

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

EKSTRAKCJA CECH TEKSTURALNYCH W KLASYFIKACJI OBRAZÓW TOMOGRAFICZNYCH WĄTROBY

Streszczenie: W pracy przedstawiono nową metodę opisu tekstur, przystosowaną do analizy grupy obrazów, przedstawiających na różne sposoby ten sam fragment organu. Charakteryzując obszary zainteresowania, uwzględniono nie tylko cechy teksturalne wyliczone na ich podstawie, ale również ich zależność od warunków pozyskiwania obrazów. Zaproponowano kilka sposobów konstrukcji przestrzeni parametrów odzwierciedlających zmianę tekstury, która zachodzi pod wpływem zmian warunków akwizycji. Proponowaną metodę zweryfikowano doświadczalnie w klasyfikacji obrazów tomograficznych wątroby. Rozpoznawano cztery typy tkanki, dla każdego przypadku rozważono trzy momenty akwizycji, związane z obecnością i propagacją środka kontrastującego. Wyniki uzyskane przy użyciu różnych zestawów cech teksturalnych i klasyfikatora w postaci dipolowych drzew decyzyjnych pokazują, że uwzględnienie zmian tekstury pod wpływem propagacji środka kontrastującego znacznie poprawia diagnozę.

Słowa kluczowe: klasyfikacja obrazów medycznych, analiza tekstur, tomografie komputerowe wątroby

1. Wprowadzenie

Tomografia komputerowa jest narzędziem szeroko stosowanym w diagnostyce chorób narządów brzusznych. Przy rozpoznawaniu patologii wątroby, standardem stało się wykonywanie trzech serii obrazów: pierwszej – przed podaniem pacjentowi środka kontrastującego oraz kolejnych dwóch – po podaniu kontrastu, w wyróżnionych przez lekarzy radiologów fazach jego propagacji (tętnicznej i żylniej). Wizualna analiza różnic w wyglądzie określonego fragmentu wątroby na trzech obrazach odpowiadających trzem kolejnym fazom akwizycji pozwala lekarzowi zlokalizować i wstępnie rozpoznać typ patologii. W wielu przypadkach nie jest

¹ Wydział Informatyki, Politechnika Białostocka, ul. Wiejska 45A, 15-351 Białystok

² Laboratoire Traitement du Signal et de l'Image, INSERM, Université de Rennes 1, Campus de Beaulieu, Bâtiment 22, 35042 Rennes CEDEX, France

jednak wystarczająca do postawienia definitywnej diagnozy i musi być uzupełniona badaniem histopatologicznym (biopsją cienkoigłową). Zastosowanie komputerowych metod analizy obrazów może znacznie podwyższyć jakość diagnozy, ograniczając tym samym konieczność stosowania szkodliwych dla organizmu człowieka metod inwazyjnych [5].

Kluczowym zagadnieniem w procesie komputerowego przetwarzania obrazów jest jednoznaczny i obiektywny opis obszarów na nich występujących – tak zwanych obszarów zainteresowania (ang. *Regions of Interests, ROIs*). Cennym źródłem informacji o analizowanych obszarach obrazów może być ich tekstura [16]. Analiza tekstur ma na celu znalezienie zbioru parametrów (nazywanych cechami teksturalnymi), z których każdy jest liczbową miarą określonej właściwości tekstury. Rozpatrywaną właściwością może być, na przykład, ziarnistość, kierunek ułożenia wzoru, jednorodność, lokalny kontrast, czy też średni poziom jasności pikseli danego obszaru obrazu. Do tej pory zaproponowano bardzo wiele sposobów ekstrakcji cech teksturalnych, stale pojawiają się nowe propozycje. Spośród nich największą popularność zdobyły metody statystyczne, polegające na analizie histogramu poziomów szarości, macierzy gradientów, macierzy współwystępowania (ang. *co-occurrence matrices, COM*) [15] lub macierzy jednorodnych ciągów pikseli (ang. *run-length matrices, RLM*) [12]. Powszechnie stosowane są też metody oparte na przekształceniach obrazu (transformacje Fouriera, Gabora [8] lub falkowe [23]), wykorzystujące modele (pola fraktalne [6] i Markowa [9]), lub operacje matematycznej morfologii [17]. Wymienione metody (w połączeniu z odpowiednimi algorytmami klasyfikacji) znalazły szerokie zastosowanie w diagnostyce chorób narządów wewnętrznych zobrazowanych różnymi metodami. Przykładem takiego zastosowania może być rozpoznawanie łagodnych i złośliwych mikrozwapnień na obrazach mammograficznych piersi (promienie X) [30], klasyfikacja blaszek miażdżycowych w tętnicach wieńcowych (ultrasonografia wewnątrznaczyniowa) [26], identyfikacja odmian złośliwego nowotworu mózgu (rezonans magnetyczny) [4], wykrywanie zmian ogniskowych w wątrobie (tomografia komputerowa) [25], ocena struktury kostnej w diagnostyce osteoporozy (mikrotomografia komputerowa) [1], czy też wykrywanie niedokrwienia mięśnia sercowego na obrazach echokardiografii kontrastowej (ultradźwięki) [2].

