


Podstawy Teorii Informacji

Ekstrakcja informacji



Artur Przelaskowski

MiNI, p. 506, artur.przelaskowski@pw.edu.pl, tel.w. 7821


Materiały: www.ire.pw.edu.pl/~arturp/Dydaktyka/PTI

Wygodny przykład obrazów - bogaty, ale też często niejasny: co widzisz?



DO NOT confuse
TORTURER
with the
VICTIM

Say **NO**
for polish death camps



Problem definicji informacji obrazowej (czym jest obrazowa forma przekazu?)


Obraz to kompozycja:

- tła
 - konturów
 - tekstur
- } obiekty

ale przede wszystkim określone obiekty i kontekst, czyli

- semantyka, treść, informacja

$$f : \mathbf{R}^{M \times N \times k} \rightarrow \mathbf{R}$$






Dwuwymiarowa struktura elementów obrazu: macierz (matryca) rozmiarów $M \times N$ o określonej dynamice wartości pikseli, w odniesieniu do przestrzennej dokładności prezentowanej informacji (rozdzielczość); inaczej, zestaw macierzy wartości k -komponentów (np. w przestrzeni barw RGB)


Informacja ukryta w teksturach, hierarchii krawędzi, kształcie obiektów, wzajemnych relacjach struktur etc. o określonym znaczeniu




ISO 400



Przykładowe projekty studenckie dotyczące ekstrakcji informacji - usuwanie artefaktów



Rysunek 1. Przykład zastosowania *inpaintingu* cyfrowego



Zdjęcie przed wykonaniem procesu reprodukcji

Zdjęcie po procesie reprodukcji

Retusz wykonała Urszula Koc.



Zdjęcie przed wykonaniem reprodukcji



Efekt końcowy

Rekonstrukcja starych fotografii

Autorzy:

Urszula Koc, Maciej Głowacki, Jakub Cieślak.




Wykrywanie ruchu twarzy, detekcja ptaków

Wykrywanie ruchu twarzy za pomocą programu uruchomionego na emulatorze. Obraz przesłany był z kamery internetowej.

Detektor Lotu Ptaków

sprawozdanie z projektu w ramach przedmiotu
"Podstawy Przetwarzania Obrazów"

Alexander Rakowski, Maciej Nowakiewicz



Zliczanie ludzi uczestniczących w pochodach


(Rafał Kukla, Jakub Troć)

źródła danych

- <https://www.youtube.com/watch?v=fiHypVs30M>
- <https://www.youtube.com/watch?v=eEi8pzcYOOY>
- <https://www.youtube.com/watch?v=6q6BSZi5LI0>
- <https://www.youtube.com/watch?v=D3COi982ko8>
- <https://www.youtube.com/watch?v=2TcYYyLCmYA>
- https://www.youtube.com/watch?v=mnZo_H_HfGM





3. Parada studentów



Przestrzenna głębia obrazów

Odtwarzanie mapy głębokości na podstawie obrazów stereoskopowych

Daria Kurpiewska

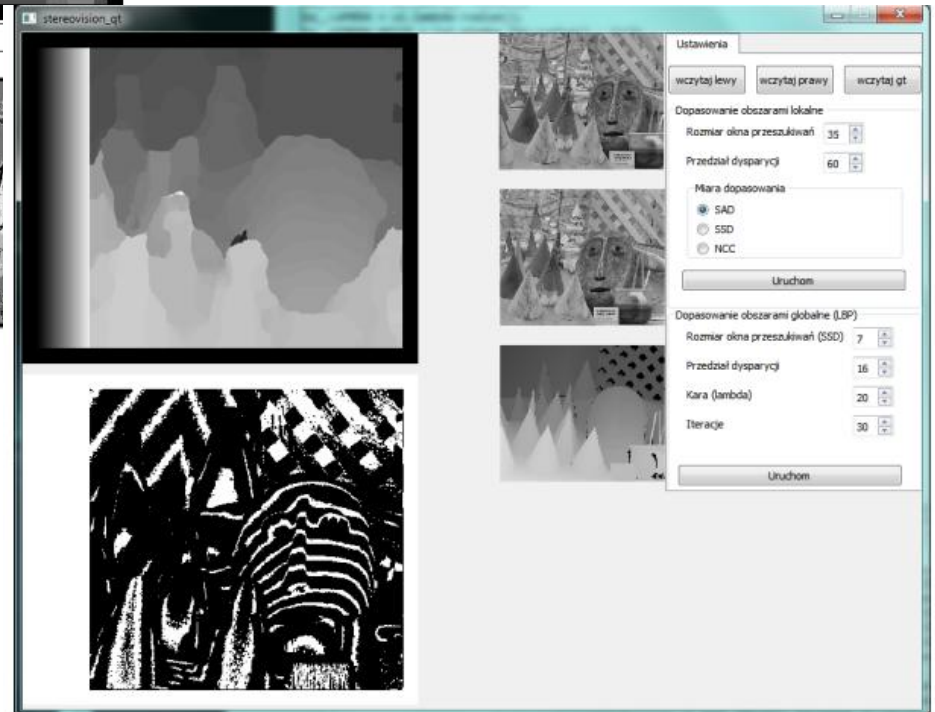



okno: 7x7, przedział dysparycji: 16, iteracje: 5

kara: 45, poprawność: 79.81%


kara: 20, poprawność: 79.00%

kara: 5, poprawność: 78.16%




Segmentacja żuchwy

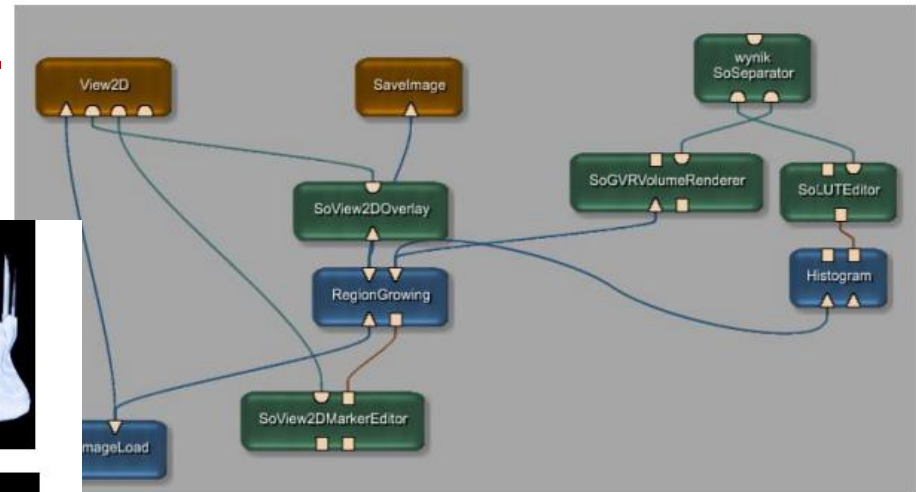
Segmentacja żuchwy z badań rentgenowskiej tomografii komputerowej (CT) głowy




Rys. 4. Efekt działania algorytmu zaimplementowanego w środowisku Matlab na wybranych badaniach z zbioru referencyjnego.



Rys. 3. Efekt działania drugiej wersji metody segmentacji żuchwy na wybranych badaniach ze zbioru referencyjnego.






Rys. 1. Obraz sieci w środowisku MeVisLab realizującej metodę segmentacji oraz trójwymiarową wizualizację jej efektów.




Rozpoznawanie człowieka za pomocą tęczówki

(Chechliński Bartłomiej)




