


**Teodora DIMITROVA-GREKOW, Sebastian DĄBKOWSKI**

POLITECHNIKA BIAŁOSTOCKA  
ul. Wiejska 45 A, 15-351 Białystok

## Zastosowanie algorytmów przeszukiwania grafów do analizy obrazów medycznych

Dr inż. Teodora DIMITROVA - GREKOW

Ukończyła studia na Wydziale Elektroniki Politechniki Sofijskiej, Bułgaria w 1991r., obroniła pracę doktorską na Uniwersytecie Technicznym w Wiedniu w 1997r. Jest adiunktem na Wydziale Informatyki Politechniki Białostockiej. Jej zainteresowania naukowe to synteza układów programowalnych, robotyka, mechatronika, analiza i przetwarzanie sygnałów.



e-mail: t.grekow@pb.edu.pl

Mgr inż. Sebastian DĄBKOWSKI

Sebastian Dąbkowski ukończył studia w 2011 z tytułem magistra inżyniera na kierunku Informatyka, specjalność Inteligentne Technologie Internetowe, Politechnika Białostocka, gdzie aktualnie studiuje na kierunku Matematyka. Od 2010 pracuje jako programista w technologii .NET. Zainteresowania naukowe to tworzenie aplikacji w chmurze oraz analiza i przetwarzanie obrazów.



e-mail: s.dabkowski@hotmail.com

### Streszczenie

W artykule przedstawiono wyniki testów niekonwencjonalnego zastosowania metod do przeszukiwania grafów w celu analizy obrazów powstałych z rezonansu magnetycznego głowy. Zaprezentowano GUI do automatycznej obróbki serii obrazów. Zbudowane klasyfikatory wykazały, że metoda BFS analizy plików DICOM, po odpowiedniej selekcji cech, pozwala na 100% rozpoznawanie chorych na wodogłowie i ponad 90% zdrowych, co zachęca do dalszych badań i obserwacji, np. czy osoby sklasyfikowane błędnie jako chorzy, po czasie rzeczywiście nie rozwinęły tej choroby.

**Słowa kluczowe:** analiza obrazów medycznych, algorytmy przeszukiwania grafów, uczenie maszynowe, eksploracja danych, rozpoznawanie choroby.

### Analysis of medical images based on graph search algorithms

#### Abstract

There are many methods for image segmentation [1, 2]: threshold, area, edge and hybrid methods. Area methods indicate groups of similar pixels form local regions [3, 4]. Edge methods detect boundaries between homogeneous segments [5, 6, 7]. In this paper we present the results of tests of unconventional implementation of graph search methods for the analysis of images generated from magnetic resonance imaging [8]. We explored the effectiveness of different approaches for dividing areas within a similar gray scale, using adapted graph search algorithms (DFS, BFS) after appropriate modification (Fig. 1). For this purpose, the Weka package (a tool for pre-processing, classification, regression, clustering and data visualization) was used [9]. A training set was generated after analyzing all the series of images from the database. First, we evaluated models created using certain algorithms and compared their efficacy (Tab. 1). This was followed by a selection of attributes (Tab. 2) and a re-evaluation of the models (Tab. 3). Comparison of the results of both evaluations showed that after selection of the relevant product attributes, you can achieve up to 100% detection of patients with hydrocephalus and over 90% proper recognition of healthy persons. This encourages further research and observation, such as whether persons wrongly classified as sick actually developed the disease in time. We designed a web application for the study, written in Windows Azure, as well as a GUI for automatic processing of a series of images (Fig. 2).

**Keywords:** image analysis, graph search algorithm, machine learning, data mining, disease recognition.

### 1. Wstęp

Nowoczesne metody obrazowania odgrywają bardzo dużą rolę we współczesnej medycynie. Pozwalają one na nieinwazyjną wizualizację budowy ludzkiego ciała, a nawet procesów w nim zachodzących. Badania realizowane przy pomocy rezonansu magnetycznego, tomografii komputerowej lub ultrasonografii mają szerokie zastosowanie w diagnostyce chorób.

