

Klasyfikacja tekstur w rozpoznawaniu nowotworów wątroby na podstawie serii obrazów tomograficznych

Dorota Duda^{1,2}, Marek Krętowski¹, Johanne Bézy-Wendling²

¹Wydział Informatyki, Politechnika Białostocka

ul. Wiejska 45A, 15-351 Białystok

²Laboratoire Traitement du Signal et de l'Image, INSERM, Université de Rennes I

Campus de Beaulieu, Bâtiment 22, 35042 Rennes CEDEX, France

Kontakt: dordu@ii.pb.bialystok.pl, mkret@ii.pb.bialystok.pl, johanne.bezy@univ-rennes1.fr

Streszczenie: W pracy prezentowana jest nowa metoda opisu tekstur na podstawie dynamicznych tomografii komputerowych wątroby. Obrazy przedstawiające ten sam fragment narządu w trzech typowych fazach akwizycji są analizowane jednocześnie. W ten sposób uwzględnione zostają zmiany ich tekstur pod wpływem propagacji środka kontrastującego. Metodę zastosowano w procesie rozpoznawania typów nowotworów pierwotnych wątroby. Eksperymenty z użyciem różnych zestawów cech teksturalnych oraz dwóch metod klasyfikacji wykazały, że jednoczesna analiza parametrów teksturalnych odpowiadających trzem fazom akwizycji prowadzi do poprawy jakości diagnozy.

Summary: A new approach to texture characterization from dynamic CT scans of the liver is presented. Images with the same slice position and corresponding to three typical acquisition phases are analyzed simultaneously. Thereby texture evolution during the propagation of contrast product is taken into account. The method is applied to recognizing hepatic primary tumors. Experiments with various sets of texture parameters and two classification methods show that simultaneous analysis of texture parameters derived from three subsequent acquisition moments improves the classification accuracy.

1. Wstęp

Tomografia komputerowa jest narzędziem szeroko stosowanym w diagnostyce chorób wątroby. Analiza serii obrazów, wykonanych zwykle przed podaniem środka kontrastującego oraz podczas jego propagacji, umożliwia lekarzowi lokalizację i wstępne rozpoznanie typu patologii. Interpretacja obrazów bazująca jedynie na wizualnej ich analizie często nie wystarcza do postawienia definitywnej diagnozy. W wielu przypadkach konieczne jest dodatkowe wykonanie badania histopatologicznego (biopsji cienkoigłowej), które niesie ryzyko powikłań. Zastosowanie komputerowych metod przetwarzania obrazów (w szczególności analizy ich tekstur) oraz ich klasyfikacji może znacznie podwyższyć ilość poprawnie rozpoznawanych schorzeń, ograniczając tym samym konieczność stosowania szkodliwych dla organizmu człowieka metod inwazyjnych.

Jednym z podstawowych problemów napotykanym w procesie komputerowej analizy obrazów jest obiektywna i jednoznaczna charakteryzacja obszarów na nich występujących. Cennym źródłem informacji o rozpatrywanych obszarach może być ich tekstura [6]. Analiza tekstur ma na celu policzenie grupy parametrów liczbowych (tzw. cech teksturalnych), z których każdy wyraża określoną własność danego obszaru. Zaproponowanych zostało bardzo wiele sposobów ekstrakcji cech teksturalnych. Najczęściej wykorzystywane są metody statystyczne (bazujące na analizie histogramu poziomów szarości, macierzy gradientów, macierzy współwystępowania (ang. *co-occurrence*) lub jednorodnych ciągów pikseli (ang. *run length*)), oparte na przekształceniach obrazu (transformacje Gabora, Fouriera, falkowa), wykorzystujące modele (pola fraktalne, Markowa), czy też operacje matematycznej morfologii. Proponowane metody analizy tekstur (wybrane odpowiednio do konkretnego problemu diagnostycznego) z powodzeniem zostały zastosowane w procesie rozpoznawania patologii różnych narządów zobrazowanych różnymi technikami [2].

