Bogdan SMOŁKA

ZASTOSOWANIE ELEMENTÓW TEORII PROCESÓW STOCHASTYCZNYCH MARKOWA W ZAGADNIENIU WZMACNIANIA KONTRASTOWOŚCI OBRAZÓW

Streszczenie. W pracy przedstawiono nową metodę wzmacniania kontrastowości obrazów. Metoda ta oparta jest na modelu traktującym punkty obrazu jako elementy dwuwymiarowej siatki o strukturze toroidu. Własności tak określonej siatki można badać rozważając szczególny przypadek procesu Markowa, tak zwany proces błądzenia przypadkowego. Przedstawiony algorytm wzmacniania kontrastu dokonuje transformacji przyporządkowującej poziomowi szarości punktu obrazu względną częstość obsadzenia tego punktu w procesie błądzenia przypadkowego na siatce, przy zadanej temperaturze układu.

CONTRAST ENHANCEMENT OF IMAGES WITH THE USE OF THE ELEMENTS OF THE THEORY OF MARKOW STOCHASTIC PROCESSES

Summary. In the paper a new method of the contrast enhancement of images is presented. The method is based on a model which treats the image points as a two dimensional toroidal lattice. The properties of a such determined lattice can be investigated considering a special case of Markow process, the so called random walk. The presented algorithm of image contrast enhancement transforms the grey scale level of an image point into the relative frequency of visits during the random walk on the lattice at a given temperature of the system.

1. Wprowadzenie

Polepszanie jakości obrazów jest podstawowym zagadnieniem przetwarzania wstępnego. Głównym jego celem jest zwiększenie kontrastowości obrazu, uwydatnienie krawędzi obiektów, zmniejszenie poziomu zakłóceń oraz wzmocnienie słabo wyraźnych a istotnych elementów obrazu. Poprawa parametrów obrazu jest warunkiem sukcesu w dalszych krokach jego analizy, takich jak: detekcja krawędzi, segmentacja, wyznaczanie cech obiektów i ich rozpoznawanie.

Metody polepszania kontrastowości obrazu można podzielić na metody przestrzenne oraz częstotliwościowe. Ograniczmy się do krótkiego omówienia metod przestrzennych.

Nr kol. 1340

Zdefiniujmy obraz jako macierz dwuwymiarową L o wymiarze N×N, o K skwantowanych wartościach L(i, j) należących do przedziału [0, 1].

Najprostszym rodzajem metod filtracyjnych służących do modyfikacji parametrów obrazów są metody jednopunktowe. Filtrowanie jednopunktowe polega na zmianie poziomu szarości poszczególnych punktów obrazu bez uwzględniania wartości punktów sąsiednich oraz lokalizacji punktu na obrazie. Jeżeli wartość odwzorowania jednopunktowego nie zależy od współrzędnych (i, j) macierzy obrazu L, wtedy mówi się o tak zwanym odwzorowaniu homogennym. Wartości poziomów szarości punktów poddanych filtracji zależą wtedy tylko od ich wartości pierwotnych.

Filtrację niehomogenną przeprowadza się w przypadku nierównomiernego oświetlenia sceny, przy znajomości parametrów tego oświetlenia. Wtedy wartość poziomu szarości, jaką przyjmuje dany punkt, zależna jest od jej wartości pierwotnej, położenia danego punktu na macierzy obrazu L oraz danych dotyczących oświetlenia sceny [1].

Transformacje te mają zazwyczaj za zadanie uwydatnienie pewnych poziomów szarości obrazu oraz zwiększenie jego kontrastowości. Niektóre przykłady operacji jednopunktowych ilustruje rysunek 1 [2,3]; x oznacza wartość poziomu szarości przed filtracja, a g po filtracji.

Transformacje jednopunktowe można podzielić na transformacje liniowe i nieliniowe. Jedną z częściej stosowanych jednopunktowych transformacji nieliniowych jest transformacja logarytmiczna. Ma ona następującą postać [3]:

> $min = \log(c_1)$ $max = \log(c_2)$ $cps = c_2 - c_1$ $c_1 < c_2$ $g(x) = [\log(c_1 + x \cdot cps) - min] / [max-min];$

dobierając c_1 i c_2 można modelować kształt funkcji transformującej. Podstawiając do wzoru zamiast funkcji logarytmicznej funkcję eksponencjalną, otrzymuje się transformację wzmacniającą kontrast w jasnych obszarach obrazu.

