

Fraktalna analiza chodu

Dariusz Mikołajewski ¹, Emilia Mikołajewska ²

¹ Instytut Informatyki, Uniwersytet Kazimierza Wielkiego w Bydgoszczy, ² Katedra Fizjoterapii, Wydział Nauk o Zdrowiu, Collegium Medium im. Ludwika Rydygiera w Bydgoszczy, Uniwersytet Mikołaj Kopernika w Toruniu

Streszczenie

Chód stanowi jedną z najbardziej złożonych i najczęściej wykonywanych czynności wykonywanych przez człowieka. Pomimo postępu technologicznego w przypadku diagnostyki i oceny funkcji chodu nie ma jednego, uniwersalnego narzędzia. Rozwiązania oparte na inteligencji obliczeniowej mogą uzupełniać tradycyjne metody klinicznej analizy chodu. W artykule przedstawiono rozwijaną przez autorów metodę fraktalnej analizy chodu.

Słowa kluczowe: modele obliczeniowe, kliniczna analiza chodu, jakość życia związana ze zdrowiem, HRQoL

Fractal analysis of gait

Abstract

Walking is one of the most complex and most frequently performed human activities. Despite technological progress, there is no single, universal tool for the diagnosis and evaluation of gait functions. Solutions based on computational intelligence can complement traditional methods of clinical analysis of gait. The article presents the method of fractal analysis of gait developed by the authors.

Keywords: computational models, clinical gait analysis, health-related quality of life, HRQoL

1. Wprowadzenie

Chód stanowi jedną z najbardziej złożonych czynności, wykonywanych przez człowieka, jest też jedną z najczęściej wykonywanych zajmując u przeciętnego człowieka ok. 10% czasu dnia [1]. Dobry diagnosta podczas obserwacji jest w stanie dostrzec patologiczne zmiany w chodzie pacjentów oraz wykorzystać je jako element wnioskowania klinicznego, jednak wymaga to wiedzy i doświadczenia, ponadto taki sposób oceny chodu jest trudny do przekazania innej osobie i standaryzacji. Z ww. względów istnieje zapotrzebowanie na obiektywne, obliczeniowe metody diagnostyki chodu. Wprowadzenie podejścia obliczeniowego w analizie chodu ułatwia fakt, że prawidłowa (fizjologiczna) lokomocja człowieka jest stereotypowa. Oznacza to, że istnieje globalny wzorzec chodu, a zakres odchyłeń od niego jest na tyle wąski, że można ustalić dopuszczalny zakres odchyłeń od niego dla całej populacji [2]. Ponadto na podstawie wartości odchyłeń od ww. globalnego wzorca chodu u konkretnego pacjenta można wnioskować o zdrowiu lub patologicznych zmianach wzorca chodu spowodowanych schorzeniem lub urazem.

W przypadku diagnostyki i oceny funkcji chodu nie ma jednego, uniwersalnego narzędzia. Stosuje się tanie, proste w użyciu, mało czasochłonne, dokładne, wiarygodne, powtarzalne oraz niezależne od pacjenta i terapeuty miar chodu, które są możliwe do wykorzystania w codziennej praktyce klinicznej. Stare rozwiązania w miarę

możliwości są udoskonalane, jednak dynamicznie rozwija się obszar rozwiązań technicznych wspomagających diagnostykę funkcji chodu. Pomimo postępu w tym obszarze:

- brak jest metod uniwersalnych,
- metody proste i szybkie nie są dokładne,
- metody dokładne i powtarzalne są czasochłonne, kosztowne i wymagają skomplikowanych procedur oraz wyposażenie techniczne [1, 3].

Rozwiązania oparte na inteligencji obliczeniowej (ang. computational intelligence, CI) mogą uzupełniać lub nawet zastępować tradycyjne metody klinicznej analizy chodu, szczególnie gdy dane pomiarowe:

- trzeba wyodrębnić z normalnej aktywności pacjenta,
- są niekompletne,
- są obciążone błędami,
- nie umożliwiają budowy modelu matematycznego i trzeba je analizować w inny sposób,
- trzeba pozyskać szybko z dużej próby pacjentów,
- trzeba pozyskać tanio.

