

Mirosław FORCZEK

Politechnika Śląska, Instytut Informatyki

MODELE BARW W ALGORYTMACH SEGMENTACJI OBRAZÓW KOLOROWYCH

Streszczenie. Algorytmy segmentacji obrazów kolorowych są rozszerzeniem algorytmów dla obrazów monochromatycznych. Wykorzystują one atrybuty decyzyjne: wartościowe oraz przestrzenne. Głównym problemem przy adaptacji tych algorytmów jest wykorzystanie barwy jako atrybutu wartościowego. Artykuł stanowi przegląd istniejących modeli dla wyznaczenia ilościowej różnicy barw. Przeprowadzono analizę cech tych modeli oraz zaproponowano postać i właściwości nowego modelu barw.

COLOR SPACES IN COLOR IMAGES SEGMENTATION ALGORITHMS

Summary. The color image segmentation algorithms are an extension of those for monochromatic images. They use the attributes of decision: valuable and spatial ones. The major problem in adaptation of the algorithms is the usage of color as a valuable attribute. This paper describes the existing color spaces for evaluating the quantitative color difference. There is the analysis of these models features done and the features for a new color space are proposed.

1. Wstęp

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

Aby możliwe było stwierdzenie, czy wybrane elementy obrazu tworzą spójny obszar jednorodny, należy uwzględnić dwa rodzaje ich atrybutów:

- **wartościowe:** podobieństwo wybranych parametrów (np. kolor, jasność),
- **przestrzenne:** względne położenie w obrazie.

Popularne algorytmy segmentacji wykorzystują kombinację obu rodzajów atrybutów jako podstawę swego działania. Techniki segmentacji przez podział obszaru (ang. *region-splitting*) oraz przez rozrost obszaru (ang. *region-growing*) uwzględniają atrybuty przestrzenne za pomocą odpowiedniej konstrukcji samego algorytmu, zaś atrybuty wartościowe są porównywane za pomocą odpowiednich modeli statystycznych [1]. Inne algorytmy traktują atrybuty wartościowe jako funkcję atrybutów przestrzennych [10],[15],[16] – najczęściej jest to dwuargumentowa funkcja współrzędnych (x,y) punktu obrazu na jednowymiarową wartość jasności tego punktu. Funkcja taka jest często przedstawiana jako powierzchnia jasności punktów obrazu w trójwymiarowym układzie przestrzennym. Dla tak określonej powierzchni możliwe jest np. wyznaczenie powierzchni progu decyzyjnego [10] (ang. *threshold surface*) dla segmentacji pojedynczego obiektu względem tła – tzw. **binaryzacji** obrazu [1],[10]. Inne stosowane metody to określenie funkcji prawdopodobieństwa przynależności poszczególnych punktów do danego obiektu [16], lub wyznaczenie atrybutów decyzyjnych przez superpozycję fragmentu powierzchni z wybraną funkcją charakterystyczną (tzw. jądrem filtru, ang. *filter kernel*) [15].

2. Segmentacja obrazów kolorowych

W przypadku obrazów kolorowych naturalnym wyborem dla atrybutów wartościowych są parametry związane z barwą elementów obrazu. Jest oczywiste, że barwa pozwala łatwiej rozróżnić poszczególne obszary rzeczywistej sceny niż np. jasność elementów. W wielu przypadkach istotne jest, aby segmentacja była w miarę możliwości niezależna od danego oświetlenia sceny. Wartości parametrów opisujących barwę powinny więc zależeć przede wszystkim od jej odcienia i być niezależne od jasności barwy. Ponadto często nie można przyjmować żadnych założeń co do kolorystyki tła sceny, ewentualnie koloru samego obiektu. Stąd parametry barwy powinny umożliwiać łatwe rozróżnienie dowolnej pary kolorów. Oczywiście warunkiem skuteczności segmentacji jest kontrastowość obszarów obiektu i tła. Przez tło rozumiany jest tutaj zbiór pozostałych obszarów występujących w obrazie, innych niż obszar wybranego obiektu. Tak zdefiniowane tło może nie być pojedynczym obszarem jednorodnym, jest natomiast różnicą obrazu i obszaru obiektu.

Konkretny zestaw parametrów opisujących barwę wraz z regułami ich pozyskiwania oraz porównywania określa dany **model barw**. Istnieją różne modele barw stosowane w grafice komputerowej [2] oraz wizji [6]. Model barw określa tzw. **przestrzeń barw**, w której wszystkie możliwe do reprezentacji kolory są odpowiednio rozmieszczone, tak aby możliwe

było wyznaczenie ilościowej różnicy dwóch kolorów. Różnica taka będzie dalej określana jako **odległość kolorów**. Odległość kolorów może zastąpić różnicę jasności w algorytmach segmentacji obrazów monochromatycznych, adaptując je w ten sposób do pracy z obrazami kolorowymi.

Wybór modelu barw może być istotnym czynnikiem decydującym o zdolności algorytmu do rozróżniania i segmentacji różnokolorowych obszarów obrazu. Wybór konkretnego modelu może też mieć wpływ na efektywny koszt algorytmu, na który składają się przekształcenia związane bezpośrednio z transformacją barwy na parametry modelu, jak również z ewentualną konwersją danych pochodzących z dostępnego urządzenia akwizycji obrazu do pożądanego formatu.

W punkcie 3 omówione zostaną wybrane modele barw z uwzględnieniem ich zastosowania w procesie segmentacji. Punkt 4 zawiera wyniki testu rozróżniania kolorów dla modeli wybranych spośród uprzednio przedstawionych. Punkt 5 jest próbą analizy cech istniejących modeli oraz określenia cech modelu przeznaczonego do segmentacji.

3. Modele barw

3.1. Model luminancyjny

Luminancja określa liczbowo jasność elementu obrazu. Jeśli dysponujemy kamerą „czarno-białą”, otrzymujemy wprost sygnał luminancji do dalszego przetwarzania. Luminancję można również wyznaczyć z obrazu kolorowego, stosując popularny w systemach telewizji wzór [2]:

$$y'(r', g', b') = 0,299r' + 0,587g' + 0,114b' \quad , \quad r', g', b' \in \langle 0; 1 \rangle$$

r', g', b' – składowe RGB barwy

(1)

W typowej reprezentacji obrazu czarno-białego w komputerze wartość luminancji reprezentowana jest w przedziale dyskretnym $\langle 0; 255 \rangle$. W ten sposób mamy do czynienia z modelem jednowymiarowym. Odległość kolorów dwóch elementów obrazu jest więc określona wzorem:

$$d(x_{ij}, x_{km}) = |y'(x_{ij}) - y'(x_{km})|$$
(2)

Wybierając spodziewaną wartość y'_o dla obszaru obiektu, można zdefiniować funkcję odległości dla pojedynczego elementu obrazu względem y'_o jako:

$$d_o(x_{ij}) = |y'(x_{ij}) - y'_o|$$
(3)

Ponieważ wiele kolorów może przyjmować zbliżone wartości parametru y' , w modelu luminancyjnym będą one nieodróżnialne.

3.2. Model RGB

Model barw RGB jest powszechnie stosowany w technice komputerowej do określania koloru elementu obrazu, jak również jest bezpośrednio wykorzystywany w procesie generacji obrazu na ekranie monitora. Także urządzenia akwizycji obrazu najczęściej wyznaczają wprost wartości składowych RGB podczas digitalizacji. Istnieje grupa urządzeń wykorzystująca model YUV – którego składowe są liniową kombinacją parametrów RGB - konwersja do modelu RGB jest prostą operacją liniową, często realizowaną sprzętowo.

