

Piotr STERA

Politechnika Śląska, Instytut Informatyki

ANALIZA DANYCH O BARWIE W MODELU RGB I HSV DLA POTRZEB KONWERSJI NA OPIS SŁOWNY

Streszczenie. Artykuł przedstawia badania związane z projektem klasyfikatora do urządzenia rozpoznającego barwy dla osób niewidomych. W ramach badań przeprowadzono analizę przydatności modelu RGB i HSV na potrzeby projektu. Sprawdzone także możliwości zastosowania teorii zbiorów przybliżonych w połączeniu z danymi o barwie przedstawionymi w obu modelach.


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

Summary. The article describes researches for classifier for the color recognition device for blind people. In researches was analyzed data in RGB and HSV model for project necessities. It was checked also possibility apply rough sets theory with data in both models.

1. Wprowadzenie

Opisane w niniejszym artykule zagadnienia stanowią część projektu, którego celem jest skonstruowanie prostego w obsłudze i małego rozmiarami urządzenia umożliwiającego osobom niewidomym rozpoznawanie barw przedmiotów. Schemat ideowy całości został przedstawiony na rys. 1. Literatura opisuje kilka prób skonstruowania podobnego urządzenia. "Color Tell" opisany w [1] rozpoznaje zaledwie 6 barw. Z kolei konstrukcja opisana w [2] rozpoznaje 10 barw, jednak oparcie jej na sztucznych sieciach neuronowych oznacza, że nie można w łatwy sposób zwiększyć liczby rozpoznawanych barw – wymaga to rekonstrukcji elementu klasyfikującego i uczenia sieci neuronowej rozpoznawania od

początku. Urządzenie, którego projekt jest opisywany w tym artykule, ma z jednej strony pozwalać na rozpoznawanie możliwie dużej liczby barw, a z drugiej pozwalać w prosty sposób zmieniać ten parametr w zależności od preferencji użytkownika. Badania przedstawione poniżej skupiają się na elemencie nazwanym *lingwistycznym klasyfikatorem barw* (zob. rys. 1). Jak wynika z rysunku, jego zadaniem jest przetworzenie danych otrzymanych z czujnika i wygenerowanie na ich podstawie odpowiedniej wartości dla generatora mowy. Element ten ma swoim działaniem naśladować sposób postrzegania barw przez człowieka.



Rys. 1. Schemat ideowy projektowanego urządzenia

Fig. 1. The scheme of designed device

Najbardziej uznana spośród teorii opisujących postrzeganie barw jest teoria Younga-Helmholtza, która zakłada istnienie w siatkówce oka ludzkiego trzech substancji światłoczułych reagujących na długości światła odpowiadające barwom: czerwonej, zielonej i niebieskiej, a mózg na podstawie stopnia pobudzenia każdej z tych substancji daje wyobrażenie o barwie ([3], [4]). Sposób odbioru barwy jest również zależny od indywidualnych predyspozycji danej osoby (stan oka i systemu wzrokowego, charakterystyk transmisyjnych receptorów i ośrodków nerwowych oraz poprzednich doświadczeń przy obserwacji podobnego obiektu) [4], a więc jest w pewnym stopniu subiektywny. Zatem również sposób nadania nazwy słownej barwie może być niejednoznaczny. Naukowcy podają bardzo różną liczbę rozróżnianych przez człowieka barw, jednak na potrzeby omawianego tu klasyfikatora należy przyjąć jedynie podstawowy zestaw nazewnictwa barw. Wynika to z ograniczonych możliwości osoby niewidomej wyobrażenia sobie znaczenia słów opisujących rzeczywistość, której nie może sama doświadczyć, zwłaszcza jeśli jest niewidoma od urodzenia. W takim przypadku jej rozumienie słów z tego zakresu ogranicza się do kojarzenia z nazwą barwy przedmiotów, którym się ją przypisuje (np. mleko jest białe).

Uwzględniając powyższe uwagi przyjęto, że dane dostarczane przez czujnik będą w formie liczb opisujących składowe RGB barwy (Red – czerwony, Green – zielony, Blue – niebieski) oraz dodatkowo będzie również przekazywana informacja o całkowitym zarejestrowanym natężeniu światła.

W ramach badań wyróżniono dwa typy obliczeń:


- obliczenia potrzebne do zbudowania klasyfikatora (algorytm, zaszyta sprzętowo wiedza) wykonane w fazie jego projektowania;
- obliczenia wykonywane każdorazowo przy rozpoznawaniu barwy w fazie użytkownika projektowanego urządzenia.