Współczesne metody obrazowania medycznego to obszar, na którym stykają się różne dziedziny wiedzy: szeroko pojęta medycyna, fizyka oraz informatyka, a w szczególności cyfrowe przetwarzanie obrazów, w którym głównym podejściem jest podział obrazu na jednolite, według przyjętych kryteriów, obszary, czyli segmentacja [1, 2]. Jednak sama segmentacja nie mogłaby dawać wystarczającej informacji w przypadkach kiedy interesujące obszary posiadają nieregularną strukturę, wiele rozgałęzień lub nie stanowią jednoznacznej ciągłości, jak jest to np. przy niektórych elementach mózgu ludzkiego.

Zautomatyzowanie analizy obrazów rezonansu magnetycznego (MRI) mogłoby w dużym stopniu wspomóc pracę lekarską – uprościć i przyspieszyć detekcję zmian w tkankach, wyróżnianie odmiennych obszarów, przeliczanie objętości wskazanego obszaru itd. Aktualnie lekarze nie posługują się podobnym wsparciem technicznym. W artykule przedstawiono wyniki testów skuteczności niekonwencjonalnego zastosowania metod do przeszukiwania grafów w celu analizy obrazów powstałych z rezonansu magnetycznego. Zaprezentowano również graficzny interfejs służący do automatycznej obróbki serii obrazów. Materiałem badawczym były serie zdjęć (plików DICOM) z MRI głowy 30 osób w różnym wieku i płci. Połowa z tych osób miała zdiagnozowaną chorobę – wodogłowie. Analiza obrazów wyodrębniała zawartość *istoty szarej* (łac. *substantia grisea*: obszar znajdujący się pomiędzy obszarem białym - *istota biała*, a pozostałą częścią mózgu) dla każdego z badanych, wyliczając jej objętość - parametr, który może wskazywać na obecność choroby. Eksperyment bada na ile skuteczne są metody wyodrębniania obszarów o podobnej skali szarości przy pomocy zaadaptowanych algorytmów przeszukiwania grafów. W tym celu wykorzystany został pakiet Weka - narzędzie do wstępnego przetwarzania, klasyfikacji, regresji, grupowania oraz wizualizacji danych [9]. Kryteria oceny tejsze efektywności stanowią rezultaty uczenia się maszynowego rozpoznawania choroby w oparciu o wyniki analizy obrazów, ponieważ każda z zaimplementowanych metod analizy i przeszukiwania obrazu daje nieco inne wyniki końcowe przy obliczaniu objętości *istoty szarej*.

### 2. Analiza obrazów za pomocą algorytmów przeszukiwania grafów

Istnieje wiele metod segmentacji: progowanie, metody obszarowe, krawędziowe i łączone. Metody obszarowe grupują piksele wzdłuż zwarte lokalne regiony [3, 4]. Metody krawędziowe bazują na wykrywaniu granic pomiędzy jednorodnymi obszarami [5, 6, 7]. Kombinacja różnych podejść tworzy metody hybrydowe.

Precyzyjna segmentacja kompleksowa jest szczególnie trudnym zadaniem przy analizie *istoty szarej* mózgu. Wynika to przede wszystkim z jej struktury i umiejscowienia. Dodatkowe problemy sprawiają często niewyraźne kontury, a manualna segmentacja

byłaby bardzo pracochłonna, omijając duże prawdopodobieństwo niedokładności z racji niedoskonałości wzroku ludzkiego [1]. Tak powstał pomysł skorzystania z algorytmów z zupełnie innej dziedziny. Podobieństwo w wizualnej prezentacji grafów i istoty szarej nasunęło idee, że przy stosownej modyfikacji algorytmów przeszukiwania grafów mogłyby się one okazać skutecznym narzędziem wyliczania objętości istoty szarej. Podstawę odróżniania obszarów w niniejszym eksperymencie stanowiła segmentacja rozrost obszarów (ang. *region growing*).

Algorytmy przeszukiwania grafu (DFS, BFS) po dodaniu ograniczeń odpowiednich głębokości oraz ograniczeń czasowych w działaniu bardzo dobrze sprawdzają się jako algorytmy do przeszukiwania sieci [9]. Po wprowadzeniu wartości progowej oraz warunków obszarowych algorytm może znaleźć zastosowanie w przeszukiwaniu obrazów (rys. 1).



Rys. 1. Adaptacja algorytmów przeszukiwania do wykrywania obrazów o podobnej skali szarości

Fig. 1. Adaptation of search algorithms to similar gray-scale area detection

Niniejsza praca porównuje skuteczność trzech różnych wersji segmentacji progowo-obszarowej, niewymagających dużych nakładów obliczeniowych:

- czysta postać;
- kombinacja z metodą przeszukiwania grafu w głąb DFS (ang. *Depth-First Search*);
- kombinacja z metodą przeszukiwania grafu w szerz BFS (ang. *Breadth-First Search*).