Barwy w modelu RGB są ułożone w trójwymiarowym sześcianie o wymiarze jednostkowym. W reprezentacji komputerowej poszczególne składowe mogą przyjmować wartości całkowite z zakresu $\langle 0-255 \rangle$.

Funkcję odległości barw można więc przedstawić jako odległość w przestrzeni trójwymiarowej:

$$d(x_{ij}, x_{km}) = \sqrt{(r_{x_{ij}} - r_{x_{km}})^2 + (g_{x_{ij}} - g_{x_{km}})^2 + (b_{x_{ij}} - b_{x_{km}})^2} \quad (4)$$

r_x, g_x, b_x - wartości składowych RGB dla punktu x .

Podstawiając dla x_{km} w powyższych wzorach wartości spodziewane r, g, b dla obszaru obiektu otrzymamy względną funkcję odległości, analogicznie jak we wzorze (3).

W modelu RGB poszczególne składowe mają wpływ zarówno na wypadkowy odcień barwy oraz jasność elementu. Sam odcień barwy wynika nie tyle z sumy składowych, co z ich stosunków. Dlatego też barwy o tym zbliżonym odcieniu są „rozrzucone” w całej przestrzeni, a nie zostają skupione – ta cecha powoduje, że odległość kolorów w modelu RGB nie zawsze jest zbieżna z naszymi subiektywnymi wrażeniami.

3.3. Model CIE XYZ

Definicja modelu XYZ jest zbliżona do modelu RGB. Model XYZ wykorzystuje abstrakcyjne barwy podstawowe, dobrane tak aby możliwa była reprezentacja wszystkich barw widzialnych za pomocą nieujemnych wartości barw składowych (co nie jest możliwe w modelu RGB) [2]. Przekształcenie parametrów RGB na XYZ jest operacją liniową:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = M \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (5)$$

Z tego względu model XYZ posiada analogiczną organizację przestrzeni barw jak model RGB – oba modele użyte do wyznaczania różnicy barw będą dawały podobne jakościowo rezultaty.

Model XYZ ma jednak istotne znaczenie dla przekształceń pomiędzy innymi modelami barw; jest często wykorzystywany jako model pośredni w łańcuchu przekształceń [2],[6],[8].

Jest również wykorzystywany jako model odniesienia przy przekształceniach pomiędzy dwoma sprzętowo zależnymi modelami RGB – wyrazy macierzy M we wzorze (5) zależą od parametrów bieli oraz barw podstawowych danego urządzenia [2],[6]. Przykładowo, dla konwersji pomiędzy układem RGB CIE (który wykorzystuje jako biel odniesienia – biel równoenergetyczną) a XYZ wyrazy macierzy M dane są następująco [6],[7]:

$$M = \begin{bmatrix} 0,490 & 0,310 & 0,200 \\ 0,177 & 0,812 & 0,011 \\ 0,000 & 0,010 & 0,990 \end{bmatrix} \quad (6)$$

3.4. Model HSV

Z rozważań w punkcie 2 wynika, iż najistotniejszym parametrem decydującym o ewentualnym podobieństwie dwóch elementów obrazu jest **barwa - ściślej odcień barwy**. Stąd następny analizowany model uwzględnia ten parametr bezpośrednio jako jeden z wymiarów przestrzeni barw.

3.4.1. Parametry modelu HSV

Model HSV opisuje barwę za pomocą trzech parametrów:

H (ang. Hue) odcień barwy,

S (ang. Saturation) nasycenie,

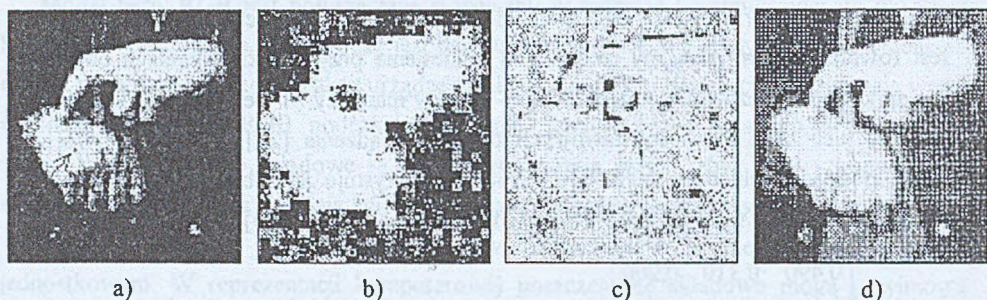
V (ang. Value) wartość.

Zakres wartości parametru H jest cykliczny, dlatego specyfikuje się go w postaci kąta od 0° do 360° . Zakresem parametru S jest przedział 0 - 100%, w praktycznych zastosowaniach skalowany do przedziału dyskretnego (np. $\langle 0,100 \rangle$ lub $\langle 0,255 \rangle$). Parametr V przyjmuje wartości z przedziału $\langle 0,1 \rangle$, może być również skalowany jak parametr S.

Bryła barw modelu HSV ma postać ostrosłupa o podstawie sześciokątna foremna [2]. Kolejnym wierzchołkom podstawy (tym samym kolejnym wartościom parametru H: 0, 60, 120, 180, 240, 300) przypisane są wybrane jako podstawowe barwy widma: czerwona (R), żółta (Y), zielona (G), turkusowa (C, ang. cyjan), niebieska (B) oraz purpurowa (M, ang. magenta).

Konwersja pomiędzy modelami RGB i HSV nie jest przekształceniem liniowym, odpowiednie procedury zdefiniowane są w [2].

Poniziej przedstawiony jest przykładowy kolorowy obraz dłoni będących obiektem segmentacji oraz rozkłady odległości dla parametrów H, S i V od spodziewanych wartości H_o, S_o, V_o dłoni (próbka oznaczona na ilustracji 1a).



Rys. 1. a) obraz barwny, b) rozkład odległości parametru H, c) rozkład odległości parametru S, d) rozkład odległości parametru V


Fig. 1. a) color image, b) distance distribution for parameter H, c) distance distribution for parameter S, d) distance distribution for parameter V

Jak widać, najbardziej użyteczną informację (do zastosowania w segmentacji) niesie parametr H, parametr V może stanowić dodatkowe uzupełnienie.

W celu zmniejszenia złożoności obliczeniowej można rozważyć wykorzystanie tylko parametru H do określenia funkcji odległości kolorów. Ponieważ zakres parametru H jest cykliczny, odległość powinna być określona następująco:

$$d(x_y, x_{km}) = \begin{cases} |h_{x_y} - h_{x_{km}}| & \text{jeśli } |h_{x_y} - h_{x_{km}}| \leq 180 \\ 360 - |h_{x_y} - h_{x_{km}}| & \text{jeśli } |h_{x_y} - h_{x_{km}}| > 180 \end{cases} \quad (7)$$

h_x - wartość składowej H dla punktu x



Rys. 2. a) obraz barwny (oznaczone punkty próbek), b) rozkład wartości składowej H

Fig. 2. a) color image (marked samples points), b) distribution of values for component H

Rozkład wartości parametru H najlepiej przedstawić za pomocą wykresu kołowego. Na rysunku 2b przedstawione jest położenie wartości H dla kilku wybranych punktów obrazu z ilustracji 2a (z obszaru dłoni, jako obiektu - oznaczone kolorem zielonym, oraz z obszaru tła - oznaczone kolorem czerwonym). Rysunek nie uwzględnia parametrów S i V. Wartości H dla próbek elementów z obszaru dłoni i obszarów tła tworzą na obwodzie okręgu dwa dobrze separowalne zbiory.

