



Przykłady dyskretnych
aproteksymacji odpowiedzi
impulsowej filtru Gaussa
 $h(m, n)$ dla $k=5$

filtr separowalny:



$$\sigma^2 = 1$$

filtr nieseparowalny:

		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	
16						

$$\sigma^2 = 2$$

Krok 2

Wyznaczenie, w każdym punkcie obrazu, wartości gradientu jasności

$$g(m, n) = \sqrt{f_x^2(m, n) + f_y^2(m, n)}$$

oraz jego orientacji

$$\theta(m, n) = \arctg \left(\frac{f_y(m, n)}{f_x(m, n)} \right)$$

Do aproteksymacji pochodnych kierunkowych $f_x(m, n)$ i $f_y(m, n)$ stosuje się zazwyczaj metodę Roberta, Prewittha lub Sobela.

Krok 3


Utworzenie mapy "stałych"
punktów krawędziowych \mathcal{K}_{min}
poprzez progowanie gradientu
z danym progiem \mathcal{g}_{min}

$$g(m, n) \gg \mathcal{g}_{min} \Rightarrow (m, n) \in \mathcal{K}_{min}$$

Krok 4

Pocieranie krańcówki poprzez usunięcie punktu „niemaksymalnych” (nonmaxima suppression)

Sprawdzamy wartość gradientu w dwóch punktach sąsiadujących z punktem badanym (m, n) , w kierunku zgodnym z orientacją gradientu (tj. wartość linii prostopadłej do krańcówki). Orientacja gradientu $\theta(m, n)$ zaakreślona jest do jednego z czterech kierunków podstawowych $(0^\circ, 45^\circ, 90^\circ, 135^\circ)$



Zachowujemy tylko te punkty, w których gradient jest większy niż w obu sąsiadnych wyżej punktach sąsiadnych.

Krok 5

Utworzenie mapy "silnych" punktow krańcówkowych K_{max} poprzez usunięcie z mapy K_{min} punktów (m, n) , dla których

$$g(m, n) \geq g_{max}$$


gdzie g_{max} , $g_{min} > g_{min}$, oznacza górny próg (zazwyczaj przyjmuje się $g_{max} = 2g_{min}$)

$$K_{max} \subset K_{min}$$

Krok 6


Utworzenie wynikowej mapy punktów krańdowych Z_k poprzez zastosowania progowania z histerezą.

Do „silnych” punktów krańdowych dołączamy, w trybie sekwencyjnym i te punkty „stabe”, które znajdują się w bezpośrednim sąsiedztwie punktów „silnych”, bądź wczesniej „dołączonych” punktów „stabych”.




- o „silny” punkt krańdowy
- x „staby” punkt krańdowy

Z_{max} C Z C Z_{min}




$O(m, n)$




$O(m, n) * h(m, n)$




$g(m, n)$



$\theta(m, n)$



$O(m, n)$




$C(m, n)$



$\sigma = 3$

$g_{min} = 25$


$g_{max} = 75$



$\sigma = 3$

$g_{min} = 75$


$g_{max} = 125$



$$\sigma = 1$$

$$f_{\min} = 75$$

$$f_{\max} = 125$$



$$\sigma = 1$$

$$f_{\min} = 75$$

$$f_{\max} = 250$$

Metody wykorzystujące

Laplasjan

Laplasjanem dwuwymiarowego sygnału ciągłego $f(x, y)$ nazywamy funkcję

$$\nabla^2 f(x, y) =$$

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

W przypadku sygnałów dyskretnych możemy się posłużyć następującymi przybliżeniami

$$f_x(m, n) = f(m, n+1) - f(m, n)$$

roznica „w przed”

$$f_{xx}(m, n) = f_x(m, n) - f_x(m, n-1)$$

roznica „w tył”

Stąd

$$f_{xx}(m, n) = f(m, n+1) - 2f(m, n) + f(m, n-1)$$

Podobnie

$$f_{yy}(m, n) = f(m+1, n) - 2f(m, n) + f(m-1, n)$$

a zatem

$$L(m, n) = f_{xx}(m, n) + f_{yy}(m, n) = f(m+1, n) + f(m-1, n) + f(m, n+1) + f(m, n-1) - 4f(m, n)$$