Pierwsze badania nad możliwościami wykorzystania analizy tekstur w procesie rozpoznawania patologii wątroby przedstawionej na obrazach tomograficznych opisano w pracy [24]. Jej autorzy charakteryzowali dwa typy tkanki wątrobowej (chorą i zdrową) przy pomocy cech teksturalnych policzonych na podstawie macierzy współwystępowania, macierzy jednorodnych ciągów pikseli oraz macierzy różnic poziomów szarości (ang. *gray level difference matrices, GLDF*) [31]. Użycie zbioru wybranych parametrów, w skład którego wchodziły: entropia (ang. *entropy*) i lokalna jednorodność (ang. *local homogeneity*), policzone na pod-

stawie macierzy współwystępowania, oraz rozkład poziomów szarości (ang. *grey level distribution*), policzony na bazie macierzy jednorodnych ciągów pikseli, pozwoliło trafnie rozpoznać niemal 99% analizowanych przypadków. W kolejnej pracy [7] zaproponowano system komputerowego wspomaganie diagnostyki, który był zdolny do samodzielnego znajdowania konturów wątroby oraz rozpoznawania jej dwóch najczęściej występujących nowotworów. W systemie tym klasyfikacja tekstur, opisanych wymiarem fraktalnym oraz cechami policzonymi na bazie macierzy współwystępowania, odbywała się przy użyciu probabilistycznych sieci neuronowych. Podobną aplikację (wykorzystującą cechy policzone na podstawie macierzy współwystępowania oraz sieci neuronowe z propagacją wsteczną), przystosowaną do rozróżniania zdrowej i patologicznie zmienionej wątroby, opisano w pracy [19]. Sariyanni *et al.* [27] próbowali rozpoznawać tkankę odpowiadającą wątrobie zdrowej oraz rakowi wątrobowokomórkowemu (*carcinoma hepatocellulare*). W tym przypadku analizowane tekstury charakteryzował wymiar fraktalny policzony z zastosowaniem czterech różnych metod. W pracy [13] zaprezentowano system, który, wykorzystując parametry teksturalne policzone na podstawie macierzy współwystępowania oraz trzy sekwencyjnie ułożone jednokierunkowe sieci neuronowe, był zdolny określić występowanie schorzeń wątroby. Kolejny system przedstawiono w pracy [29]. Jej autorzy badali przydatność systemu do wykrywania zmian ogniskowych w wątrobie. Do opisu właściwości czterech typów tkanki (cysty, naczyniak krwionośny (*haemangioma*), rak wątrobowokomórkowy, wątroba zdrowa), wykorzystali macierze współwystępowania, macierze różnic poziomów szarości pikseli, filtrację obrazu z zastosowaniem masek Lawsa [21] oraz wymiar fraktalny. Klasyfikacji natomiast dokonywano stosując sieci neuronowe oraz klasyfikatory statystyczne. Bardzo podobny system opisano w pracy [28]. Mała *et al.* [22] zaproponowali system, który pozwalał rozróżnić stłuszczenie wątroby (*steatosis*) od marskości. Opisując tekstury, autorzy wykorzystali ortogonalną transformację falkową oraz cechy statystyczne drugiego rzędu; w procesie klasyfikacji użyto dwuwarstwowej probabilistycznej sieci neuronowej.

Spośród systemów zaprezentowanych w ostatnim roku, na uwagę zasługuje *DIAGNOSIS* [25] – zintegrowany system umożliwiający zarządzanie bazą obrazów medycznych, zdalny dostęp do bazy, półautomatyczną segmentację obrazów, ekstrakcję cech teksturalnych oraz klasyfikację. W aplikacji zastosowano wiele rozwiązań przedstawionych w pracach [29], [28]. Kolejny przykład systemu można znaleźć w pracy [18]. Charakteryzowanie obszarów zainteresowania odbywa się tu przy użyciu znormalizowanych współczynników autokowariancji (ang. *normalized autocovariance coefficients*) [14] poziomów szarości pikseli. W procesie poszukiwania klasyfikatora wykorzystano maszyny wektorów wspierających (ang. *Support Vector Machines, SVM*). System testowano na danych odpowiadających złośliwym i łagodnym zmianom nowotworowym w wątrobie.

Cechą wspólną opisanych aplikacji jest analiza tomografii komputerowych wątroby, wykonanych bez wykorzystania środka kontrastującego. W prowadzonych przez nas badaniach [20], do rozpoznawania przerzutów nowotworowych w wątrobie, posłużono się także obrazami tomograficznymi, uzyskanymi w dwóch fazach (tętnicznej i żylniej) po podaniu pacjentom kontrastu. Każdą z trzech serii obrazów, odpowiadających trzem fazom akwizycji, rozpatrywano oddzielnie. Wyniki przeprowadzonych wówczas doświadczeń okazały się lepsze w przypadku analizy obrazów wykonanych po podaniu pacjentom środka kontrastującego, przy czym najwyższej jakości diagnozę uzyskano rozpatrując grupę obrazów wykonanych w fazie tętnicznej. W kolejnej pracy [11] po raz pierwszy zaproponowaliśmy jednoczesną analizę trójek obrazów przedstawiających ten sam fragment wątroby w trzech kolejnych momentach akwizycji. Wektory parametrów opisujące trójkę obszarów zainteresowania składały się z trzech takich samych zestawów cech teksturalnych, policzonych kolejno dla fazy bez kontrastu, fazy tętnicznej i fazy żylniej. W ten sposób uwzględniono zmiany tekstury pod wpływem propagacji środka kontrastującego. Wyniki uzyskane w pracach [11] oraz [10] pokazują, że jednoczesna analiza obrazów w trzech następujących po sobie fazach akwizycji pozwala lepiej rozpoznawać patologie. nierozwiązanym problemem pozostaje jednak wybór przestrzeni parametrów, odzwierciedlających ewolucję tekstury w czasie.

Dalsza część pracy zorganizowana jest w następujący sposób. W kolejnym paragrafie opisano proces projektowania klasyfikatorów na podstawie danych obrazowych oraz zaproponowano kilka metod konstrukcji wektora cech teksturalnych na podstawie trzech obrazów tego samego fragmentu wątroby (w kolejnych trzech fazach akwizycji). W punkcie 3 opisano przeprowadzone eksperymenty z wykorzystaniem proponowanych zestawów parametrów oraz porównano i przedyskutowano wyniki. Ostatni – czwarty paragraf jest podsumowaniem pracy oraz przedstawia planowane na przyszłość kierunki prac badawczych.