3.4.2. Problem czerni i bieli

Niestety, wykorzystanie tylko parametru H okazuje się niewystarczające, kiedy w obrazie występują barwy biała lub czarna. Barwy te nie są uwzględnione w zakresie wartości H, ale są modelowane odpowiednio przez brak nasycenia S oraz maksymalną wartość V (barwa biała) lub zerową wartość V i nieokreślone nasycenie S (barwa czarna). Przyczyną tego jest odmienny mechanizm powstawania tych barw i postrzegania ich przez człowieka - biel i czerń nie istnieją jako barwy z zakresu widma, zamiast tego brak bodźców świetlnych interpretowany jest jako czerń, natomiast równomierne zmieszanie wszystkich barw widzialnych jako biel. Podobnie biel i czerń są rejestrowane przez urządzenia akwizycji obrazu.

Dlatego niezbędne staje się jednak wykorzystanie wszystkich trzech parametrów H,S,V, co prowadzi do przestrzeni trójwymiarowej.

Zanim jednak będzie możliwe określenie odległości barw wyrażonych wartościami HSV, należy dokonać konwersji tych wartości do współrzędnych XYZ przestrzeni Euklidesowej (nie należy mylić wprowadzonych poniżej współrzędnych z parametrami popularnego modelu barw XYZ). Jak zostało wcześniej wspomniane, bryła barw modelu HSV ma kształt ostrosłupa o podstawie sześciokąta foremnego. Tak przyjęty kształt podstawy komplikuje proces konwersji.

Jeśli jednak przedstawić model HSV za pomocą stożka (zmiana podstawy z sześciokąta na kolo), konwersja upraszcza się, kosztem pomijalnie małych zniekształceń. Przyjmując, że promień podstawy r będzie równy S_{\max} , wysokość h będzie równa V_{\max} , oraz że wierzchołek stożka zostanie umiejscowiony w punkcie $(0,0,0)$, a środek podstawy w punkcie $(0,0,V_{\max})$, wzory konwersji będą miały postać:

$$\begin{aligned} x &= \frac{\sin\left(H \frac{\pi}{180}\right)SV}{V_{\max}} \\ y &= \frac{\cos\left(H \frac{\pi}{180}\right)SV}{V_{\max}} \\ z &= V \end{aligned} \tag{8}$$

Należy zaznaczyć, że konkretna orientacja i umiejscowienie bryły barw HSV w przestrzeni XYZ są nieistotne dla wyniku wyznaczenia odległości dwóch barw.

Układ barw w modelu HSV znacznie lepiej odpowiada percepcji człowieka (barwy interpretowane jako podobne leżą bliżej siebie w przestrzeni barw) niż w modelu RGB. Istotną cechą modelu HSV jest zawężanie się przestrzeni barw wraz ze zmniejszaniem się wartości V , aż do osiągnięcia wierzchołka ostrosłupa (stożka) dla wartości $V=0$. W ten sposób modelowana jest istotna zależność w postrzeganiu barw, która polega na malejącej zdolności rozróżniania barw w warunkach słabnącego oświetlenia sceny.

3.4.3. Skalowanie modelu HSV

Ponieważ parametry H, S, V mają bezpośrednią interpretację psychofizyczną, możliwe jest kształtowanie miary odległości barw przez wprowadzenie wag określających wpływ danego parametru na wyznaczaną odległość. W szczególności, należy zwiększyć wagę parametru H , oraz zminimalizować wagi parametrów S i V . W ten sposób uzyskana zostanie miara różnicy barw wrażliwa na odcienie barw i względnie niezależna od warunków oświetlenia.

Przypisanie wag parametrom S i V nie stanowi problemu, można to zrobić wprost według wzoru:

$$\begin{aligned} H' &= H \\ S' &= w_s S \\ V' &= w_v V \end{aligned} \tag{9}$$

Zmiana skali parametru S odpowiada zmianie skali wymiarów wzdłuż osi X oraz Y w przestrzeni XYZ stożka barw, a zmiana skali parametru V powoduje zmianę skali na osi Z . Ze względu na biegunowy charakter parametru H (który interpretowany jest jako miara kąta), nie jest możliwe przypisanie wagi w sposób analogiczny jak dla S i V . Przy założonym powyżej algorytmie wyznaczania odległości barw przez przekształcenie współrzędnych HSV do układu geometrycznego XYZ, wpływ parametru H zwiększa się wraz ze wzrostem wagi w_s , dla barw silnie nasyconych (duże wartości S) – co odpowiada zwiększaniu się długości łuku na obrzeżu podstawy stożka HSV pomiędzy dwoma odcieniami barw.

Aby niezależnie skalować parametr H , trzeba zrezygnować z wykorzystania przestrzennej reprezentacji bryły HSV do wyznaczania odległości barw i zastosować w tym celu prostą miarę odległości opartą tylko na parametrach H, S, V traktowanych tym razem wprost jak współrzędne układu geometrycznego:

$$\begin{aligned} H' &= w_h H \\ S' &= w_s S \\ V' &= w_v V \end{aligned} \tag{10}$$

$$d(x_{ij}, x_{km}) = \sqrt{(H'_{x_{ij}} - H'_{x_{km}})^2 + (S'_{x_{ij}} - S'_{x_{km}})^2 + (V'_{x_{ij}} - V'_{x_{km}})^2} \quad (11)$$

Takie podejście wykorzystuje istotną cechę modelu HSV: separację opisu odcienia barwy od pozostałych czynników (jasności i nasycenia), bez użycia oryginalnego przestrzennego rozkładu barw.

3.5. Modele barw percepcyjnie równomierne

Jak widać z dotychczasowej analizy modeli barw, najbardziej pożądaną cechą modelu (w zastosowaniu rozróżniania kolorów) jest taki układ barw w przestrzeni, aby jak najbardziej odpowiadał on psychofizycznej percepcji barw przez człowieka. Modele spełniające to kryterium określane są jako **percepcyjnie równomierne** [2].

3.5.1. Model CIE LAB

Głównym założeniem konstrukcji modelu LAB jest rozkład barw w przestrzeni zgodny z percepcją ludzkiego narządu wzroku – odległość między barwami w modelu jest proporcjonalna do różnicy tych barw odbieranej przez przeciętnego obserwatora bez wad wzroku. Jednocześnie składowe L^* , a^* , b^* zostały związane z wartościami x' , y' , z' (model XYZ) w sposób analityczny [2],[6], co umożliwia łatwą konwersję barw pomiędzy modelami XYZ i LAB, oraz LAB i innymi modelami (np.: RGB) z użyciem modelu XYZ jako pośredniego przekształcenia.

Efektom takiego podejścia są nieliniowe formuły określające wartości L^* , a^* , b^* , które z pewnym przybliżeniem uwzględniają problem percepcji barw[2,6]:

$$L^* = \begin{cases} 116 \left(\frac{y'}{y'_n} \right)^{1/3} - 16 & \text{dla } \frac{y'}{y'_n} > 0,008856 \\ 903,3 \left(\frac{y'}{y'_n} \right) - 16 & \text{dla } \frac{y'}{y'_n} \leq 0,008856 \end{cases}$$

$$a^* = 500 \left[f \left(\frac{x'}{x'_n} \right) - f \left(\frac{y'}{y'_n} \right) \right]$$

$$b^* = 200 \left[f \left(\frac{y'}{y'_n} \right) - f \left(\frac{z'}{z'_n} \right) \right]$$

gdzie: $f(t) = \begin{cases} t^{1/3} & \text{dla } t > 0,008856 \\ 7,787t + 16 / 116 & \text{dla } t \leq 0,008856 \end{cases}$
 (x'_n, y'_n, z'_n) – współrzędne bieli

Model LAB definiuje miarę różnicy barw jako [2,6]:

$$\Delta E_{ab} = \sqrt{\Delta L^{*2} + \Delta a^{*2} + \Delta b^{*2}} \quad (13)$$

traktując składowe L^* , a^* , b^* jak współrzędne prostokątnego układu trójwymiarowego.

