

Hrany (= gradienty), hranové body a ostření obazu

Václav Hlaváč

České vysoké učení technické v Praze

Český institut informatiky, robotiky a kybernetiky

160 00 Praha 6, Jugoslávských partyzánů 1580/3

<http://people.ciirc.cvut.cz/hlavac>, vaclav.hlavac@cvut.cz

Poděkování: O. Drbohlav, T. Svoboda a T. Werner za několik obrazovek této přednášky.

Osnova přednášky:

- ◆ Hrany, motivace, původ, hranový bod, definice obou.
- ◆ Tři skupiny hranových operátorů.
- ◆ Hledání hran pomocí konvoluce.
- ◆ Marr-Hildrethové hranový detektor.
- ◆ Prostor měřítek.
- ◆ Cannyho hranový detektor.

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 hranových bodů.

Proč jsou hrany (gradienty) a hranové body užitečné?

- ◆ Neurofyziologický a psychofyzický výzkum ukazuje, že pro zrakové vnímání vyšších organismů jsou důležitá místa v obraze, kde se náhle mění hodnota jasu, což jsou významné hrany = hranové elementy (edge elements, zkratka edgel).
- ◆ **Místa** v obraze **odpovídající významným hranám**, tj. s velkým modulem gradientu, nesou **více znalosti** než jiná místa v obraze.
- ◆ Hranové body jsou do jisté míry invariantní vůči změně osvětlení a směru pohledu.
- ◆ Tato **místa chceme**
 - buď **zvýraznit**, tj. zvýraznit vysoké kmitočty operací ostření
 - nebo **detekovat** významné hrany.
- ◆ Výpočet hran (= gradientů)/ hranových elementů má časté použití v počítačovém vidění: rozpoznání obsahu obrazu, 3D rekonstrukce scény, problém korespondence, sledování aj.

Příklad – kresba souhlasí s hranovými body





4/48



Pablo Picasso, La Sieste 1919

Příklad – automatická detekce hranových bodů



Původ hranových bodů

Hranové body vznikají díky nespojitostem v normále k povrchu, hloubce, odrazivosti povrchu (barvě), odleskům nebo nespojitostech v osvětlení (stínům).



- surface normal discontinuity
- depth discontinuity
- highlights
- surface color/texture
- shadow/illumination discontinuity



Hrana, hranový bod

Hrana (= gradient, angl. edge)

- ◆ je dána vlastnostmi obrazového elementu a jeho okolí;
- ◆ popisuje rychlost změny a směr největšího růstu obrazové funkce $f(x, y)$; tj. je gradientem $\nabla f(x, y)$;
- ◆ je vhodnou diskretní aproximací gradientu $f(x, y)$, je tedy vektorem o dvou složkách.

Hranový bod (angl. edgel = edge element, jako pixel = picture element)

- ◆ je bod s velkým modulem gradientu;
- ◆ Některé body v obraze jsou tedy hranové body a jiné nejsou hranové body.
- ◆ Hranové body jsou v obraze dobře lokalizované.
- ◆ Poloha hranových bodů v obraze je stabilní vůči změně směru pohledu.

Tři kategorie detektorů hran/hranových bodů

Výpočet gradientu a detektory hranových bodů založené na

1. Aproximování maxim prvních derivací (Roberts, Prewittová, Sobel apod., Canny);
2. Hledání průchodů druhých derivací nulou (Marr-Hildreth);
3. Lokální aproximaci obrazové funkce parametrickým modelem, např. polynomem dvou proměnných;

Vypočítání derivace analyticky z parametrů modelu.

(V počítačovém vidění zavedl R. Haralick).


Gradient obrazové funkce

- ◆ Pro obecný případ n proměnných je gradient spojité funkce f vektorem parciálních derivací:


$$\nabla f(x_1, \dots, x_n) = \left(\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right)$$

- ◆ Pro $n = 1$ (1D signál), se gradient zjednoduší na (standardní) derivaci vyjadřovanou obvykle ve dvou značeních: f' (Lagrange) nebo $\frac{df}{dx}$ (Leibnitz).