Ogólnie, manipulacja poziomów szarości punktów jest odwzorowaniem

$$g: F \rightarrow F, F \in [0,1],$$

gdzie: g może być dowolną funkcją określoną na F taką, że:

 $min\{g\} > -\infty \text{ oraz } max\{g\} < +\infty.$

Wtedy unormowana funkcja $g_n(x)$ ma postać:

$$g_n(x) = (g(x) - min \{g\}) / (max\{g\} - min\{g\}).$$

Jest to najogólniejsza postać transformacji jednopunktowych.



Rys. 1. Przykłady transformacji jednopunktowych;

- a) progowanie, b) inwersja poziomów szarości,
- c) wycinanie, d) transformacja logarytmiczna i eksponencjalna poziomów szarości w celu wzmocnienia kontrastu obrazu
- Fig. 1. Examples of one-point transformations;
 - a) thresholding, b) inversion of the grey scale, c) cutting, d) logarithmical and exponential transformations for the image contrast enhancement

Innym przykładem transformacji nieliniowych jest tak zwane wyrównywanie histogramu. W tym przypadku funkcja g nie jest zadana, lecz obliczana na podstawie rozkładu poziomów szarości punktów obrazu [4-8].

Niech $x_1, x_2, x_3 \dots x_m$ oznaczają dyskretne poziomy szarości punktów występujących w obrazie. Histogram obrazu oblicza się wyznaczając względną częstość $p_k(x_k)$ występowania pikseli o danym poziomie szarości x_k w obrazie $p_k(x_k) = n_k/n$, gdzie *n* to ogólna liczba punktów obrazu.

Wyrównywanie histogramu jest transformacją:

$$g(x_k) = \sum_{j=1}^k p_j(x_j) \cdot$$

Celem tej transformacji jest utworzenie obrazu, którego histogram obejmuje cały zakres dostępnych poziomów szarości. Podobne zadanie ma tak zwana operacja rozciągania histogramu. Po tej transformacji histogram obrazu zostaje unormowany na cały zakres dostępnych poziomów szarości. Poniższy rysunek ilustruje działanie obu transformacji.





Rys.2. a) Obraz testowy przedstawiający wydmę, b) obraz po operacji wyrównywania histogra-mu, c) obraz po operacji rozciągania histogramu. Poniżej odpowiednie histogramy

Fig. 2. a) Test picture of a dune, b) test image after the histogram equalization, c) test image after the stretching of the histogram. Below the appropriate histograms

Powyższe transformacje są przykładami operacji globalnych. Transformacja poziomów szarości pikseli dokonywana jest na podstawie informacji o ich rozkładzie na całym obrazie. Transformacje lokalne opierają się na rozkładzie poziomów szarości punktów z pewnego sąsiedztwa danego piksela. W ten sposób operacja lokalnego wyrównywania histogramu wyrównuje histogram w pewnym określonym małym sąsiedztwie danego piksela i przypisuje mu wartość wynikającą z przeprowadzonej lokalnej transformacji. Operacja ta jest powtarzana dla wszystkich punktów obrazu.

Inna operacja lokalna opiera się na informacji o wartości średniej i wariancji poziomu szarości sąsiedztwa piksela, którego wartość ma zostać poddana transformacji [9, 10]. Wartość średnia poziomu szarości jest miernikiem jasności danego obszaru obrazu, natomiast wariancja jest miarą jego kontrastu.

Typowa transformacja tego rodzaju ma postać:

 $g(i, j) = A(i, j) \cdot [L(i, j) - m(i, j)] + m(i, j)$ $A(i, j) = c \cdot M / \sigma (I, j) \qquad 0 < c < I,$

gdzie m(i, j) i $\sigma(i, j)$ to wartość średnia i odchylenie standardowe poziomów szarości pewnego sąsiedztwa piksela (i, j), M to globalna wartość średnia punktów obrazu, a c to stała z

przedziału (0,1). Ponieważ A(i, j) jest odwrotnie proporcjonalna do lokalnej wariancji , wzmocnieniu po transformacji ulegają obszary obrazu o słabej kontrastowości .