Wartości a^* , b^* nie mają swoich bezpośrednich interpretacji psychofizycznych, jedynie wartość L^* można interpretować jako miarę jasności barwy[2], stąd niemożliwe jest dalsze skalowanie modelu tak, jak zostało to opisane w punkcie 3.4.2 dla modelu HSV.

W modelu LAB wprowadzono natomiast pojęcia chromy c^*_{ab} oraz odcienia h^*_{ab} , które wraz z wartością L^* tworzą zestaw parametrów równoważny funkcjonalnie z trójką HSV lub HVC z omawianego dalej modelu Munsella. Są one określone następująco [2,6]:

$$\begin{aligned} c^*_{ab} &= \sqrt{a^{*2} + b^{*2}} \\ h^*_{ab} &= \arctg\left(\frac{b^*}{a^*}\right) \end{aligned} \quad (14)$$


3.5.2. Model Munsella

Model barw, zdefiniowany przez A.H. Munsella w roku 1905 [3], jest również modelem percepcyjnie równomiernym, opracowanym eksperymentalnie. Barwa określana jest za pomocą trzech parametrów o znaczeniu podobnym jak w modelu HSV:

H (ang. Hue) – kolor (odcien),

V (ang. Value) - wartość (jasność),

C (ang. Chroma) - chroma (nasycenie).



Rys. 3. Okrąg odcieni w modelu Munsella [3]

Fig. 3. Hue circle for Munsell model [3]


Podobnie jak w modelu HSV wartości parametru H przedstawiane są we współrzędnych kątowych, nasycenie koloru C decyduje o jego odległości od osi bryły barw, natomiast jasność V o wysokości. Różnica modelu Munsella od HSV polega na tym, iż skale osi wszystkich trzech parametrów HVC są nieliniowe względem znanych mierzalnych fizycznie parametrów barwy (są natomiast liniowe względem odczuć przeciętnego obserwatora) – podobnie jak w

modelu LAB, ale ustalone na drodze eksperymentów. Stąd bryła barw posiada nieregularne kształty – rys.4.

Skala parametru H przedstawiana jest na okręgu podzielonym umownie na 100 jednostek. Model definiuje pięć wybranych (jako podstawowe) barw widma: czerwoną (R), żółtą (Y), zieloną (G), niebieską (B) oraz purpurową (P), które zostały rozmieszczone równomiernie na okręgu H (rys. 3).

Skala parametru V jest ograniczona od 0 (czerni) do 10 (biel). Skala parametru C jest nie ograniczona od góry: wartość 0 odpowiada barwom achromatycznym (skala szarości), typowe barwy nasycone osiągają wartość do 20 jednostek, materiały fluorescencyjne mogą osiągać nawet do 30 jednostek [3].

Dzięki swojemu empirycznemu charakterowi oraz wielokrotnie uzupełnianym pomiarom model Munsella uważany jest za najlepszy pod względem percepcyjnie równomiernego rozkładu barw [8].



Rys. 4. Bryła barw systemu Munsella [2]

Fig. 4. The solid of colors from Munsell's system [2]

Z zalety modelu wynika jednocześnie jego wada: brak jest analitycznych zależności wiążących wartości H,V,C z reprezentacją danej barwy w innym modelu, co uniemożliwia jego bezpośrednie zastosowanie w algorytmach numerycznych. Zamiast tego model Munsella zadany jest w postaci katalogu barwnych próbek (ang. *color chips*), a ewentualna transformacja do innego modelu barw zadana jest w postaci tabeli konwersji próbek kolorów Munsella (określonych parametrami HV/C) na odpowiadające im wartości składowych danego modelu. Ponieważ tablica taka ma skończoną dokładność (kolejne próbki wybierane są z określonym kwantem $\Delta H, \Delta V, \Delta S$), dla konwersji pozostałych barw konieczna jest interpolacja wyniku na podstawie najbliższych wpisów z tablicy. Zależnie od wyboru

dokładności tablicy konwersji, innego modelu barw oraz metody interpolacji pozostałych barw można uzyskać wyniki o różnej dokładności.

Przykładem konwersji barw z modelu RGB do modelu Munsella jest metoda wykorzystująca modele pośrednie: XYZ oraz LAB, a także tabelę odchyłek pomiędzy parametrami $(h_{ab}^*, c_{ab}^*, L^*)$ dla modelu LAB a parametrami (H,C,V) dla modelu Munsella [8].

3.5.3. Porównanie modeli HSV, LAB i Munsella

Poniższa tabela przedstawia porównanie cech wybranych modeli barw.

Tabela 1

Zestawienie cech modeli: HSV, LAB oraz Munsella

		HSV	LAB	Munsell
Odcień	parametr	H	(h_{ab}^*)	H
	typ	cykliczny	cykliczny	cykliczny
	zakres	$\langle 0; 360 \rangle$	$\langle 0; 2\pi \rangle$	$\langle 0; 100 \rangle$
Nasylenie	parametr	S	(c_{ab}^*)	C
	typ	liniowy	nieliniowy	nieliniowy
	zakres	$\langle 0; 100 \rangle / \langle 0.0; 1.0 \rangle$	$\langle 0; +\infty \rangle$	$\langle 0; +\infty \rangle$
Jasność	parametr	V	L^*	V
	typ	liniowy	nieliniowy	nieliniowy
	zakres	$\langle 0; 100 \rangle / \langle 0.0; 1.0 \rangle$	$\langle 0; 100 \rangle$	$\langle 0; 10 \rangle$
Wybrane barwy bazowe		R, Y, G, C, B, M	-	R, Y, G, B, P
Barwy szczególne		czerń, biel	czerń, biel	czerń, biel

Modele: LAB oraz Munsella nie posiadają określonej z góry granicy wartości nasycenia. W praktyce granica ta jest wyznaczana przez dostępne fizycznie metody syntezy barw (zob. punkt 3.5.2).

Wszystkie trzy modele traktują w sposób specjalny biel oraz czerń – ich położenie w przestrzeni barw jest ściśle określone – barwy takie będą określane dalej jako barwy szczególne.

Dwa modele posiadają zbiory barw (konkretnie odcieni barw w pełni nasyconych), które w regularny sposób dzielą podprzestrzeń odcieni na obszary, w których pozostałe odcienie są charakteryzowane przez ich względne podobieństwo do barw wybranych – barwy takie będą określane dalej jako barwy bazowe.

4. Testy porównawcze wybranych modeli barw

4.1. Precyzja w modelach XYZ, LAB

Zakresy wartości parametrów opisujących barwę w modelach XYZ oraz LAB dla podzbioru barw reprezentowanych w sześcianie RGB, zebrane w tabeli 2, są zbliżone do zakresów wartości parametrów RGB (typowo: $\langle 0;255 \rangle$). Sugeruje to możliwość użycia typu całkowitego do zapisu koloru w systemie XYZ lub LAB. Jednocześnie postać formuł określających konwersję pomiędzy modelami RGB \rightarrow XYZ (5),(6) oraz XYZ \rightarrow LAB (12) wyraźnie wymaga użycia arytmetyki zmiennoprzecinkowej.