Każde z wymienionych podejść stanowi bazę do wyliczenia objętości istoty szarej oznaczanej odpowiednio:  $V_{sgN}$ ,  $V_{sgD}$ ,  $V_{sgB}$ . W celu dalszych badań, zostały one przyjęte jako *cechy podstawowe*. *Dodatkowe cechy* natomiast to wiek (W), płeć (P), rozmiary czaszki -  $C_b$ ,  $C_h$ ,  $C_d$  i inne. W trakcie testów wyłonione zostały również nowe cechy - kompozycje z cech podstawowych i dodatkowych.

### 3. Testy

#### Warunki

Celem testów jest zbadanie, który z zaimplementowanych algorytmów pozwala na podjęcie najbardziej trafnej decyzji czy pacjent ma lub nie ma wodogłowia. Testy zostały przeprowadzone przy pomocy systemu Weka ver.3.6 dla wybranych metod selekcji atrybutów oraz klasyfikacji.

Aplikacja główna tworzy i eksportuje plik \*.arff do systemu Weka. Baza zawiera 30 pacjentów z czego 15 to osoby chore na wodogłowia, a pozostałe to osoby zdrowe. Ważniejsze atrybuty wyznaczone do testów to:

- objętość istoty szarej zwracana przez poszczególnych algorytmów:  $V_{sgN}$ ,  $V_{sgD}$ ,  $V_{sgB}$ ;
- objętość komory mózgowej:  $V_b$ ;
- rozmiary czaszki:  $C_b$ ,  $C_h$ ,  $C_d$  (szerokość, wysokość, głębokość czaszki);
- średnia z  $C_b$ ,  $C_h$ ,  $C_d$ :  $A_c$ ;
- iloczyn z  $C_b$ ,  $C_h$ ,  $C_d$ :  $M_c$ ;
- wiek: W.

Po selekcji atrybutów (cech) system Weka powinien wskazać, które z atrybutów są istotne oraz w jakim stopniu.

#### Przebieg

Zbiór uczący został wygenerowany po analizie wszystkich serii zdjęć z bazy danych. W pierwszej kolejności została wykonana

ewaluacja modeli utworzonych za pomocą wybranych algorytmów oraz porównana została ich skuteczność (tab. 1). Później została przeprowadzona selekcja atrybutów i ponownie została wykonana ewaluacja modeli. Następnie wykonano porównanie wyników obu ewaluacji.

Na podstawie rozbudowanego zestawu cech zbudowano szereg klasyfikatorów, z których część (Functions SimpleLogistic, Trees.LMT) wykazała bardzo wysoką trafność detekcji choroby wodogłowia (tab. 1).

Przedstawiona klasyfikacja została przeprowadzona z uwzględnieniem wyników pracy wszystkich trzech algorytmów. Jak było wcześniej wspomniane, dla każdego pacjenta wyliczone zostały trzy różne objętości istoty szarej (OIS) oznaczone odpowiednio:

$V_{sgN}$  – OIS wg metody podstawowej (rozrost obszarów),

$V_{sgD}$  – OIS wg metody DFS (zmodyfikowanej poprzez metodę DFS rozrost obszarów),

$V_{sgB}$  – OIS wg metody BSF (zmodyfikowanej poprzez metodę BFS rozrost obszarów),

Pozostałe parametry były brane z materiału badawczego i stanowiły informację dodatkową wspomagającą klasyfikację.

Całość tego pierwszego etapu miała na celu zweryfikowanie słuszności podejścia: czy istnieje klasyfikator, który wykaże wystarczająco wysoką trafność (ponad 85%) rozpoznawania osób chorych.

Z tab. 1 widać, iż otrzymane wyniki okazały się bardzo obiecujące. Dla klasyfikatorów *Function SimpleLogistic* oraz *Trees.LMT* trafność ogólna (rozpoznawanie osób chorych i zdrowych) przekroczyła 90%. W obu dwóch przypadkach detekcja chorych (93,33%) jest lepsza niż detekcja zdrowych (86,66%). Te wstępne rezultaty można uznać za bardzo wysokie.

