

Marcin JUKIEWICZ\*\*  
Mikołaj BUCHWALD\*\*  
Anna CYSEWSKA-SOBUSIAK\*

## USUWANIE ARTEFAKTÓW Z SYGNAŁÓW STERUJĄCYCH INTERFEJSEM MÓZG-KOMPUTER

Elektroencefalografia jest metodą pozwalającą na pomiar elektrycznej aktywności mózgu. Metoda ta jest wykorzystywana do diagnostyki pracy mózgu oraz w tzw. interfejsach mózg-komputer, czyli urządzeniach pozwalających na bezpośrednią komunikację pomiędzy mózgiem a jednostką obliczeniową. Interfejsy takie tworzone są głównie z myślą o osobach częściowo sparaliżowanych lub dotkniętych syndromem zamknięcia. Jednym ze zjawisk zachodzącym w mózgu, wykorzystywanym w interfejsach mózg-komputer, są Wzrokowe Potencjały Wywołane Stanu Ustalonego SSVEP (*Steady State Visually Evoked Potentials*). Jeśli osoba badana obserwuje bodziec, migający z określoną częstotliwością, to sygnał o tej samej częstotliwości (dominującej) zostanie zmierzony nad korą wzrokową. W takich urządzeniach bardzo istotne jest przetwarzanie zmierzonego sygnału w taki sposób, aby zapewnić jak największą skuteczność rozpoznania na co w danej chwili patrzy osoba badana. Jednym ze sposobów na osiągnięcie tego celu może być wykorzystanie Ślepej Separacji Sygnałów BSS (*Blind Source Separation*), której celem jest znalezienie i usunięcie z mierzonych sygnałów niepożądanych składowych, np. związanych z mrugnięciami oczu czy napinaniem mięśni twarzy. W prezentowanym artykule zostały umówione sposoby wykorzystania Ślepej Separacji Sygnałów w badaniach elektroencefalograficznych nad Wzrokowymi Potencjalami Wywołanymi Stanu Ustalonego. Przedstawiono także wyniki skuteczności rozpoznania intencji badanego w zależności od liczby usuniętych składowych, rodzaju algorytmu Ślepej Separacji Sygnału i sposobu klasyfikacji sygnału.

SŁOWA KLUCZOWE: interfejs mózg-komputer, potencjały wywołane, SSVEP, BSS, FastICA, AMUSE, Infomax, MATLAB, Python

### 1. WPROWADZENIE

Interfejs mózg-komputer BCI (*Brain-Computer Interface*) to urządzenie, które pozwala osobom sparaliżowanym sterować np. robotem, protezą bądź wózkiem inwalidzkim wykorzystując jedynie reakcje ich własnego mózgu.

---

\* Politechnika Poznańska.

\*\* Uniwersytet im. Adama Mickiewicza w Poznaniu.

Rozwiązanie takie pozwala zatem na przełożenie intencji człowieka na sygnały sterujące, tworząc bezpośrednią ścieżkę komunikacji pomiędzy ludzkim mózgiem a urządzeniami zewnętrznymi bez udziału mięśni i obwodowego układu nerwowego. Za jeden z głównych celów badań nad BCI uważa się umożliwienie komunikacji z otoczeniem pacjentom częściowo sparalizowanym lub dotkniętym tzw. syndromem zamknięcia LIS (*locked-in syndrome*) [5].

Zasada działania interfejsów mózg-komputer, wykorzystujących do pomiaru elektroencefalograf (EEG), polega na analizie potencjałów wywołanych. Jednym z wykorzystywanych zjawisk jest SSVEP (*Steady State Visual Evoked Potential*). Jest to reakcja, która występuje podczas "wpatrywania się" w bodziec migający z określoną częstotliwością. Wówczas nad korą wzrokową w mózgu pojawia się sygnał o tej samej, dominującej częstotliwości. W sytuacji, kiedy bodźców jest więcej i każdy pulsuje z inną częstotliwością, można stwierdzić, na który z obiektów w danym momencie osoba badana spogląda [5, 10, 11, 12].

Najlepszą sytuacją jest taka, w której analizowany jest sygnał pochodzący tylko z kory wzrokowej bez żadnych dodatkowych składowych czy zakłóceń. Przy takich idealistycznych założeniach można liczyć na skuteczniejsze rozpoznawanie (przez komputer) na co w danej chwili patrzy osoba badana. Niestety w praktyce badawczej trzeba liczyć się z różnego rodzaju zakłóceniami. W zasadzie nigdy nie zdarza się sytuacja, w której ma się do czynienia wyłącznie z sygnałami pochodzącymi z mózgu. Trzeba zatem poszukiwać sposobów na radzenie sobie ze wspomnianymi źródłami niepożądanego wariacji.

