

Roman Vorobel*, Magdalena Stobińska**

Wykorzystanie kontrastu stosowanego w nieostrym maskowaniu

1. Wprowadzenie

Poprawa jakości obrazów jest jednym z ważniejszych aspektów obróbki obrazów. Przy czym ma ona dość szerokie zastosowanie, a także wykorzystywana jest w różnych sytuacjach, na ogół jest to: usunięcie szumu, zniekształceń geometrycznych, zwiększenie rozdzielczości i kontrastów szczegółów oraz usunięcie zniekształceń przestrzennych. Bardzo często okazuje się, iż przedstawienie obserwatorowi obiektu za pomocą zidealizowanego systemu wizualizacji nie jest wystarczające. Skomplikowane zagadnienia, wymagające dokładnej analizy obrazu (odszukanie lub identyfikacja obiektów, określenie różnego rodzaju charakterystyk ilościowych, uogólnienie opisu itd.), korzystnie jest rozwiązywać za pomocą narzędzi ułatwiających interpretację obrazu, poprzez wydobywanie z niego odpowiednich informacji. Są to zarówno narzędzia techniczne, jak i metody obróbki programowej sygnałów wideo. Obróbka taka nazywana jest preparowaniem obrazu [31].

W odniesieniu do korekcji systemów wizualizacji, preparowanie można rozpatrywać jako korekcję sposobu współdziałania sensora wideo z obiektem. Dla przykładu, w medycznej rentgenoskopii stosowane jest zwiększenie kontrastu szczegółów zdjęcia przez wprowadzenie pacjentowi specjalnej substancji kontrastującej. Ale faktycznie informacja o tych szczegółach jest uwzględniona na zdjęciu otrzymanym bez takiej substancji. Problem polega jednak na tym, iż szczegóły te nie można obserwować bezpośrednio. Tak powstały niedostatek procedury rejestracji zdjęcia skompensować można za pomocą komputerowej obróbki zdjęcia, przez jego preparowanie.

Preparowanie było dawniej stosowane w fotografii artystycznej i naukowej oraz w technice wizualizacji informacji. Przykładami tego są metody tworzenia szkicu graficznego, solaryzacji, nieostrego maskowania, odtwarzania obrazu szarego w pseudokolorach i inne [6]. Jednym z celów preparowania jest wyodrębnienie szczegółów obrazu. Celem niniejszego artykułu jest przedstawienie metody poprawy jakości obrazów na podstawie

* Wyższa Szkoła Humanistyczno-Ekonomiczna w Łodzi, Polska, Fizyko-Mechaniczny Instytut, Ukraińska Akademia Nauk, Lwów, Ukraina

** Wyższa Szkoła Humanistyczno-Ekonomiczna w Łodzi

nieostrego maskowania, opartego na stosowanym kontraście lokalnym. Omówione zostaną podstawowe metody poprawy jakości obrazów przez zwiększenie rozróżnienia ich szczegółów.

W zakończeniu przedstawione zostaną wyniki i wnioski z przeprowadzonych badań.

2. Podstawowe metody poprawy jakości obrazów

Metody poprawy jakości obrazów można podzielić na dwie kategorie:

- 1) obróbkę częstotliwościową,
- 2) obróbkę przestrzenną.

Do obróbki częstotliwościowej stosowana jest transformacja Fouriera z przekształceniem widma za pomocą nieliniowego wzmocnienia składowych wysokoczęstotliwościowych i niskoczęstotliwościowych, z zastosowanym następnie odwrotnym przetwarzaniem Fouriera – nazywane inaczej jako filtracja homomorfna [16]. Drugim podejściem jest stosowanie przetwarzań falkowych – wavelets oraz curvelets [12]. Jednak wspólną cechą takich podejść, przy realizacji wspomnianych metod, jest złożoność obliczeniowa oraz wymagania związane z pamięcią komputerową.

Oprócz metod obróbki częstotliwościowej istnieją również metody obróbki przestrzennej. Również tutaj wyróżnić można szereg klas metod poprawy jakości obrazów, poprzez zwiększenie rozróżnienia szczegółów.

Są to metody dwóch typów:

- 1) przetwarzań globalnych,
- 2) przetwarzań lokalnych.