	1	
1	-4	1
	1	

Inne stosowane operacje -
macie

1	1	1
1	-8	1
1	1	1

-1	2	-1
2	-4	2
-1	2	-1

Wytęgnięcie krawędzi

przy użyciu Laplasjenu

Sprawdzamy przejścia przez zero w kierunku x lub y funkcji $L(m, n)$

$(m_0, n_0) \in \mathcal{K}$ jeżeli :

$$L(m_0, n_0) L(m_0, n_0 + 1) \leq 0$$

lub

$$L(m_0, n_0) L(m_0 + 1, n_0) \leq 0$$

Własności

- nie ma potrzeby poierenia -
nia wykrytych krawędzi
- metoda jest bardzo uciążliwa -
lwa na lokalne zmiany
jakości a więc również
na szum

Aby obniżyć czułość detek-
tora wprowadza się do -
datkowy warunek postaci

$$G_f^2(m_0, n_0) > \delta_0^2$$

gdzie σ_f^2 oznacza próg
 (dobierany eksperymental-
 nie) zaś $\sigma_f^2(m_0, n_0)$
 jest lokalną oceną
 wariancji sygnału $f(m, n)$
 w p.

$$\sigma_f^2(m, n) = \frac{1}{(2K+1)^2} \sum_{i=0-K}^K \sum_{j=0-K}^K$$




$$[f(m+i, n+j) - \mu_f(m+i, n+j)]^2$$

gdzie


$$\mu_f(m, n) =$$

$$= \frac{1}{2K+1} \sum_{i=0-K}^K \sum_{j=0-K}^K f(m+i, n+j)$$


zaś K najczęściej przyjmuje
 wartości 1, 2 lub 3




Porównanie czterech
metod wykrywania
krawędzi (obrazy
bez szumu)




(a) Sobel



(b) Kirsch



(c) Stochastic 5 x 5



(d) Laplacian

Wyznaczanie linii na mapie krajoznazki

metoda szablona

-1	-1	-1
2	2	2
-1	-1	-1

-1	-1	2
-1	2	-1
2	-1	-1

-1	2	-1
-1	2	-1
-1	2	-1

2	-1	-1
-1	2	-1
-1	-1	2

transformacja Hougha

maksymalna liczba linii, które można przeprowadzić przez dane dwa piksele należąca do zbioru krajoznazki wynosi $N_x \cdot (N_x - 1) / 2$

Obserwacje

każdej prostej o równaniu

$$y = ax + b$$

odpowiada w przestrzeni parametrów punkt (a, b)

algorytm wyszukiwania linii prostych:

1. dyskretyzujemy par-

metry a i b

$a : a_1 < a_2 < \dots < a_R$

$b : b_1 < b_2 < \dots < b_L$

2. tworzymy $K \times L$ -wymia-

rową macierz wykreśl-

$H(a, b)$ i nadajemy

wszystkim elementom wartości zerowe

3. dla wszystkich pikseli

$(m, n) \in \mathcal{I}$ oraz
 wszystkich zdyktowanych wartości a_i
 zważanych wartości a_i
 wyznaczamy odpowiednie wartości b_j :

$$b_j = (m - a_i n) a$$

a następnie zwiększamy wartość stosownego elementu macierzy $H(a, b) + 1$:

$$H(a_i, b_j) := H(a_i, b_j) + 1$$

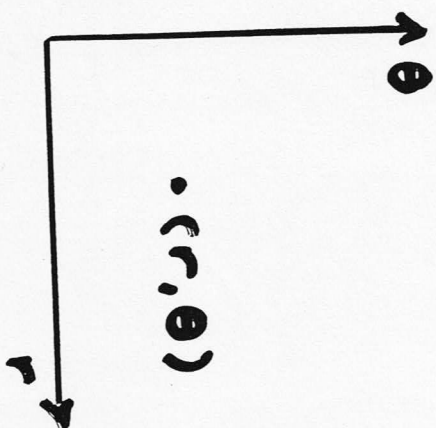

4. wyszukujemy wszystkie pary (a_i, b_j) , które spełniają warunki

$$H(a_i, b_j) > H_{\min}$$

Wada

W przypadku pionowych linii $a = \infty$ co oznacza, że przyjęta parametryzacja prostej nie jest wygodna z punktu widzenia kwantyzacji

