

Jacek Śmietański\*, Ryszard Tadeusiewicz\*\*

## **System automatycznego wykrywania i lokalizacji raka stercza na obrazach perfuzyjnej tomografii komputerowej**

### **1. Zarys problemu**

Rak stercza jest jedną z najczęściej występujących chorób nowotworowych wśród mężczyzn i jedną z głównych przyczyn ich zgonów z powodu nowotworu złośliwego [1, 2]. Na przestrzeni ostatnich lat obserwuje się wzrost liczby rejestrowanych zachorowań. I mimo że po części wiąże się on z coraz lepszymi metodami diagnostycznymi oraz rosnącą świadomością wśród pacjentów (co w sumie powoduje wyższą wykrywalność tej choroby), to nie ulega wątpliwości, iż nowotwory prostaty są poważnym problemem medycznym i społecznym.

Tak jak w przypadku każdego nowotworu, również w raku stercza kluczową kwestią zwiększającą szanse przeżycia jest jego wczesne wykrycie. Tylko taki, bezobjawowy i nie dający jeszcze przerzutów nowotwór można z powodzeniem leczyć. Tymczasem skuteczność stosowanych dziś metod diagnozy raka prostaty jest stosunkowo niska. Potwierdzenie jego obecności we wczesnych stadiach rozwoju jest bardzo trudne. Jediną metodą pozwalającą z całą pewnością stwierdzić ten fakt jest biopsja, podczas której pobierany jest niewielki wycinek gruczołu do badania histopatologicznego. Potwierdzenie obecnego w tkance raka możliwe jest tylko wtedy, gdy uda się trafić igłą biopsyjną w zmienione chorobowo miejsce. Rutynowo towarzyszące biopsji badania ultrasonograficzne (TRUS), mające wskazać lekarzom miejsce podejrzanego o zmianę nowotworową, często zawodzą (zmiany te są izoechogeniczne), diagnosta jest więc skazany na pobieranie tkanki z losowo wybranych fragmentów gruczołu, co jest uciążliwe dla pacjenta i może okazać się fatalne w skutkach w przypadku błędnej decyzji.

Z tego względu wielu badaczy podjęło wyzwanie mające na celu opracowanie nowych metod obrazowania umożliwiających zwiększenie pewności diagnozy, zwłaszcza we wspomnianych wyżej trudnych przypadkach. Zespół z krakowskiego oddziału Centrum Onkologii diagnozuje pacjentów, u których podejrzewa się zmiany nowotworowe, metodą perfuzyjnej

---

\* Institute of Computer Science, Jagiellonian University, Kraków

\*\* Department of Automatics, AGH University of Science and Technology, Kraków

tomografii komputerowej (p-CT), zbierając w ten sposób niezbędny materiał doświadczalny. Wśród zbadanych chorych odnotowano przypadek wykrycia i lokalizacji nowotworu właśnie na podstawie perfuzji, podczas gdy biopsja wspomagana jedynie ultrasonografią TRUS niczego nie wykazała [3].

Obrazowanie p-CT należy do funkcjonalnych metod diagnostyki obrazowej. Metoda ta pozwala ocenić parametry przepływu krwi przez badane obszary [4, 5]. Bodźcem do wykorzystania tej techniki w diagnostyce zmian nowotworowych jest udokumentowany w literaturze fakt nasilonego tworzenia nowych, charakteryzujących się zwiększoną przepuszczalnością, naczyń krwionośnych w obrębie wzrostu guza (angiogeneza) [6, 7]. Przypuszcza się zatem, że badanie perfuzyjne prostaty będzie w stanie wskazać te obszary, które zostały objęte angiogenezą, a więc podejrzane są o obecność nowotworu.

Obecnie obrazowanie p-CT stosuje się z powodzeniem przede wszystkim w diagnostyce udaru mózgu [8, 9, 10]. Nieliczne wzmianki dotyczące wykorzystania perfuzji w diagnozie raka prostaty dotyczyły badań prowadzonych zazwyczaj na stosunkowo niewielkiej grupie pacjentów i pozbawionych wsparcia ze strony metod przetwarzania oraz rozpoznawania obrazów [11–13].