Jednak jak pokazano w [1] minimalny zestaw parametrów odzwierciedlających z wystarczającą dokładnością kliniczną zmianę u pacjentów po udarze obejmuje:

- wymiar fraktalny – miarę nierównomierności chodu,

- parametr rozmyty – zagregowaną (całościową) ocenę funkcji chodu [1, 4].

Celem dalszym naszych badań jest rozbudowa rodziny parametrów fraktalnych chodu w kierunku samodzielnego narzędzia badawczego.

Celem niniejszej pracy jest przeanalizowanie sposobu wyliczania fraktalnych miar chodu oraz ich użyteczności w codziennej praktyce klinicznej.

2. Metodologia

Twórca geometrii fraktalnej Benoi B. Mandelbrot analizował cykliczne zmiany poziomu wody Nilu wykazujące potęgową zależność skalowania dla kilku rzędów powiększenia [5]. Pozwala to na analizę szeregów czasowych (w tym aperiodycznych w krótkiej skali czasowej, o dużym odchyleniu standardowym) przy użyciu wykładników skalujących:

- fraktalnych – przy jednym czynniku skalującym,
- multifraktalnych – przy wielu czynnikach skalujących [6-11].

W przypadku chodu długie szeregi czasowe (odzwierciedlające rytm kolejnych kroków, również z podziałem na stronę lewą i prawą) odzwierciedlają stan układu ruchu badanego pacjenta. Oprócz możliwości obiektywnego opisu funkcji chodu pozwala to na prognozowanie w obszarze zachowania się tej funkcji w przypadku zewnętrznych ingerencji np. technikami terapeutycznymi. Z praktycznego punktu widzenia analiza fraktalna chodu stosowana jest do określania nieregularności chodu (np. wskutek osłabienia jednej strony, męczliwości) poprzez odzwierciedlenie korelacji przestrzennych (długość kroku) lub czasowych (rytm cyklu kroku) dla zdefiniowanych skal na płaszczyźnie dwuwymiarowej (wymiar fraktalny przyjmuje wartość z zakresu 1-2). W szerszym zakresie może być stosowana do analizy nierównomierności rytmu przemieszczanie się poszczególnych punktów charakterystycznych kończyn dolnych: lewej i prawej (po kilka punktów na kończynę), w przestrzeni dwuwymiarowej lub trójwymiarowej (w tym jednocześnie położenia na płaszczyźnie oraz w czasie). Dobór układu współrzędnych – w tym położenie punktu (0,0) - zależy od przyjętej metody analizy. Może znajdować się np. w dolnym lewym rogu lub na środku analizowanej płaszczyzny.

W badaniu analizowane są szeregi czasowe, generowane z filmów powstałych podczas nagrywania 10 m testu chodu. Do generacji szeregów czasowych wykorzystywane jest oprogramowanie Open Source *Tracker Video Analysis and Modelling Tool* w wersji 5.1.5. pod

MS Windows¹. Wygenerowane szeregi czasowe są eksportowane do programu Matlab umożliwiającego analizę fraktalną i multifraktalną szeregów czasowych.

Badając daną strukturę fraktalną przy jej opisie posługiwaliśmy się wymiarem fraktalnym D (z ang. *Dimension*). Relację między czynnikiem skalującym, wymiarem przestrzennym rozpatrywanego obiektu, a liczbą otrzymanych elementów opisuje wzór:

$$a = \frac{1}{s^D} \quad (1)$$

$$D = \frac{\log a}{\log \frac{1}{s}} \quad (2)$$

gdzie:

a – liczba elementów otrzymanych w wyniku wykonania operacji skalowania obiektu,

D – wymiar samopodobieństwa (ang. *self-similarity dimension*),

s – czynnik skalujący.

Wymiar fraktalny pokazuje, jaki jest poziom złożoności struktury/sygnału. Dla chodu jest to liczba z zakresu 1-2, przy czym 1 oznacza przebieg idealnie gładki (wszystkie kroki o jednakowym czasie trwania), a 2 oznacza maksymalne zróżnicowanie czasu trwania kolejnych kroków.

