

Bogdan SMOLKA

ZASTOSOWANIE ROZKŁADU KANONICZNEGO GIBBSA W DETEKCJI KRAWĘDZI

Streszczenie. W niniejszej pracy przedstawiono nowy algorytm detekcji krawędzi, oparty na modelu traktującym punkty obrazu jako zespół statystyczny Gibbsa. Model ten zakłada, że punkty obrazu są powiązane związkami statystycznymi z punktami należącymi do ich sąsiedztwa. Związki te są określone rozkładem kanonicznym Gibbsa. Uzyskane rezultaty zostały porównane z wynikami uzyskanymi przy zastosowaniu kilku najbardziej rozpowszechnionych metod detekcji krawędzi. Wstępne wyniki wskazały na interesujące własności nowej metody.


EDGE DETECTION WITH THE USE OF THE GIBBS DISTRIBUTION

Summary. In the paper a new algorithm of edge detection, based on a model treating the image points as a Gibbs statistical ensemble, is presented. This model assumes the existence of a statistical dependence between the points of an image and the ones belonging to their neighbourhood. This dependence is described by the Gibbs canonical distribution. The results obtained with the use of the new method are then compared with the ones acquired using the most popular algorithms of edge detection. The preliminary results demonstrate the interesting properties of the presented method.

1. Wprowadzenie

Detekcja krawędzi obiektów obrazu jest jednym z podstawowych zadań wstępnej analizy obrazów. Wynika to między innymi ze znanego już od dawna faktu, że system wzrokowy człowieka jest zdolny rozpoznawać obiekty na podstawie informacji o ich krawędziach czy konturach [1]. Ze względu na podstawowe znaczenie detekcji krawędzi w segmentacji obrazów, w ich rozpoznawaniu i kompresji, od wielu już lat prowadzone są intensywne badania nad algorytmami wykrywającymi różne rodzaje krawędzi. Badania te nie doprowadziły jednak do wypracowania optymalnej metody detekcji. W większości przypadków dostosowuje się metodę detekcji do rodzaju krawędzi, jaki ma się zamiar wyodrębnić z obrazu.

Krawędź można zdefiniować jako zbiór punktów brzegowych danego obiektu, w których następuje nagle zmiana ich poziomu szerokości. Większość metod detekcji zakłada, że obiekty przedstawione na obrazie składają się z pikseli o jednakowym poziomie szerokości. Zmiany poziomu szerokości występują w tym uproszczonym modelu jedynie na brzegach obiektów. W dużym uproszczeniu można wyróżnić kilka rodzajów idealnych krawędzi [2] (rys. 1).




Rys.1. Podstawowe typy krawędzi : (A) dach wypukły, (B) dach wklęsły, (C) uskok liniowy wklęsły, (D) uskok, (E) uskok liniowy wypukły, (F) uskok nieliniowy

Fig.1. Basic types of edges: (A) convex roof, (B) concave roof, (C) concave ramp edge, (D) step edge, (E) convex ramp edge, (F) nonlinear ramp edge

Klasyczne metody detekcji krawędzi polegają na wyznaczeniu:

-) punktów nieciągłości poziomu szerokości (punkty typu D),
-) punktów nieciągłości pierwszej pochodnej (punkty typu A, B, C, E),
-) punktów zerowania się drugiej pochodnej (punkty typu F).

Krawędź typu uskoku liniowego charakteryzuje się dwoma punktami nieciągłości pierwszej pochodnej x_1 i x_2 (rys. 2)




Rys. 2. Krawędź typu uskoku liniowego i jej pochodna w przypadku jednowymiarowym

Fig. 2. Concave ramp edge and its derivative in a one-dimensional case

Detektor krawędzi oparty na pierwszej pochodnej wykaze krawędź o szerokości $x_2 - x_1$, natomiast detektor opierający się na drugiej pochodnej tego typu krawędzi w ogóle nie wykryje.

Kształty krawędzi występujących w obrazach rzeczywistych różnią się oczywiście od przedstawionych kształtów idealnych. W większości przypadków mają one nieliniowy charakter. Przyjmuje się, że idealny detektor krawędzi powinien być w stanie zlokalizować jej położenie w punkcie \bar{x} (rys. 3), który odpowiada połowie wartości różnicy poziomu szarości danego obiektu i poziomu szarości tła. Punkt ten w przybliżeniu odpowiada miejscu zerowania się drugiej pochodnej.



