

DOBÓR FUNKCJI BAZOWYCH DO APROKSYMACJI SYGNAŁU ELEKTROKORTYGRAFICZNEGO W DETEKCJI OBSZARU PADACZKORODNEGO

SELECTION OF BASE FUNCTIONS FOR ELECTROGRAPHIC SIGNAL APPROXIMATION IN THE DETECTION OF EPILEPTIC ZONE

Marcin Kołodziej^{1*}, Andrzej Majkowski¹, Remigiusz J. Rak¹, Andrzej Rysz²

¹ Politechnika Warszawska, Wydział Elektryczny, Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, 00-662 Warszawa, ul. Koszykowa 75

² Warszawski Uniwersytet Medyczny, Katedra i Klinika Neurochirurgii, 02-097 Warszawa, ul. Banacha 1A

* e-mail: marcin.kolodziej@ee.pw.edu.pl

STRESZCZENIE

Celem badań opisanych jest dobór funkcji bazowych, które pozwolą na dokładne opisanie sygnałów elektrokortykograficznych (ECoG) z zachowaniem ich właściwości diagnostycznych. Sygnały ECoG są powszechnie wykorzystywane do wskazania miejsca obszaru padaczkorodnego mózgu. Do doboru najlepszej rodziny falek w charakterze funkcji bazowych zastosowano algorytm MP (ang. *Matching Pursuit*). Przedstawiono przykład, w jaki sposób z wykorzystaniem analizy falkowej można wykryć zapisy patologiczne w sygnale ECoG.

Słowa kluczowe: elektrokortykografia, ECoG, padaczka, analiza falkowa, algorytm Matching Pursuit

ABSTRACT


The purpose of this research is a selection of base functions, which allow to accurately describe the electrocortical signals (ECoG), while maintaining their diagnostic properties. ECoG signals are commonly used to indicate the epileptogenic zone in the brain. The Matching Pursuit algorithm was used to select the best wavelet family as a base function. An example of using wavelet analysis to detect pathological records in ECoG signal, is demonstrated.

Keywords: electrocorticography, ECoG, epilepsy, wavelet analysis, Matching Pursuit algorithm

1. Wstęp

Padaczka jest jedną z najczęściej występujących chorób ośrodkowego układu nerwowego. W Europie choruje na nią około 1% populacji [1]. Padaczka powoduje stygmatyzację pacjentów i jest przyczyną wielu ograniczeń normalnego funkcjonowania człowieka (zakaz prowadzenia pojazdów, negatywny

stosunek osób postronnych). U części pacjentów (około 30% przypadków), leczenie farmakologiczne działa słabo, albo w ogóle. Jednak w przypadku lekooporności można pomóc pacjentom poprzez operacyjne usunięcie (resekcja) obszaru padaczkorodnego (ang. *epileptogenic zone*, EZ). Przed leczeniem operacyjnym konieczna jest jednak właściwa (bezbłędna) diagnoza – lokalizacja obszaru padaczkorodnego. W diagnostyce śródoperacyjnej wykorzystuje się rejestrację sygnału elektrokortykograficznego (ECoG), z powierzchni mózgu, z użyciem elektrod podtwardówkowych uformowanych w postaci 20-elektrodowej płytki (p. rys. 1). Następnie, na podstawie wzrokowej analizy sygnału, jest podejmowana ostateczna decyzja, co do obszaru resekcji. Zazwyczaj dokonuje tego lekarz posiadający specjalizację neurofizjologa klinicznego, poprzez wykrycie zmian patologicznych w zapisie ECoG. Trudność polega na tym, że w sygnale ECoG, oprócz fal „ostrzych”, związanych bezpośrednio z obszarem padaczkorodnym, występują fale, pochodzące od normalnych czynności fizjologicznych, które można pomylić z wyładowaniami patologicznymi. Dlatego też, istnieje wyraźne zapotrzebowanie na dodatkowe, automatyczne narzędzie wspomagające wykrywanie obszaru kory mózgu, w którym występują zmiany patologiczne.