Ponieważ założenia projektu mówią o prostym i tanim urządzeniu, więc badania były prowadzone pod kątem minimalizacji kosztów obliczeń na etapie użytkowania, których ilość i złożoność wpływa bezpośrednio na stopień skomplikowania urządzenia, a w związku z tym na jego koszt i rozmiary.

Rzeczywisty czujnik, który zostanie zastosowany w projektowanym urządzeniu, nie przewyższy skanera w wierności przetwarzania barwy na składowe RGB, więc można przyjąć w tym przypadku skaner jako urządzenie wzorcowe. Jako zbiór danych do przeprowadzenia badań użyto 167 rzeczywistych próbek barw, z których każdą zeskanowano w rozdzielczości 8 bitów dla każdej składowej RGB (rozdzielczość ta jest zdecydowanie nadmiarowa, ale zastosowano ją, aby nie okazało się w trakcie przeprowadzania badań, że przyjęto wartość zbyt małą). Zestaw próbek został tak dobrany, aby w miarę możliwości reprezentował barwy z całej przestrzeni RGB.

2. Analiza przydatności modelu RGB do klasyfikacji barw

Dane przekazywane przez czujnik do klasyfikatora są liczbami opisującymi barwę w przestrzeni RGB. Przestrzeń ta ma kształt sześcianu (rys. 2).



Rys. 2. Model RGB

Fig. 2. The RGB model

Najprostszym rozwiązaniem problemu byłoby bezpośrednie zastosowanie danych dostarczanych przez czujnik do klasyfikacji, a więc liczb opisujących barwę w modelu RGB. Dlatego w tej części badania polegały na próbie zastosowania wzorów geometrycznych do wyodrębnienia zbiorów punktów reprezentujących tę samą barwę w sensie leksykalnym. Dla potrzeb tej analizy ustalono zbiór słów mogących wystąpić jako efekt klasyfika-

cji barwy (biały, szary, czarny, żółty, pomarańczowy, różowy, czerwony, zielony, niebieski, fioletowy, brązowy) i każdej z próbek przypisano odpowiednią nazwę. Następnie próbowano tak utworzone zbiory interpolować do prostych brył.

Pierwszą bryłą wziętą pod uwagę była kula:

$$f(r, g, b) = \{(r, g, b) \in D^3 : r^2 + g^2 + b^2 \leq R^2\} \quad (1)$$


gdzie r, g, b są wartościami składowych barwy w modelu RGB; D jest zakresem wartości, jakie te zmienne mogą przyjmować, a R promieniem kuli. Kule utworzono tak, aby zawierały wszystkie elementy danego zbioru. Wiele z nich miało jednak części wspólne z kulami opisującymi inne barwy, np. kula dla barwy szarej obejmowała prawie całą przestrzeń RGB (jej średnicę stanowiła prawie cała przekątna KW sześcianu RGB; zob. rys. 2).

Kolejną bryłą wziętą pod uwagę była elipsoida:

$$f(r, g, b) = \left\{ (r, g, b) \in D^3 : \frac{r^2}{R_1^2} + \frac{g^2}{R_2^2} + \frac{b^2}{R_3^2} \leq 1 \right\} \quad (2)$$

gdzie R_1, R_2 i R_3 są półosiami elipsoidy. Efekt był podobny do otrzymanego w przypadku kuli.

Wykorzystując wnioski wypływające z analizy tych brył, odrzucono sensowność zastosowania walca. Charakter skupisk punktów odpowiadających tej samej nazwie barwy jest bardzo różnorodny, np. odcienie szarości tworzą bryłę zbliżoną do walca o osi będącej główną przekątną sześcianu tworzącego przestrzeń RGB, zaś barwa niebieska czy czerwona wycinek kuli o środku będącym wierzchołkiem tego sześcianu (rys. 3).



Rys. 3. Klastry dla barwy szarej i niebieskiej w modelu RGB

Fig. 3. Clusters for gray and blue colours in RGB model


Badania te doprowadziły do wniosku, że lepszymi parametrami, którymi można opisać powstałe zbiory punktów, są:

- kąt pomiędzy główną przekątną sześcianu a prostą łączącą środek ciężkości grupy z punktem odpowiadającym barwie czarnej;
- kierunek, w którym ta prosta jest skierowana;
- odległość od punktu odpowiadającego barwie czarnej.

