

Mirosław FORCZEK

Politechnika Śląska, Instytut Informatyki

MODELOWANIE FUNKCJI ODLEGŁOŚCI BARW Z UWZGLĘDNIENIEM ZNAJOMOŚCI OCZEKIWANYCH BARW OBIEKTÓW W ZASTOSOWANIU DO SEGMENTACJI OBRAZÓW KOLOROWYCH

Streszczenie. Znajomość dodatkowych informacji o zawartości analizowanego obrazu - np.: spodziewany kolor obiektu i kolory obiektów tła, umożliwia dodatkową zmianę własności funkcji odległości, tak aby pozwalała uzyskać jeszcze lepszą segmentację. Przedstawione zostały modele odległości barw wykorzystujące różną liczbę próbek kolorów obiektu oraz tła. Uzyskane z zastosowaniem nowych funkcji rozkłady odległości charakteryzują się większym kontrastem, co poprawia ostateczny wynik segmentacji.

MODELING OF THE COLORS DISTANCE FUNCTION WITH USE OF KNOWLEDGE ABOUT EXPECTED COLORS OF OBJECTS, IN APPLICATION FOR COLOR PICTURES SEGMENTATION

Summary. The additional knowledge about the analyzed picture contents - for example the expected color of the object and colors of background objects, makes it possible to change the feature of distance function in such a way, that a better segmentation results can be achieved. Some models of distances of colors were presented, that use different number of object and background colors samples. The distance distributions produced with the use of new functions have higher contrast, what improves the final result of segmentation.

1. Problem segmentacji obrazu

Pierwszym etapem w przetwarzaniu pojedynczego, statycznego obrazu (przy rozpoznawaniu przedstawionych obiektów) jest ekstrakcja obszarów obrazu, w których widoczne są obiekty będące przedmiotem rozpoznawania.

Czynność ta określana jest jako *segmentacja obrazu*.

Istotą *segmentacji* jest wyznaczenie obszarów jednorodnych według ustalonego kryterium [1]. Kryterium tym jest oczekiwany zakres wartości wybranego parametru dla wszystkich elementów obszaru, przy czym zakres ten może być zdefiniowany wprost lub jako maksymalna dopuszczalna odchyłka od wartości przeciętnej.

Podział istniejących technik segmentacji przedstawiony w [1] obejmuje:

- segmentację przez podział obszaru,
- segmentację przez rozrost obszaru,
- segmentację metodą wykrywania krawędzi.

W dwóch pierwszych metodach decyzja o podziale obszaru lub grupowaniu obszarów sąsiednich oparta jest na teście podobieństwa własności pikseli w tych obszarach. Trzecia metoda stosuje operator gradientu na wybranej własności pikseli. Najczęściej wykorzystywane własności pikseli to: kolor lub jasność. Powyższe metody opierają się więc na ilościowym określeniu podobieństwa (lub różnicy) pomiędzy pikselami. W tym celu wyznaczana jest po prostu różnica arytmetyczna wartości wybranego parametru (np.: koloru, nasycenia lub jasności).

Przedstawione dalej rozważania dotyczą konstrukcji bardziej złożonych algorytmów określania różnic pomiędzy pikselami. W szczególności zdefiniowana zostanie *funkcja odległości barw*, której własności uwzględniają dodatkową wiedzę o oczekiwanej kolorystyce analizowanego obrazu. Funkcja ta może zastąpić zwykłą różnicę wartości we wspomnianych wyżej metodach segmentacji. W celu uproszczenia dalszych rozważań przyjmuje się, że analizowany obraz zawiera jeden obszar obiektu (którego wyznaczenie będzie właśnie celem segmentacji) oraz jeden lub więcej obszarów tła.

