

V. OCHRONA ZDROWIA

Piotr Walecki, Jan Trąbka

LAKUNARNOŚĆ – MIARY FRAKTALNE W NEUROOBRAZOWANIU

1. Wprowadzenie

Obecnie wracamy do stawiania na pierwszym miejscu morfologii, czyli aspektów geometrycznych nad charakterystykami czynnościowymi w ujęciu chaotycznej nieliniowej dynamiki mózgu. W podejściu architekturno-przestrzennym jak również fizjologiczno-czasowym uwzględniane są zarówno paradygmaty ciągłości-polowości, jak i digitalizacji, z wyjątkiem falo-kwantów w skali mikroświata. Powyższe problemy sprowadzają się do zagadnień jednorodności lub zróżnicowania struktur anatomicznych w neuroobrazowaniu. W obrazach anatomoklinicznych szczególną uwagę poświęca się jednostkom chorobowym o charakterze chronicznym, obserwując głównie stopień wakuolizacji i opustoszeń oraz pola ostatniej łączki np. stan gąbczasty, wieloogniskowe zaniki i zaburzenia unaczynienia w utkaniu tkanki nerwowej. Zmiany patologiczne oceniane przy pomocy zasugerowanych przez koncepcję chaotyczną wskaźników lakunarności i wymiary fraktalnej dostarczają nowych i poznawczo wartościowych narzędzi oceny i interpretacji obrazów medycznych. W całości zmiany strukturalne mogą geometrycznie wyglądać podobnie, ale mieć definitywnie różny rozkład fraktalny i topologiczny. Ponadto zmiany tkankowe posiadające jednakowy kształt, lecz charakteryzujące się odmienną gęstością mogą dawać inny obraz kliniczny¹.

¹ P. Walecki, J. Trąbka, *Miary fraktalne w neuroobrazowaniu*, „Sztuczna inteligencja w inżynierii biomedycznej”, SIIB 2004, s. 1–4.

Analiza morfometryczna złożonych obiektów naturalnych, jakimi są komórki nerwowe przy użyciu klasycznych metod pomiarowych i obliczeniowych szybko napotyka poważne ograniczenia. Okazuje się, że metody oparte na pomiarach „klasycznych” parametrów geometrycznych komórek nerwowych nie są wystarczające. Jednym z powszechnych ograniczeń metod tradycyjnych jest uzależnienie ich rezultatów od bezwzględnych rozmiarów analizowanego obiektu. W przypadku neuronów, zasięg wypustek nerwowych niekoniecznie musi nieść informację o stopniu rozwoju, funkcji, aktywności czy uszkodzeniach komórki. Wprost przeciwnie: komórki o różnych rozmiarach mogą wykazywać zbliżony stopień dojrzałości itd. Istnieje idea, aby złożone obiekty naturalne, takie jak komórki nerwowe, sieci naczyń krwionośnych, struktura płuc czy nerek, traktować jako fraktale. W istocie, struktury te wykazują na różnych poziomach swej organizacji samopodobieństwo. Należy zaznaczyć, że jest ono oczywiście innej natury niż samopodobieństwo abstrakcyjnych tworów matematycznych – fraktali. Jest mianowicie niedoskonałe i zachodzi jedynie w pewnym zakresie (jednym lub wielu) skali rozważanego obiektu. Przyjęcie fraktalnych właściwości kształtu niektórych struktur naturalnych pociąga za sobą możliwość użycia do ich opisu terminów geometrii fraktalnej. W szczególności stopień złożoności tych struktur może być określony poprzez geometrycznie wyznaczony wymiar fraktalny. Praktycznie określenie takiego wymiaru przeprowadza się komputerowo, operując na odpowiednio przygotowanych danych uzyskanych z obrazów cyfrowych².