Pierwsze próby wykorzystania analizy tekstur w charakteryzacji patologicznie zmienionych obszarów tkanki wątrobowej występujących na obrazach tomograficznych przedstawiono w [8]. Stosując metodę jednorodnych ciągów pikseli pokazano, że średnie wartości jednej z cech (*gray level distribution*) odpowiadające tkance nowotworowej różniły się znacznie od policzonych dla tkanki zdrowej. W pracy [3] zaproponowano system diagnostyczny, który był zdolny do automatycznego znajdowania konturów wątroby oraz rozpoznawania jej dwóch najczęściej występujących nowotworów. W systemie tym wykorzystano sztuczne sieci neuronowe do rozpoznawania tekstur opisanych przy pomocy cech liczonych na podstawie macierzy współwystępowania oraz analizy fraktalnej. Zbliżony system (wykorzystujący cechy policzone z macierzy współwystępowania oraz sieci neuropodobne) został zaprezentowany w [5]. Wszystkie z przedstawionych wyżej aplikacji analizowały tomografie komputerowe wątroby wykonane bez podania środka kontrastującego. W prowadzonych przez nas badaniach [7] do rozpoznawania typów przerzutów nowotworowych w wątrobie dodatkowo wykorzystano obrazy tomograficzne wykonane w dwóch fazach (tętniczej i żylniej) po podaniu pacjentom kontrastu, przy czym serie obrazów pozyskanych w każdej z faz były rozpatrywane oddzielnie. Zauważono wówczas, że analiza obrazów po podaniu środka kontrastującego może poprawić jakość klasyfikacji. W [4] zaproponowaliśmy jednoczesną analizę tomografii przedstawiających ten sam fragment wątroby w trzech wspomnianych wyżej momentach akwizycji. Wyniki wstępnych doświadczeń pokazały, że uwzględnienie ewolucji tekstury w czasie prowadzi do znacznie lepszego rozpoznawania patologii.


Dalsza część pracy zorganizowana jest w następujący sposób. W kolejnym punkcie omówiono proces projektowania klasyfikatorów na podstawie danych obrazowych oraz przedstawiono metodę konstrukcji zestawu cech teksturalnych na podstawie trzech obrazów. Punkt 3 zawiera opis przeprowadzonych eksperymentów, w których dwie metody klasyfikacji (*Dipolowe Drzewa Decyzyjne* oraz *Support Vector Machines*) zostały wykorzystane do rozpoznawania nowotworów pierwotnych wątroby. W ostatnim punkcie podsumowano uzyskane wyniki i przedstawiono planowane kierunki przyszłych badań.

2. Klasyfikacja tekstur

Pierwszym etapem wykorzystania systemu wspomagania diagnostyki bazującego na użyciu klasyfikatorów jest przygotowanie zbioru uczącego, który posłuży do wygenerowania klasyfikatorów. Zbiór ten, tworzony na podstawie bazy obrazów, składa się z przykładów, dla których określono przynależność do poszczególnych klas. Po nauczaniu klasyfikatora, system można wykorzystać w procesie rozpoznawania nowych, niezdiagnozowanych jeszcze przypadków.

2.1. Budowa klasyfikatora na podstawie bazy obrazów

Na rysunku 1 przedstawiono schematycznie proces budowy klasyfikatora na podstawie wcześniej zgromadzonej i opisanej przez lekarza specjalistę bazy obrazów. Po zlokalizowaniu określonych patologii, na poszczególnych obrazach wyznaczane są obszary zainteresowania (ang. *Region of Interest, ROI*). Umieszczenie obszarów do analizy może być dokonywane manualnie lub w sposób półautomatyczny, przy użyciu odpowiednich procedur segmentacji. Kolejnym etapem jest charakteryzacja tekstury wykonywana dla każdego obszaru zainteresowania. Polega ona na policzeniu zestawu cech teksturalnych, które utworzą pojedynczy wektor do zbioru uczącego. Dysponując zbiorem przykładów, dla których informacja o przynależności do klasy jest znana, można przystąpić do budowy klasyfikatora.