Rys. 3. Wyznaczanie krawędzi typu uskoku nieliniowego

Fig. 3. Determination of a nonlinear ramp edge

Najczęściej detekcja krawędzi obiektów dokonywana jest przy użyciu operatorów będących cyfrowymi odpowiednikami pierwszej i drugiej pochodnej względem współrzędnych x i y macierzy obrazu.

Operacja różniczkowania

$$\frac{df(x,y)}{dx} = \lim_{\Delta x \rightarrow 0} \frac{f(x + \Delta x, y) - f(x, y)}{\Delta x}$$

odpowiada w przypadku dyskretnym wyrażeniu:

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

Ogólnie operacja różniczkowania po współrzędnych x i y odpowiada splotowi elementów macierzy obrazu z odpowiednimi maskami konwulcyjnymi (rys. 4).

0	0	0	0	0	0
0	-1	0	0	-1	1
0	1	0	0	0	0
H_x			H_y		

Rys. 4. Maski konwulcyjne operatora gradientu

Fig. 4. Convolution masks of the gradient operator

Odmianą operatora pierwszej pochodnej jest operator Roberts'a (rys. 5).

0	0	0	0	0	0	0
0	1	0	0	0	0	1
0	0	-1	0	0	-1	0
H_x			H_y			

Rys. 5. Maski konwolucyjne operatora Roberts'a
Fig. 5. Convolution masks of the Roberts operator

Wspólną cechą tych dwóch masek jest uwzględnianie wartości poziomu szarości tylko jednego lub dwóch punktów należących do sąsiedztwa punktu centralnego. Ignorowanie innych punktów sąsiednich wpływa na dużą szybkość, z jaką można przeprowadzić konwolucję tych masek z obrazem, ale szybkość ta okupiona jest małą dokładnością detekcji i dużą wrażliwością na zakłócenia. Ze względu na te wady, konstruuje się maski operatora różniczkowania uwzględniające wartości dalszych punktów sąsiednich. Przykładem takiej maski jest popularna maska Sobela i maska Prewitta (rys. 6). Zaletą tych masek jest ich mała czułość na zakłócenia.

a)			b)								
1	2	1	1	0	-1	1	1	1			
0	0	0	2	0	-2	1	0	-1			
-1	-2	-1	1	0	-1	-1	-1	-1			
H_x			H_y			H_x			H_y		

Rys. 6. Maski konwolucyjne Sobela (a) i Prewitta (b)
Fig. 6. Convolution masks of Sobel (a) and Prewitt (b)

Następna klasa detektorów krawędzi korzysta z operatora Laplace'a, dokonującego operacji obliczania drugiej pochodnej. Maski laplasjanu przyjmują najczęściej następującą postać [3,4]:

-1	0	-1	-1	-1	-1	1	-2	1	1	2	1
0	4	0	-1	8	-1	-2	4	-2	2	-12	2
-1	0	-1	-1	-1	-1	1	-2	1	1	2	1

Rys. 7. Typowe maski konwolucyjne laplasjanu
Fig. 7. Typical masks of the Laplacian

Istnieje wiele sposobów konstruowania przybliżenia cyfrowego laplasjanu. Przegląd tych metod można znaleźć między innymi w pracach [5-10].

Inną metodą spłotową jest tzw. metoda szablonów. Polega ona na splocie obrazu z ośmioma maskami, przy czym za wartość wynikową w danym punkcie biera się wartość maksymalną z wartości wszystkich spłotów. Zazwyczaj podaje się dwie maski odpowiadające kierunkowi "północ" i "północny zachód". Komplet masek szablonowych otrzymuje się poprzez ich obrót o 90, 180 i 270 stopni. Przykładowo przedstawiono poniżej komplet masek typu "kompas".

1	1	1	1	1	1	-1	1	1	1	1	1
1	-2	1	1	-2	-1	-1	-2	1	-1	-2	1
-1	-1	-1	1	-1	-1	-1	1	1	-1	-1	1
S_N			S_{NW}			S_E			S_{NE}		

-1	-1	-1	-1	-1	1	1	1	-1	1	-1	-1
1	-2	1	-1	-2	1	1	-2	-1	1	-2	-1
1	1	1	1	1	1	1	1	-1	1	1	1
S_S			S_{SE}			S_W			S_{SW}		

Rys. 8. Komplet masek szablonowych typu "kompas"
Fig. 8. Complete set of the template masks "compass"

Do innych popularnych masek należą : Maska "3 - Level", "5 - Level" i najczęściej stosowana maska Kirscha [11].

a)			b)								
1	1	1	1	1	0	1	2	1	2	1	0
0	0	0	1	0	-1	0	0	0	1	0	-1
-1	-1	-1	0	-1	-1	-1	-2	-1	0	-1	-2
S_1			S_2			S_1			S_2		