W wyniku procesu segmentacji dla każdego elementu obrazu zostanie wyznaczona wartość funkcji przynależności μ do obszaru obiektu.

$$\mu(x_{ij}) = \begin{cases} 0 & \text{jeśli } x_{ij} \notin O \\ 1 & \text{jeśli } x_{ij} \in O \end{cases}$$

x_{ij} – element obrazu,

O – obszar obiektu.

(1)

Proces zamiany wartości punktów obrazu na odpowiadające im wartości funkcji przynależności μ (zdefiniowanej jak powyżej) nazywany jest *binaryzacją* obrazu [4].

W praktyce, aby wyznaczyć funkcję przynależności, konieczne jest określenie w sposób ilościowy różnicy (lub podobieństwa) pomiędzy dwoma wybranymi punktami obrazu. Przykładowo, dla obrazów monochromatycznych jako różnicę pomiędzy dwoma punktami obrazu przyjmuje się zwykle różnicę ich jasności [1],[6].

W przypadku obrazów kolorowych możliwe jest wykorzystanie do tego celu barwy punktów, należy więc określić w sposób ilościowy różnicę dwóch barw. Różnica taka nazywana jest *odległością barw* (zdefiniowaną w określonym modelu barw). Model barw definiuje ilość oraz rodzaj parametrów opisujących jednoznacznie barwę. Definiowane są również dopuszczalne zakresy wartości poszczególnych parametrów, a także sposób odwzorowania parametrów w wybranej przestrzeni. Najczęściej stosowane są przestrzenie trójwymiarowe, przy czym przyjęty układ współrzędnych może być inny niż prostokątny. Wszystkie możliwe do reprezentacji przez model barwy są ułożone systematycznie w takiej przestrzeni (określonej dalej jako *przestrzeń barw*) tworząc tzw. *bryłę barw*. Przestrzeń barw pozwala na ilościowe określenie różnicy pomiędzy dwoma barwami poprzez wyznaczenie odległości pomiędzy punktami reprezentującymi te barwy. W pracy [2] omówione są popularne modele barw stosowane w technice komputerowej. W pracy [6] omówiona została przydatność wybranych modeli barw jako podstawy do zdefiniowania *odległości barw* oraz funkcji przynależności μ .

W wyniku zamiany wartości punktów obrazu na odpowiadające im odległości barw od wybranej barwy wzorcowej uzyskany zostanie obraz monochromatyczny. Obraz taki nazywany będzie dalej *rozkładem odległości* lub *mapą odległości*.

1.1. Modele funkcji odległości

W opracowaniu [6] omówione zostały modele barw wprowadzające funkcję odległości barw, co pozwala wstępnie w sposób ilościowy określać różnice pomiędzy dwoma punktami obrazu. Tak otrzymany rozkład odległości może być bezpośrednio przedmiotem procesu binaryzacji, czyli jednoznacznego określenia przynależności do obiektu lub tła każdego punktu obrazu (jeśli obiektów jest więcej niż jeden, proces ten określany jest również jako *etykietowanie* [1]).

Znajomość dodatkowych informacji o zawartości analizowanego obrazu, np.: spodziewany kolor obiektu i kolory obiektów tła, umożliwia dodatkową zmianę własności funkcji odległości, tak aby pozwalała uzyskać ona jeszcze lepszą segmentację. Przedstawione dalej modele opierają się na określeniu w przestrzeni barw obszarów właściwych dla obiektu i tła, oraz na dynamicznej zmianie miary odległości barw w zależności od ich położenia względem

takich obszarów. Przez dynamiczną zmianę odległości określana jest taka zmiana własności funkcji, aby odległości pomiędzy barwami obiektu i tła uzyskały możliwie duże wartości (w idealnym przypadku – nieskończone). Odległości pozostałych barw mierzone względem barw obiektu lub tła powinny istotnie zależeć od proporcji analogicznych odległości w oryginalnym modelu barw.


1.2. Model 1-punktowy

Model ten odpowiada dokładnie zastosowaniu wyłącznie wybranego modelu koloru do uzyskania mapy odległości barw. Jediną wymaganą informacją jest oczekiwana wartość parametrów barwy obiektu, co pozwoli na określenie położenia centralnego punktu b_o w przestrzeni barw.

