

# Cyfrowe przetwarzanie obrazów i sygnałów

## Wykład 8

### AiR III

**Joanna Ratajczak**

KCiR (W4/K7)

Copyright © 2015 Joanna Ratajczak<sup>1</sup>

---

<sup>1</sup>Niniejszy dokument zawiera materiały do wykładu z przedmiotu Cyfrowe Przetwarzanie Obrazów i Sygnałów. Jest on udostępniony pod warunkiem wykorzystania wyłącznie do własnych, prywatnych potrzeb i może być kopiowany wyłącznie w całości, razem ze stroną tytułową.

## Reprezentacja obrazu w bazie F-C

W. Frei, C. Chen, *Fast Boundary Detection: A Generalization and New Algorithm*, IEEE Trans. Computers, 1977.

W ósmiospójnym otoczeniu punktu  $(x, y)$  funkcję obrazu  $f$  można traktować jako dziewięciowymiarowy wektor

$$\mathbf{f}_8(x, y) \in \mathcal{R}^9$$

o składowych równych wartościom  $f$  w poszczególnych punktach tego otoczenia.

$f(x-1, y-1)$	$f(x, y-1)$	$f(x+1, y-1)$
$f(x-1, y)$	$f(x, y)$	$f(x+1, y)$
$f(x-1, y+1)$	$f(x, y+1)$	$f(x+1, y+1)$

 $\rightarrow \mathbf{f}_8 = \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_9 \end{bmatrix}$

## Reprezentacja obrazu w bazie F-C

Jego reprezentacja w bazie  $h_i$

$$\mathbf{f}_8(x, y) = \sum_{i=1}^9 a_i h_i$$

ma składowe

$$a_i = \frac{(\mathbf{f}_8(x, y), h_i)}{(h_i, h_i)}.$$

## Baza kształtów lokalnych

$$h_1 = \begin{bmatrix} 1 & \sqrt{2} & 1 \\ 0 & 0 & 0 \\ -1 & -\sqrt{2} & -1 \end{bmatrix} \quad (h_1, h_1) = 8$$

$$h_2 = \begin{bmatrix} 1 & 0 & -1 \\ \sqrt{2} & 0 & -\sqrt{2} \\ 1 & 0 & -1 \end{bmatrix} \quad (h_2, h_2) = 8$$

$$h_3 = \begin{bmatrix} 0 & -1 & \sqrt{2} \\ 1 & 0 & -1 \\ -\sqrt{2} & 1 & 0 \end{bmatrix} \quad (h_3, h_3) = 8$$

## Baza kształtów lokalnych

$$h_4 = \begin{bmatrix} \sqrt{2} & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & -\sqrt{2} \end{bmatrix} \quad (h_4, h_4) = 8$$

$$h_5 = \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & -1 \\ 0 & 1 & 0 \end{bmatrix} \quad (h_5, h_5) = 4$$

$$h_6 = \begin{bmatrix} -1 & 0 & 1 \\ 0 & 0 & 0 \\ 1 & 0 & -1 \end{bmatrix} \quad (h_6, h_6) = 4$$

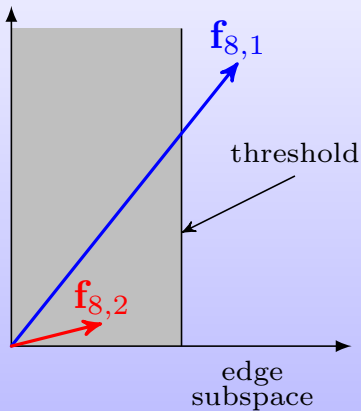
## Baza kształtów lokalnych

$$h_7 = \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix} \quad (h_7, h_7) = 36$$

$$h_8 = \begin{bmatrix} -2 & 1 & -2 \\ 1 & 4 & 1 \\ -2 & 1 & -2 \end{bmatrix} \quad (h_8, h_8) = 36$$

$$h_9 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (h_9, h_9) = 9$$

non-edge  
subspace



## Baza F–C a wykrywanie krawędzi

Podprzestrzeń „krawędziowa” jest rozpięta przez  $h_1$  i  $h_2$

$$E = \text{span}\{h_1, h_2\}.$$

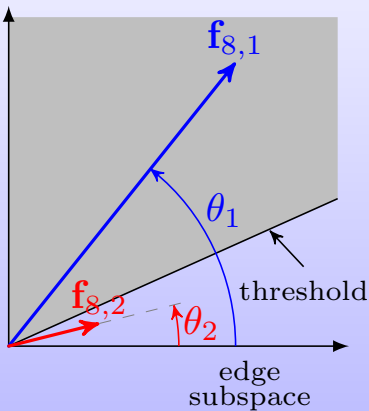
Kryterium przyjęcia punktu  $(x, y)$  za element krawędzi stanowi kąt pomiędzy wektorem  $\mathbf{f}_8(x, y)$  a podprzestrzenią  $E$ .