Aby ułatwić kwantyzację parametrów stosuje się współrzędne biegunowe



$$r = x \cos \theta + y \sin \theta$$

Obserwacje

- wszystkim liniom prostym przechodzonym przez punkt (x_0, y_0) na płaszczyźnie xy odpowiada na płaszczyźnie $r\theta$ sinusoida o równaniu

$$r = x_0 \cos \theta + y_0 \sin \theta$$

- punktem współliniowym na płaszczyźnie xy odpowiada precyzyjnie sinusoida na płaszczyźnie $r\theta$

algorytm wyszukiwania linii prostych:

1. dyskretyzujemy parametry r i θ

$$r : r_1 < r_2 < \dots < r_k$$

$$\theta : \theta_1 < \theta_2 < \dots < \theta_L$$

$$-R_{\max} \leq r \leq R_{\max}$$

$$-\frac{\pi}{2} \leq \theta < \frac{\pi}{2}$$

gdzie

$$R_{\max} = \sqrt{M^2 + N^2}$$

2. tworzymy $K \times L$ -wymiarową macierz wykrywcę $H(r, \theta)$ i nadajemy wszystkim elementom wartości zerowe

3. dla wszystkich pikseli

$(m, n) \in \mathcal{K}$ oraz

wszystkich zdyktowanych -
zowanych wartości θ_j
wyznaczamy odpowiednie
wartości r_i


$$r_i = (n \cos \theta_j + m \sin \theta_j) a$$

a następnie zwiększamy
wartość stosownego ele-
mentu macierzy $H(r, \theta)$
o 1

$$H(r_i, \theta_j) := H(r_i, \theta_j) + 1$$

4. wyzujemy wszystkie
pary (r_i, θ_j) , które
spełniają warunki

$$H(r_i, \theta_j) > H_{min}$$



Zastosowanie transfor-
maty Hougha

Złożoność obliczeniowa transformacji Hougha

$$O(N_x \cdot N_a)$$

gdzie N_x oznacza liczbę pikseli tworzących zbiór J_k , zaś N_a jest przyjętą liczbą poziomów kwantyzacji parametru a lub θ

W przypadku, gdy detektor krańczi dostarcza zarówno informację o położeniu pikseli tworzących zbiór J_k jak o nachyleniu krańczi w każdym punkcie, złożoność obliczeniową można obniżyć do

$$O(N_x)$$

Uogólnienia

Metoda pozwala na wykrywanie dowolnych krzywych opisanych równaniem

$$f(x, y; \alpha) = 0$$

gdzie α jest wektorem parametryśu, np.

$$(x-a)^2 + (y-b)^2 = r^2$$

$$H(a, b, r)$$

$$m, n, r_i$$



$$a_j = (n - r_i \cos \theta_j) a$$


$$b_j = (n - r_i \sin \theta_j) a$$

Przekształcenia morfologiczne

morphological transformations

morfologia - nauka o budowie i kształtach roślin i zwierząt

terminologia geograficzna :




Erozja

erosion


Rozważmy dowolny obszar X na płaszczyźnie oraz tzw. element strukturalny $B(x, y)$ w kształcie koła o promieniu r i środku w punkcie (x, y)

Erozja obszaru X przy użyciu elementu B nazywamy zbiór środków wszystkich kół o promieniu r , które zawarte są w obszarze X

$$\{(x, y) : B(x, y) \subset X\}$$



otwarcie




zamknięcie



- Usunięcie szumu impulsowego typu "pieprz z solą" (a)
- (b) otwarcie obrazu ele - mentem 2×2
- (c) otwarcie + zamknięcie obrazu
- (d) wynik filtracji media - nowej z oknem 3×3