5	5	5	5	5	-3
-3	0	-3	5	0	-3
-3	-3	-3	-3	-3	-3
S_1			S_2		

c)

Rys. 9. a) Maska Typu "3 -Level", b) Maska typu "5-Level", c) Maska Kirscha
 Fig. 9. a) "3-Level" mask , b) "5-Level" mask , c) Kirsch mask

Inną metodę wyznaczania krawędzi zaprezentował Binford [12]. Polega ona na porównywaniu średnich wartości poziomu szarości pewnego sąsiedztwa danego piksela. Jeżeli różnica wartości średnich punktów otoczenia dwóch sąsiednich pikseli przekroczy pewną wartość progową, wtedy piksele te traktowane są jako elementy krawędzi. Wadą tej metody jest jej duża wrażliwość na zakłócenia oraz brak informacji o kierunku krawędzi.

Metody wyznaczające krawędzie w punktach zerowania się drugiej pochodnej zostały przedstawione przez Haralicka i Canny'ego [10,13]. Metody te dobrze wykrywają krawędzie typu uskoku, jednak zawodzą w przypadku krawędzi typu dachu. Poza tym wymagają one dużego nakładu obliczeniowego.

Metoda detekcji krawędzi, opierająca się na wyznaczaniu parametrów krzywizny obrazu, który traktowany jest jak powierzchnia trójwymiarowa, została zaproponowana w pracach [14,15]. W metodzie tej każdemu punktowi obrazu przypisany jest parametr krzywizny pewnego otoczenia danego punktu. Metoda ta wykrywa wszystkie rodzaje krawędzi i jest nieczuła na translacje i rotacje obrazu. Jest ona jednak czuła na zakłócenia i wymaga dobrego określenia wartości progowej.

Shiozaki [16] zaproponował detekcję krawędzi polegającą na wyznaczaniu w każdym punkcie obrazu lokalnej entropii .

$$H = \sum_{i=0}^n \frac{P_i \cdot \log P_i}{\log(n+1)} \quad P_i = X_i / \sum_{k=0}^n x_k ,$$

gdzie n oznacza liczbę punktów należących do sąsiedztwa punktu, dla którego oblicza się entropię, a X_i wartości poziomów szarości punktów sąsiedztwa. Sumowanie dotyczy tylko punktów o wartości różnej od zera.

Metody morfologiczne wyznaczania krawędzi opierają się na tzw. gradiencie Beuchera , który zdefiniowany jest jako różnica operatora dyatacji i erozji [17,18].

$$GRAD(L) = (L \oplus B) - (L \otimes B),$$

gdzie L jest obrazem, B elementem strukturalnym , symbol \oplus oznacza operację dyatacji natomiast symbol \otimes operację erozji .

Wykorzystuje się tu fakt, że ogólnie mówiąc dyatacja zwiększa powierzchnię obiektu, a erozja ją zmniejsza. Tak więc różnica jest obszarem brzegowym obiektu. Wynik detekcji jest zależny oczywiście od wyboru elementu strukturalnego oraz metody interpretacji obrazu wynikowego. Istnieje wiele różnych wariantów gradientu morfologicznego. Obszerny ich przegląd można znaleźć w pracy Rivesta [19].

Analiza przedstawionych metod [20] prowadzi do wniosku, że nie istnieje uniwersalna metoda detekcji krawędzi. O zastosowaniu tej lub innej metody decyduje przede wszystkim charakter krawędzi, który ma być poddany detekcji lub wzmocnieniu oraz jej szybkość obliczeniowa.

W niniejszej pracy przedstawiono nową metodę detekcji krawędzi obiektów obrazów z odcieniami szarości.

2. Opis metody

Zdefiniujmy obraz jako macierz kwadratową L o wymiarze $N \times N$, przyjmującą K kwantowanych wartości z przedziału $[0,1]$.

Zdefiniujmy teraz pojęcie sąsiedztwa punktu [21-23] na L .

Rodzina podzbiorów L określona jako : $S = \{ S_{ij} : (i, j) \in L, S_{ij} \subset L \}$

jest sąsiedztwem określonym na L wtedy i tylko wtedy, gdy sąsiedztwo punktu (i, j) spełnia dwa warunki:

1. $(i, j) \notin S_{ij}$,
2. $(k, l) \in S_{ij} \Rightarrow (i, j) \in S_{kl}$ dla każdego $(i, j) \in L$.