Rys. 1. Płytką z 20 elektrodami podtwardówkowymi do rejestracji sygnału ECoG na powierzchni kory mózgowej

Warto podkreślić, że komputerowe badania wyładowań w mózgu, związanych z padaczką, rozpoczęto już w 1970 r. i stanowią one przedmiot intensywnych prac do dnia dzisiejszego [2]. Bardzo często, z przyczyn praktycznych, w rozważaniach dotyczących wyładowań patologicznych nawiązuje się do sygnałów EEG, które mają charakter podobny do sygnałów ECoG. Jednak pomimo wielu podobieństw, sygnały ECoG mają większe amplitudy oraz swoistą morfologię, co powoduje, że są one bardziej przydatne w praktyce. Z drugiej strony, cechują się specyficznymi artefaktami, które zakłócają proces ich analizy [3]. Warto zaznaczyć, że w zagadnieniach przetwarzania i analizy sygnałów EEG i ECoG stosuje się te same narzędzia. Analiza ta, w kontekście padaczki, obejmuje najczęściej trzy odrębne zagadnienia: predykcję napadów padaczkowych, detekcję chwili rozpoczęcia napadu oraz identyfikację kanałów (elektrod), w obrębie których powstają wyładowania [4, 5]. Zaproponowano wiele algorytmów wykrywania wyładowań związanych z padaczką, bazujących na analizie częstotliwościowej, czasowo-częstotliwościowej i falkowej, sztucznych sieciach neuronowych, klasyfikatorach SVM (ang. *support vector machine*, maszyna wektorów nośnych) oraz narzędziach data-mining (eksploracja danych) [6, 7, 8, 9, 10, 11]. Konwencjonalna czasowa i częstotliwościowa analiza sygnału została wykorzystana w pracach [12, 13, 14]. W wielu pracach skupiono uwagę na opisie ilościowym oraz dynamice sygnałów [15, 16]. Stosowano wiele miar, takich jak: korelacja wzajemna, wykładniki Lapunova, entropia Kołmogorowa [17, 18, 19, 20].

Celem przedstawionych w artykule eksperymentów jest dobór rodziny funkcji bazowych do opisu sygnału ECoG, w celu dalszego ich wykorzystania w diagnostyce wyładowań patologicznych. Spośród wielu metod analizy, w opisywanym podejściu autorzy skupili swoją uwagę tylko na analizie falkowej

[21]. Aby znaleźć jak najlepszy zbiór funkcji falkowych, wykorzystano algorytm MP (ang. *Matching Pursuit*) [22, 23]. Dobór najlepszej falki jest kluczowy w dalszych procesach analizy i klasyfikacji sygnału. Zgodnie z ideą analizy falkowej poszukuje się takiej falki, która pozwala na najlepsze „dopasowanie” i „najprostszy” opis sygnału. Reasumując, dobór falki ma kluczowe znaczenie dla wychwycenia i zapisania, w jak najmniejszej liczbie współczynników, istotnej informacji o sygnale (w tym przypadku informacji diagnostycznej). Eksperymenty przeprowadzono dla 51 przypadków rejestracji sygnału ECoG.

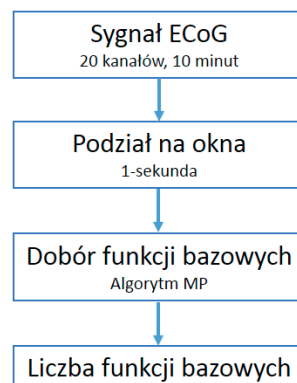
2. Materiał badawczy

Sygnały ECoG zarejestrowano w Katedrze i Klinice Neurochirurgii Warszawskiego Uniwersytetu Medycznego. Dane, pochodzące od 51 pacjentów, zarejestrowano w trakcie diagnostyki śródoperacyjnej, tuż przed resekcją obszaru padaczkorodnego mózgu. Czas rejestracji sygnałów ECoG wynosił 10–15 minut. Rejestracji dokonano z wykorzystaniem wspomnianej płytki elektrod ECoG (p. rys. 1) umieszczonej na korze mózgowej. Do akwizycji sygnału ECoG wykorzystano wzmacniacz firmy Elmiko. Częstotliwość próbkowania sygnału wynosiła 250 Hz. Wszystkie osoby badane, wyraziły zgodę na wykorzystanie zarejestrowanych sygnałów do celów naukowych. Przydatność zarejestrowanych danych do celów diagnostycznych została potwierdzona przez neurofizjologa klinicznego z WUM.