2. Klasyfikacja tekstur

W praktyce klinicznej diagnoza jest często stawiana na podstawie jednoczesnej analizy grupy obrazów, które w różny sposób przedstawiają ten sam fragment organu. Liczbę wykonywanych serii obrazów dyktuje rodzaj badanego organu, sposób propagacji środka kontrastującego (jeśli go zaaplikowano), technika obrazowania, czy też potrzeba porównania obrazów w różnych profilach. Wykonując tomografie komputerowe wątroby rozpatruje się zwykle trzy serie obrazów, związane z obecnością i propagacją środka kontrastującego. Pojawienie się nowotworu lub innych patologii pociąga za sobą zmiany ukrwienia chorych tkanek oraz wpły-

wa na sposób dostarczania krwi do wątroby. Oglądając obrazy wykonane w kolejnych fazach propagacji kontrastu można zlokalizować miejsca o nadmiernym lub zbyt ubogim ukrwieniu, świadczące o obecności choroby. W zależności od jej rodzaju, tekstura rozpatrywanych fragmentów obrazów ulega charakterystycznym zmianom, które można zaobserwować porównując obrazy wykonane przed podaniem pacjentowi płynu kontrastującego oraz po jego podaniu. Na podstawie analizy wizualnej zmian tekstury na obrazach przedstawiających ten sam fragment organu, lecz w innych fazach akwizycji, lekarz próbuje postawić diagnozę.

Projektując system komputerowego wspomaganie diagnostyki postąpiono w sposób analogiczny do stosowanego przez lekarzy. Przedmiotem badań było nie tylko znalezienie zestawu cech teksturalnych, odzwierciedlających właściwości analizowanych obszarów zainteresowania, ale również opis ich zmian pod wpływem zmiany warunków pozyskiwania obrazów (w przypadku wątroby – pod wpływem propagacji środka kontrastującego). Analizie poddawano zatem nie pojedyncze obrazy, lecz uporządkowane trójki obrazów, spośród których każdy pochodził z innej serii.

2.1. System komputerowego wspomaganie diagnostyki

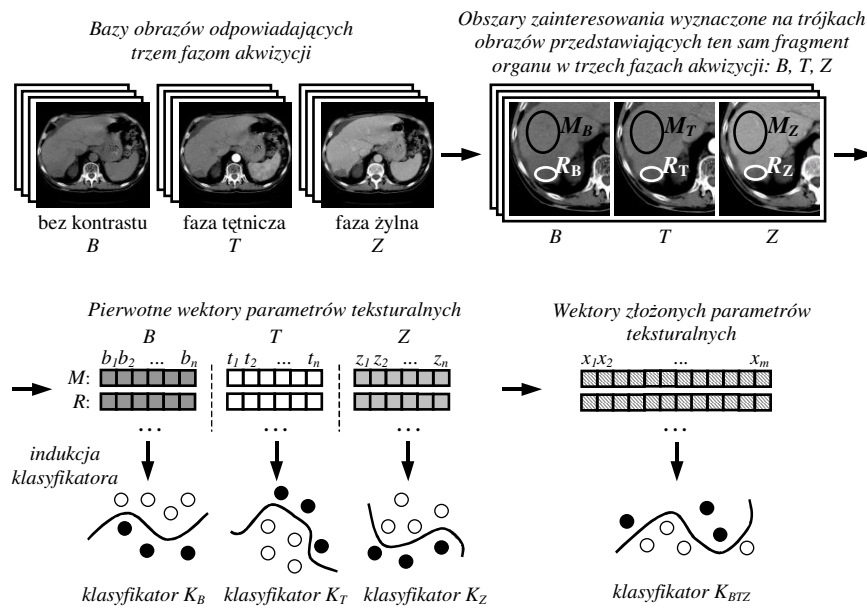
Wstępnym etapem pracy z komputerowym systemem wspomaganie diagnostyki jest przygotowanie tego systemu do rozpoznawania ustalonej grupy patologii. W przypadku systemów bazujących na użyciu klasyfikatorów, przygotowanie to polega na stworzeniu zbioru uczącego, w skład którego wchodzi obserwacje o znanej etykiecie (przynależności do klas), a następnie wykorzystaniu go do wygenerowania klasyfikatora. Po nauczaniu klasyfikatora system można wykorzystać w procesie rozpoznawania nowych, niezdiagnozowanych jeszcze przypadków.

Proces budowy klasyfikatorów na podstawie opisanego przez lekarza specjalistę zbioru tomografii komputerowych wątroby przedstawiono na rysunku 1. Pierwszym etapem procesu jest zgromadzenie możliwie jak największej bazy danych składającej się z trzech grup obrazów. Każda z wyróżnionych grup odpowiada innej fazie pozyskiwania obrazów: pierwsza (B) – fazie przed podaniem pacjentowi środka kontrastującego, druga (T) – fazie tętnicznej propagacji środka, ostatnia (Z) – fazie żylnnej propagacji. Obrazy przedstawiające ten sam fragment organu w trzech kolejnych fazach akwizycji są grupowane i powstałe trójki obrazów są analizowane jednocześnie. Na każdym z obrazów tworzących trójkę wyznacza się taki sam obszar zainteresowania (położenie i rozmiary obszaru są jednakowe dla wszystkich obrazów) i nadaje się mu etykietę. Proces ten przebiega przy udziale lekarza, który bazując na analizie wizualnej i histopatologicznej jest w stanie trafnie określić typ schorzenia. Kolejnym etapem jest policzenie zestawu cech teksturalnych, oddzielnie dla każdego z trzech rozpatrywanych obszarów. Powstają