Rys. 1. Proces budowy klasyfikatora na podstawie przetworzonej bazy obrazów [7]

2.2. Uwzględnienie zmian tekstury pod wpływem propagacji środka kontrastującego

W praktyce klinicznej diagnoza jest często stawiana na podstawie jednoczesnej analizy grupy obrazów, spośród których każdy w inny sposób przedstawia ten sam fragment organu. Kolejne serie obrazów mogą być pozyskiwane z zastosowaniem różnych parametrów akwizycji (na przykład czasu repetycji i czasu echa dla obrazów rezonansu magnetycznego) lub różnych faz propagacji podanego pacjentowi płynu kontrastującego (w przypadku tomografii komputerowych narządów jamy brzusznej). W diagnozowaniu chorób wątroby, wykonywane są zwykle trzy serie obrazów: pierwsza – przed podaniem środka kontrastującego, kolejne – po podaniu kontrastu, w wyróżnionych przez lekarzy radiologów tzw. fazach związanych z jego propagacją (tętniczej i żylniej). Obserwując różnice wyglądu analizowanego obszaru na obrazach poszczególnych faz, lekarz próbuje rozpoznać typ patologii.

W projektowanym systemie komputerowego wspomaganie diagnostyki chorób wątroby postąpiono w sposób analogiczny do stosowanego przez lekarzy: parametry teksturalne odpowiadające temu samemu obszarowi organu zobrazowanemu w następujących po sobie fazach akwizycji były analizowane jednocześnie. Rysunek 2 przedstawia schemat konstrukcji złożonych wektorów cech. Na trzech obrazach przedstawiających ten sam fragment wątroby w kolejnych fazach akwizycji wykreślany jest ten sam obszar zainteresowania. Następnie dla każdego z trzech obszarów liczony jest ten sam zestaw cech teksturalnych. Kolejnym etapem jest połączenie otrzymanych zestawów cech (odpowiadających wyróżnionym fazom) w jeden wektor.




Rys. 2. Tworzenie wektorów cech opisujących ten sam fragment organu w różnych fazach pozyskiwania obrazu

3. Wyniki eksperymentów

Opisana metoda analizy tekstur została wykorzystana w klasyfikacji typów tkanki wątrobowej przedstawionej na dynamicznych tomografiach komputerowych. Rozpoznawano dwa najczęściej występujące nowotwory pierwotne wątroby: raka wątrobowokomórkowego (*carcinoma hepatocellulare*) oraz raka przewodów żółciowych wewnątrzwątrobowych (*cholangiocarcinoma*). Trzecią klasę stanowiła tkanka wątroby zdrowej.

Baza danych zawierała 495 obrazów (po 165 obrazów odpowiadających każdej z trzech faz akwizycji) pochodzących od 22 pacjentów. Wykorzystane w eksperymentach serie obrazów zostały wykonane w Centrum Leczenia Nowotworów Eugene Marquis w Rennes (Francja), przy użyciu tomografu HiSpeed CT firmy GE Medical Systems. We wszystkich przypadkach wykorzystano ten sam protokół akwizycji: stosowany był tryb skanowania spiralnego, grubość warstwy wynosiła 7 mm, płyn kontrastujący (w ilości około 100 ml) podawany był z szybkością 4 ml/s. Akwizycja obrazów odpowiadających fazie tętniczej propagacji kontrastu rozpoczynała się 20 sekund od momentu rozpoczęcia jego wstrzykiwania. Obrazy odpowiadające fazie żylny były pozyskiwane z opóźnieniem 50-60 s. Wszystkie obrazy miały rozmiar 512x512 pikseli i zapisane były w formacie DICOM.

Dla każdego typu tkanki i każdej z faz akwizycji wyznaczono ręcznie 150 rozłącznych obszarów zainteresowania w kształcie kół o średnicy od 30 do 70 pikseli. W każdym przypadku rozpoznanie typu tkanki zostało potwierdzone przy wykorzystaniu badań histopatologicznych. Na rysunku 3 przedstawiono przykładowe wycinki z wyznaczonych obszarów zainteresowania w poszczególnych klasach i fazach akwizycji.