- ◆ Pro $n = 2$ (2D signál), $\nabla f(x, y) = \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right)$



$$\nabla f = \left(\frac{\partial f}{\partial x}, 0 \right)$$



$$\nabla f = \left(0, \frac{\partial f}{\partial y} \right)$$




$$\nabla f = \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right)$$

- $\nabla f(x, y)$ se často vyjadřuje v polárních souřadnicích svou velikostí a směrem ψ

$$\|\nabla f(x, y)\| = \sqrt{\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2}, \quad \psi = \arctan \left(\frac{\partial f}{\partial y} / \frac{\partial f}{\partial x} \right).$$

Směrová derivace

- ◆ Uvažujme 2D funkci $f(x, y)$, jeden určitý bod (x_0, y_0) a směr daný vektorem $\mathbf{u} = (u_1, u_2)$. Odpovídající jednotkový vektor $\hat{\mathbf{u}}$ k vektoru \mathbf{u} je $\hat{\mathbf{u}} = \frac{\mathbf{u}}{|\mathbf{u}|}$.
- ◆ Směrová derivace $\nabla_{\mathbf{u}} f(x_0, y_0)$ určuje rychlost, jakou funkce $f(x, y)$ roste v bodě (x_0, y_0) ve směru \mathbf{u} . Může se definovat dvěma alternativními způsoby
 - $\nabla_{\mathbf{u}} f(x_0, y_0) \equiv \nabla f(x, y) \frac{\mathbf{u}}{|\mathbf{u}|}$ nebo
 - $\frac{df(x, y)}{du} \equiv \hat{\mathbf{u}} \cdot \nabla f(x, y) = u_1 \frac{\partial f(x, y)}{\partial x} + u_2 \frac{\partial f(x, y)}{\partial y}$.



Diskrétní aproximace derivace


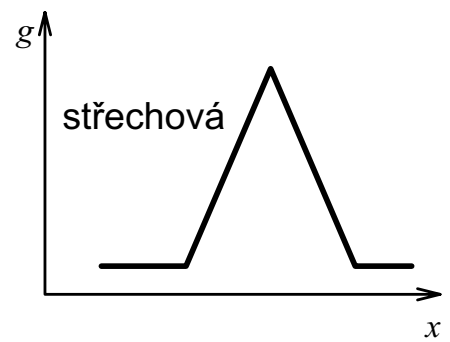

Dva přístupy aproximace derivací diskrétní funkce, vzniklé vzorkováním spojité funkce (oba vedou k podobným algoritmům):

- ◆ rekonstruuji spojitou funkci a spočítám její derivaci;
- ◆ aproximuji derivace konečnými diferencemi.

Nejjednodušší aproximace jednorozměrné funkce v celočíselném bodě i :

- ◆ Nesymetrická (vlastně odpovídá derivaci v bodě $i - \frac{1}{2}$): $f'(i) \approx f(i) - f(i - 1)$.
- ◆ Symetrický tvar možný, ale zanedbává vliv pixelu i : $f'(i) \approx f(i + 1) - f(i - 1)$.
- ◆ V termínech konvoluce: $f' \approx [-1, +1] * f$ nebo $f \approx [-1, 0, +1] * f'$.


Typické jasové profily v okolí hranových bodů




- ◆ První tři profily zleva, tj. skoková změna, střechová změna, tenká linie, jsou idealizované.
- ◆ Poslední profil odpovídá zašuměné změně intenzity, kterou lze najít v reálném obrázku.
- ◆ V MATLABu je k dispozici funkce `improfile`.

Citlivost derivace na šum

jasový profil se šumem




jeho derivace




Kde je v derivovaném zašuměném obraze hranový bod?

