

Joanna GÓRECKA, Roman KASZYŃSKI  
POLITECHNIKA SZCZECIŃSKA, INSTYTUT AUTOMATYKI PRZEMYSŁOWEJ

## Usuwanie artefaktów z danych EEG przy użyciu analizy składowych niezależnych

Mgr inż. Joanna GÓRECKA

Absolwentka Wydziału Elektrycznego Politechniki Szczecińskiej-specjalność Inżynieria Biomedyczna i Akustyczna. Dyplom magistra inżyniera uzyskała w 2005 roku. Obecnie doktorantka w Zakładzie Teorii Sterowania i Techniki Symulacyjnych Politechniki Szczecińskiej. Zajmuje się zagadnieniami związanymi z analizą i przetwarzaniem sygnałów EEG.



e-mail: gorecka@ps.pl

### Streszczenie

Celem przedstawionych wyników badań jest eliminacja wybranych niepożądanych sygnałów przy użyciu analizy składowych niezależnych. W artykule przedstawiono następujące algorytmy BSS (z ang. Blind Signal Separation): HJ oraz Infomax jako narzędzia do separacji i usuwania wybranej grupy artefaktów (mrużenie powiek, artefakty mięśniowe) z przebiegów EEG. Jak udowodniono w eksperymentach proponowane algorytmy adaptacyjne mogą efektywnie wykrywać i usuwać wybrane artefakty z przebiegów EEG.

**Słowa kluczowe:** Ślepa separacja sygnałów, analiza składowych niezależnych (ICA), sygnały EEG, artefakty.

## Removal of artifacts from EEG data by means of Independent Component Analysis

### Abstract

The aim of the performed investigations is to remove selected undesired signals by means of ICA approach. In the paper there are presented the following algorithms BSS (Blind Signal Separation): HJ and Infomax for separation and removal of selected group of artifacts (eye blinks, muscle activity) from EEG recordings. It has been proved in the experiments which are described in the paper that the proposed adaptive algorithms can effectively detect and remove these selected artifacts from EEG recordings.

**Keywords:** Blind Signal Separation, Independent Component Analysis, EEG data, artifacts.

## 1. Wstęp

Elektroencefalografia jest metodą badania czynności elektrycznej mózgu. W trakcie wykonywania pomiarów sygnałów o tak małych amplitudach (rzędu  $100\mu\text{V}$ ) dokonuje się rejestracji zjawisk niepożądanych - artefaktów, które zniekształcają pobieraną informację. Obecność w zarejestrowanym sygnale EEG artefaktów pochodzących od mrużania powiek czy napięcia mięśni nie objawiają się charakterystyczną odmiennością zapisu, co powoduje pewne trudności w automatycznym zidentyfikowaniu tych zakłóceń. Ponadto sporadyczne potencjały mięśniowe często trudno jest odróżnić od iglic korowych. Dotyczy to zwłaszcza arytmicznych ruchów mimowolnych np. tików w obrębie mięśni twarzy a zwłaszcza w mięśniach czołowych, żwaczach czy skroniowych [1]. Z tych względów przedmiotem dalszych rozważań będą właśnie te artefakty.

Zarejestrowane z powierzchni czaszki przebiegi EEG zawierają sygnały pochodzenia mózgowego i pozamózgowego oraz pozamózgowe asymetrie zapisu, co umożliwia przedstawienie tego procesu rejestracji w postaci modelu zjawiska znanego w literaturze jako ślepa separacja sygnałów (ang. Blind Signal Separation – BSS). Ślepa separacja sygnałów to proces estymacji nieznanych sygnałów źródłowych na podstawie sygnałów rejestrowanych


Dr hab inż. Roman KASZYŃSKI

Profesor nadzwyczajny w Instytucie Automatyki Przemysłowej na Wydziale Elektrycznym PS. Studia ukończył w 1973 roku na Wydziale Elektrycznym PS na kierunku Elektrotechnika-specjalność Automatyka. Stopień doktora uzyskał w 1978 r. a doktora habilitowanego w 2002 na Wydziale Elektrycznym Politechniki Śląskiej w Gliwicach. Jego zainteresowania naukowe to zagadnienia na styku automatyki, metrologii i przetwarzania sygnałów ze szczególnym uwzględnieniem analizy i syntezy układów o zmiennych parametrach.



e-mail: romkasz@ps.pl

przez czujniki lub ekstrakcja niepożądanych sygnałów zakłócających celem ich późniejszej eliminacji. Ideę BSS przedstawiono na rys. 1.



