

# ROZ1 - Cv. 4 - Detektory hran a ekvalizace histogramu







ÚTIA - ZOI

# Motivace

- ▶ Proč se zabývat v obraze hranami?

# Motivace

- ▶ Proč se zabývat v obraze hranami?
  - ▶ hrany nesou více informace, než místa bez hran
  - ▶ jsou důležité pro detekci objektů a segmentaci obrazu
- ▶ Co je to hrana v obraze?
  - ▶ místo s velkou změnou (gradientem) jasových hodnot pixelů



Obrázek: Vizualizace hrany v obraze

# Jaké známe detektory hran?

## Jaké známe detektory hran?

- ▶ založené na 1. derivaci obrazu:
  - ▶ Roberts
  - ▶ Sobel
  - ▶ Prewitt
  - ▶ Kirsch
  - ▶ Canny
- ▶ založené na 2. derivaci obrazu:

## Jaké známe detektory hran?

- ▶ založené na 1. derivaci obrazu:
  - ▶ Roberts
  - ▶ Sobel
  - ▶ Prewitt
  - ▶ Kirsch
  - ▶ Canny
- ▶ založené na 2. derivaci obrazu:
  - ▶ Marr-Hildreth
- ▶ nepracující s derivacemi - Whitening
- ▶ pracující ve frekvenční oblasti

# Popište Robertsův detektor:



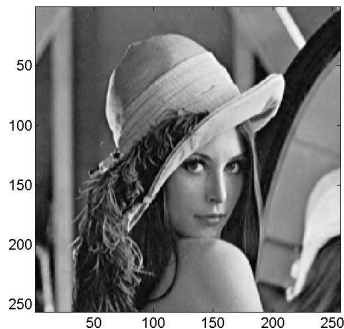
## Popište Robertsův detektor:

- ▶ konvoluce s maskami  $\begin{pmatrix} -1 & 1 \end{pmatrix}$  a  $\begin{pmatrix} -1 \\ 1 \end{pmatrix}$
- ▶ porovnáám oba směry a beru maximum z nich
- ▶ velmi citlivé na šum – kde je šum, jsou všude hrany
- ▶ mohou obrázek nejprve trochu rozmazat


# Cvičení I. - naprogramujte Robertsův detektor

```
► funciton R = roberts(I,Prah)  
% I...obrázek  
% Prah...práh
```

Vstupní obrázek I



roberts(I,20)



# Řešení - Cvičení I.

```
► function R = roberts(I,Prah)  
% I...obrázek  
% Práh...práh  
M=[-1,1];  
R1=abs(conv2(I,M,'same'));  
R2=abs(conv2(I,M','same'));  
R=R1 > Prah | R2 > Prah;
```

# Popište Sobelův detektor:

## Popište Sobelův detektor:

- ▶ používá masku  $\begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix}$
- ▶ takových masek je celkem 4 (resp. 8)
- ▶ podle maxima vyberu tu největší (je to ta, kde hrana běží ve směru nul)
- ▶ jde vlastně o průměrování 1. derivací, kde centrální bod má dvojnásobnou váhu
- ▶ robustnější proti šumu, díky velikosti matice


## Cvičení II. - naprogramujte Sobelův detektor

- ▶ `funciton R = sobel(I,Práh)`
  - `% I...obrázek`
  - `% p...práh`
  - *nápověda* `rot90()`

Vstupní obrázek I



sobel(I,110)



# Řešení - Cvičení II.

```
► function R = sobel(I,p)
% I...obrázek
% p...práh
M = [1 2 1; 0 0 0; -1 -2 -1];
R = abs(conv2(I,M,'same')) > Prah;
R = R | (abs(conv2(I,M','same')) > Prah);
M = [2 1 0; 1 0 -1; 0 -1 -2];
R = R | (abs(conv2(I,M,'same')) > Prah);
R = R | (abs(conv2(I,rot90(M),'same')) > Prah);
```

# Prewitt + Kirsch + Robinson- obdobné jako Sobel

► maska Prewittové 
$$\begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix}$$