Tabela 2

Zakresy wartości parametrów w modelach XYZ, LAB¹

	Model XYZ			Model LAB		
	X	Y	Z	L*	a*	b*
min	0	0	0	0	-122	149
max	100	100	100	100	186	157

Możliwość wykorzystania typu całkowitego zamiast zmiennoprzecinkowego jest istotna dla ewentualnych przyspieszeń obliczeń w danym modelu. Głównym niebezpieczeństwem zastąpienia typu rzeczywistego całkowitym jest utrata precyzji reprezentacji barw w pewnych zakresach rozważanego podzbioru. Dostępne źródła obrazu, takie jak strumień AVI lub karta akwizycji obrazu (ang. *frame-grabber*), dostarczają informacji o kolorze najczęściej z wykorzystaniem modelu RGB z rozdzielczością 8-bitów na każdy z parametrów R,G,B, co odpowiada dyskretnej wartości $\langle 0;255 \rangle$. Minimalna różnica barw w takiej reprezentacji mierzona dla każdego parametru wynosi 1. Dla dowolnej barwy C wybranej z wnętrza sześcianu RGB można więc wskazać zbiór barw C' leżących w minimalnej odległości równej 1, co zostało opisane wzorem:

¹ Podane zakresy zostały wyznaczone dla podzbioru barw reprezentowanych w sześcianie RGB, przez pomiary wyników konwersji RGB \rightarrow XYZ oraz XYZ \rightarrow LAB.

$$C = \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad C' = \left\{ C'_i = \begin{bmatrix} r'_i \\ g'_i \\ b'_i \end{bmatrix}, i = 0..5 \right\} \quad (15)$$

gdzie

$$r'_i = \begin{cases} r-1 & \text{dla } i=0 \\ r+1 & \text{dla } i=1 \\ r & \text{dla } i \notin \{0,1\} \end{cases} \quad g'_i = \begin{cases} g-1 & \text{dla } i=2 \\ g+1 & \text{dla } i=3 \\ g & \text{dla } i \notin \{2,3\} \end{cases} \quad b'_i = \begin{cases} b-1 & \text{dla } i=4 \\ b+1 & \text{dla } i=5 \\ b & \text{dla } i \notin \{4,5\} \end{cases}$$

Minimalna różnica barw zostanie oznaczona symbolem Δ_1 i zdefiniowana dla dowolnie wybranej barwy C jako:

$$\Delta_1 C = \min_{C'_i \in C'} \left\| \begin{bmatrix} r \\ g \\ b \end{bmatrix} - \begin{bmatrix} r'_i \\ g'_i \\ b'_i \end{bmatrix} \right\| = \begin{bmatrix} \min_i |r-r'_i| \\ \min_i |g-g'_i| \\ \min_i |b-b'_i| \end{bmatrix} = \begin{bmatrix} \Delta_1 r \\ \Delta_1 g \\ \Delta_1 b \end{bmatrix}$$

gdzie operator \min_1 jest określony jako: (16)

$$\min_1(X) = \min(X_i) \text{ dla } X = \{x_i\}, \quad X_i = \{x_i : x_i \in X \wedge x_i > 0\}$$

Dla modelu RGB opartego na typie całkowitym tak zdefiniowana minimalna różnica barw wynosi:

$$\Delta_1 = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} \quad (17)$$

Po transformacji barw C oraz C' do modelu XYZ czy LAB odległości pomiędzy barwami ulegną zmianie, a tym samym zmieni się wartość minimalnej różnicy barw Δ_1 rejestrowanej w tym modelu. W tabeli 3 przedstawione są wartości minimalnych różnic barw wyznaczone dla modeli XYZ oraz LAB. Metoda wyznaczenia poniższych wartości polegała na konwersji zestawów barw C oraz C' z przestrzeni RGB do modeli XYZ oraz LAB i wyznaczaniu odpowiadającym im różnic Δ_1 . W tabeli znajdują się najmniejsze znalezione wartości różnic dla każdego z parametrów. Zestawy barw zostały wybrane z regularnie rozmieszczonych punktów sześcianu RGB, ze szczególnym uwzględnieniem barw leżących na obrzeżach.

Jak widać, istnieją podzbiory barw w przestrzeni RGB, dla których odpowiadające im odległości w modelach XYZ oraz LAB są znacznie mniejsze od jedności. Aby więc zachować te różnice z dokładnością do co najmniej jednej pozycji dziesiętnej w reprezentacji barwy z użyciem typu całkowitego, należy przeskalować wartości parametrów o 10^3 lub 10^4 odpowiednio dla modelu XYZ lub LAB (tabela 3). Zakresy wartości parametrów w modelach

XYZ oraz LAB zebrane w tabeli 1 ulegną odpowiedniemu poszerzeniu w wyniku przeskalowania, tak że do reprezentacji każdego z parametrów konieczne będzie użycie typu całkowitego o rozdzielczości 32 bitów – rozdzielczość 16 bitów staje się już niewystarczająca.


Tabela 3

Minimalne różnice barw dla modeli XYZ, LAB

Model XYZ		Model LAB	
$\Delta_1 X$	0,078431	$\Delta_1 L^*$	0,001672
$\Delta_1 Y$	0,004314	$\Delta_1 a^*$	0,000520
$\Delta_1 Z$	0,003922	$\Delta_1 b^*$	0,046384
skala	10^3	skala	10^4

4.2. Pomiar odległości kolorów

Poniższy test weryfikuje zdolność danego modelu do skutecznego odróżnienia barw na przykładzie rzeczywistego obrazu (rys. 5).



Rys. 5. Obraz testowy z zaznaczonymi punktami próbek
Fig. 5. Test image with marked samples points

Do testu zostały wybrane modele:

- RGB – jako najczęściej używany model barw,
- HSV – jako model o fizycznie interpretowalnych parametrach opisu barwy,
- LAB – jako model percepcyjnie równomierny.

Dodatkowo został użyty model HSV z zastosowaniem skalowania parametrów (wg punktu 3.4.2) oznaczany dalej jako s-HSV.

Z obrazu zostały wybrane cztery punkty próbek dla różnych kolorów: A – czarny (zakłócenie na brzegu obrazu), B – niebieski (ściana), C – biały (napis) oraz D – żółty (dłoń). Każda próbka składała się z kwadratowego obszaru o wymiarach 3x3 pikseli. Jako cel zostało określone zadanie wskazania, które z pikseli próbek przynależą do obszaru dłoni jako obiektu pierwszoplanowego. Dodatkowo została wybrana próbka wzorcowa E również z obszaru dłoni. Barwy pikseli z poszczególnych próbek zostały przedstawione w wybranych do testu modelach, a następnie wykonane zostały pomiary odległości wg poniższych reguł.

Miara odległości $d(x)$ wybranej barwy x od próbki wzorcowej E została wyznaczona z użyciem modelu funkcji odległości z jednym zbiorem [9] wg wzoru:

$$d(x, E) = \min_{e_i \in E} (d(x, e_i)) \quad (18)$$

Jako miary odległości dwóch barw $d(x_1, x_2)$ wybrane zostały przedstawione wcześniej formuły odpowiednie dla danego modelu barw:

- (4) dla RGB,
- (8) dla HSV,
- (11) dla s-HSV,
- (13) dla LAB.

Dla każdej próbki testowej $X=A, B, C, D$ wyznaczone zostały następujące wskaźniki:

- średnia odległość bezwzględna barw pikseli z próbki testowej względem próbki wzorcowej \bar{d}_x ,
- odchylenie standardowe tej odległości Δd_x ,
- stosunek k_x średniej odległości \bar{d}_x do średniej odległości \bar{d}_D dla próbki testowej D z obszaru dłoni:

$$k_x = \frac{\bar{d}_x}{\bar{d}_D} \quad (19)$$

Uzyskane wyniki zostały przedstawione w tabeli 4. W idealnym przypadku wskaźniki Δd_x powinny uzyskać możliwie małe wartości, natomiast wskaźniki k_x dla próbek A, B, C powinny być możliwie duże. Odpowiadałoby to silnemu skupieniu barw poszczególnych pikseli w ramach próbki w danej przestrzeni barw oraz wyraźnemu zróżnicowaniu odległości pomiędzy barwami pikseli różnych próbek. Obie cechy są bardzo pożądane w algorytmach segmentacji, takich jak w [1, 10, 15, 16].