2. Założenia metodologiczne

Komputerowa analiza obrazów medycznych wydaje się przedsięwzięciem trudnym, ponieważ wymaga implementacji na maszynach liczących złożonych algorytmów oraz procedur opisujących zależności strukturalne i treściowe interpretowanych obrazów w języku programowania opartym o matematykę. Stanowi to istotną różnicę pomiędzy interpretacją dokonywaną przez doświadczonego lekarza specjalistę, który w swej ocenie posługuje się innymi parametrami znaczącymi. Jedną z możliwości jest modelowanie procesu wnioskowania (np. wnioskowanie

² A. Łuczak, J. Skrzat, W. Lasoń, W. Pyczak, J. Trąbka, *Parametryczny opis kształtu komórek nerwowych na podstawie generatora sztucznych neuronów*, „Sztuczna Inteligencja” 1999.

abdukcyjne³) i diagnozowania lekarskiego wykorzystując systemy logik niemonotonicznych, będącymi pewnymi modelami rozumowań zdroworozsądkowych (np. *default logic* – logika domyślna Reitera⁴, *circumscription* – logika okoliczności McCarthy'ego⁵ czy *motivated action theory* – teoria działań oczekiwanych Morgenstern⁶), a także pewne techniki modelowania niepewności – probabilistyczne, posybilistyczne czy za pomocą logiki przybliżonej (*rough logic*)⁷. Jednakże bardzo ważną drogą pozostaje tworzenie systemów zaawansowanej analizy obrazu, ponieważ korzysta się w ten sposób z olbrzymiego potencjału maszyn liczących do operowania i przeliczania wielkich ilości zdigitalizowanych danych, które obecnie stanowią gros informacji zapisywanych w procesie obrazowania medycznego.

Analiza i interpretacja obrazów medycznych przy użyciu komputera opiera się na matematycznych metodach opisu cech obiektów obrazu. Różnorodne techniki obrazowania neurologicznego służące do diagnostyki lekarskiej dostarczają cyfrowych danych m.in. osiowa tomografia komputerowa (CAT), tomografia emisyjna (PET lub SPECT), czynnościowy rezonans magnetyczny (fMRI), elektroencefalografia (EEG) czy magnetoencefalografia (MEG). Również wycinki histopatologiczne w postaci preparatów mikroskopowych za pośrednictwem cyfrowych kamer mogą dawać wysoce precyzyjne dane obrazowe. Niezależnie z jakiego źródła pochodzi otrzymany materiał to matematyczne sposoby jego obróbki są podobne. Najpierw następuje segmentacja obrazu, gdzie zostaje on sprowadzony do obrazu wynikowego, czyli do obrazu w nieskompresowanej postaci (najczęściej obrazu binarnego) posiadającego odpowiednie parametry lokalizacyjne poszczególnych obiektów. Następnie wyodrębnione obiekty charakteryzuje się na podstawie cech wydzielonych za pomocą różnych metod matematycznych, które można podzielić na dwie grupy: opis cech linii brzegowej obiektu i opis cech pola obszaru obiektu⁸. W zależności od medycznego celu przeprowadzania analizy obrazu, bardziej korzystne będzie użycie procedur należących do jednej bądź drugiej grupy, jak

³ P. Walecki, W. Lasoń, Z. Wiśniowski, I. Roterman-Konieczna, *Abductive Logic Programming in medical diagnosis*, „Journal of Artificial Intelligence” 2004, vol. 1, nr 2(24), s. 107–115.

⁴ R. Reiter, *A logic for default reasoning*, „Artificial Intelligence” 1980, 13, s. 81–132.

⁵ J. McCarthy, *Circumscription – a form of monotonic reasoning*, „Artificial Intelligence” 1980, 13, s. 27–39.

⁶ L. Morgenstern, L. A. Stein, *Motivated action theory: A formal theory of causal reasoning*, „Artificial Intelligence” 1994, 71, s. 1–42.

⁷ S. Tsumoto, *Automated discovery of decision rule chains using rough sets and medical diagnostic model*, Berlin 2002, s. 321–332.