Rys. 1. Ogólny schemat procesu ślepej separacji BSS

Fig. 1. General scheme of the blind separation process BSS

Jeżeli poszukiwane sygnały emitowane są przez kilka źródeł położonych w różnych punktach przestrzeni i rejestrowane przez zestaw czujników, to można założyć, że sygnały odbierane tworzą kombinacje liniowe sygnałów źródłowych w postaci [2]:

$$x(k) = \mathbf{H}s(k) + v(k), \quad (1)$$

gdzie:  $x(k) = [x_1(k), x_2(k), \dots, x_m(k)]^T$  - wektor obserwowanych sygnałów EEG,  $\mathbf{H} \in \mathbf{R}^{m \times n}$  - macierz mieszająca o wymiarach  $m \times n$ ,  $s(k) = [s_1(k), s_2(k), \dots, s_n(k)]^T$  - wektor źródłowych sygnałów EEG,  $v(k) = [v_1(k), v_2(k), \dots, v_m(k)]^T$  - wektor szumów addytywnych. W dalszej części artykułu dla uproszczenia rozważań szum addytywny  $v(k)$  został pominięty.

Jeżeli współczynniki macierzy mieszającej  $\mathbf{H}$  są znane i liczba sygnałów obserwowanych równa jest liczbie sygnałów źródłowych ( $m = n$ ), to zadanie separacji źródeł polega na odwróceniu macierzy mieszającej i pomnożeniu wektora sygnałów rejestrowanych przez wyznaczoną macierz odwrotną  $\mathbf{W}$ :

$$y(k) = \mathbf{W}x(k) \quad (2)$$

gdzie:  $y(k) = [y_1(k), y_2(k), \dots, y_n(k)]^T$  - wektor sygnałów wyjściowych,  $\mathbf{W} \in \mathbf{R}^{n \times n}$  - macierz separująca o wymiarach  $n \times n$ . W przypadku, gdy macierz mieszająca jest nieznana, należy ją wyznaczyć na podstawie sygnałów rejestrowanych.

## 2. Algorytmy adaptacyjne w zastosowaniu do detekcji i eliminacji artefaktów

Istnieje wiele rozwiązań problemu BSS. Wybór odpowiedniego algorytmu separacji uzależniony jest od rodzaju i własności staty-

stycznych poszukiwanych sygnałów źródłowych. W procesie separacji sygnałów EEG można wykorzystywać statystyki wyższych rzędów HOS (ang. Higher Order Statistics) oraz algorytm będący skutkiem połączeń HOS ze statystykami 2-go rzędu SOS (ang. Second Order Statistics). Założenie statystycznej niezależności zmiennych źródłowych umożliwia zastosowanie metody analizy składowych niezależnych ICA (ang. Independent Component Analysis), co prowadzi m.in. do adaptacyjnych algorytmów wyznaczania macierzy transformacji odwrotnej [3]. Technika ICA wymaga wstępnego przetworzenia – tzw. wybielenia sygnałów, czego można dokonać korzystając z analizy składników głównych PCA (ang. Principal Component Analysis), co pozwala już na wstępie usunąć pewną część niepożądanych komponentów.

Do najczęściej stosowanych separatorów zalicza się algorytm bazujące na metodach algebry tensorowej (Cardoso): FOBI (ang. Fourth Order Blind Identification) oraz jego pochodne: FOBI-E (ang. Fourth Order Blind Identification with Transformation matrix E), JADE (ang. Joint Adaptive Diagonalization of Eigenmatrices), JADE TD (ang. Joint Adaptive Diagonalization of Eigenmatrices with Time Delay), ERICA (ang. Extended Robust ICA) [2, 4, 5].