Rys. 8. Położenie środka tęczówki oraz




Rys. 10. Tęczówka po zamianie z pierścienia na prostokąt



Rys. 14. Przykładowy kod tęczówki uzyskany za pomocą falek Gabora

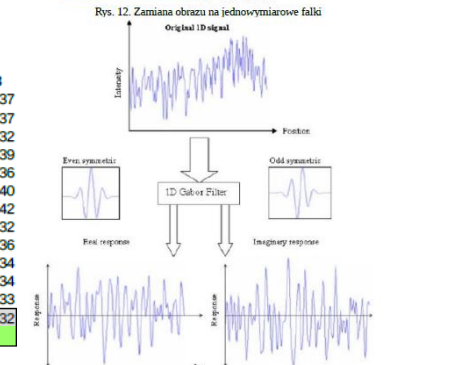


Rys. 12. Zamiana obrazu na jednowymiarowe falki



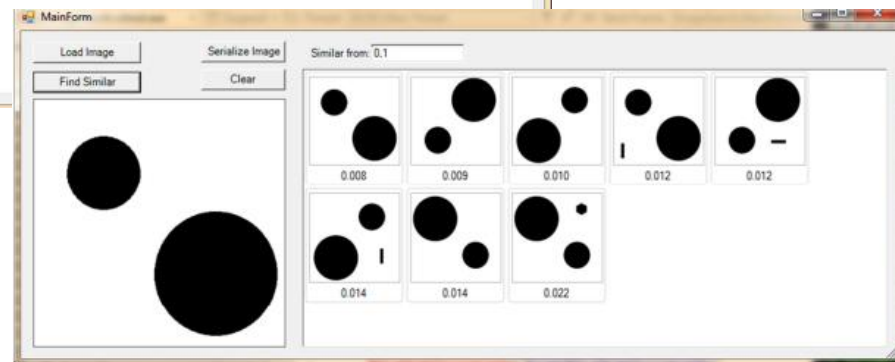
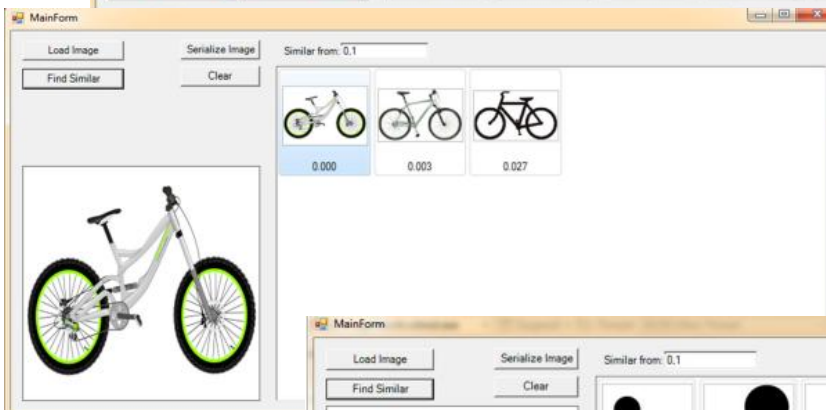
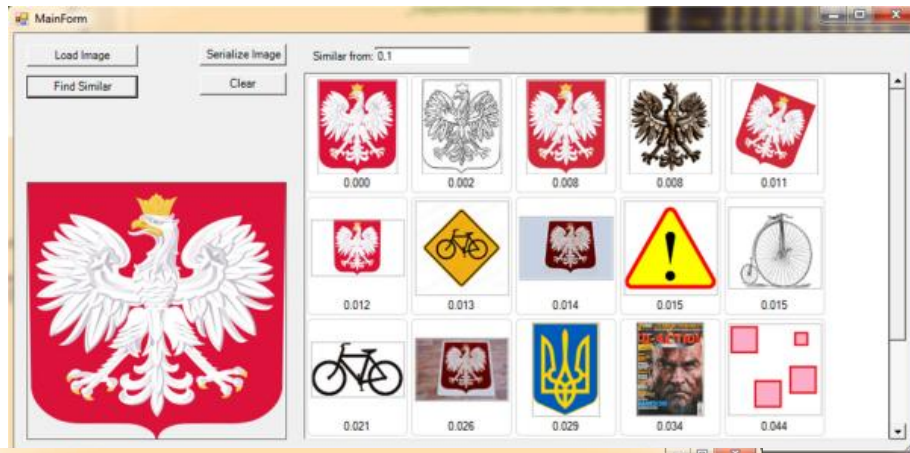
	2_R_2	2_R_4	3_L_3	3_L_5	5_R_1	5_R_2	5_R_4	11_L_2	11_L_4	13_R_1	13_R_2	13_R_4	13_L_2	13_L_3
2_R_2	0,35	0,36	0,39	0,35	0,38	0,42	0,33	0,38	0,38	0,35	0,33	0,36	0,39	0,37
2_R_4	0,35	0,34	0,37	0,37	0,39	0,40	0,33	0,40	0,35	0,36	0,36	0,39	0,37	0,37
3_L_3	0,36	0,34	0,33	0,33	0,32	0,37	0,40	0,27	0,34	0,33	0,33	0,31	0,34	0,32
3_L_5	0,39	0,37	0,33	0,33	0,35	0,37	0,42	0,32	0,39	0,35	0,34	0,36	0,38	0,39
5_R_1	0,35	0,37	0,32	0,35	0,37	0,37	0,40	0,30	0,38	0,35	0,35	0,33	0,35	0,36
5_R_2	0,38	0,39	0,37	0,37	0,37	0,37	0,43	0,35	0,40	0,39	0,37	0,35	0,40	0,40
5_R_4	0,42	0,40	0,40	0,42	0,40	0,43	0,37	0,41	0,43	0,40	0,37	0,41	0,42	0,42
11_L_2	0,33	0,33	0,27	0,32	0,30	0,35	0,37	0,32	0,35	0,30	0,31	0,30	0,32	0,32
11_L_4	0,38	0,40	0,34	0,39	0,38	0,40	0,41	0,34	0,34	0,39	0,41	0,36	0,37	0,36
13_R_1	0,38	0,35	0,33	0,35	0,35	0,39	0,43	0,30	0,39	0,34	0,34	0,35	0,37	0,34
13_R_2	0,35	0,36	0,33	0,34	0,35	0,37	0,40	0,31	0,41	0,34	0,34	0,31	0,34	0,34
13_R_4	0,33	0,36	0,31	0,36	0,33	0,35	0,37	0,30	0,36	0,35	0,31	0,33	0,33	0,33
13_L_2	0,36	0,39	0,34	0,38	0,35	0,40	0,41	0,32	0,37	0,37	0,34	0,33	0,32	0,32
13_L_3	0,37	0,37	0,32	0,39	0,36	0,40	0,42	0,32	0,36	0,34	0,34	0,33	0,32	0,32

Tabela 1. Wyniki uzyskane za pomocą falek Gabora i odległości Hamminga.



Rys. 13. Zastosowanie filtra Gabora w celu uzyskania części rzeczywistej i urojonej falki

Rozpoznawanie twarzy, wyszukiwanie obrazów podobnych



Ludzki system widzenia – modele i metody

HUMAN VISUAL SYSTEM

każde z oczu muchy składa się z 4 tysięcy małych oczek; mucha rejestruje 200 obrazów na sekundę (człowiek tylko 20)


Widzenie, czyli oczy



oczy kameleona są niezależne



orzeł z 2km dostrzega ruch królika ...



koń widzi w kącie 340 stopni



kot lepiej widzi w nocy,
świetnie widzi ruch ...



Geony jako wyróżniki (atomy) poznania (jest ich 36) – rozpoznaj obiekt!