⁸ S. Kishk, B. Javidi, *Distortion Tolerant Image Recognition Receiver by Use of a Multiple-Hypothesis Method*, „Appl. Opt.” 2002, 41, s. 2149–2157.

również w związku z tym, że procedury te mówią o różnych komplementarnych cechach analizowanego obiektu, to dla poszerzenia informacji opisu można stosować obie metody razem. W obu grupach są zarówno metody wzięte z klasycznej geometrii jak i geometrii fraktalnej.

3. Analiza konturu

Analiza konturu, obrysu wyekstrahowanego obiektu jest jedną z najczęściej stosowanych grup miar służących do interpretacji danych obrazowych. Długość i kształt linii brzegowej wyznaczającej granice analizowanego obiektu opisują różne metody począwszy od prostych algorytmów śledzenia konturu, poprzez analizę sąsiedztwa punktów w siatce dyskretnej czy cztero-, ośmio- lub wielokierunkowe kody łańcuchowe Freemana aż po syntaktyczną reprezentację konturów i wymiary fraktalne⁹.

Geometryczne odwzorowania brzegu obszaru badanego przedstawia się również za pomocą sygnatur – jednowymiarowych funkcji opisujących brzeg obiektu np. przez wykreślanie zależności pomiędzy odległością punktów brzegu od umownego środka obszaru lub śledzenie brzegu obiektu i wykreślanie kąta utworzonego przez styczną do brzegu z osią układu współrzędnych w funkcji parametru określającego kolejne punkty brzegu¹⁰.

Funkcje sklejane – *splines*, będące złożeniem funkcji wielomianowych bywają wykorzystywane w komputerowej syntezie i rozpoznawaniu kształtów, ponieważ umożliwiają aproksymację kształtu brzegu czy konturu za pomocą małej liczby parametrów. Rozwinięciem tej metody jest zaproponowana w Zakładzie Biocybernetyki procedura, która polega na zastąpieniu konkretnej linii, danej w postaci chmury punktów wyodrębnionej z przetwarzanego obrazu, analitycznym równaniem tej linii wyznaczonym metodą regresji odcinkowej oraz równaniem opisującym zmiany grubości linii. Regresja odcinkowa mimo tego, iż wykorzystuje mechanizm sklejania funkcji, zasadniczo różni się od klasycznych metod aproksymacji funkcji za pomocą *splines*¹¹. Po pierwsze, liczby punktów danej próby losowej przypisane poszczególnym odcinkom nie są z góry ustalone. Po drugie, z góry zakłada się wygładzający charakter aproksymacji. W szczególności nie

⁹ K. Wojciechowski, *Rozpoznawanie obrazów*, Gliwice 1997.

¹⁰ S. M. Yamany, A. A. Farag, *Free-Form Surface Registration Using Surface Signatures*, ICCV. 2: 1098, September 20–25, 1999.

¹¹ I. B. Onukogu, *Merging Spline Approximations with Analysis of Nonlinear Regression Models*, „Biom. J.” 1984, 26, 3, s. 263–270.

obowiązuje tu wymaganie przechodzenia linii aproksymującej dokładnie przez wszystkie punkty próby, a wielkości odchyłek nie wynikają z właściwości przypisywanych punktom (na przykład tak zwanych „sprężystości podpór”) a ze statystycznych ocen jakości dopasowania modelu – zgodnie z zasadami analizy regresji¹².

W postaci parametrycznej kontur obiektu można przedstawić za pomocą szeregu par współrzędnych $\{x(t), y(t)\}$. Następnie tak skonstruowany szereg interpretuje się jako okresowy sygnał zespolony:

$$s(k) = x(k) + jy(k), k = 0, 1, \dots, N-1 \quad (1)$$

Dyskretna transformata Fouriera tego sygnału:

$$a(n) = \frac{1}{N} \sum_{k=0}^{N-1} s(k) \exp(-j2\pi nk/N) \quad (2)$$

$$n = 0, 1, \dots, N-1$$

Współczynniki $a(n)$ zwane są deskryptorami Fouriera (FD) kształtu¹³.