W celu dokonania eliminacji wybranych artefaktów zaproponowano użycie dwóch algorytmów: HJ oraz Infomax.

Pierwszy algorytm ślepej separacji sygnałów niezależnych - algorytm HJ (Herault i Jutten, 1986) wykorzystuje architekturę sieci neuronowej liniowej ze sprzężeniem zwrotnym. Reguła uczenia dla tego algorytmu dana jest następującą zależnością macierzową [6]:

$$\frac{d\mathbf{W}}{dt} = \eta(t)\mathbf{g}(\mathbf{y}(t))\mathbf{h}(\mathbf{y}(t)) \quad (3)$$

gdzie:  $\mathbf{W}$  - macierz separująca (wagowa)  $\mathbf{W} \in \mathbf{R}^{n \times n}$  taka, że:

$$\mathbf{W} = \begin{bmatrix} 0 & w_{12} & \dots & w_{1n} \\ w_{21} & 0 & \dots & w_{2n} \\ \dots & \dots & \dots & \dots \\ w_{n1} & w_{n2} & \dots & 0 \end{bmatrix} \quad (4)$$

$g(\cdot)$  oraz  $h(\cdot)$  - różne nieparzyste funkcje nieliniowe,  $\eta$  - współczynnik uczenia.

Zależności między rozkładami prawdopodobieństwa poszukiwanych sygnałów źródłowych a wyborem funkcji nieliniowych nie zostały jednoznacznie określone. W praktyce funkcje te są tak dobierane, aby jedna z nich była typu wypukłego zaś druga typu wklęsłego. Z kolei współczynnik uczenia zazwyczaj jest funkcją, która na początku przyjmuje wartości stałe a następnie maleje wykładniczo do zera w funkcji czasu adaptacji [3, 6].

Nowym podejściem do zagadnienia analizy składowych niezależnych było zaproponowanie (Bell i Sejnowski, 1995) adaptacyjnego algorytmu opartego na kryterium Infomax, który dokonywał minimalizacji wspólnej informacji zmiennych losowych  $X$  i  $Y$  celem wyizolowania składowych statystycznie niezależnych [7]. Jeżeli za kryterium separacji zostanie przyjęty współczynnik ekscesu [8], to do konstrukcji sieci neuronowej realizującej ten algorytm można wykorzystać reguły uczenia Hebba:

$$w(t+1) = w(t) + \mu(t)[x(t)g(w(t)^T x(t)) - w(t)] \quad (5)$$

oraz reguły antyhebbowskie (dekorelacyjne):

$$w(t+1) = w(t) + \mu(t)[-x(t)g(w(t)^T x(t)) - w(t)] \quad (6)$$

gdzie:  $\mu(t)$  - stała uczenia zmienna w czasie,  $g(\cdot)$  - funkcja nieliniowa. Warto dodać, że w tym przypadku składowe o gaussowskim rozkładzie prawdopodobieństwa nie będą wydzielone, ponieważ uczenie hebbowskie umożliwia separację składowych


tylko o ekscesie ujemnym, zaś uczenie dekorrelacyjne separuje dane o ekscesie dodatnim. Uogólniona reguła adaptacyjna Infomax przyjmie zatem postać [8]:

$$w(t+1) = w(t) + \mu(t)[\phi x(t)g(w(t)^T x(t)) - w(t)] \quad (7)$$

dla której  $\phi$  - określa znak ekscesu separowanej składowej.


### 3. Opis eksperymentu

Prezentowane wyniki symulacji komputerowej wykonano przy użyciu programów: Matlab [9], EEGLAB [10] oraz ICALAB [11]. Badania przeprowadzono korzystając z plików bazy danych BIOSIG [12] zawierających przebiegi EEG (rys.2) oraz zbiór typowych artefaktów (rys.3). W celu sprawdzenia skuteczności eliminacji wybranych artefaktów znane sygnały źródłowe poddano procesowi mieszania macierzą pełnego rzędu  $n \times n$  (założono, że liczba sygnałów obserwowanych jest równa liczbie sygnałów źródłowych oraz liniowość kombinacji tych sygnałów) dla której  $\det(H) = 67,7567$ . Na zakończenie do odpowiednich kanałów dodano artefakty: (T3, T4, T6, O2) - artefakty mięśniowe; (F3, F4) - artefakty z mrukania [1].