Metody klasy przetwarzań globalnych noszą nazwę metod *Look-up-Table* (tablic przeglądowych). Oznacza to, że zasadniczą cechą tej metody jest funkcja globalnego przetwarzania poziomów szarości elementów obrazu z jednej strony, z drugiej metody te różnią się sposobem formowania funkcji przetwarzania. Do klasy tej należą metody rozciągania przedziału poziomów szarości (liniowe, odcinkowo-liniowe, nieliniowe, odcinkowo-nieliniowe) [9], metody deformacji histogramu [8] oraz metody przetwarzania histogramu [10]. Te ostatnie pozwalają obliczać funkcję przetwarzania jako taką, która zapewnia pożądany rozkład częstotliwości poziomów szarości. Do najczęściej używanych zaliczamy wyrównanie (ekwalizację) histogramu [21], hiperbolizację [5] lub przetwarzania eksponentialne [13]. Również nowym podejściem jest wykorzystanie informacji o lokalnych własnościach obrazu dla konstruowania różniczkowego histogramu, w celu jego globalnego wyrównania [18]. Są to jednak metody transformacji globalnych, co z góry prowadzi do pewnych ograniczeń poprawy jakości, wobec trudności uwzględnienia lokalnych osobliwości obrazu w jego różnych miejscach. Dla usunięcia tych problemów stosowana jest ślizgająca transformacja histogramu [19, 2, 20], co pozwala zwiększyć rozróżnienie szczegółów. Są to skomplikowane obliczeniowo procesy [29], lecz pozwalają one na zrealizowanie obliczeń w czasie rzeczywistym obróbki sygnałów telewizyjnych [15]. Niedostatkiem tych metod są małe możliwości sterowania warunkami realizacji oraz modyfikacji funkcji przetwarzania. Stąd też, jako metody klasy przestrzennej obróbki lokalnej, stosowane są transformacje ran-

kingowe, oparte na obliczaniu takiej statystyki szeregowej z elementów ślizgającego okna, która odpowiada centralnemu elementowi tego okna. Faktycznie, przy takim podejściu modeluje się ślizgające wyrównanie histogramu, lecz są przy tym obecne rozszerzone możliwości funkcjonalne, przez dodatkowe sterowanie wyborem statystyk jako numeru elementu obrazu w szeregu rankingowym [11, 31]. Opisane wyżej metody obróbki w dziedzinie przestrzennej noszą również nazwę metod pośredniej poprawy kontrastu obrazu, ponieważ nie stosują one obliczania kontrastu elementów obrazu [3]. Jednak bardziej skuteczne, z punktu widzenia poprawy jakości obrazu – przez zwiększenie jego szczegółów, są metody bezpośrednio obliczania kontrastu lokalnego i następnie jego wzmacnianie [7, 1, 3, 26]. Ale te metody są niedoskonałe w przypadku obecności obiektów o dużych rozmiarach efektywność poprawy obrazu jest niska. Dlatego korzystają z metod przetwarzania obrazu wejściowego $L(i, j)$ za pomocą nieostrego maskowania, które przedstawia obraz wyjściowy $L^*(i, j)$ jako addytywną sumę dwóch składowych – niskoczęstotliwościowej $L_f(i, j)$, prezentującej tło, oraz wysokoczęstotliwościowej $L_d(i, j)$ – prezentującej podstawowe szczegóły obiektów na obrazie. To powoduje opisanie procedury nieostrego maskowania jako [22, 27]

$$L^*(i, j) = L_f(i, j) + L_d(i, j) \quad (1)$$

lub w dokładnej formie matematycznej

$$L^*(i, j) = MEAN(W) + k[L(i, j) - MEAN(W)] \quad (2)$$

gdzie:

k – współczynnik wzmacniania kontrastu lokalnego,
 $L_f(i, j)$ – niskoczęstotliwościowa składowa, opisywana przez ślizgające średnie
 $MEAN(W)$ poziomów szarości elementów obrazu, w oknie W rozmiaru $n \times m$

$$MEAN(S) = \frac{1}{N_W} \sum_{i, j \in W} L(i, j) \equiv \bar{L}(i, j) \quad (3)$$

