

Piotr Walecki i Jan Trąbka

## Lakunarność i inne miary fraktalne w neuroobrazowaniu

Obecnie wracamy do stawiania na pierwszym miejscu morfologii, czyli aspektów geometrycznych przed charakterystykami czynnościowymi w ujęciu chaotycznej nieliniowej dynamiki mózgu. W podejściu architekturno-przestrzennym, jak również fizjologiczno-czasowym, uwzględniane są zarówno paradygmaty ciągłości-półowości, jak i digitalizacji, z wyjątkiem falo-kwantów – jak w skali mikroświata. Problemy powyższe sprowadzają się do zagadnień jednorodności lub zróżnicowania specjalizacyjnego struktury w medycynie, a w szczególności w naukach psycho-neuro-biologicznych, w warunkach prawidłowych i patologicznych. W obrazach klinicznych uwagę poświęca się raczej 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 za pomocą zasugerowanych przez koncepcję chaotyczną wskaźników lakunarność i dymensji 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 kliniczny.

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 cyfrowych<sup>1</sup>.

## 1. 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 na matematyce. Stanowi to istotną różnicę wobec interpretacji dokonywanej przez doświadczonego lekarza specjalistę, który w swej ocenie posługuje się innymi parametrami znaczącymi. Można oczywiście modelować proces wnioskowania i diagnozowania lekarskiego, wykorzystując systemy logik niemonotonicznych, które są w istocie pewnymi modelami rozumowań zdroworozsądkowych (np. *default logic* – logika domyślna Reitera<sup>2</sup>, *circumscription* – cyrkumskrypcja McCarthy'ego<sup>3</sup> czy *motivated action theory* – teoria działań oczekiwanych<sup>4</sup>, a także pewne techniki modelowania niepewności – probabilistyczne, posybilistyczne czy za pomocą logiki przybliżonej (*rough logic*)<sup>5</sup>. Jednakże bardzo ważną drogą pozostaje tworzenie nowych, specyficznych dla komputerów i im dedykowanych metod analizy obrazu. 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.

<sup>1</sup> A. Łuczak, J. Skrzat, W. Lasoń, W. Pyrczak, J. Trąbka, *Parametryczny opis kształtu komórek nerwowych na podstawie generatora sztucznych neuronów*, „Sztuczna Inteligencja”, Siedlce–Warszawa 1999.

<sup>2</sup> R. Reiter, *A logic for default reasoning*, „Artificial Intelligence” 1980, 13: 81–132.

<sup>3</sup> J. McCarthy, *Circumscription – a form of monotonic reasoning*, „Artificial Intelligence” 1980, 13: 27–39.

<sup>4</sup> L. Morgenstern, L.A. Stein, *Motivated action theory: A formal theory of causal reasoning*, „Artificial Intelligence” 1994, 71: 1–42.

<sup>5</sup> S. Tsumoto, *Automated discovery of decision rule chains using rough sets and medical diagnostic model*, ISMIS, Berlin 2002, 321–332.

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), czynnościowy rezonans magnetyczny (fMRI), magnetoencefalografia (MEG). Również wycinki histopatologiczne w postaci preparatów mikroskopowych za pośrednictwem cyfrowych kamer mogą dawać wysoce precyzyjne dane obrazowe. Niezależnie od źródła, z jakiego pochodzi otrzymany materiał, matematyczne sposoby jego obróbki są podobne. Najpierw następuje segmentacja obrazu, tzn. 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 obiektu<sup>6</sup>. W zależności od medycznego celu przeprowadzania analizy obrazu, bardziej korzystne będzie użycie procedur należących do jednej bądź drugiej grupy, jak 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.

## 2. 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 fraktalne<sup>7</sup>.

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 brzegu<sup>8</sup>.

<sup>6</sup> R. Tadeusiewicz, M. Flasiński, *Rozpoznawanie obrazów*, PWN, Warszawa 1991.

<sup>7</sup> K. Wojciechowski, *Rozpoznawanie obrazów*, Gliwice 1997.

<sup>8</sup> S.M. Yamany, A.A. Farag, *Free-form surface registration using surface signatures*, ICCV. 2: 1098, September 20–25, 1999.

Funkcje sklepane – *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 sklepania funkcji, zasadniczo różni się od klasycznych metod aproksymacji funkcji za pomocą *splines*<sup>9</sup>. 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 obowiązuje tu wymaganie przechodzenia linii aproksymującej dokładnie przez wszystkie punkty próby, a wielkości odchyłek nie wynikają z właściwości przypisywanych punktom (np. tzw. sprężystości podpór), a ze statystycznych ocen jakości dopasowania modelu – zgodnie z zasadami analizy regresji<sup>10</sup>.