Rys. 2. Przykładowy zapis EEG z uwzględnieniem artefaktów mięśniowych i z mrukania

Fig. 2. An example of EEG data with muscle artifacts and eye movements artifacts



Rys. 3. Artefakty: a) z mrukania (1÷2,5) Hz; b) mięśniowe (20÷60) Hz  
Fig. 3. Artifacts: a) eye movement (1÷2,5) Hz; b) muscle (20÷60) Hz

Podczas przeprowadzania symulacji komputerowych dla algorytmu HJ wykorzystano funkcje nieliniowe:  $g(x) = x^3$  oraz  $h(x) = \arctg(x)$ , zaś współczynnik uczenia został zmieniany adaptacyjnie przy wartości startowej równej 3000. Z kolei dla algorytmu Infomax zakładając, że poszukiwane sygnały mają rozkład super-gaussowski, wykorzystano następującą regułę uczenia [7]:

$$\Delta \mathbf{W} = -\mu \left( \frac{\partial \mathbf{H}(\mathbf{Y})}{\partial \mathbf{W}} \right) \mathbf{W}^T \mathbf{W} = \mu (\mathbf{I} + \hat{\mathbf{y}} \mathbf{u}^T) \mathbf{W} \quad (8)$$

gdzie:  $\mu = 0,01$ ,  $\mathbf{H}(\mathbf{Y})$  - entropia sygnału,  $\mathbf{U} = \mathbf{U}(t)$  - estymata wektora źródłowego taka, że  $\mathbf{Y} = \mathbf{g}(\mathbf{U}) = \mathbf{g}(\mathbf{W}\mathbf{H}\mathbf{S})$ , sigmoidalna

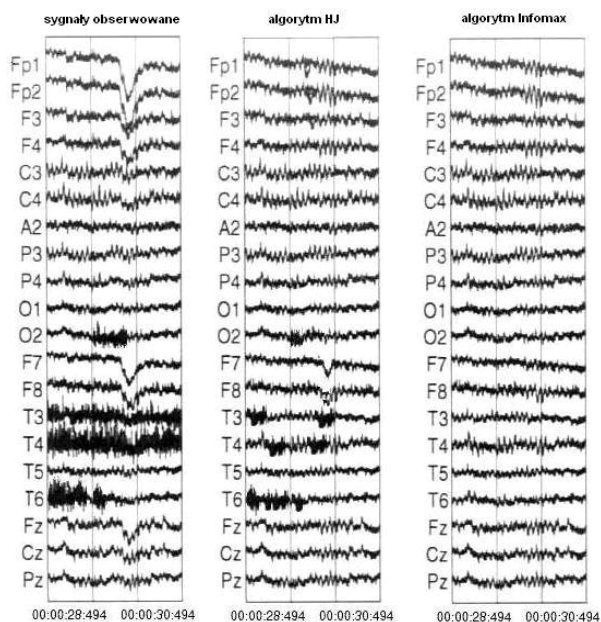
funkcja aktywacji:  $g(u_i) = \frac{1}{1 + e^{-u_i}}$ ,  $\hat{y}_i = \frac{\partial}{\partial u_i} \ln \left( \frac{\partial y_i}{\partial u_i} \right)$ . Skuteczność

eliminacji tych artefaktów wybranymi algorytmami BSS poddano ocenie wizualnej wykorzystując do tego celu przebiegi sygnału błędu  $\varepsilon_n(t)$  wygenerowane dla odpowiednich kanałów:

$$\varepsilon_n(t) = \sum_{n=1}^m [y_n(t) - s_n(t)] \quad (9)$$

#### 4. Wyniki badań symulacyjnych

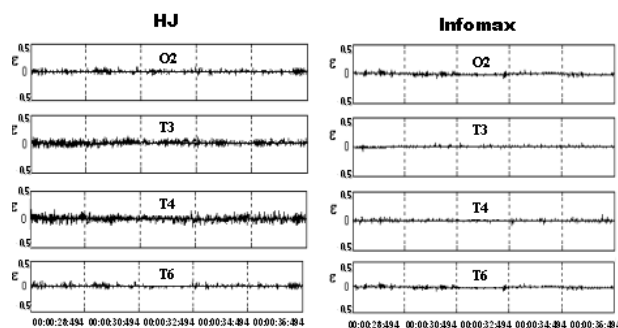
Na rys. 4 przedstawiono wyniki symulacji przeprowadzonej dla dwóch algorytmów BSS: HJ oraz Infomax, której celem była eliminacja odpowiednio wygenerowanych artefaktów.