Jak się wydaje, takie wsparcie jest niezbędne. Opublikowane do tej pory prace opisujące badania z zastosowaniem metody p-CT w diagnostyce raka stercza skupiały się jedynie na analizie podstawowych parametrów statystycznych i na wykazaniu obecności (lub braku) istotnych różnic w bezwzględnych wartościach parametrów przepływu krwi na z góry ustalonych przez diagnostę fragmentach obrazu. Skrajnie różne wyniki uzyskiwane w tym zakresie przez poszczególnych autorów mogą wynikać nie tylko z nieco odmiennej metodologii badań, ale też (a może przede wszystkim) z faktu, że w istocie nie wiadomo, czego i jak szukać na badanych obrazach. Wzrokowa ocena obrazów uzyskiwanych z zastosowaniem metody p-CT w diagnostyce raka stercza jest niewystarczająca. Cechy odróżniające narząd zdrowy od narządu, w którym występuje rak, są trudne do zwerbalizowania i jeszcze trudniejsze do wzrokowej oceny przez człowieka. W tej sytuacji formułowano zadanie badawcze polegające na próbie znalezienia cech obrazu możliwych do oceny z pomocą analizy komputerowej obrazu, które pozwolą wskazywać efektywne sugestie wspomagające lekarza w procesie diagnostycznym.

## 2. Strategia poszukiwań

Obrazy p-CT prostaty pozyskane do przeprowadzonej analizy numerycznej przedstawiają mapy czterech parametrów perfuzji (rys. 1):

- 1) przepływ krwi BF (*blood flow*) – objętość krwi przepływającej w jednostce czasu przez dany obszar;
- 2) objętość krwi BV (*blood volume*) – całkowita objętość krwi w łożysku naczyniowym w danym obszarze;
- 3) średni czas przejścia MTT (*mean transit time*) – określony w sekundach średni czas przepływu krwi przez tkankę;

- 4) współczynnik przepuszczalności PS (*permeability surface*) – ocenia przepuszczalność naczyń dla środków kontrastowych przedostających się z przestrzeni wewnątrznaczyniowej do zewnątrznaczyniowej.



**Rys. 1.** Mapy parametryczne pozyskane w badaniu p-CT prostaty u przykładowego pacjenta:  
 a) przepływ krwi (BF); b) objętość krwi (BV); c) średni czas przejścia (MTT);  
 d) współczynnik przepuszczalności (PS)

Obrazy te poddano odpowiednim przekształceniom, w celu polepszenia ich jakości oraz ułatwienia porównania danych pochodzących od różnych pacjentów. Przyjęto tutaj dwie strategie:

- 1) polepszenia kontrastu każdego obrazu, abstrahując od konkretnych wartości przepływu krwi;
- 2) ujednoczenia wartości referencyjnych.

W obu przypadkach pierwszym krokiem było zastosowanie przekształcenia LUT [14] w celu zastąpienia pseudokoloru, stosowanego na uzyskanych z kliniki zdjęciach, skalą szarości, lepiej nadającą się do komputerowej analizy. Przekształcenie to nie powoduje utraty żadnej informacji, jednocześnie zdecydowanie ułatwia obliczenia numeryczne.

Kolejnym wspólnym elementem, wykorzystywanym w ramach obu wyżej zasygnalizowanych podejść, jest przeskalowanie wielkości danego obrazu do ich przeciętnego rozmiaru, tj.  $120 \times 100$  pikseli.

Następnie, w celu uwydatnienia lokalnych różnic intensywności dokonano wyrównania histogramu [14] (pierwsze podejście), albo przeskalowano wartości przepływu krwi do tej samej, ustalonej odgórnie, wartości referencyjnej (druga strategia).

Potwierdzona w wielu badaniach potencjalna przydatność metod bazujących na macierzach współwystąpień [15–23] skłoniła autorów do podjęcia w pierwszej kolejności rozważań nad przydatnością tych właśnie metod w problematyce diagnostyki p-CT prostaty.