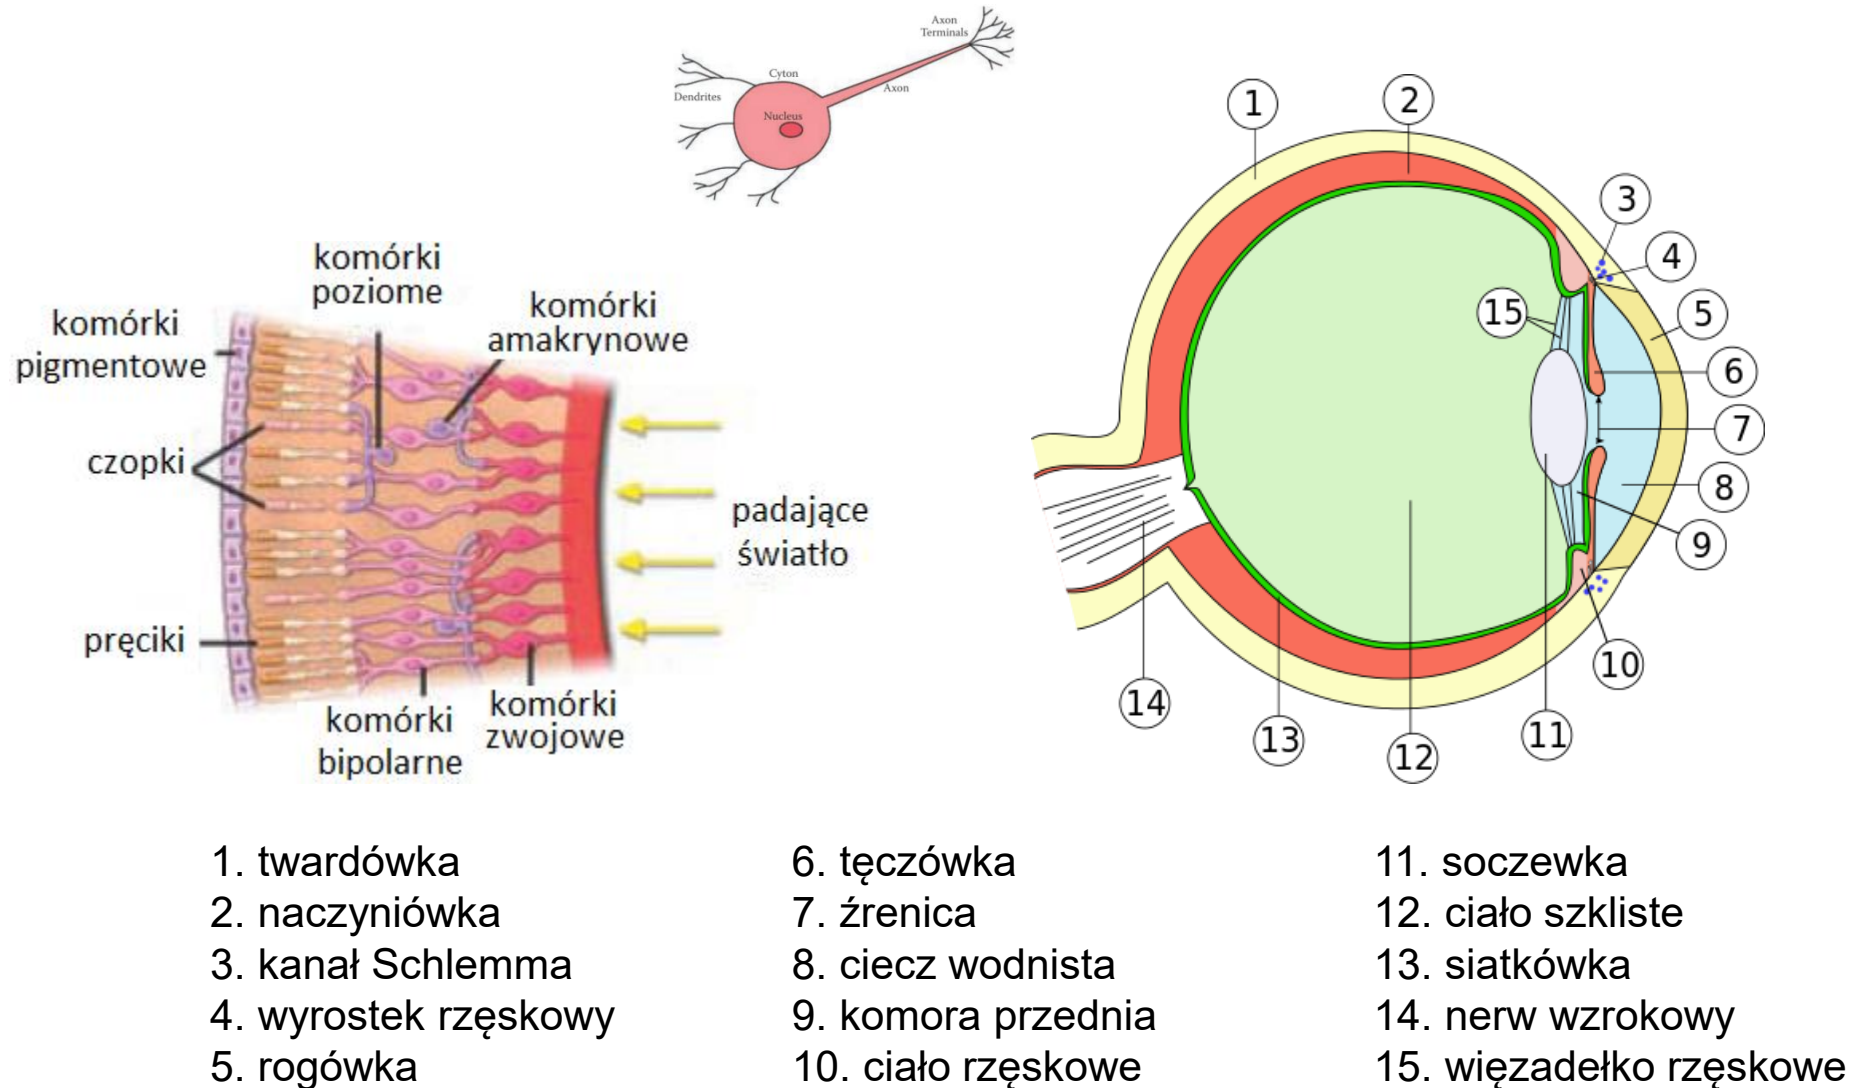
		Locus of Deletion				
		At Midsegment	At Vertex			
	Proportion Contour Deleted					
	25%					
	45%					
	65%					

Geons	Objects				

I. Biederman: *Recognition-by-components: a theory of human image understanding*, Psychol Rev, 94(2), 1987, 115-147.


filiżanka
kieliszek
konewka
nożyczki
stołek

Budowa oka ...



Optyczna koncepcja widzenia




■ Idealna



■ Zniekształcenia

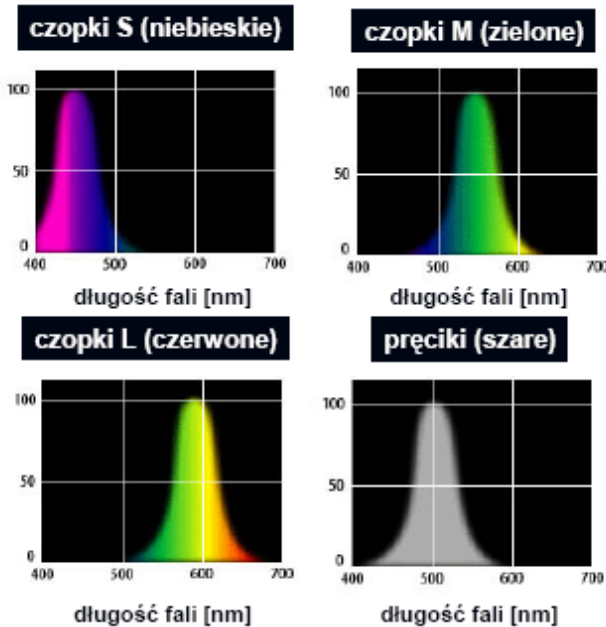

- Apertura oka
- Aberracja (deformacja obrazu)
 - niechromatyczna, np. sferyczna (grubość soczewki), astygmatyzm (rozchodzą się ogniska zogniskowań prostopadłych), dystorsja (różne powiększenie, zależne od odległości od osi)
 - chromatyczna
- Dyspersja (pryzmat)

astygmatyzm - powierzchnia oka lub soczewka tuż za nią nie ma regularnego, „kulistego” kształtu, co powoduje rozproszenie światła wpadającego do oka, które nie skupia się prawidłowo na siatkówce - **widziany obraz jest rozmyty**



Wykorzystanie modeli HVS

- Percepcja koloru (wybór przestrzeni)
- Wielokanałowy model percepcji (czas, częstotliwość i przestrzeń)
- Maskowanie
- Czułość kontrastu



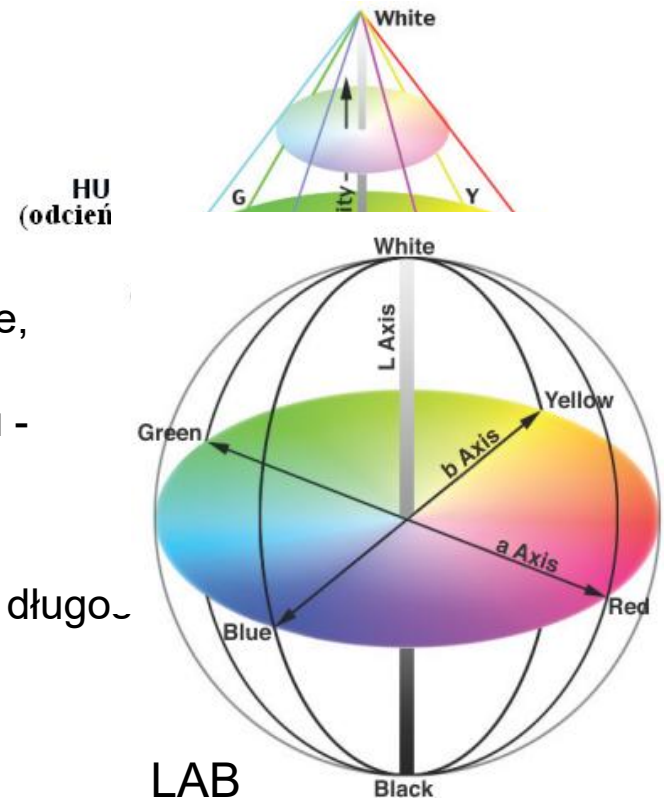
receptory siatkówki – **czopki**:

- szybka reakcja na światło
- duża ostrość, rozdzielczość
- *niewielka czułość (światło bezpośrednie)*

pręciki:

- widzenie przy bardzo słabym oświetleniu (światło rozproszone, bez rozróżniania barw)
- postrzeganie kształtów i ruchu - wolniejsza reakcja na światło
- ograniczona ostrość widzenia

Względna czułość oka ludzkiego



- najlepiej widzimy (z zakresu 380-780 nm) barwę żółtozieloną o długości fali około 555 nm
- najgorzej widzimy barwę niebieską **440 nm**
- potrafimy rozróżnić maksymalnie **128** nasyconych barw
- potrafimy rozróżnić do około **30** odcieni tej samej barwy

Składowe barwowe



(a)

Figure 1.50 Color separations from a real-world color image of flowers:

- (a) original;
- (b) red component;
- (c) green component;
- (d) blue component;
- (e) hue component;
- (f) intensity component;
- (g) saturation component.



(b)



(c)



(d)



(e)




(f)




(g)


Charakterystyka percepcji




Wykresy Campbella-Robsona




HVS – typowe analizy





koło o stałej jasności






tło o stałej jasności



czułość kontrastu





tło różne



tło jak prawa półówka




Modele wizualizacji i percepcji











Analiza i percepcja wideo




- Przestrzenno-czasowe modele percepcji
- Modele w dziedzinie DCT



Iluzje




... iluzje



Iluzja Ebbinghausa

Test

Które klocki są identyczne, a które są lustrzanym odbiciem?