Są to parametry odpowiadające barwie opisanej w modelu HSV (Hue – odcień, Saturation – nasycenie, Value – wartość) – wystarczy utworzyć płaszczyznę prostopadłą do głównej przekątnej sześcianu zawierającą punkt odpowiadający barwie białej, zrzutować na nią pozostałe wierzchołki sześcianu RGB i tak powstałe punkty połączyć z punktem odpowiadającym barwie czarnej – otrzymuje się w ten sposób ostrosłup modelu HSV.

3. Analiza przydatności modelu HSV do klasyfikacji barw

W tej części badań założono, że pierwotne dane z modelu RGB zostaną przeliczone na model HSV. Oznacza to, że koszt obliczeniowy (a zarazem złożoność i cena urządzenia) odpowiednio zostaną zwiększone o blok konwertera danych. Model HSV został przedstawiony na rys. 4.



Rys. 4. Model HSV

Fig. 4. The HSV model

Konwersję danych z modelu RGB na model HSV opisują poniższe wzory:

$$v = \max(r, g, b) \tag{3}$$


$$s = \begin{cases} 0 & \text{dla } v = 0 \\ \frac{v - \min(r, g, b)}{v} & \text{dla } v \neq 0 \end{cases} \tag{4}$$

$$h = \begin{cases} UNDEFINED & \text{dla } v = \min(r, g, b) \\ \frac{\pi}{3} \frac{g - b}{r - \min(r, g, b)} & \text{dla } v = r \\ \frac{\pi}{3} \left(2 + \frac{b - r}{g - \min(r, g, b)} \right) & \text{dla } v = g \\ \frac{\pi}{3} \left(4 + \frac{r - g}{b - \min(r, g, b)} \right) & \text{dla } v = b \end{cases} \tag{5}$$

Model HSV jest bardzo bliski w swojej koncepcji systemowi Munsella [5], który ze swojego założenia porządkuje barwy wg tego, jak są one postrzegane przez człowieka i opisuje

każdą barwę trzema parametrami: odcień (Hue), chroma (Chroma – zawiera w sobie nasycenie i jasność) oraz walor (Value). Różnica w stosunku do modelu HSV polega na tym, że w ramach każdego parametru system ten zachowuje równomierne rozmieszczenie percepcyjne. Układ barw jest tu z założenia tworzony na podstawie danych doświadczalnych. Opisano już matematycznie formuły transformujące składowe RGB do systemu Munsella [6], jednak są one zbyt złożone, aby mogły zostać zastosowane w projektowanym urządzeniu. Model HSV można jednak, mimo jego niejednorodności percepcyjnej, przyjąć za pewnego rodzaju przybliżenie systemu Munsella.

Badania polegały na sprawdzeniu możliwości klasyfikacji barw wg przyjętych założeń w modelu HSV. Określono zbiór rozpoznawanych 9 barw wynikający bezpośrednio ze struktury modelu: czerwony (R), żółty (Y), zielony (G), cyjan (C), niebieski (B) i magenta (M) oraz czarny, szary i biały. Przestrzeń HSV podzielono w następujący sposób: punkty ostrosłupa leżące nie dalej niż $1/9$ zakresu parametru S są interpretowane jako achromatyczne, przy czym jest to barwa biała, gdy parametr V osiąga wartość maksymalną; barwa czarna, gdy jest on mniejszy niż 30 % dostępnego zakresu, zaś szara w pozostałych przypadkach. Pozostałą część bryły podzielono równomiernie wycinając z niej jednakowe fragmenty co 36° według parametru H. Przedstawia to rys. 5.



Rys. 5. Klastry w modelu HSV

Fig. 5. Clusters in HSV model

Przy tak zadanych warunkach badano skuteczność rozpoznawania, przy czym przyjęto dwie metody postępowania:

- optymistyczną – oceniano, czy nazwa nadana przez klasyfikator jest do przyjęcia w zestawieniu z odebrany wrażeń barwnym;
- realną – każdej próbce przypisano nazwy, jakie mógłby im przypisać człowiek (z dostępnego zbioru) i porównywano z tymi, które wygenerował klasyfikator.

Skuteczność rozpoznawania przedstawia tab. 1 w części oznaczonej jako $\delta+3$. Analiza najbardziej problematycznych do zakwalifikowania próbek doprowadziła do wniosku, iż należy zwiększyć liczbę rozpoznawanych barw. W szczególności wskazane było dodanie

nazwy *brązowy*. W tym celu podzielono zakres parametru V dla barw chromatycznych w miejscu, gdzie osiąga on wartości 80 % zakresu i przypisano części odpowiadającej większym wartościom etykiety barw jasnych, zaś drugiej części barw ciemnych. Wyróżniono przy tym barwę *brązowy* jako *ciemny żółty* i *ciemny czerwony*. Dla tak zdefiniowanych warunków powtórzono proces rozpoznawania. Wyniki zawiera tab. 1 w części oznaczonej jako 11+3.