Jednak takie podejście nie zawsze pozwala otrzymać pożądane zwiększenie rozróżnienia szczegółów i kontrastu obrazu. Dlatego też w pracy [14] zaproponowano wykorzystanie adaptacyjnego wzmacniania kontrastów lokalnych, przez obliczenia według wzoru

$$L^*(i, j) = MEAN(S) + K(i, j) \cdot [L(i, j) - MEAN(S)] \quad (4)$$

gdzie współczynnik $K(i, j)$ adaptacyjnego wzmacniania kontrastu lokalnego jest obliczany jako

$$K(i, j) = Q \frac{L_0}{\sigma(i, j)} \quad (5)$$

współczynnik normujący Q ma wartości z przedziału $0 < Q \leq 1$, L_0 jest uśrednionym znaczeniem poziomów szarości wszystkich elementów obrazu L rozmiaru $N \times M$ elementów

$$L_0 = \frac{1}{N \cdot M} \sum_{i=1}^N \sum_{j=1}^M L(i, j) \quad (6)$$

a $\sigma(i, j)$ – to odchylenie średniokwadratowe poziomów szarości elementów okna W . Innym sposobem zwiększenia kontrastów lokalnych i rozróżnienia szczegółów jest opisana w pracy [24] metoda nieliniowego przetwarzania składowej tła oraz stosowanie dla formowania składowej wysokoczęstotliwościowej filtrów racjonalnych, jako rozwiązanie zaprezentowane w pracy [17]. Jednak te podejścia nie są zadowalające, przy rozwiązywaniu problemu poprawy jakości obrazów przez zwiększenie ich rozróżnienia szczegółów za pomocą wzmacniania kontrastów lokalnych, gdyż wymagają wielokrotnych rozwiązań z różnymi parametrami i wyboru lepszego z nich. Stąd celem niniejszej pracy jest stworzenie takiej metody poprawy jakości obrazu, która pozwoliłaby zmniejszyć liczbę prób w osiągnięciu potrzebnych wymagań do transformowanego obrazu. Osiągnęliśmy to za pomocą optymalizacji przetwarzania składowej niskoczęstotliwościowej obrazu w nieostrym maskowaniu, na podstawie kontrastu stosowanego. W celu dokładnej prezentacji nowej metody nieostrego maskowania omówimy najpierw wykorzystanie w niej kontrastu stosowanego.

3. Nieostre maskowanie na podstawie lokalnego kontrastu stosowanego

W pracy [24] przedstawiono uogólniony opis metod nieostrego maskowania obrazów na podstawie kontrastów lokalnych. Według tego podejścia możemy przedstawić opis algorytmu nieostrego maskowania wzorem

$$L^*(i, j) = L_f(i, j) + Kamp(i, j) \cdot LMAX \cdot C(i, j) \quad (7)$$

gdzie:

- $Kamp(i, j)$ – adaptacyjny współczynnik wzmacniania kontrastów lokalnych,
- $LMAX$ – maksymalnie możliwe znaczenie poziomu jasności elementów obrazu,
- $C(i, j)$ – stosowany kontrast lokalny ($-1 \leq C(i, j) \leq 1$), obliczany według wzoru [23, 28]

$$C(i, j) = \frac{L(i, j) - \bar{L}(i, j)}{\max(L(i, j), \bar{L}(i, j))} \quad (8)$$

lub z wykorzystaniem nieliniowego przetwarzania poziomu tła jako

$$L^*(i, j) = \alpha \cdot S(L_f(i, j)) + \beta \cdot Kamp(i, j) \cdot LMAX \cdot C(i, j) \quad (9)$$

gdzie:

- α, β – współczynniki bilansowego regulowania ($\alpha, \beta \geq 0$),
- $S(\cdot)$ – funkcja nieliniowego przetwarzania niskoczęstotliwościowej składowej.

