálním okolí

Václav Hlaváč

České vysoké učení technické v Praze  
Fakulta elektrotechnická, katedra kybernetiky  
Centrum strojového vnímání

<http://cmp.felk.cvut.cz/~hlavac>, [hlavac@fel.cvut.cz](mailto:hlavac@fel.cvut.cz)

*Poděkování Ing. Tomáši Svobodovi, PhD., jehož několik průsvitek jsem použil.*

## Osнова přednášky:

- ◆ Filtrace šumu (a hranová detekce, v jiné přednášce).
- ◆ Šum a jeho statistická podstata.
- ◆ Prostorově invariantní filtry.
- ◆ Diskrétní 2D konvoluce.
- ◆ Separabilní filtry.
- ◆ Nelineární filtrace šumu.

# Předzpracování obrazu, úvod

Vstupem je obraz, výstupem je obraz.

Obraz se neinterpretuje.

---

## Cíl

- ◆ Potlačit **zkreslení** (např. korekce geometrického zkreslení díky zakřivenosti Země u družicového snímku).
- ◆ Zvýšení **kontrastu** (jen pro prohlížení obrazu člověkem).
- ◆ Odstranění **šumu**.
- ◆ **Zdůraznění charakteristik** obrazu pro další zpracování, např. nalézání hran.

# Lokální operace předzpracování

Obvykle se nevyužívají specifické znalosti o obraze a charakteru poruch.

Dělení z hlediska použití:

1. Vyhlazování.
2. Hledání hran (gradientní operátory, ostření).

Dělení podle vlastností rovnic:

1. Lineární.
2. Nelineární.

# Statistický princip filtrace šumu

Nechť je každý pixel obrazu zatížen náhodným aditivním šumem:

- ◆ statisticky nezávislým,
- ◆ s nulovou střední hodnotou  $\mu$ ,
- ◆ směrodatnou odchylkou  $\sigma$ .

Mějme  $i$  realizací,  $i = 1, \dots, n$ . Odhad správné hodnoty je

$$\frac{g_1 + \dots + g_n}{n} + \frac{\nu_1 + \dots + \nu_n}{n}.$$

Výsledkem je náhodná veličina s  $\mu' = 0$  a  $\sigma' = \sigma/\sqrt{n}$ .

# Vyhlazování z více obrazů bez rozmazání


**Předpoklady:**  $n$  obrazů téže neměnné scény, u nichž lze předpokládat náhodné poruchy nezávislé na signálu.

**Správné hodnota jasů:**  $f(i, j)$  se odhaduje pro každý pixel obrazu z náhodné populace tvořené pixely v téže pozici ve všech vstupních obrazech  $g_k(i, j)$  např. obyčejným průměrováním,

$$f(i, j) = \frac{1}{n} \sum_{k=1}^n g_k(i, j) .$$

**Příklad:** Potlačení tepelného šumu kamery u přesných měření. Typicky se správná hodnota odhaduje asi z 50 obrazů.

# Problém: potřebujeme filtrovat šum z jediného obrazu



- ◆ Nezbyvá než se spolehnout na nadbytečnost údajů v obraze.
- ◆ Sousední pixely mají převážně stejnou nebo podobnou hodnotu jasu.
- ◆ Hodnotu jasu můžeme opravit na základě analýzy bodů v okolí. Použije se **typický reprezentant z okolí nebo kombinace několika hodnot.**
- ◆ Problém rozmazávání na jasových přechodech.

## Obecná lokální filtrace

- ◆ Správná hodnota (nová hodnota) se odhaduje z malého okolí.
- ◆ Přístup je založen na představě, že se celý obraz systematicky (např. po řádcích) prochází. Kolem reprezentativního bodu je zkoumáno malé okolí  $\mathcal{O}$ , často malý obdélník (též okno).
- ◆ Výsledek analýzy je zapsán do výstupního obrazu jako hodnota reprezentativního pixelu.
- ◆ Vlastnosti filtru mohou být v každém pixelu obrazu jiné.

# Operátory nezávislé na posunu též prostorově invariantní filtry

- ◆ Speciální případ lokální filtrace.
- ◆ Vlastnosti filtru jsou ve všech polohách stejné.
- ◆ Shoduje se s představou frekvenční filtrace (např. Fourierova transformace), kdy působení filtru je prostorově omezené. Např. filtrace Gausiánem s malým rozptylem.

# Lokální lineární předzpracování

- ◆ Nová hodnota je vypočítána jako **lineární kombinace hodnot obrazové funkce v okolí**.
- ◆ Připomínka: Linearita, tj. 2 vlastnosti: aditivita a homogenita.
- ◆ U skutečných obrazů je předpoklad linearity narušen
  - Hodnotu pixelu nelze vynásobit libovolným skalárem nebo výsledek součtu nemůže být jakýkoliv. Problém saturace díky omezenému rozsahu hodnot obrazové funkce, typicky  $\langle 0, 255 \rangle$ .
  - Problémy na okraji obrazu. Maska přesahuje.

