

State-of-the-art
in image segmentation

Jarosław Marek Gliwiński
#indeksu 74839

1 października 2009

Spis treści

1	Wstęp	2
2	Klasyfikacja metod segmentacji	2
3	Opis wybranych rodzajów metod segmentacji	3
3.1	Punktowe	3
3.1.1	Podział na klastry	3
3.1.2	Progowanie histogramów	4
3.2	W domenie obrazu	4
3.2.1	Rozrost obszaru	5
3.2.2	Podział i łączenie	5
3.2.3	Krawędzie	6
3.3	Własności obiektów	6
3.4	Podsumowanie	7
4	Przykłady nowoczesnych metod segmentacji	7
4.1	Segmentacja oparta na próbkach tekstur obrazu (2007)	7
4.2	„Solidne” statystyki (2009)	7

1 Wstęp

W ogólności segmentacja obrazu (*ang. image segmentation*) to proces podziału obrazu na obszary homogeniczne pod względem określonych własności. W teorii możliwa jest bardzo szeroka interpretacja tego terminu, w praktyce jednak najczęściej celem segmentacji jest identyfikacja i grupowanie punktów obrazu według określonych cech semantycznych. O ile segmentacja ze względu na podstawowe cechy obrazu, takie jak kolor czy jasność, jest względnie nieskomplikowana, o tyle w przypadku podziału sceny fotografii na obszary odpowiadające fizycznym obiektom o określonych własnościach jest wciąż otwartym problemem zarówno teoretycznym, jak i technicznym.

Narzędzia i algorytmy związane z segmentacją są integralną częścią znaczącej części przemysłowych, komercyjnych, jak i badawczych zastosowań multimedialnych związanych z przetwarzaniem i analizą obrazu. Ta praca skupia się na przeglądzie współcześnie stosowanych i proponowanych metod segmentacji.

2 Klasyfikacja metod segmentacji

Jak przystało na permanentnie rozwijaną gałąź techniki, klasyfikacja metod segmentacji może zostać przeprowadzona na wiele równorzędnych sposobów. Przykładowo, podział metod segmentacji ze względu na rodzaj informacji wykorzystywanej bezpośrednio w czasie segmentacji[5] wygląda następująco:

- metody punktowe
 - progowanie
 - klasteryzacja

- metody krawędziowe
 - metody obszarowe
 - rozrost obszarów (*region growing*),
 - łączenie obszarów (*region merging*),
 - podział obszarów (*region splitting*),
 - metoda podziału i łączenia (*split & merge*),
 - segmentacja wododziałowa (*watershed segmentation*),
- metody hybrydowe – wykorzystujące dwie lub więcej z powyższych metod

Innym rodzajem klasyfikacji może być bardziej ogólny ze względu na wykorzystywane cechy obiektów występujących w rzeczywistości[2]. Według tego podziału możemy wyróżnić metody:

- wykorzystujące przestrzeń cech obiektów (*feature-space techniques*)
- działające w domenie obrazu (*image-domain techniques*)
- wykorzystujące naturalne właściwości obiektów (*physics based techniques*)

Jak łatwo zauważyć, przytoczone kategorie „zazębiają się”, jednak nie sposób izomorficznie rzutować jedna na drugą. Dalsze rozważania nie będą ściśle przestrzegać żadnego z tych podziałów, jakkolwiek oczywiście będą w pewien sposób uporządkowane na wzór powyższych klasyfikacji

3 Opis wybranych rodzajów metod segmentacji

3.1 Punktowe

Pierwsza grupa technik segmentacji wykorzystuje fakt, że każdy punkt w obrazie ma kolor, określony współrzędnymi w jakiejś przestrzeni kolorów, dlatego możemy wyróżnić i stworzyć grupy składające się z pikseli, które w zamyśle odpowiadać mają wykrytym obiektom. Wpływ na odpowiedni podział na mogą mieć cienie i sposób odwzorowania kolorów w obrazie. W tym przypadku problem segmentacji obrazu sprowadza się do znalezienia klastrów poprzez odpowiedni algorytm wyszukiwania pikseli o tych samych, bądź według zdefiniowanej miary podobnych, cechach. Innym podejściem jest stworzenie histogramów na podstawie liczby występujących pikseli o spełniającym określone warunki danym kolorze i analizowanie tak pobranych informacji. Można zatem wyróżnić w tej grupie technik:

3.1.1 Podział na klastry

Metodę klasteryzacji można krótko określić jako klasyfikację obiektów ze względu na ich cechy. Przypisywanie poszczególnych punktów obrazu do danego klastra może odbywać się ze względu na kolor. W bardziej ścisły sposób technikę tę możemy opisać w następujący sposób:

Mamy M wzorców x_1, \dots, x_m w pewnej przestrzeni kolorów \mathcal{S} . Technika podziału na klastry w tak zdefiniowanym środowisku polega na wyznaczeniu regionów S_1, \dots, S_k takich, że każdy wzorec x_i należy do wyłącznie jednego regionu S_j .

Przykładami algorytmów z podziałem na klastry są algorytmy miękkoodecyzyjne takie jak algorytm k-means (iteracyjne obliczanie środków regionów przy początkowo losowym ich rozmieszczeniu) czy jego modyfikacja ISODATA (*Iterative Self-Organizing Data Analysis Technique*) pozwalająca na dzielenie bądź łączenie regionów na podstawie ich własności – dzielenie na podstawie wariancji, łączenie na podstawie miary odległości środków regionów.


3.1.2 Progowanie histogramów

Progowanie jest naturalną metodą w przypadku obrazów monochromatycznych. Fakt, iż taki obraz posiada jeden jednoznacznie opisujący jego własności histogram oparty na jasności punktów czyni go wygodną metodą analizy dla tego przypadku. Łatwo uzyskać wyraźne obrazy wynikowe progowania (Ryc. 1b), jednak istotny jest właściwy wybór poziomu progu (Ryc. 1c, 1d). Ponadto istotną częścią algorytmu jest wygładzanie i „czyszczenie” histogramu z szumów.


Algorytmy tego typu zastosowane dla obrazu kolorowego muszą analizować po jednym histogramie na kanał barwy podstawowej, a więc operują w przestrzeni wielowymiarowej. W praktyce większość metod wykorzystuje $3D$, dla układu współrzędnych RGB lub LUV, możliwe są też rozwiązania bazujące na segmentacji na podstawie barwy (dla ujednoznacznienia – chodzi o *hue*).




(a) obraz oryginalny



(b) obraz po segmentacji, próg właściwy



(c) obraz po segmentacji, próg zbyt niski



(d) obraz po segmentacji, próg zbyt wysoki

Ryc. 1: Progowanie histogramu

3.2 W domenie obrazu

Nazwa grupy zwanej technikami w domenie obrazu (*Image-Domain Techniques*) swoją nazwę zawdzięcza operowaniu nie na punktach, ale na „podobrazach” stanowiących rozłączne obszary obrazu. Oparte jest to na spostrzeżeniu, że szukane obiekty mogą być homogeniczne,

jednak niekoniecznie muszą być ograniczone w przestrzeni do punktu – pojedynczy obiekt może zająć istotną powierzchnię obrazu, a analiza punktowa nie pozwala na uzyskanie informacji o dokładnych granicach obszarów przynależących do poszczególnych obiektów.

Opracowano wiele metod określania rozmieszczenia w przestrzeni i rozmiarów obiektów, a także tzw. *spatial compactness*, rozmiarów przestrzennych. W ogólności tę grupę technik można podzielić na przykład w następujący sposób:

3.2.1 Rozrost obszaru

Metody segmentacji oparte na zasadzie rozrostu obszarów (*region growing*) polegają na rozszerzaniu początkowo wybranego punktu. Wzrost trwa do momentu osiągnięcia granicy zbioru punktów obrazu dających się zakwalifikować do grupy o danych własnościach. Proces taki można porównać z sekwencyjnym tworzeniem klastrów w obrazie.

Ponownie naturalnym zastosowaniem dla tej klasy metod są obrazy o jednowymiarowej przestrzeni barw, algorytmy operujące przy takim założeniu są dobrze dopracowane i stosunkowo skuteczne. W przypadku obrazów kolorowych problem jest bardziej złożony. Wykorzystuje się w tym wypadku metody operujące na współrzędnych w przestrzeniach RGB bądź HSV (*hue saturation value*, w przypadku tego drugiego bywa, że na podprzestrzeni przestrzeni trójwymiarowej).