Niech  $I : Z^2 \supset D \rightarrow G = \{ 1, \dots, N_g \}$  ( $Z$  – zbiór liczb całkowitych) będzie dwuwymiarowym dyskretnym obrazem o  $N_g$  stopniach szarości. Dla danego obrazu  $I$  definiujemy macierz współwystąpień (GLCM):

$$P(i, j | d, \theta) = \frac{\#\{k, l \in D : I(k) = i, I(l) = j, \|k - l\| = d, \angle(k - l) = \theta\}}{\#\{m, n \in D : \|m - n\| = d, \angle(m - n) = \theta\}} \quad (1)$$

gdzie:

- $i, j \in G$  – odpowiednio jasności punktów  $k$  i  $l$ ,
- $\angle(k-l)$  – kąt nachylenia wektora  $kl$  w stosunku do osi  $OX$ ,
- $d$  – odległość między tymi punktami,
- $\theta$  – kierunek współwystępowania,
- $\#X$  – moc (liczba elementów) zbioru  $X$  [24].

Rozważano tutaj macierze (rys. 2) wyznaczone dla wszystkich możliwych odległości, począwszy od  $d = 1$ , uzależniając górną granicę wartości tego parametru od rozmiarów oraz charakterystyki analizowanego obszaru (ROI – *region of interest*). W większości przypadków  $d$  nie przekracza 10–20 pikseli.



**Rys. 2.** Przykład macierzy współwystąpień (GLCM): a) obraz źródłowy o czterech poziomych szerokościach; b) ilustracja zliczania współwystąpień dla  $d = 1, \theta = 0^\circ$ ; c) GLCM dla  $d = 1, \theta = 0^\circ$  (zliczone współwystąpień dzielone są przez liczbę wszystkich rozważanych par punktów (tutaj przez 9), pokazano wartości zaokrąglone do drugiego miejsca po przecinku)

Ponieważ tekstura na analizowanych obrazach wykazuje wyraźną anizotropię, która koncentruje się jednak głównie na kierunkach poziomym i pionowym, wydaje się, że cechy tekstury wyznaczone dla kierunków ukośnych nie wniosą szczególnie istotnych dla rozpoznania informacji. Wstępne analizy potwierdziły to przypuszczenie. Z tego względu w końcowych eksperymentach wyznaczano macierze i ich właściwości jedynie dla kątów  $\theta = 0^\circ$  oraz  $\theta = 90^\circ$ .

Dla każdej macierzy wyznaczono 21 charakteryzujących ją współczynników [25]. Z wartości tych odrzucono pojedyncze wartości odstające, a następnie znormalizowano je do przedziału  $[0, 1]$ . Celem dalszych obliczeń było wskazanie zestawu takich parametrów macierzy GLCM oraz jej współczynników, który stanowiłby zbiór cech dystynktywnych dla obrazu p-CT prostaty. Dzięki temu zestawowi cech możliwe powinno być wydzielenie na analizowanym obrazie dwóch klas obszarów – zdrowego (1) oraz podejrzanego o zmianę nowotworową (2).

Aby uniknąć niebezpieczeństwa przetrenowania algorytmu uczącego i nie pozbawić go zdolności do generalizacji zdobytej wiedzy dla nowych, niespotykanych wcześniej przypad-

ków, zastosowano odpowiednią strategię uczenia. W zależności od liczności zbioru danych testowych była to metoda rotacji (*cross-validation*) z  $n = 10$ , albo metoda usuwania (*leave-one-out*) [26].

W celu określenia stopnia separowalności klas, wykorzystano miarę Bhattacharyya [27], która (przy założeniu rozkładu normalnego przestrzeni cech) dana jest wzorem:

$$J = \frac{1}{4}(\mu_1 - \mu_2)^T [\Sigma_1 + \Sigma_2]^{-1} (\mu_1 - \mu_2) + \frac{1}{2} \log \left[ \frac{|\frac{1}{2}(\Sigma_1 + \Sigma_2)|}{\sqrt{|\Sigma_1| |\Sigma_2|}} \right] \quad (2)$$

gdzie:

$\mu_1, \mu_2$  – wektory średnich,

$\Sigma_1, \Sigma_2$  – macierze kowariancji cechy  $x$  odpowiednio dla klas 1 i 2,

$|\Sigma|$  – wyznacznik macierzy  $\Sigma$  [21].