Podstawiając (8) w (9) i przyjmując dla uproszczenia $\alpha = 1, \beta = 1$, otrzymujemy

$$L^*(i, j) = S(L_f(i, j)) + Kamp(i, j) \cdot LMAX \cdot \frac{L(i, j) - \bar{L}(i, j)}{\max(L(i, j), \bar{L}(i, j))} \quad (10)$$


Faktycznie każda z opisanych wyżej metod nieostrego maskowania jest częściowym przypadkiem realizacji obliczeń według wzoru (9) lub (10). Wszystko zależy od wyboru konkretnego sposobu obliczania kontrastu lokalnego $C(i, j)$, współczynnika $Kamp(i, j)$, funkcji $S(\cdot)$ oraz metody opisaną $L_f(i, j)$. I tak, na przykład, podstawiając:

$$S(L_f(i, j)) = MEAN(W) \quad \text{i} \quad Kamp(i, j) = \frac{k}{LMAX \cdot \max(L(i, j), MEAN(W))} \quad (11)$$

otrzymujemy wzór (2). Jednak w praktyce, skomplikowany jest wybór konkretnej zależności $S(L_f)$. Aby usunąć ten problem, proponujemy opis $S(L_f)$ przez S -podobne funkcji należności, które są zadawane swoimi parametrami a, b i c oraz wykładnikiem γ w postaci wzoru

$$\mu_L(L(i, j)) = S(L(i, j), a, b, c, \gamma) = \begin{cases} 0, & \text{gdy } 0 < L(i, j) = 0, \\ w, & \text{gdy } 0 < L(i, j) \leq a, \\ \frac{(1-2w)(L(i, j)-a)^\gamma}{(b-a)(c-a)}, & \text{gdy } a < L(i, j) \leq b, \\ 1-w - \frac{(1-2w)(c-L(i, j))^\gamma}{(c-b)(c-a)}, & \text{gdy } a < L(i, j) \leq c, \\ 1-w, & \text{gdy } L(i, j) > c, \\ 1, & \text{gdy } L(i, j) = 255. \end{cases} \quad (12)$$

Widok funkcji należności (12) przedstawiony na rysunku 1.



Rys. 1. Widok funkcji rozmytej należności

W celu optymalizacji wyboru parametru b obrazu wykorzystamy znaną w teorii zbiorów rozmytych zasadę maksimum entropii rozmytej, jaką zapewnia optymalna transformacja S -podobnej funkcji należności [4]. O ile funkcja rozmytej należności obecnie należy przedziału $[0, 1]$, to, normując ten przedział mnożeniem na maksymalnie możliwe znaczenie poziomu jasności elementów obrazu $LMAX = 255$, otrzymujemy funkcję optymalnego przetwarzania poziomu szarości składowej niskoczęstotliwościowej $L_f(i, j)$. Tę funkcję będziemy stosować przy konstruowaniu metod poprawy jakości obrazów. Aby ją odnaleźć, szukamy za pomocą S -funkcji (12) takiego przetwarzania $\mu(L)$, które maksymalizuje rozmytą entropię

$$H_{\max}(L; a, b_{opt}, c) = \max \{H(L; a, b, c \mid L_{\min} \leq a < b < c \leq L_{\max})\} \quad (13)$$

gdzie:

L_{\min}, L_{\max} – minimalny i maksymalny poziom szarości obrazu;
 $H(L)$ – entropia pojedynczego przetwarzania.

Entropię pojedynczego przetwarzania obliczamy następująco

$$H(L) = \frac{1}{N \cdot M} \sum_{i=1}^N \sum_{j=1}^M S_f(\mu_L(L(i, j))) \quad (14)$$

gdzie $S_f(\mu_L(L(i, j)))$ – funkcja Shennona,

$$S_f(\mu_L(L(i, j))) = -\mu_L(L(i, j)) \log_2 \mu_L(L(i, j)) - \\ - (1 - \mu_L(L(i, j))) \log_2 (1 - \mu_L(L(i, j))) \quad (15)$$

Zmieniając od $a+1$ do $a-1$ znaczenie parametru b funkcji rozmytej należności $\mu(L)$ (12), szukamy takiego jego znaczenia, jakie zapewnia maksimum entropii (13). Otrzymane w taki sposób optymalne przetwarzanie pozwala obliczyć odpowiednio transformowane niskoczęstotliwościowe składowe obrazu jako obraz $L0_f(i, j)$ i stosować go przy realizacji nowych metod nieostrego maskowania, opartych na wykorzystaniu obliczeń za wzorami (9) i (10).

