

Zastosowanie sieci neuronowej opartej na parametrach charakterystyki widma sygnału EEG w celu rozróżnienia ruchu i zamiaru ruchu oraz przynależności personalnej sygnału

The application of neural network based on the parameters of EEG-signal spectrum characteristics for classification of movement, intention of movement and personal affiliation of the signal

Anna Broniec

Wydział Fizyki i Informatyki Stosowanej/Laboratorium Biocybernetyki EAiE, Akademia Górniczo-Hutnicza, al. Mickiewicza 30, 30-059 Kraków, tel. +48 (012) 617-38-73, e-mail: broniec@novell.ftj.agh.edu.pl

Streszczenie

Badanie zmian zachodzących w sygnale elektroencefalograficznym (EEG) pod wpływem zadanego bodźca wymaga założenia, że ta reakcja ma własną i powtarzalną charakterystykę, w przeciwieństwie do ciągłej, spontanicznej aktywności mózgu, która w tym kontekście może być traktowana jako addytywny szum. Na podstawie powyższego założenia podzielono otrzymane w eksperymencie próbki sygnału EEG na grupy danych, związanych z odpowiedzią mózgu na zadane bodźce.

Artykuł przedstawia wyniki otrzymane po zastosowaniu prostej sieci neuronowej LVQ (*learning vector quantization*) do rozróżnienia otrzymanych w eksperymencie danych. Porównano dane związane z ruchem palca i z wyobrażeniem ruchu palcem oraz przeprowadzono rozróżnienie danych otrzymanych od różnych osób. Zastosowanie sieci neuronowej samoorganizującej LVQ, opartej na parametrach charakterystyki widma EEG, pozwoliło na rozróżnienie przynależności personalnej sygnału EEG pomiędzy dwiema osobami ze średnią skutecznością 87,31% oraz pomiędzy czterema osobami ze średnią skutecznością 77,39%.

Słowa kluczowe: sygnał elektroencefalograficzny, sieć neuronowa

Abstract

The evaluation of changes within electroencephalography signal (EEG) occurred in response to stimuli, requires the assumption that this reaction has its own, repeatable characteristics compare to the continuous spontaneous brain activity, which can be treated in this context as the additive noise. Therefore, the recorded EEG signal samples, were divided into data groups connected with brain response to the stimuli. The simple neural network LVQ (*learning vector quantization*) was applied to evaluate recorded data. Movement of finger and voluntary intention of movement were examined. The application of simple neural network LVQ based on parameters of EEG-signal spectrum characteristics allowed for differentiation of EEG signal between two persons

with the average efficiency of 87.31% and between four persons with the 77.39% accuracy.

Key words: electroencephalography signal, neural network

Wprowadzenie


Sygnał elektroencefalograficzny jest sygnałem elektrycznym, generowanym przez człowieka. Analiza tego sygnału nie jest prosta. Jego wysoka złożoność, niska amplituda, duża różnorodność osobnicza, a także zależność od wieku i stanu psychofizjologicznego badanej osoby są czynnikami, które utrudniają opis zależności pomiędzy tym, co można zaobserwować na zewnątrz w postaci sygnału elektrycznego, a tym, co się dzieje faktycznie wewnątrz mózgu [1, 2]. Uzyskanie jednoznacznej odpowiedzi wymaga zwykle wielokrotnego stymulowania mózgu zdefiniowanym bodźcem, co umożliwia zaobserwowanie w sygnale EEG powtarzalnej odpowiedzi. Badania tego typu dają możliwość wyodrębnienia schematów pracy mózgu, związanych z konkretnym wydarzeniem (jak na przykład wyobrażenie ruchu palcem), a co za tym idzie – wykorzystania ich do sterowania w sposób świadomy urządzeniem czy komputerem (BCI – *brain-computer interface*) [3-5].

Metodyka badań

Przeprowadzone doświadczenie polegało na stukrotnym powtórzeniu ruchu i stukrotnym wyobrażeniu ruchu palcem wskazującym prawej ręki, w sposób losowy, u dziesięciu praworęcznych ochotników płci męskiej w wieku 22-24 lata. Badany wykonywał ruch (zamiar ruchu) po ok. 5 s, liczonych według własnego uznania, od momentu usłyszenia polecenia. Miało to na celu wyeliminowanie nałożenia się potencjału słuchowego, wywołanego usłyszanym dźwiękiem polecenia, na badany potencjał, wywołany ruchem (zamiarem ruchu).