# Diskrétní 2D konvoluce

Příspěvek jednotlivých pixelů v okolí  $\mathcal{O}$  je vážen v lineární kombinaci koeficienty  $h$  podle

$$g(x, y) = \sum_{(m,n) \in \mathcal{O}} h(x - m, y - n) f(m, n) .$$

**Konvoluční jádro  $h$** , též konvoluční maska.

Často se používá obdélníkové okolí  $\mathcal{O}$  s lichým počtem řádků a sloupců, a tak může reprezentativní bod ležet uprostřed konvoluční masky.

# Obyčejné průměrování

Průměrování v okolí  $3 \times 3$

$$h = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} .$$

Dvě varianty zvýraznění pixelů blíže středu masky

$$h = \frac{1}{10} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix} , \quad h = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} .$$

# Obyčejné průměrování, příklad 1



Originál  $256 \times 256$



Přidán umělý šum



Průměrování  $3 \times 3$

## Obyčejné průměrování, příklad 2



13/22



Originál  $256 \times 256$



Přidán umělý šum



Průměrování  $7 \times 7$

# Separabilní filtry

Příklad: binomický 2D filtr rozměru  $5 \times 5$  (prvek je součtem dvou předchozích čísel v Pasclově trojúhelníku)

$$\begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 36 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} = \begin{bmatrix} h_1 \end{bmatrix} \begin{bmatrix} h_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 4 \\ 6 \\ 4 \\ 1 \end{bmatrix} \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \end{bmatrix} .$$

# Separabilita $\Rightarrow$ úspora výpočtů

Rozměr konvoluční masky je  $2N + 1$ .

$$\begin{aligned}g(x, y) &= \sum_{m=-N}^N \sum_{n=-N}^N h(x - m, y - n) f(m, n) \\&= \sum_{m=-N}^N \sum_{n=-N}^N h(m, n) f(x + m, y + n) \\&= \sum_{m=-N}^N h_1(m) \sum_{n=-N}^N h_2(n) f(x + m, y + n)\end{aligned}$$

## Separabilita $\Rightarrow$ úspora výpočtů 2

- ◆ Pro náš  $5 \times 5$  filtr potřebuje přímý výpočet 25 násobení a 24 sčítání pro každý pixel.
  - ◆ Při použití separabilního filtru stačí 10 součinů a 8 součtů.
- 
- ◆ Ještě výraznější by byla úspora v případě konvoluční filtrace 3D obrázku (např. z tomografu). Pro konvoluční jádro rozměru  $9 \times 9 \times 9$  by na každý voxel byla potřeba 729 součinů a 728 součtů
  - ◆ Pro separovatelný filtr stačí 27 součinů a 24 součtů na voxel.

## Ověření separability a rozklad

Každý filtr s hodnotí 1 je separovatelný.


Rozklad pomocí singulárního rozkladu (SVD).

```
[u,s,v] = svd(A);  
s = diag(s);  
tol = length(A) * max(s) * eps;  
rank = sum(s > tol);  
if (rank == 1)  
    hcol = u(:,1) * sqrt(s(1));  
    hrow = conj(v(:,1)) * sqrt(s(1));  
    y = conv2(hcol, hrow, x, shape);  
else  
    %Nonseparable stencil  
end
```

# Nelineární vyhlazování

**Cíl:** omezit rozmazávání hran při vyhlazování.

**1. princip:** najít část okolí, ve kterém se jas kvalitativně nemění.




**2. princip – robustní statistika:** střední hodnota je špatným odhadem, pokud existují vychýlené hodnoty.


# Metoda rotující masky

V okolí  $5 \times 5$  vyhledává homogenní část rotující maska  $3 \times 3$ .

Celkem 9 poloh, 1 uprostřed + 8 na obrázku.




1




2

...



7



8

Z masek se vybere ta, kde má jas nejmenší rozptyl.

## Filtrace mediánem

- ◆ Medián = výběrový kvantil.
- ◆ Nechť je  $x$  náhodnou veličinou. Medián  $M$  je hodnota, pro kterou je pravděpodobnost jevu  $x < M$  rovna jedné polovině.
- ◆ Výpočet mediánu je pro diskrétní obrazovou funkci jednoduchý. Stačí uspořádat vzestupně hodnoty jasu v lokálním okolí a medián určit jako prvek, který je uprostřed této posloupnosti.
- ◆ Aby se snadno určil prostřední prvek, používají se posloupnosti s lichým počtem prvků, typicky okolí  $3 \times 3$ ,  $5 \times 5$ , atd.
- ◆ Výpočet ještě urychlí skutečnost, že k nalezení mediánu stačí částečné uspořádání posloupnosti.

## Medián, příklad

100	98	102
99	105	101
95	100	255

Aritmetický průměr = 117,2

Medián: 95 98 99 100 **100** 101 102 105 255

Robustní, protože snese méně než 50 % vychýlených hodnot.

## Medián, příklad Hradčany



Originál  $256 \times 256$



Přidán umělý šum



Medián  $3 \times 3$

- ◆ Filtraci mediánem lze použít iterativně.
- ◆ Hlavní nevýhodou filtrace mediánem v obdélníkovém okolí je to, že porušuje tenké čáry a ostré rohy v obraze.