3. Metoda badawcza

Algorytm MP został zaproponowany przez Mallata w 1993 r. i cieszy się coraz większą popularnością [24, 25, 26, 27, 28]. Idea rozkładu polega na przeszukiwaniu słownika, w którym znajdują się funkcje bazowe. Algorytm przeszukuje słownik i dobiera najlepiej pasującą funkcję do analizowanego sygnału. Następnie obliczana jest różnica pomiędzy fragmentem sygnału a najlepiej dopasowaną funkcją bazową. Jest to tzw. sygnał resztkowy (residuum). W dalszym etapie, residuum staje się analizowanym sygnałem i to dla tego sygnału przeszukiwany jest słownik funkcji bazowych. Iteracyjne powtarzanie procesu poszukiwania funkcji bazowych kończy się dla ustalonej wartości niedopasowania. Istotnym elementem, z punktu widzenia algorytmu MP, jest tworzenie słownika – pierwotny dobór zestawu funkcji bazowych. Większa liczba i duża różnorodność funkcji bazowych pozwala na łatwiejszy wybór bardziej dopasowanych funkcji i opisanie analizowanego sygnału z wykorzystaniem mniejszej ich liczby.

W analizie falkowej posługujemy się zwykle rodzinami falek, zawężając zbiór funkcji bazowych do pewnych specyficznych kształtów. Aby dobrać najlepszą funkcję falkową do sygnału ECoG, autorzy zastosowali algorytm przedstawiony na rysunku 2.



Rys. 2. Algorytm doboru funkcji bazowych do aproksymacji sygnału ECoG

Pierwszym elementem algorytmu jest wczytanie, dla każdego pacjenta, sygnału ECoG zawierającego dane z 20 elektrod z pierwszych 10 minut rejestracji. W celu eliminacji zakłóceń sieci elektroenergetycznej, sygnał ECoG przefiltrowano z wykorzystaniem filtra pasmowo-zaporowego Butterwortha, w pasmie 48–52 Hz. Następnie sygnał z każdej elektrody poddano procesowi okienko-

wania, z użyciem okien jednosekundowych bez nakładania. Po czym, dla każdego okna zastosowano algorytm MP, dopasowujący funkcje bazowe. Kryterium dopasowania stanowiła norma L2 na poziomie 5% błędu [29]. Dla każdego analizowanego okna zapisywano liczbę funkcji bazowych wykorzystanych do poprawnej aproksymacji analizowanego sygnału.

W trakcie eksperymentów przebadano falki: haar, db1, db2, db3, db4, db5, db6, db7, db8, db9, db10, sym2, sym3, sym4, sym5, sym6, sym7, sym8, sym9, sym10, coif1, coif2, coif3, coif4, coif5, bior1.1, bior1.3, bior1.5, bior2.2, bior2.4, bior2.8, bior3.1, bior3.3, bior3.5, bior3.7, bior3.9, bior4.4, bior5.5, bior6.8, dmey. W celach porównawczych, wykorzystano również funkcje bazowe dyskretnej transformacji cosinusowej (DCT) oraz sinusowej [30, 31].

4. Wyniki

W tabeli 1 zaprezentowano wartości średnie, odchylenia standardowe oraz wartości minimalne liczby funkcji bazowych liczonych dla każdego okna czasowego, wszystkich kanałów i wszystkich pacjentów, dla każdej rodziny falek.

Tabela 1. Wartości średnie, odchylenia standardowe i minimalna liczba funkcji bazowych potrzebnych do aproksymacji sygnału ECoG

Słownik	Wartość średnia	Odchylenie standardowe	Wartość minimalna	Słownik	Wartość średnia	Odchylenie standardowe	Wartość minimalna
haar	86,1	37,3	25	coif3	72,0	41,4	20
db1	86,1	37,3	25	coif4	71,4	41,1	21
db2	77,7	40,7	23	coif5	71,4	41,1	21
db3	74,7	41,0	22	bior1.1	86,1	37,3	25
db4	72,1	41,0	20	bior1.3	88,4	37,2	26
db5	71,8	40,9	20	bior1.5	90,4	38,3	27
db6	72,7	40,8	22	bior2.2	81,0	49,3	21
db7	72,2	41,0	21	bior2.4	78,1	46,0	20
db8	71,5	40,8	21	bior2.8	78,0	46,2	20
db9	71,8	41,0	21	bior3.1	102,0	74,5	21
db10	71,7	40,9	21	bior3.3	90,0	62,0	20
sym2	77,7	40,7	23	bior3.5	85,8	57,4	20
sym3	74,7	41,0	22	bior3.7	84,6	56,4	19
sym4	72,5	41,0	21	bior3.9	84,1	56,0	19
sym5	70,8	41,1	20	bior4.4	74,5	44,3	20
sym6	71,6	41,2	21	bior5.5	75,0	44,5	21
sym7	70,7	40,9	20	bior6.8	71,9	42,1	20
sym8	71,1	41,2	20	dmey	70,0	41,0	20
sym9	70,0	41,1	20	DCT	55,8	23,4	20
sym10	70,8	41,1	20	sin	250,0	0	250