Před derivováním nutno vyhladit



Záměna derivace a konvoluce

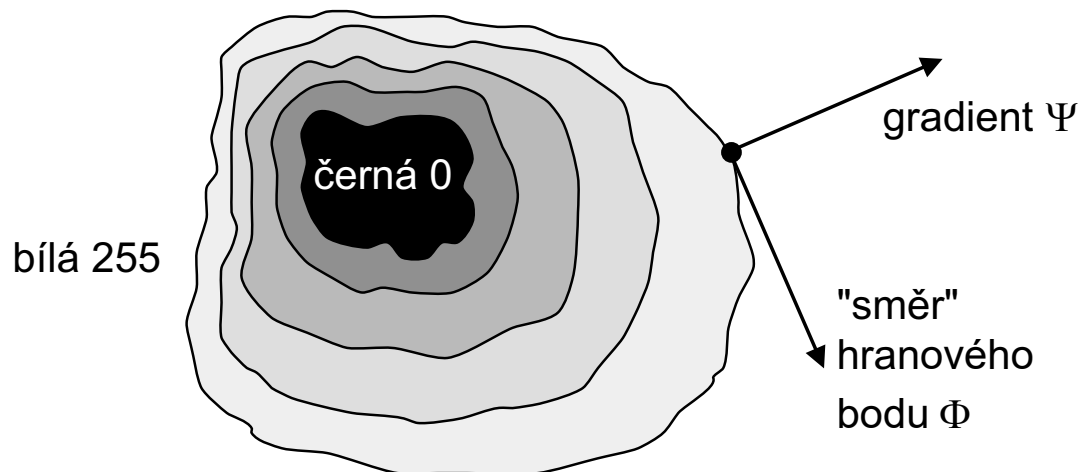


- ◆ Díky komutativitě derivace a konvoluce lze oba operátory zaměnit.
- ◆ Díky asociativitě je lze shrnout do jediného operátoru:

$$\frac{d}{dx}(h * f) = \frac{dh}{dx} * f$$

Vztah hrany a hranice

- ◆ Nalezené silné hrany (hranové body, edgels) v obraze lokálními operátory se někdy používají pro hledání hranic objektů.
- ◆ Za předpokladu, že objektu odpovídá oblast homogenního jasu, jsou body hranice právě pixely s vysokou hodnotou gradientu.
- ◆ Hranové body se spojují do hranic, a proto se “směr” hranového bodu Φ někdy definuje jako kolmý ke směru gradientu Ψ .




Derivace a konvoluční masky 3×3

- ◆ Roberts, jen 2×2 , Lawrence Roberts 1963
 - ◆ Prewittová, Judith Prewitt 1970
 - ◆ Sobel, Irwin Sobel 1968
 - ◆ Robinson
 - ◆ Kirsch, Russell A. Kirsch 1971 a další
 - ◆ Laplacián (aproximuje 2. všesměrovou derivaci)
-
- ◆ Když se uvažuje 8-okolí, existuje osm možných 3×3 masek. Důsledkem je, že směry gradientu jsou kvantovány do osmi směrů modulo 45° .
 - ◆ V obrazu se v okamžitém bodě spočte konvoluce s osmi maskami, jednou po druhé. Masky, která dává největší odezvu v absolutní hodnotě, určuje směr hrany.

Robertsův operátor v okolí 2×2

Dvě konvoluční masky (souřadnice: r - řádek, c - sloupec)

$$h_1 = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, \quad h_2 = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}.$$



Velikost gradientu se počítá podle

$$|\nabla g(r, c)| \approx |g(r, c) - g(r + 1, c + 1)| + |g(r, c + 1) - g(r + 1, c)|.$$

Nevýhoda: velká citlivost na šum, protože okolí použité pro aproximaci je malé.

Operátor Prewittové v 3×3 okolí

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix},$$


$$h_4 = \begin{bmatrix} -1 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix}, h_5 = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}, h_6 = \begin{bmatrix} 0 & -1 & -1 \\ 1 & 0 & -1 \\ 1 & 1 & 0 \end{bmatrix},$$

$$h_7 = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}, h_8 = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -1 \end{bmatrix},$$


Příklad: operátor Prewittové, hrany v západním směru



originál 256×256



západní gradienty




prahované hrany, edgels


Příklad: operátor Prewittové, hrany v severním směru



originál 256×256



severní gradienty



prahované hrany, edgels

Sobelův operátor v 3×3 okolí

$$h_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, \quad h_2 = \begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix},$$

$$h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \dots$$

Robinsonův operátor v 3×3 okolí

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix}, \quad h_2 = \begin{bmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{bmatrix},$$

$$h_3 = \begin{bmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{bmatrix}, \dots$$

Kirschův operátor v 3×3 okolí

$$h_1 = \begin{bmatrix} 3 & 3 & 3 \\ 3 & 0 & 3 \\ -5 & -5 & -5 \end{bmatrix}, \quad h_2 = \begin{bmatrix} 3 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & -5 & 3 \end{bmatrix},$$

$$h_3 = \begin{bmatrix} -5 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & 3 & 3 \end{bmatrix}, \dots$$

Laplacián obrazové funkce

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}$$

- ◆ $\nabla^2 f$ je skalár, oproti gradientu přicházíme tedy o směr hrany.
- ◆ Podobně jako velikost gradientu $\|\nabla f\|$, také $\nabla^2 f$ je invariantní vůči natočení souřadné soustavy.
- ◆ Pro monotónně rostoucí jasovou funkci $f(x, y)$ v příslušném okolí je Laplacián nulový tam, kde je velikost gradientu $\|\nabla f(x, y)\|$ maximální \Rightarrow průchody nulou (angl. zero-crossings).