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:

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

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) kształtu<sup>11</sup>.

Jednymi z bardziej obiecujących metod stosowanych do analizy obrazów medycznych są te oparte na miarach fraktalnych. W literaturze przedmiotu opisano szereg metod wyznaczania poszczególnych odmian wymiaru fraktalnego<sup>12</sup>. Wszystkie te metody mają na celu określenie wykładnika  $D$  w zależności:

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

<sup>9</sup> I.B. Onukogu, *Merging Spline Approximations with Analysis of Nonlinear Regression Models*, Biom. J. 26, 3: 263–270, 1984.

<sup>10</sup> M. Górkiewicz, M. Usarz, J. Trąbka, *Zastosowanie funkcji sklepanych do tworzenia modeli struktur biologicznych*, CIR-13'98, Siedlce–Warszawa 1998.

<sup>11</sup> P.E. Lestrel, ed., *Fourier Descriptors and their Applications in Biology*, Cambridge 1997.

<sup>12</sup> F. Normat, C. Tricot, *Method for evaluation the fractal dimension of curves using convex hulls*, „Physical Review” A, 43, 12: 6518–6525, 1991.

gdzie  $N(\varepsilon)$  jest minimalną liczbą zbiorów otwartych o średnicy  $\varepsilon$  pokrywających badany zbiór<sup>13</sup>. Można wyróżnić trzy główne metody obliczania wymiaru fraktalnego:

– Wymiar Richardsona – otrzymywany przez zliczanie liczby kroków potrzebnych do przemierzenia konturu w funkcji długości kroku. Wymiar fraktalny otrzymujemy poprzez wykreślenie tej funkcji w skali podwójnie logarytmicznej i wyznaczeniu tangensa kąta stycznej do tej funkcji<sup>14</sup>.

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

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

gdzie  $N$  jest minimalną liczbą okręgów o promieniu  $s$  potrzebnych do pokrycia danego obiektu<sup>15</sup>.

– Wymiar Kołmogorowa – zwany także *wymiarem pojemnościowym*. W metodzie tej stosowane są sześciennie 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 wartość<sup>16</sup>. Jedną z takich procedur jest wspomniana metoda *box-counting*<sup>17</sup>. Wymiar fraktalny  $Df$  liczony metodą *box-counting* definiowany jest jako  $Df = \log(a) / \log(1/s)$ , 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:  $x_i = \log(a_i)$ ,  $y_i = \log(1/s_i)$ . 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:

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

<sup>13</sup> M. Usarz, M. Górkiewicz, J. Trąbka, *Określanie wymiaru fraktalnego obrazu obiektów biologicznych*. CIR-13'98, Siedlce-Warszawa 1998.

<sup>14</sup> K. Krawiec, *Rozpoznawanie obrazów*, <http://www-idss.cs.put.poznan.pl/~krawiec/ro/>.

<sup>15</sup> B.B. Mandelbrot, *The fractal geometry of nature*, New York 1982.

<sup>16</sup> J. Theiler, *Estimating Fractal Dimension*, J. Opt. Soc. Am. A.; vol. 7, no. 6; 1055–1073, 1990.

<sup>17</sup> L. Liebovitch, A. Toth, *A Fast Algorithm to Determine Fractal Dimension by Box Counting*, „Physics Letters” A, vol. 141: 386–390, 1989.

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, która wraz z wprowadzaną nowatorską miarą  $RDf$ , czyli wartością bezwzględną różnicy między zmierzonym wymiarem fraktalnym krwiaka ( $Df$ ) a wymiarem fraktalnym koła ( $Dfk$ ) o tej samej powierzchni, stanowiła postawę 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 dniach<sup>18</sup>.

W Zakładzie Biocybernetyki CM UJ prowadzone były pionierskie w skali kraju prace badawcze nad opisem fraktalnym obrazów neurologicznych<sup>19</sup> oraz modelowaniem fraktalnym struktur nerwowych (model wyjaśniający rozmieszczenie przestrzenne ciał komórkowych w korze mózgowej szczura<sup>20</sup> oraz model wzrostu neuronu oparty na algorytmach probabilistycznych z obszarami atrakcji<sup>21</sup>). Wykorzystano również praktyczne właściwości miar fraktalnych do analizy krwotoków miąższowych mózgu na podstawie obrazów z tomografii komputerowej w celu oszacowania rokowań prognostycznych i terapeutycznych<sup>22</sup>.