Rys. 4. 2-sekundowy zapis „zasmurowanych” przebiegów EEG (sygnały obserwowane) i ich „filtracja” dwoma algorytmami: HJ oraz Infomax  
Fig. 4. A 2-second record of „noisy” EEG data (observed signals) and their „filtering” with two algorithms: HJ and Infomax

Algorytm HJ, pomimo wielu zalet (łatwy w implementacji, dobra zbieżność, wysoka skuteczność separacji dla sygnałów mowy) niestety jest wrażliwy na duże różnice w amplitudach sygnałów odbieranych, co w zastosowaniu do przebiegów EEG powoduje problemy z separacją sygnałów o mniejszych amplitudach a tym samym niedokładne oddzielenie artefaktów od pożądanych przebiegów.

Dokładniejszy obraz efektów działania wybranych algorytmów w poszczególnych kanałach przedstawiają rys. 5 i 6. Przebiegi sygnału błędu w dziedzinie czasu obrazują różnicę pomiędzy przebiegami wyjściowymi, czyli poddanymi działaniu wybranych algorytmów celem usunięcia niepożądanych sygnałów a sygnałami źródłowymi. W idealnym przypadku, gdyby nastąpiła całkowita eliminacja artefaktów, sygnał błędu  $\varepsilon_n(t)$  powinien osiągnąć poziom 0. Niestety w żadnym z przypadków (HJ, Infomax) nie udało się uzyskać takiego stanu, choć nastąpiło znaczne ograniczenie występowania tych niepożądanych komponentów, co ilustrują poniższe rysunki.



Rys. 5. Jakość eliminacji artefaktów mięśniowych dla dwóch algorytmów: HJ oraz Infomax dla różnych kanałów  
Fig. 5. The quality of removing muscle artifacts for two algorithms: HJ and Infomax for different channels



Rys. 6. Jakość eliminacji artefaktów z mrukania powiek dla dwóch algorytmów: HJ oraz Infomax dla różnych kanałów  
Fig. 6. The quality of removing eye movement artifacts for two algorithms: HJ and Infomax for different channels

Większą skuteczność w eliminacji zarówno artefaktów pochodzenia mięśniowego jak i z mrukania wykazał algorytm Infomax.

#### 5. Wnioski

W przeprowadzonych badaniach symulacyjnych zaproponowano wykorzystanie algorytmów BSS jako narzędzia do wstępnego przetwarzania sygnałów EEG. Na podstawie dwóch typowych algorytmów adaptacyjnych przedstawiono problem ślepej separacji dla przebiegów EEG w otoczeniu charakterystycznych dla tego typu sygnałów zakłóceń zwanych artefaktami.

Podczas badania testowano skuteczność przeprowadzania separacji wybranymi algorytmami, co miało umożliwić eliminację wskazanych artefaktów. W tym celu dokonano sztucznego mieszania znanych sygnałów i znanych artefaktów, co umożliwiło uzyskanie sygnałów wyjściowych, które po przeprowadzeniu procesu separacji powinny stanowić odwzorowanie sygnałów źródłowych. W praktyce metoda BSS zakłada pewien stopień niewiedzy o sygnałach źródłowych oraz systemie mieszającym i na podstawie tak przyjętych założeń dokonuje się procesu separacji. W prezentowanych przykładach uzyskano zadowalające efekty separacji prowadzące do częściowej eliminacji komponentów niepożądanych bez naruszania struktury sygnałów pożądanych, co w przypadku sygnałów zawierających odcinki o ostrym lub iglicowym kształcie istotnie wpływa na interpretację uzyska-

nych wyników pomiarowych, gdyż część z tych składowych może mieć charakter padaczkorodny.