$$\theta = \arccos \sqrt{\frac{\sum_{i=1}^2 (\mathbf{f}_8, h_i)^2}{\sum_{j=1}^9 (\mathbf{f}_8, h_j)^2}}$$

Można założyć wartość progową tego kąta, poniżej której uznamy zasadność przyjęcia  $(x, y)$  jako elementu krawędzi.



non-edge  
subspace



## Baza F-C a wykrywanie krawędzi

Równoważnie

$$|\mathbf{f}_E| = \sqrt{(\mathbf{f}_8, h_1)^2 + (\mathbf{f}_8, h_2)^2}$$

$$|\mathbf{f}_N| = \sqrt{\sum_{i=3}^9 (\mathbf{f}_8, h_i)^2}$$

$$\theta = \arctg \frac{|\mathbf{f}_N|}{|\mathbf{f}_E|}$$

## Detektor Frei–Chen

- Nieczuły na długość wektora  $\mathbf{f}_g$ .
- Wykrywa krawędzie w ciemnych obszarach.
- Wykrywa subtelne krawędzie.
- "Mocne" krawędzie oznaczone są cienką linią.
- Czuły na zakłócenia.

# Detektor krawędzi Canny

Canny J., *A Computational Approach to Edge Detection*, IEEE Trans. Pattern Analysis and Machine Intelligence, 1986.

Cele:

- 1 skuteczne wykrywanie** – znaleźć jak najwięcej rzeczywistych krawędzi. Przy czym błędem jest zarówno detekcja fałszywych krawędzi jak i pomijanie rzeczywistych krawędzi.
- 2 poprawna lokalizacja** – punkt sklasyfikowany jako punkt krawędzi powinien być jak najbliższy środkowemu punktowi rzeczywistej krawędzi.
- 3 minimalny nadmiar** – oznaczyć każdą krawędź pojedynczą linią, nie oznaczać szumów.

# Detektor krawędzi Canny

## Etapy przetwarzania

- 1** Redukcja szumu poprzez zastosowanie filtru Gaussa  $G(x, y, \sigma)$  parametryzowanego przez odchylenie standardowe  $\sigma$ .  $\sigma$  odpowiada za rozmiar maski użytej do filtracji i ma wpływ na stopień eliminacji szumów (a przy okazji krawędzi) w obrazie.
- 2** Wyznaczenie gradientu jasności obrazu (dowolny filtr gradientowy: Sobel, Roberts, Prewitt)

$$\nabla f(x, y) = \begin{bmatrix} \frac{\partial f(x, y)}{\partial x} \\ \frac{\partial f(x, y)}{\partial y} \end{bmatrix} = \begin{bmatrix} \nabla_x f \\ \nabla_y f \end{bmatrix}$$

oraz wyznaczenie modułu (wartości) i kierunku gradientu



$$|\nabla f(x, y)| = \sqrt{(\nabla_x f)^2 + (\nabla_y f)^2} \quad \alpha(x, y) = \frac{\nabla_y f}{\nabla_x f}$$

## Detektor krawędzi Canny

- 3 Odrzucenie punktów nie będących maksimami gradientu wzdłuż jego kierunku – tłumienie niemaksymalne.
- 4 Śledzenie segmentów krawędzi z progowaniem podwójnym (progowanie z histerezą). Usunięcie z obrazu słabych krawędzi, ale jednocześnie generowanie ciągłych krawędzi.


## Składowe gradientu z filtracją

$$\sigma = 0.5 \rightarrow h_{3 \times 3}$$



## Składowe gradientu z filtracją

$$\sigma = 2 \rightarrow h_{9 \times 9}$$







## Moduł gradientu



$\sigma = 0.5$



$\sigma = 2$




## Kierunek gradientu



## Tłumienie niemaksymalne

**Cel:** generowanie przez detektor pojedynczej odpowiedzi dla każdej rzeczywistej krawędzi w obrazie.


Zapewnia, że pikselem krawędzi jest piksel, którego wartość jest maksymalna w danym kierunku gradientu.



# Tłumienie niemaksymalne


## Algorytm

- 1 Przeglądaj wartości gradientu  $|\nabla f(x, y)|$  dla kolejnych pikseli. Dla piksela o niezerowej wartości wyznacz kierunek gradientu.
- 2 Dla aktualnie przeglądanej piksela sprawdź dwóch najbliższych sąsiadów w kierunku zgodnym z kierunkiem gradientu.