Diskrétní aproximace Laplaciánu

- ◆ Diskrétní druhá derivace je složením (konvolucí) prvních derivací:

$$\frac{d^2}{dx^2} \approx [-1, +1] * [-1, +1] = [+1, -2, +1]$$

- ◆ Diskrétní Laplacián je součtem druhých parciálních derivací:

$$\nabla^2 \approx \begin{bmatrix} 0 & 0 & 0 \\ 1 & -2 & 1 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 1 & 0 \\ 0 & -2 & 0 \\ 0 & 1 & 0 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

- ◆ Alternativní používané tvary (8-okolí, zvýraznění středu):

$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \quad \begin{bmatrix} 2 & -1 & 2 \\ -1 & -4 & -1 \\ 2 & -1 & 2 \end{bmatrix}, \quad \begin{bmatrix} -1 & 2 & -1 \\ 2 & -4 & 2 \\ -1 & 2 & -1 \end{bmatrix}$$

Ostření Laplacianem

Někdy nechceme detekovat hranové body, ale pouze zvýraznit hrany (ostření). Laplacian je vhodný, neboť zdůrazňuje vysoké frekvence (srov. DoG) a je všesměrový.



originál 256 × 256



Hrany (Laplace)



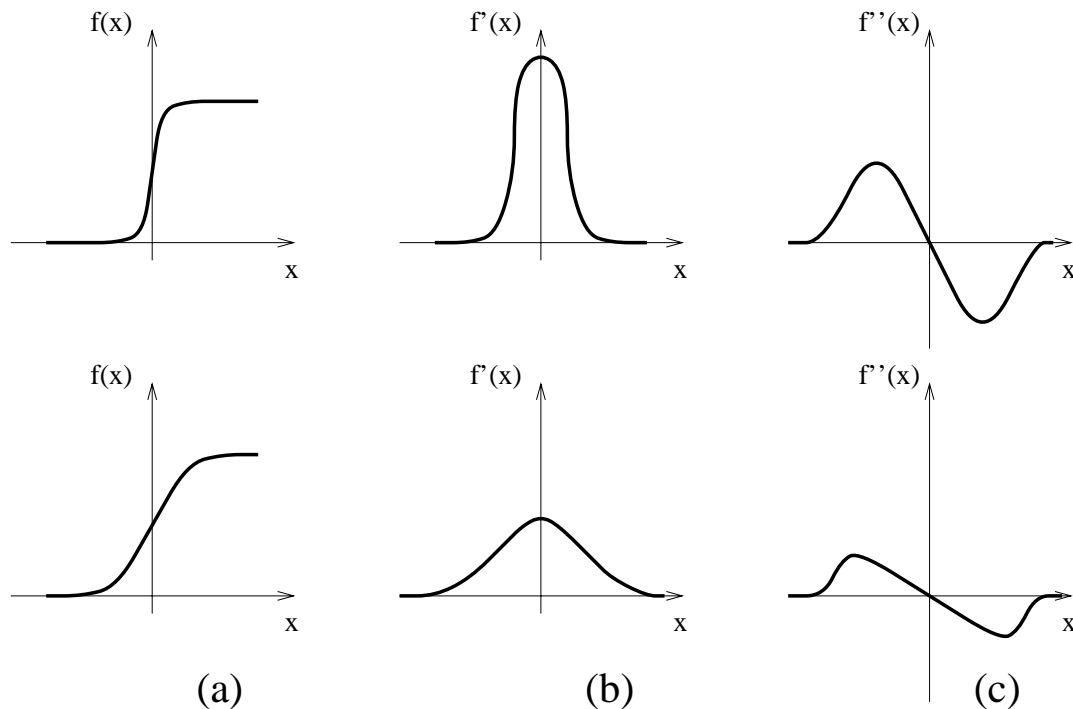
Ostření (- 0,4 ·)

Detektor hranových bodů založený na 2. derivaci (Marr-Hildreth)



28/48

- ◆ Extrém 1. derivace funkce jedné proměnné (1D signálu) odpovídá místu průchodu 2. derivace nulovou hladinou.



- ◆ Pro funkce dvou proměnných to není totéž: do hry vstupuje Laplaceův operátor ∇^2 .