Przyjmijmy dalej metrykę d_{\max} definiującą odległość pomiędzy dwoma elementami L
 $p = (p_1, p_2)$ i $q = (q_1, q_2)$

$$d_{\max}(p, q) = \max\{|p_1 - q_1|, |p_2 - q_2|\}$$

i określmy zgodnie z tą metryką sąsiedztwo S_{ij} punktu $X_{i,j}$.

Punkt $X_{k,l}$ jest punktem sąsiadującym z punktem $X_{i,j}$, jeśli $d_{\max}(X_{i,j}, X_{kl}) = 1$. Tak więc punkt X_0 ma w macierzy obrazu L ośmiu równorzędnych sąsiadów $X_1, X_2 \dots X_8$ (rys. 10).

X_1	X_2	X_3
X_8	X_0	X_4
X_7	X_6	X_5

Rys. 10. Ilustracja definicji ośmiosąsiedztwa
 Fig. 10. Illustration of the 8-neighbourhood

Zdefiniujmy teraz rozkład Gibbsa określony na elementach macierzy obrazu L . Niech S będzie sąsiedztwem określonym na L . Zespół statystyczny $X = \{X_{i,j}\}$ określony na L jest zespołem statystycznym Gibbsa z sąsiedztwem S wtedy i tylko wtedy, gdy prawdopodobieństwo realizacji X jest równe:

$$P(X=x) = \exp(-U(x)) / Z,$$

gdzie $U(x)$ jest tak zwaną funkcją potencjałów punktów macierzy L , natomiast $Z = \sum_x \exp(-U(x))$ jest stałą normalizacji dobraną tak, by suma prawdopodobieństw wszystkich możliwych realizacji X była równa 1. Na podstawie twierdzenia Hammersley'a -Cliforda [23, 24] układ statystyczny z tak określonym prawdopodobieństwem jest równoważny polu Markowa pierwszego rzędu.

Rozkład statystyczny Gibbsa ma swoje źródło w fizyce statystycznej, gdzie modeluje on między innymi własności gazów i materiałów ferromagnetycznych.

Korzystając z analogii z modelami fizyki statystycznej, a szczególnie z modelem Isinga, przypisuje się elementom macierzy obrazu L energię potencjalną, a macierz L utożsamia się z fizyczną, regularną siatką dwuwymiarową. W celu uniknięcia trudności związanych z określeniem sąsiedztwa elementów brzegowych macierzy L rozszerza się jej definicję. Niech sąsiadami elementów brzegowych macierzy będą elementy z jej przeciwległego brzegu. W ten sposób siatka

przyjmuje strukturę toroidu [25]. Sytuację tę prezentuje rysunek 11. W ten sposób każdy punkt siatki, łącznie z elementami brzegowymi, ma ośmiu sąsiadów.

N,N	N,1			N,N	N,1
1,N	1,1			1,N	1,1
N,N	N,1			N,N	N,1
1,N	1,1			1,N	1,1

Rys. 11. Dwuwymiarowa siatka toroidalna

Fig. 11. Two-dimensional toroidal lattice

W siatce fizycznej istnieje możliwość przeskoku cząstek pomiędzy jej punktami o różnych energiach potencjalnych. Prawdopodobieństwo przeskoku cząstki z punktu A o energii E_A do sąsiedniego punktu B o energii E_B jest określone klasycznym rozkładem Gibbsa

$$P(A \rightarrow B) = \exp[(E_A - E_B) / T] / Z,$$

gdzie Z jest stałą normalizującą określoną wzorem

$$Z = 1 + \exp[(E_A - E_B) / T].$$

Jedynka w wyrażeniu na Z odpowiada sytuacji, w której cząstka nie dokonuje przeskoku do punktu B i pozostaje w punkcie A . W siatce, w której każdy punkt sąsiaduje z ośmioma punktami, cząstka może dokonać przeskoku do każdego z tych ośmiu punktów lub nie zmienić swojego dotychczasowego położenia.


Prawdopodobieństwo P_0 pozostania cząstki w danym punkcie siatki jest równe:

$$P_0 = \frac{1}{\sum_{i=0}^8 \exp((E_0 - E_i) / T)} = \frac{1}{1 + \sum_{i=1}^8 \exp((E_0 - E_i) / T)}.$$

Istota proponowanej metody detekcji krawędzi polega na przyporządkowaniu każdemu pikselowi obrazu prawdopodobieństwa P_0 pozostania wirtualnej cząstki w tym punkcie. Przyporządkowanie to definiuje operator Φ , którego niektóre własności zbliżone są do własności laplasjanu. Tak więc, na podstawie wybranej definicji sąsiedztwa, jest on symetryczny ze względu na obrót o 45 stopni, działa niezależnie od kierunku przebiegu krawędzi oraz jest nieczuły na liniowe zmiany poziomu szarości.