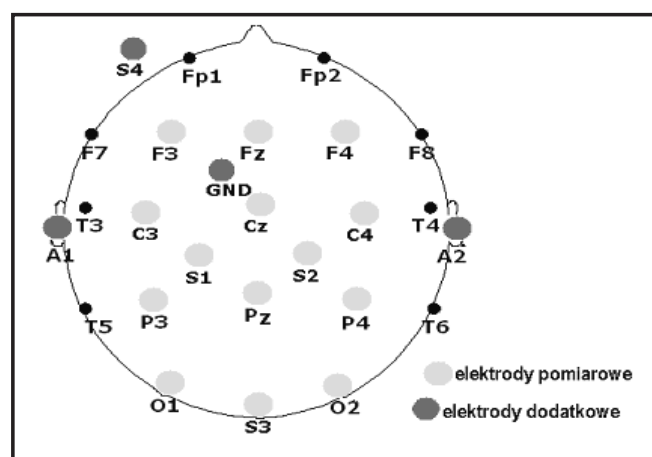
Doświadczenie (rys. 1) składało się z 200 pojedynczych realizacji (prób). Polecenia następowały co 12 s, a zatem całkowity czas zarejestrowanego sygnału wynosił niecałe 45 minut przy częstotliwości próbkowania 500 Hz. Badany, w celu maksymalnego odizolowania

od innych bodźców, miał zamknięte oczy, a badanie było przeprowadzone przy słabym naturalnym oświetleniu.



Rys. 1 Schemat pojedynczej realizacji doświadczenia

W doświadczeniu użyto 18 elektrod miseczkowych (rys. 2), w tym 14 pomiarowych, dwie odniesienia – elektrody uszne A1 i A2, jedną uziemiającą GND i jedną zbierającą artefakty z okolic oczu S4. Do przymocowania elektrod została użyta pasta EC2, przeznaczona do badań elektroencefalograficznych.



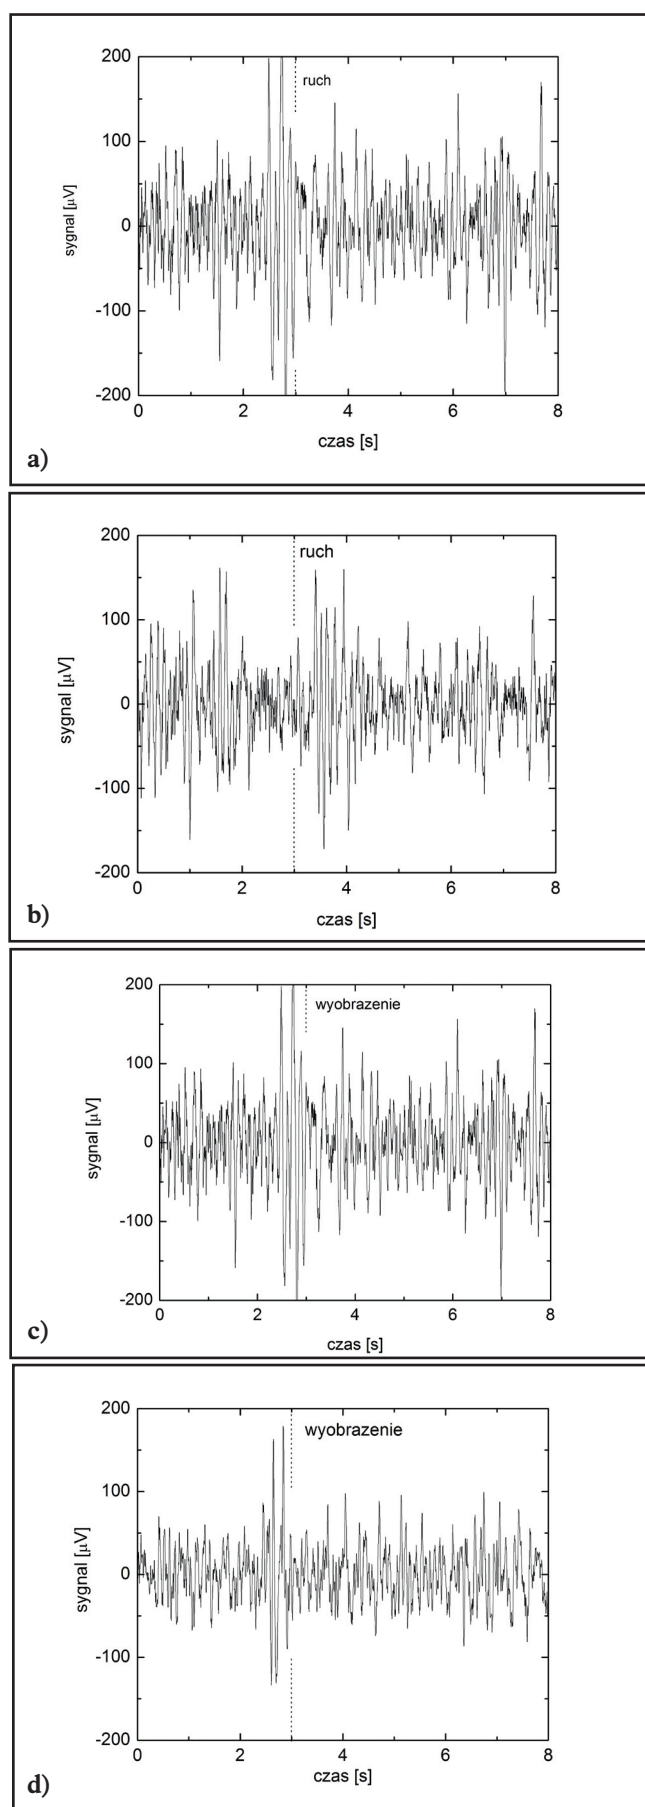
Rys. 2 Rozmieszczenie elektrod w doświadczeniu. Elektrody dodatkowe to: elektrody odniesienia A1 i A2, elektroda oczna S4 i elektroda uziemiająca GND