- 3 Jeśli wartość gradientu dla aktualnego piksela jest większa od obu sąsiadów zachowaj ją w przeciwnym wypadku przypisz pikselowi wartość zero.

## Usuwanie niemaksimów




## Śledzenie z progowaniem podwójnym

**Cel:** zachowanie punktów dla których wartość gradientu jest duża i odrzucić te dla których wartość gradientu jest mała.

Problem z krawędziami, które posiadają ciemniejsze fragmenty.

Wykorzystujemy progowanie z histerezą.


## Progowanie podwójne (histerezowe)





## Wykorzystujemy rekurencyjne śledzenie krawędzi:

- 1 Przeglądamy obraz z lewa na prawo, z góry do dołu.
- 2 Pixel, którego wartość (gradientu) jest powyżej ustalonego progu radykalnego  $T_r$  jest przyporządkowywany do krawędzi.
- 3 Przeglądamy „sąsiadów”. Wszyscy, którzy posiadają wartość większą od  $T_l$  stają się nowymi początkami śledzenia.
- 4 Warunek STOPu: wartość gradientu sąsiadów jest poniżej  $T_l$  lub pixel był już analizowany.



## Śledzenie z progowaniem podwójnym

$T_r = 50, T_l = 10;$


$T_r = 100, T_l = 10;$

$T_r = 50, T_l = 40;$



<http://suraj.lums.edu.pk/~cs436a02/images/anim.mpg>

► Animacja





## Wybór cech



### ■ Modele barw

model	kierunek oświetlenia	natężenie oświetlenia	kolor oświetlenia	refleksy
RGB	+	+	+	+
HSV	-	-	+	-

### ■ Miara podobieństwa

## Wybór cech

- Modele barw
- Miara podobieństwa



## Metodologie

- 1 Konwersja do skali szarości.
- 2 Suma gradientów dla poszczególnych składowych RGB.  
Dobre do aplikacji dla obrazów, w których kolory i obiekty są dobrze zdefiniowane.
- 3 Kombinacja gradientów poszczególnych składowych HSV.  
Mniej czułe na cienie w obrazie.
- 4 Zmodyfikowane operatory Robertsa, Sobela, itp.

## Metodologie

- 5 Gradienty dla wybranej miary podobieństwa (np. odległości euklidesowej, miary kątowej).
- 6 Metody statystyczne – średnia z elementów wektora, mediana z elementów, itp.
- 7 Gradient wektorowy, w otoczeniu punktu centralnego bierzemy max odległość euklidesową.
- 8 Metody hybrydowe – w oparciu o ideę fuzzy logic wykorzystujemy więcej niż jedną reprezentację (np. RGB + HSV).



## Wybrane operatory

### Zmodyfikowany operator Robertsa

- skala szarości

$$|\nabla f(x, y)| = \frac{1}{\sqrt{(f(x, y) - f(x + 1, y + 1))^2 + (f(x + 1, y) - f(x, y + 1))^2}}$$

- kolor

$$\mathcal{G}_c f(x, y) = \max \left( \left| \vec{f}(x, y) - \vec{f}(x + 1, y + 1) \right|, \left| \vec{f}(x + 1, y) - \vec{f}(x, y + 1) \right| \right)$$

# Wybrane algorytmy

## Zmodyfikowany operator Sobela

- skala szarości

$$\nabla_x f(x, y) = \frac{1}{2} (f(x + 1, y) - f(x - 1, y))$$

$$\nabla_y f(x, y) = \frac{1}{2} (f(x, y + 1) - f(x, y - 1))$$

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

- kolor

$$\mathcal{G}_{xc} f(x, y) = \frac{1}{2} (\vec{f}(x + 1, y) - \vec{f}(x - 1, y))$$

$$\mathcal{G}_{yc} f(x, y) = \frac{1}{2} (\vec{f}(x, y + 1) - \vec{f}(x, y - 1))$$

$$\mathcal{G}_c f(x, y) = \max(|\mathcal{G}_{xc} f(x, y)|, |\mathcal{G}_{yc} f(x, y)|)$$

## Wybrane algorytmy

### Zmodyfikowany filtr medianowy

- Obraz jest przeglądany z oknem o ustalonym rozmiarze.
- Wartość środkowego piksela zastępowana jest medianą ze zbioru sąsiedztwa.
- Należy przyjąć jakąś metodę porządkowania, np. wyznaczamy sumaryczną odległość wektora w stosunku do pozostałych wektorów opisujących piksele w otoczeniu.
- Wyznaczoną odległość porządkujemy rosnąco.
- Wyjściem filtru jest mediana, tzn. wektor, który minimalizuje odległość od wszystkich pozostałych wektorów.