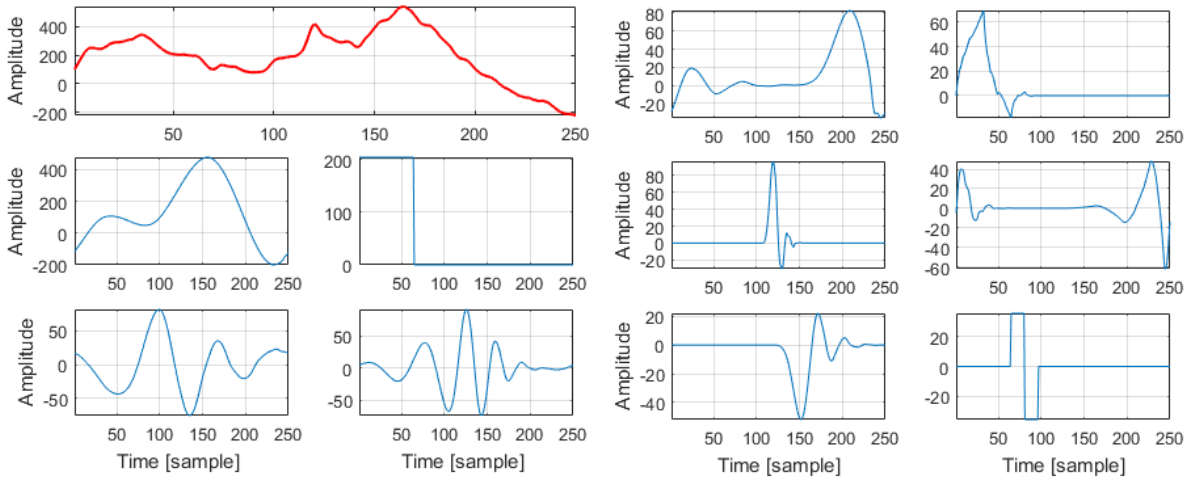
Przeprowadzono również eksperymenty z wykorzystaniem do aproksymacji sygnału ECoG słowników zbudowanych ze zbiorów falek: db1–db9, sym2–sym10, coif3–coif5, bior1.3–bior6.8, dmey, DCT i sin. Wynik przykładowej aproksymacji sygnału ECoG, z dopuszczalnym błędem na poziomie 5% dla normy L2, do którego wybranych zostało 10 funkcji bazowych (z rodziny db1–db9), zaprezentowano na rysunku 3. Liczba funkcji bazowych w słownikach oraz średnia liczba funkcji bazowych konieczna do aproksymacji sygnału ECoG z błędem 5% zamieszczona została w tabeli 2.

Tabela 2. Rozmiar słowników oraz średnia liczba funkcji bazowych konieczna do aproksymacji sygnału ECoG

Rodzina	db1–db9	sym2–sym10	coif3–coif5	bior1.3–bior6.8	dmey	dct
Rozmiar słownika	25200	22680	12600	35280	2520	250
Liczba wybranych funkcji	50	54	58	58	70	56

Najmniejszą liczbę (50) funkcji bazowych otrzymano dla rodziny db. Wynik wskazuje, że powiększenie rozmiaru słownika, pozwala na ograniczenie liczby funkcji bazowych niezbędnych do aproksy-


macji. Jednocześnie, istotny wpływ na liczbę funkcji bazowych niezbędnych do aproksymacji ma typ funkcji (kształt).