Erozja

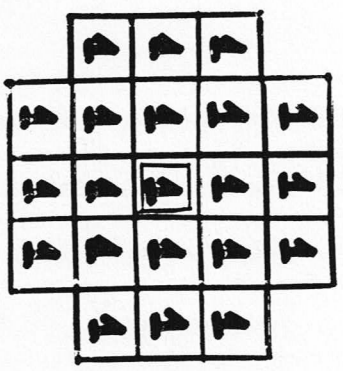




Własności:

- usuwa drobne szczegóły (wyspy, półwyspy) oraz wykadra brzeg obszaru
- dzieli obszar na podobszary (jeżeli przesmyki łączące poszczególne podobszary są wystarczająco wąskie)
- zmniejsza powierzchnię badanego obszaru

Erozja obrazów binarnych

najczęściej stosowane elementy strukturalne $B(m, n)$



= element środkowy

"Programowanie" elementu strukturalnego w oparciu o szablon o standardowym kształcie

X	1	X
1	1	1
X	1	X


\boxed{X} - element neutralny (nie brany pod uwagę podczas analizy)

$B^*(m, n)$ - element

Strukturalny otrzymany w wyniku zastosowania symetrii środkowej względem punktu (m, n) do elementu $B(m, n)$

$$E_{\theta}(X) = X \ominus B \triangleq \{ (m, n) : B(m, n) \subset X \}$$

wektory translacji związane z elementem strukturalnym



$$B = \{ (0, 0), (0, 1), (-1, 0), (-1, +1) \}$$

X_b - obszar otrzymany w wyniku translacji $X \ominus$ wektor b

$$E_B(X) = \bigcap_{b \in B^*} X_b \subset X$$

gdzie B^* oznacza zbiór wektorów translacji związanych z elementem strukturalnym $B^*(m, n)$

zastępowanie - przetwarzanie niemożliwe


Dylatacja

dilation

Dylatacja obszaru X przy użyciu elementu B nazywamy zbiór środków wszystkich kół o promieniu r , które mają przynajmniej jeden punkt wspólny z X .

$$\{ (x, y) : B(x, y) \cap X \neq \emptyset \}$$

Dylatacja



własności:

- Zastępuje małe jeziora i wąskie zatoki
- Skłaja obszary położone blisko siebie
- Zwiększa powierzchnię badanego obszaru

Dylatacja obrazów binarnych

$$D_B(X) = X \oplus B \triangleq$$

$$= \{ (m,n) : B(m,n) \cap X \neq \emptyset \}$$

$$= \bigcup_{b \in B} X_b \supset X$$

Uwaga

Erozja i dylatacja są przekształceniami dualnymi.

$$X \ominus B = \overline{\overline{(X \oplus B)}}$$

$$X \oplus B = \overline{\overline{(X \ominus B)}}$$

gdzie $\overline{X} = \mathbb{R} - X$ oznacza dopełnienie zbioru (obszary n) X .

Własności matematyczne erozji i dylatacji

rozdzielczość

$$X \ominus (B_1 \cup B_2) =$$

$$= (X \ominus B_1) \cap (X \ominus B_2)$$

$$X \oplus (B_1 \cup B_2) =$$

$$= (X \oplus B_1) \cup (X \oplus B_2)$$

superpozycja

$$(X \ominus B_1) \ominus B_2 =$$

$$= X \ominus (B_1 \oplus B_2)$$

$$(X \oplus B_1) \oplus B_2 =$$

$$= X \oplus (B_1 \oplus B_2)$$

Złożone elementy strukturalne można tworzyć na drodze superpozycji elementów prostych