<sup>18</sup> A. Łuczak, „Zastosowanie geometrii fraktalnej w neuroanatomii”, praca doktorska, promotor: prof. dr hab. Jan Trąbka, obroniona na Wydziale Lekarskim CM UJ.

<sup>19</sup> 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.

<sup>20</sup> A. Łuczak, J. Skrzat, W. Lasoń, J. Trąbka, *Model mechanizmów przestrzennego rozmieszczenia komórek kory mózgowej szczura na podstawie automatu komórkowego*, MCSB, Kraków 2000: 377–381.

<sup>21</sup> A. Łuczak, J. van Pelt, *The model of neurons growth with the branching probability depended of the neurons environment*, „Acta Neurobiologiae Experimentalis”, 61: 194, Warsaw 2001.

<sup>22</sup> A. Łuczak, „Zastosowanie geometrii fraktalnej w neuroanatomii”...

### 3. 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<sup>23</sup> opisują teksturę jako „wrażenie chropowatości lub gładkości stworzone przez zróżnicowanie w tonie czy powtórzeniu wizualnych wzorów na powierzchni”. Strukturalna analiza tekstury bada powtarzające się wzory podstawowych elementów w obrazie i próbuje opisywać charakterystyki przestrzenne, takie 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<sup>24</sup> – jako matematyczny opis tekstury fraktala. Voss<sup>25</sup> 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 funkcji:

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

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 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:

$$Df = \log N / \log (1/r) = \log 2^k / \log 4^k = 1/2 .$$

Jeśli wartość indeksu  $k$  zmienia się, rozmieszczenie „przestrzeni” zawartych w 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.


<sup>23</sup> J. Irons, G.W. Petersen, *Texture transforms of remote sensing data*, „Remote Sensing Environment”, 11: 359–370, 1981.

<sup>24</sup> B.B. Mandelbrot, *The fractal geometry of nature...*

<sup>25</sup> R. Voss, *Random fractals: characterization and measurement*, „Scaling phenomena in disordered systems” 1–11, New York 1985.

Zaproponowanych zostało kilkanaście sposobów mierzenia lakunarności, lecz wspólna definicja bazuje na wzajemnym stosunku jasnych i ciemnych regionów zawartych w danym obrazie  $\lambda(r) = \text{variance} / (\text{mean})^2$ . Gdzie  $\lambda$  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 strukturę<sup>26</sup>.

Powyższe miary pozwalają na wychwycenie różnic w rozkładzie zagęszczeń punktów występujących między obrazami; innymi słowy wyrażają stopień złożoności obrazu, dlatego dobrze nadają się do porównywania rozmieszczenia komórek nerwowych w preparacie mikroskopowym<sup>27</sup> lub badanych obiektów w obrazach z tomografii komputerowej czy rezonansu magnetycznego<sup>28</sup>. W badaniach własnych posługiwaliśmy się programem komputerowym *ImageJ* udostępnionym przez National Institute of Health, USA.



Rys 1. Obraz z TK przedstawiający zdiagnozowane za pomocą lakunarności zmiany w mózgu. Źródło własne

## Podsumowanie

Projekt badawczy realizowany obecnie w Zakładzie Bionformatyki i Telemedycyny CM UJ dotyczy zagadnień związanych z medycznymi metodami diagnostycznymi, wśród których coraz mocniej uwidacznia się postulat jak najwcześniejszego rozpoznawania procesów chorobowych, a więc tyczy się on kwestii

<sup>26</sup> C. Allain, M. Cloitre, , *Characterizing the Lacunarity of Random and Deterministic Fractal Sets*, „Physics Review”, vol 44: 6, 1991.

<sup>27</sup> J. Skrzat, M. Usarz, J. Trąbka, G. Goncerz, *Differentiation of neurons populations based on fractal dimension*, „Folia Morphologica”, 55, 4: 444–446, 1996.

<sup>28</sup> C. Balestra, et al., *The fractal approach as a tool to understand asymptomatic brain hyperintense mri signals*, „Fractals”, 12, 1: 67–72, 2004.



wczesnego i wyraźnego wyznaczenia granicy pomiędzy normą a patologią, które następnie rzutuje na konkretne wskazania terapeutyczne. Problem ten nabiera istotnego znaczenia 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 główny nacisk 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 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).

## Lacunarity and other fractal measures in neuroimaging

### Abstract

This paper presents original results of fractal measures application to analyses of medical images. Shape and surface field measures of medical imaging data are presented. The main part of this work concerns the fractal measure and lacunarity. We analyzed several types of description of fractal dimension. The mathematical expressions for these methods are presented and used to explain their usefulness for analyses of medical images (especially neuroimaging).