Rys. 3. Rozkład 1-sekundowego okna sygnału ECoG (kolor czerwony) na funkcje bazowe db1-db9 (kolor niebieski)

5. Dyskusja

W trakcie dekompozycji sygnału metodą MP założono, że liczba funkcji bazowych potrzebna do prawidłowej aproksymacji sygnału badanego jest wartością zmienną. Na rysunku 4 zaprezentowano sygnały ECoG oraz ich aproksymacje. Widać bardzo nieznaczne różnice dla sygnałów oryginalnych i sygnałów aproksymowanych z wykorzystaniem funkcji bazowych. Wizualna ocena pozwala na stwierdzenie, że nie utracono żadnej istotnej informacji z punktu widzenia diagnostycznego.

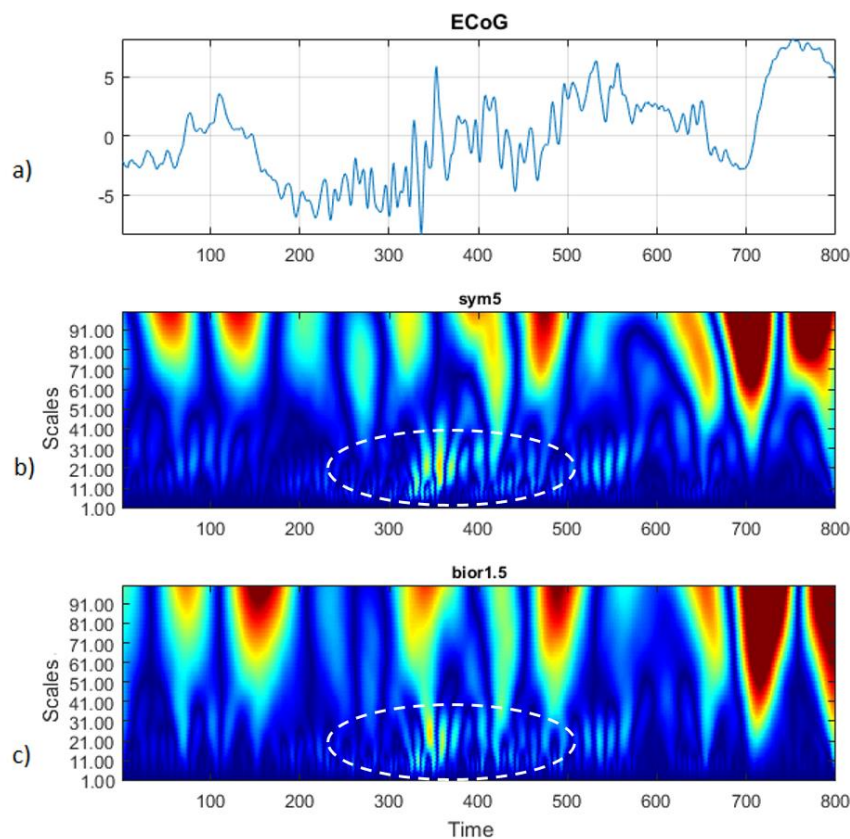


Rys. 4. Jednosekundowy fragment sygnału ECoG (5 elektrod),
kolor niebieski – sygnały aproksymowane, kolor czerwony – sygnały oryginalne

Tabela 1 wskazuje na dużą rozpiętość wyników dla poszczególnych rejestracji ECoG. Jest to zapewne spowodowane specyficznymi artefaktami występującymi w trakcie rejestracji, jak również samą morfologią zapisu ECoG. To wskazuje, że bardzo trudno będzie znaleźć funkcję falkową (słownik), która da optymalne wyniki w konkretnym przypadku rejestracji ECoG. Jednak przebadanie sygnałów z 51 rejestracji u różnych pacjentów wskazuje, że najlepiej spisują się falki z rodziny: sym5, sym9, sym10, dmey. Dobre wyniki, w sensie ograniczenia liczby współczynników niezbędnych do opisu sygnału, otrzymano również dla dyskretnej transformacji kosinusowej (DCT). Natomiast transformacja