Rysunek 12 przedstawia wynik działania tego operatora na najprostszy model krawędzi w przypadku jednowymiarowym.

$$P_{max} = 1/(2 + \exp(-1/T)) \quad P_{min} = 1/(2 + \exp(1/T)) \quad K = P_{max} / P_{min}$$




Rys. 12. Działanie operatora Φ przypisującego danemu punktowi prawdopodobieństwo pozostania w nim wirtualnej cząstki

Fig. 12. Output of the operator Φ which assigns to a point the probability that a virtual particle will stay in its current position

Poniższy wykres przedstawia zależność $K = P_{max} / P_{min}$ od $1/T$.

K



Rys. 13. Zależność P_{max} / P_{min} od $1/T$

Fig. 13. P_{max} / P_{min} vs. $1/T$

Jak widać, dla $1/T$ większych od około 5 P_{max} / P_{min} zaczyna gwałtownie rosnąć.

Ogólnie charakter odpowiedzi operatora Φ na skok jednostkowy jest podobny do odpowiedzi laplasjanu. Jednakże zmieniając temperaturę układu można parametry tej odpowiedzi modelować, co dla laplasjanu nie jest możliwe.

Integralną częścią omawianej metody jest jednopunktowa transformacja wartości prawdopodobieństwa $H_\lambda(i, j)$:

$$H_\lambda(i, j) = \exp(-\lambda \cdot P_\lambda(i, j) / P_s),$$

gdzie λ jest stałą, a P_s jest równe prawdopodobieństwu pozostania w danym punkcie X_0 wirtualnej cząstki przy założeniu, że wszystkie punkty ośmiosąsiedztwa mają taką samą wartość poziomu szarości jak punkt X_0 ($P_s=1/9$). Wartość $H_\lambda(i, j)$ jest poziomem szarości piksela obrazu wynikowego detekcji krawędzi obrazu.

3. Wyniki







Poniżej przedstawiono działanie omówionych klasycznych metod detekcji krawędzi i porównano je z wynikami metody opartej na rozkładzie kanonicznym Gibbsa. Porównania dokonano na przykładzie dwóch obrazów testowych o rozmiarach 125×125 pikseli i 256 poziomach szarości.

Pierwszy zestaw (rys. 14.1) przedstawia obraz testowy (budynek) oraz szereg obrazów będących wynikiem detekcji krawędzi metodami opisanymi we wprowadzeniu. Ostatnie dwa obrazy przedstawiają wyniki detekcji krawędzi otrzymane za pomocą opisanej w pracy metody. Wraz z malejącą temperaturą układu zwiększa się dokładność detekcji krawędzi. Wiąże się to z zależnością P_{\max}/P_{\min} od temperatury (rys. 13).


Drugi zestaw (rys. 14.2) przedstawia wyniki detekcji krawędzi obrazu przedstawiającego głowę tygrysa.

Następny zestaw (rys. 15) przedstawia działanie nowej metody na kilku obrazach testowych. Zestaw ostatni (rys. 16) ilustruje rolę parametru λ transformacji H_λ . Wraz z rosnącym parametrem λ maleje poziom szumów i zakłóceń obrazu wynikowego.


Przy porównywaniu nowej metody ograniczono się do przedstawienia działania metod detekcji operujących na punktach należących do ośmiosąsiedztwa. Ze względu na różny charakter otrzymanych obrazów wynikowych i mnogość metod progowania [11,26] obrazy te nie były poddawane, z wyjątkiem liniowej normalizacji, żadnym transformacjom poziomu szarości.

**a****b****c****d****e****f**


Rys.14.1. Detekcja krawędzi przy użyciu najczęściej stosowanych metod: a) Obraz testowy, b) Gradient pierwszej pochodnej, c) Gradient Roberta, d) Laplasjan, e) Gradient Sobela, f) Gradient Prewitta, g) Metoda Kompas, h) Metoda Kirscha, i) Gradient morfologiczny, j) Operator entropii, k) i l) Detekcja krawędzi metodą opisaną w niniejszej pracy przy $T = 0.05, \lambda = 5$ (k) oraz $T = 0.02, \lambda = 5$ (l)




g




h




i



j



k



l

Fig.14.1 Edge detection with the use of some mostly used methods: a) Test image, b) First derivative gradient method, c) Roberts gradient, d) Laplacian, e) Sobel gradient, f) Prewitt gradient, g) Compass method, h) Kirsch method, i) Morphological gradient, j) Entropy operator, k) and l) Edge detection with the use of the method described in this paper at $T=0.05$, $\lambda=5$ (k) and $T=0.02$, $\lambda=5$ (l)