Tab. 1. Trafność detekcji klasyfikatorów

Tab. 1. Classifier accuracy

Klasyfikator	Poprawnie sklasyfikowane przykłady (%)		
	Cross-validation 10		
	Ogólnie	Zdrowi	Chorzy
Bayes.BayesNet	83,35	86,66	79,99
Bayes.NaiveBayes	70,03	73,32	66,65
Functions.Logistic	80,02	86,66	73,32
Functions.SMO	83,35	79,99	86,66
Lazy.IBk	63,37	59,98	66,65
Functions SimpleLogistic	90,01	86,66	93,33
Meta.Dagging	70,03	73,32	66,65
Misc.HyperPipes	73,39	79,99	66,65
Misc.VFI	70,03	66,65	73,32
Trees.RandomTree	73,39	73,32	73,32
Trees.LMT	90,01	86,66	93,33

Następnym bardzo ważnym krokiem była selekcja istotnych atrybutów. Selekcja ta miała zbadać czy i jeżeli tak, w jakim stopniu parametry wyliczone za pomocą testowanych metod segmentacji (DSF i BSF) miały wpływ na wysoką rozpoznawalność chorych osób. Istotność atrybutów, mierzona w procentach, została zbadana dla klasyfikatorów o najwyższych wynikach z tab. 1 metodą Cross-validation w obu kierunkach (Forward i Backward).

Tab. 2 przedstawia dla każdego klasyfikatora atrybuty mające minimum 20% istotności (same znaczenie atrybutów zostało umówione we wcześniejszych rozdziałach). Selekcja wykazała, że spośród interesujących nas atrybutów, wyliczonych za pomocą badanych metod, właśnie *objętość istoty szarej*, wyliczona za pomocą metody BFS ( $V_{sgB}$ ), przyczyniła się do wysokiej trafności wyników rozpoznawania wodogłowia (tab. 2, podkreślone wyniki). Objętości istoty szarej  $V_{sgD}$  i  $V_{sgN}$  nie zostały

wyselekcjonowane przez system Weka, co oznacza że metody za pomocą których zostały one wyliczone nie są wystarczająco skuteczne w przypadku obliczania istoty szarej z obrazów rezonansu magnetycznego.

Tab. 2. Wyniki selekcji atrybutów z użyciem metody WrappSubsetEval w obu kierunkach (Forward i Backward)

Tab. 2. Attribute selection for both directions by WrappSubsetEval metod

Klasyfikator	Atrybuty (istotność, %)	
	Forward	Backward
Functions.SimpleLogistic	1. C <sub>b</sub> (100) 2. W(100) 3. V <sub>sgB</sub> (30) 4. V <sub>b</sub> (20) 5. C <sub>b</sub> (20)	1. C <sub>h</sub> (100) 2. W (100) 3. V <sub>b</sub> (20) 4. V <sub>sgB</sub> (20)
Trees.LMT	1. C <sub>h</sub> (100) 2. W (100) 3. V <sub>sgB</sub> (30) 4. V <sub>b</sub> (20) 5. C <sub>b</sub> (20)	1. C <sub>h</sub> (100) 2. W (100) 3. V <sub>b</sub> (20) 4. V <sub>sgB</sub> (20)

Po zastosowaniu redukcji cech, zgodnie z tablicą tab. 2 testy zostały powtórzone dla wybranych klasyfikatorów. Otrzymane nowe wyniki zostały polepszone, zgodnie z oczekiwaniami. Osiągnięto aż 100% trafność rozpoznawania osób chorych i ponad 90% zdrowych (tab. 3).

Tab. 3. Trafność detekcji klasyfikatorów po selekcji atrybutów  
Tab. 3. Classifier accuracy after the attribute selection

Klasyfikator	Trafność (%) (Cross-validation 10)			
	Ogólnie		Chory	
	Forward	Backward	Forward	Backward
Rule.DecisionTable	63,37	63,37	33,35	33,35
Functions.SimpleLogistic	96,67	96,67	100	100
Trees.J48	63,37	63,37	53,31	53,31
Trees.LMT	96,67	96,67	100	100

#### 4. Interfejs


Aplikacja została napisana w systemie Windows Azure, jako aplikacja webowa. Umożliwia ona lekarzowi skłasyfikowanie nowego pacjenta za pomocą różnych algorytmów.

