

Szczepan PASZKIEL

POLITECHNIKA OPOLSKA, WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI I INFORMATYKI, INSTYTUT AUTOMATYKI I INFORMATKI,
ul. Generała Kazimierza Sosnkowskiego 31, 45-217 Opole

Koncepcja systemu dwumodułowego, łączącego modelowanie populacyjne frakcji komórek neuronalnych z algorytmami analizy artefaktów sygnału EEG

Dr inż. Szczepan PASZKIEL

Doktor inżynier w dyscyplinie Automatyka i Robotyka, specjalność: cybernetyka, sterowanie ruchem, inteligentne systemy. Aktualnie pracuje jako asystent w Instytucie Automatyki i Informatyki Politechniki Opolskiej. Prowadzi badania naukowe w zakresie Brain Computer Interfaces oraz neuromarketingu. Autor kilkudziesięciu publikacji naukowych. Prelegent na kilkudziesięciu konferencjach naukowych w tym międzynarodowych. Absolwent 2 kierunków studiów: Informatyki oraz Zarządzania i inżynierii produkcji.



e-mail: s.paszkiel@po.opole.pl

Streszczenie

W artykule przedstawiono nowatorskie połączenie modelowania populacyjnego z algorytmami analizy artefaktów zakłócających. Badania prowadzone w zakresie wykorzystania dwóch metod analizy sygnału elektroencefalograficznego: *Principal Component Analysis* oraz *Independent Component Analysis*. Pierwszy moduł systemu zawiera model populacyjny frakcji komórek neuronalnych, opracowany na bazie pierwszego modelu Wilsona i Cowana. Drugi moduł składa się z zaimplementowanych metod analizy sygnału EEG w kontekście eliminacji zakłóceń występujących w modelowanym sygnale, odzwierciedlającym reakcję na konkretny potencjał wywołany.

Słowa kluczowe: system dwumodułowy, modelowanie populacyjne, EEG, analiza artefaktów.

Conception of a two-module system connecting population modelling of neuron cells with algorithms of EEG signal analysis

Abstract

The paper presents an innovative connection of population modelling with algorithms of analysis of disruptive artefacts. The research was conducted for two methods concerning analysis of the electroencephalographic signal. These are Principal Component Analysis and Independent Component Analysis described in Section 4. Conceptions of a two-module system are shown in Fig. 1 and described in Section 3. The module 1 of the system contains a population model of a fraction of neuron cells prepared on a basis of the first Wilson and Cowan's module. It is described in Section 2 of the paper. The module 2 consists of implemented methods concerning analysis of the EEG signal for elimination of disruptions in the modelling signal which reflects a reaction for a particular evoked signal. There is no doubt that the two-module system, presented here, would be a helpful device for those scientists who construct brain-computer and brain-machine interfaces. Its usefulness in laboratory conditions would advance implementation of particular states which are typical for modifications of the electroencephalographic signal in terms of reactions for external impulses, limb movements or eye closing etc.

Keywords: two-module system, population modelling, EEG, analysis of artefacts.

1. Wprowadzenie

Poprzez zastosowanie modeli populacyjnych w pierwszym module proponowanego systemu możliwe jest generowanie sygnału EEG, który jest zapisem elektrycznej aktywności mózgu. Sygnał elektroencefalograficzny odzwierciedla potencjał połowy w przetrzeni wokół neuronów. Im bardziej zsynchronizowana jest dana populacja neuronów, tym łatwiej jest dokonać rzeczywistego pomiaru sygnału elektroencefalograficznego. Jak wynika z szeregu doświadczeń, sygnał EEG cechuje się wysoką aktywnością czasową około 1 ms. W modelowanym sygnale możemy wyodrębnić kilka rodzajów aktywności, które charakteryzują się specy-

ficznymi częstotliwościami i amplitudami sygnału, takie jak fale: Alfa, Beta, Delta, Gamma, Theta, Mu. Badania wskazały, że zarówno częstotliwość fal mózgowych jak i ich amplituda nie jest ściśle stała i ściśle zależy od czynności, jaką umysł wykonuje. Zapis sygnału EEG traktowany jest jako zjawisko quasi-okresowe, będące superpozycją wielu fal składowych.