Ponieważ jednak założenie normalności rozkładu nie zawsze jest spełnione dla rzeczywistych danych, przed wyznaczeniem miary zastosowano metodę drabiny potęg (*ladder of powers*). Idea tej transformaty polega na podniesieniu wszystkich parametrów badanej cechy o odpowiedni (jednakowy dla obu klas) wykładnik  $\gamma$  należący do zbioru liczb rzeczywistych  $R$  [28].

Zasadniczym problemem w pracy była redukcja przestrzeni cech do kilku takich, które mają najlepszą zdolność dyskryminacyjną. Zastosowano w tym celu iteracyjną metodę *plus-2-take-away-1* [29]. W procesie selekcji cech, przeprowadzono również analizę korelacji, niedopuszczając do rozważanego zestawu cech silnie skorelowanych.

W toku rozważań nad poszukiwaniem algorytmu umożliwiającego rozpoznanie na badanych obrazach obszarów chorych, potrzebne jest jeszcze wskazanie odpowiedniego klasyfikatora, który będzie w stanie na podstawie posiadanej wiedzy (dane treningowe) poprawnie interpretować nowe, wcześniej nie spotykane obrazy. W naszym przypadku klasyfikatorem tym były kwadratowe funkcje decyzyjne dane wzorem:

$$d_c(x) = \log p_c - \frac{1}{2} \log |\Sigma_c| - \frac{1}{2} \left[ (x - \mu_c) \Sigma_c^{-1} (x - \mu_c)^T \right] \quad (3)$$

gdzie:

$c \in \{1, 2\}$  – indeks rozważanej klasy,

$p_c$  – prawdopodobieństwo *a priori* przynależności badanego obiektu do klasy  $c$ ,

$\Sigma_c$  – wyznaczona dla danej klasy macierz kowariancji,

$\mu_c$  – wektor średnich dla klasy  $c$ ,

$x$  – wektor cech klasyfikowanego obiektu [30].

Granica decyzyjna między dwiema dowolnymi klasami  $k$  i  $l$  określona jest przez rozwiązanie równania


$$d_k(x) - d_l(x) = 0 \quad (4)$$

i (również w przypadku ogólnym) jest funkcją kwadratową  $x$ .

### 3. Udokumentowana przydatność p-CT – studium przypadku

W opisanych w tym punkcie badaniach weryfikowano skuteczność zaproponowanych technik na przykładzie konkretnego badania, dla którego użyteczność diagnozy p-CT została wcześniej udokumentowana w literaturze [3].


Rozważano obraz przedstawiający parametr BF, przeskalowany do rozmiaru  $120 \times 100$  pikseli metodą najbliższego sąsiada. Podstawowe statystyki, obliczone bezpośrednio z histogramu obrazu, okazały się niewystarczające do poprawnego wskazania obszaru chorego. Jednak wykorzystanie macierzy GLCM pozwoliło na wskazanie takich cech obrazu, które umożliwiają jednoznaczne rozgraniczenie pomiędzy obszarem zdrowym a chorym (rys. 3) [25].



Rys. 3. Analizowany obraz (a) oraz graficzna reprezentacja dwóch najlepiej dyskryminujących cech: b)  $d = 10, \theta = 90^\circ, f_{19}$ ; c)  $d = 8, \theta = 0^\circ, f_{19}$

### 4. Poszukiwanie globalne

Podczas kolejnego etapu badań obrazy były analizowane w całości. Poszukiwano cech obrazu pozwalających na określenie, czy dany pacjent w ogóle posiada zmiany nowotworowe. Problemem, jaki należało tutaj rozwiązać, było ustalenie poziomu badania oraz sposobu wydobycia informacji z map (obrazów) dla tego samego pacjenta, ale przedstawiających różne parametry badania (rys. 4).