Jednymi z bardziej obiecujących metod stosowanych do analizy obrazów medycznych są miary fraktalne. W literaturze opisano szereg metod wyznaczania poszczególnych odmian wymiaru fraktalnego¹⁴. Wszystkie te metody mają na celu określenie wykładnika D w zależności:

$$N(\varepsilon) = \varepsilon^{-D} \quad (3)$$

gdzie $N(\varepsilon)$ jest minimalną liczbą zbiorów otwartych o średnicy ε pokrywających badany zbiór¹⁵. Można wyróżnić trzy główne metody obliczania wymiaru fraktalnego:

- Wymiar Richardсона – otrzymywany przez zliczanie liczby kroków potrzebnych do przemierzenia konturu w funkcji długości kroku. Wymiar fraktalny

¹² M. Górkiewicz, M. Usarz, J. Trąbka, *Zastosowanie funkcji sklepanych do tworzenia modeli struktur biologicznych*. CIR-13'98, Siedlce–Warszawa 1998.

¹³ P. E. Lestrel (red.), *Fourier Descriptors and their Applications in Biology*, Cambridge 1997.

¹⁴ F. Normat, C. Tricot, *Method for evaluation the fractal dimension of curves using convex hulls*, „Physical Review” 1991, 43, 12, s. 6518–6525.

¹⁵ M. Usarz, M. Górkiewicz, J. Trąbka, *Określanie wymiaru fraktalnego obrazu obiektów biologicznych*. CIR-13'98, Siedlce–Warszawa 1998.

otrzymujemy poprzez wykreślenie tej funkcji w skali podwójnie logarytmicznej i wyznaczeniu tangensa kata stycznej do tej funkcji¹⁶.

- Wymiar Minkowskiego – zwany także *metodą cyrklową*, która polega na poszukiwaniu liniowej zależności pomiędzy logarytmami długości badanej krzywej i *rozstawu cyrkla* użytego do pomiaru. Znajduje on jednak ograniczone zastosowanie, głównie ze względu na trudności implementacyjne. Wymiar fraktalny D_f opisywany jest wzorem:

$$D_f = \lim_{s \rightarrow 0} \frac{\log(N)}{\log(1/s)} \quad (4)$$

gdzie N jest minimalną liczbą okręgów o promieniu s potrzebnych do pokrycia danego obiektu¹⁷.

- Wymiar Kołmogorowa – zwany także *wymiarem pojemnościowym*. W metodzie tej stosowane są sześciennne elementy pokrywające badany zbiór, zwykle na obraz nakładana jest kwadratowa siatka. Jest to metoda znacznie łatwiejsza do implementacji.

Wymiar fraktalny z definicji jest niezależny od wielkości jednostki pomiarowej i jest stały dla danej figury niezależnie od jej rozmiarów. Jednak dla rzeczywistych obiektów nie można obliczyć wymiaru fraktalnego w sposób analityczny i dlatego wprowadzono numeryczne procedury podające jego przybliżoną wartość¹⁸. Jedną z takich procedur jest wspomniana metoda *box-counting*¹⁹. Wymiar fraktalny D_f liczony metodą *box-counting* definiowany jest jako $D_f = \log(a) / \log(1/s)$, gdzie a oznacza liczbę niepustych kwadratów (zawierających przynajmniej jeden czarny punkt) o boku długości s . Wymiar fraktalny wyznacza się z nachylenia prostej regresji dla punktów: $x_i = \log(ai)$, $y_i = \log(1/si)$. Niestety przy tych metodach wartość wymiaru fraktalnego rzeczywistego obrazu może być zniekształcona przez wielkość mierzonego obiektu. Powoduje to konieczność wyznaczenia zależności wymiaru fraktalnego koła od jego pola powierzchni dla powyższej metody, dla której wymiar fraktalny obliczany jest w następujący sposób:

$$D_f = \text{Nachylenie prostej regresji wyznaczonej dla punktów } \{\ln(N_i), \ln(1/s_i)\}, \quad (5)$$

¹⁶ K. Krawiec, *Rozpoznawanie obrazów*, <http://www-idss.cs.put.poznan.pl/~krawiec/ro/>

¹⁷ B. B. Mandelbrot, *The fractal geometry of nature*, New York 1982.