Wstępna obróbka sygnału składała się z kilku etapów. W pierwszym etapie sygnał z każdej elektrody był wyznaczany względem wartości średniej z elektrod usznych A1 i A2. Następnie stosowano filtrację filtrem pasmowo-przepustowym w zakresie częstotliwości od 2,5 Hz do 87,5 Hz oraz filtrem zakłóceń sieci elektrycznej, tj. wycinającym częstotliwość 50 Hz.

Kolejnymi etapami były:

- przepróbkowanie sygnału z 500 Hz na 250 Hz,
- podzielenie sygnału na 200 odcinków trwających 12 s każdy,
- zawężenie analizowanego przedziału poprzez odcięcie dwusekundowych odcinków na końcach sygnału,
- rozdzielenie zbioru danych na podzbiory reprezentujące odpowiednio ruch i wyobrażenie.

Ostatnim etapem było subiektywne, wzrokowe usunięcie takich artefaktów, jak: sygnał EMG (elektromiograficzny) i EOG (elektrookulograficzny), zewnętrzne pole elektromagnetyczne, ruchy pacjenta czy zły kontakt elektrod ze skórą. Do dalszej analizy wybrano odcinki o długości 8 sekund, niezawierające widocznych artefaktów (próbkowanie 250 Hz, 2000 punktów), z ruchem (wyobrażeniem ruchu) następującym w około trzeciej sekundzie. Po analizie czasowo-częstotliwościowej metodami krótkoczasowej transformaty Fouriera oraz algorytmem dopasowania kroczącego (*matching pursuit* – MP) [6] wybrano elektrodę C3, na której obserwowano największe zmiany.



Rys. 3 Przykładowy przebieg sygnału z elektrody C3 w trakcie ruchu palcem u badanego 'F' i 'C' na rys. a) i b) oraz wyobrażenia ruchu palcem na rys. c) i d)

Metody

Do prostej sieci neuronowej LVQ (*Learning Vector Quantization*) [7] jako parametry wejścia zostały zaimplementowane parametry charakteryzujące widmo EEG: aktywność, ruchliwość, złożoność [8].

Aktywność A (*activity*) informuje o całkowitej intensywności widma:

$$(1) \quad A = \sqrt{m_0}$$

Ruchliwość M (*mobility*) rośnie wraz z udziałem wysokich częstotliwości w widmie:

$$(2) \quad M = \sqrt{\frac{m_2}{m_0}}$$

Złożoność Z (*complexity*) zależy od ilości pików występujących w widmie:

$$(3) \quad C = \sqrt{\frac{m_4}{m_2} - \frac{m_2}{m_0}}$$

We wzorach (1)–(3) wartości m_n to momenty widmowe rzędu n :

$$(4) \quad m_n = \int_{-\infty}^{+\infty} (2\pi f)^n S_x(f) df$$

Gdzie

$$(5) \quad S_x(f) = \lim_{T \rightarrow +\infty} E\left[\frac{1}{T} |X(f)|^2\right]$$

jest funkcją gęstości widmowej mocy, natomiast

$$(6) \quad X(f) = \int_{-\infty}^{+\infty} x(t) e^{-i\omega t} dt$$

jest gęstością widmową realizacji procesu $x(t)$.