Model populacyjny frakcji komórek neuronalnych w zakresie swojej funkcjonalności bazuje na potencjałach wywołanych [1]. W czasie analizy sygnału EEG opartego na bazie potencjałów wywołanych należy uwzględnić efekt habituacji. Wynika on z osłabienia potencjałów wywołanych kolejnymi powtórzeniami bodźca. Badania w tej dziedzinie od dłuższego czasu zmierzają do określenia odpowiedniej parametryzacji pojedynczych potencjałów wywołanych. W sygnale EEG potencjały wywołane obserwowane są jako zmiany wartości amplitudy sygnału w danym przedziale czasowym. Najbardziej stabilne oscylacje są jednak możliwe w sieciach składających się zarówno z komórek pobudzających, jak i hamujących, co opisali naukowcy *Wilson H.* i *Cowan J.* [2].

Z przeprowadzonych studiów literaturowych wynika, że pojedyncze neurony są bardzo hałaśliwe. Na przykład, badając aktywność tylko pojedynczego neuronu kory wzrokowej trudno jest zrekonstruować, co w danej chwili widzi oko badanego. Informacja przetwarzana jest w mózgu przez populację neuronów i przetwarzanie to jest rozdzielone na wiele z nich. W wielu sytuacjach każdy neuron przetwarza tylko cząstkę informacji i im więcej neuronów bierze udział w pracy, tym bardziej precyzyjne jest kodowanie informacji. Podczas gdy pojedyncze neurony wykazują duży współczynnik szumu do sygnału, populacja jako całość dokonuje uśrednienia szumu i w konsekwencji stosunek szumu do sygnału staje się niewielki. Podobny efekt wykorzystujemy podczas rejestracji z powierzchni czaszki potencjałów wywołanych. Dlatego też w niniejszym artykule zdecydowano się opisać podejście populacyjne.

2. Modelowanie populacyjne

Tak jak wspomniano we wprowadzeniu do niniejszego artykułu, modelowanie populacyjne daje możliwości odtwarzania efektów korelacyjnych na poziomie pojedynczych neuronów oraz na badanie rewerberacji, czyli procesu wzajemnego pobudzania się sprzężonych ze sobą neuronów, przy uśrednieniu próby odtwarzania potencjałów EEG. W literaturze często spotyka się uproszczenie modeli neuronów impulsujących tworzących sieci, w których zanika zależność od czasu oraz problemy synchronizacji. Ma w tym przypadku zastosowanie hipoteza *Stevensa*, według której wysyłane przez neurony impulsy wykorzystywane są jedynie w procesie komunikacji. Do opisu stanu sieci według tej hipotezy zastosować należy miarę aktywności neuronów proporcjonalną do ładunku na wierzchołku aksonowym. Aktywność neuronu jest w tym przypadku nieliniowa i zależna od sumy sygnałów wejściowych. Do zalet modelowania populacyjnego zaliczyć należy: możliwość porównywania wyników modelu z sygnałami pochodzącymi z przeprowadzonych doświadczeń, zastosowanie metod analitycznych do badania zachowania modelu, wydajność obliczeniową oraz prostotę modelu. Zaletą modeli populacyjnych, a tym samym proponowanego systemu dwumodułowego, jest również kwestia symulowania eksperymentów niemożliwych do wykonywania w rzeczywistości, a także możliwość przewidywania złożonych zachowań dynamicznych populacji neuronalnych.