Jeśli założyć, iż do tak uzyskanego rozkładu odległości zastosowany zostanie proces binaryzacji ze stałym progiem (określonym za pomocą wartości granicznej $d_{o\max}$), to barwy leżące wewnątrz koła¹ (na rys. 1) o promieniu $d_{o\max}$ zostaną przypisane do obiektu, natomiast barwy leżące na zewnątrz do obszaru tła

Ilustruje to rys. 1, który w uproszczeniu przedstawia 2-wymiarową przestrzeń barw z zaznaczonym punktem oczekiwanej barwy obiektu oraz zasięgiem dopuszczalnej odchyłki. Wyznaczone w ten sposób koło reprezentuje zbiór barw przypisywanych obiektowi.


Punkt oczekiwanej barwy można wyznaczyć próbując wybrany arbitralnie element obrazu, o którym wiadomo, iż należy do obszaru obiektu, lub też uśredniając wartości kilku próbek ze znanego obszaru. Jeśli kształt zbioru barw występujących rzeczywiście w obiekcie jest inny niż okrąg, wtedy nie można dobrać właściwego progu binaryzacji bez wprowadzenia zakłóceń do wyniku segmentacji. Sytuację tę ilustruje rys. 2: zbyt duży próg spowoduje zaliczenie do obszaru obiektu punktów obrazu należących w rzeczywistości do tła, zbyt mały próg spowoduje odrzucenie części punktów obiektu do obszaru tła. (Oczywiście warunkiem jest występowanie w obrazie punktów o danej barwie).



Rys. 1. Model 1-punktowy

Fig. 1. 1-point model

¹ rys. 1 jest uproszczony do 2 wymiarów, dla przestrzeni barw 3-wymiarowej będzie to kula.



Rys. 2. Model 1-punktowy dla zbioru o owalnym kształcie

Fig. 2. 1-point model for oval shape set

1.3. Model z 1 zbiorem

Wprowadzony poprzednio model 1-punktowy, w którym punkt określony został za pomocą uśrednienia pewnej liczby rzeczywistych próbek, jest tani obliczeniowo - wybrany punkt obrazu jest porównywany tylko z jednym punktem wzorcowym.

Jednak zastąpienie zbioru wartości przez jedną uśrednioną wartość powoduje utratę informacji o kształcie zbioru. Alternatywą jest posługiwanie się w procesie wyznaczania odległości całym zbiorem n próbek. W takim przypadku każdy punkt obrazu jest porównywany n razy z każdą próbką, a jako wynik końcowy przyjmowana jest najmniejsza ze zmierzonych odległości. Odpowiednią formułę przedstawia wzór (2), ilustrację tak zdefiniowanej przestrzeni odległości przedstawia rys. 3. Jak widać, już sam rozkład odległości adaptuje się do kształtu zbioru, tak że nawet przy stałym progu binaryzacji można uzyskać lepszą segmentację. Inne możliwe do zastosowania techniki to np.: *binaryzacja warunkowa* lub *binaryzacja wielokryterialna* [1].

$$d_{1s}(x_{ij}, b_o) = \min_{l=1..n} (d(x_{ij}, b_{o_l}))$$

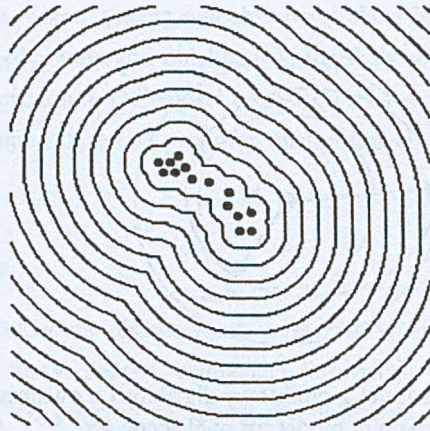
b_o - zbiór próbek barw obiektu,

b_{o_l} - próbka barwy obiektu,

n - liczba próbek,

$d()$ - wybrana miara odległości barw.