$$B = B_1 \oplus B_2 \dots \oplus B_n$$

$$X \ominus B =$$

$$= (\dots ((X \ominus B_1) \ominus B_2) \dots \ominus B_n)$$

$$X \oplus B =$$

$$= (\dots ((X \oplus B_1) \oplus B_2) \dots \oplus B_n)$$



$$\dots \oplus \dots = ?$$

Otwarcie i zamknięcie

otwarcie = erozja + dyfuzja

$$O_B(X) = X \circ B$$

$$= (X \ominus B) \oplus B$$

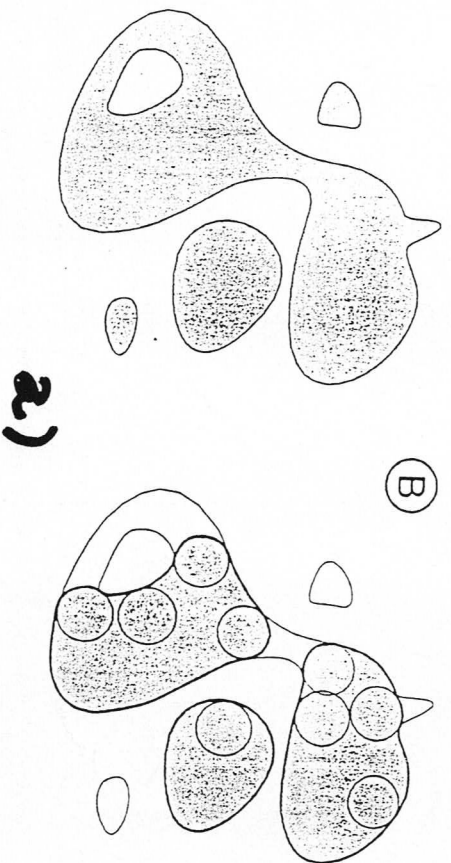
opening

zamknięcie = dyfuzja + erozja


$$C_B(X) = X \bullet B$$

$$= (X \oplus B) \ominus B$$

closing



a)



b)


Otwarcie (a) oraz
zamknięcie (b) figur
za pomocą kota

Właściwości:


- Otwarcie usuwa drobne szczegóły (wyspy, półwyspy) oraz „otwiera” niektóre jeziora tworząc z nich zatoki; rozdziela obszary położone wąskimi przesmykami.
- Zamknięcie wypełnia zatoki oraz małe jeziora; skleja obszary położone blisko siebie
- Oba przekształcenia nie zmieniają kształtu ani rozmiarów dużych obszarów o gładkim brzegu




EROSION




DILATION



OPENING



CLOSING



$$E_B(X) \subset O_B(X) \subset X$$

$$X \subset C_B(X) \subset D_B(X)$$

Uwaga 1

Wielokrotne stosowanie operacji otwarcia bądź zamknięcia nie ma sensu gdyż

$$O_B(O_B(X)) = O_B(X)$$

$$C_B(C_B(X)) = C_B(X)$$

Uwaga 2

$$O_B(C_B(X)) \neq C_B(O_B(X))$$

Przekształcenie trafie-
nie trafi

hit - miss

$$X \odot B = \{ (m, n) : \dots \}$$

$$B(m, n) \subset X \}$$

wykręcanie izolowanych punktów

0	0	0
0	1	0
0	0	0

wykręcanie narożników



x	1	0
1	1	0
0	0	0

wykręcanie punktów
koncowych

x	x	x
0	1	0
0	0	0

Aby wykręcić elementy o
dowolnej orientacji stosuje
się rotację szablona

- $B^1 = B$
- $B^2 = \text{rot} \{ B^1 \}$
- $B^3 = \text{rot} \{ B^2 \}$
- $B^4 = \text{rot} \{ B^3 \}$








Szkieletyzacja

Skeleton


Szkielelet figury - zbiór środków tzw. maksymalnych okręgów wpisanych w figurę

maksymalny okrąg wpisany w figurę - każdy okrąg, który styka się z brzegiem figury w co najmniej dwóch punktach lecz nie przecina jego brzegu



Uwaga

Na kształt szkieletu silny wpływ mają wszystkie nierówności brzegu badanej figury