Poważnym wyzwaniem dla algorytmów z tej grupy jest wybór właściwych punktów startowych, „załączków” rozrostu. Problem optymalnego rozwiązania tej kwestii pozostaje otwarty, niektóre ze stosowanych rozwiązań sprowadzają się do poszukiwania lokalnych ekstremów obrazu – jest to podejście o złożoności i skuteczności zależnej od liczby wymiarów przestrzeni i informacji niesionej przez poszczególne kanały. Przykładowo, korelacja między kanałami RGB zazwyczaj jest wysoka, zatem informacja niesiona przez nie jest podobna, podczas gdy na przykład przestrzenie oparte na luminancji i chrominancjach (LUV , YC_rC_b) z założenia mają kanały słabo skorelowane ze sobą. Stosuje się także wstępny podział obrazu na kwadraty bądź sześciokąty, wyjściowym obszarem, a także elementarną jednostką rozrostu, jest wtedy rzeczywiście obszar, a nie punkt.

3.2.2 Podział i łączenie

Segmentacja przez podział i łączenie, bądź podział i scalanie (*split & merge*) jest techniką opierającą się na niehomogenicznych warunkach początkowych. Algorytm z tej grupy zaczyna na ogół od pojedynczego niehomogenicznego fragmentu obrazu i jest iterowany aż do etapu, na którym obraz jest podzielony na jednorodne obiekty. Kolejnym etapem jest scalanie obszarów, co pozwala połączyć homogeniczne obszary tej samej klasy w jeden. W ogólności etapy mogą występować naprzemiennie, aż do warunku zatrzymania algorytmu, jakim jest osiągnięcie ostatecznego podziału.


W tego rodzaju algorytmach wykorzystuje się różne struktury danych takie jak grafy czy drzewa. Innym podejściem ułatwiającym implementację jest nadreprezentacja obrazu przez tzw. piramidy, tj. przechowywanie i jednoczesne operowanie na wielu wersjach tego samego obrazu o różnych rozdzielczościach. Wariantem wykorzystania reprezentacji piramidowej jest automatycznie łączenie bądź podział przez przemieszczanie się po „piętrach” piramidy.

Jednym z ciekawszych algorytmów wykorzystywanych do podziału obrazu jest triangulacja Delaunay’a, omawiana na laboratorium. Innym nietypowym wariantem, o dużej złożoności, jest reprezentacja każdego punktu obrazu jako niezależnego obszaru. Łączenie następuje na

podstawie pomiaru odległości między sąsiednimi punktami w określonej metryce (na przykład według różnicy barwy).

3.2.3 Krawędzie

Segmentacja przy pomocy krawędzi (*edge based*) także jest wykorzystywana dla szerokiej gamy obrazów, zarówno monochromatycznych jak i kolorowych. Zgodnie z nazwą, algorytmy z tej grupy nie wykrywają bezpośrednio obszarów, a ich wykrywanie odbywa się pośrednio poprzez ustalenie granic pomiędzy nimi. Jedną z najpowszechniejszych metod jest zastosowanie operatorów gradientowych, bądź Laplace'a. W ogólności w zależności od założeń i szczegółów implementacyjnych zastosowanie może znaleźć każda z ogólnie stosowanych metod wykrywania krawędzi, możliwe jest także użycie specjalizowanych metod dla konkretnego przypadku.



(a) obraz oryginalny

(b) obraz po segmentacji

Ryc. 2: Segmentacja krawędziowa

3.3 Własności obiektów

Ostatnią grupą metod segmentacji obrazów są techniki wykorzystujące naturalne własności obiektów. Tego typu rozwiązania wykorzystują oświetlenie, rozbłyśki światła na materiałach odbijających światło, cienie i półcienie, co pozwala na uniknięcie pewnych klas błędów w segmentacji, którymi obarczone są pozostałe metody. W tym przypadku analizowane jest jak światło oddziałuje z obiektami na obrazie.