(2)



Rys. 3. Rozkład funkcji odległości d_{1n} dla zbioru barw (linie wyznaczają powierzchnie stałej odległości)


Fig. 3. Distance function d_{1n} distribution for colors set (the lines shows constant distance surfaces)

Różnicę pomiędzy punktem uśrednionym a zbiorem punktów w modelu odległości obrazuje przykład segmentacji - rys. 4. Z obszaru punktów oznaczonego okręgiem wyznaczona została wartość średnia barwy dłoni b_o dla modelu 1-punktowego oraz zbiór próbek barw dłoni $b_o = \{\dots\}$ dla modelu ze zbiorem punktów. Następnie dla każdego punktu - rys. 4 - wyznaczona została wartość odległości w obu modelach. Uzyskane w ten sposób mapy odległości zostały poddane binaryzacji z ustalonym progiem - punkty o odległości mniejszej niż wartość progowa uzyskały wartość 1, pozostałe punkty uzyskały wartość 0. Wartość progowa została ustalona indywidualnie dla każdego obrazu na drodze eksperymentów w sposób interakcyjny.

Rysunki 5a1), 5b1) są mapami odległości uzyskanymi w modelu 1-punktowym i z 1 zbiorem, rys. 5a2), 5b2) przedstawiają wynik końcowy po binaryzacji map.

Obszar dłoni na ilustracji 5b1) jest wyraźnie jaśniejszy niż na 5a1) (obliczone odległości barw są mniejsze), ponadto jest on bardziej jednorodny - duży fragment obszaru dłoni (na ilustracji obszar biały) uzyskał wartość odległości bliską zero. Niepożądanym efektem jest natomiast skrócenie odległości barw tła do zbioru barw obiektu (wyraźne rozjaśnienie tła na ilustracji 5b1) - w konsekwencji binaryzacja map odległości ze stałym progiem daje tutaj zbliżone jakościowo wyniki.

Problemem modelu z 1 zbiorem jest jego złożoność obliczeniowa, która dla n próbek w zbiorze barw obiektu jest n -krotnie większa od złożoności dla modelu 1-punktowego. Stąd powstaje konieczność minimalizacji liczby próbek w zbiorze barw bez jednoczesnej utraty jakości jego odwzorowania.



Rys. 4. Obraz barwny (oznaczone punkty próbek barw dłoni)

Fig. 4. Color picture (marked samples points of hand's colors)

	1) Mapa odległości	2) Wynik binaryzacji	3) Złożenie maski z obrazem
a)			
1 punkt			
b)			
2 punkty			

Rys. 5. Wyniki segmentacji rysunku 4

Fig. 5. The results from segmentation of the figure 4

Dla celów dalszych rozważań wprowadzone zostaną definicje *kształtu zbioru barw obiektu* $K(o)$ oraz *zmienności kształtu* $dK(o)$:


Kształtem $K(o)$ zbioru barw obiektu o jest brzeg najmniejszej figury zawierającej wszystkie punkty barw możliwych do zaobserwowania na powierzchni obiektu przy ustalonych warunkach akwizycji obrazu¹.

¹ Przez ustalone warunki akwizycji obrazu rozumiany jest niezmienny w czasie zestaw czynników zewnętrznych (np.: oświetlenie sceny) oraz parametrów akwizycji (np.: regulacja jasności).

Zmiennością kształtu $dK(o)$ zbioru barw obiektu o w danym punkcie x należącym do kształtu zbioru jest wartość pochodnej kąta nachylenia stycznej do kształtu zbioru w punkcie x .

Należy oczekiwać, że dla obiektów o jednolitej i naturalnej fakturze (np.: skóra) kształt zbioru barw będzie ciągłą i różniczkowalną krzywą.