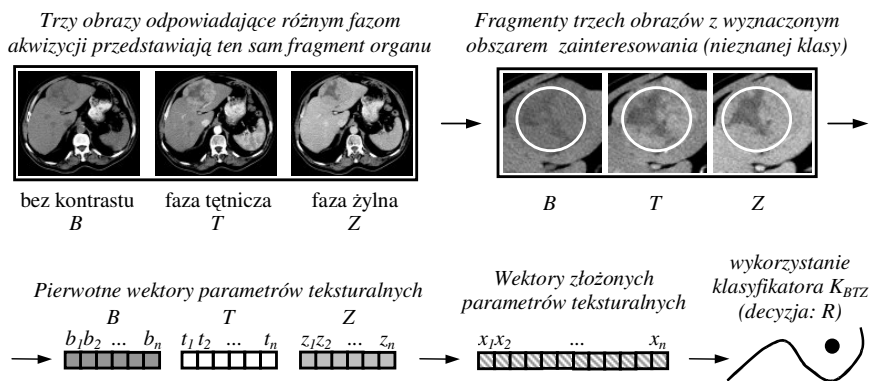
w ten sposób trzy wektory cech (które będziemy nazywać pierwotnymi wektorami cech), $w_B = [b_1, b_2, \dots, b_n]$, $w_T = [t_1, t_2, \dots, t_n]$, $w_Z = [z_1, z_2, \dots, z_n]$, przy czym każde trzy cechy b_i , t_i , z_i ($i = 1, \dots, n$) liczone są taką samą metodą. Grupy wektorów cech pierwotnych, odpowiadających każdej z trzech faz mogą być analizowane oddzielnie [20] – można poszukiwać klasyfikatora na podstawie wektorów cech odpowiadających jedynie fazie bez kontrastu (klasyfikator K_B), jedynie fazie tętnicznej (klasyfikator K_T) lub jedynie żylniej (klasyfikator K_Z). Trójka wektorów (w_B, w_T, w_Z) może posłużyć do konstrukcji nowego zestawu parametrów (nazywanego zestawem parametrów złożonych) $x = [x_1, x_2, \dots, x_m]$, które wyrażają zmiany właściwości tekstury na trzech obszarach zainteresowania. Na podstawie zbioru obserwacji opisanych zestawem parametrów złożonych powstaje klasyfikator K_{BTZ} .

Po utworzeniu klasyfikatora (lub grupy klasyfikatorów, wykorzystujących różne algorytmy klasyfikacji), system jest gotowy do wspomagania diagnostyki znanych mu chorób (takich, jakie stwierdzono u pacjentów, których obrazy wykorzystano przy konstrukcji zbioru uczącego).

Rysunek 2 przedstawia schematyczny proces wykorzystania klasyfikatora w rozpoznawaniu typu patologii wątroby. Spośród obrazów wchodzących w skład trzech serii należy wybrać takie (trzy), które przedstawiają ten sam fragment wątroby (każdy obraz ma odpowiadać innej serii). Kolejnym etapem jest wyznaczenie trzech obszarów zainteresowania (po jednym na każdym obrazie) o takich samych wymiarach i współrzędnych. Obszary zainteresowania zakreślone są w obrębie tego fragmentu tkanki, dla którego chcemy postawić diagnozę. Następnie liczy się cechy teksturalne, osobno dla każdego z trzech obszarów zainteresowania. Zestawy cech pierwotnych wyznacza się przy zastosowaniu metod identycznych jakich użyto w procesie indukcji klasyfikatora. Na podstawie trzech zestawów cech jest konstruowany wektor cech złożonych, opisujący trójkę obszarów zainteresowania. Ostatnim etapem jest wykorzystanie zbudowanego klasyfikatora, który przyporządkuje obserwację do jednej z klas. Na tej podstawie można postawić diagnozę.



Rys. 1. Tworzenie klasyfikatora na podstawie zbioru uczącego, zbudowanego z pierwotnych wektorów cech (klasyfikator K_B , klasyfikator K_T , klasyfikator K_Z), oraz na podstawie zbioru wektorów cech złożonych (klasyfikator K_{BTZ}). Na każdym z obrazów wyznaczono dwa obszary zainteresowania, odpowiadające marskości wątroby (M) oraz rakowi wątrobowokomórkowemu (R). Dolne indeksy w oznaczeniach obszarów (B , T , Z) odpowiadają kolejnym fazom akwizycji



Rys. 2. Wykorzystanie klasyfikatora K_{BTZ} w rozpoznawaniu patologii wątroby na podstawie trzech obrazów tego samego fragmentu wątroby, wykonanych w różnych fazach propagacji środka kontrastującego. Decyzja R odpowiada przyporządkowaniu badanego obszaru zainteresowania do klasy „rak wątrobowokomórkowy”

3. Przeprowadzone eksperymenty

Zaproponowana metoda analizy tekstur była wykorzystana w procesie klasyfikacji obrazów tomograficznych wątroby, wykonanych w trzech fazach związanych z propagacją środka kontrastującego. Rozpoznawano cztery typy tkanki wątrobowej. Dwa pierwsze odpowiadały najczęściej występującym nowotworom pierwotnym wątroby: rakowi wątrobowokomórkowemu (*carcinoma hepatocellulare*) oraz rakowi przewodów żółciowych wewnątrzwątrobowych (*cholangiocarcinoma*). Kolejny typ stanowiła tkanka dotknięta marskością. Ostatnia, czwarta klasa odpowiadała tkance wątroby zdrowej.