Czas ustalenia podobieństwa klocków jest proporcjonalny do różnic kątowych wzajemnego położenia

Podstawowy schemat operacji na obrazie

- akwizycja (próbkowanie, kwantyzacja, kodowanie)

źródło informacji \Rightarrow obraz

- ulepszanie obrazu (wstępne, poprawa jakości, ekstrakcja informacji)

obraz \Rightarrow obraz

- analiza (segmentacja-objekty, dekompozycja-komponenty, rozpoznanie, komputerowe widzenie)

obraz \Rightarrow opis

(wyróżnienie i charakterystyka obiektów czy regionów zainteresowań, ich wzajemnych relacji)

- **grafika komputerowa** (synteza)


opis \Rightarrow obraz

(model – z typowych cech obrazów)

- interpretacja (rozumienie)

obraz, opis \Rightarrow użytkowy opis semantyczny odnoszący się do określonej wiedzy (na poziomie abstrakcji użytkownika)

Podstawy przetwarzania obrazów




- Przekształcenia geometryczne (np. afiniczne)
- Wieloobrazowe (np. morfing) i wolumetryczne
- Przekształcenia splotowe, widmowe, nieliniowe (mediana, dominanta, morfologia matematyczna)
- Interpolacja, podpróbkiwanie



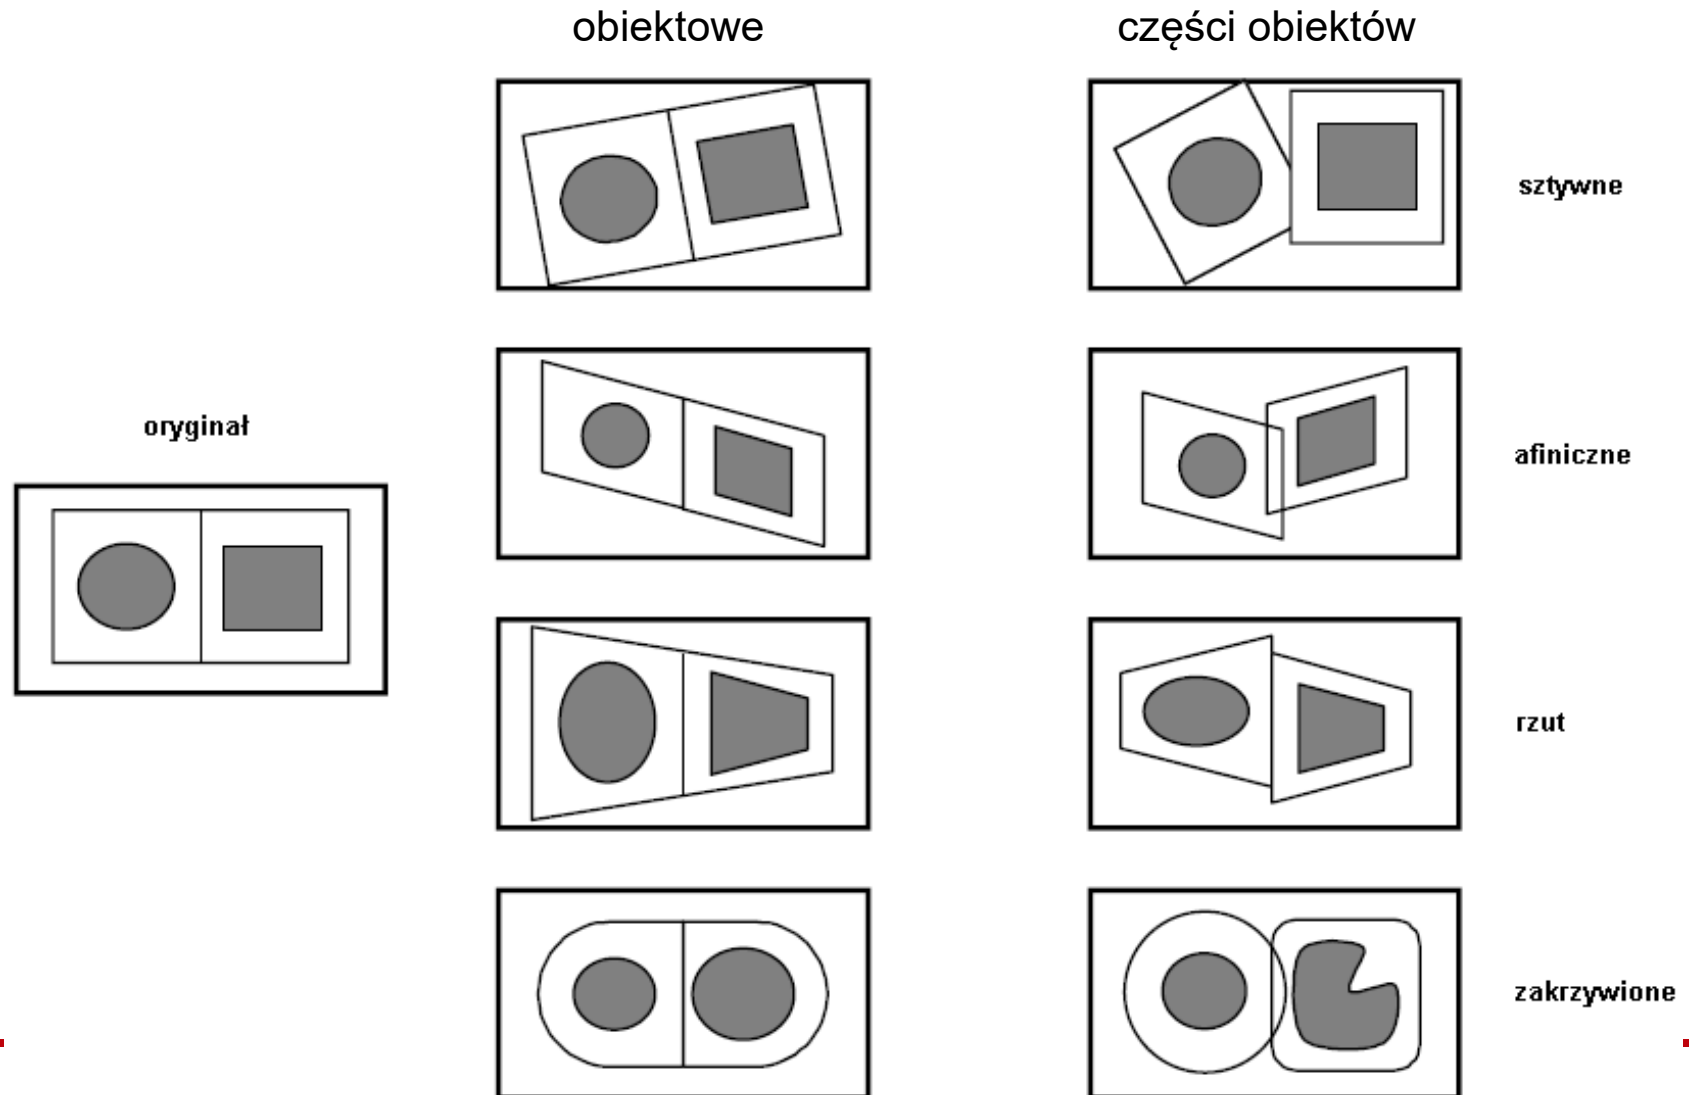
Przekształcenia geometryczne (obrazowe)

- Translacje, obroty, odbicia, skalowanie, zniekształcanie itd..



Przekształcenia geometryczne (obiektywne)