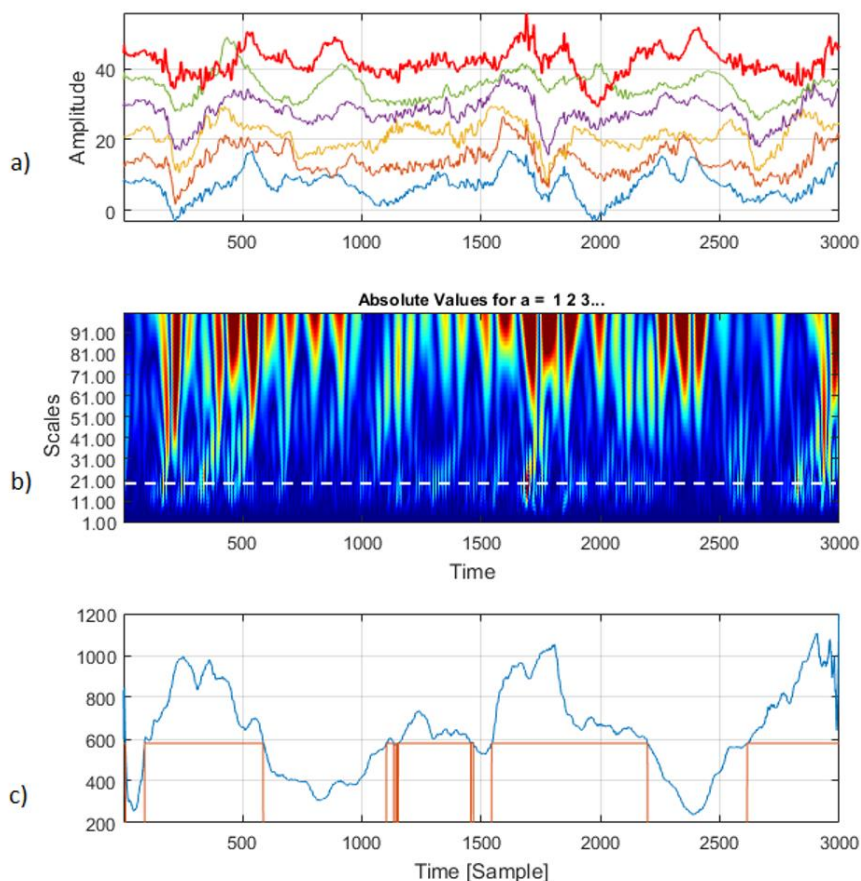
sinusowa nie pozwoliła na skuteczne ograniczenie liczby funkcji bazowych.

W założeniu autorów, opracowany algorytm umożliwi znaczne ograniczenie liczby współczynników użytych do opisu diagnostycznego wyładowań patologicznych. Aby potwierdzić to założenie, przeprowadzono dodatkowe badania sygnału ECoG z wykorzystaniem ciągłej transformacji falkowej – CWT (ang. *continuous wavelet transform*) [32]. Wyładowania związane z padaczką cechują się bardzo dużą zmiennością. Morfologia takich wyładowań jest bardzo różna, zarówno u każdego pacjenta jak i dla każdego zapisu. Autorzy skupili swoją uwagę na pewnym typie wyładowań patologicznych, tzw. wieloiglicach. Na rysunku 5 zamieszczono fragment sygnału ECoG zawierający wyładowania patologiczne (220–450 próbek sygnału) oraz wyniki analizy CWT dla dwu rodzajów falek sym5 oraz bior1.5. Wyładowania patologiczne charakteryzują się występowaniem wyższych częstotliwości. W wynikach analizy CWT zaobserwować można pojawienie się charakterystycznych wzorców dla niskiej skali (wysokiej częstotliwości). Dla falki sym5 energia rozkłada się na mniejszą liczbę współczynników niż dla falki bior1.5.



Rys. 5. a) Fragment sygnału ECoG oraz wyniki analizy CWT dla dwóch wybranych falek b) sym5 i c) bior1.5

Zaproponowano prosty sposób detekcji miejsc wystąpienia wieloiglic (p. rys. 6a). Pierwszym elementem proponowanego algorytmu jest analiza CWT z wykorzystaniem falki sym5 (p. rys. 6b). Następnie, sumowane są wartości bezwzględne uzyskanych współczynników dla niskich skal od 1 do 20, oddzielnie dla każdej chwili czasu. Zsumowane wartości współczynników są poddawane procesowi progowania. Odpowiedni dobór progu pozwala na detekcję wyładowań patologicznych (wieloiglic) związanych z padaczką. Wyniki analizy przykładowego zapisu 12 sekund sygnału ECoG zaprezentowano na rysunku 6c. Skupiono się na jednej wybranej elektrodzie (kolor czerwony). Próg detekcji sygnału ustalono arbitralnie na wartość 600. Pełny algorytm, zastosowany dla wszystkich kanałów, wraz z odpowiednim doбором progu detekcji, pozwoli w przyszłości na skuteczne wykrycie wyładowań patologicznych.