Rys. 4. Nałożenie na siebie obrazów z różnych poziomów może spowodować utratę istotnych informacji o teksturze: a, b, c) obrazy BV jednego z pacjentów dla poszczególnych poziomów badania, odpowiadających podstawie, środkowi i szczytowi prostaty; d) obraz powstały przez złożenie obrazów a-c. Wskazany strzałką obszar o zwiększonej perfuzji jest niewidoczny na obrazie wynikowym

Wykonano 24 eksperymenty uwzględniające różne kombinacje metod wstępnego przetwarzania i analizowanych parametrów perfuzji. Macierze GLCM oraz współczynniki wyznaczone były dla każdego poziomu z osobna. W każdym eksperymencie, który był wykonywany niezależnie od pozostałych, dokonano wyboru zestawów składających się z maksymalnie trzech, najlepiej dyskryminujących, niezależnych cech.

W większości eksperymentów jedno- i dwuwymiarowe przestrzenie cech okazały się niewystarczające. Jednak już odpowiednio dobrane trójwymiarowe przestrzenie dały bardzo dobre rozpoznanie. Należy jednak zauważyć, że ze względu na trudności w pozyskaniu wystarczającej liczby obrazów pochodzących od zdrowych pacjentów, rezultaty te należy w przyszłości zweryfikować na bardziej licznej i reprezentatywnej grupie obrazów.

## 5. Lokalizacja nowotworu


Głównym celem prowadzonego rozpoznania medycznego jest możliwie dokładne wskazanie lokalizacji ewentualnych zmian nowotworowych. Dlatego też do dalszych badań obraz podzielony został na mniejsze fragmenty (ROI – *regions of interest*), w których lokalnie poszukiwano nieprawidłowości. Zatem dla każdego rozważanego ROI wyznaczane i weryfikowane były parametry charakteryzujące teksturę tego obszaru.

Po przeprowadzeniu wstępnych analiz i obliczeń, wybrano i zastosowano dwie strategie doboru ROI:

- 1) pokrycie obszaru maską prostokątną;
- 2) „koło ratunkowe”.

Idea metody „koła ratunkowego” opiera się na następujących faktach:

- Zmiany przepływu krwi widoczne w środkowej części obrazu (odpowiadającej w pewnym przybliżeniu strefie przejściowej i centralnej stercza) spowodowane są zazwyczaj łagodnym rozrostem (BPH) (rys. 5). Z tego względu obszar ten wydzielono i wyłączono z dalszych rozważań.



**Rys. 5.** Zwiększona perfuzja w centralnej części obrazu spowodowana jest zazwyczaj łagodnym gruczolakiem (BPH): a) przykład prostaty z BPH; b) ten sam obraz z nałożoną maską „koła ratunkowego” – centralny obszar został wyłączony z analizy

- Rak rozwija się zazwyczaj w strefie obwodowej prostaty. Budowa strefowa nie jest jednak uwidoczniona w badaniu p-CT. Dlatego obszar ten wyznaczono umownie, ustalając jego szerokość na obwodzie całego obrazu.

- Przesłanką pozwalającą podejrzewać obecność nowotworu o charakterze izochogenicznym, niewidocznym w badaniu TRUS, jest asymetria zarysu stercza. Nie zawsze ma to miejsce, gdyż nowotwór może mieć postać wielogniskową, obecną w obu płatach gruczołu. Tym niemniej zdrowa prostata wykazuje symetrię. Z tego względu wprowadzono dodatkową, symetryczną odmianę omawianej metody, opierającą się na przypuszczeniu, że porównanie tekstur pochodzących z naprzeciwległych, odpowiadających sobie fragmentów płatów może być źródłem niezwykle cennych informacji.