Kolejną metodą poprawy jakości obrazów jest tak zwane wyostrzanie [11-16] poprzez wzmocnienie krawędzi obiektów obrazu. Dokonywane jest ono zazwyczaj poprzez transformacje, które są cyfrowymi odpowiednikami operatorów pierwszej i drugiej pochodnej względem współrzędnych punktów obrazu. W wersji cyfrowej pierwsze pochodne względem współrzędnych *i*, *j* macierzy *L* obliczane są ze wzorów:

$$f_{i}^{\prime} = [f(i+1, j) - f(i, j)] / [i+l-l] = f(i+1, j) - f(i, j),$$

$$f_{j}^{\prime} = [f(i, j+1) - f(i, j)] / [j+l-l] = f(i, j+1) - f(i, j).$$

Obliczanie pierwszej pochodnej jest równoważne konwolucji macierzy obrazu z poniższymi maskami:

0	0	0	0	0	0
0	-1	0	0	-1	1
0	1	0	0	0	0
	H			H	

Rys. 3. Maski konwolucyjne operatora pierwszej pochodnej Fig. 3. Convolution masks of the first derivative

Inne przybliżenie pierwszej pochodnej, tak zwane przybliżenie Sobela, osiąga się obliczając następujące wyrażenia :

$$f'_{i} = [f(i+1, j-1)+2f(i+1, j)+f(i+1, j+1)] - [f(i-1, j-1)+2f(i-1, j)+f(i-1, j+1)],$$

$$f'_{j} = [f(i+1, j-1)+2f(i, j+1)+f(i+1, j+1)] - [f(i-1, j-1)+2f(i, j-1)+f(i-1, j+1)].$$

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1
H				H	

Rys. 4. Maski konwolucyjne Sobela Fig. 4. Sobel convolution masks

Jak widać (rys. 4), maski te ignorują wartość poziomu szarości punktu centralnego, czego efektem jest nieostrość obrazu wynikowgo. Z drugiej jednak strony taka konstrukcja pochodnej zapewnia jej małą czułość na szumy zakłócające.

Wartość gradientu w danym punkcie oblicza się najczęściej ze wzorów :

$$GRAD(i, j) = \left\{ \left(L(i, j) \oplus H_i \right)^2 + \left(L(i, j) \oplus H_j \right)^2 \right\}^{1/2},$$

$$GRAD(i, j) = \left| L(i, j) \oplus H_i \right| + \left| L(i, j) \oplus H_i \right|.$$

Innym ważnym operatorem różniczkowym jest laplasjan będący cyfrowym odpowiednikiem operatora drugiej pochodnej. Istnieje wiele metod przybliżania cyfrowego laplasjanu. Najczęściej stosowane maski mają postać przedstawioną na rysunku 5.

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

Rys.5. Najczęściej używane maski laplasjanu Fig. 5. Mostly used masks of Laplacian

Wyostrzenia obrazu dokonuje się poprzez złożenie obrazu oryginalnego z obrazem poddanym działaniu operacji pierwszej względnie drugiej pochodnej, a następnie poprzez przeskalowanie poziomów szarości jedną z opisanych wyżej metod.

Poniższy rysunek ilustruje działanie operatorów różniczkowych na idealną krawędź w przypadku jednowymiarowym .



- Rys. 6. Działanie operatorów różniczkowych na jednowymiarowy model krawędzi;
 a) funkcja modelująca krawędź, b) odpowiedź operatora pierwszej pochodnej, c) odpowiedź operatora Laplace'a, d) efekt wyostrzenia krawędzi uzyskany poprzez wyznaczenie różnicy funkcji wyjściowej (a) i laplasjanu (c)
- Fig. 6. The action of the derivative operators on a one-dimensional model of an edge;

a) modelling function of an edge b) answer of the first derivative operator c) answer of the Laplacian d) the sharpening effect obtained by substracting the laplacian (c) from the modelling function (a)

Jak widać, istnieje wiele metod prowadzących do poprawy jakości obrazów. Wybór danej metody podyktowany jest cechami obrazu wyjściowego oraz celem, jaki zamierza się osiągnąć poprzez filtrację. W wielu przypadkach chodzi głównie o wzmocnienie kontrastowości obrazu i uwypuklenie niosących ważną informację, lecz słabo zaznaczonych szczegółów.