Układ nerwowy człowieka cechuje się bardzo dużą złożonością, dlatego też nawet z wykorzystaniem najnowszych zdobyczy technologicznych nie jesteśmy w stanie uwzględnić wszystkich wła-

sności neuronów w ramach jednego modelu. Szczególnie w przypadku modelowania złożonych sygnałów elektroencefalograficznych. Dlatego też wiele właściwości poddaje się procesom uśredniania. Przykładem mogą być modele populacyjne, które właściwości elektryczne neuronu interpretują jako średnie potencjały postsynaptyczne. W literaturze znaleźć można modele, które komórkę piramidalną opisują aż 64 kompartmentami [3].

Założenia modelu Wilsona i Cowana mówią, że każda z populacji neuronów zachowuje się jednorodnie. *Wilson H.* i *Cowan J.* nie analizowali rozciągłości przestrzennej populacji. W modelu założono, że $E(t)$ to miara populacji komórek pobudzających, uruchamiających potencjały czynnościowe w jednostce czasu t , a $I(t)$ to miara populacji komórek hamujących. Średni potencjał błonowy populacji pobudzającej $V_e(t)$ oraz średni potencjał błonowy populacji komórek hamujących $V_i(t)$ można wyrazić wzorami 1 i 2:

$$V_e(t) = \int_0^{\infty} [c_1 E(t-\tau) + P(t-\tau)] h_e(\tau) d\tau - \int_0^{\infty} c_2 I(t-\tau) h_i(\tau) d\tau, \quad (1)$$

$$V_i(t) = \int_0^{\infty} [c_3 E(t-\tau) + Q(t-\tau)] h_e(\tau) d\tau - \int_0^{\infty} c_4 I(t-\tau) h_i(\tau) d\tau. \quad (2)$$

Współczynniki c_1 i c_2 określają średnią ilość synaps na komórkę pobudzającą o potencjale $V_e(t)$. Natomiast współczynniki c_3 i c_4 określają średnią ilość synaps na komórkę hamującą o potencjale $V_i(t)$. $P(t)$ określa średnią liczbę impulsów pobudzających docierających do pojedynczej komórki. $h_e(\tau)$ oraz $h_i(\tau)$ to funkcje odpowiedzi impulsowej. Od średniego potencjału błonowego, jaki występuje wśród danej populacji, zależy czy dany neuron będzie w stanie pobudliwym. Wzory 3 i 4 przedstawiają wartości $E(t)$ oraz $I(t)$:

$$E(t) = \lambda_e \left[1 - \int_{t-r_e}^t E(t') dt' \right] f(V_e(t)), \quad (3)$$

$$I(t) = \lambda_i \left[1 - \int_{t-r_i}^t I(t') dt' \right] f(V_i(t)). \quad (4)$$

Stałe pojawiające się w tych wzorach: λ_e oraz λ_i definiują średnie częstości pobudzenia pojedynczej komórki w każdej z frakcji.

Na potrzeby przedstawionego w niniejszym artykule systemu dwumodułowego powyżej opisany model został zoptymalizowany poprzez uproszczenie równania definiującego potencjał błonowy populacji komórek hamujących. W równaniu zrezygnowano ze sprzężenia pomiędzy interneuronami, gdyż następują one bardzo szybko [4].

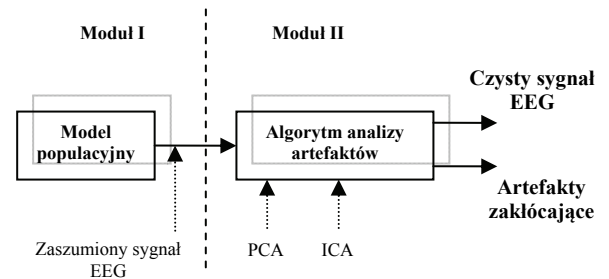
W strukturze mózgu człowieka często występuje zjawisko kodowania populacyjnego - ma ono miejsce wówczas, gdy informacja jest reprezentowana w postaci skoordynowanej aktywności dużej liczby komórek. Generowanie potencjału czynnościowego można zaobserwować, gdy neuron po zintegrowaniu wszystkich docierających do niego sygnałów analogowych dokona porównania wyniku tej operacji z określoną wartością progową. Jeżeli taka sytuacja będzie miała miejsce, to mamy do czynienia z sygnałem cyfrowym. Sygnał ten jest przetwarzany na sygnał analogowy przez synapsę. W wyniku przeprowadzonych doświadczeń stwierdzono, że około 100 synaps pobudzających musi być jednocześnie aktywnych, aby spowodować powstanie potencjału czynnościowego.