# Prewitt + Kirsch + Robinson- obdobné jako Sobel

- ▶ maska Prewittové  $\begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix}$
- ▶ maska Kirsche  $\begin{pmatrix} 3 & 3 & 3 \\ 3 & 0 & 3 \\ -5 & -5 & -5 \end{pmatrix}$




# Prewitt + Kirsch + Robinson- obdobné jako Sobel

- ▶ maska Prewittové  $\begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix}$
- ▶ maska Kirsche  $\begin{pmatrix} 3 & 3 & 3 \\ 3 & 0 & 3 \\ -5 & -5 & -5 \end{pmatrix}$
- ▶ maska Robinsona  $\begin{pmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{pmatrix}$

# Popište Marrův detektor:

## Popište Marrův detektor:

- ▶ **LoG** (Laplacian of Gaussian)
- ▶  $\Delta(G * f) = \Delta G * f$
- ▶ zero-crossing detection
- ▶ hrany mají tendenci se uzavírat do sebe





## Cvičení III.

- ▶ odzkoušejte hranové detektory pro různé šумы
- ▶ přiložené skripty `bilySum()`; `sulPepr()`; `maar()`;

## Cvičení III.





- ▶ odzkoušejte hranové detektory pro různé šумы
- ▶ přiložené skripty `bilySum()`; `sulPepr()`; `maar()`;



## Co to je histogram v obraze:

## Co to je histogram v obraze:

- ▶ mějme obraz s  $L$  úrovněmi jasu
- ▶  $H(k) = n_k$ , kde  $n_k$  je počet pixelů s jasnem  $k \in \langle 0, L - 1 \rangle$
- ▶ Histogram je tedy vektor absolutních četností každého jasu v obraze:  $H = [H(0), H(1), \dots]$









## Cvičení IV. - lineární roztažení histogramu

- ▶ napište funkci, která "roztáhne" obrázek po celé délce jasu  $< 0, 255 >$

```
funciton R = linhist(I)
% I...obrázek
- nápověda hist(), randi()
```

# Řešení - Cvičení IV.



## Řešení - Cvičení IV.

► `W=randi([100,125],5,5);`

```
funciton R = linhist(I)
% I...obrázek
R = I-min(I(:));
R = R/max(R(:))*255;
zobr(I);
```

Co to je ekvalizace histogram a jak byste ji provedli:




## Co to je ekvalizace histogram a jak byste ji provedli:

- ▶ jde o tzv. vyrovnaní histogramu, resp. zploštění
- ▶ jasy se transformují tak, aby každý z nich 'měl pro sebe' takovou část jasové osy, jaké je jeho zastoupení v obrázku
- ▶ histogram  $\approx$  **hustota pravděpodobnosti**
- ▶ kumulativní histogram  $\approx$  **distribuční funkce** - co to je?

# Kumulativní histogram:

## Kumulativní histogram:

- ▶ Necht'  $n_k$  je počet pixelů v obraze s úrovní  $k \in \langle 0, L - 1 \rangle$
- ▶ a  $p(x_k) = \frac{n_k}{N}$  četnost výskytu jasu  $k$  v tomto obraze ( $N$  je počet pixelů celkem)
- ▶ kumulativní histogram je pak:  $c(k) = \sum_{i=0}^k p(x_i)$









# K čemu kumulativní histogram?



## K čemu kumulativní histogram?

- ▶ naše transformace  $T(x_k) = c(k) \in \langle 0, 1 \rangle$
- ▶ proto ještě  $T(x_k) * (max - min) + min$ , u nás  $max = 255$  a  $min = 0$









## Cvičení V. - ekvalizace histogramu

- ▶ napište funkci, která ekvalizuje obrázek

```
function R = ekvHist(I)
```

```
% I...obrázek
```