W ostatnich kilkunastu latach można zauważyć wzrastające zainteresowanie zastosowaniem teorii procesów stochastycznych Markowa w przetwarzaniu obrazów. Elementy tej teorii stosowane są między innymi w zagadnieniu filtracji silnie zakłóconych obrazów [18-22], w zagadnieniu ich segmentacji [23-26] oraz w analizie tekstur [27-29].

W niniejszej pracy przedstawiono nową metodę modyfikacji kontrastu obrazów opierającą się na modelu traktującym obraz jako pole Markowa.

2. Opis metody

Określmy obraz jako macierz kwadratową L o wymiarze $N \times N$, przyjmujacą K skwantowanych wartości z przedziału [0,1].

Zdefiniujmy teraz podstawowe w teorii Markowa pojęcie sąsiedztwa punktu na macierzy obrazu L [20,23,24].

Definicja: Rodzina podzbiorów *L* określona jako $S=\{S_{i,j}: (i, j) \in L, S_{i,j} \subset L\}$ jest sąsiedztwem na *L* wtedy i tylko wtedy, gdy sąsiedztwo punktu (i, j) spełnia dwa warunki :

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

Tak więc sąsiedztwo punktu (i, j) oznaczane jako $S_{i,j}$ jest zbiorem wszystkich punktów (k, l), które sąsiadują z (i, j) i sąsiadują ze sobą. Poniższy rysunek przedstawia podstawowe rodzaje sąsiedztw dyskretnej siatki dwuwymiarowej.



Rys. 7. a) relacja czterosąsiedztwa S^1 , b) relacja ośmiosąsiedztwa S^2 Fig. 7. a) four-neighbourhood relation S^1 , b) eight-neighbourhood relation S^2 Rysunek 8 przedstawia tak zwaną hierarchię sąsiedztw. Punkt (i, j) może mieć czterech (punkty oznaczone przez 1), ośmiu (1 i 2), dwunastu (1,2 i 3), dwudziestu sąsiadów (1,2,3,4) itd. Sąsiedztwa te oznaczane są odpowiednio przez S', S^2 , S^3 ... S^m i nazywane są sąsiedztwem *m*-tego rzędu.

5	4	3	4	5
4	2	1	2	4
3	1	ī.j	1	3
4	2	1	2	4
5	4	3	4	5

Rys. 8. Hierarchia sąsiedztw na siatce dwuwymiarowej Fig. 8. Hierarchy of the neighbourhoods on a two-dimensional lattice

Ważnym pojęciem teorii pól Markowa jest tak zwana klika.

Definicja: Klika C jest podzbiorem L takim, że C składa się z pojedynczego piksela lub grupy pikseli, dla których zachodzi :

jeśli $(i, j) \neq (k, l)$ oraz $(i, j) \in C$ oraz $(k, l) \in C$, wtedy $(i, j) \in S_{k, l}$

oraz oczywiście $(k, l) \in S_{i,l}$. Innymi słowy, każde dwa elementy kliki sąsiadują ze sobą.

Rysunek 9 ilustruje rodzaje klik dla sąsiedztwa typu S^2 .



Rys. 9. Rodzaje klik siatki dwuwymiarowej dla sąsiedztwa typu S^2 Fig. 9. Clique classes on a two-dimensional lattice with the S^2 neighbourhood system

Zdefiniujmy teraz pole Markowa określone na macierzy obrazu L.

Zespół statystyczny $X = \{X_{L_j}\}$ określony na L jest polem Markowa z sąsiedztwem S wtedy i tylko wtedy, gdy

 $P[X_{i,j}=x_{i,j} | X_{k,l}=x_{k,l}, (k, l) \in L, (i, j) \in L, (k, l) \neq (i, j)] = P[X_{i,j}=x_{i,j} | X_{k,l}=x_{k,l}, (k, l) \in S_{i,j}]$

dla wszystkich $(i, j) \in L$ oraz P(X=x) > 0 dla wszystkich x, przy czym X oznacza zmienną statystyczną, a x jej konkretną realizację. Równanie to mówi, iż prawdopodobieństwo zdarzenia, że punkt (i, j) przyjmie wartość x(i, j), zależy tylko od wartości punktów należących do sąsiedztwa tego punktu S_{kl} .