W komórce nerwowej następuje proces sumowania się potencjałów postsynaptycznych zarówno hamujących, jak i pobudzających, co generuje potencjał czynnościowy. Zachodząca w ten sposób korelacja umożliwia funkcjonowanie neuronu, jako „urządzenia obliczeniowego”. Ze względu na warunki czasowe, w jakich następuje proces sumowania potencjałów postsynaptycznych, mamy do czynienia z sumowaniem czasowym, które wyka-

zuje właściwości nieliniowe. Kolejno następujące PSP (ang. *Post-synaptic Potential*) sumują się w czasie. Występuje również sumowanie przestrzenne uwarunkowane miejscem powstawania w różnych częściach komórki. Zakres sumowania przestrzennego jest określony przez właściwości kablowe neuronu. Zarówno sumowanie czasowe, jak i przestrzenne występują jednocześnie, ale mimo to traktuje się je jako dwa oddzielne zjawiska. Częstotliwość potencjałów czynnościowych oraz czas, w jakim są generowane, określane są przez amplitudę sygnału oraz czas trwania depolaryzacji wzgórka aksonowego. Sposób połączeń neuronu czuciowego koduje informacje o jakości bodźca i jego lokalizacji. Cechą charakterystyczną układów nerwowych jest bardzo małe prawdopodobieństwo wystąpienia przekłamań w transmisji informacji. Potencjały czynnościowe to sygnały cyfrowe, które są mniej podatne na zakłócenia niż inne sposoby transmisji danych.

3. System dwumodułowy

Na bazie systemu dwumodułowego możliwe jest modelowanie zmian synchronizacji sygnału EEG z uwzględnieniem i klasyfikacją artefaktów zakłócających. W koncepcji zaproponowanego modelu populacyjnego, przedstawiającego zmiany synchronizacji sygnału elektroencefalograficznego zachodzące podczas ruchu palcem, wykorzystano założenie wektora populacji. Charakteryzując model populacyjny należy stwierdzić, że może on służyć do analizy struktury sieci neuronalnej, ze względu na fakt, iż w stosunkowo małym obszarze znajduje się wiele neuronów cechujących się identycznymi właściwościami. Na rysunku 1 przedstawiono architekturę proponowanego systemu dwumodułowego.



Rys. 1. Architektura systemu dwumodułowego [Źródło: opracowanie własne]
Fig. 1. Architecture of the two-module system [Source: own elaboration]

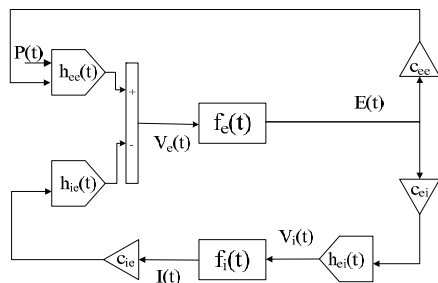
Jednym z założeń proponowanego modelu populacyjnego jest fakt, że rytmy wysokich częstotliwości generowane są przez niewielkie obszary kory mózgowej. Podczas projektowania modelu populacyjnego, szczególną uwagę zwrócono na sprzężenia występujące pomiędzy interneuronami. Miało to kluczowe znaczenie na etapie budowy algorytmu dla modelu populacyjnego.