Rys. 6. a) Fragment sygnału ECoG zawierający wyładowania patologiczne, b) wynik analizy CWT, c) efekt detekcji wieloglic z wykorzystaniem falki sym5 i energii dla skal od 1 do 20 z progowaniem na poziomie 600

6. Podsumowanie

Analiza z wykorzystaniem algorytmu *Matching Pursuit* pozwoliła na wskazanie rodziny funkcji falkowych, użytecznych w analizie sygnału ECoG. Najmniejszą liczbę funkcji potrzebnych do aproksymacji sygnału ECoG otrzymano dla falek sym5, sym7, db5 i db8. Przeprowadzone eksperymenty dają nadzieję, że dokonując analizy sygnału ECoG z wykorzystaniem tych rodzin falek, można będzie poprawnie wykrywać patologiczne zapisy związane z padaczką.

Praca finansowana ze środków na działalność statutową Wydziału Elektrycznego Politechniki Warszawskiej, w ramach grantu dziekańskiego.

LITERATURA

- [1] J.A. Messenheimer: *Epilepsy: Frequency, causes and consequences*, Journal of Epilepsy, vol. 4(4), 1991, s. 246.
- [2] M. Bozek-Juzmicki, D. Colella, G.M. Jacyna: *Feature-based epileptic seizure detection and prediction from ECoG recordings*, Proceedings of IEEE International Symposium on Time-Frequency and Time-Scale Analysis, 1994, s. 564–567.
- [3] N.J. Hill, D. Gupta, P. Brunner, A. Gunduz, M.A. Adamo, A. Ritacco, G. Schalk: *Recording human electrocorticographic (ECoG) signals for neuroscientific research and real-time functional cortical mapping*, Journal of Visualized Experiments, no. 64, 2012.
- [4] J. Gotman: *Automatic detection of seizures and spikes*, Journal of Clinical Neurophysiology, vol. 16, 1999, s. 130–140.
- [5] N.S. McGrogan, L. Tarassenko: *Neural Network Detection of Epileptic Seizures in the Electroencephalogram*, 1999.
- [6] R. Harner: *Automatic EEG Spike Detection*, Clinical EEG and Neuroscience, vol. 40(4), 2009, s. 262–270.
- [7] M. Dümpelmann, C.E. Elger: *Automatic detection of epileptiform spikes in the electrocorticogram: a comparison of two algorithms*, Seizure, vol. 7(2), 1998, s. 145–152.