¹⁸ J. Theiler, *Estimating Fractal Dimension*. „J. Opt. Soc. Am. A.” 1990, vol. 7, nr 6; s. 1055–1073.

¹⁹ L. Liebovitch, A. Toth, *A Fast Algorithm To Determine Fractal Dimension By Box Counting*, „Physics Letters” 1989, vol. 141, s. 386–390.

gdzie N_i oznacza liczbę niepustych kwadratów o długości boku s_i , co odpowiada polu powierzchni figury wyrażonej w jednostkach s_i^2 , a i jest numerem kolejnej długości boku. Ponieważ równanie prostej regresji ma postać $y = ax + b$, można więc zapisać powyższe równanie jako :

$$\ln(N_i) = Df * \ln(1/s) + b \quad (6)$$

stąd

$$Df = \frac{\ln(N_i)}{\ln(1/s)} + \frac{b}{\ln(1/s)} \quad (7)$$

Wzór ten wyraża zależność Df od pola powierzchni dla danej figury w metodzie *box-counting*.

Przykładem stosowania powyższej metody była analiza krwotoków miąższowych mózgu na podstawie obrazów z tomografii komputerowej gdzie wraz z wprowadzaną nowatorską miarą RDf , czyli wartością bezwzględną różnicy pomiędzy zmierzonym wymiarem fraktalnym krwiaka (Df) a wymiarem fraktalnym koła (Dfk) o tej samej powierzchni, stanowiły podstawę predykcyjną stanu zdrowia pacjentów. Wprowadzona fraktalna miara RDf pozwoliła na ilościowe oszacowanie nieregularności przekroju krwiaka i jego podobieństwa do kształtu koła. RDf dobrze odzwierciedla tendencje zmiany stanu zdrowia pacjentów wyrażony w SSU (Skandynawskiej Skali Udarowej) po około 30 dniach²⁰.

W Zakładzie Biocybernetyki CM UJ prowadzone były pionierskie w skali kraju prace badawcze nad opisem fraktalnym obrazów neurologicznych²¹ oraz modelowaniem fraktalnym struktur nerwowych (model wyjaśniający rozmieszczenie przestrzenne ciał komórkowych w korze mózgowej szczura²² i model wzrostu neuronu oparty o algorytmy probabilistyczne z obszarami atrakcji²³. Wykorzystano

²⁰ A. Łuczak, *Zastosowanie geometrii fraktalnej w neuroanatomii*, Praca doktorska, Promotor: Prof. dr hab. Jan Trąbka, Obroniona na Wydziale Lekarskim Collegium Medicum Uniwersytetu Jagiellońskiego.

²¹ J. Trąbka, M. Górkiewicz, M. Usarz, W. Lasoń, *Aksjomatyczne i aproksymacyjne podejście do identyfikacji zbiorów rozmytych*. III Conf. on Acoustical Meth. and Mech. in Biomed. Eng., Zakopane, 23–24.04.98

²² A. Łuczak, J. Skrzat, W. Lasoń, J. Trąbka, *Model mechanizmów przestrzennego rozmieszczenia komórek kory mózgowej szczura na podstawie automatu komórkowego*. MCSB, Kraków 2000 s. 377–381.

²³ A. Łuczak, J. van Pelt, *The model of neurons growth with the branching probability depended of the neurons environment*, „Acta Neurobiologiae Experimentalis” 2001, 61, s. 194.

również praktyczne właściwości miar fraktalnych do analizy krwotoków mięszkowych mózgu na podstawie obrazów z tomografii komputerowej celem oszacowania rokowań prognostycznych i terapeutycznych²⁴.