W dalszej analizie zastosowano trzy schematy doboru ROI. W każdym z nich wyłączono z rozważań centralny obszar gruczołu:

- Pokrycie obrazu maskami prostokątnymi o rozmiarach  $10 \times 20$  pikseli. Maski wyznaczone były ze skokiem 10 pikseli, przy czym pominięto maski w narożnych i centralnej części obrazu. Dla każdego obrazu wyznaczono 76 obszarów ROI.
- Duże koło ratunkowe – każdy obszar ROI obejmuje wycinek elipsy (bez jej centralnej części) o szerokości  $60^\circ$  (rys. 5b). Kolejne obszary wyznaczone są z obrotem  $20^\circ$ , zatem również tutaj mamy do czynienia z częściowym nakładaniem się sąsiadujących ROI. Dla każdego obrazu wyodrębniamy 18 takich obszarów.
- Małe koło ratunkowe – odmiana poprzedniej wersji, w której poszczególne obszary są mniejsze – każdy ma szerokość  $20^\circ$ . Poszczególne obszary są rozłączne, a jest ich również 18 dla każdego obrazu (rys. 6).



**Rys. 6.** Małe „koło ratunkowe”.


Pary symetryczne oznaczono tym samym kolorem

Oprócz zwykłej analizy poszczególnych ROI wprowadzono również pojęcie „różnic symetrycznych”. Podejście to bazuje na wspomnianym już przypuszczeniu, że obecność raka sugerować mogą symetryczne różnice w obrębie odpowiadających sobie płatów prostaty. Na rysunku 6 odpowiadające sobie pary obszarów wskazano tym samym kolorem. W analizie symetrycznej, dla każdej takiej pary ROI wyznaczana była różnica wartości współczynników otrzymanych odpowiednio w płacie lewym i prawym.

Autorzy proponują także technikę określenia stopnia anizotropii, bazującą na wyznaczonych dla różnych kierunków macierzach GLCM, które – jak wiadomo – są wrażliwe na kierunek tekstury. Do wyznaczenia wspomnianej anizotropii wybrano metodę umożliwiającą wskazanie w jednym eksperymencie cech opierających się na różnych odległościach  $d$ .



Spośród 159 zakwalifikowanych do analizy zestawów danych do ciągu uczącego wybrano tylko te obrazy, na których przepływ krwi w obrębie gruczołu jest dobrze zróżnicowany, co pozwoliło diagnostom wskazać obszar podejrzany o zmianę chorobową. Wyodrębniono 59 takich zestawów. Dla każdego z nich wyznaczono wzorec wskazujący miejsca chore (rys. 7).



**Rys. 7.** Przykładowy obraz (a) i odpowiadający mu wzorec (b).  
Kolorem czarnym oznaczono obszar chory

Na podstawie wzorców przygotowano również mapy klasyfikacji. Dla każdego z rozważanych obrazów uczących i dla każdej metody doboru ROI wskazano obszary, na których występuje zmiana nowotworowa. Dla ROI niesymetrycznych, wyznaczano dwie klasy: „zdrowa” i „chora”. Klasyfikacja dla rozważań symetrycznych ustalana była na podstawie odpowiednich danych dla przypadku niesymetrycznego. Tutaj wyróżniamy cztery klasy: „obszar zdrowy”, „chory tylko lewy płąt”, „chory tylko prawy płąt”, „chore oba płaty”.

Dla każdego wyznaczonego parametru perfuzji i każdej z rozważanych metod wstępnego przetwarzania oraz doboru ROI wykonano niezależne doświadczenie (łącznie było ich 240). Oprócz czterech wskazanych wcześniej parametrów perfuzji (BF, BV, MTT, PS), które analizowane były niezależnie od siebie, dla każdego badania wygenerowano dodatkową mapę parametryczną uwzględniającą wszystkie te właściwości łącznie. Mapa ta wyznaczana była wg wzoru (5) zgodnie z przypuszczeniem, że w obszarze chorym powinien być zwiększony przepływ i objętość krwi, a także zwiększona przepuszczalność naczyń, natomiast czas przejścia powinien być krótszy.

$$\text{mapa parametryczna} = \text{BF} + \text{BV} + \text{PS} - \text{MTT} \quad (5)$$

Największą liczbę poprawnych rozpoznań (ok. 86%) osiągnięto w eksperymencie, w którym rozważano obrazy łączne, uwzględniające wpływ wszystkich wyznaczanych parametrów perfuzji. Obrazy te zostały uprzednio przeskalowane metodą najbliższego sąsiada i poddane operacji wyrównania histogramu. Obszary zainteresowania (ROI) wyodrębniono metodą „małego koła ratunkowego”.