Rys. 3. Przykładowe wycinki obrazów tomograficznych reprezentujące klasy analizowanych tkanek w trzech fazach akwizycji

Wykonano eksperymenty z użyciem różnych zestawów cech teksturalnych:

- 4 parametrów policzonych na podstawie histogramu poziomów szarości (FO),
- entropii obrazu przefiltrowanego przy użyciu masek Lawsa (14 parametrów),
- 8 cech policzonych na podstawie macierzy jednorodnych ciągów (RLM),
- 11 cech policzonych na podstawie macierzy współwystępowania (COM),
- 35 parametrów otrzymanych z przy użyciu wszystkich wyżej wymienionych metod.

Macierze współwystępowania oraz macierze jednorodnych ciągów zostały utworzone dla czterech standardowych kierunków ułożenia par (ciągów) pikseli: 0° , 45° , 90° oraz 135° . W przypadku obu metod zredukowano liczbę poziomów szarości (z 256 pierwotnie używanych do 64). Podczas tworzenia macierzy współwystępowania wzięto pod uwagę odległości par pikseli od 1 do 5. Cechy liczone dla różnych kierunków oraz odległości pikseli zostały uśrednione. W przypadku filtracji obrazów zastosowano 24 maski Lawsa o wymiarach 5×5 . Suma elementów każdej macierzy konwolucji wynosiła zero. Pary przefiltrowanych obrazów odpowiadające poszczególnym maskom oraz ich transpozycjom zostały dodane. Obrazy odpowiadające maskom symetrycznym zostały pomnożone przez dwa.

Stosując każdą z wyżej wymienionych metod ekstrakcji cech teksturalnych wykonano cztery eksperymenty. W pierwszych trzech analizowano oddzielnie wektory obserwacji odpowiadające trzem fazom pozyskiwania obrazu (B, T, $\check{Z}$). W kolejnym eksperymencie jednocześnie wykorzystano zestawy cech teksturalnych opisujących ten sam obszar obrazu w trzech fazach (B + T + $\check{Z}$). W każdym przypadku rozpoznawanie tekstur przeprowadzono z użyciem dwóch metod klasyfikacji: Dłopolowych Drzew Decyzyjnych (DDT) [1] oraz *Support Vector Machines* (SVM) [9]. Zbiory uczące wykorzystane do budowy klasyfikatorów zawierały po 75 obserwacji każdej klasy w każdej fazie akwizycji (łącznie 225 obserwacji). Tak samo liczne zbiory testowe posłużyły do oceny jakości klasyfikatora. Tabele 1 i 2 przedstawiają uzyskane wyniki. Na podstawie otrzymanych rezultatów możemy stwierdzić, że jednocześnie wykorzystanie charakterystyk teksturalnych odpowiadających trzem fazom pozyskiwania obrazów poprawia jakość klasyfikacji. Obserwuje się to niezależnie od stosowanej metody ekstrakcji cech i algorytmu klasyfikacji.

Tab. 1. Jakość klasyfikacji uzyskana dla różnych grup cech teksturalnych przy użyciu DDT

	bez kontrastu (B)	faza tętnicza (T)	faza żylna ($\check{Z}$)	B + T + $\check{Z}$
FO	90.16 ± 1.31	85.82 ± 1.48	90.40 ± 1.69	98.76 ± 0.73
Laws	91.13 ± 0.84	92.27 ± 1.25	88.33 ± 2.20	95.11 ± 1.19
COM	96.36 ± 0.88	94.29 ± 1.79	94.87 ± 0.83	99.67 ± 0.37
RLM	95.53 ± 1.02	93.89 ± 1.28	95.45 ± 1.59	99.73 ± 0.42
Wszystkie razem	99.11 ± 0.74	98.89 ± 0.44	99.18 ± 0.62	99.53 ± 0.86