Momenty widmowe m_n mogą być też wyrażone jako wartości oczekiwane, odpowiednio kwadratu sygnału $x(t)$ lub jego pochodnych:

$$(7) \quad m_0 = E[x^2(t)]$$

$$(8) \quad m_2 = E\left[\left(\frac{dx(t)}{dt}\right)^2\right]$$

$$(9) \quad m_4 = E\left[\left(\frac{d^2x(t)}{dt^2}\right)^2\right]$$

Wyniki

Spodziewanym wynikiem pierwszej części analizy danych było rozróżnienie ruchu rzeczywistego i wyobrażenia ruchu palcem. Zastosowanie sieci neuronowej samoorganizującej LVQ, opartej na trzech parametrach charakteryzujących widmo EEG: aktywności, złożoności i ruchliwości, nie pozwoliło na rozróżnienie ruchu od wyobrażenia ruchu palcem. Powyższy wynik potwierdza wcześniej opisywane podobieństwo obydwu zjawisk [9]. Otrzymano skuteczność rozpoznania poniżej 50%, co świadczy o braku możliwości wykorzystania tych parametrów do rozwiązania powyższego problemu.

Drugą częścią analizy było rozróżnienie przynależności sygnału EEG. Zastosowanie sieci neuronowej samoorganizującej LVQ,

opartej na tych samych parametrach, pozwoliło na rozpoznanie przynależności personalnej sygnału EEG pomiędzy dwoma osobami (tabela 1) ze średnią skutecznością 87,31% (maksymalnie dla jednej pary badanych osób uzyskano 100%) dla danych z elektrody C3. Przebadano sześć par. Średnia skuteczność w rozpoznaniu przynależności personalnej sygnału EEG w przypadku czterech osób (tabela 2) wyniosła 77,39 % dla danych z tej samej elektrody. Uczenie sieci odbywało się na 20 próbach eksperymentu dla każdej osoby (łącznie brany był ruch i wyobrażenie), po czym następowało rozpoznawanie 50 prób od każdej osoby.

Tabela 1 Zestawienie procentowej skuteczności sieci neuronowej w przypadku rozróżnienia przynależności sygnału pomiędzy dwoma osobami

Badana para	Skuteczność [%]
Badany 'C' i 'F'	80,61
Badany 'B' i 'F'	94,89
Badany 'B' i 'C'	89,79
Badany 'H' i 'C'	77,50
Badany 'H' i 'D'	81,10
Badany 'F' i 'H'	100,00

Tabela 2 Zestawienie procentowej skuteczności sieci neuronowej w przypadku rozróżnienia przynależności sygnału pomiędzy czterema osobami

Badana para	Skuteczność [%]
Badany 'F','H','C','A'	70,5
Badany 'F','H','C','B'	73,5
Badany 'B','C','F','H'	87,5
Badany 'H','C','F','T'	71,5
Badany 'F','H','C','D'	93,5
Badany 'F','H','D','T'	71,5
Badany 'F','H','D','E'	72,5
Badany 'F','H','C','J'	70,0
Badany 'F','H','C','E'	86,5

Dyskusja

Zaplanowanie doświadczenia jako naprzemiennej realizacji ruchu i jego wyobrażenia pozwoliło na rejestrację zmian w sygnale EEG, wywołanych bodźcem w identycznych warunkach fizjologicznych, w tym samym czasie i u tych samych badanych, co dawało dobre podstawy do porównywania badanych zjawisk.

Głównym problemem, jaki napotyka się w trakcie przeprowadzania doświadczeń EEG, jest duże zaszumienie sygnału, w głównej mierze spowodowane artefaktami pochodzącymi od napięcia mięśni, szczególnie szyi. Dodatkowo swój negatywny wpływ ma zbyt słabo zdefiniowane rozpoczęcie ruchu (wyobrażenia) w każdej kolejnej próbie doświadczenia – bardzo ważnym etapem planowania doświadczenia jest zaprojektowanie go w sposób umożliwiający idealne nałożenie czasowe kolejnych reakcji na zadany bodziec. Również brak dobrze wyciszzonego laboratorium oraz zmęczenie i znużenie badanych w trakcie eksperymentu, pogarszają jakość zebranego elektroencefalogramu, choć już w mniejszym stopniu.

Zgodnie z przewidywaniami, ruch i jego wyobrażenie są reprezentowane przez analogiczne zmiany w przebiegu EEG, dlatego nie było możliwe rozróżnienie obu zjawisk za pomocą sieci neuronowej. Potwierdza to teoria, mówiąca, że ruch hamowany jest dopiero na poziomie rdzenia kręgowego, dlatego nie jest możliwe odnalezienie różnic w sygnale EEG, który pochodzi z obszaru kory mózgowej [10].