Szkielelet morfologiczny

morphological skeleton


$$nB \hat{=} \underbrace{B \oplus B \oplus \dots \oplus B}_n$$



B



2B



3B

$$\begin{aligned}
 S_B(X) &= \\
 &= \bigcup_{n=0}^N [(X \cap B) - (X \cap B) \cap B] \\
 &= \bigcup_{n=0}^N S_n(X)
 \end{aligned}$$

gabe

$$N = \max \{ n : X \cap B \neq \emptyset \}$$

$$S_0(X) = X - [X \cap B] \cap B$$


$$S_1(X) = (X \cap B) +$$

$$- [(X \cap B) \cap B] \cap B$$


⋮

$$S_N(X) = (X \cap B) +$$


$$- [(X \cap B) \cap B] \cap B$$



Schemat blokowy algorytmu składowczy



(a)



(b)

Obraz binarny (a) oraz jego szkielek (b)

Rekonstrukcja obrazu w oparciu o jego szkielek


$$\bigcup_{n=1}^N s_n(X) \oplus nB = X \oplus nB$$

a zatem

$$X = \bigcup_{n=1}^N s_n(X) \oplus nB$$


Dekompozycja szkielekowa wykorzystywana jest do kompresji obrazów

Minimalny podzbiór zbioru $S_0(X)$ gwarantujący bezwzględny rekonstrukcyjny różniczek jest szkieletem minimalnym



Scherz algoritmu bloku rekonstrukcijski algoritmu

Inne podejście do skiele-tyzacji



element strukturalny typu L

$$X \square L \triangleq X - X \circ L$$

$$S_L(X) =$$

$$= (((\dots(X \square L^1) \square L^2) \dots \square L^N))$$

n=0							
n=1							
n=2							
n=3							

Kolejne fazy skieletyzacji i rekonstrukcji obrazu

- a) erozje $X \ominus nB$
- b) otwarcia erozji $(X \ominus nB) \circ B$
- c) podzbiory szkieletu $S_n(X)$
- d) podzbiory szkieletu po dyfuzji $S_n(X) \oplus nB$
- e) czystkowe sumy $\bigcup_{k=1}^N S_k(X)$
- f) czystkowe rekonstrukcje $\bigcup_{k=1}^N S_k(X) \oplus kB$

Przekształcenia morfologiczne dla obrazów wielokolorowych i kolorowych

Erozyja i dylatacja funkcji

$f(x)$ przy użyciu zbioru

$$B = [b_1, b_2], \quad b_1 < 0, b_2 > 0$$

$$(f \ominus B)(x) =$$


$$= \min_{b \in B} \{ f(x-b) \} \leq f(x)$$

filtr minimalny


$$(f \oplus B)(x) =$$

$$= \max_{b \in B} \{ f(x+b) \} \geq f(x)$$


filtr maksymalny



Szkieletyzacja przy użyciu
wzrastającego elementu
typu L



erozja



dylatacja

Uwaga

Złożoność obliczeniowa filtrów min/max


$$y(t) = \max \{ x(t), x(t-1), \dots, x(t-n+1) \}$$

$$y(t) =$$

$$\left[\begin{array}{ll} x(t) & \text{gdys } x(t) > y(t-1) \\ y(t-1) & \text{gdys } x(t) < y(t-1) \\ \max \{ \cdot \} & \text{gdys } x(t) < y(t-1) \\ & \text{i } x(t-n) = y(t-1) \end{array} \right.$$

Średnia liczba porównań przypadająca na jeden krok wynosi 3 i nie zależy od szerokości okna analizy n .

Erozja i dylatacja obrazów cyfrowych



Otwarcie i zamknięcie funkcji $f(x)$ przy użyciu zbioru $B = [b_1, b_2]$, $b_1 < 0$, $b_2 \gg 0$

$$(f \ominus B)(m, n) =$$

$$= \min \{ f(m-k, n-l), (k, l) \in B(m, n) \}$$

$$(f \oplus B)(m, n) =$$

$$= \max \{ f(m+k, n+l), (k, l) \in B(m, n) \}$$

$$(f \circ B)(x) =$$

$$= ((f \ominus B) \oplus B)(x) \leq f(x)$$

$$(f \bullet B)(x) =$$


$$= ((f \oplus B) \ominus B)(x) \geq f(x)$$

$$(f \ominus B)(x) \leq (f \circ B)(x)$$


$$(f \bullet B)(x) \geq (f \oplus B)(x)$$

Otwarcie i zamknięcie
obrazów wieloodcieniowych
ma podobne właściwości jak
analogiczne operacje
zdefiniowane dla obra-
zów binarnych