Odvození LoG operátoru

Laplacián ∇^2 , viz průsvitka 25, je ještě citlivější na šum než gradient \Rightarrow opět kombinujeme s vyhlazením Gaussiánem G . Oba operátory lze spojit do jediného, označovaného jako LoG (Laplacian of Gaussian). Všimněte si použití asociativity operátorů.

$$\nabla^2(G * f) = (\nabla^2 G) * f = \text{LoG}(f)$$


Odvodíme analytický tvar $\nabla^2 G$. Zavedeme substituci $x^2 + y^2 = r^2$, která uvažuje rotační symetrii:

$$G(r) = e^{-\frac{r^2}{2\sigma^2}}, \quad G'(r) = -\frac{1}{\sigma^2} r e^{-\frac{r^2}{2\sigma^2}}, \quad G''(r) = \frac{1}{\sigma^2} \left(\frac{r^2}{\sigma^2} - 1 \right) e^{-\frac{r^2}{2\sigma^2}}.$$


Návrat k původním souřadnicím x, y a zavedení normalizačního koeficientu c

$$\nabla^2 G(x, y) = c \left(\frac{x^2 + y^2 - \sigma^2}{\sigma^4} \right) e^{-\frac{x^2 + y^2}{2\sigma^2}}.$$


2D operátory, s nimiž jsme se setkali




Gaussián




$\frac{\partial}{\partial x} G$




$\frac{\partial}{\partial y} G$



$\frac{\partial^2}{\partial x^2} G$



$\frac{\partial^2}{\partial y^2} G$



Laplacián Gaussiánu

DoG jako aproximace LoG

- ◆ Cílem je aproximovat LoG operátor (Laplacian of Gaussian), tj. $\nabla^2 G$.
- ◆ Aproximovat lze pomocí difference dvou obrazů, které vznikly konvolucí s Gausiánem o různém σ .

Jak počítat průchody nulou?

- ◆ Při implementaci detektoru založeného na hledání průchodů nulou je třeba se vyhnout naivnímu řešení pomocí prahování LoG obrazu v intervalu hodnot blízkých k nule. Výsledkem by byly hodně nespojitě hrany.
- ◆ Lepší je použít opravdový detektor průchodů nulou, např. v masce 2×2 s reprezentativním bodem třeba v levém horním rohu. Hrana se zde indikuje tehdy, pokud se uvnitř okna opravdu mění znaménko.


Příklad průchodů nulou



Originál



DoG $\sigma_1 = 0,1$ $\sigma_2 = 0,09$




Průchody nulou


Nevýhody:

- ◆ Příliš vyhlazeny ostré tvary. Například ostré rohy se ztrácejí.
- ◆ Snaží se spojit hranové body do uzavřených křivek. “Talíř špaget”.


Odstranění nevýznamných hranových bodů



Průchody nulou



Odstr. nevýzn. edgels



LoG, $\sigma = 0,2$

Biologické opodstatnění LoG operátoru

- ◆ Sítnice je evolučně součástí mozku. Probíhá v ní nejen zachycení světla (tyčinky, čípky), ale i předzpracování. Data jsou komprimována asi 1:100 ← omezná přenosová kapacita očního nervu.
- ◆ Kruhová receptivní pole. Jejich vnější část přispívá k odezvě opačným znaménkem než střed (tzv. uspořádání center-surround).




Fig. 10. Center-surround receptive fields can be ON center or OFF center with the opposite sign annular surround.





Fig. 12. Diagram of the organization of center-surround responses using horizontal cell circuitry to provide the antagonistic surround.


Problém volby měřítka vyhlazení (1)



Problém volby měřítka vyhlazení (2)

- ◆ Jaké zvolit σ Gausiánu při počítání derivací? Čím větší σ , tím ...
 - lepší potlačení šumu,
 - více slabých hran zanikne,
 - menší přesnost lokalizace hran.
- ◆ Problém není omezen na detekci hran. Je to obecný problém při detekci primitiv (lokálních vlastností) v obrazech (např. významných bodů).
- ◆ Často nás nezajímají detaily, i když nevznikly díky šumu. Jako bychom se chtěli podívat na obraz z 'větší dálky' a detekovat jen významnější hranové body (či jiná primitiva).

... Prostor měřítek pro 1D signál



- ◆ S rostoucím měřítkem σ může hranový bod zaniknout, ale nový hranový bod se tak nikdy nevytvoří.
- ◆ V 1D: A.P. Witkin: Scale-space filtering. Proceedings of 8th Int. conference on AI, August 1983, pp. 1019-1022.
- ◆ Ve 2D: T. Lindeberg: Scale-Space Theory in Computer Vision, Kluwer Academic Publishers/Springer, Dordrecht, Netherlands, 1994.

