

Inżynieria Mechatroniczna

Wizja Komputerowa Cechy obrazu

Krzysztof Holak
Akademia Górniczo-Hutnicza w Krakowie

1

Harmonogram

- Wykład 1 : Wstęp
- Wykład 2: Segmentacja obrazu
- **Wykład 3: Cechy obrazu**
 - Cechy Geometryczne
 - Momenty i Niezmienniki Momentowe
 - Dopasowanie Wzorca – Korelacja Obrazów
 - Cechy lokalne i Deskryptory Cech
- Wykład 4: Przetwarzanie wideo

2

Analiza obrazu

Aby sklasyfikować obiekty na obrazie, najpierw należy zbudować ich reprezentację matematyczną - wyznaczyć **cechy**




Pole powierzchni = ?	Czy to jest dysk ?
Środek ciężkości = ?	Czy to jest gwiazda?
Liczba Eulera = ?	Czy to prostokąt ?
Eccentricity = ?	Czy to jest kwadrat ?
Orientacja = ?	...
...	

3

Etykietowanie

Najpierw należy określić ile obiektów jest na obrazie

Etykietowanie – przypisanie liczby naturalnej do każdego obiektu na obrazie



4

Cechy geometryczne

W Matlabie do wyznaczenia cech geometrycznych używa się funkcji regionprops
Przykłady :

Pole Powierzchni – Ile pikseli ma obiekt (jak duży jest jest)

Środek Ciężkości – centroif (pozycja obiektu na obrazie)

Prostokąt ograniczający – prostokąt opisany na obiekcie (ile miejsca zajmuje obiekt)

Liczba Eulera- Ile otworów ma obiekt

Kołowość – jest bardzo obiekt jest zbliżony do koła

Eccentricity (wydłużenie) – jak bardzo rozciągnięty obiekt jest

5

Cechy geometryczne

Przykłady w Matlabie



4x4 image with 16 tests

Index	Area	Centroid	BoundingBox	Neighborhood	MinNeighborhood	Eccentricity	Orientatio	ConvexArea	Convexity	FillFactor	FillNumber	ShapeMeasure
1	1267681.0000000000	[23.5000 145.5000 108.1250]	[127 12473]	[127 12473]	0	0	12736	1.0152	12676	1	1273617	
2	4209219.0000000000	[1165.5000 151.5000 108.1250]	[8187 126]	[8187 126]	0.0056	80.0001	1779	0.0414	4400	1	147546	
3	3710391.0000000000	[1205.5000 114.5000 108.1250]	[147 8017]	[147 8017]	0.0000	0	3712	0.0000	3712	1	683478	
4	9621052.1176	[1044.5000 171.5000 108.1250]	[105 6746]	[105 6746]	0	0	9625	0.0000	9625	1	1071760	

4x4 image with 32 tests

Index	SubArea	Extent	Perimeter	PerimeterSq	MeanPerimSq	MeanPerimSq	MeanPerimSq	MeanPerimSq	MeanPerimSq	MeanPerimSq	MeanPerimSq	MeanPerimSq
1	0.9942	0.7717	294.8888	478.9405	138.4706	127.4054	126.5000	126.5000	126.5000	126.5000	126.5000	126.5000
2	0.9442	0.9472	294.8888	478.9405	138.4706	127.4054	126.5000	126.5000	126.5000	126.5000	126.5000	126.5000
3	1	1	301.4160	310	137.2480	147.2480	147.2480	147.2480	147.2480	147.2480	147.2480	147.2480
4	1	1	304.1440	310	138.4706	147.2480	147.2480	147.2480	147.2480	147.2480	147.2480	147.2480

6

Momenty Geometryczne

Momenty

Obliczane jak w przypadku momentów geometrycznych w mechanice technicznej (wytrzymałość materiałów)

$$M_{pq} = \sum_x \sum_y x^p y^q I(x, y)$$

p, q – rząd momentu względem osi y i x


jeśli $p = 0$ i $q = 0$ – pole powierzchni

Jeżeli ($p = 0$ i $q = 1$) lub ($p = 1$ i $q = 0$) – moment statyczny – aby obliczyć środek ciężkości

Jeżeli ($p = 0$ i $q = 2$) lub ($p = 2$ i $q = 0$) – moment II. rzędu, moment bezwładności

7


Momenty Geoetryczne Zwykłe



$p = 0$
 $q = 2$

8

Momenty Geoetryczne Zwykłe



$p = 2$
 $q = 0$

9

Momenty Centralne


Momenty zwykłe **nie są niezmiennie względem** przesunięcia, obrotu i skali!
Należy liczyć momenty względem środków ciężkości obiektów!