Tabela 1
Skuteczność rozpoznawania dla modelu HSV
(+ — prawidłowe; - — nieprawidłowe)

Badanie	Optymistyczne		Realne	
	+	-	+	-
6+3	91.0%	9.0%	73.7%	26.3%
11+3	91.2%	8.8%	74.1%	25.9%

Porównanie liczb w tabeli dla rozpoznawania *optymistycznego* i *realnego* pokazuje stopień wpływu subiektywności na te liczby. Mimo to widać również, iż taka metoda po dopracowaniu może okazać się użyteczna w prowadzonym projekcie. Metoda ta pozwala sklasyfikować każdą barwę możliwą do zapisania w modelu HSV.

4. Zastosowanie zbiorów przybliżonych do klasyfikacji barw

Zastosowanie zbiorów przybliżonych pozwala bez wnikania w opis matematyczny zagadnienia jedynie na podstawie odpowiednio dużej liczby danych zdefiniować reguły rządzące procesem wnioskowania. Jako kryterium jakości otrzymanych reguł przyjmuje się ich liczbę oraz ich wzajemną niesprzeczność. Opis metod analizy danych za pomocą zbiorów przybliżonych można znaleźć w [7].

W trakcie próby zastosowania zbiorów przybliżonych natknięto się na kilka poważnych trudności wynikających z właściwości tej metody badawczej. Pierwszą była duża wrażliwość na zakłócenia pojawiające się w danych (ze względu na sposób ich uzyskania nie można dać gwarancji, iż się nie pojawiają). Drugim problemem było wygenerowanie wszystkich kombinacji danych wejściowych i oczekiwanych odpowiedzi klasyfikatora (zalecane, aby klasyfikacja mogła być poprawna w 100%). Z drugiej strony taka liczba danych wymagałaby olbrzymich mocy obliczeniowych do ich przetworzenia (tzw. przekleństwo wymiarowości).

Po kilku nieudanych próbach znalezienia zadowalających rezultatów przy spełnieniu częściowym powyższych warunków zrezygnowano z takiego sposobu zastosowania zbiorów przybliżonych. Podyktowane było to również tym, że chęć zmiany zestawu rozpozna-

wanych barw oznaczała w tym przypadku konieczność powtórzenia przeprowadzonych obliczeń dla innego zestawu danych.

Zbiory przybliżone wykorzystano natomiast do próby odpowiedzi na pytanie, jaka reprezentacja danych o barwie jest najkorzystniejsza z punktu widzenia postawionego problemu. W tym celu przygotowano odpowiedni zestaw danych, gdzie atrybutami warunkowymi były parametry barwy zapisane w trzech formatach:

- składowe RGB;
- wzajemne proporcje składowych RGB (R:G, R:B, G:B);
- parametry HSV.

Badania wykonano na dwa sposoby. W pierwszym atrybuty warunkowe stanowiły parametry ze wszystkich trzech postaci zapisu barwy. Wyniki obliczeń przedstawia tab. 2. Wartości zawarte w tabeli to liczba reguł, w której występuje dany atrybut oraz liczba obiektów (danych, na podstawie których były generowane reguły), do których odnoszą się reguły zawierające dany atrybut. Porównując całe modele zdecydowanie największy wpływ na reguły ma model HSV, co oznacza, że on najlepiej reprezentuje barwę dla badanego zagadnienia. Nieco gorzej wypada reprezentacja RGB. Zaskakujące jest to, że atrybuty związane z proporcjami składowych RGB mają mały udział w regułach, choć wg teorii opisanej w [3] (powołując się na [8]) wzajemne proporcje składników RGB bardziej odpowiadają temu, jak postrzega je człowiek niż ich bezwzględne wartości. Z analizy szczegółowych danych wynika, że w ramach modelu RGB największe znaczenie mają bity najstarsze (co wydaje się oczywiste), zaś w ramach modelu HSV najbardziej znaczącym czynnikiem jest parametr H.