Biorąc za podstawę klasyczną metodę nieostrego maskowania (2) oraz metodę (9) ze wzoru (10), otrzymujemy modyfikację 1

$$L^*(i, j) = S(MEAN(W)) + k \cdot LMAX \cdot \frac{L(i, j) - MEAN(W)}{\max(L(i, j), MEAN(W))} \quad (16)$$

Wykorzystując metodę (4) ze wzoru (10), otrzymujemy modyfikację 2:

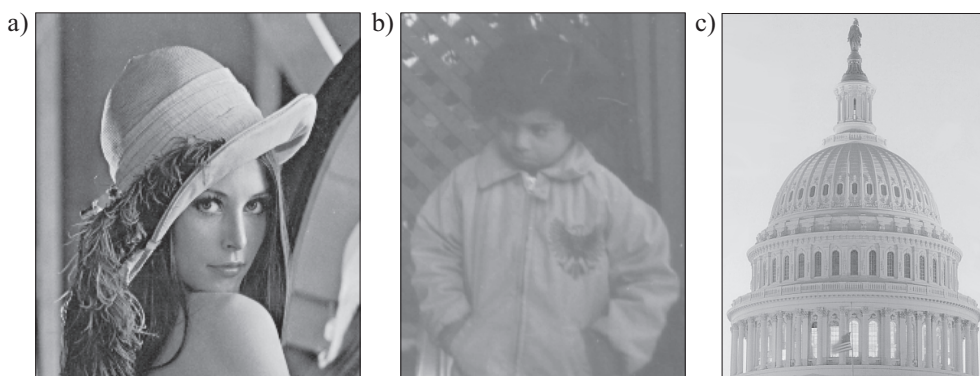
$$L^*(i, j) = S(MEAN(W)) + K(i, j) \cdot LMAX \cdot \frac{L(i, j) - MEAN(W)}{\max(L(i, j), MEAN(W))} \quad (17)$$

gdzie współczynnik wzmacniania adaptacyjnego $K(i, j)$ obliczamy według wzoru (5).

Te dwie metody (16) i (17) dają nowe rozwiązanie problemu zwiększenia efektywności metod nieostrego maskowania przez wykorzystanie stosowanego kontrastu lokalnego i optymalizacji nieliniowego przetwarzania składowej niskoczęstotliwościowej obrazu.

4. Badania efektywności metod nieostrego maskowania obrazu

W celu zbadania efektywności zaproponowanych dwóch metod (16) i (17) porównamy je z tradycyjnym podejściem do nieostrego maskowania (2), i adaptacyjnym nieostrym maskowaniem (4). Przy tym wybierane współczynniki pozostawiamy bez zmian, aby lepiej poznać różnice tych metod. Dla metody (2) wybieramy $k = 1,2$. Dla metody (4) ograniczamy współczynnik $K(i, j)$ wzmacniania kontrastu przez wybór jego znaczeń tylko z przedziału $1 < K(i, j) \leq 1,5$, parametr $Q = 0,1$. Dla metod (16) i (17) wybieramy $k = 0,8$, $LMAX = 255$, $K(i, j) \leq 1,5$. Dla funkcji nieostrej należności (11) będziemy zmieniać znaczenia dwóch parametrów – w i γ . Wykorzystamy obrazy *Lena* (rys. 2a), *Pout* (rys. 2b), i *Capitol* (rys. 2c) jako testowe. Parametrem ilościowej oceny kontrastu obrazu będzie uogólniony kontrast C_{gen} , obliczany według pracy [25]










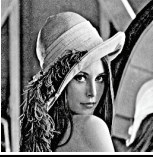


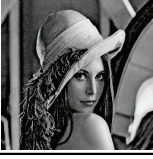


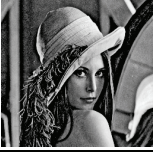




Rys. 2. Obrazy testowe: a) *Lena*, $C_{gen} = 0,34$; b) *Pout*, $C_{gen} = 0,16$; c) *Capitol*, $C_{gen} = 0,23$