Jeśli założyć, że zbiór barw ma kształt wypukły, to do poprawnego jego odwzorowania wystarczą tylko punkty leżące na jego obrzeżu, które wyznaczają granicę zbioru. Dokładność wyznaczenia granicy zależy od gęstości punktów próbek wzdłuż obrzeża - powinna być ona proporcjonalna do zmienności kształtu zbioru. Punkty leżące we wnętrzu tak wyznaczonego obszaru mogą zostać pominięte podczas obliczania odległości. Idee tę ilustruje rys. 6 - pomimo usunięcia punktów leżących wewnątrz zbioru rozkład odległości pozostaje niezmienny (w istotny sposób). Wnętrze skończonego zbioru próbek można zdefiniować jako podzbiór tych próbek, których punkty leżą we wnętrzu najmniejszego wypukłego wielokąta zawierającego cały zbiór próbek.



Rys. 6. Rozkład funkcji d_1 dla zbioru reprezentujących brzeg zbioru: a) dla 23 próbek, b) dla 12 próbek

Fig. 6. Function d_1 distribution for set of samples from set's border: a) for 23 samples, b) for 12 samples

Opracowanie algorytmu dokonującego redukcji próbek w zbiorze barw oraz modyfikacja algorytmu wyznaczania odległości, tak aby dla barw leżących wewnątrz zbioru wyznaczana była zerowa odległość, mogą być przedmiotem dalszych prac.

1.4. Modele: 2-punktowy i z 2 zbiorami . Algorytm "czarnej dziury"

Wadą poprzednich modeli jest wykorzystywanie jedynie informacji o oczekiwanej barwie obiektu. Znajomość spodziewanej barwy tła okazuje się dodatkowo pomocna w ocenie "bliskości" wybranego punktu obrazu względem barw obiektu.

Oczekiwana barwa tła b_t reprezentowana jest dodatkowym punktem (pierwszym jest punkt oczekiwanej barwy obiektu b_o) w przestrzeni barw. Rozkład odległości w tak zdefiniowanym modelu powinien spełniać warunek, aby odległość pomiędzy barwami b_o i b_t była możliwie duża.

Taka modyfikacja funkcji odległości powoduje wyraźne pogłębienie kontrastu dla obszarów obiektu i tła na mapie odległości, co ułatwia binaryzację.

Możliwą do zastosowania formułę przedstawia wzór (3). Funkcja $d_{2p}(x_{ij})$ reprezentuje odległość punktu x_{ij} względem punktu b_o .

$$d_{2p}(x_{ij}) = \frac{d_o(x_{ij})}{1 + d_o(x_{ij}) + d_t(x_{ij})}, \quad d_o(x_{ij}) = d(x_{ij}, b_o), \quad d_t(x_{ij}) = d(x_{ij}, b_t) \quad (3)$$

gdzie:

b_o – barwa obiektu,


b_t – barwa tła.

Ilustrację modelu przedstawia rys. 7.

Barwę tła można również wykorzystać w modelu ze zbiorem barw - otrzymamy wtedy dwa zbiory próbek: $b_o = \{b_{o_1}, \dots, b_{o_n}\}$ dla barw obiektu oraz $b_t = \{b_{t_1}, \dots, b_{t_m}\}$ dla barw tła. Formuła odległości barwy punktu obrazu przyjmuje wtedy postać:

$$d_{2s}(x_{ij}) = \frac{d_{os}(x_{ij})}{1 + d_{os}(x_{ij}) + d_{ts}(x_{ij})}, \quad d_{os}(x_{ij}) = d_{1s}(x_{ij}, b_o), \quad d_{ts}(x_{ij}) = d_{1s}(x_{ij}, b_t) \quad (4)$$