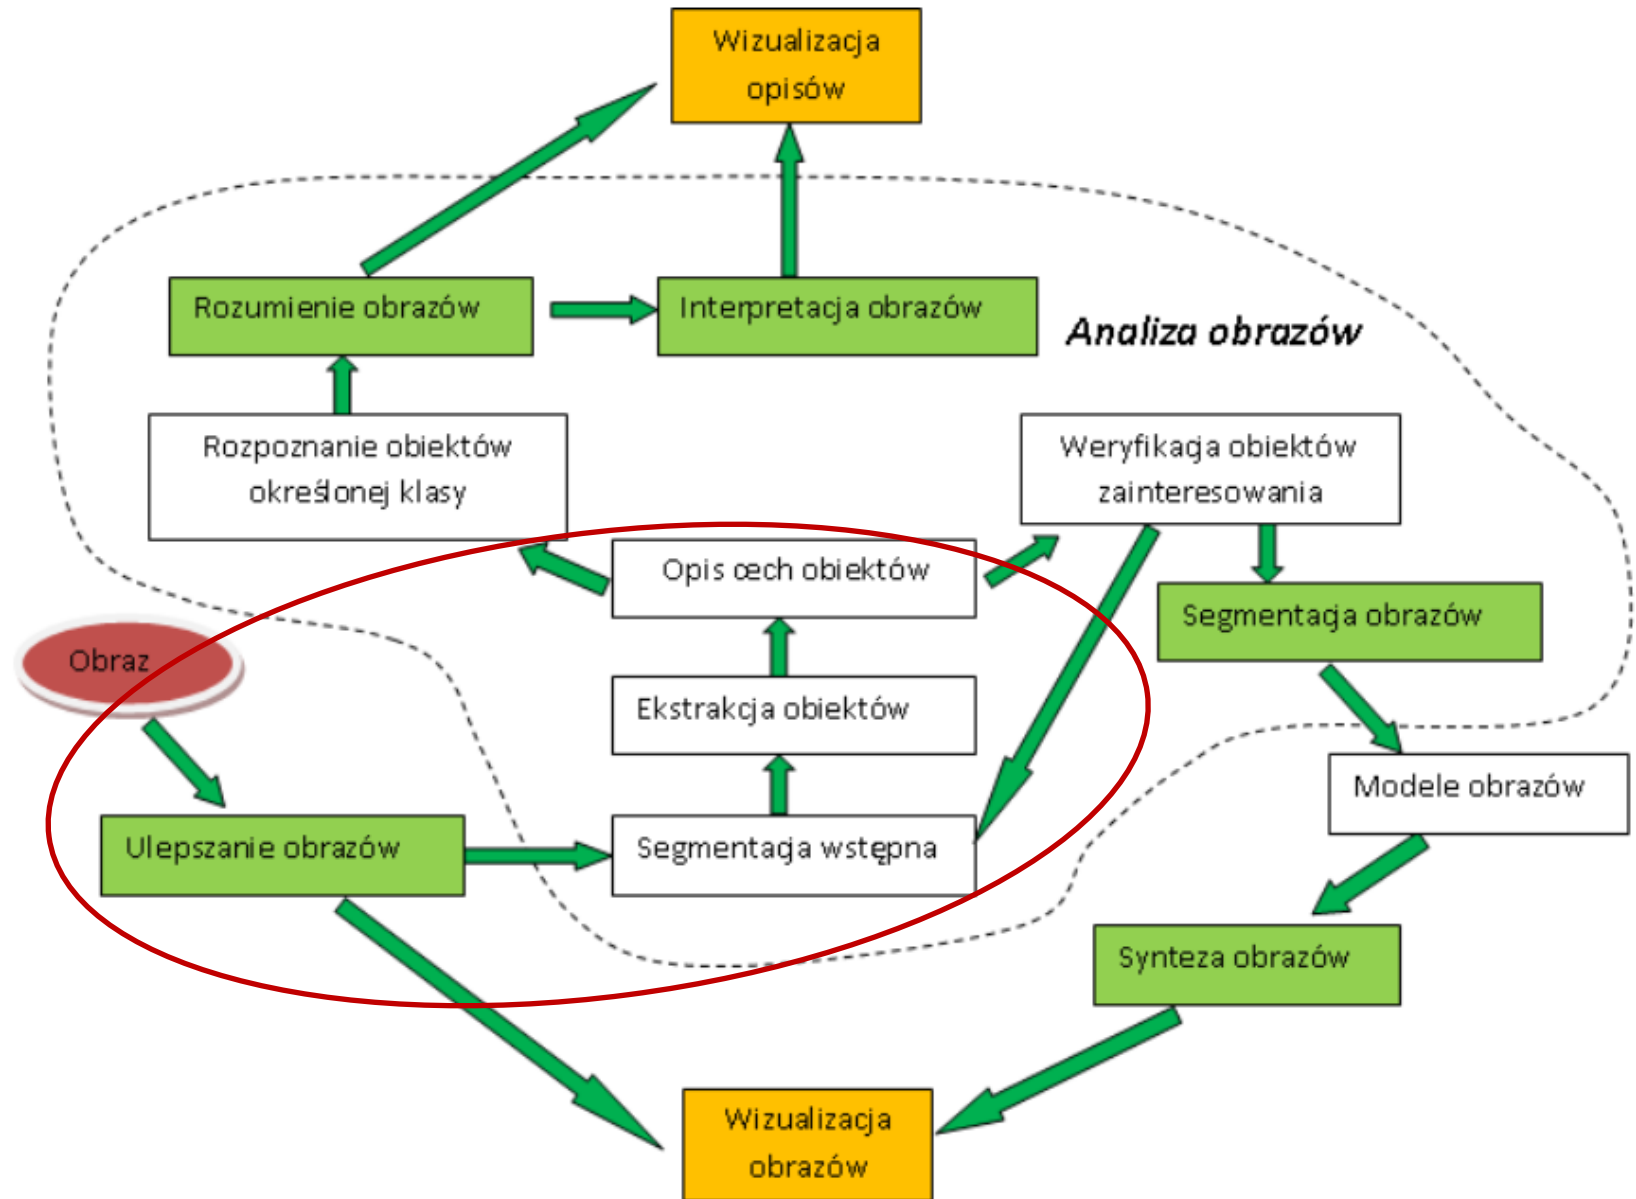
- Translacje, obroty, odbicia, skalowanie, zniekształcanie itd..



Metody obróbki obrazów celem ekstrakcji informacji w różnych zastosowaniach



Kontekst realnych zastosowań: dotarcie do kluczowej treści (przykład informacji obrazowej)



Przekształcenia punktowe

METODY I EFEKTY

Przekształcenia punktowe (pikselowe) poprawa widoczności

- Regulacja kontrastu, jasności: $f'(x,y) = k \cdot f(x,y) + j$



- Korekcja gamma, pierwiastkowanie, logarytmowanie




Poprawa kontrastu – nieliniowe operacje punktowe

Ekstrakcja wąskiego przedziału wartości funkcji




1
potęgowanie

$$f_p = f^p$$



rozjaśniająca funkcja logarytmiczna

$$f_p = a \cdot \log(1 + f)$$




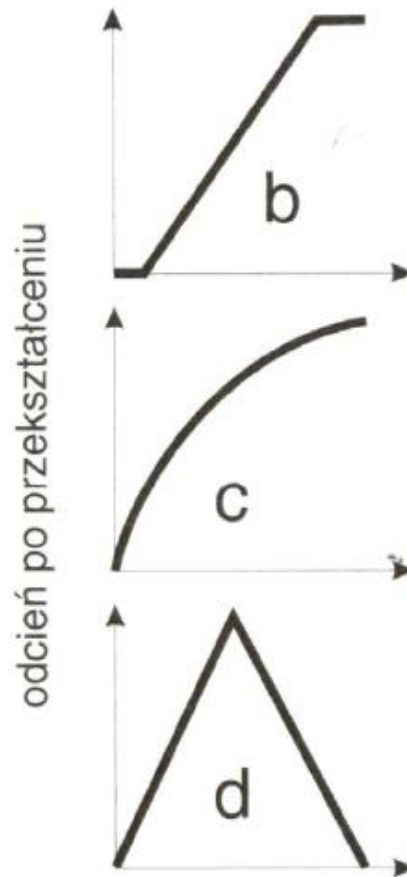



Operacje punktowe LUT

Tablica przypisań LUT (look-up table):

$$g(k, l) = F\{f(k, l)\} \quad f, g \in [0, 1]$$

LUT



solaryzacja

Efekty (gamma, negatyw, solaryzacja, okno)



$$g(k, l) = f(k, l)^\gamma$$

$$g(k, l) = 1 - f(k, l)$$

$\gamma = 1/2, 2$

$$g(k, l) = \begin{cases} 2 \cdot f(k, l) & \text{dla } 0 \leq f(k, l) \leq 0,5 \\ 2(1 - f(k, l)) & \text{dla } 0,5 < f(k, l) \leq 1 \end{cases}$$




$$g(k, l) = \begin{cases} 0 & \text{dla } 0 \leq f(k, l) \leq d \\ \frac{1}{g-d}(f(k, l) - d) & \text{dla } d < f(k, l) < g \\ 1 & \text{dla } g \leq f(k, l) \leq 1 \end{cases}$$

w porządku od lewej do prawej, góra-
dół mamy kolejno:

- obraz źródłowy
- korekcja gamma $\gamma = 2,2$
- korekcja gamma $\gamma = 1/2,2$
- negatyw
- solaryzacja
- funkcja okna ustawioną na zakres $d = 0,4$,
 $g = 0,9$ znormalizowanej dynamiki (okno tak
dobrano, by uwidocznić szczegóły twarzy
poprzez poprawę kontrastu)

Efekt poprawy kontrastu

$p=0,6$



$p=0,4$




$p=0,3$



$$f_p = a \cdot f^p$$

kawałkami liniowe
przekształcenie

Uwydatnienie treści – kształtowanie funkcji przekształcenia kontrastu



$$x = x \cdot |x_{norm}|^{1-p}$$





$$y(x) = \begin{cases} x \cdot \left(\frac{m}{n}\right)^p & \text{if } |x| < n, \\ x \cdot \left(\frac{m}{|x|}\right)^p & \text{if } n \leq |x| < m, \\ x & \text{if } |x| \geq m, \end{cases}$$

dalsze operacje punktowe


Inne metody lokalnej poprawy kontrastu

- Wyrównywanie wariancji (zmienności) – liczona jest statystyczna wariancja w określonym kontekście piksela w relacji do całkowitej wariancji obrazu, po czym korygowana jest wartość pikseli, by wyrównać wariancję