Narzędzia używane w tego typu metodach wykorzystują model matematyczny opisujący zachowanie się światła – na podstawie własności materiałów oraz zasad optyki, podobnych jak na przykład w algorytmach używanych do zaawansowanego ray-tracingu. Dla obrazów kolorowych można rozróżnić 3 kategorie obiektów:

- niejednorodnie optycznie dielektryki
- jednorodnie optyczne dielektryki
- metale

Osiągnięciem umożliwiającym rozwój tej dziedziny było opracowanie modelu opisującego odbicia od takich obiektów, wiążącego promieniowanie odbite z geometrią obiektu, materiałem i długością fali.

Efektywność tego rodzaju metod zależy w dużym stopniu od własności oświetlenia, takich jak kolor światła, czy ilość i wzajemne rozmieszczenie jego źródeł. Algorytmy dla wielu źródeł światła muszą rzecz jasna mierzyć się z dodatkowym zagadnieniem rozróżniania poszczególnych źródeł na podstawie efektów ich działania. Teoretyczny projekt jak i implementacja jest wtedy trudniejsza, jednak prawidłowo opracowany algorytm ma szansę na wysoką efektywność ze względu na dodatkowe informacje przenoszone przez dodatkowe odbicia, cienie, etc.

3.4 Podsumowanie

Na podstawie przeprowadzonego przeglądu najistotniejszym możliwym spostrzeżeniem jest fakt, nieistnienia uniwersalnego algorytmu segmentacji. Każda metoda daje inne rezultaty w zależności od specyfiki obrazu. Efekty pracy są zależne m.in. od jednorodności, dobrego odgraniczenia, ciągłości obiektów, co jest jedną z głównych przyczyn stosowania metod hybrydowych, łączących wiele podejść w celu eliminacji specyficznych dla danej metody niedoskonałości.

4 Przykłady nowoczesnych metod segmentacji

Po omówieniu ogólnie dziedziny segmentacji pora na podanie przykładów rzeczywistych rozważań akademickich na temat tego zagadnienia.

4.1 Segmentacja oparta na próbkach tekstur obrazu (2007)

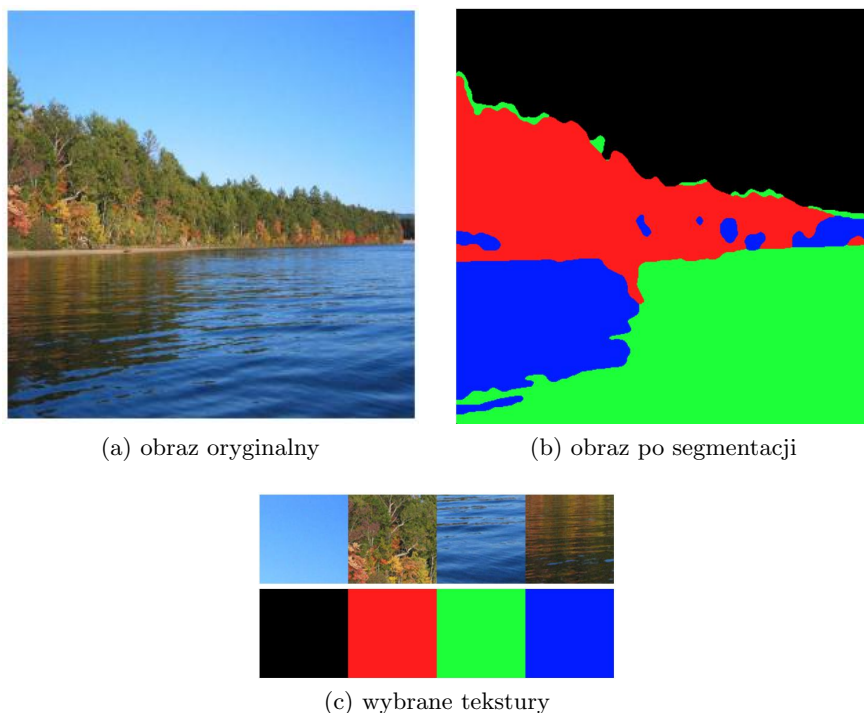
Segmentacja oparta na próbkach obrazu[3] (*example based image processing*) opiera się na spostrzeżeniu, że w pełni automatyczna segmentacja jest być może niewłaściwie zdefiniowanym zagadnieniem, ponieważ taki algorytm nie musi (i częstokroć nie będzie) generować podziału zgodnego z pożądaną interpretacją semantyczną obrazu – a w danym obrazie może być wiele takich interpretacji.