Warto dodać, że w przypadku zastosowania standardowej filtracji podczas przeprowadzania rejestracji fal mózgowych w obecności artefaktów pochodzenia mięśniowego można dokonać błędnego usunięcia wybranych istotnych komponentów analizowanych fal, czego nie zauważono przy algorytmach BSS. Z tych względów algorytmy BSS mogą być wykorzystywane do redukcji artefaktów, detekcji i estymacji sygnałów EEG oraz ekstrakcji ich cech charakterystycznych mających znaczenie głównie diagnostyczne (np. iglice, fale delta, wrzeciona) w oparciu o zależności korelacyjne. Ponadto, przy standardowej filtracji, zdarzają się problemy nie tylko z identyfikacją właśnie tych artefaktów, ale również czynności fal beta. Pojawiają się także problemy z różnieniem pochodzenia (mózgowego od mięśniowego) iglicy towarzyszącej skurczom mioklonicznym, czego nie odnotowano podczas używania do filtracji algorytmów BSS.

Artykuł powstał w ramach projektu badawczego promotorskiego MNiSW nr N N518 335035.

## 6. Literatura

[1] J. Majkowski (Red.): Elektroencefalografia kliniczna, Państwowy Zakład Wydawnictw Lekarskich, Warszawa 1986

- [2] A. Cichocki, S. Amari: Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications, Wiley 2003
- [3] S. Osowski: Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006
- [4] A. Hyvärinen, J. Karhunen, E. Oja: Independent Component Analysis, John Wiley&Sons, 2001
- [5] S. I. Amari, A. Cichocki, H. Yang: A new learning algorithm for blind signal separation, Advances in Neural Information Processing Systems, 8:757-763, 1996
- [6] C. Jutten, J. Hérault: Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic architecture, Signal Processing, 24:1-10, 1991
- [7] A. J. Bell, T. J. Sejnowski: An information - maximization approach to blind separation and blind deconvolution, Neural Computation, 7:1129 -1159, 1995
- [8] M. Girolami: Self - organizing artificial neural network for signal separation, Phd thesis, Department of Computing and Information Systems, Paisley University, Scotland 1997
- [9] <http://www.mathworks.com/>
- [10] <http://sccn.ucsd.edu/eeglab/>
- [11] A. Cichocki, S. Amari, K. Siwek, T. Tanaka, Anh Huy Phan: ICALAB Toolboxes, <http://www.bsp.brain.riken.jp/ICALAB>
- [12] <http://biosig.sourceforge.net/index.html>

*Artykuł recenzowany*

## INFORMACJE

# Studia Podyplomowe

Wydział Elektryczny Politechniki Śląskiej w Gliwicach, Instytut Metrologii, Elektroniki i Automatyki ogłasza nabór na Dwusemestralne Zaoczne Studia Podyplomowe

## Organizacja i Akredytacja Laboratoriów

Studia prowadzone są na Wydziale Elektrycznym Politechniki Śląskiej w Gliwicach, w systemie zaocznym w każdą sobotę lub w co drugi weekend (do wyboru) przez dwa semestry. Zajęcia prowadzone są przez nauczycieli akademickich ze stopniem co najmniej doktora oraz przez zaproszonych Gości o uznanym dorobku i autorytecie. Studia obejmują 200 godzin dydaktycznych. Rozpoczęcie Studiów nastąpi po skompletowaniu odpowiedniej liczby kandydatów na dany rodzaj studiów.

### Organizator studiów:

Instytut Metrologii, Elektroniki i Automatyki Politechniki Śląskiej, 44-100 Gliwice, ul. Akademicka 10, tel. 032 237 12 41, fax: 032 237 20 34, e-mail: [re2@polsl.pl](mailto:re2@polsl.pl) lub [agnieszka.skorkowska@polsl.pl](mailto:agnieszka.skorkowska@polsl.pl), <http://imeia.elekt.polsl.pl>

### Kierownik studiów:

Prof. dr hab. inż. Tadeusz SKUBIS