Ponadto określano parametry dynamiki chaotycznej: wykładnik Hursta i jego zmienność w czasie, widmo multifraktalne oraz dystrybucję prawdopodobieństwa w celu oceny przewidywalności wartości tak opisanego systemu złożonego (tj. możliwości predykcji wyników samoleczenia oraz samoleczenia wspieranego terapią). Wykładnik Hursta H jest określony wzorem:

$$SD = a^H \quad (3)$$

gdzie:

SD – odchylenie standardowe,

a – długość szeregu czasowego.

Przyjmuje on wartości z przedziału (0, 1).

Interpretacja wartości H :

- H w zakresie 0-0,5 – szereg czasowy o dużej zmienności, o częstych zmianach kierunku trendów krótkoterminowych,
- $H=0,5$ – charakter losowy, jednakowe prawdopodobieństwo zmiany oraz utrzymania trendu,
- H w zakresie 0,5-1 – uporządkowany przebieg, o większym prawdopodobieństwie utrzymania obecnego trendu.

¹ <https://www.compadre.org/osp/items/detail.cfm?ID=7365> - data dostępu 20.04.2020 r.

3. Wyniki

Do badań wykorzystano zgromadzone w archiwum zapisy chodu osób zdrowych oraz po udarze (sposób doboru: *convenience sample*). Podjęta próba ustalenia normy dla osób zdrowych potwierdziła wyniki poprzednich badań (tabela 1) i pacjentów po udarze (tabela 2). Podjęta próba ustalenia normy dla osób zdrowych (dla $n=30$) potwierdziła wyniki poprzednich badań [1].

Tabela 1. Wyniki badań grupy osób zdrowych ($n=30$)

Wartość	Wymiar fraktalny [1]	Wymiar fraktalny (badanie obecne)	Wykładnik Hursta
Średnia	1,13	1,14	0,2
SD	0,04	0,05	0,04
Min	1,04	1,03	0,1
Q1	1,09	1,07	0,15
Mediana	1,12	1,11	0,2
Q3	1,15	1,14	0,25
Max	1,2	1,18	0,32

Do porównań z grupami pacjentów przyjęto gdzie przyjęto wartość maksymalną (1,2).

Tabela 2. Wyniki badań grupy pacjentów po udarze ($n=30$)

Wartość	Wymiar fraktalny [1]	Wymiar fraktalny (badanie obecne)	Wykładnik Hursta
Średnia	1,38	1,39	0,3
SD	0,32	0,31	0,06
Min	1,07	1,11	0,14
Q1	1,22	1,25	0,22
Mediana	1,35	1,37	0,29
Q3	1,42	1,43	0,35
Max	1,57	1,52	0,39

Zaobserwowano wyższe (tj. gorsze) wartości parametrów oraz większą zmienność parametrów fraktalnych chodu w grupie pacjentów po udarze. Wykładnik Hursta wskazuje, że są to szeregi czasowe o dużej zmienności, o częstych zmianach kierunku trendów krótkoterminowych, co dobrze wróży podatności na wpływ terapii (możliwe odwrócenie trendu).

4. Dyskusja

Ww. wyniki będą analizowane, a metoda będzie rozwijana w kolejnych pracach. W ramach rozwoju metody proponuje się opracować tabelę kierunków trendu i wartości wykładnika Hursta oraz badać zmienność współczynnika Hursta w miarę postępów terapii, np. metodą odtrendowanej średniej kroczącej.

Do rozpowszechnienia proponowanej metodyki badawczej, po potwierdzeniu jej czułości i powtarzalności planuje się, wykorzystanie aplikacji mobilnych. Już obecnie zwiększają one możliwości i bezpieczeństwo osób uprawiających sport (np. biegaczy, rowerzystów), a rozwiązania takie jak smartbandy, smartwatche czy czujniki oddechu łatwo zintegrować z aplikacjami telemedycznymi, również wyposażonymi w czujniki noszone (ang. *wearable sensors*), przetwarzającymi danych w czasie rzeczywistym. Ważnym elementem jest pełna cyfryzacja oraz celowe i planowane wykorzystanie danych już zgromadzonych. Stąd planowana integracja pomiarów z wykorzystaniem parametrów oraz klasyfikacji i predykcji za pomocą sztucznych sieci neuronowych.