Neurony występują we wzajemnych korelacjach między sobą w związku z powyższym, wprowadzono na potrzeby modelu dwie stałe mnożące reprezentujące średnią ilość synaps, przez które frakcje komunikują się, są to stałe: c_{ei} , c_{ie} . Neurony komunikują się również w obrębie własnej frakcji, w związku z powyższym występuje także stała: c_{ee} . Pozostałe oznaczenia w algorytmie adekwatnym, dla projektowanego modelu, bazują na scharakteryzowanym w punkcie drugim niniejszego artykułu modelu Wilsona i Cowana. Na rysunku 2 przedstawiono schemat ogólny dla modułu I z rysunku 1.

Proponowany model nie obejmuje podkorowych struktur mózgowych, skupiając się na samej korze mózgowej. Średni potencjał panujący w populacji komórek piramidalnych zapisany wzorem (5):

$$V_e(t) = \int_0^{\infty} [c_{ee} E(t-\tau) + P(t-\tau)] h_{ee}(\tau) d\tau - \int_0^{\infty} c_{ie} I(t-\tau) h_{ie}(\tau) d\tau \quad (5)$$

jest potencjałem dominującym w sygnale elektroencefalograficznym.



Rys. 2. Schemat ogólny modelu populacyjnego [Źródło: opro elaboration]

Rezygnując ze sprzężenia pomiędzy neuronami, w związku z tym, że następują one bardzo szybko zapisano w modelu matematycznym populacji ilość potencjałów, które docierają do synaps $E(t - \tau)d\tau$ w chwili czasu $(t - \tau)$. Funkcja czasu jest efektem, jaki wywołują potencjały w neuronach postsynaptycznych charakteryzuje to funkcja odpowiedzi impulsowej h_{ei} .

$$V_i(t) = \int_0^{\infty} c_{ei} E(t - \tau) h_{ei}(\tau) d\tau \quad (6)$$

Reakcja synapsy na dany bodziec wzorowana jest na potencjale wzmocnienia amplitudy charakterystycznym dla danego rodzaju synaps. Kształt i charakter uśrednionego wzmocnienia amplitudy modelowany jest przy pomocy funkcji dwueksponencjalnej (7):

$$\begin{aligned} h_{ee}(t) &= a[\exp(-a_1 t) - \exp(-a_2 t)] \\ h_{ei}(t) &= b[\exp(-b_1 t) - \exp(-b_2 t)] \\ h_{ie}(t) &= c[\exp(-c_1 t) - \exp(-c_2 t)] \end{aligned} \quad (7)$$


gdzie: $a_1 < a_2$, $b_1 < b_2$, $c_1 < c_2$. W wyniku sumowania wzorów 5 i 6 otrzymuje się zmienne reprezentujące potencjały błonowe, odzwierciedlają one charakter uśredniony, świadczący o poziomie pobudzenia, jaki panuje w populacji. Ilość potencjałów, które są przy danej depolaryzacji wytwarzane $E(t)$, $I(t)$ można wyznaczyć zakładając jednorodny rozkład synaps w populacji. Z założenia tego wynika, że każdy neuron otrzymuje średnio podobny poziom pobudzenia, tym samym ilość wszystkich pobudzonych neuronów zapisana jest wzorem 8. $D(V)$ to rozkład potencjałów progowych danych populacji. Założono, że jest on zbliżony do normalnego.

$$f(V(t)) = \int_0^{V(t)} D(V') dV' \quad (8)$$

Połączenia wejściowe i wyjściowe neuronu kodują informację o przestrzennej lokalizacji bodźca. Częstość przesyłania potencjałów czynnościowych pozwala zebrać informacje o intensywności bodźca oraz o czasie jego trwania. Binarność potencjałów czynnościowych umożliwia zdecydowanie bardziej efektywną reprezentację informacji, mniej podatną na błędy oraz zniekształcenia. Istotną jest także modulacja częstości generowania potencjałów czynnościowych. Pojawienie się dodatkowego potencjału czynnościowego, bądź też jego brak w danej chwili nie wpływa w istotny sposób na częstość serii. Podczas reprezentacji informacji poprzez populację komórek mamy także do czynienia z jej redundancją. Błędna aktywność kilku komórek neuronalnych, która może pojawić się w sygnale, jest kompensowana przez pozostałe, których ilość jest zdecydowanie większa.