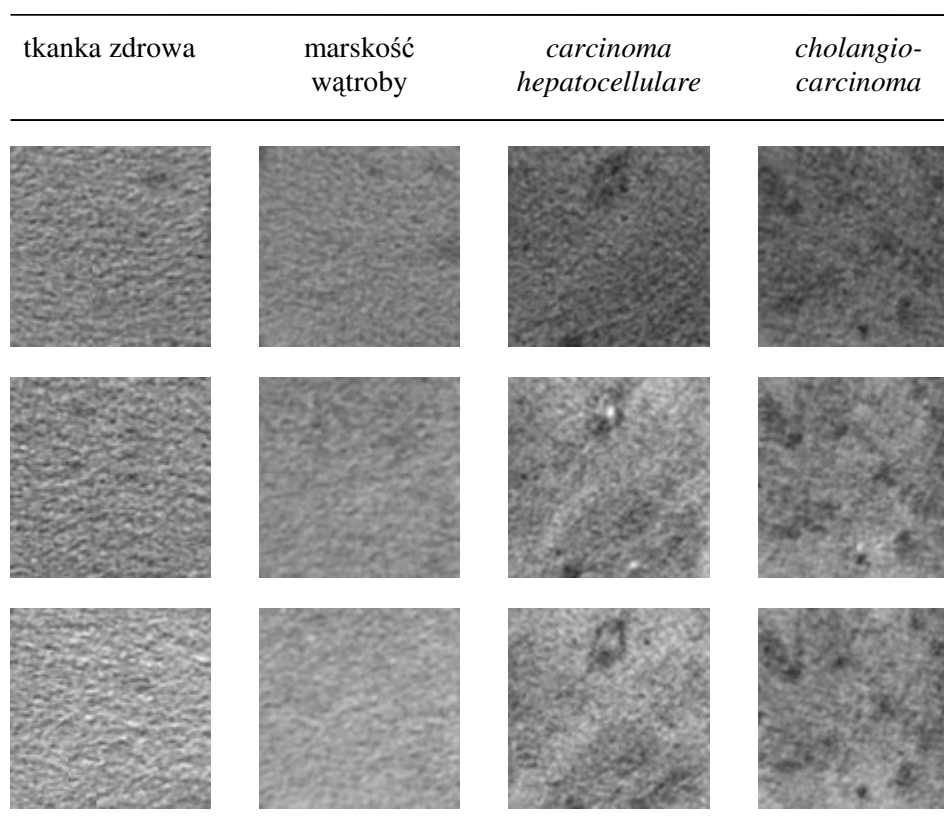
3.1. Baza danych obrazowych

Analizowane obrazy pochodziły z dwóch ośrodków w Rennes (Francja): Centrum Leczenia Nowotworów Eugène Marquis (tomograf HiSpeed CT firmy GE Medical Systems) oraz Szpitala Uniwersyteckiego Pontchaillou (tomograf LightSpeed16 firmy GE Medical Systems). W obu szpitalach wykorzystywane były zbliżone protokoły akwizycji: stosowany był tryb skanowania spiralnego, grubość warstwy wynosiła 5 lub 7 mm. Płyn kontrastujący (z reguły 100 ml) podawany był pacjentom przez żyłę przedłokciową, z szybkością 4 ml/s. Pozyskiwanie obrazów odpowiadających fazie tętnicznej propagacji środka kontrastującego rozpoczynało się około 20 sekund po rozpoczęciu jego wstrzykiwania. Obrazy odpowiadające fazie żylniej wykonano z opóźnieniem 50-60 sekund. Wszystkie obrazy zapisano w formacie DICOM i miały rozmiar 512x512 pikseli.

W doświadczeniach wykorzystano obrazy pochodzące od 76 pacjentów. Utworzona z nich baza danych zawierała 2961 obrazów, po 987 obrazów uzyskanych w każdej z trzech faz akwizycji. Obrazy pogrupowano w trójki, na których był przedstawiony ten sam fragment wątroby w kolejnych fazach. Na obrazach wykreślono w sumie 1511 trójek obszarów zainteresowania: 537 odpowiadających wątrobie zdrowej, 433 – marskości wątroby, 319 – rakowi wątrobowokomórkowemu oraz 222 – rakowi przewodów żółciowych wewnątrzwątrobowych.

Na potrzeby programu do analizy tekstur (*TextureAnalyser*) obrazy przekonwertowano do formatu BMP, nie tracąc przy tym pełnej informacji o zmienności poziomów szarości pikseli w obrębie zakreślonych obszarów zainteresowania.

Przykładowe wycinki analizowanych obrazów przedstawia rysunek 3.



Rys. 3. Przykładowe wycinki (100x100) obszarów zainteresowania, reprezentujące 4 klasy analizowanych tkanek wątroby. Obrazy znajdujące się w górnym wierszu uzyskane były bez podawania pacjentowi środka kontrastującego, kolejne dwa wiersze odpowiadają fazie tętnicznej (wiersz środkowy) i żyłnej (wiersz dolny) propagacji kontrastu

3.2. Ekstrakcja cech teksturalnych

Obszary zainteresowania (wykreślone na każdym z trzech obrazów) scharakteryzowano przy użyciu następujących zestawów (pierwotnych) cech teksturalnych:

- 4 parametry wyznaczone na podstawie histogramu poziomów szarości,
- 11 cech wyznaczonych na podstawie macierzy współwystępowania,
- 8 cech wyznaczonych na podstawie macierzy jednorodnych ciągów pikseli,
- entropie obrazu przefiltrowanego przy użyciu masek Lawsa (14 parametrów),
- wszystkie cztery wyżej wymienione grupy parametrów jednocześnie (37 cech).

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

Każdy z pięciu wymienionych wcześniej zestawów cech był liczony oddzielnie dla każdego z trzech obszarów zainteresowania. Następnie, na podstawie parametrów teksturalnych odpowiadających trzem obszarom zainteresowania, wyznaczono zestawy parametrów złożonych mające postać:

- $w_{od} = [t_1 - b_1, t_2 - b_2, \dots, t_n - b_n, z_1 - b_1, z_2 - b_2, \dots, z_n - b_n]$ ($2n$ parametrów),
- $w_{dz} = [t_1/b_1, t_2/b_2, \dots, t_n/b_n, z_1/b_1, z_2/b_2, \dots, z_n/b_n]$ ($2n$ parametrów),
- $w_{zm} = [w_1, \dots, w_n]$ (n parametrów),

gdzie w_i ($i = 1, \dots, n$) jest klasycznym współczynnikiem zmienności i -tej cechy, liczonym na podstawie jej trzech wartości (b_i , t_i , z_i), opowiadających rozpatrywanym fazom akwizycji.

Ponadto wykonano doświadczenia, w których analizowano:

- grupy wektorów opisujących obserwacje w każdej z trzech faz pozyskiwania obrazów: w_B , w_T , w_Z (oddzielna grupa dla każdej z faz),
- zbiór obserwacji opisanych wektorami parametrów odpowiadających jednocześnie trzem fazom akwizycji: $w_{BTZ} = [b_1, b_2, \dots, b_n, t_1, t_2, \dots, t_n, z_1, z_2, \dots, z_n]$ ($3n$ parametrów) [11],
- zbiór obserwacji opisanych przez $2n$ pierwszych (spośród $3n$) składowych głównych (wektory $w_{PCA_{2n}}$), które policzono na podstawie zbioru, o którym mowa w poprzednim punkcie,
- zbiór obserwacji opisanych przez n pierwszych składowych głównych (wektory w_{PCA_n}), o których mowa powyżej.