W tablicy 1 przedstawione są wyniki stosowania badanych metod nieostrego maskowania (2), (4), (16) i (17) z następującymi parametrami w i γ : A – $w = 10$, $\gamma = 0,8$; B – $w = 10$, $\gamma = 1,2$; C: – $w = 0$, $\gamma = 0,8$; D: – $w = 0$, $\gamma = 1,2$ oraz uogólnione kontrasty C_{gen} odpowiednich

obrazów. Analiza otrzymanych wyników wskazuje na skuteczność zaproponowanych metod (16) i (17). Dla wszystkich przedstawionych wypadków, nowe metody pozwalają otrzymać znaczne wzmacnianie uogólnionego kontrastu obrazu C_{gen} , o czym świadczą jego ilościowe znaczenia, przedstawione w pierwszej kolumnie tabeli 1. Przy tym otrzymaliśmy równoległe zwiększenie rozróżnienia szczegółów obrazu. Współczynników k i $K(i, j)$ wzmacniania kontrastu lokalnego, niewiele różnią się od jedynki. To znaczy, że można je zwiększyć, co spowoduje dodatkowe wzmacnianie kontrastu lokalnego i rozróżnienie szczegółów.

Tablica 1
Zastosowanie metod nieostrego maskowania do obróbki obrazów

Metody i parametry	Obróbka obrazu <i>Lena</i> (rys. 2a)	Obróbka obrazu <i>Pout</i> (rys. 2b)	Obróbka obrazu <i>Ca-pitol</i> (rys. 2c)
metoda (2): $C_{gen} = 0,36$ $C_{gen} = 0,16$ $C_{gen} = 0,23$	a) 	b) 	c) 
metoda (4): $C_{gen} = 0,35$ $C_{gen} = 0,16$ $C_{gen} = 0,23$	d) 	e) 	f) 
metoda (16): $C_{gen} = 0,47; A$ $C_{gen} = 0,36; A$ $C_{gen} = 0,37; A$	g) 	h) 	i) 
metoda (17): $C_{gen} = 0,50; A$ $C_{gen} = 0,37; A$ $C_{gen} = 0,38; A$	j) 	k) 	l) 
metoda (16): $C_{gen} = 0,44; B$ $C_{gen} = 0,30; C$ $C_{gen} = 0,48; D$	m) 	n) 	o) 
metoda (17): $C_{gen} = 0,47; B$ $C_{gen} = 0,40; C$ $C_{gen} = 0,48; D$	p) 	q) 	r) 

5. Wnioski

Zaproponowane metody wykorzystania kontrastu stosowanego przy nieostrym maskowaniu obrazów potwierdziły skuteczność takiego podejścia. Wykorzystanie optymalizacji funkcji transformacji niskoczęstotliwościowej składowej na podstawie wyboru przetwarzania z maksymalną entropią rozmytą pozwoliło podwyższyć efektywność nowych metod zwiększenia rozróżnienia szczegółów obrazów. Przeprowadzone badania potwierdziły również wyższą czułość nowych metod nieostrego maskowania w porównaniu ze znanymi podejściami. Pozwala to tworzyć w przyszłości nowe modyfikacje metod nieostrego maskowania na podstawie wykorzystania zarówno stosowanego kontrastu lokalnego, jak i innych oceny lokalnego średniego obrazu, takich jak mediana i statystyki rankingowe.