Rozróżnienie przynależności sygnału do badanej osoby dało bardzo dobre wyniki, ale jednocześnie jest źródłem kolejnych pytań. Dotyczą one udziału wpływu różnic osobniczych i wpływu warunków, mimo próby zachowania identycznych warunków przeprowadzania doświadczenia.

Podsumowanie

Niezrealizowane nigdy wcześniej wykorzystanie sieci neuronowej do rozróżnienia badanych zjawisk daje kolejny argument popierający teorię, mówiącą, że ruch i jego wyobrażenie na poziomie kory mózgowej zachodzą niemal identycznie.

W oparciu o studia literaturowe i wyniki przeprowadzonego eksperymentu można stwierdzić, że dla zastosowań BCI rozróżnienie pomiędzy ruchem a jego wyobrażeniem nie jest konieczne i nie usprawniłoby ono w żaden sposób komunikacji pomiędzy człowiekiem a maszyną. W zastosowaniach tych największy nacisk należy położyć na poprawne zaimplementowanie etapu przygotowania i planowania ruchu. Wydaje się też, że dostosowywanie interfejsu indywidualnie dla danego pacjenta, z uwzględnieniem różnic osobniczych w przebiegu fal EEG, mogłoby dawać lepsze rezultaty komunikacji pomiędzy człowiekiem a maszyną. Zwykle jest to realizowane za pomocą wstępnej nauki sieci, realizującej komunikację pomiędzy mózgiem a komputerem [11-14]. ■

Literatura

1. G. Pfurtscheller, F. L. da Silva: *Handbook of electroencephalography and clinical neurophysiology*, revised series, Elsevier Science B.V., 1999.
2. G. Pfurtscheller, C. Neuper: *Motor imagery activates primary sensorimotor area in humans*, *Neurosci. Lett.*, vol. 239, 1997, s. 65-68.
3. G. Pfurtscheller, G.R. Müller-Putz, A. Schlögl, B. Graimann, R. Scherer, R. Leeb, C. Brunner, C. Keinrath, F. Lee, G. Townsend, C. Vidaurre, C. Neuper: *15 years of BCI research at Graz University of Technology: Current projects*, *IEEE Trans Neural Sys. Rehab. Eng.*, vol. 14(2), 2006, s. 205-210.
4. J. R. Wolpaw, N. Birbaumer, D. McFarland, G. Pfurtscheller, T.M. Vaughan: *Brain-computer interfaces for communication and control*, *Clinical Neurophysiology*, vol. 113, 2004, s. 767-791.
5. J.R. Wolpaw, D.J. McFarland: *Multichannel EEG-based brain-computer communication*, *Electroenceph. Clin. Neurophysiol.*, vol. 90, 1994, s. 444-449.
6. P. J. Durka: *Matching Pursuit and Unification in EEG Analysis*, Artech House, 2007.
7. R. Tadeusiewicz: *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
8. K.J. Klinowska-Cieślak: *Zagadnienia cyfrowej analizy przebiegów fizjologicznych*, WUW, Warszawa 1980.
9. J. Ginter: *Analiza czynności elektrycznej mózgu towarzyszącej świadomym ruchom lub ich wyobrażeniu*, UW, 2004.
10. A. Grabska-Barwińska: *Model zmian synchronizacji czynności EEG związanych z wykonywaniem ruchu*, Praca magisterska, Pracownia Fizyki Medycznej, Instytut Fizyki Doświadczalnej, Wydział Fizyki, UW, 2004.
11. J. Deng, B. He: *Classification of imaginary tasks from three channels of EEG by using an artificial neural network*, Dept. of Bioengineering, Illinois Univ, Chicago, IL, USA, Sept 2003.
12. M. Phothisonothai, M. Nakagawa: *EEG-Based Classification of New Imagery Tasks Using Three-Layer Feedforward Neural Network Classifier for Brain-Computer Interface*, *J Phys Soc Jpn*, vol. 75, 2006, s. 104801. 1-104801.6.
13. M. Phothisonothai, M. Nakagawa: *EEG-Based Classification of Motor Imagery Tasks Using Fractal Dimension and Neural Network for Brain-Computer Interface*, *IEICE – Transactions on Information and Systems*, vol. E91-D, 2008, s. 44-53.
14. X. Liu, S. Hibino, T. Hanai, T. Imanishi, T. Shirataki, T. Ogawa, H. Honda, and T. Kobayashi: *Construction of an electroencephalogram-based brain-computer interface using an artificial neural network*, *IEICE Trans. Inf. & Syst.*, vol. E86-D, 2003, s. 1879-1886.

otrzymano / received: 02.03.2009 r.
zaakceptowano / accepted: 29.06.2009 r.