Określmy teraz rozkład kanoniczny Gibbsa określony na L. Niech S będzie sąsiedztwem określonym na L. Zespół statystyczny $X=\{X_{ij}\}$ 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 energii. Jest to dowolna funkcja potencjałów wszystkich klik danej siatki L.

 $U(x) = \sum_{c \in C} V_c(x) \qquad \qquad Z = \sum_{x} \exp(-U(x)).$

Z jest stałą normalizacji dobraną tak, by suma prawdopodobieństw wszystkich możliwych realizacji X była równa 1.

Na podstawie twierdzenia Hammersley'a-Cliforda [31, 32] układ statystyczny z tak określonym prawdopodobieństwem P(X=x) jest równoważny polu Markowa.

W celu uniknięcia trudności związanych z określeniem sąsiedztwa elementów brzegowych siatki L zachodzi potrzeba rozszerzenia jej definicji. Przyjmijmy na siatce L sąsiedztwo S^2 oraz niech sąsiadami elementów brzegowych macierzy będą elementy z jej przeciwległego brzegu. W ten sposób siatka przyjmuje strukturę toroidu [28] i każdy punkt siatki L ma ośmiu sąsiadów. Sytuację tą ilustruje rysunek 10.

N,N	N,1		И,И	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. 10. Siatka dwuwymiarowa o strukturze toroidu Fig. 10. Two-dimensional toroidal lattice

Na tak określonym toroidzie można symulować proces błądzenia przypadkowego (rys. 11).



Rys. 11. Błądzenie przypadkowe na siatce dwuwymiarowej o strukturze toroidu Fig. 11. Random walk on a two dimensional toroidal lattice

Prawdopodobieństwa przeskoku błądzącej cząstki pomiędzy stanami fazowymi siatki można wyznaczyć korzystając z rozkładu kanonicznego Gibbsa oraz własności Markowa, która gwarantuje, że wystarczy uwzględnić stany należące do ich sąsiedztwa. Jeśli oznaczymy punkty siatki tak jak na rysunku 12,

Xi	X ₂	X ₃
X ₈	X,	X4
X7	X6	Xs

Rys. 12. Oznaczenia punktów siatki z sąsiedztwem S²

Fig. 12. Auxiliary denotation of the lattice points with the S² neighnourhood

to prawdopodobieństwo przeskoku cząstki błądzącej z puntu X_0 do punktu X_1 jest dane rozkładem Gibbsa

$$P(X_0 \to X_i) = \frac{\exp((X_0 - X_i) / T)}{\sum_{i=0}^{8} \exp((E_0 - E_i) / T)} = \frac{\exp((X_0 - X_i) / T)}{1 + \sum_{i=1}^{8} \exp((E_0 - E_i) / T)}$$

gdzie T jest temperaturą układu, a E_i są energiami potencjalnymi poszczególnych punktów sąsiedztwa punktu X_0 . W celu uproszczenia całego modelu uwzględnione zostały tylko kliki dwupunktowe sąsiedztwa punktu X_0 .

Nowy algorytm modyfikacji kontrastowości obrazu polega w pierwszym kroku na obliczeniu dla wszystkich punktów obrazu ośmiu prawdopodobieństw przejścia do punktów należących do ich sąsiedztwa. Następnie kolejno z każdego punktu startuje błądząca cząstka wykonując zadaną liczbę N_s przeskoków. Algorytm rejestruje liczbę odwiedzin poszczególnych punktów obrazu i następnie wyznacza ich względną częstość V(i,j). Częstość ta jest poddawana następnie homogennej transformacji jednopunktowej

$$H_{\lambda}(V(i,j)) = \exp(-\lambda V(i,j)),$$

gdzie λ jest stałą współdecydującą obok temperatury układu T o końcowym efekcie zmiany kontrastu.