We wszystkich eksperymentach wykorzystano klasyfikator w postaci Dipolowych Drzew Decyzyjnych (ang. *Dipolar Decision Trees*) [3] z wbudowaną selekcją cech. W każdym doświadczeniu jakość klasyfikacji oceniano z wykorzystaniem 10-krotnie powtórzonej krosvalidacji 10-przedziałowej. Tabela 1 zawiera zestawienie uzyskanych wyników.

Tabela 1

Jakość klasyfikacji (%) uzyskana dla różnych zestawów pierwotnych cech teksturalnych oraz różnych metod konstrukcji wektora parametrów złożonych, opisujących trójkę obszarów zainteresowania. Kolejne wiersze tabeli odpowiadają różnym metodom ekstrakcji cech, zastosowanym do policzenia parametrów pierwotnych (oddzielnie dla każdej z trzech faz). Przy każdej metodzie podano liczbę wyznaczonych parametrów (n). Kolumny tabeli odpowiadają zaś różnym metodom liczenia złożonych wektorów cech. W nawiasie podano liczby otrzymywanych cech (wykorzystując w każdym przypadku liczbę cech liczonych oddzielnie dla każdej z faz)

Cechy pierwotne		Wektory cech złożonych								
Zestaw cech	Liczba cech, n	w_{BTZ} ($3n$)	w_{PCA2n} ($2n$)	w_{od} ($2n$)	w_{dz} ($2n$)	w_{PCAn} (n)	w_{zm} (n)	w_B (n)	w_T (n)	w_Z (n)
FO	$n=4$	78,2	78,0	71,5	64,7	69,1	64,0	66,2	52,2	62,7
RLM	$n=8$	77,4	79,7	75,7	74,9	78,6	72,6	70,4	69,5	71,4
COM	$n=11$	76,4	76,5	74,0	72,0	78,5	70,6	69,9	66,1	69,9
Laws	$n=14$	69,1	70,9	56,4	55,9	74,0	70,1	64,3	66,9	66,0
wszystkie	$n=37$	78,3	77,4	72,8	68,4	77,8	74,5	71,8	70,6	72,5

3.3. Dyskusja

Na podstawie wyników przeprowadzonych doświadczeń można stwierdzić, że analiza zmian charakterystyk teksturalnych, towarzyszących propagacji środka kontrastującego, może prowadzić do poprawy jakości diagnozy. Niemal we wszystkich przypadkach wyniki uzyskane przy zastosowaniu zestawów złożonych cech teksturalnych okazały się lepsze od rezultatów otrzymanych przy oddzielnej analizie trzech grup wektorów, odpowiadających trzem fazom pozyskiwania obrazu (w_B , w_T , lub w_Z). Największe ilości poprawnie rozpoznawanych tkanek wątroby (do 80% analizowanych) odnotowywano przy opisie obserwacji z jednoczesnym zastosowaniem trzech grup nieprzekształconych parametrów (wektory w_{BTZ} o rozmiarze $3n$) lub części składowych głównych ($2n$ lub n pierwszych składowych), otrzymanych na podstawie zbioru obserwacji opisanych $3n$ -wymiarowymi wektorami w_{BTZ} . W przypadku zastosowania zestawów pierwotnych cech teksturalnych, policzonych na podstawie macierzy współwystępowania, macierzy jednorodnych ciągów pikseli lub wszystkich czterech metod, podobne wyniki uzyskano przy różnych liczbach składowych głównych (n lub $2n$) oraz przy wszystkich nieprzekształconych cechach pierwotnych (w liczbie $3n$). W przypadku zestawów cech pierwotnych, otrzymanych z użyciem masek Lawsa, użycie n pierwszych składowych głównych prowadziło do najlepszego rozpoznawania tkanek. Można zatem wnioskować, że wykorzystanie większej liczby składowych głównych (w naszym przypadku powyżej n) nie prowadzi do podwyższenia jakości klasyfikacji, jedynie może wydłużyć czas indukcji klasyfikatora. Co prawda w przypadku parametrów pierwotnych, liczonych na podstawie histo-

gramu poziomów szarości, stosowanie jedynie n składowych głównych prowadziło do znacznego zmniejszenia liczby trafnie rozpoznawanych obiektów (9,1% w stosunku do wyników uzyskanych z zastosowaniem $3n$ nieprzetworzonych parametrów). Jednak w tym przypadku liczba cech pierwotnych wynosiła zaledwie 4, co mogło nie wystarczyć do pełnego opisu zobrazowanych tkanek.

Wyniki uzyskane przy zastosowaniu pozostałych wektorów o $2n$ parametrach (w_{od} , w_{dz}) pokazują, że lepszym rozwiązaniem jest rozpatrywanie różnic wartości parametrów pierwotnych, odpowiadających fazie tętnicznej i bez kontrastu oraz żylniej i bez kontrastu (wektory w_{od}). Takie rozwiązanie prowadzi jednak do gorszego rozpoznawania obserwacji (od 2,5% dla zestawu parametrów pierwotnych policzonych na podstawie macierzy współwystępowania do 14,5% dla parametrów pierwotnych policzonych z zastosowaniem masek Lawsa), niż w przy zastosowaniu wektorów w_{PCA2n} , o których mowa w poprzednim akapicie. W przypadku rozpatrywania ilorazów wartości parametrów (wektory w_{dz}) jakość klasyfikacji okazywała się gorsza nawet od uzyskanej w sytuacji, gdy analizowano cechy odpowiadające jedynie fazie bez kontrastu (w_B), jedynie fazie tętnicznej (w_T) lub jedynie fazie żylniej (w_Z). Tak było przy zastosowaniu zestawu parametrów pierwotnych, policzonych na podstawie histogramu poziomów szarości (1,5% różnicy), obrazów przefiltrowanych z zastosowaniem masek Lawsa (do 11,0% różnicy) oraz przy zastosowaniu kombinacji wszystkich parametrów (do 4,1% różnicy).