- Lokalna normalizacja (w otoczeniu piksela szacowana jest średnia i wariancja)

$$f_{LN} = \frac{f - \bar{f}}{(\bar{f}^2 - (\bar{f})^2)^{0.5}} \quad \bar{f}^2 = \frac{\sum C_f (f - \bar{f})^2}{|C_f|}$$





```

epsilon=1e-1;
halfsize1=ceil(-norminv(epsilon/2,0,sigma1));
size1=2*halfsize1+1;
halfsize2=ceil(-norminv(epsilon/2,0,sigma2));
size2=2*halfsize2+1;
gaussian1=fspecial('gaussian',size1,sigma1);
gaussian2=fspecial('gaussian',size2,sigma2);
num=IM-imfilter(IM,gaussian1);
den=sqrt(imfilter(num.^2,gaussian2));
ln=num./den;
    
```

Medical Image Analysis 10 (2006) 247-258
 A computer-aided diagnosis system for detection of lung nodules
 in chest radiographs with an evaluation on a public database

Arnold M.R. Schilham *, Bram van Ginneken, Marco Loog












Przekształcenia histogramowe

METODY I EFEKTY


Operacje histogramowe

- Rozciąganie histogramu


$$\bar{f}(k,l) = \frac{f(k,l) - \min_f\{f(k,l)\}}{\max_f\{f(k,l)\} - \min_f\{f(k,l)\}} \cdot a_{M-1}$$




Wydobywanie informacji (przekształcenia histogramu)




Metody korekcji histogramu



Histogram obrazu źródłowego –
informacja niewidoczna





Rozciąganie histogramu





Wyrównanie histogramu

Uwydatnienie (wydobycie) zmian



oryginał




po rozciągnięciu histogramu




po lokalnie sterowanej binaryzacji histogramu







(a)




(b)



(c)



(d)




(e)

Figure 5.9 Histogram modification (each representation of the image is shown with its histogram, and the cumulative histogram in red):
(a) original;
(b) linear equalization;
(c) exponential function (bright emphasis);
(d) power-law function (ends emphasis);
(e) error-curve function (center emphasis).


Uwydatnianie guzków (korekcja histogramu)



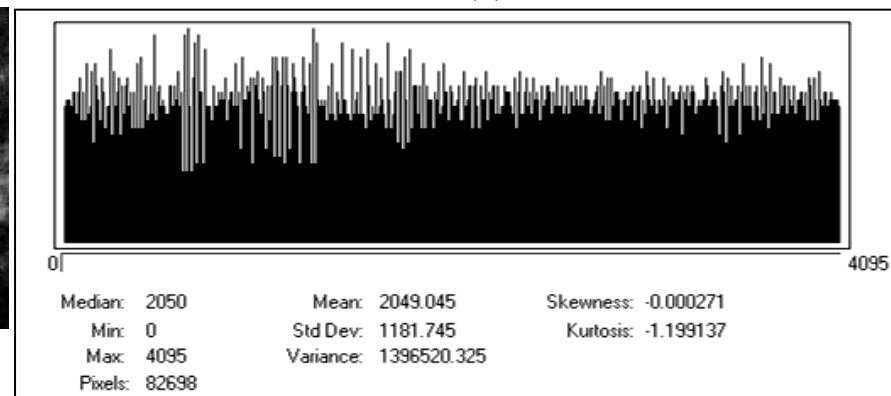
(a)



(b)




(c)



(d)

Obraz radiologiczny guza spikularnego. (a) Obraz oryginalny; (b) Histogram obrazu (a); (c) Obraz po wyrównaniu histogramu; (d) Histogram ulepszanego obrazu (c).


Lokalne wyrównanie histogramu



oryginał


globalne wyrównanie
histogramu

lokalne wyrównanie
histogramu



lokalne wyrównanie histogramu z
klasyfikacją - zmieniamy tylko
ciemne obszary nie ruszając
jaśniejszych

Korekcja histogramu –cd.




oryginał



rozciąganie histogramu



wyrównanie histogramu



lokalne rozciąganie histogramu

lokalne rozciąganie histogramu:

oryginał



*mniejszy kontekst
(21 pikseli)*

*wiekszy kontekst
(177 pikseli)*

Filtry lokalne

METODY I EFEKTY


Filtracja (kontekstowa, splotowa)

- Metoda splotu w dziedzinie obrazu

$$\tilde{f}(x, y) = \sum_i \sum_j h(i, j) f(x - i, y - j)$$

filtr

obraz



- Odpowiednik: metoda mnożenia w dziedzinie częstotliwości (transformacja Fouriera)

- selekcja widma w następującym schemacie (oddziaływanie filtru na sygnał): transformacja prosta sygnału - mnożenie przez częstotliwościowe widmo filtru - transformacja odwrotna

oryginał



f. różnicowe



f. Prewitta



f. Sobela

f. Sobela z
diag.

f. Kirscha



Efekty filtracji splotowej

Rozkłady krawędzi o różnej
kontrastowości, kierunkowości,
szczegółowości ...

Liniowa filtracja obrazów z wykorzystaniem
metody splotu (w 1D i 2D)

$$f * h(k) = \sum_n f(k - n)h_n$$

$$g(k, l) = f * h(k, l) = \sum_{(m, n) \in W_h} f(k - m, l - n)h_{m, n}$$

Operacje splotowe/kontekstowe - wykrywanie krawędzi pionowych i poziomych za pomocą lokalnych filtrów HP

Filtry krawędziowe - często uzupełnione operacją progowania (modułów) celem wykrycia krawędzi



◆ Operatory standardowe

$$\Delta f_x = \begin{bmatrix} 0 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \Delta f_y = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & -1 & 0 \end{bmatrix}$$

◆ Operatory Robertsza

$$\Delta f_x = \begin{bmatrix} 0 & 0 & -1 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \Delta f_y = \begin{bmatrix} 0 & -1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}$$

Przykładowy filtr wielokierunkowy (z kontrolą gradientu)

$$\begin{bmatrix} -1 & -2 & -1 \\ -2 & 12 & -2 \\ -1 & -2 & -1 \end{bmatrix}$$


◆ Operatory Prewitta

$$\Delta f_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad \Delta f_y = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$$

efekt f. Robertsza

◆ Operatory Sobela

$$\Delta f_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad \Delta f_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$



Filtry krawędziowe diagonalne i efekty

- diagonalne Robertsa


$$h_{m,n}^{(r)} = \begin{bmatrix} 0 & 0 & -1 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \text{oraz} \quad h_{m,n}^{(c)} = \begin{bmatrix} -1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

- diagonalne Sobela


$$h_{m,n}^{(d1)} = \begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix} \quad \text{oraz} \quad h_{m,n}^{(d2)} = \begin{bmatrix} -2 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 2 \end{bmatrix} \quad \text{przy } \rho = 1/4$$

- diagonalne linii


$$h_{m,n}^{(d1)} = \begin{bmatrix} 0 & 1 & -1 \\ 0 & -1 & 1 \\ 0 & 0 & 0 \end{bmatrix} \quad \text{oraz} \quad h_{m,n}^{(d2)} = \begin{bmatrix} -1 & 1 & 0 \\ 1 & -1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$



Efekty działania gradientu Sobela 0 stopni



Efekty działania gradientu Sobela 45 stopni



Oryginał

Roberts



Obrazy gradientowe




Sobel

Prewitt



Wyznaczanie krawędzi kierunkowych zestawem filtrów Kirscha


$$\begin{aligned} h_{m,n}^{(k1)} &= \begin{bmatrix} 5 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & -3 & -3 \end{bmatrix}, h_{m,n}^{(k2)} = \begin{bmatrix} -3 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & 5 & -3 \end{bmatrix}, h_{m,n}^{(k3)} = \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & -3 \\ 5 & 5 & 5 \end{bmatrix} \\ h_{m,n}^{(k3)} &= \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{bmatrix}, h_{m,n}^{(k5)} = \begin{bmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & 5 \end{bmatrix}, h_{m,n}^{(k6)} = \begin{bmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -3 \end{bmatrix} \\ h_{m,n}^{(k7)} &= \begin{bmatrix} 5 & 5 & 5 \\ -3 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix}, h_{m,n}^{(k8)} = \begin{bmatrix} 5 & 5 & -3 \\ 5 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix} \end{aligned} \quad \text{wszystkie przy } \rho = 1/15$$



oryginał

oryginał+szum


Problem szumów wzmacnianych przez gradient



Derivative in the horizontal direction

gradient




odszumianie plus gradient



With smoothing

Metoda: odszumić i potem gradientować

Użyteczne: odszumić f. gaussowskim, potem gradientować (inaczej przetwarzać zgradientowanym filtrem gaussowskim)




gradient po x


Problem: słabe krawędzie!