a



b



c



d



e



f

Rys.14.2. Detekcja krawędzi przy użyciu najczęściej stosowanych metod: a) Obraz testowy, b) Gradient pierwszej pochodnej, c) Gradient Roberta, d) Laplasjan, e) Gradient Sobela, f) Gradient Prewitta, g) Metoda Kompas, h) Metoda Kirscha, i) Gradient morfologiczny, j) Operator entropii, k) i l) Detekcja krawędzi metodą opisaną w niniejszej pracy przy $T = 0.05, \lambda = 5$ (k) oraz $T = 0.02, \lambda = 5$ (l)

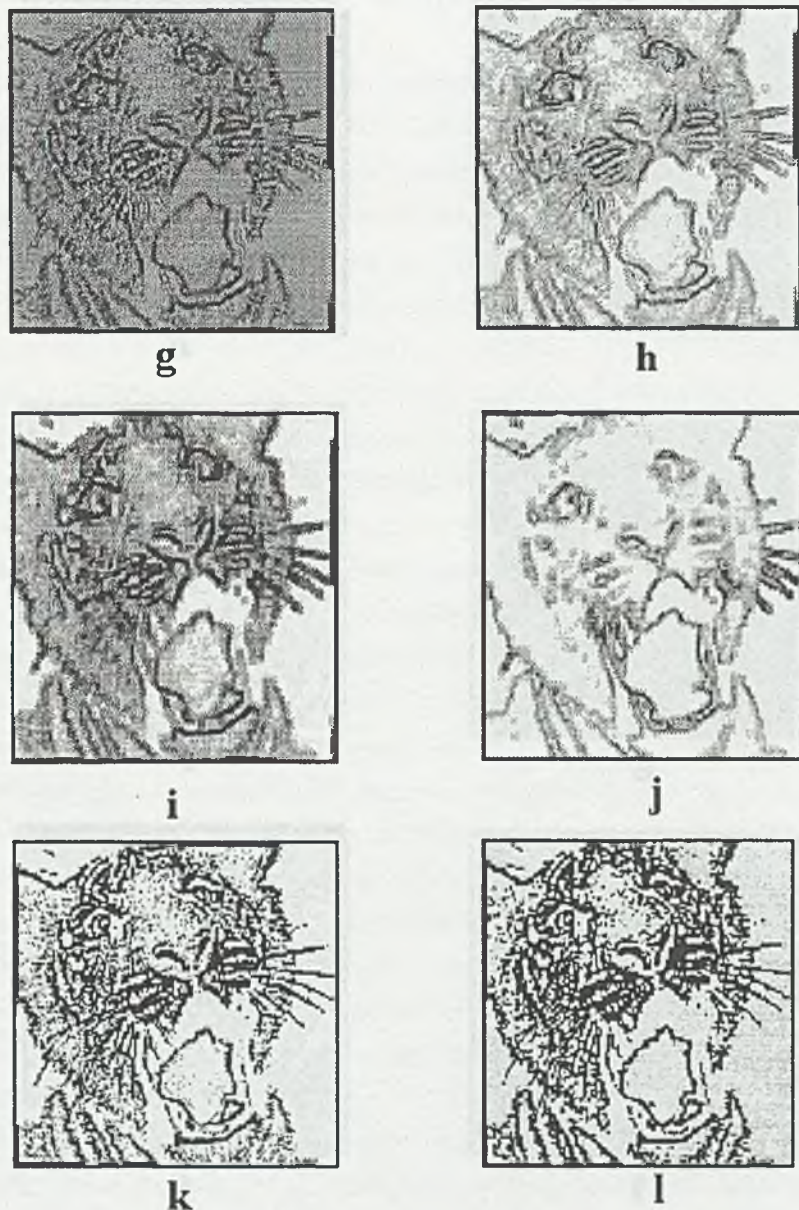

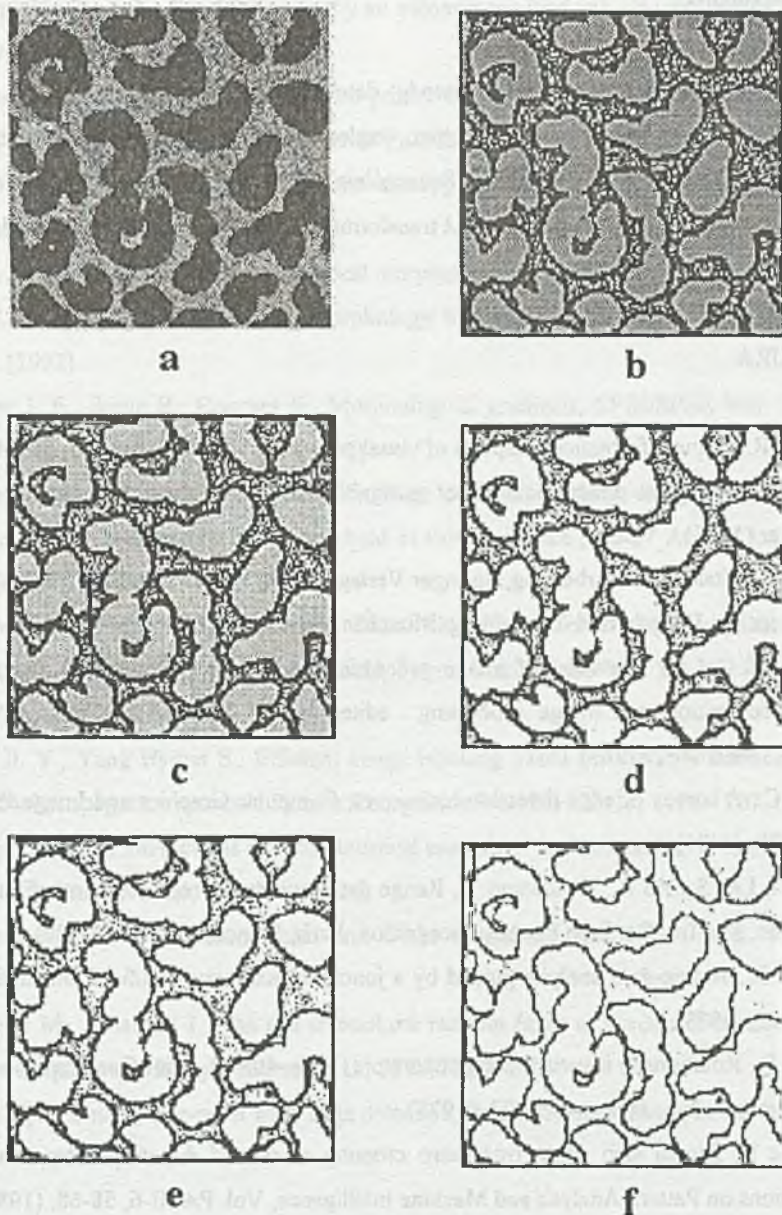


Fig.14.2 Edge detection with the use of some mostly used methods: a) Test image, b) First derivative gradient method, c) Roberts gradient, d) Laplacian, e) Sobel gradient, f) Prewitt gradient, g) Compass method, h) Kirsch method, i) Morphological gradient, j) Entropy operator, k) and l) Edge detection with the use of the method described in this paper at $T=0.05$, $\lambda=5$ (k) and $T=0.02$, $\lambda=5$ (l)



Rys.15. Wyniki detekcji krawędzi uzyskane za pomocą nowej metody, po lewej obraz testowy, a po prawej wyniki detekcji krawędzi

Fig. 15. Edge detection results obtained with the use of the new method. Test image (Left), edge detection result (Right) ($T = 0.05$, $\lambda = 5$)



Rys. 16. Wpływ parametru λ transformacji H_1 na wyniki detekcji krawędzi przy $T=0.05$:

a) obraz testowy przedstawiający skórę leoparda, b) $\lambda=1$, c) $\lambda=2$, d) $\lambda=5$, e) $\lambda=10$,
 f) $\lambda=100$

Fig. 16. The influence of the parameter λ of the H_1 transformation on the detection results at $T=0.05$

a) test image of a leopard skin, b) $\lambda=1$, c) $\lambda=2$, d) $\lambda=5$, e) $\lambda=10$, f) $\lambda=100$

4. Podsumowanie

Analiza wyników działania nowej metody detekcji krawędzi świadczy o jej dobrych własnościach. Jest ona stosunkowo precyzyjna, względnie szybka (wielokrotnie szybsza niż np. metoda Kirscha) i łatwa w implementacji. Szczególnie interesująca jest możliwość kształtowania obrazu wynikowego za pomocą parametru λ transformacji skalującej i temperatury T układu.