4.1. Dotychczasowe badania nad analizą chodu z wykorzystaniem parametrów fraktalnych

Badania własne nad metodyką i narzędziami do stosunkowo prostej, szybkiej i taniej klinicznej analizy chodu z wykorzystaniem parametrów fraktalnych należą do pierwszych prób w tym obszarze. Ze względu na silną interdyscyplinarność badania te są prowadzone we współpracy Katedry Fizjoterapii CM UMK w Bydgoszczy z Instytutem Informatyki Uniwersytetu Kazimierza Wielkiego w Bydgoszczy. Wykorzystano przy tym dotychczasowe publikacje dotyczące wykorzystania parametrów fraktalnych do analizy zmian EEG pod wpływem różnych zachowań, w tym chodu [12] oraz elektromiografii powierzchniowej (ang. *surface electromyogram* - sEMG) [13]. Ripoli i wsp. zaproponował algorytm obliczający wartość liczby z zakresu 1-2 odzwierciedlającej geometrię sygnału będącego odpowiednikiem wzorca chodu człowieka po terenie płaskim, pod górę oraz po schodach [14].

4.2. Dotychczasowe badania nad analizą chodu z wykorzystaniem sztucznych sieci neuronowych

Klasyfikacja chodu na prawidłowy i patologiczny bezpośrednio w oparciu o przykłady chodu, a nie na podstawie zbudowanego wcześniej modelu chodu jest już realizowana przez sztuczne sieci neuronowe [15-20], z dokładnością od 75-80% [21] do niemal stuprocentowej, przy identyfikacji czynników ryzyka oraz błędów pomiarowych [22, 23]. ANN są w stanie dokonać zautomatyzowanej oceny jakościowej, a nie tylko ilościowej chodu dzięki porównaniu przestrzenno-czasowych wzorców chodu (postaci krzywych) oraz wyodrębnionego przez sieć poprawnego przebiegu cyklu chodu [24]. Dotyczy to zarówno analizy chodu w schorzeniach pacjentów podłożu neurologicznym (np. u pacjentów niedowładem

połowiczym po udarze) [25], jak i po złamaniach [26]. Kluczowe stają się badania nad ANN oceniającymi postępy w rehabilitacji funkcji chodu w terapii personalizowanej (ang. *patient-tailored therapy*) czy z użyciem robotów rehabilitacyjnych [27, 28]. Badania w tym zakresie prowadzono również w Polsce u pacjentów po udarze [1, 29-31] oraz w grupie pacjentów z chorobą Parkinsona [32].

Rzeczywisty potencjał klasyfikacji chodu za pomocą ANN pozostaje nie w pełni wykorzystany, szczególnie przy braku systemów ekspertowych dedykowanych analizie ruchu u sportowców [33]. Kolejne dziesięciolecie to przewidywany okres dominacji sieci sensorycznych i systemów wieloagentowych oraz Internetu Rzeczy i telemedycyny/telerehabilitacji w praktyce klinicznej. Pojawia się coraz więcej rozwiązań tego typu, dostarczających danych do analizy sztucznym sieciom neuronowym i innym rozwiązaniom z obszaru inteligencji obliczeniowej [34, 35]. Sztuczne sieci neuronowe mogą być wspomagane metodą wektorów nośnych (ang. *support vector machine* - SVM) [36-38], wykorzystuje się również głębokie sieci neuronowe dokonujące złożonej dekompozycji cech oraz odnajdowanie ukrytych współzależności.

5. Wnioski

Wyłaniające się możliwości fraktalnej analizy chodu w połączeniu z istniejącymi już elektronicznymi kartotekami pacjentów z nagraniami chodu mogą przyczynić się do zwiększenia wiedzy oraz poprawienia efektywności diagnostyki, terapii i opieki w grupie pacjentów, jak również monitorowania osób zdrowych, w tym rozwoju dzieci i treningu sportowego [39]. Dzięki rozwojowi IoT może to przełożyć się na efektywne działania profilaktyczne, również podczas normalnej aktywności, tj. bliżej analizy chodu w środowisku naturalnym pacjentów, a nie w warunkach laboratoryjnych [39, 40].