Proste wyjaśnienie sygnałowe


Natura
sygnału
wejściowego
Gradientowy
operator różnicowy




Efekt przetwarzania
(odszumienie plus
gradient różnicowy –
wybrany fragment)



Gaussowski operator
gradientowy




'Gładzszy' efekt
przetwarzania filtrem
pochodnej Gaussa




Problem: rozmyte krawędzie, chociaż dobre odszumianie




testowy obraz z krawędzią




dokładne położenie krawędzi



testowy obraz zaszumiony




efekt filtracji gradientowej



efekt wygładzonej filtracji gradientowej – redukcja szumu, ale rozmycie krawędzi

Efakty: przykład poprawy percepcji guz spikularnego



Operatory kontrastowe o różnej intensywności wzmacniają szczegóły

Filtry laplasjanowe do detekcji krawędzi

- Laplasjan (suma drugich pochodnych)

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


- Estymacja laplasjanu na podstawie różnicowych przybliżeń drugiej pochodnej w ortogonalnych kierunkach kartezjańskiego układu współrzędnych obrazu

$$l_{m,n} = \begin{bmatrix} 0 & 0 & 0 \\ -1 & 2 & -1 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & -1 & 0 \\ 0 & 2 & 0 \\ 0 & -1 & 0 \end{bmatrix} = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

— funkcja
— gradient
- - - laplasjan
- - - laplasjan odwrócony i wzmocniony



- Operatory (filtry) Laplace'a stosowane do detekcji krawędzi

$$l_{m,n} = \begin{bmatrix} -1 & 0 & -1 \\ 0 & 4 & 0 \\ -1 & 0 & -1 \end{bmatrix}, \quad l_{m,n} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$
$$l_{m,n} = \begin{bmatrix} -2 & 1 & -2 \\ 1 & 4 & 1 \\ -2 & 1 & -2 \end{bmatrix}, \quad l_{m,n} = \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix}$$




Efekty f. laplasjanowej


$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$




Dalsze efekty wyostrzania (dodawanie laplasjanu do obrazu)



oryginał




po f. laplasjanowej



suma (unormowana)

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

f. wyostrzająca



Wyostrowanie – filtracja splotowa do wzmocnienia krawędzi

- Filtry na bazie laplasjanów

$$h_{m,n} = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad h_{m,n} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

$$h_{m,n} = \begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & -2 & -1 & 0 \\ -1 & -2 & 17 & -2 & -1 \\ 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$$

- Unsharp masking (nieostre maskowanie)



$$f_{kraw}(i, j) = f - f_{mask}(i, j) = f - [f * h](i, j) \quad h_{m,n} = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$

$$g(i, j) = f + \alpha \cdot [f * g](i, j) \quad g_{m,n} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$


g-bezpośredni filtr gradientowy



Filtr LoG (Laplacian of Gaussian)



$$LoG(k, l) = f * l * h(k, l) = f * lh(k, l)$$



sigma = 2

1	1	2	2	2	2	2	1	1
1	2	2	1	1	1	2	2	1
2	2	0	-2	-3	-2	0	2	2
2	1	-2	-6	-8	-6	-2	1	2
2	1	-3	-8	-10	-8	-3	1	2
2	1	-2	-6	-8	-6	-2	1	2
2	2	0	-2	-3	-2	0	2	2
1	2	2	1	1	1	2	2	1
1	1	2	2	2	2	2	1	1


sigma = 1

0	0	0	0	0	0	0	0	0
0	0	1	4	6	4	1	0	0
0	1	9	20	22	20	9	1	0
0	4	20	0	-48	0	20	4	0
0	6	22	-48	-159	-48	22	6	0
0	4	20	0	-48	0	20	4	0
0	1	9	20	22	20	9	1	0
0	0	1	4	6	4	1	0	0
0	0	0	0	0	0	0	0	0

sigma = 1,4

0	0	1	2	2	2	1	0	0
0	2	4	5	5	5	4	2	0
1	4	6	3	0	3	6	4	1
2	5	3	-12	-24	-12	3	5	2
2	5	0	-24	-41	-24	0	5	2
2	5	3	-12	-24	-12	3	5	2
1	4	6	3	0	3	6	4	1
0	2	4	5	5	5	4	2	0
0	0	1	2	2	2	1	0	0

$$\begin{aligned}
 LoG &= \nabla^2 G_\sigma(x, y) = \frac{\partial^2}{\partial x^2} G_\sigma(x, y) + \frac{\partial^2}{\partial y^2} G_\sigma(x, y) = \\
 &= \frac{x^2 - \sigma^2}{\sqrt{2\pi} \sigma^5} e\left(-\frac{x^2+y^2}{2\sigma^2}\right) + \frac{y^2 - \sigma^2}{\sqrt{2\pi} \sigma^5} e\left(-\frac{x^2+y^2}{2\sigma^2}\right) = \\
 &= \frac{x^2 + y^2 - 2\sigma^2}{\sqrt{2\pi} \sigma^5} e\left(-\frac{x^2+y^2}{2\sigma^2}\right)
 \end{aligned}$$



Jednowymiarowa postać ciągłej odpowiedzi impulsowej filtru LoG, zależna od malejącej wartości odchylenia standardowego σ .

Przykładowe postacie filtrów LoG

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

← zwykłe filtry laplasjanowe →

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

LoG

$$lh_{m,n} = \begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & -2 & -1 & 0 \\ -1 & -2 & 16 & -2 & -1 \\ 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$$

$$lh_{m,n} = \begin{bmatrix} 0 & 0 & -1 & -2 & -2 & -2 & -1 & 0 & 0 \\ 0 & -2 & -3 & -5 & -5 & -5 & -3 & -2 & 0 \\ -1 & -3 & -5 & -3 & 0 & -3 & -5 & -3 & -1 \\ -2 & -5 & -3 & 12 & 23 & 12 & -3 & -5 & -2 \\ -2 & -5 & 0 & 23 & 40 & 23 & 0 & -5 & -2 \\ -2 & -5 & -3 & 12 & 23 & 12 & -3 & -5 & -2 \\ -1 & -3 & -5 & -3 & 0 & -3 & -5 & -3 & -1 \\ 0 & -2 & -3 & -5 & -5 & -5 & -3 & -2 & 0 \\ 0 & 0 & -1 & -2 & -2 & -2 & -1 & 0 & 0 \end{bmatrix}$$



Efekty splotowej filtracji służącej detekcji krawędzi (laplasjan w akcji!)

Adaptacje zależne od specyfiki problemu

FILTRY INTELIGENTNE (ALGORYTMY KOMBINOWANE)

Detektor krawędzi Cannego – esencja metod gradientowych

- **Odszumianie** za pomocą filtru gaussowskiego zwykle w postaci jak niżej (przy odch. standardowym równym 1.4)

$$\mathbf{B} = \frac{1}{159} \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix}$$

- **Ekstrakcja krawędzi** za pomocą filtrów gradientowych (zwykle Robertsa, Prewitta lub Sobela) z ustaleniem modułu gradientu i kąta (w zakresie wartości 0, 45, 90 i 135 stopni)
 - **Lokalizacja krawędzi** poprzez ustalenie kluczowych punktów krawędziowych – wyznaczanie jednopikselowych punktów krawędziowych (o maksymalnym module gradientu w dominującym spośród czterech rozważanych kierunków) – uwiarygodnienie **cienkich zarysów** krawędzi
 - **Ukształtowanie krawędzi** poprzez progowanie z histerezą celem usunięcia nieistotnych punktów krawędziowych poniżej dolnego progu oraz uzupełnienia krawędzi nieciągłych (w zakresie histerezy pomiędzy dolnym i górnym progiem):
 - jeśli w otoczeniu 3x3 jest piksel powyżej górnego progu
 - jeśli w otoczeniu 3x3 jest piksel w zakresie histerezy i w otoczeniu 5x5 jest piksel powyżej górnego progu
 - Parametry filtrów i stosownych reguł można dostosować do problemu
-

Problem punktów krawędziowych

jeśli w otoczeniu 3x3 jest
piksel powyżej górnego progu

0	0	0	0	1	1	1	3
0	0	0	1	2	1	3	1
0	0	2	1	2	1	1	0
0	1	3	2	1	1	0	0
0	3	2	1	0	0	1	0
2	3	2	0	0	1	0	1
2	3	2	0	1	0	2	1

0	0	0	0	1	1	1	3
0	0	0	1	2	1	3	1
0	0	2	1	2	1	1	0
0	1	3	2	1	1	0	0
0	3	2	1	0	0	1	3
2	3	2	0	0	1	0	1
2	3	2	0	1	0	2	1

nieciągłość krawędzi

jeśli w otoczeniu 3x3 jest piksel w zakresie
histerezy i w otoczeniu 5x5 jest piksel powyżej
górnego progu

An Improved Canny Edge Detection Algorithm

Weibin Rong, Zhanjing Li, Wei Zhang and Lining Sun
State Key Laboratory of Robotics and System
Harbin Institute of Technology
Harbin, Heilongjiang Province, China