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q I(x, y)$$

Moment Centralny **nie** zmienia się, gdy przesuwamy obiekty na obrazie


10

Momenty Centralne



11

Momenty Centralne



12

Momenty centralne znormalizowane


Znormalizuj momenty centralne, aby były niezmiennie wobec **skalowania**

$$\varphi_{pq} = \frac{\mu_{pq}}{(\mu_{00})^{1+\frac{p+q}{2}}}$$

Momenty te są niezmiennie względem **skalowania i przesunięcia** obiektów, ale **nie są** niezmiennie dla **obrotów** !


13

Momenty centralne znormalizowane



14

Momenty centralne znormalizowane



15

Momenty Hu

Siedem momentów niezmiennych względem **przesunięcia, skalowania i obrotu**

$$I_1 = \eta_{20} + \eta_{02}$$

$$I_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$I_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$I_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$$

$$I_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$


$$I_6 = (\eta_{30} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$$

$$I_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

16

Momenty Hu


Pierwszy moment Hu



17

Momenty Hu

Drugi moment Hu




18

Dopasowanie wzorców

Znany jest wzorec – fragment obrazu

Znajdujemy położenie tego wzorca do obrazie



Źródło: OpenCV

19

Dopasowanie wzorca

Przesuwamy wzorec po obrazie jak przy filtracji i liczymy miarę dopasowania między wzorcem a częścią obrazu pod nim

Summed Squared Distance (SSD)

$$h[m,n] = \sum_{k,l} (g[k,l] - f[m+k,n+l])^2$$



Normalized Cross-Correlation (NCC)

$$h[m,n] = \frac{\sum_{k,l} (g[k,l] - \bar{g})(f[m+k,n+l] - \tilde{f}_{m,n})}{\left(\sum_{k,l} (g[k,l] - \bar{g})^2 \sum_{k,l} (f[m+k,n+l] - \tilde{f}_{m,n})^2 \right)^{0.5}}$$

20

Korelacja obrazów


Przebieg funkcji korelacji obrazów dla przykładowego obrazu



21

Korelacja obrazów



Czy ten wzorec jest lepszy/gorszy do znalezienia?



22

Korelacja obrazów




A ten wzorec?



23

DIC – Zastosowanie w inżynierii mechanicznej

Korelacja obrazu cyfrowego (DIC) jest praktycznym zastosowaniem metody korelacji obrazów



System GOM Aramis,
Źródło: GOM

24

Cechy lokalne

Geometryczne cechy są przydatne w analizie płaskich obiektów – w przetwarzaniu obrazów binarnych

A jak analizować obiekty na bardziej naturalnych obrazach?
samochody, ludzie, zwierzęta, budynki itp.

Potrzebujemy innego podejścia do analizy takich obiektów

Jedno z możliwych rozwiązań – **cechy lokalne** opisujące sąsiedztwo punktów charakterystycznych – np. narożników

Reprezentacja bardziej złożonych obiektów może być zbudowana na podstawie **cech lokalnych**

25


Narożniki na obrazie

Narożniki są podstawowymi obiektami na których działają deskryptory cech



26

Narożniki na obrazie



27

Detektor narożników Harrisa

Pomysł: Dla każdego piksela, przygotuj prostokątną maskę z punktem centralnym w tym pikselu.

Przesuwaj maskę w dwóch kierunkach prostopadłych i obserwuj jak zmienia się jasność obrazu

Od strony matematycznej – dla wszystkich pikseli należący do wzorca obrazu, oblicz miarę :

$$E(dx, dy) = \sum_{x,y} w(x,y) [I(x+dx, y+dy) - I(x,y)]^2$$

Gdzie dx i dy przesunięcia w kierunku x i y , $I(x,y)$ to funkcja jasności piksela i $w(x,y)$ – jest oknem, maską filtra LP (np. Gaussa)

28

Detektor narożników Harrisa

Chcemy zobaczyć jak działa ta funkcja zachowuje się przy małych przesunięciach

Obliczamy jej lokalne przybliżenie **formą kwadratową**

Napisz rozwinięcie w **szereg Taylora** dla $I(x+dx, y+dy)$

$$I(x+dx, y+dy) \approx I(x,y) + I_x(x,y)dx + I_y(x,y)dy$$

I po podstawieniu do naszego równania, otrzymujemy

$$E(dx, dy) = \sum_{x,y} w(x,y) [I_x(x,y)dx + I_y(x,y)dy]^2$$

29

Detektor narożników Harrisa

Napiszemy to równanie w formie macierzowej:

$$E(dx, dy) \approx [dx \quad dy] M \begin{bmatrix} dx \\ dy \end{bmatrix}$$

Gdzie macierz M jest to tzw. „tensor strukturalny”

$$M = \sum_{x,y} w(x,y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix}$$

Elementy tej macierzy są obliczone na podstawie **gradientu obrazu** (pochodne w kierunkach x i y), a $w(x,y)$ to **Gausa maska**