4. Analiza powierzchni

Analiza obszaru obiektu związana jest miarami tekstury i lakunarności. Odbieramy fakturę poprzez dotyk i wzrok. Wizualne struktury pomagają lekarzom pośrednio postrzegać charakterystyczne cechy powierzchni badanych obiektów zobrazowanych w materiale klinicznym. Irons i Petersen opisują teksturę jako „wrażenie chropowatości lub gładkości stworzone przez zróżnicowanie w tonie czy powtórzeniu wizualnych wzorów na powierzchni”²⁵. Strukturalna analiza tekstury bada powtarzające się wzory podstawowych elementów w obrazie i próbuje opisywać przestrzenne charakterystyki jak kształt, obszar i zasięg tych wzorów. Binarna macierz z różnym schematem podstawowych składowych jest użyteczna dla identyfikacji dyspersji przestrzennej i zagęszczenia populacji obiektów, a więc badania tekstury obrazu i obliczania lakunarności.

Pierwszy pojęcie lakunarności zaproponował Mandelbrot jako matematyczny opis tekstury fraktala²⁶. Voss opisał lakunarność jako stosunek wariancji dla funkcji $P(m, L)$, która określa prawdopodobieństwo znalezienia punktów m w kwadracie o rozmiarze L dla danej wartości L do kwadratu średniej tej funkcji²⁷:

$$\lambda(L) = \frac{\sum_{m=1}^{L^2} m^2 P(m, L) - \left(\sum_{m=1}^{L^2} m P(m, L) \right)^2}{\left(\sum_{m=1}^{L^2} m P(m, L) \right)^2} \quad (8)$$

Lakunarność jest odpowiednikiem wymiaru fraktalnego, opisuje budowę fraktala. Związana jest z wielkością dystrybucji dziur. Ogólnie mówiąc opisuje, czy fraktal ma duże otwory lub dziury, i wtedy ma wysoką lakunarność oraz na odwrót. Pojęcie lakunarności stosowane jest w technikach przetwarzania obrazu, w tym przy analizie obrazów medycznych. Dla obrazowania medycznego ta miara wydaje


²⁴ A. Łuczak, *Zastosowanie geometrii fraktalnej...*

²⁵ J. Irons, G. W. Petersen, *Texture transforms of remote sensing data*, „Remote Sensing Environment” 1981, 11, s. 359–370.

²⁶ B. B. Mandelbrot, *op.cit.*

²⁷ R. Voss, *Random fractals: characterization and measurement*, „Scaling phenomena in disordered systems” 1985, s. 1–11.

Rysunek 1.



Obraz z TK przedstawiający zdiagnozowane za pomocą analizy lakunarności zmiany w mózgu. Źródło: własne.

się szczególnie ważna, ponieważ pewne obrazy mogą charakteryzować się podobnym wymiarem fraktalnym, lecz równocześnie widocznie różnić się od siebie. Na przykład można stworzyć grupę zbiorów Cantora, każdy o wymiarze fraktalnym:

$$Df = \log N / \log (1/r) = \log 2k / \log 4k = \frac{1}{2}.$$

Jeśli wartość indeksu k zmienia się, rozmieszczenie „przestrzeni” zawartych tych zbiorach zwiększa się. Pojęcie „przestrzeni” – dziur pomiędzy liczbami lub obiektami – określa właśnie lakunarność. W tym przykładzie można zobaczyć jak lakunarność może znacznie różnicować obrazy posiadające ten sam wymiar fraktalny.

Zaproponowanych zostało kilkanaście sposobów mierzenia lakunarności, lecz wspólna definicja bazuje na wzajemnym stosunku jasnych i ciemnych regionów zawartych danym obrazie $\lambda(r) = \text{variance}/(\text{mean})^2$. Gdzie λ jest lakunarnością a r rozmiarem obrazu. We względnie rozmytym lub jednorodnym zbiorze fraktalnym, gdzie $\lambda \rightarrow 1$ rozmiar dziur i zmienność jest minimalna. Jeśli natomiast $\lambda \rightarrow \infty$ szerokie rozmieszczenie i zasięg rozmiarów dziur tworzą heterogenną strukturę²⁸.