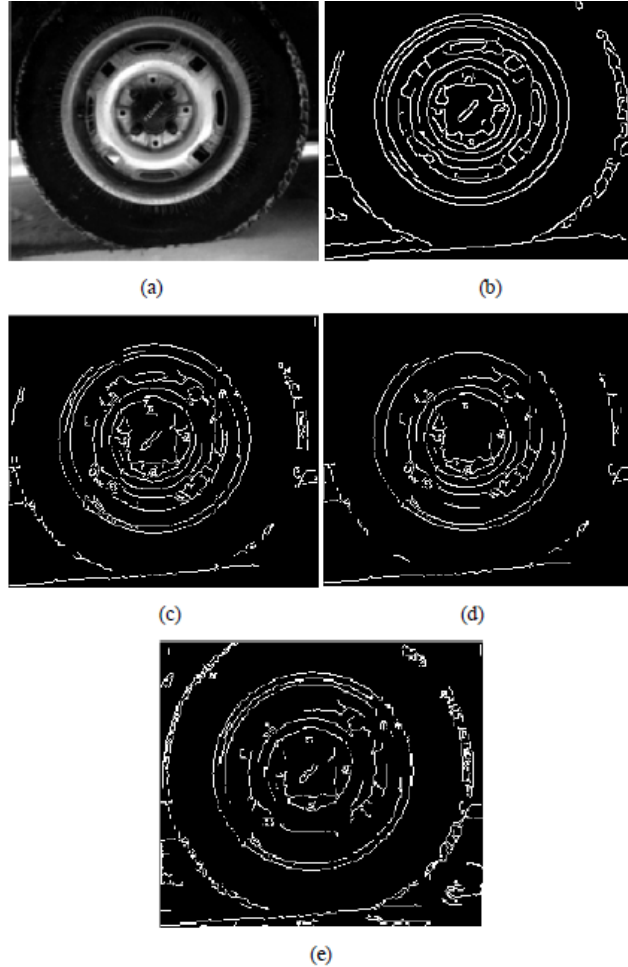



Fig.5. Experiments for *tire* image:(a)*tire* image,(b) traditional method,(c) and (d) are obtained by method for images with less information, the former $k=1.2$,and the latter $k=1.6$,(e)the improved Canny algorithm for images with rich edge information, 21×21 neighbouring area, $k=1.2$

Przykładowe efekty CED



(a) *liftingbody* image

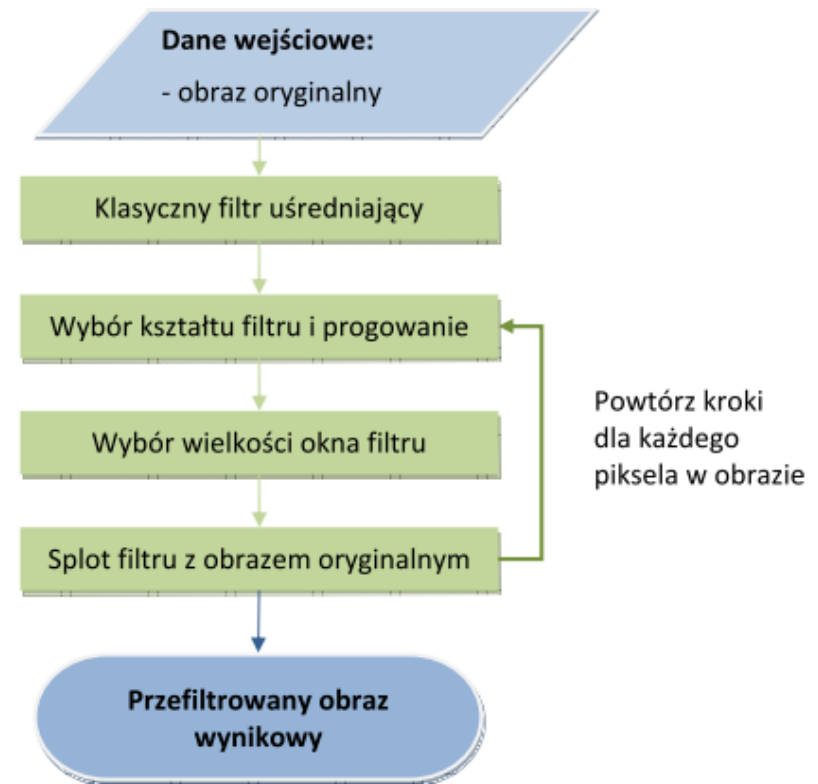
(b) Traditional method



(c)Method for images with less edges, $k=1.2$
Fig.3 Experiments for *tire* image

Filtr APAF (APMF) – adaptive partial average (median) filter

- Początkowo dla danego piksela $I(i,j)$ przyporządkowujemy okno o maksymalnej wielkości: $W_{\max} \times W_{\max}$
- Dokonujemy operacji progowania **z progiem T**, tworząc binarną maskę A: 1 dla pikseli o jasności różnej od piksela centralnego nie więcej niż wartość T, natomiast 0 - w p.p.
- Mając maskę A, dla każdej wielkości filtru $W = \{3, 5, \dots, W_{\max}\}$ obliczamy P_0 – procent punktów o wartości 0 znajdujących się na obwodzie okna
- Wybieramy okno o takiej wielkości W, aby P_0 było jak najbliższe P, lecz mniejsze od P
- Przetworzony obraz otrzymujemy przypisując pikselowi w centrum okna $W \times W$ wartość średnią (medianę) wszystkich pikseli znajdujących się w oknie $W \times W$, którym odpowiadała wartość 1 w binarnej masce A
- Kroki te powtarzamy dla każdego piksela obrazu




Działanie i efekty APMF

83	82	72	65	75	73	72	62	44
82	83	79	75	66	64	67	68	43
73	67	67	53	53	34	45	44	54
62	69	83	77	56	54	52	47	53
71	62	68	59	55	51	49	59	32
88	43	46	48	64	62	48	62	31
90	67	64	55	53	55	46	44	45
67	66	52	50	46	48	42	48	49
68	44	48	47	42	49	71	63	81

(a)

0	0	0	1	0	0	0	1	0
0	0	0	0	0	1	0	0	0
0	0	0	1	1	0	1	0	1
1	0	0	0	1	1	1	1	1
0	1	0	1	1	1	1	1	0
0	0	1	1	1	1	1	1	0
0	0	1	1	1	1	1	0	1
0	0	1	1	1	1	0	1	1
0	0	1	1	0	1	0	1	0

(b)



(c)


najbliższe α , lecz mniejsze od α

83	79	75	66	64	67	68
67	67	53	53	34	45	44
69	83	77	56	54	52	47
62	68	59	55	51	49	59
43	46	48	64	62	48	62
67	64	55	53	55	46	44
66	52	50	46	48	42	48



(d)

Fig.1 An example corresponding to each step of APMF procedure. (a) A wind Assigned mask image from (a) in case of $T=10$ in Step 3. (c) Calculation of the at $W=[3, 5, 7, 9]$ in Step 4. When $P=60\%$, $W=7$ are determined as actual obtained from pixel values (in dark gray pixels) corresponding with mask v replaces the center pixel value $I(i_c, j_c)=55$ changes to $I(i_c, j_c)=53$.

$$W_{\max} = 13, \alpha = 70\%,$$



Efekty APMF



Original

$T=0$

$T=1$

$T=2$



$T=3$

$T=4$


$T=5$

$T=6$

zwiększamy
próg T

Filtr IRIS (filtr detekcji zaokrąglone wypukłe regiony - guzy)

- Liczy stopień zbieżności wektorów gradientowych w sąsiedztwie danego piksela
- Stopień zbieżności zależy od rozkładu orientacji wektorów gradientów
- Nośnik filtru (rozmiar i kształt) dobieramy tak, by taki stopień zbieżności był maksymalny (zbiegają do centrum)
- **Wykrywa (wydobywa) zaokrąglone regiony wypukłe i zbiegające się struktury liniowe, tłumi obiekty wydłużone**




Generalized iris filter

indeks zbieżności na podstawie wektora gradientu g :

$$c(x', y') = f(g|x', y')$$

uproszczona postać indeksu zbieżności:

$$f(g|x', y') = \begin{cases} \cos \theta, & |g| \neq 0, \\ 0, & |g| = 0, \end{cases}$$



Simplified iris filter


odpowiedź filtru:

$$C(x, y) = \frac{1}{N} \sum_{i=0}^{N-1} C_i(x, y)$$


gdzie

$$C_i(x, y) = \max_{Q_i} \frac{\int_P^{Q_i} \cos \theta dl}{PQ_i}$$

Przykład - detekcja symptomów raka sutka





Badanie z roku 1996, diagnoza: brak zmian



Badanie tej samej pacjentki z roku 1998, stwierdzona obecność nowotworu

Przykład: ulepszanie badań bronchoskopowych



Skala ocen: -3 ... 3

Obserwatorzy	Metoda	MSU SS	WHE	CL1	CL2	CL3	WA1	WA2	WA3
Lekarze	Średnia ocen	1.94	-1.81	0.16	-1.04	-1.59	0.66	1.44	1.41
	Odch. Std.	0.08	0.44	0.66	0.05	0.47	0.04	0.08	0.22
Inżynierowie	Średnia ocen	-0.10	-0.44	1.58	-0.42	-1.33	1.40	1.52	1.47
	Odch. Std.	1.96	1.42	0.54	1.81	1.76	0.55	0.99	1.46