Jako optymalne dla wskazanego algorytmu cechy ustalono:  $d = 1, \theta = 90^\circ, f_9$ ;  $d = 2, \theta = 0^\circ, f_6$ ;  $d = 4, \theta = 90^\circ, f_3$ ;  $d = 4, \theta = 90^\circ, f_6$ ;  $d = 5, \theta = 90^\circ, f_{11}$  oraz  $d = 6, \theta = 90^\circ, f_1$ .

## 6. Podsumowanie

Przeprowadzone rozważania wskazują na potencjalną użyteczność metody perfuzyjnej tomografii komputerowej w diagnostyce wczesnego raka prostaty. Wynika to z faktu, że możliwa jest konstrukcja algorytmu oraz bazującego na nim oprogramowania, stanowiącego istotną pomoc w interpretacji otrzymywanych w trakcie diagnozy obrazów. Zastosowanie metod analizy tekstur opierających się na macierzach GLCM pozwala na zwiększenie skuteczności rozpoznania i lokalizacji obszaru objętego zmianą nowotworową.

Każdy z diagnozowanych parametrów perfuzji stanowi cenną i istotną informację. Dlatego, dokonując analizy numerycznej, należy uwzględnić wszystkie te parametry. Ponadto, istotnym elementem, decydującym o skuteczności rozpoznania, jest ustalenie odpowiednich obszarów zainteresowania (ROI). Spośród przebadanych przez autorów najlepiej sprawdziła się technika „koła ratunkowego”, szerzej opisana w pracy [31].

Badanie p-CT stercza stanowić może istotną wskazówkę diagnostyczną, umożliwiającą zlokalizowanie PCa niewidocznego w innych, stosowanych obecnie technikach. Warto zatem podjąć dalszy wysiłek, dzięki któremu możliwe będzie wprowadzenie tego badania do codziennej praktyki, jako metody uzupełniającej w stosunku do standardowych, choć tańszych i mniej obciążających, ale też nie zawsze skutecznych technik.

## Literatura

- [1] American Cancer Society, Estimated New Cancer Cases and Deaths by Sex, US, 2009, [http://www.cancer.org/downloads/stt/CFR2009\\_EstCD\\_3.pdf](http://www.cancer.org/downloads/stt/CFR2009_EstCD_3.pdf).
- [2] Krajowy Rejestr Nowotworów. Liczba zachorowań w podziale na kody rozpoznai oraz grupy wiekowe. 2009, [http://85.128.14.124/krn/english/liczba\\_zach\\_rozp/default.asp](http://85.128.14.124/krn/english/liczba_zach_rozp/default.asp).
- [3] Łuczyńska E., Anioł J., Szczudło J., et al., *Perfusion of prostate cancer: correlation between p-CT and whole-mount pathology – case report*. Pol J. Radiol., 71(4), 2006, 70–73.
- [4] Miles K.A., Griffiths M.R., *Perfusion CT: a worthwhile enhancement?* Br. J. Radiol., 76, 2003, 220–231.
- [5] Wintermark M., Maeder P., Thiran J-P., et al., *Quantitative assessment of regional cerebral blood flows by perfusion CT studies at low injection rates: a critical review of the underlying theoretical models*. Eur. Radiol., 11, 2001, 1220–1230.
- [6] Carmeliet P., Jain R.K., *Angiogenesis in cancer and other diseases*. Nature, 407(6801), 2000, 249–257.
- [7] Charlesworth P., Harris A., *Mechanisms of disease: angiogenesis in urologic malignancies*. Nature Clinical Practice Urology, 3(3), 2006, 157–169.
- [8] Hartel M., Dziubińska-Basiak M., Konopka M., et al., *Kompleksowa diagnostyka obrazowa udaru niedokrwiennego mózgu – opis przypadku*. Udar Mózgu, t. 8, nr 2, 2006, 81–86.
- [9] Hoeffner E.G., Case I., Jain R., et al., *Cerebral perfusion CT: technique and clinical applications*. Radiology, 231(3), 2004, 632–644.
- [10] Rosenberg R., Wojtek P., Konopka M., et al., *Kliniczne zastosowanie obrazowania perfuzyjnego metodą tomografii komputerowej oraz obrazowania dyfuzyjnego i perfuzyjnego metodą rezonansu magnetycznego w wykrywaniu wczesnych zmian w udarze niedokrwinnym mózgu*. Udar Mózgu, 6(2), 2004, 71–78.
- [11] Henderson E., Milosevic M.F., Haider M.A., Yeung I.W., *Functional CT imaging of prostate cancer*. Psys. Med. Biol., 38, 2003, 3085–3100.