Cannyho detektor hranových bodů

- ◆ V jistém smyslu završení období hledání 'nejlepšího' hranového detektoru.
J. Canny: A Computational Approach To Edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 8(6):679–698, 1986.
 - ◆ Formulovaný jako hledání optimálního filtru za prakticky potřebných omezení.
 - ◆ Používá se v mnoha aplikacích. Implementace jsou dostupné.
-
- ◆ Vstup: šedotónový obraz.
 - ◆ Výstup: binární obraz s hranovými body.

Cannyho algoritmus pro hledání hranových bodů:

1. Najdi přibližně směry gradientu.
2. Pro každý pixel najdi 1D derivaci ve směru gradientu pomocí 'optimální' masky spojující vyhlazení a derivaci.
3. Najdi lokální maxima těchto derivací.
4. Hranové body získej prahováním s hysterezí.
5. Proveď syntézu hran získaných pro různě velká vyhlazení (málokdy se používá).


Optimální lineární filtr pro detekci hranových bodů

Předpokládá se zjednodušený model: ideální schodová hrana; aditivní gaussovský šum nezávislý na obrázku.


Požadavky, které chceme maximalizovat (=omezení pro optimalizaci):

1. Spolehlivá detekce (nalézt co nejvíce existujících hranových bodů);
2. Dobrá lokalizace (malá chyba detekované pozice hranového bodu);
3. Jednoznačná odezva (nalezeno co nejméně neexistujících hranových bodů).


-
- ◆ Požadavky protichůdné: čím lepší detekce, tím horší lokalizace.
 - ◆ Hledáme tedy 'nejlepší' kompromis: optimalizujeme součin kritérií 1 a 2 a přidáme kritérium 3 (podrobnosti vynechávám kvůli stručnosti).
 - ◆ Výsledek nelze napsat jedním vzorečkem, ale byl by velmi podobný derivaci Gaussiánu.




skutečný
edgel



detekovaný




špatně
lokalizovaný




nejednoznačně
detekovaný

Nalezení maxim první derivace v 1D

- ◆ Prahování je nevhodné (leďaže maxima jsou velmi ostrá).





- ◆ Správné je hledat lokální maxima derivace (non-maxima suppression).



- ◆ Umožňuje subpixelovou (tj. lepší než celočíselnou) přesnost nalezení maxima: např. proložíme parabolou a analyticky spočítáme maximum.


Nalezení maxim gradientu ve 2D

- ◆ Hledáme 1D maxima v (přibližném) směru gradientu.
- ◆ Funkci ve směru gradientu vzorkujeme mřížkou.



Nalezení hranových bodů prahováním s hysterezí

- ◆ Chceme potlačit krátké (tj. typicky nevýznamné) řetězy hranových bodů, ale přitom zabránit fragmentaci dlouhých řetězů.
- ◆ Nelze dosáhnout jediným globálním prahem → prahování dvěma prahy s hysterezí: slabší hranový bod zachováme pokud je součástí řetězu obsahujícího silnější body.



Cannyho hranové body, příklad; práh = 0.15, tři hodnoty σ



originál



thres = 0.15, $\sigma = 0.2$



thres = 0.15, $\sigma = 0.5$



thres = 0.15, $\sigma = 1.0$

Cannyho hranové body, příklad; práh = 0.3, tři hodnoty σ



45/48



originál



thres = 0.3, $\sigma = 0.2$



thres = 0.3, $\sigma = 0.5$




thres = 0.3, $\sigma = 1.0$

Cannyho hranové body, příklad; práh = 0.5, tři hodnoty σ




originál



thres = 0.5, $\sigma = 0.2$



thres = 0.5, $\sigma = 0.5$




thres = 0.5, $\sigma = 1.0$

Spojování hranových bodů do úseček



- ◆ Filtrováno Laplaciánem.
- ◆ Detekovány průchody nulou.
- ◆ Spojeno do úseček



Kritika hran v rozích

- ◆ Hranové detektory (např. LoG, Laplacian of Gaussians) nejsou přesné 'v rozích'.
- ◆ Ovšem úkolem hranových detektorů není hledání rohů.
- ◆ K tomu slouží detektory rohů (viz samostatná přednáška).