Model taki (z dwoma zbiorami barw - obiektu i tła) łączy w sobie zalety wykorzystania zbioru próbek oraz informacji o barwie tła. Ponieważ w rzeczywistych scenach analizowany obiekt bywa otoczony kilkoma obszarami o wyraźnie różnych barwach, celowe staje się wprowadzenie większej liczby zbiorów barw dla tła. Modyfikacji ulega wtedy formuła wyznaczania odległości barwy punktu obrazu (4): zbiór b_t zastępujemy sumą kilku zbiorów b_{t_l} , $l=1..m$, po czym stosujemy wzór (5). Analogiczne rozszerzenie możliwe jest dla barw obiektu, jest to jednak najczęściej niepotrzebne - jeśli obiekt ma barwę jednolitą.



Rys. 7. Rozkład funkcji d_{2p} , punkt b_o oznaczony kolorem zielonym (z prawej), punkt b_l oznaczony kolorem czerwonym (z lewej): a) linie wyznaczają powierzchnie stałej odległości, b) jasne obszary oznaczają punkty o małej odległości, ciemniejsze o większej odległości

Fig. 7. Function d_{2p} , distribution point b_o marked as green (on the right), point b_l marked as red (on the left): a) the lines shows constant distance surfaces, b) light areas are points of small distance, dark areas are points of big distance

$$d_{ns}(x_{ij}) = \frac{d_{os}(x_{ij})}{1 + d_{os}(x_{ij}) + d_{ls}(x_{ij})}, \quad d_{os}(x_{ij}) = \min_{l=1, on}(d_{ls}(x_{ij}, b_{ol})), \quad d_{ls}(x_{ij}) = \min_{l=1, ln}(d_{ls}(x_{ij}, b_{ll})) \quad (5)$$

on, ln - ilości zbiorów próbek dla obiektu oraz tła.

Przykłady wykorzystania modeli z więcej niż jednym zbiorem barw ilustruje segmentacja rysunku 8. Oprócz obszaru dłoni występują tu obszary: ściany, garnitur, koszuli oraz krawatu. Wszystkie te obszary składają się na tło obrazu. W szczególności barwa obszaru koszuli w istotnym stopniu różni się od pozostałych, dlatego nie jest możliwe poprawne opisanie barw tła za pomocą jednego tylko zbioru próbek (pochodzących z wybranego obszaru - np. obszaru garnituru).

Rysunki 9a) zostały uzyskane w wyniku zastosowania modelu z 1 zbiorem o barw obiektu, obrazy 9b) powstały przy wykorzystaniu modelu ze zbiorem o i zbiorem $b1$ barw tła, obrazy 9c) powstały z użyciem modelu wykorzystującego zbiory o , $b1$ oraz $b2$.

Jak widać, dodanie tylko zbioru $b1$ usunęło większość źle uprzednio sklasyfikowanych punktów z obszaru garnituru. Pozostały obszar koszuli nadal nie został zaliczony do tła (jako zbyt zbliżony do barw dłoni).



Rys. 8. Obraz barwny (oznaczone punkty próbek)

Fig. 8. Color picture (marked sample points)

	Mapa odległości	Wynik binaryzacji	Złożenie maski z obrazem
a) 1 zbiór			
b) 2 zbiory			
c) 3 zbiory			

Rys. 9. Wyniki segmentacji rysunku 8

Fig. 9. The results from segmentation of the figure 8

Wynika to z faktu, iż koszula stanowi w tym przypadku zupełnie odrębny obszar tła niż garnitur (duża różnica barw). Tło składa się więc z kilku mocno się różniących obszarów, które nie mogą zostać opisane tylko jednym zbiorem *b1*. Dodanie do modelu zbioru *b2* reprezentującego barwy koszuli pozwoliło już skuteczniej odrzucić punkty tego obszaru - ubocznym efektem jest odrzucenie również pewnej liczby punktów z obszaru dłoni. Jest to skutkiem słabej jakości obrazu wejściowego, w którym zdigitalizowane barwy zostały rozmyte

przez przetwornik A/C. Eliminacja tego efektu jest zadaniem dla algorytmów **przekształceń morfologicznych** [1].