Tabela 2

Statystyczne pokrycie danych przez wygenerowane reguły

sposób opisu barwy	model RGB	proporcje RGB	model HSV
średnia liczba udziału w regułach	346	151	406
średnia liczba pokrytych obiektów	1130	640	1456

Druga metoda obliczeń polegała na wygenerowaniu reguł osobno dla każdego sposobu zapisu informacji o barwie i porównaniu liczby wygenerowanych reguł (im mniej tym lepiej). Zestawienie wyników zawiera tab. 3. Szczegółowa analiza wyników obliczeń tą metodą potwierdza wnioski uzyskane z obliczeń przeprowadzonych pierwszym sposobem. Okazało się też, że opis proporcjami składowych RGB może powodować niejednoznaczności ze względu na błędy zaokrągleń związane z operacją dzielenia przy generacji tych proporcji.

Tabela 3

Liczba wygenerowanych reguł dla różnych sposobów opisu barwy

sposób opisu barwy	model RGB	proporcje RGB	model HSV
liczba reguł	370	397	350

Badania przeprowadzone przy zastosowaniu zbiorów przybliżonych prowadzą do wniosku, że bezpośrednie zastosowanie tej metody w klasyfikatorze barw jest niecelowe. Okazała się ona jednak użyteczna w fazie projektowania tego elementu.

5. Podsumowanie

Z przeprowadzonych badań wynika, że najbardziej obiecujący z punktu widzenia założeń projektu jest model HSV. Jego zastosowanie jest jednak związane z konwersją składowych RGB do tego modelu, co komplikuje nieco urządzenie i zwiększa jego koszt. Model RGB również daje perspektywy zastosowania. Natomiast wydaje się, że oparcie się na wzajemnych stosunkach wartości składowych RGB jest bezcelowe.

Przeprowadzone analizy i badania skłaniają do wniosku, że jest możliwe zastosowanie jako klasyfikatora w postaci opisu przestrzeni modelu HSV podzielonej w miarę nieskomplikowany sposób na fragmenty odpowiadające nazwom słownym barw i funkcji badającej przynależność wartości parametrów otrzymanych z czujnika do każdego ze wspomnianych fragmentów przestrzeni HSV. Natomiast wydaje się, że liczba danych, złożoność obliczeniowa, wrażliwość na dane zakłócone i trudności w modyfikacji klasyfikatora w przypadku zmiany słownika opisującego barwy wskazują na niecelowość zastosowania teorii zbiorów przybliżonych bezpośrednio w projektowanym urządzeniu.

LITERATURA

1. Nguyen D. T., Kennedy H., Cornwall J.: A Vocalized Color Recognition System for the Blind. IEEE Transactions on Instrumentation and Measurement, June 1984, vol. IM-33, No 2, s. 122-126.
2. Stoksik M., Nguyen D. T., Czernkowski M.: A Neural Net Based Color Recognition System. Proceedings of 2nd International Conference on Artificial Neural Network, Bournemouth 1991, s. 86-89.
3. Ostrowski M. – red.: Informacja obrazowa. WNT, Warszawa 1992.
4. Red. Zabrodzki J.: Grafika komputerowa. WNT, Warszawa 1994.
5. Munsell Book of Color, <http://www.it.lu.fi/research/color/database/munsell.html>.

6. Miyahara M., Yoshida Y.: Mathematical transform of (r, g, b) color data to Munsell (h, v, c) color data. SPIE Visual Communications and Image Processing, 1988, vol. 1001, s. 650-657.
7. Mrózek A., Płonka L.: Analiza danych metodą zbiorów przybliżonych. Zastosowanie w ekonomii, medycynie i sterowaniu. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1999.
8. Duda R. O., Hart P. E.: Pattern classification and scene analysis. New York, Wiley 1973.

Recenzent: Dr inż. Henryk Palus

Wpłynęło do Redakcji 15 grudnia 1999 r.

Abstract

The article describes classifier for the color recognition device for blind people. The main project's idea is presented on fig. 1. The sensor gives data for the classifier as RGB parameters and summary light intensity. As a result of recognition process I obtain a word corresponding to input data.

First, I try to define fragments of the RGB space (fig. 3) and the HSV space (fig. 5) for each word taken from vocabulary. Only the HSV space fragmentation was effective enough to apply it in the project. Results are presented in tab. 1.

Second, I test rough sets in this problem, but it was not effective way. It is caused by huge number of necessary data, complexity computation, sensitivity to interference in data and problems with modification of the classifier for changed vocabulary. Rough sets let to determine which model was the best for use in described project (results are in tab. 2 and 3). The HSV model is better, but it needs the RGB to HSV convertor. That cause growing the device's cost. Proportions of the RGB parameters (R:G, R:B, G:B) were the worst from among considered models. The raw RGB parameters are a little worse then HSV parameters.