Model może generować różne grupy frakcji komórek nerwowych. W przypadku aktywności stochastycznej, mamy do czynienia z brakiem synchronizacji. W przypadku drgań sygna-

łu EEG występuje bardzo duża synchronizacja sygnału. Na rysunkach 3 oraz 4 przedstawiono przykładowe wyniki zmian potencjału dominującego podczas symulacji rytmów Alfa oraz Gamma. Na osi poziomej czas na osi pionowej oznaczono wartości napięcia w mV .




Rys. 3. Przykładowe wyniki symulacji EEG, $V_e(t)$ dla rytmu Alfa: $P=180$ pps,

$c_{ee}=750$, $c_{ie}=c_{ei}=1200$. [Źródło: opracowanie własne]

Fig. 3. Exemplary results of the EEG simulation, $V_e(t)$ for the Alpha rhythm:

$P=180$ pps, $c_{ee}=750$, $c_{ie}=c_{ei}=1200$. [Source: own elaboration]



Rys. 4. Przykładowe wyniki symulacji EEG, $V_e(t)$ dla rytmu Gamma: $P=500$ pps,

$c_{ee}=300$, $c_{ie}=c_{ei}=1500$. [Źródło: opracowanie własne]

Fig. 4. Exemplary results of the EEG simulation, $V_e(t)$ for the Gamma rhythm:

$P=500$ pps, $c_{ee}=300$, $c_{ie}=c_{ei}=1500$. [Source: own elaboration]

4. Analiza artefaktów

Drugi z modułów w proponowanym systemie odpowiada za kwestię związaną z eliminacją artefaktów zakłócających. Niestety w sygnale EEG, jeśli nie jest on proporcjonalny do potencjału elektrycznego wygenerowanego przez mózg, pojawiają się artefakty. Zniekształcają one rzeczywisty przebieg fal mózgowych. Artefakty ze względu na swoje pochodzenie możemy podzielić na: techniczne oraz biologiczne. Wpływ źródeł artefaktów jest wprost proporcjonalny do amplitudy generowanego sygnału i odwrotnie proporcjonalny do odległości pomiędzy źródłami a elektrodami EEG. Do artefaktów zaliczyć należy także zmiany przewodności występujące pomiędzy elektrodami a mózgiem. Stan psychiczny osoby badanej ma również bezpośredni wpływ na jakość sygnału EEG - w tym na zakłócenia biologiczne, jakie w tym sygnale mogą występować.

Istotnym spostrzeżeniem w kierunku eliminacji artefaktów powinna być obiektywna ocena wpływu każdego źródła zakłóceń na zapis sygnału EEG [5]. Podczas rzeczywistych pomiarów eliminacja artefaktów może odbyć się na drodze zlikwidowania źródła zakłóceń, z którego pochodzą. Im dokładniej można scharakteryzować źródło zakłóceń, tym lepiej można je eliminować z pomiaru. Jeżeli niemożliwe jest odizolowanie źródła zakłóceń ani odcięcie kanału przenoszenia zakłóceń, pozostaje obróbka zarejestrowanego przebiegu w celu odzyskania czystego zapisu EEG. W praktyce najprostszą, powszechnie stosowaną metodą eliminacji zakłóceń, jest filtracja pasmowo-przepustowa. Filtracja ta polega na wytłumieniu wszystkich częstotliwości poza pasmem sygnału użytecznego. Problemy stwarzają zakłócenia o paśmie częstotliwości pokrywającym się z pasmem fal mózgowych. Przykładem może być pole elektromagnetyczne wytwarzane przez przewody sieci energetycznej 50 Hz. Powszechnie stosowany filtr wąskopasmowy wycina z zapisu składową o częstotliwości 50 Hz, ale wytłumiony zostaje zarówno sygnał sieci, jak i sygnał generowany przez mózg. W sytuacji, gdy niemożliwe jest odfiltrowanie zakłóceń i uzyskanie czystego zapisu fal mózgowych, konieczne jest wykluczenie z badania wszystkich fragmentów zapisu, w których podejrzewa się wystąpienie artefaktów.