We wszystkich przypadkach testowanych modeli barw wskaźniki k_x są wyraźnie większe od 1, co pozwala na ustalenie kryterium decyzyjnego o przynależności danej próbki do obszaru dłoni. Najmniejszą wartość wskaźnika k_x uzyskiwała próbka C, szczególnie w modelu

LAB (2,81). Wyjątkowo dużą wartość uzyskał wskaźnik Δd_x dla próbki D w modelu RGB, co oznacza znaczny rozrzut barw pikseli tej próbki w przestrzeni RGB (aż 46%). Wydaje się że najlepsze wskaźniki zostały uzyskane dla modelu HSV (również s-HSV z wagami 1:1:1 – por. punkt 3.4.2), co jest wynikiem innym od oczekiwanego – najbardziej obiecującym wg rozważań teoretycznych był model LAB. Ponadto zwiększanie wag każdego parametru z osobna w modelu s-HSV nie dało oczekiwanej poprawy wyników.

Tabela 4

Zestawienie wyników testu pomiaru odległości barw

		A (czarny)	B (niebieski)	C (biały)	D (żółty)
RGB	\bar{d}_x	258,22	114,08	71,34	12,38
	Δd_x [%]	0,96	4,64	19,12	46,83
	k_x	20,84	9,21	5,76	1,00
HSV	\bar{d}_x	67,93	53,06	26,38	4,58
	Δd_x [%]	1,35	2,58	8,97	18,98
	k_x	14,82	11,57	5,75	1,00
s-HSV (1:1:1)	\bar{d}_x	128,68	176,98	162,06	12,12
	Δd_x [%]	5,51	2,97	7,54	10,45
	k_x	10,62	14,60	13,37	1,00
LAB	\bar{d}_x	79,44	34,08	12,75	4,53
	Δd_x [%]	2,85	8,13	7,98	12,34
	k_x	17,53	7,52	2,81	1,00

5. Konstrukcja alternatywnych modeli barw

Mechanizm postrzegania barw jest procesem skomplikowanym [2]. Właściwości ludzkiego narządu wzroku ciągle nie są do końca zbadane. Również istniejące modele barw są jedynie próbami usystematyzowania subiektywnego pojęcia, jakim jest barwa. Ze względu na niedoskonałości istniejących modeli pojawiają się również nowe koncepcje i związane z nimi definicje nowych reprezentacji barwy [2,11]. Postać danego modelu zależy silnie od stawianych przed nim zadań – np. do syntezy barw, interakcyjnego doboru barwy, opisu źródeł światła lub powierzchni rozpraszających światło wybierane są różne modele barw. Nie ma jednak jednego uniwersalnego modelu dla wszystkich zastosowań.

Niniejszy punkt jest próbą zdefiniowania postaci oraz cech, jakie powinien posiadać model barw do automatycznej segmentacji obrazów barwnych. W dalszej części będzie on oznaczany akronimem CSS (ang. *Color Space for Segmentation*). Podstawą dla wysuwanych propozycji są doświadczenia z modelami barw prezentowanymi w punkcie 3.

5.1. Cechy modelu CSS

Poszczególne cechy modelu CSS są przedstawione przez dyskusję wybranych problemów omówionych dotychczas modeli barw.

Problem barw: czarnej i białej. Większość przedstawionych tutaj modeli barw traktuje czern oraz biel w sposób istotnie odbiegający od reprezentacji pozostałych barw (por. punkty 3.4.2 i 3.6). Jest to przyczyną późniejszych kłopotów przy porównywaniu tych barw z innymi. Charakterystycznym przykładem są model HSV oraz model Munsella, w których jedynie czerń i biel nie są reprezentowane na okręgu odcieni barw. W istocie z takiej definicji modelu wynika wniosek, iż biel i czerń nie są *kolorami* w potocznym znaczeniu tego słowa (ściślej odcieniami barwy – ang. *hues*). Zamiast tego są one traktowane jako szczególne przypadki psychofizycznej interpretacji stanów: braku strumienia światła lub obecności strumienia w całym zakresie widzialnym widma. Nie jest to zgodne z intuicyjnym postrzeganiem obrazów – dla człowieka barwy czarna i biała są takimi samymi kolorami, jak np.: czerwony czy niebieski. Podobnie podczas segmentacji obrazu obszar o barwie białej lub czarnej jest po prostu obszarem o określonym kolorze, podobnie jak obszar o kolorze np. czerwonym. Z tego względu w modelu CSS czerń i biel powinny być reprezentowane tak samo, jak pozostałe barwy, bez żadnych odstępstw. W szczególności jeśli model posiada określone barwy bazowe, powinny do nich należeć również barwy: biała i czarna. Problem bieli i czerni jest poruszany również w innych opracowaniach: w pracy [11] znajduje się osobny rozdział poświęcony temu problemowi – wskazane są prace [12,13], w których autorzy sugerują reprezentację czerni i bieli jako osobnych wymiarów zamiast tradycyjnie przyjmowanej jako przeciwległych punktów tego samego wymiaru.

Problem odległości barw bazowych. Problem ten dotyczy modeli z określonymi barwami bazowymi. Do modeli takich, spośród przedstawionych wyżej, można zaliczyć model HSV oraz model Munsella. Barwy bazowe dzielą w sposób charakterystyczny dla danego modelu podprzestrzeń odcieni barw (najczęściej jednowymiarową i cykliczną). Punkty tej podprzestrzeni charakteryzują barwę w sposób jakościowy, ale nie ilościowy. Dlatego nie ma żadnej podstawy, aby odległość mierzona pomiędzy wybraną parą barw bazowych była inna niż w przypadku innej pary. Tak - niestety - dzieje się zarówno w modelu HSV, jak i w modelu Munsella. Sugeruje to, że np. barwy czerwona i żółta są bardziej do siebie zbliżone niż barwy czerwona i niebieska. Wniosek taki, jakkolwiek zależy w znacznej mierze od

subiektywnych odczuć obserwatora, jest co najmniej dyskusyjny. W modelu CSS odległości pomiędzy wszystkimi barwami bazowymi powinny być identyczne. Jeśli model posiada więcej niż 4 barwy bazowe, to warunek ten możliwy jest do spełnienia tylko przy wykorzystaniu przestrzeni rzędu wyższego niż trójwymiarowa. Możliwe jest zatem, że do konstrukcji nowych modeli barw należy użyć wielowymiarowych przestrzeni. Podobny wniosek pojawia się np. w [11], choć wynika on z innych przesłanek.