3. Wyniki

Rezultaty uzyskane za pomocą nowej metody modyfikującej kontrastowość obrazów zostały przedstawione na przykładzie kilku obrazów testowych (rys. 13). Obrazy te miały rozmiar 125×125 pikseli oraz 256 poziomów szarości. Eksperymenty z błądzącą cząstką zostały przeprowadzone przy liczbie przeskoków Ns, równej 1000 i temperaturze T, równej 0.1. Ta właśnie temperatura zapewnia dobre wyniki działania algorytmu. Wpływ stałej λ transformacji H_{λ} na wynik końcowy algorytmu przedstawia zestaw obrazów (rys. 14). Jak widać, λ pełni rolę wartości progującej.



Rys.13. Przykłady działania algorytmu poprawy kontrastowości obrazów na kilku obrazach testowych dla T=0.1, $\lambda = 0.25$, $N_s = 1000$; a) obraz glowy kota, b) obraz lokomotywy. c) fragment obrazu przedstawiającego żyrafy, d) obraz powierzchni marmuru, e) obraz skóry ludzkiej. f) rozmyty obraz tablicy rejestracyjnej



Fig.13. Properties of the presented method of contrast enhancement shown on a few test images at T = 0.1, $\lambda = 0.25$ and $N_s = 1000$; a) image of a cat, b) image of a locomotive, c) fragment of an image of giraffes, d) surface of a marble stone, c) human skin, f) blurred image of a number plate



- Rys. 14. Wplyw parametru λ na cíckt poprawy kontrastowości obrazów; a) obraz powierzchni granitu, b) obraz wynikowy przy $\lambda = 2$, c) $\lambda = 1$, d) $\lambda = 0.5$, c) $\lambda = 0.25$, f) $\lambda = 0.05$. Parametry transformacji T = 0.1 i $N_x = 1000$
- Fig. 14. Effect of the parameter λ on the image contrast enhancement results; a) image of a granite surface, b) result of the contrast enhancement at $\lambda = 2$, c) $\lambda = 1$, d) $\lambda = 0.5$, c) $\lambda = 0.25$, f) $\lambda = 0.05$. Parameters of the transformations T = 0.1 and $N_s = 1000$

3. Uwagi końcowe

Przedstawiona metoda modyfikacji kontrastu obrazów, wykorzystująca pewne elementy teorii procesów stochastycznych Markowa, stanowi wzbogacenie metod istniejących. Szczególną jej własnością jest możliwość wzmacniania słabo widocznych elementów obrazu, takich jak cienie, delikatne linie itp. Własność ta mogłaby znaleźć zastosowanie w przetwarzaniu obrazów, w których słabo zaznaczone elementy niosą bardzo istotne informacje.

W trakcie eksperymentów przyjęto dość dowolnie liczbę N, kroków cząstki błądzącej, startującej z poszczególnych punktów obrazu. Wszystkie przedstawione wyniki zostały uzyskane przy $N_r = 1000$ i temperaturze T = 0.1. Przy tej temperaturze opisany algorytm zapewniał najlepsze rezultaty. Zachowanie się algorytmu w zależności od zadanej temperatury układu i optymalizacja liczby kroków błądzacej cząstki wymaga podjęcia dalszych badań.

LITERATURA

- Johnson, R. P., Contrast based edge detection. Pattern Recognition Vol.23, No. 34, 311-3128, (1990)
- 2. Jahne B., Digitale Bildverarbeitung. Springer Verlag, Berlin, Heidelberg, New York, (1989)
- 3. Haberacker P., Digitale Bildverarbeitung. München, Wien, Hanser Verlag, (1989)
- 4. Gauch J.M., Investigations of image contrast space defined by variations on histogram equalization. Graphical Models and Image Processing Vol. 54, 269-280, (1992)
- O' Gorman L., A note on histogram equalization for optimal intensitity range utilization. Computer Vision Graphics Image Processing Vol. 41, 229-232, (1988)
- Dale-Johns R., Tjabaldi T., Four algorithms for enhancing images with large peaks in their histogram. Image and Vision Computing Vol. 10, 495-507, (1992)
- Woods R., Gonzales R.C., Real-time digital image enhancement. Proc. IEEE Vol. 69, No. 5, 643-654, (1981)
- Pizer S.M., Adaptive histogram equalization and its variations. Computer Vision Graphics and Image Processing Vol. 39, 355-366, (1987)
- Narendra P.M., Fitch. R.C., Real time adaptive contrast enhancement. IEEE Trans. Pattern Anal. Mach. Intell. Vol. PAMI-3 No. 6, 655-661, (1981)