30

Detektor narożników Harrisa

To jest forma kwadratowa, równanie elipsoidy

$$E(dx, dy) \approx [dx \quad dy] M \begin{bmatrix} dx \\ dy \end{bmatrix}$$

Ponieważ M jest macierzą symetryczną, to można ją zdiagonalizować

$$M = R \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} R^T$$

Wartości własne M ujawniają lokalną zmianę jasności w dwóch głównych ortogonalnych kierunkach

31

Detektor narożników Harrisa

$$M = \sum_{x,y} w(x,y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix}$$

Strukturalny tensor

Suma po wszystkich pikselach w otoczeniu

Maska filtra LP - maska Gaussa


Macierz kwadratów lokalnych pochodnych Obliczone przez filtr górnoprzepustowy

Macierz jest diagonalna Wartości własne

32

Detektor narożników Harrisa

Jak wyglądają wartości własne tej macierzy dla różnych typów punktów charakterystycznych



"jednorodny":

λ_1 i λ_2 są małe,
 $\lambda_1 \sim \lambda_2$;

"krawędź":

$\lambda_1 \gg \lambda_2$
Lub $\lambda_2 \gg \lambda_1$

"narożnik":


λ_1 i λ_2 są duże,
 $\lambda_1 \sim \lambda_2$;

33

Detektor narożników Harrisa

Harris przedstawił w swojej pracy prostą miarę odpowiedzi detektora

$$R = \det(M) - \alpha \text{trace}(M)^2 = \lambda_1 \lambda_2 - \alpha (\lambda_1 + \lambda_2)^2$$



34

Detektor narożników Harrisa

Algorytm

- 1) Oblicz macierz M dla każdego piksela aby uzyskać dla nich odpowiedź detektora narożników
- 2) Znajdź punkty charakterystyczne dla których odpowiedź narożnika była duża ($R > \text{próg}$)
- 3) Znajdź punkty o najwyższej odpowiedzi jeśli dostaniesz dużo punktów w pobliżu tego samego punktu obrazu – non-maxima suppression

35

Zastosowanie cech lokalnych

Automatyczne dopasowanie obrazów na podstawie ich cech (np. algorytm RANSAC)



36

Zastosowanie cech lokalnych

Automatyczne dopasowanie obrazów na podstawie ich cech (np. algorytm RANSAC)



37


Zastosowanie cech lokalnych

Łączenie obrazów – tworzenie panoramy
Śledzenie obiektów w sekwencji wideo
Kalibracja kamery
Stereowizja – obliczenia dysparycji i głębi
Wielo-widokowe śledzenie i rekonstrukcja położenia kamer i struktury 3D
Rozpoznawanie, wykrywanie i dopasowywanie obiektów
Mapowanie i nawigacja dla robotów mobilnych
...

38

Deskryptor cech SIFT


Oblicz gradient obrazu – długość i kąt
Skwantuj kąty do kilku wartości
Podziel fragment obrazu na komórki
Oblicz histogram orientacji dla każdej komórki
Na podstawie wyników przygotuj deskryptor



39

Deskryptor GIST

Oblicz dla obrazu odpowiedź na bank filtrów Gabora (N filtrów)
 Podziel fragment obrazu na komórki (4x4)
 Oblicz średnią odpowiedź filtrów dla każdej komórki
 Zbuduj deskryptor na podstawie tych odpowiedzi dla każdego fragmentu obrazu
 Rozmiar deskryptora 4x4xN





40

Deskryptor oparty na tekstonach

Przygotuj bazę danych tekstonów
 Policz jaka jest zwartość każdego tekstonu w fragmencie obrazu (np. stosując dopasowanie wzorca)
 Utwórz histogram tekstonów dla wybranego fragmentu obrazu

Przykłady tekstonów



41

Pytania do powtórki

Napisz trzy geometryczne cechy wykorzystanie w analizie obrazów
 Jaka jest różnica między zwykłym i centralnym momentem?
 Jaka jest różnica między momentem centralnym i znormalizowanym ?
 Które momenty są niezmiennie wobec skali / obrotu / przesunięcia ?
 Jak jest główny zastosowanie współczynnika korelacji obrazów ?
 Co to jest cecha lokalna?
 Jakiego rodzaju cechy lokalne są wykrywane przez algorytm Harrisa ?
 Jakie są zastosowania cech lokalnych?
 Jakie filtry liniowe są stosowane w algorytmie Harrisa?

42

Dziękuję za uwagę