Literatura

- Mikołajewska E. Nowe markery chodu w klinicznej analizie chodu w grupie pacjentów po udarze mózgu usprawnianych metodą NDT-Bobath. Wydawnictwo CM UMK, Bydgoszcz 2017.
- Zembaty A. Kinezyterapia. Kasper, Kraków 2003.
- Mikołajewska E. Obiektywizacja wyników rehabilitacji – próba ujęcia kompleksowego. Nowiny Lekarskie, 2011; 80(4):305-311.
- Prokopowicz P., Mikołajewski D., Tyburek K., Mikołajewska E. Computational gait analysis for post-stroke rehabilitation purposes using fuzzy numbers, fractal dimension and neural networks. Bull. Pol. Acad. Sci. Tech. Sci. 2020; 68(2):191-198.
- Mandelbrot B. B. The fractal geometry of nature. W.H. Freeman, San Francisco 1982.
- Ivanov P. C., Amaral L. A. N., Goldberger A. L., Havlin S., Rosenblum M. G., Struzik Z., Stanley, H. Multifractality in human heart dynamics. Nature 1999; 399:461-465.
- Zheng Y., Geo J. B., Sanchez J. C., Principe J. C., Okun M. S. Multiplicative multifractal modelling and discrimination of human neuronal activity. Phys. Lett. A 2005; 344:253-264.
- Jose G. Halos and Voids in a Multifractal Model of Cosmic Structure, Astrophysical Journal 2007; 658:11-24.
- Peng C. K., Mietus J. E., Liu Y., Lee C., Hausdorff J. M., Stanley H. E., Goldberger A. L., Lipstiz, I. A.. Quantifying fractal dynamics of human respiration: age and gender effects. Ann. Biomed. Eng. 2002; 30: 683-692.
- Kudinov A. N., Tsvetkov V. P., Tsvetkov I. V., Catastrophes in the multi-fractal dynamics of social-economic systems. Russian Journal of Mathematical Physics 2011; 18(2):149-155.
- Kantelhardt J. W. Fractal and multifractal time series. In: Meyers RA, editor. Mathematics of complexity and dynamical systems. New York, NY: Springer; 2012. p.463-87.
- Pradhan N., Dutt D. N. Use of running fractal dimension for the analysis of changing patterns in electroencephalograms. Comput Biol Med. 1993; 23(5):381-8.
- Arjunan S. P., Kumar D. K. Fractal based modelling and analysis of electromyography (EMG) to identify subtle actions. Conf Proc IEEE Eng Med Biol Soc. 2007; 2007:1961-4.
- Ripoli A., Belardinelli A., Palagi G., Franchi D., Bedini R. An effective algorithm for quick fractal analysis of movement biosignals. J Med Eng Technol. 1999; 23(6):216-21.
- Holzreiter S. H., Köhle M. E. Assessment of gait patterns using neural networks. J Biomech. 1993; 26(6):645-51.
- Gioftsos G., Grieve D. W. The use of neural networks to recognize patterns of human movement: gait patterns. Clin Biomech. 1995; 10(4):179-183.
- Lapham A. C., Bartlett R. M. The use of artificial intelligence in the analysis of sports performance: a review of applications in human gait analysis and future directions for sports biomechanics. J Sports Sci. 1995; 13(3):229-37.
- Clayton H. M. Instrumentation and techniques in locomotion and lameness. Vet Clin North Am Equine Pract. 1996; 12(2):337-50.
- Kajijima M., Foutz T. L., McClendon R. W., Budsberg S. C. Diagnosis of lameness in dogs by use of artificial neural networks and ground reaction forces obtained during gait analysis. Am J Vet Res. 2012; 73(7):973-8.
- Leon M. A. Distributed neural networks for biomedical research. Biomed Sci Instrum. 1997; 34:201-5.
- Lafuente R., Belda J. M., Sánchez-Lacuesta J., Soler C., Prat J. Design and test of neural networks and statistical classifiers in computer-aided movement analysis: a case study on gait analysis. Clin Biomech. 1998; 13(3):216-229.
- Azulay J. P., Vacherot F., Vaugoyeau M. Gait disorders: mechanisms and classification. Rev Neurol. 2010; 166(2):142-8.
- Begg R., Kamruzzaman J. Neural networks for detection and classification of walking pattern