- [12] Ives E.P., Burke M.A., Edmonds P.R., *et al.*, *Quantitative computed tomography perfusion of prostate cancer: correlation with whole-mount pathology*. Clinical Prostate Cancer, 4(2), 2005, 109–112.
- [13] Prando A., Wallace S., *Helical CT of prostate cancer: early clinical experience*. American Journal of Roentgenology, 175(2), 2000, 343–346.
- [14] Tadeusiewicz R., Korohoda P., *Komputerowa analiza i przetwarzanie obrazów*. Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków 1997.
- [15] Connors R.W., Harlow C.A., *A theoretical comparison of texture algorithms*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2(3), 1980, 204–222.
- [16] Ohanian P.P., Dubes R.C., *Performance evaluation for four classes of textural features*. Pattern Recognition, 25(8), 1992, 819–833.
- [17] Ojala T., Pietikäinen M., Harwood D., *A comparative study of texture measures with classification based on feature distributions*. Pattern Recognition, 29(1), 1996, 51–59.
- [18] Randen T., Husøy J.H., *Filtering for texture classification: a comparative study*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 21(4), 1999, 291–310.
- [19] Sharma M., Markou M., Singh S., *Evaluation of texture methods for image analysis*. Proceedings of the 7th Australian and New Zealand Intelligent Information Systems Conference 2001, 117–121.
- [20] Unser M., *Sum and difference histograms for texture classification*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 8(1), 1986, 118–125.
- [21] Walker R.F., *Adaptive multi-scale texture analysis with application to automated cytology*. University of Queensland 1997.
- [22] Weszka J.S., Dyer C.R., Rosenfeld A., *A comparative study of texture measures for terrain classification*. IEEE Trans. Syst., Man, Cybern., 6, 1976, 269–285.
- [23] Wu C.M., Chen Y.C., Hsieh K.S., *Texture features for classification of ultrasonic liver images*. IEEE Transactions on Medical Imaging, 11(2), 1992, 141–152.
- [24] Haralick R.M., Shanmugam K., Dinstein I., *Textural features for image classification*. IEEE Transactions on Systems, Man and Cybernetics, 3, 1973, 610–621.
- [25] Śmiateński J., Tadeusiewicz R., Łuczyńska E., *Texture Analysis in Perfusion Images of Prostate Cancer – Case Study*. International Journal of Applied Mathematics and Computer Science 2010, 20(1), 144–156.
- [26] Hand D., Mannila H., Smyth P., *Eksploracja danych*. WNT, Warszawa 2005.
- [27] Bhattacharyya A., *On a measure of divergence between two statistical populations defined by their probability distributions*. Bulletin of the Calcutta Mathematical Society, 35, 1943, 99–110.
- [28] Tukey J.W., *Exploratory Data Analysis*. Addison-Wesley 1977.
- [29] Kittler J., *Feature set search algorithms*. w: Chen C.H. (red.), Pattern Recognition and Signal Processing, Sijthoff & Noordhoff 1978.
- [30] Krzyśko M., *Analiza dyskryminacyjna*. WNT, Warszawa 1990.
- [31] Śmiateński J., Tadeusiewicz R., *The „Life Belt” Method – a New Approach to Prostate Images Analysis* (zgłoszony do Medical Image Analysis).