²⁸ C. Allain, M. Cloitre, *Characterizing the Lacunarity of Random and Deterministic Fractal Sets*, „Physics Review” 1991, vol. 44, 6.

Powyższe miary pozwalają na wychwycenie różnic w rozkładzie zagęszczeń punktów występujących pomiędzy obrazami innymi słowy wyrażają stopień złożoności obrazu, dlatego dobrze nadają się do porównywania rozmieszczenia komórek nerwowych w preparacie mikroskopowym²⁹ lub badanych obiektów w obrazach z tomografii komputerowej czy rezonansu magnetycznego³⁰. W badaniach własnych posługiwaliśmy się programem komputerowym *ImageJ* udostępnionym przez National Institute of Health, USA.

5. Podsumowanie

Projekt badawczy realizowany obecnie w Zakładzie Bionformatyki i Telemedycyny CM UJ dotyczy zagadnień związanych z medycznymi metodami diagnostycznymi, wśród których obecnie coraz mocniej uwidacznia się postulat jak najwcześniejszego rozpoznawania procesów chorobowych, a więc tyczy się on kwestii wczesnego i wyraźnego wyznaczenia granicy pomiędzy normą a patologią, które następnie rzutuje na konkretne wskazania terapeutyczne. Problem ten nabiera istotnych znaczeń wraz z wykorzystaniem najnowszych technik badań obrazowych (CT, MRI) oraz matematycznych metod analizy danych zaczerpniętych z geometrii fraktalnej (wymiar fraktalny, lakunarność). Takie zaawansowane sposoby prowadzenia prac badawczych możliwe są obecnie dzięki mocy przeliczeniowej systemów komputerowych zdolnych do operowania na odpowiednio przygotowanym materiale uzyskanym z obrazów cyfrowych pochodzących z praktyki klinicznej. Dane kliniczne poddawane będą obróbce matematycznej, która korzysta z teorii nieliniowości oraz metod fraktalnych. Wnoszą one nowe parametry diagnostyczne pozwalając dalece precyzyjniej uchwycić początki procesu chorobowego i przedsięwziąć odpowiednie kroki zapobiegawcze lub lecznicze.

W niniejszym projekcie kładziemy główną uwagę na analizę zmian patomorfologicznych tkanki mózgowej jakie występują przy zespołach minimalnego uszkodzenia mózgu (ZMUM). Wybór tej właśnie jednostki nozologicznej był podyktowany następującymi względami: skomplikowaną diagnostyką związaną

²⁹ J. Skrzat, M. Usarz, J. Trąbka, G. Goncerz, *Differentiation of neurons populations based on fractal dimension*, „Folia Morphologica” 1996, 55, 4, s. 444–446.

³⁰ C. Balestra, et al., *The fractal approach as a tool to understand asymptomatic brain hyperintense mri signals*, „Fractals” 2004, 12, 1, s. 67–72.

z niejednoznacznym obrazem klinicznym (symptomatologią) przy trudnych do uchwycenia zmianach morfologicznych w ośrodkowym układzie nerwowym, powszechności tego typu zaburzeń w chorobach uzależnieniowych (nikotynizm, alkoholizm, narkomania) oraz znajomości tematu poprzez wcześniejsze prowadzenie prac badawczych w tym zakresie (badania encefalograficzne nad otiatrycznym zespołem minimalnego uszkodzenia mózgu – OZMUM).

Summary

Lacunarity – Fractal Measures in Neuroimaging

This paper presents research to the point of practicability of fractal measure, and particularly of lacunarity suitable for analysis and interpretation of medical images. The new approach to study measures on ensembles of contours (spline functions) in medical imaging. However the main part of this work was devoted to the fractal measures and lacunarity. Several different ways to describe and estimate these dealings were considered in aspect of neuroimaging.