Wyszukiwanie artefaktów o dużej amplitudzie w porównaniu z zapisem EEG nie jest trudne zarówno metodą wizualną, jak i za pomocą automatycznej analizy. Istnieją algorytmy służące wyszu-


kiwaniu specyficznych rodzajów artefaktów np. pochodzących od ruchu gałki ocznej. W wyniku takich poszukiwań dochodzi do eliminacji fragmentów z zakłóceniami, a gdy natura zakłóceń jest dobrze znana możliwe jest odzyskanie właściwego przebiegu. Trudniejsze jest wyszukiwanie zakłóceń o względnie małych wartościach amplitud. Jedynie na podstawie analizy widmowej lub topograficznej można orzec o wystąpieniu takich artefaktów.

Jak wynika z analiz przeprowadzonych na potrzeby niniejszego artykułu, przykładowo: ruch gałki ocznej wywiera największy wpływ na potencjały elektrod czołowych a ruch mięśni szkieletowych przejawia się w postaci zakłóceń na odprowadzeniach bocznych. Artefakty spowodowane przemieszczeniem elektrody względem ciała powodują zakłócenia tylko w jednym własnym kanale rejestracji, są więc dość łatwe do zaobserwowania.

Eliminacja artefaktów natury technicznej nie przysparza większych problemów. Dużo trudniej jest wyeliminować artefakty natury biologicznej (fizjologiczne oraz mięśniowe).

Jednym z rozwiązań problemu pojawiających się w modelowanym sygnale artefaktów jest metoda *ICA*, czyli *Independent Component Analysis* [6]. Jest to analiza składowych niezależnych. W 1986 roku *Herault J.* i *Jutten C.* opracowali algorytm, działający na bazie powyższej analizy dla sieci neuronowych ze sprzężeniem zwrotnym. W 1994 roku *Comon P.* zastosował kryterium separacji w postaci minimalizacji informacji wzajemnej. Kolejnym sposobem estymacji składowych niezależnych jest metoda największej wiarygodności o nazwie *Maximum Likelihood*. W przypadku tym wymagana jest jednak znajomość rozkładów prawdopodobieństwa separowanych źródeł sygnału EEG. Adaptacyjnym algorytmem wykorzystywanym do analizy składowych niezależnych w projektowanym systemie jest także *Infomax*. Mamy w tym przypadku do czynienia z maksymalizacją informacji pomiędzy wejściem a wyjściem sieci neuronowej z nieliniowymi funkcjami aktywacji.

Rysunek 5 przedstawia potencjały związane z bodźcem *ERP* (ang. *Event-Related Potentials*), zaszumione oraz po zastosowaniu metody *ICA*. Analizę wykonano za pomocą *toolbox-u EEGLAB for Matlab*.



Rys. 5. Przykładowe ERP sygnału EEG dla próbkowania 128 [Hz], 16 kanałów. Linia jaśniejszą oznaczono sygnały po zastosowaniu *ICA*, ciemniejszą sygnały z artefaktami. [Źródło: opracowanie własne]

Fig. 5. Exemplary ERP of the EEG signal for 128 [Hz] sampling, 16 canals. Signals after using *ICA* are marked with a bright line and signals with artefacts with a dark line. [Source: own elaboration]

Kolejną metodą do klasyfikacji artefaktów w sygnale EEG zaproponowaną dla drugiego modułu projektowanego systemu, jest *Principal Component Analysis*, czyli *PCA* [7]. Jest to statystyczna metoda analizy czynnikowej. Transformacja danych wykonana za pomocą *PCA* stanowi adekwatne przybliżenie liniowe. Pozwala to na późniejsze rzutowanie punktów na przestrzeń o mniejszym wymiarze, przy równoczesnym zachowaniu jak największej ilości informacji.