- Gonzalez R.C., An overview of image processing and pattern recognition techniques in Handbook of geophysical exploration Vol. 20 - "Pattern recognition and image processing" edited by F. Aminzadeh, Geophysical Press, London, Amsterdam, (1987)
- Pelli T. Malah. D., A study of edge detection algorithms. Computer Vision Graphics and Image Processing 20,1-21, (1982)
- Leu J.G., Image contrast enhancement based on intensities of edge pixels, Graphical Models and Image Processing Vol. 54, 497-505, (1992)
- Davis L.C., A survey of edge detection techniques. Computer Graphics Vision and Image Processing 4, 248-270, (1975)
- 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)
- Canny J. A., A computational approach to edge detection techniques, Computer Vision Graphics and Image Processing Vol. 4, 248-270, (1975)
- V. Koivunen, O. Silven, M. Pietikainen, 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
- Abdou I. E. W. K. Pratt, Quantitative design and evaluation of enhancement / thresholding edge detectors, Proc. IEEE 67,753-763, (May 1979)
- 18. Rosenfeld A., Kak A., Digital Picture Processing, Academic Press, New York (1991)
- Chalmond B., Image restoration using an estimated Markow model, Signal Processing 15 (2), 115-129, (1988)
- Chalmond B., An iterative Gibbsian technique for reconstruction of m-ary images, Pattern Recognition Vol. 22, No 6, 747-761, (1989)
- Geman S., Geman D., Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images, IEEE Trans. Pattern Anal. Mach. Intell. Vol. PAMI-6, 721-741, (1984)
- 22. Gray A.J., Kay. W., Titterington D.M., On the estimation of noisy binary Markow random fields, Pattern Recognition Vol. 25, No. 7, 749-768, (1992)
- Chung-Lin Huang, Tai Yuen Cheng, Chaur-Chin Chen, Color images' segmentation using scale space filter and Markov random field, Pattern Recognition Vol. 25, No. 10, 1217-1229, (1992)
- Kim II. Y., Yang Hyun S., Efficient image labelling based on Markow random field and error backpropagation network. Pattern Recognition Vol. 26, No. 11, 1695-1707, (1993)

- Derin H., Elliot H., Geman D., Bayes smoothing algorithms for segmentation of binary images modelled by Markow random fields, IEEE Trans. Pattern Anal. Mach. Intell. Vol. PAMI-6,707-720, (1984)
- Besag. J., On the statistical analysis of dirty pictures, Journal of the Royal Statistical Society, Ser. B 48, (3), 259-302, (1986)
- Haralick R.M., Statistical image texture analysis in "Handbook of Pattern Recognition and Image Processing, Academic Press, New York, 247-279, (1986)
- Hassner M., J. Sklansky, The use of markow random fields as models of texture, Computer Vision Graphics and Image Processing 12, 357-370, (1980)
- Cross G.R., Jain A.K., Markow random fields texture models, IEEE Trans. Pattern Anal. Mach. Intell. Vol. PAMI - 5(1), 25-39, (1983)
- Besag J., Spatial interaction and the statistical analysis of lattice systems, Journal of the Royal Statitistical Society Ser. B 36, 192-236, (1974)
- Spitzer F., Markow random fields and Gibbs ensambles. Am. Math. Mon. 78, 142-154, (1971)

Recenzent : Doc. dr inż. Bohdan Wołczak

Wpłynęło do Redakcji 18.03.1996 r.

Abstract

In the paper a new method of contrast enhancement of images is presented. The method is based on a model which treats the image points as a toroidal two-dimensional lattice, the points of which possess the potential energy which is equal to the grey scale level values of the image points. On a such defined lattice, a special case of Markow stochastic processes, the so called random walk can be investigated. The probability of a transition of a virtual particle to a point belonging to its neighbourhood, can be determined using the Gibbs canonical distribution, defined on a an eight-connectivity system. The idea of the presented algorithm consists in the calculation of eight values of the transition probabilities for each point of the image. Afterwards, a random walk starting from each point of the lattice is simulated. The trajectory of the particle is random but influenced by the values of the transition probabilities. The algorithm registers the visits of the