2. Podsumowanie

Jak widać z powyższych rozważań, dodatkowa wiedza o spodziewanych barwach obserwowanej sceny pozwala znacznie zwiększyć efektywność segmentacji poprzez zmianę rozkładu funkcji odległości barw. Z tego względu celowe jest dalsze badanie własności zaproponowanych modeli oraz poszukiwanie dodatkowych rozwiązań optymalizujących ich działanie. Szczególną uwagę należy zwrócić na problem optymalnej reprezentacji zbioru próbek, sygnalizowany w powyższym tekście. Ponadto ciekawym zagadnieniem jest automatyczna aktualizacja zestawu próbek w czasie segmentacji kolejnych klatek obrazu wideo. Cecha ta pozwoliłaby na samodzielne doskonalenie się algorytmu w trakcie działania. Uzyskana zostałaby również odporność na stopniową zmianę kolorystyki sceny.

LITERATURA

1. Tadeusiewicz R., Korohoda P.: Komputerowa analiza i przetwarzanie obrazów. Wydawnictwo Fundacji Postępu Telekomunikacji. Kraków 1997.
2. Praca zbiorowa pod redakcją J. Zabrodzkiego: Grafika komputerowa - metody i narzędzia. Wydawnictwa Naukowo-Techniczne. Warszawa 1994.
3. The Munsell System of Color Notation. Munsell Corporation. URL: <http://www.munsell.com>.
4. Luchowski L.: Segmentacja płaskich scen binarnych w warunkach nierównomiernego oświetlenia. Gliwice 1994.
5. Watkins Ch. D., Sadun A., Marenka S.: Nowoczesne metody przetwarzania obrazu. WNT, Warszawa 1995.
6. Forczek M.: Zastosowanie segmentacji obrazu do ekstrakcji obszaru dłoni z obrazu wideo, z wykorzystaniem informacji o barwie. Raport z prac BW. Gliwice 1998.

Recenzent: Dr inż. Leszek Luchowski

Wpłynęło do Redakcji 8 marca 1999 r.

Abstract

The first stage of objects recognition is extraction of picture areas (picture segmentation). As result, for each element of picture, there will be defined value for function $\mu(1)$, the membership of object area function. In order to calculate the membership function, we have to define the difference between two particular points from picture. For monochromatic pictures, the difference in lightness is normally used [1],[6]. For colorful pictures, such difference is called *colors distance*. Additional information like: expected color of object and colors of background objects, makes it possible to change the feature of distance function. Presented models are based on defining areas for object and background in the colors space, and on dynamical change of distance unit for colors. The distance change depends on location of the color in relation to areas of object and background colors.

The 1-point model requires only defining the central point b_o in colors space (fig. 1). If a shape of set that contains real colors from the object is different from circular, then it is impossible to choose the right threshold level for binarization without causing errors in the segmentation result (fig 2).

Using one average value in 1-point model causes the loss of information about the shape of set. The alternative is to use the whole set of n samples (model with 1 set) (2), (fig. 3). Figures 5a1), 5b1) are distance maps produced with use of 1-point model and model with 1 set, figures 5a2), 5b2) shows the final results after maps binarization. The problem of model with 1 set is its computational complexity, that for n samples is n times greater than for 1-point model. Because of this, it is needed to reduce the number of samples without loss of the representation quality of the set (fig. 6). Development of the algorithm making such reduction of samples in colors set, can be the focus of future work.

Adding the expected color of background (2-points model) noticeable increases contrast between object and background areas in the distance map (3) (fig. 7). The color of background can be also used in the model with colors set (model with 2 sets) (4). Because in real scenes, the analyzed object is surrounded by a few areas with noticeable different colors, it makes sense to introduce the multiple number of background colors sets (5).