- [8] S.B. Wilson, C.A. Turner, R.G. Emerson, M.L. Scheuer: *Spike detection II: automatic, perception-based detection and clustering*, Clinical Neurophysiology, vol. 110(3), 1999, s. 404–411.
- [9] W.R. Webber, B. Litt, K. Wilson, R.P. Lesser: *Practical Detection of Epileptiform Discharges (EDs) in the EEG Using an Artificial Neural Network: A Comparison of Raw and Parameterized EEG Data*, Electroencephalography and Clinical Neurophysiology vol. 91(3), 1994, s. 194–204.
- [10] J. Fan, C. Shao, Y. Ouyang, J. Wang, S. Li, Z. Wang: *Automatic Seizure Detection Based on Support Vector Machines with Genetic Algorithms*, Simulated Evolution and Learning, 2006, s. 845–852.
- [11] T.P. Exarchos, A.T. Tzallas, D.I. Fotiadis, S. Konitsiotis, S. Giannopoulos: *EEG Transient Event Detection and Classification Using Association Rules*, IEEE Transactions on Information Technology in Biomedicine, vol. 10(3), 2006 s. 451–457.
- [12] V. Srinivasan, C. Eswaran, N. Sriraam: *Artificial Neural Network Based Epileptic Detection Using Time-Domain and Frequency-Domain Features*, Journal of Medical Systems, vol. 29(6), 2005, s. 647–660.
- [13] K. Polat, S. Güneş: *Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform*, Applied Mathematics and Computation, vol. 187(2), 2007, s. 1017–1026.
- [14] E.D. Übeyli, İ. Güler: *Features extracted by eigenvector methods for detecting variability of EEG signals*, Pattern Recognition Letters, vol. 28(5), 2007, s. 592–603.
- [15] L.D. Iasemidis, J.C. Sackellares: *REVIEW: Chaos Theory and Epilepsy*, The Neuroscientist, vol. 2(2), 1996, s. 118–126.
- [16] N. Kannathal, U.R. Acharya, C.M. Lim, P.K. Sadasivan: *Characterization of EEG-A comparative study*, Computer Methods and Programs in Biomedicine, vol. 80(1), 2005 s. 17–23.
- [17] D.E. Lerner: *Monitoring changing dynamics with correlation integrals: Case study of an epileptic seizure*, Physica D: Nonlinear Phenomena, vol. 97(4), 1996, s. 563–576.
- [18] V. Srinivasan, C. Eswaran, and N. Sriraam: *Approximate entropy-based epileptic EEG detection using artificial neural networks*, IEEE Transactions on Information Technology in Biomedicine, vol. 11(3), 2007, s. 288–295.
- [19] S. Osowski, B. Swiderski, A. Cichocki, A. Rysz, *Epileptic seizure characterization by Lyapunov exponent of EEG signal*, COMPEL, vol. 26(5), 2007, s. 1276–1287.
- [20] M. Schwab, K. Schmidt, H. Witte, R.M. Abrams: *Investigation of Nonlinear ECoG Changes during Spontaneous Sleep State Changes and Cortical Arousal in Fetal Sheep*, Cereb Cortex, vol. 10(2), 2000, s. 142–148.
- [21] C.Y. Guo, J.P. Li: *Development and future of wavelet analysis*, 10th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP), 2013, s. 335–338.
- [22] S.G. Mallat, Z. Zhang: *Matching pursuits with time-frequency dictionaries*, IEEE Transactions on Signal Processing, vol. 41(12), 1993, s. 3397–3415.
- [23] P.J. Durka, K.J. Blinowska: *Analysis of EEG transients by means of matching pursuit*, Annals of Biomedical Engineering, vol. 23(5), 1995, s. 608–611.
- [24] Y. Wu, H. Zhang, H. Wang, Y. Lu: *The sparse decomposition and compression of ECG and EEG based on matching pursuits*, 3rd International Conference on Biomedical Engineering and Informatics, vol. 3, 2010, s. 1094–1097.
- [25] A. Picot, H. Whitmore, F. Chapotot: *Automated detection of sleep EEG slow waves based on matching pursuit using a restricted dictionary*, Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2011, s. 4824–4827.
- [26] A. Picot, H. Whitmore, F. Chapotot, *Detection of Cortical Slow Waves in the Sleep EEG Using a Modified Matching Pursuit Method With a Restricted Dictionary*, IEEE Transactions on Biomedical Engineering, vol. 59(10), 2012, s. 2808–2817.
- [27] C.A. Loza, J.C. Principe: *Transient model of EEG using Gini Index-based matching pursuit*, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2016, s. 724–728.
- [28] M. Kołodziej, A. Majkowski, R.J. Rak: *Simplified Matching Pursuit as a new method for SSVEP recognition*, 39th International Conference on Telecommunications and Signal Processing (TSP), 2016, s. 346–349.
- [29] S. Ravindran, R. Cole: *Low complexity algorithms for heart rate and epileptic seizure detection*, 2nd International Symposium on Applied Sciences in Biomedical and Communication Technologies, 2009, s. 1–5.
- [30] Z. Xuan, Y. Zhenghua, Y. Songyu: *Method for detecting all-zero DCT coefficients ahead of discrete cosine transformation and quantisation*, Electronics Letters, vol. 34(19), 1998, s. 1839–1840.
- [31] N. Agarwal: *Computationally efficient ABS scheme for sinusoidal transform coding of speech*, Proceedings of the 3rd IEEE International Symposium on Signal Processing and Information Technology, 2003, s. 737–740.
- [32] A. Majkowski, M. Kołodziej, R. Rak, *Joint Time-Frequency And Wavelet Analysis - An Introduction*, Metrology and Measurement Systems, vol. 21(4), 2014, s. 741–758.

otrzymano / submitted: 10.07.2017
zakceptowano / accepted: 15.11.2017