Podstawowa różnica -
oba przekształcenia
powodują pewne zmiany
szczegółów obrazu:
jasnych - w przypadku
zamknięcia
ciemnych - w przypadku
otwarcia



a)



b)



c)

Oryginalny obraz (a) oraz
wynik jego otwarcia (b)
i zamknięcia (c)

Detekcja krawędzi



$$\partial^- X = X - X \ominus B$$

$$\partial^+ X = X \oplus B - X$$

gradient morfologiczny
Beuchera

$$\partial^- X + \partial^+ X =$$

$$= X \oplus B - X \ominus B$$

Inne metody wykrywania
krawędzi

$$\min \{ \partial^- X, \partial^+ X \}$$

$$\max \{ \partial^- X, \partial^+ X \}$$

nie liniowy operator
Laplacela

$$\partial^+ X - \partial^- X$$

Uwaga

w przypadku obrazów wielo-
odcieniowych zarówno gra-
dient energii ∂^- jak
dylatacyjny ∂^+ może być
wyznaczony metodą dekom-
pozycji binarnej

Detekcja szczytów i dolin




top-hat transformations

wykrywanie miejsc lokalnie najjaśniejszych

$$f(x) - (f \circ B)(x) \\ + \text{binaryzacja}$$

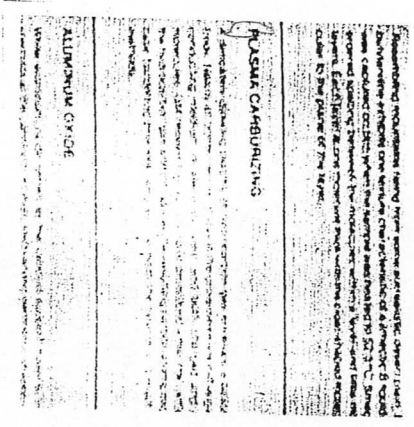

wykrywanie miejsc lokalnie najciemniejszych

$$(f \bullet B)(x) - f(x) \\ + \text{binaryzacja}$$



wykrywanie szczytów
(po lewej) i dolin
(po prawej)

POMIYER OBRETI



- Zrobila :
- ograniczona rozdzielczosc układu optycznego lub jego niewłaściwa kalibracja

- wpływ środowka, przez który przechodzi promienie świetlne np. atmosfera ziemskiej (złgicia astro-nomiczne i satelitarne) lub cieczy (złgicia mikroskopowe)

- ruch obiektu i/lub kamery podczas wywołania złgicia

$$g(x,y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} o(x,y) * h(x,y)$$

$$* h(x - \delta_1, y - \delta_2) d\delta_1 d\delta_2$$

gdzie

$$h(x,y) \geq 0$$

oznacza odpowiedzi impulsowy układu optycznego charakteryzujacy stopien rozmywania obrazu

PSF - point spread function

Przykłady funkcji PSF

Usuwanie nieostrości obrazu

$$h(x, y) = (\pi\sigma^2)^{-\frac{1}{2}} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

funkcja dobrze opisująca efekty atmosferyczne przy badaniu gwiazd

$$h(x, y) = b(x) \cdot S(y)$$

głazie

$$b(x) = \begin{cases} \frac{1}{2x_0} & \text{gdzy } |x| \leq x_0 \\ 0 & \text{gdzy } |x| > x_0 \end{cases}$$

zaś $S(\cdot)$ oznacza funkcję delta Diraca

$$g(m, n) = f(m, n) * * h(m, n) + z(m, n)$$

głazie $h(m, n)$ oznacza odpowiedź impulsowy ukła - dw opłyznogo zać $z(m, n)$ - addytywngy proces zakłócający