Opracowany interfejs pozwala na łatwe przeliczanie objętości obszarów o jednakowej skali szarości z wskazanej serii plików DICOM. Pozwala również na wybór metody analizy obrazu, domyślnie stosując metodę BFS.

Oba algorytmy DFS i BFS wykonywane są dla pewnej ilości pikseli startowych, które są wybierane na podstawie wskazanych wartości. Aby w pełni wykorzystać moc komputera w Azure, został dodany kod, który pozwala aby algorytm był uruchamiany w oddzielnym wątku. Synchronizacja wykonywana jest automatycznie przez środowisko .NET.

Cała infrastruktura aplikacji znajduje się w systemie Azure, gdzie przechowywane są pliki DICOM oraz cały moduł decyzyjny Weka. Zastosowanie takiego rozwiązania pozwala na przetestowanie bardzo dużego zbioru pacjentów w krótkim czasie.

Na rys. 2 jest przedstawiony widok aplikacji ilustrujący przeglądanie obrazów (lista plików po prawej stronie) oraz działanie jednego z zaimplementowanych algorytmów. Wybór algorytmu jest dokonywany za pomocą grupy radio-butonów w górnej części okna. Interfejs pozwala na wybór przedziału skali szarości dla selekcjonowanych pikseli (osobno w i poza komorą mózgową). Opcja **Delta** ma wpływ na dostrajanie pracy z użyciem metod DFS i BFS. Na samym dole znajduje się lista tagów danego pliku DICOM.



Rys. 2. Widok przeglądania obrazów oraz ich parametrów

Fig. 2. GUI – images selection and image properties presentation

#### 5. Wnioski

W artykule przedstawiono wyniki testów skuteczności niekonwencjonalnego zastosowania metod do przeszukiwania grafów w celu analizy obrazów powstałych z rezonansu magnetycznego. Analiza obrazów wyodrębniała zawartość *istoty szarej* dla każdego z badanych pacjentów, wyliczając jej objętość - parametr, który może wskazywać na obecność choroby. Przebadano na ile skuteczne są metody wyodrębniania obszarów o podobnej skali szarości przy pomocy zaadaptowanych algorytmów przeszukiwania grafów. Zaprezentowane w artykule wyniki zachęcają do dalszych badań i obserwacji. Można by w przyszłości szukać odpowiedzi na pytanie: czy osoby sklasyfikowane błędnie jako chorzy, po pewnym czasie rzeczywiście nie rozwinęły tej choroby. Planowane jest tworzenie nowych atrybutów opisujących pliki DICOM, które mogłyby polepszyć wyniki klasyfikacji, jak również dalsza rozbudowa bazy pacjentów.

#### 6. Literatura

- [1] Ludwiczuk R., Bochniak A.: Metody segmentacji obrazów medycznych; Przetwarzanie informacji w społeczeństwie informacyjnym, S. 95-99 PWSZ, Biała Podlaska, 2007.
- [2] Liu L., Sclaroff S.: Region segmentation via deformable model-guided split and merge. Boston University Computer Science Technical Report, (24), 2000.
- [3] Ding L., Goshtasby A.: On the Canny edge detector, Elsevier, Pattern Recognition, 34, p721-725, 2001.
- [4] Wanpeng C., Rensheng C., Dong Y.: An illumination-independent edge detection and fuzzy enhancement algorithm based on wavelet transform for non-uniform flood illumination images, Elsevier, Pattern Recognition, 29, 192-199, 2008.
- [5] Cohen I., Cohen L.D.: Finite-element method for active contour models and balloons for 2D and 3D images. IEEE Transactions on Pattern Analysis and Machine Intelligence, 15:1131 - 1147, 1993.
- [6] Caselles V., Catta F., Coll T.: A geometric model for active contours in image processing. Numerische Mathematik, 66(1):1-31, 1993.
- [7] Xu C., Prince J. L.: Snakes, shapes, and gradient vector flow. IEEE Transactions on Image Processing, 7(3):359-369, 1998.
- [8] Pianyhk O. S.: Digital Imaging and Communications in Medicine (DICOM), Springer-Verlag Berlin Heidelberg, 2008.
- [9] Liu B.: Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data, Springer-Verlag Berlin Heidelberg, 2007.

otrzymano / received: 11.04.2012

przyjęto do druku / accepted: 01.06.2012

artykuł recenzowany / revised paper