Tab. 2. Jakość klasyfikacji uzyskana dla różnych grup cech teksturalnych przy użyciu SVM

	bez kontrastu (B)	faza tętnicza (T)	faza żylna ($\check{Z}$)	B + T + $\check{Z}$
FO	82.46 ± 0.59	71.11 ± 0.69	74.44 ± 0.90	89.42 ± 0.91
Laws	79.38 ± 1.24	71.42 ± 1.59	66.27 ± 1.08	82.44 ± 1.20
COM	86.80 ± 0.63	78.71 ± 0.31	76.27 ± 0.66	91.47 ± 0.55
RLM	71.02 ± 0.89	51.42 ± 0.66	56.50 ± 1.14	71.82 ± 1.87
Wszystkie razem	91.02 ± 0.86	90.09 ± 0.56	90.00 ± 0.83	95.87 ± 0.93

4. Podsumowanie

W pracy przedstawiono nową metodę charakteryzacji obszarów zainteresowania na dynamicznych tomografiach komputerowych wątroby. Do opisu obszarów zainteresowania brane były pod uwagę nie tylko parametry teksturalne wyliczone na ich podstawie, ale również ich zmiany pod wpływem propagacji środka kontrastującego. Doświadczenia przeprowadzone z użyciem trzech typów tkanki wątrobowej (wątroba zdrowa oraz dwa nowotwory pierwotne) wykazały, że jednocześnie zastosowanie informacji zawartej w

obrazach odpowiadających trzem fazom akwizycji prowadzi do poprawy jakości diagnozy. Można to zauważyć niezależnie od stosowanego zestawu parametrów teksturalnych oraz metody klasyfikacji.

W przyszłości kontynuowane będą prace nad rozpoznawaniem typów nowotworów wątroby na podstawie wielofazowych tomografii komputerowych. Poszukiwane będą metody konstrukcji „złożonych” cech teksturalnych wyrażających zmianę tekstury w trzech fazach akwizycji. Planowane jest rozszerzenie bazy obrazów o przypadki innych patologii wątroby. Rozpoczęto także badania nad możliwością wykorzystaniem analogicznego rozwiązania (uwzględnienie zmian tekstury po podaniu środka kontrastującego oraz przy różnych parametrach pozyskiwania obrazu) w klasyfikacji nowotworów mózgu na podstawie obrazów rezonansu magnetycznego (we współpracy ze Szpitalem Uniwersyteckim w Caen (Francja)).

Bibliografia

- [1] Bobrowski L., Krętowski M.: Induction of multivariate decision trees by using dipolar criteria, LNCS Vol. 1910, Springer-Verlag, 2000, 331-336.
- [2] Bruno A., Collorec R., Bézy-Wendling J., Reuzé P., Rolland Y.: Texture analysis in medical imaging. W Roux C., Coatrieux J. L. (edytorzy): Contemporary Perspectives in Three-dimensional Biomedical Imaging, IOS Press, 1997, 133-164.
- [3] Chen C., Daponte J. S., Fox M. D.: Fractal feature analysis and classification in medical imaging, IEEE Transactions on Medical Imaging, 8, 1989, 133-142.
- [4] Duda D., Krętowski M., Bézy-Wendling J.: Texture-based classification of hepatic primary tumors in multiphase CT. Proc. of 7th MICCAI, LNCS Vol. 3217, Springer-Verlag, 2004, 1050-1051.
- [5] Gletsos M., Mougiakakou S. G., Matsopoulos G. K., Nikita K. S., Nikita A. S., Kelekis D.: A computer-aided diagnostic system to characterize CT focal liver lesions: design and optimization of a Neural Network classifier, IEEE Transactions on Information Technology in Biomedicine, 7(3), 2003, 153-162.
- [6] Haralick R. M.: Statistical and structural approaches to texture, Proc. IEEE, 67, 1979, 786-804.
- [7] Krętowski M., Bezy-Wendling J., Duda D.: Classification of hepatic metastasis in enhanced CT images by dipolar decision tree, Proc. of 19th GRETSI, 2003, 327-330.
- [8] Mir A. H., Hanmandlu M., Tandon S. N.: Texture analysis of CT-images, IEEE Engineering in Medicine and Biology, 5, 1995, 781-786.
- [9] Vapnik V.: The Nature of Statistical Learning Theory, Springer-Verlag, New York, 1995.

Artykuł zrealizowano w ramach pracy badawczej Politechniki Białostockiej W/WI/1/05.