Najgorszym rozwiązaniem wydaje się opisywanie zobrazowanych tkanek przy użyciu n współczynników zmienności parametrów pierwotnych. Dla trzech metod ekstrakcji parametrów pierwotnych (wykorzystujących histogram poziomów szarości, macierze jednorodnych ciągów pikseli lub macierze współwystępowania) wspomniana metoda konstrukcji złożonych wektorów cech okazała się najgorsza spośród wszystkich proponowanych. Względnie dobre wyniki uzyskano dla zestawu współczynników zmienności parametrów policzonych na podstawie obrazów przefiltrowanych z zastosowaniem masek Lawsa oraz dla kombinacji współczynników zmienności parametrów policzonych z wykorzystaniem wszystkich czterech metod ekstrakcji cech pierwotnych. Rozpoznawalność tkanek wątroby określono: w pierwszym przypadku ponad 70%, (porównywalny wynik otrzymano wykorzystując wektory zawierające $3n$ nieprzekształconych parametrów, w_{BTZ}), w drugim – 74,5%.

Na koniec warto zauważyć, że, na otrzymywane wyniki, wpływ ma także specyfika użytego klasyfikatora. Dzięki selekcji cech, dokonującej się w trakcie budowy drzewa decyzyjnego, w każdym węźle drzewa, wybierane są cechy, które uznano za najistotniejsze w rozróżnianiu obiektów w węźle. Tym samym może się okazać, że spośród $3n$ parametrów, początkowo opisujących obserwacje w zbiorze

uczającym, tylko część jest wykorzystywana do podejmowania decyzji o przynależności obiektów do klas

4. Podsumowanie

W pracy skupiono się na poszukiwaniu metod możliwie jak najlepszego opisu obszarów zainteresowania na dynamicznych tomografiach komputerowych wątroby. Analizowane obrazy były wykonane w trzech fazach akwizycji, wyróżnionych ze względu na obecność środka kontrastującego: pierwszej – przed podaniem pacjentowi kontrastu, kolejnych dwóch (tętnicznej i żylniej) – po jego podaniu. Trójki obrazów (odpowiadających trzem następującym po sobie fazom akwizycji), na których przedstawiony był ten sam fragment wątroby, były analizowane jednocześnie. Uwzględniono w ten sposób nie tylko właściwości tekstury rozpatrywanych obszarów zainteresowania, ale również ich zmiany w czasie, dokonujące się pod wpływem propagacji płynu kontrastującego. Zaproponowano kilka metod opisu ewolucji tekstury w czasie, opierających się na wykorzystaniu różnych funkcji trzech argumentów, którymi były wartości tego samego parametru, odpowiadające trzem fazom pozyskiwania obrazów. Wykorzystano również składowe główne policzone na podstawie zbioru obserwacji opisanych jednocześnie parametrami odpowiadającymi trzem wymienionym fazom. Doświadczenia przeprowadzone na zbiorze danych opisujących cztery typy tkanki wątrobowej pokazały, że znacznie lepszą diagnozę można uzyskać, gdy się uwzględnia informacje o zmianach tekstury w czasie pod wpływem propagacji kontrastu. Najlepszym z proponowanych rozwiązań okazało się zastosowanie zestawów cech zawierających wszystkie nieprzekształcone parametry (odpowiadające fazie bez kontrastu, fazie tętnicznej i fazie żylniej). Należy jednak podkreślić, że wybór przestrzeni parametrów opisujących trójki obszarów zainteresowania nie jest definitywny i pozostanie nadal przedmiotem badań.

W przyszłości kontynuowane będą prace nad rozpoznawaniem typów tkanki wątrobowej na dynamicznych tomografiach komputerowych. Baza danych obrazowych będzie rozszerzona o przypadki nowych pacjentów, pojawi się również możliwość klasyfikacji innych, niż dotychczas analizowane, patologii wątroby (na przykład nowotworów wtórnych). Planowane są dalsze poszukiwania przestrzeni parametrów złożonych, charakteryzujących zmiany właściwości tekstury podczas propagacji środka kontrastującego. Przeprowadzone będą również badania nad możliwością zastosowania w systemie klasyfikatorów złożonych. W dalszej perspektywie autorzy rozważają wykorzystanie analogicznych rozwiązań w rozpoznawaniu obrazów innych organów, które wykonano różnymi technikami (na przykład w klasyfikacji glejaków mózgu na obrazach rezonansu magnetycznego).

Literatura:

- [1] Apostol L., Peyrin F., Yot S., Basset O., Odet C., Tabary J., Dinten J. M., Boller E., Boudousq V., Kotzki P. O.: *A procedure for the evaluation of 2D radiographic texture analysis to assess 3D bone micro-architecture*, Proc. of SPIE, Vol. 5370 Medical Imaging, 2004, pp. 195-206.
- [2] Bae R. Y., Belohlavek M., Greenleaf J. F., Seward J. B.: *Myocardial contrast echocardiography: texture analysis for identification of nonperfused versus perfused myocardium*, Echocardiography, 18(8), 2001, pp. 665-672.
- [3] Bobrowski L., Krętowski M.: *Induction of multivariate decision trees by using dipolar criteria*, LNCS Vol. 1910, Springer-Verlag, 2000, pp. 331-336.
- [4] Brown R. A., Zlatescu M. C., Cairncross J. G., Mitchell J. R.: *Texture Analysis for Non-Invasive Identification of Brain Tumor Genotype from MRI*, Proc. of the Fifth IASTED International Conference on Visualization, Imaging, and Image Processing, ACTA Press, 2005, pp. 459-464.
- [5] 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, pp. 133-164.
- [6] Chen C., Daponte J. S., Fox M. D.: *Fractal feature analysis and classification in medical imaging*, IEEE Transactions on Medical Imaging, 8, 1989, pp. 133-142.
- [7] Chen E. L., Chung P. C., Chen C. L., Tsai H. M., Chang C. I.: *An automatic diagnostic system for CT liver image classification*, IEEE Transactions on Biomedical Engineering, 45(6), 1998, pp. 783-794.
- [8] Clausi D. A., Jernigan M. E.: *Designing Gabor filters for optimal texture separability*, Pattern Recognition, 33, 2000, pp. 1835-1849.
- [9] Cross G. R., Jain A. K.: *Markov random fields texture models*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 5(1), 1985, pp. 25-39.
- [10] Duda D., Krętowski M., Bézy-Wendling J.: *Texture characterization for Hepatic Tumor Recognition in Multiphase CT*, Biocybernetics and Biomedical Engineering, 26(4), 2006, pp. 15-24.
- [11] 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, pp. 1050-1051.
- [12] Galloway M. M.: *Texture analysis using gray level run lengths*, Computer Graphics and Image Processing, 4, 1975, pp. 172-179.
- [13] 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, pp. 153-162.
- [14] Gonzalez R. C., Woods R. E.: *Image Compression*, W: Digital Image Processing, Wydanie drugie, Reading, MA: Addison-Wesley, 2002, pp. 409-518.
- [15] Haralick R. M., Shanmugam K., Dinstein I.: *Textural features for image classification*, IEEE Transactions on Systems, Man and Cybernetics, 3, 1973, pp. 610-621.
- [16] Haralick R. M.: *Statistical and structural approaches to texture*, Proc. of the IEEE, 67, 1979, pp. 786-804.
- [17] Haralick R., Sternberg S. R., Zhuang X.: *Image analysis using mathematical morphology*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 9(4), 1989, pp. 532-550.
- [18] Huang Y. L. Chen J. H. Shen W. C.: *Diagnosis of Hepatic Tumors With Texture Analysis in Nonenhanced Computed Tomography Images*, Academic Radiology, 13(6), 2006, pp. 713-720.
- [19] Husain S. A., Shigeru E.: *Use of neural networks for feature based recognition of liver region on CT images*, Proc. of the IEEE Signal Processing Society Workshop, Vol. 2, 2000, pp. 831-840.
- [20] Krętowski M., Bezy-Wendling J., Duda D.: *Classification of hepatic metastasis in enhanced CT images by dipolar decision tree*, Proc. of 19th GRETSI, 2003, pp. 327-330.
- [21] Laws K. I.: *Texture Energy Measures*, Proc. of the DARPA Image Understanding Workshop, 1979, pp. 47-51.
- [22] Mala K., Sadasivam V.: *Automatic Segmentation and Classification of Diffused Liver Diseases using Wavelet Based Texture Analysis and Neural Network*, Annual IEEE INDICON Conference, 2005, pp. 216 - 219.
- [23] Mallat S. G.: *A theory for multiresolution signal decomposition: The wavelet representation*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 11(7), 1989, pp. 674-693.
- [24] Mir A. H., Hanmandlu M., Tandon S. N.: *Texture analysis of CT-images*, IEEE Engineering in Medicine and Biology, 5, 1995, pp. 781-786.
- [25] Mougiakakou S. G., Valavanis I., Mouravliansky N., Nikita A., Nikita K. S.: *DIAGNOSIS: A Telematics Enabled System for Medical Image Archiving, Management and Diagnosis Assistance*, Proc. of the IEEE IST International Workshop, 2006, pp. 43-48.
- [26] Nair A., Kuban B. D., Tuzcu E. M., Schoenhagen P., Nissen S. E., Vince D. G.: *Coronary plaque classification with intravascular ultrasound radiofrequency data analysis*, Circulation, 106(17), 2002, pp. 2200-2206.

- [27] Sariyanni C. P. A., Asvestas P., Matsopoulos G. K., Nikita K. S., Nikita A. S., Kelekis D.: *A fractal analysis of CT liver images for the discrimination of hepatic lesions: A comparative study*, Proc. of the 23rd Annual EMBS International Conference, 2001, pp. 1557-1560.
- [28] Stoitsis J., Valavanis I., Mougiakakou S. G., Golemati S., Nikita A., Nikita K.: *Computer aided diagnosis based on medical image processing and artificial intelligence methods*, Nuclear Instruments and Methods in Physics Research, 2006, pp. 591-595.
- [29] Valavanis I., Mougiakakou S. G., Nikita K. S., Nikita A.: *Computer aided diagnosis of CT focal liver lesions by an ensemble of neural network and statistical classifiers*, Proc. of the IEEE International Joint Conference on Neural Networks, Vol. 3, 2004, pp. 1929-1934.
- [30] Wei L., Yang Y., Nishikawa R. M., Jiang Y.: *A study on several Machine-learning methods for classification of Malignant and benign clustered microcalcifications*, IEEE Trans. Med. Imaging, 24(3), 2005, pp. 371-380.
- [31] Weszka J. S., Dyer C. R., Rosenfeld A.: *A Comparative Study of Texture Measures for Terrain Classification*, IEEE Trans. Systems, Man, Cybernetics, 6, 1976, pp. 269-285.

TEXTURE FEATURE EXTRACTION IN LIVER CT IMAGE ANALYSIS

Abstract: In the work, a new method of texture characterization from multiple scan series is presented. Images with the same slice position, acquired at different conditions, are analyzed simultaneously. Thereby not only texture characteristics of the considered region of interest are taken into account, but also their variations over the different acquisition moments. A few approaches to description of these variations were proposed. They were applied in recognition of four types of hepatic tissue. Liver CT images were acquired during the three typical phases related to presence and propagation of contrast material. Experiments with various sets of texture parameters and dipolar decision tree as a classifier showed that simultaneous analysis of texture features derived from three subsequent acquisition moments could considerably improve the classification accuracy.

Keywords: computer-aided diagnosis, texture analysis, liver CT images

Artykuł zrealizowano w ramach prac badawczych W/WI/1/05 oraz W/WI/5/05.