Gallagher proponuje metodę półautomatyczną, w której algorytm dostaje na wejście próbki pochodzące z obrazu odpowiadające pożądanym obszarom wynikowym segmentacji (choć w ogólności mogą one pochodzić spoza obrazu). Na podstawie każdej próbki przy pomocy specjalizowanej transformacji falkowej generowany jest wzorzec tekstury. Sam w sobie proces analizy i generacji tekstur jest znacznym, jeśli nie głównym problemem w tego typu podejściu.

Zastosowanie tego typu algorytmu jest bardzo trudne w wielu dziedzinach, wymagających długotrwałej samodzielnej pracy systemu w zmiennych warunkach, jednak wszystko w tym przypadku zależy od bazy tekstur – a w dziedzinach o stałych kategoriach obszarów (na przykład w medycynie) takie podejście ma duży potencjał. Autor wskazuje na możliwość łatwego rozszerzenia zastosowanych modeli matematycznych o dodatkowe wymiary, a więc przetwarzanie obrazów trójwymiarowych lub sekwencji wizyjnych. Przykład segmentacji metodą zamieszczono na ryc. 3.

4.2 „Solidne” statystyki (2009)

Najnowsza z przytaczanych przykładów metoda segmentacji[4] oparta jest na tzw. *robust statistics*, co można dosłownie tłumaczyć jako „odporne” bądź „solidne” statystyki. W rzeczywistości mowa o dziedzinie matematyki zwanej statystyką odpornościową, obejmującej metody projektowane pod kątem odporności na niewielkie odejście od założeń modelu lub rezygnacji z niektórych założeń[?]. W szczególności mowa tu o tzw. M-estimatorach.



Ryc. 3: *example based image processing*

Metoda używa deskryptorów MPEG-7 do spójnego, standaryzowanego opisu tekstur w obrazie. Algorytm oparty jest na założeniu o geometrycznych zmianach regionu w czasie i na własnościach powierzchni. Ruch jednorodny regionu jest opisywany parametrycznie, co pomaga ustalić granice obszarów. Statystykę odpornościową wykorzystuje się do podejmowania decyzji dotyczących podziału, łączenia i korekcji konturów. Autorzy wykazują, że to podejście owocuje lepszymi niż dla dotychczasowych metod wynikami (dokonali porównania z algorytmem segmentacji MPEG-4).

Dodatek A – publicznie dostępne bazy obrazów testowych

W Internecie dostępnych jest wiele baz o tej tematyce. Przykładowo baza masek stworzona przez Berkeley University dostępna pod adresem:

<http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/segbench/>

Na potrzeby analizy wydajności algorytmów zajmujących się sekwencjami wizyjnymi został opracowany generator sekwencji gtgen (Ground Truth Image Series Generator) umożliwiający generację sekwencji i ich wzorcową segmentację. Jest on dostępny na licencji GNU GPL pod adresem:

http://cbia.fi.muni.cz/projects/optical-flow-for-live-cell-imaging_3.html.

Literatura

- [1] en.wikipedia.org *Segmentation (image processing)*.

- [2] L. Lucchese, S.K. Mitra *Color Image Segmentation: A State-of-the-Art Survey*, Department of Electrical and Computer Engineering, University of California.
- [3] C. Gallagher *Example Based Image Processing*, Signal Processing and Media Applications Department of Electronic and Electrical Engineering, Trinity College, Dublin.
- [4] P. Ndjiki-Nya, S. Gerke, T. Wiegand *Improved video segmentation through robust statistics and MPEG-7 features*, Image Processing Department, Fraunhofer Institute for Telecommunications – Heinrich-Hertz-Institut, Berlin, Germany.
- [5] pl.wikipedia.org *Statystyka odpornościowa*.