Problem zgodności modelu CSS z ludzkim mechanizmem percepcji barw. Prezentacja kolejnych modeli barw w punkcie 3 może prowadzić do wniosku, iż bardziej zaawansowane modele powinny być zgodne z mechanizmem percepcji barw przez człowieka. Wiadomo jednak, że w procesie percepcji barw znaczna ilość informacji jest tracona. Efektem tego jest np. możliwość uzyskania wrażenia tej samej barwy dla rozkładów widmowych promieniowania zwanych *metamerami* [2]. Z własności tej korzysta trójchromatyczna teoria widzenia, która jest podstawą budowy większości dostępnych obecnie urządzeń akwizycji obrazu. Wynika stąd, że dwa różne rozkłady widmowe promieniowania mogą być nierozróżnialne w procesie percepcji barw przez człowieka, a tym samym będą nierozróżnialne w modelach zgodnych z tym mechanizmem. Są to jednak dwa różne stany, możliwe fizycznie do rozróżnienia, choć niekoniecznie za pomocą tylko trzech sygnałów R,G,B (dla przykładu). Model barw przeznaczony do segmentacji obrazów niekoniecznie musi być więc zgodny z mechanizmem percepcji barw człowieka, mechanizm ten nie stanowi tutaj żadnego wzorca. Konsekwencją tego jest możliwość, iż parametry opisujące barwę w nowym modelu nie będą posiadały fizycznej interpretacji, takiej jak w modelu HSV czy w modelu Munsella.

Problem rozkładu przestrzennego barw w modelu CSS i akwizycji barw. Prezentowane wcześniej modele barw można ze względu na organizację przestrzennego rozkładu barw podzielić na dwie grupy nazwane umownie jako: *syntezowalne* i *proporcjonalne*.

W modelach pierwszej grupy wybrane barwy podstawowe tworzą poszczególne wymiary przestrzeni barw. Barwa przypisana określonemu punktowi w takiej przestrzeni jest wynikiem syntezy barw podstawowych w proporcjach określonych przez współrzędne tego punktu. Do grupy tej można zaliczyć modele RGB i XYZ. Konstrukcja tych modeli opiera się na trójchromatycznej teorii widzenia [2].

Modele drugiej grupy posiadają zbiór punktów/kierunków o określonej lokalizacji/orientacji w przestrzeni barw, które reprezentują położenie wybranych barw bazowych lub barw specjalnych (por. punkt 3.6). Punkty/kierunki te wyznaczają kształt i rozmiary bryły barw w przestrzeni. Barwa przypisana określonemu punktowi w takiej przestrzeni jest wynikiem złożenia cech barw bazowych i specjalnych w proporcjach odpowiadających względnym odległościom/kątom od poszczególnych punktów/kierunków

bazowych lub specjalnych. Do grupy tej można zaliczyć modele HSV, LAB oraz model Munsella.

Samo określenie liczby wymiarów przestrzeni oraz dobór barw podstawowych lub bazowych nie stanowi jeszcze pełnej definicji modeli z praktycznego punktu widzenia. Aby model mógł być realnie wykorzystywany, potrzebna jest jeszcze metoda transformacji barw z reprezentacji dostępnej fizycznie do reprezentacji nowego modelu. W przypadku modeli syntezowalnych problem sprowadza się do konieczności zapewnienia możliwości akwizycji parametrów opisujących w sposób ilościowy udział barw podstawowych w danym punkcie obrazu. Na przykład model RGB jest ściśle związany z konstrukcją dostępnych urządzeń akwizycji obrazu, natomiast model XYZ, który wykorzystuje abstrakcyjne barwy podstawowe, posiada zdefiniowaną ściśle macierz pozwalającą na wyznaczenie wartości X, Y, Z z dostępnych wartości R, G, B . W przypadku modeli proporcjonalnych konieczne jest zdefiniowanie algorytmu pozwalającego wyznaczyć stosunki podobieństw dowolnej barwy do barw bazowych lub specjalnych, a tym samym lokalizację odpowiadającego tej barwie punktu w przestrzeni – w oparciu o dostępne parametry fizyczne barwy z procesu akwizycji.

Podsumowując, definicja nowego modelu musi zachować łączność z dostępnymi metodami akwizycji obrazu. Możliwa jest również sytuacja, w której do osiągnięcia założonych własności modelu barw konieczne będzie zastosowanie nowych urządzeń akwizycji, które mogą dostarczyć więcej parametrów charakteryzujących barwę. Przykładem takiego urządzenia jest spektrofotometr.

5.2. Uogólniona definicja funkcji odległości barw

Oznaczając zbiór wszystkich barw możliwych do zarejestrowania w procesie akwizycji obrazu jako Ω , oraz dwie dowolnie wybrane z tego zbioru barwy jako $C_1, C_2 \in \Omega$, problem wyznaczenia ilościowej różnicy barw sprowadza się do znalezienia funkcji odległości:

$$d: \Omega^2 \rightarrow R \quad (20)$$

takiej, że dla dwóch wybranych barw C_1, C_2 będzie przyjmować ona wartości $d(C_1, C_2)$ znikomo małe, jeśli barwy te są do siebie bardzo podobne (reprezentują ten sam kolor w obrazie), oraz wartości możliwie duże, jeśli barwy są zdecydowanie różne.

Ponadto możliwe jest określenie zbioru barw bazowych:

$$B = \{B_1, \dots, B_k\} \quad (21)$$

dla których funkcja odległości powinna przyjmować wartość maksymalną:

$$\forall_{B_i, B_j \in B \wedge B_i \neq B_j} d(B_i, B_j) = MAX \quad (22)$$

5.2.1. Definicja pośrednia z jawnie określonym modelem barw

Funkcja odległości może być wyznaczana w sposób pośredni z użyciem jawnie zdefiniowanego modelu barw. Model taki określa w sposób systematyczny przestrzenne uporządkowanie barw, które jest podstawą do wyznaczenia odległości.

Na definicję modelu barw:

$$CSS = (M, L, \delta) \quad (23)$$

składają się:

- N -wymiarowa przestrzeń barw M :

$$M = R^N \quad (24)$$

- funkcja lokacji L , która każdej barwie ze zbioru Ω przyporządkowuje punkt przestrzeni M :

$$L: \Omega \rightarrow R^N \quad (25)$$

- oraz metryka δ określona na przestrzeni M .

Barwa reprezentowana jest więc przez wektor N parametrów:

$$C = (x_1, \dots, x_N) \quad (x_1, \dots, x_N) \in M \quad (26)$$

niekoniecznie fizycznie interpretowalnych.

Jeśli model posiada zdefiniowany zbiór barw bazowych B (21), konieczne będzie użycie przestrzeni o:

$$N \geq k - 1 \quad (27)$$

wymiarach, aby możliwe było spełnienie warunku maksymalnej odległości (22).

Wyznaczenie wartości funkcji odległości d dla barw C_1, C_2 polega więc na pomiarze odległości pomiędzy odpowiadającymi im punktami X_1, X_2 w przestrzeni barw:

$$d(C_1, C_2) = \delta(X_1, X_2) \quad \text{gdzie } X_1 = L(C_1), \quad X_2 = L(C_2) \quad (28)$$

Funkcję lokacji L można przedstawić jako złożenie dwóch funkcji:

$$L(C) = A(m(C)) \quad m: \Omega \rightarrow R^P \quad A: R^P \rightarrow R^N \quad (29)$$

gdzie:

- m jest funkcją pomiaru (lub funkcją akwizycji) barwy, która określa wartości dostępnych P parametrów mierzalnych. Zarówno liczba P , jak i funkcja m są określone przez możliwości posiadanego sprzętu do akwizycji obrazu.
- A jest właściwym algorytmem realizacji rozkładu przestrzennego barw w modelu.

Podsumowując, problem rozróżniania barw może zostać rozwiązany przez znalezienie odpowiedniego algorytmu wyznaczającego lokalizację punktów barw w przestrzeni modelu.

Istotną kwestią jest tutaj dobór właściwej bazy sprzętowej, wymiaru N przestrzeni barw oraz ewentualnie zbioru barw bazowych B .