$$g(m, n) \xrightarrow{?} f(m, n)$$

Jest to tzw. problem rozplatu deconvolution

Metoda filtru odwrotnego

$$G(p, q) = F(p, q) \cdot H(p, q) + Z(p, q)$$

gdzie

$$X(p, q) = \mathcal{F}[x(m, n)]$$

Jeśli pominiemy obecność procesu zakłócającego możemy postąpić z oszacowaniem

$$\hat{F}(p, q) = \frac{G(p, q)}{H(p, q)}$$

$$\hat{f}(m, n) =$$

$$= \mathcal{F}^{-1}[\hat{F}(p, q)]$$

Wada

Pominięcie

$$\hat{F}(p, q) =$$

$$= F(p, q) + \frac{Z(p, q)}{H(p, q)}$$

szum jest silnie wzmacniany w punktach, w których $H(p, q) \cong 0$

Filtr pseudoodwrotny


$$H^{-1}(p, q) =$$

$$= \begin{cases} \frac{1}{H(p, q)} & \text{gdz } |H(p, q)| > \epsilon \\ 0 & \text{gdz } |H(p, q)| \leq \epsilon \end{cases}$$

Rozplot przy użyciu metody iteracyjnej

w dziedzinie częstotliwości

$$\hat{F}_{i+1}(p, q) = \hat{F}_i(p, q) + \mu [G(p, q) - \hat{F}_i(p, q)] * H(p, q)$$



Zastosowanie filtracji odwrotnej i pseudoodwrotnej

gdzie $\mu > 0$ oznacza współczynnik adaptacji który (w celu zagwarantowania zbieżności procedury) powinien spełniać ograniczenie

$$|1 - \mu H(p, q)| < 1 \quad \forall p, q$$

oszacowanie początkowe

$$\hat{F}_0(p, q) = \mu G(p, q)$$

Rozplot przy użyciu metody iteracyjnej

w dziedzinie czystości

$$\hat{F}_{i+1}(p, q) = \hat{F}_i(p, q) + \mu [G(p, q) - \hat{F}_i(p, q)] * H(p, q)$$

gdzie $\mu > 0$ oznacza współczynnik adaptacji który (w celu zagwarantowania zbieżności procedury) powinien spełniać ograniczenie

$$|1 - \mu H(p, q)| < 1 \quad \forall p, q$$

oszacowanie początkowe

$$\hat{F}_0(p, q) = \mu G(p, q)$$

Analiza zbieżności
algorytmu iteracyjnego

$$\begin{aligned} \hat{F}_0(p, q) &= \mu G(p, q) \\ \hat{F}_1(p, q) &= \hat{F}_0(p, q) + \mu [G(p, q) - \hat{F}_0(p, q)] H(p, q) \\ &\vdots \\ \hat{F}_i(p, q) &= \mu G(p, q) \cdot [1 + (1 - \mu H(p, q)) + \dots + (1 - \mu H(p, q))^i] = \end{aligned}$$

$$\begin{aligned}
 &= \mu \theta(p, q) \cdot \\
 &\quad \cdot \frac{[1 - (1 - \mu H(p, q))^{i+1}]}{1 - (1 - \mu H(p, q))} \\
 &= \frac{\theta(p, q)}{H(p, q)} [1 - (1 - \mu H(p, q))^{i+1}]
 \end{aligned}$$

ty. zbieżność ma miejsce
w przypadku gdy

$$|1 - \mu H(p, q)| < 1 \quad \forall \quad p, q$$

W dziedzinie czasu

$$\begin{aligned}
 \hat{f}_{i+1}(m, n) &= \hat{f}_i(m, n) \\
 &+ \mu [g(m, n) - \hat{f}_i(m, n) \\
 &\quad * h(m, n)]
 \end{aligned}$$

$$\hat{f}_0(m, n) = \mu g(m, n)$$

Metoda filtracji Wienera

$$g(m, n) = f(m, n) + z(m, n)$$

Zadaniem i z sygnały
 $\{f(m, n)\}$ i $\{z(m, n)\}$
 są stacjonarne, wzajemnie
 nieskorelowane i mają
 zerowe wartości oczekiwane

$$\begin{aligned}
 E[f(m, n)f(m-k, n-k)] \\
 = R_f(k, l)
 \end{aligned}$$