LITERATURA

1. Attneave R., Some informational aspects of visual perception, *Psychol. Rev.* 61, (1954)
2. Besl P, Jain R., Three dimensional object recognition, *ACM Computing Surveys* Vol. 17, 1, 75-145, Mar (1985)
3. Jähne B., *Digitale Bildverarbeitung*, Springer Verlag, Berlin, Heidelberg, New York, (1989)
4. Haberäcker P., *Digitale Bildverarbeitung*, München, Wien, Hanser Verlag (1989)
5. Gonzalez R.C., An overview of image processing and pattern recognition techniques in *Pattern recognition and image processing* edited by F. Aminzadeh, Geophysical Press, London-Amsterdam, (1987)
6. Davis L.C., A survey of edge detection techniques, *Computer Graphics and Image Processing* 4, 248-270, (1975)
7. Bhanu B., Lee S., Ho C., Henderson T., Range data processing: representation of surfaces by edges *Proc. 8th Int. Conf. on Pattern Recognition*, Paris, France, 236-238, (1986)
8. Sugihara K., Range-data analysis guided by a junction dictionary, *Artificial Intelligence*, Vol 12, 41-69, (1979)
9. Beaudet P., Rotationally invariant image operators, *Proc. 4th Int. Joint Conference on Pattern Recognition*, Tokyo, Japan, 579-583, (1978)
10. Haralick R, Digital step edges from zero crossing of second directional derivative, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-6, 58-68, (1984)
11. Meer P., Wang S., Edge detection by associative mapping, *Pattern Recognition* , Vol. 22, No.5, 49-503, (1989)
12. Binford T., Inferring surfaces from images, *Artificial Intelligence* Vol. 17, 205-244, (1981)
13. Canny J. A., A computational approach to edge detection techniques, *Computer Vision Graphics and Image Processing* Vol. 4 , 248-270, (1975)

14. Sharma U., Davis L., Road following by an autonomous land vehicle using range data, CAR-TR-194, University of Maryland, 1986
15. Ponce J., Brady M., Toward a surface primal sketch. Three dimensional Machine Vision, Edited by Takeo Kanade, Kluwer Academic Publishers, 195-240, (1987)
16. Shiozaki A., Edge extraction using the entropy operator, Computer Vision Graphics and Image Processing 36, 1-9, (1986)
17. Serra J., Image analysis and mathematical morphology, Academic Press, London, (1982)
18. E. R. Dougherty, Mathematical morphology in image processing, Merrell-Dekker, New York, (1992)
19. Rivest J. F., Soille P., Beucher S., Morphological gradients, SPIE/SPSE Vol. 1658, Non-linear Image Processing , 139-150, (1992)
20. Koivunen V., Silven O., Pietikainen M., Edge detection in range images in From pixels to features - Proceedings of a workshop held at Bonas, France , 22-27 August 1988 edited by J.C. Simon , 175-184
21. Chung-Lin Huang, Tai Yuen Cheng, Chaur-Chin Chen, Color images' segmentation using scale space filter and Markow random field, Pattern Recognition Vol. 25, No. 10, 1217-1229, (1992)
22. Kim Il. Y., Yang Hyuon S., Efficient image labelling based on Markow Random Field and error backpropagation network. Pattern Recognition Vol. 26, No. 11, 1695-1707, (1993)
23. Besag J., Spatial interactions and the statistical analysis of lattice systems, Journal of the Royal Statistical Society B-36, 192-236, (1974)
24. Spitzer F., Markow random fields and Gibbs ensembles, Am. Math. Mon. 78, 142-154, (1971)
25. Hassner M , Sklansky J., The use of markow random fields as models of texture, Computer Vision Graphics and Image Processing 12, 357-370, (1980)
26. Shou-Pyng Shu J., One-pixel wide edge detection, Pattern Recognition Vol. 22, No. 6, 665-673, (1989),

Recenzent Doc. dr hab. inż. Bohdan Wołczak

Wpłynęło do Redakcji 18.03.1996 r.

Abstract

In the paper a new algorithm of edge detection, based on a model treating the points of an image as a Gibbs statistical ensemble is presented. This model, equivalent to the Markov random field model, assumes the existence of a statistical dependence between the points of an image and the ones belonging to their neighbourhood. This dependence is described by the Gibbs canonical distribution. Using the analogy with the models of statistical physics and especially the well known model of Ising, a correspondence between the image points and the points of a two-dimensional toroidal lattice can be established. On a two-dimensional lattice a virtual particle can jump to a point belonging to its neighbourhood. The probability of such a transition is given by the Gibbs canonical distribution. The presented method ascribes to each point of the lattice the probability that the particle remains in its current position. This assignation defines an operator, which properties are similar to the Laplacian. The probability values are then subjected to a transformation which plays a thresholding role. The analysis of the preliminary results demonstrate the interesting performance of the presented method.