5.2.2. Definicja bezpośrednia bez jawnego modelu barw

Funkcja odległości barw (20) może być również określona wprost bez konieczności definiowania modelu barw jako:

$$d(C_1, C_2) = f(m(C_1), m(C_2)) \quad \text{gdzie } f: R^{2p} \rightarrow R \quad (30)$$

ogólna funkcja f $2p$ -argumentów mierzalnych. Taka postać funkcji jest szczególnie wygodna do realizacji za pomocą algorytmów nieprecyzyjnych (ang. *soft computing*), takich jak sieci neuronowe czy logika rozmyta [14].

6. Podsumowanie

Przedstawiony został problem rozróżniania barw poprzez wyznaczanie ilościowej różnicy pary kolorów, w kontekście algorytmów segmentacji obrazów. Omówione zostały istniejące modele barw oraz ich cechy funkcjonalne. W wyniku analizy tych modeli zaproponowane zostały cechy nowego modelu barw dla algorytmów segmentacji oraz określona została ogólna postać definicji funkcji odległości barw (20).

Dalsze badania polegać będą na poszukiwaniu praktycznych implementacji algorytmów rozkładu przestrzennego barw A (29) oraz ogólnej funkcji odległości f (30). Rozważane są dwa rodzaje modeli:

- statyczne, których parametry są ustalone,
- adaptacyjne, których własności można regulować za pomocą dostępnych *a priori* informacji dotyczących zadania segmentacji.

Przykładem takich informacji jest wstępna znajomość barw obiektu oraz tła, uzyskana w poprzednim cyklu (przy przetwarzaniu sekwencji obrazów). W ramach poprzednich badań [9] zaproponowane zostały funkcje odległości barw, które wykorzystują informację o oczekiwanych barwach obiektu i tła.

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. L. Luchowski: Segmentacja płaskich scen binarnych w warunkach nierównomiernego oświetlenia. Praca doktorska. Gliwice 1994.
5. Ch. D. Watkins, A. Sadun, S. Marenka: Nowoczesne metody przetwarzania obrazu. WNT, Warszawa 1995.
6. Palus H.: Colour spaces in computer vision. Machine GRAPHICS and VISION, 1992, nr 3, t. 1, s. 543-554.
7. Rzeszut J.: Transformacje składowych i współrzędnych trójchromatycznych. Machine GRAPHICS and VISION, 1992, nr 1/2, t. 1, s. 208-215.
8. Zhang J., Sokhansanj S., Wu S., Fang R., Yang W., Winter P.: A transformation technique from RGB signals to the Munsell system for color analysis of tobacco leaves. Computers and Electronics in Agriculture, 1998, nr 2, t. 19, s. 155-166.
9. Forczek M.: Modelowanie funkcji odległości barw z uwzględnieniem znajomości oczekiwanych barw obiektów w zastosowaniu do segmentacji obrazów kolorowych. ZN Pol. Śl. s. Informatyka z. 37, s. 273-285, Gliwice 1999.
10. Shen D., Ip H.H.S.: Markov random field regularisation models for adaptive binarisation of nonuniform images. IEE Proc.-Vis. Image Signal Process., Vol. 145, No. 5, 1998
11. Boker S.M.: The representation of color metrics and mappings in perceptual color space. The University of Virginia. Department of Psychology. URL: http://kiptron.psyc.virginia.edu/steve_boker/ColorVision2
12. Heggelund P.: A bidimensional theory of achromatic color vision. Vision research, 32(11), s. 2107-2119, 1992.
13. Izmailov C. A., Sokolov E. N.: A semantic space of color names. Psychological Science, 3(2), s. 105-110, 1992.
14. Nauck D., Klawonn F., Kruse R.: Foundations of neuro-fuzzy systems. John Wiley & Sons. 1997.
15. Porter R., Canagarajah N. Robust rotation-invariant texture classification: wavelet, Gabor filter and GMRF based schemes. IEE Proc.-Vis. Image Signal Process., Vol. 144, No. 3, 1997.

16. Leung C.K., Lam F.K.: Maximum a posteriori spatial probability segmentation. IEE Proc.-Vis. Image Signal Process., Vol. 144, No. 3, 1997.

Recenzent: Dr inż. Henryk Palus

Wpłynęło do Redakcji 14 grudnia 1999 r.

Abstract

The algorithms of segmentation use two kinds of attributes of decision:

- valuable ones – similarity of measurable parameter (like brightness, color)
- spatial ones – position of elements in image.

Using the color space for evaluating the quantitative difference of colors of two image's points will allow to adopt the algorithms of monochromatic images segmentation for working with colorful images. In the paper, there have been existing color spaces and their features presented. These models can be classified into two groups: simple models (RGB, XYZ) and perceptually uniform spaces (LAB, Munsell). The given comparison of features (table 1) shows the similarity of models. All the tree models have **special colors**, and two of them have also the **base color sets**.

The value ranges for XYZ and LAB models have been evaluated and the **minimal color difference** $\Delta_1(16)$ for color subset of RGB cube has been determined (table 3). There is defined the required resolution of integer type for color storage in XYZ and LAB models – it is 32-bit long, and also the scaling factor: 10^3 and 10^4 correspondingly for XYZ and LAB. In example task of segmentation of hand area from test image (fig. 5), the factors Δd_x i k_x have been evaluated, that define the potential ability of given model to resolve the colors (table 4). The optimal results have been given by HSV model (huge values of k_x factor for samples from outside of the hand, and small values of Δd_x factor, defining the samples coherence in color space). What's more, the best promising LAB model has given proportionally small value of k_x for white-yellow color pair.

In the end, features of new color space dedicated to segmentation (CSS) have been defined. In particular, the CSS model should not contain special colors, like white or black – they should be treated in the same way as the other colors represented in the model. The distances of base colors should all be the same and possibly maximal. The model does not have to be compatible with human mechanism of color perception. The explicitly defined color

model has to contain the algorithm A of distribution of colors in space (29), that determines the relation of color position in space to values of accessible measurable parameters. The function d of color difference (20) may be defined indirectly by evaluating the distance of points in color space (28) or directly (30) in a way suitable for implementation with soft-computing algorithms.

ANALIZA DANYCH O BARWIE W MODELI RGB I HSV DŁA POTRZEB KONWERSJI NA OPIS SŁOWNY

Streszczenie. Artykuł przedstawia badania dotyczące sposobu klasyfikacji kolorów w algorytmach rozpoznawania twarzy dla osób niedowidzących. W ramach badań przeprowadzono analizę wybranych modeli kolorów RGB i HSV, na podstawie których sprawdzono, które z nich najlepiej pasowałyby do opisu kolorów w sposób słowny i łatwy o barwy przydatny dla osób niedowidzących.

ANALYSIS COLOUR DATA IN RGB AND HSV MODEL FOR CONVERSION TO VERBAL DESCRIPTION

Summary. The article describes research for classification for face-recognition device for blind people by researchers who are blind themselves. RGB and HSV model for color description is investigated and suitability for verbal color data theory with data in both models.

1. Wprowadzenie

Opisze w tym artykule wybranych zagadnień związanych z tym problemem. Klasyfikacja kolorów w algorytmach rozpoznawania twarzy dla osób niedowidzących, tego rodzaju badania, wymagają odpowiedniego wyboru parametrów, których opis słowny kolorów przydatny dla osób niedowidzących. W artykule sprawdzono, które z nich najlepiej pasowałyby do opisu kolorów w sposób słowny i łatwy o barwy przydatny dla osób niedowidzących. W ramach badań przeprowadzono analizę wybranych modeli kolorów RGB i HSV, na podstawie których sprawdzono, które z nich najlepiej pasowałyby do opisu kolorów w sposób słowny i łatwy o barwy przydatny dla osób niedowidzących.