5. Wnioski

Zaproponowany w niniejszym artykule system dwumodułowy będzie niewątpliwie pomocnym narzędziem dla osób zajmujących się konstruowaniem interfejsów mózg-komputer, mózg-maszyna. Jego użyteczność w warunkach laboratoryjnych zdecydowanie przyspieszy proces implementacji poszczególnych stanów charakterystycznych dla zmian sygnału elektroencefalograficznego w zakresie reakcji na bodźce zewnętrzne bądź też ruchy kończyn, zamknięcie oka, etc.

Dzięki opracowaniu dwumodułowego systemu *model + algorytm identyfikacji* poszerzono dotychczasową wiedzę w zakresie możliwości zrozumienia szczegółów zachowania oraz specyficznych cech mózgowia. Jest to nowoczesna koncepcja połączenia znanych metod analizy sygnałów z modelowaniem populacyjnych frakcji komórek neuronalnych.

Niewątpliwie badania naukowe prowadzone w temacie interfejsów mózg-komputer są niezmiernie istotne z punktu widzenia wielu dziedzin nauki oraz przemysłu [8]. Nowe media komunikacji na linii człowiek-komputer będą w ciągu najbliższych lat jednym z wielu trendów rozwojowych. Biorąc pod uwagę zainteresowanie tematyką *BCI* (ang. *Brain Computer Interfaces*) przez wiele ośrodków badawczych na świecie, będzie ona stanowiła znaczący udział w rozwoju mechanizmów sterowania zarówno komputerów i oprogramowania, jak i innych urządzeń i robotów. Technologia ta będzie także pomocna dla osób niepełnosprawnych, którzy nie są w stanie wykonywać wielu czynności samodzielnie.

6. Literatura

- [1] Wypych M., Wróbel A.: Identyfikacja stanu funkcjonalnego mózgu przy pomocy nowych metod analizy potencjałów wywołanych. Materiały Konferencji Nowe metody w neurologii, s. 49-55, 2004.
- [2] Wilson H.R., Cowan J.D.: Excitatory and inhibitory interactions in localized populations of model neurons. *Biophysics* 12, 1972, s. 1-24.
- [3] Tadeusiewicz R., et. all: *Neurocybernetyka teoretyczna*. Wydawnictwo Uniwersytetu Warszawskiego, Warszawa, 2009.
- [4] Delorme A., Kothe C., Bigdely N., Vankov A., Oostenveld R., Makeig S.: *Matlab Tools for BCI Research? Human-computer interaction and brain-computer interfaces*, Springer Publishing, 2010.
- [5] Delorme A., Sejnowski T., Makeig S.: Improved rejection of artifacts from EEG data using high-order statistics and independent component analysis. *Neuroimage* 34, s. 1443-1449, 2007.
- [6] Hung C., Lee P., Wu Y., Chen L., Yeh T., Hsieh J.: Recognition of Motor Imagery Electroencephalography Using Independent Component Analysis and Machine Classifiers. *Annals of Biomedical Engineering* Vol. 33, No. 8, s 1053-1070, 2005.
- [7] Meghdadi A.H., Fazel-Rezai R., Aghakhani Y.: Detecting determinism in EEG signals using principal component analysis and surrogate data testing. *IEEE Engineering in Medicine and Biology Society* 2006.
- [8] Paszkiewicz Sz., Zmarzły D., Kawala A., Szmechta M.: Zastosowanie pomiarów elektroencefalograficznych EEG w procesie uwierzytelniania biometrycznego użytkowników. *Miesięcznik naukowo-techniczny Pomiary, Automatyka, Kontrola*, Vol. 53, Warszawa, s. 433-436, 2009.