- changes due to ageing. *Australas Phys Eng Sci Med.* 2006; 29(2):188-95.
24. Barton G., Lisboa P., Lees A., Attfield S. Gait quality assessment using self-organising artificial neural networks. *Gait Posture.* 2007; 25(3):374-9.
 25. Scheffer C., Cloete T. Inertial motion capture in conjunction with an artificial neural network can differentiate the gait patterns of hemiparetic stroke patients compared with able-bodied counterparts. *Comput Methods Biomech Biomed Engin.* 2012; 15(3):285-94.
 26. Lozano-Ortiz C. A., Muniz A. M., Nadal J. Human gait classification after lower limb fracture using Artificial Neural Networks and principal component analysis. *Conf Proc IEEE Eng Med Biol Soc.* 2010; 2010:1413-6.
 27. Luu T. P., Low K. H., Qu X., Lim H. B., Hoon K. H. An individual-specific gait pattern prediction model based on generalized regression neural networks. *Gait Posture.* 2014; 39(1):443-8.
 28. Oh S. E., Choi A., Mun J. H. Prediction of ground reaction forces during gait based on kinematics and a neural network model. *J Biomech.* 2013;46(14):2372-80.
 29. Kaczmarczyk K. Próba klasyfikacji chodu u osób po udarze mózgu. W: *Zastosowania metod statystycznych w badaniach naukowych IV.* Statsoft Polska. Kraków 2012, s. 333-42.
 30. Kaczmarczyk K., Wit A., Krawczyk M., Zaborski J. Gait classification in post-stroke patients using artificial neural networks. *Gait Posture.* 2009; 30(2):207-210.
 31. Kaczmarczyk K., Wit A., Krawczyk M., Zaborski J. Artificial Neural Networks (ANN) Applied for Gait Classification and Physiotherapy Monitoring in Post Stroke Patients. [W:] Suzuki K. *Artificial Neural Networks : Methodological Advances and Biomedical Applications*, InTech, Rijeka 2011, ss. 303-328.
 32. Kostek B., Kupryjanow A. Wykorzystanie sieci neuronowych i metody wektorów nośnych SVM w procesie rozpoznawania aktywności ruchowej pacjentów dotkniętych chorobą Parkinsona. [W:] Tadeusiewicz R., Korbicz J., Rutkowski L., Duch W. (red.) *Sieci neuronowe w inżynierii biomedycznej.* Tom 9. monografii: Torbacz W., Maniewski R., Wójcicki J. M., Liebert A. (red.) *Inżynieria biomedyczna – podstawy i zastosowania.* Akademicka Oficyna Wydawnicza EXIT, Warszawa 2013, ss. 239-262.
 33. Bartlett R. Artificial intelligence in sports biomechanics: new dawn or false hope? *J Sports Sci Med.* 2006;5(4):474-9.
 34. Jacobs D. A., Ferris D. P. Estimation of ground reaction forces and ankle moment with multiple, low-cost sensors. *J Neuroeng Rehabil.* 2015;12:90.
 35. Lau H. Y., Tong K. Y., Zhu H. Support vector machine for classification of walking conditions of persons after stroke with dropped foot. *Hum Mov Sci.* 2009;28(4):504-14.
 36. Lau H. Y., Tong K. Y., Zhu H. Support vector machine for classification of walking conditions using miniature kinematic sensors. *Med Biol Eng Comput.* 2008;46(6):563-73.
 37. Muniz A. M., Nadal J. Application of principal component analysis in vertical ground reaction force to discriminate normal and abnormal gait. *Gait Posture.* 2009; 29(1):31-5.
 38. Muniz A. M., Liu W., Liu H., Lyons K. E., Pahwa R., Nobre F. F., Nadal J. Assessment of the effects of subthalamic stimulation in Parkinson disease patients by artificial neural network. *Conf Proc IEEE Eng Med Biol Soc.* 2009;2009:5673-6.
 39. Ferber R., Osis S. T., Hicks J. L., Delp S. L. Gait biomechanics in the era of data science. *J Biomech.* 2016; 49(16): 3759-3761.
 40. Syczewska M., Wąsiewicz P. Contemporary techniques to manage of databases in gait analysis. *Elektronika Polish Journal.* 2009; 8:294-296.