Literatura

- [1] Beghdadi A., Negrate A.L.: *Contrast enhancement technique based on local detection of edges*. Comput. Vision Graphics Image Process, vol. 46, 1989, 172–174
- [2] Dale-Jones R., Tjahjadi T.: *A study and modification of the local histogram equalization algorithm*. Pattern Recognition, No. 9, vol. 26, 1993, 1373–1381
- [3] Dash L., Chatterji B.N.: *Adaptive contrast enhancement and de-enhancement*. Pattern Recognition, No. 4, vol. 24, 1991, 289–302
- [4] Cheng H.D., Xu H.: *A novel fuzzy logic approach to contrast enhancement // Pattern recognition*. No. 5, vol. 33, 2000, 809–819
- [5] Frei W.: *Image enhancement by histogram hyperbolization*. Comp. Graph. & Image Proc. No.3, vol. 6, 1977, 286–294
- [6] Gonzalez R.C., Woods R.E.: *Digital Image Processing*. Prentice Hall, 2002
- [7] Gordon R., Rangayyan R.M.: *Feature enhancement of film mammograms using fixed and adaptive neighborhood*. Applied Optics, vol. 23, 1984, 560–564
- [8] Grundland M., Dodgson N.A.: *Interactive contrast enhancement by histogram warping*. Computational Imaging and Vision, Springer, New York, vol 32, 2005, 832–838
- [9] Hall E.L.: *Almost Uniform Distributions for Computer Image Enhancement*. IEEE Trans. on Computers. No. 2, vol. C-23, 1974, 207–208
- [10] Hummel R.A.: *Histogram modification techniques*. Computer Graphics & Image Processing, No. 4, vol. 3, 1975, 209–224
- [11] Kim V., Yaroslavskii L.: *Rank algorithms for pictures processing*. Comput. Vision Graphics Image Process. No. 2, vol.35, 1986, 234–258
- [12] Laine A.F., Schuler S., Fan J., Huda W.: *Mammographic feature enhancement by multiscale analysis*. IEEE Trans. on Medical Imaging, vol. 13, 1994, 725–740
- [13] Mather P.M.: *Computer processing of remotely-sensed images*. John Wiley & Sons, Chichester
- [14] Narendra P.M., Fitch R.C. 1981: *Real-time contrast enhancement*. IEEE Trans. on Pattern Analysis and Machine Intelligence, No. 3, vol. 3., 1987, 655–661
- [15] Pirsch P.: *Architectures for Digital Signal Processing*. John Wiley & Sons, New York, 1998
- [16] Pratt W.K.: *Digital Image Processing*. John Wiley and Sons, 2001
- [17] Ramponi G., Polesel A.: *Rational unsharp masking technique*. Journal of Electronic Imaging, No. 2, 1998, 333–338
- [18] Saitoh F.: *Image contrast improvement based on differential Gray-levels Histogram*. The Journal of the Institute of Image Electronic Engineers of Japan, No. 2 vol. 126-C, 2006, 228–236
- [19] Stark J.A.: *Adaptive image contrast enhancement using generalizations of histogram equalization*. IEEE Trans. on Image Processing, No. 5, vol. 9, 2000, 889–896

-
- [20] Stark J.-L., Murtagh F., Candes J., Donoho D.L.: *Gray and color image contrast enhancement by curvelet transform*. IEEE Trans. On Image Processing, No. 6, vol. 12, 2003, 706–717
- [21] Trahanias P.E., Venetsanopoulos A.N.: *Color image enhancement through 3-D histogram equalization*. Proceedings of 11-th International Confer. on Pattern Recognition. Vol. 3, 1992, 545–548
- [22] Vorobel R.: *Nonlinear transformation of images with linear definition of contrast*. The Third All-Ukrainian International Conference Signal/Image Processing and Pattern Recognition. Kyjiv, Ukraine, November 26–30, 1996, 194–196
- [23] Vorobel R.A.: *Kernels for the evaluations of the image element contrast*. Information Extracting and Processing. No. 11(97), 1997, 96–100
- [24] Vorobel R.A.: *Some approach to construction methods of image unsharp masking*. Mathematical Machine and Systems, No. 2, 1998, 53–60
- [25] Vorobel R.A.: *Perception of the subject images and quantitative evaluation of their contrast based on the linear description of elements of contrast*. Bulletin of the Ukrainian Academy of Sciences. No. 9, 1998, 103–108
- [26] Vorobel R.: *Local contrast as a base for construction of methods of the image improvement*. Information Extracting and Processing, 15(91), 2001, 154–163
- [27] Vorobel R.: *Kontrast lokalny jako podstawa konstrukcji składowych wysoko-częstotliwościowych obrazu*. Automatyka, t. 3, 2003, 525–535
- [28] Vorobel R., Stobińska M.: *Dwuskładnikowy multiplikatywny model obrazu jako podstawa dla wzmacniania kontrastu*. 4-a Ukraińsko-Polska konferencja Mechanika środowiska, metody informatyczne, symulacje. Lwów, 24–26 czerwca 2004 r. Cz. 2, 156–164
- [29] Wiatr K.: *Akceleracja obliczeń w systemach wizyjnych*. Warszawa, WNT 2003
- [30] Yang X.D., Xiao Q., Raafat H.: *Direct Mapping between histograms: An improved interactive image enhancement method*. IEEE Intern. Confer. on Systems, Man and Cybernetics, vol. 1, 1991, 243–247
- [31] Yaroslavskii L.P.: *Applied Problems of Digital Optics*. Academic Press, New York 1986