# Řešení - Cvičení V.



## Řešení - Cvičení V.

```

► function R = ekvHist(I)
  B = 255;      % intenzita bile barvy
  Vel = length(Img(:)); % pocet pixelu v obrazku
  R = Img;     % vysledny snimek
  S = 0;      % pocet zpracovanych pixelu
  for K = 0 : B % prochazime pixely pres intenzity
    W = (Img == K); % pixely s intenzitou K
    P = sum (W(:)); % pocet techto pixelu
    R(W) = round((S + P/2) * B / Vel); % nova
    intenzita
    S = S + P; % pocet zpracovanych pixelu
  end

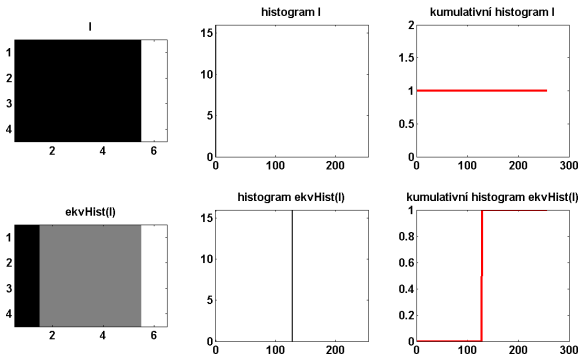
```

## Kontrolní otázka:

- ▶ Co se stane, když je vstupní obrázek celý černý?

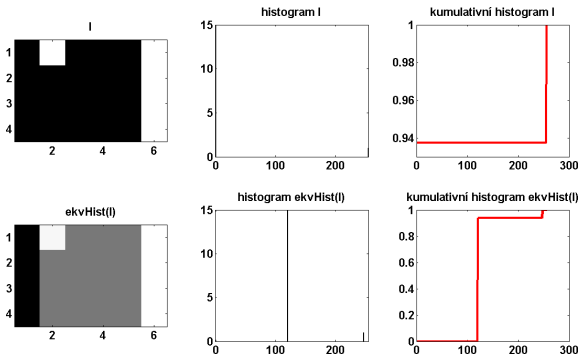
## Kontrolní otázka:

- ▶ Co se stane, když je vstupní obrázek celý černý?
- ▶ Co se stane, když je vstupní obrázek celý černý s bílou tečkou?



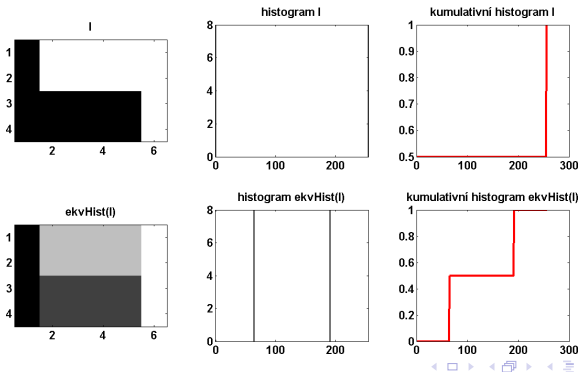
## Kontrolní otázka:

- ▶ Co se stane, když je vstupní obrázek celý černý?
- ▶ Co se stane, když je vstupní obrázek celý černý s bílou tečkou?
- ▶ Co se stane, když je vstupní obrázek půl černý půl bílý?



## Kontrolní otázka:



- ▶ Co se stane, když je vstupní obrázek celý černý?
- ▶ Co se stane, když je vstupní obrázek celý černý s bílou tečkou?
- ▶ Co se stane, když je vstupní obrázek půl černý půl bílý?








## Bonusový úkol:

- ▶ Zvýraznit na snímku hrany



## Bonusový úkol:

- ▶ Zvýraznit na snímku hrany



## Řešení - Bonus

```
► funciton R = kruhgauss(R,N)  
% vraci gaussovskou masku o rozptylu R v mat. NxN  
[ X, Y] = meshgrid(-(N-1)/2:(N-1)/2,...  
    -(N-1)/2:(N-1)/2);  
K=exp(-0.5*(X.^2+Y.^2)/R.^2);
```

## Řešení - Bonus

```

▶ funciton R = zvyrazniHrany(I,prah,coef)
  F=fft2(I);
  mi=min(I(:));
  ma=max(I(:));
  K=(-kruhgauss(prah,size(I,1))+1)*coef+1;
  J=abs(ifft2(F.*fftshift(K)));
  J(J<mi)=mi;
  J(J>ma)=ma;
  %-----
  mesh(K);
  zobr(J);

```

## Co jsme se dnes naučili:

- ▶ detekovat hrany
- ▶ pracovat s histogramem obrázku
- ▶ roztáhnout ho a ekvalizovat

KONEC  
Děkuji za pozornost !