## 2. ŚLEPA SEPARACJA SYGNAŁÓW

Ślepa separacja sygnałów BSS (*Blind Source Separation*) jest to estymacja nieznanymi sygnałów źródłowych na podstawie sygnałów rejestrowanych lub ekstrakcja sygnałów zakłócających, celem ich późniejszej eliminacji.

Przyjęto, że nieznanymi sygnałami źródłowymi są wzajemnie niezależne  $s^i(t)$ , gdzie  $i = 1, \dots, n$ , a sygnałem rejestrowanym jest:

$$x(t) = As(t) \quad (1)$$

gdzie:  $A \in R^{n \times n}$  jest nieznaną, nieosobliwą macierzą mieszającą o wymiarach  $n \times n$ ,  $s(t) = [s^1(t), \dots, s^n(t)]^T$  oraz  $x(t) = [x^1(t), \dots, x^n(t)]^T$ . Aby poznać sygnały źródłowe, należy dokonać następującej transformacji sygnałów obserwowanych  $x(t)$ :

$$y(t) = Wx(t) \quad (2)$$

gdzie:  $y(t) = [y^1(t), \dots, y^n(t)]^T$ , a  $W \in R^{n \times n}$  jest macierzą separującą [1, 4].

Źródłem artefaktów, tj. składowych niepożądanych w zapisie sygnału EEG, mogą być: praca serca, ruch oczu (mrugnięcia), mimika (ruchy mięśni twarzy), ruch szczęki lub przełykanie oraz ruch klatki piersiowej podczas oddychania. Ponadto na wartość sygnału mierzonego poza aktywnością mózgu w miejscu pomiaru składają się sygnały pochodzące z innych obszarów mózgu oraz inne zakłócenia spoza organizmu. Algorytmy ślepej separacji sygnałów w badaniach związanych z EEG mają na celu możliwe jak najdokładniejsze usunięcie wspomnianych artefaktów, aby w dalszych krokach analizy sygnału przetwarzać jedynie sygnały pochodzące z interesujących badacza obszarów kory mózgowej.

### 3. PRZEPROWADZONE POMIARY

Do przygotowania zbioru analizowanych sygnałów przeprowadzono badania z udziałem 4 osób. Każdej z nich montowano na głowie czepek EEG ze 128 aktywnymi elektrodami. Do dalszej analizy wykorzystano jednak jedynie elektrody montowane nad korą wzrokową – O1, O2, Oz, PO7, PO8, POz oraz jedną na czole – FPz (razem siedem elektrod). Wszystkie oznaczenia są zgodne z międzynarodowym standardem montowania elektrod 10–20 [2, 9].

Osoba badana obserwowana na 21-calowym monitorze CRT szachownicy migające z częstotliwością 8 lub 14 Hz. Każda z częstotliwości była prezentowana 5-krotnie. Czas prezentacji bodźca wynosił 15 s. Pomiedzy kolejnymi prezentacjami bodźca, badana osoba odpoczywała. Sygnał był próbkowany z częstotliwością 256 Hz.

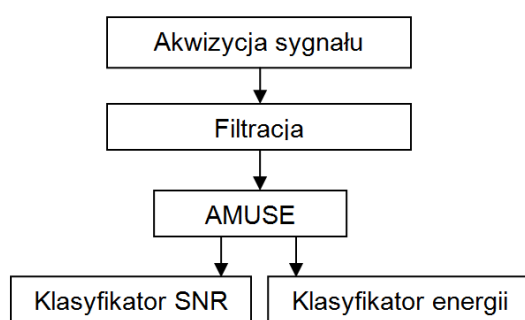
Sygnał po akwizycji został przetworzony za pomocą filtru pasmowo-przepustowego Butterwortha czwartego rzędu w zakresie od 1 do 40 Hz. W kolejnym kroku zbiór danych był poddawany działaniu jednego z czterech algorytmów Ślepej Separacji Sygnałów: „AMUSE”, „FastICA”, „Infomax” oraz „Extended Infomax” [3, 7, 9].

Następnie otrzymane sygnały były klasyfikowane, tj. komputer rozpoznawał na jaki bodźce w danej chwili patrzyła osoba badana. Wykorzystano dwa proste klasyfikatory: analizujący współczynnik SNR (*Signal-to-Noise Ratio*) dwóch składowych 8 i 14 Hz (na rys. 1 „klasyfikator SNR”) oraz klasyfikator analizujący energię sygnału w pasmach: od 7,8 do 8,2 Hz oraz od 13,8 do 14,2 Hz (na rys. 1 „klasyfikator energii”) [11, 12]. W zależności od tego, który z dwóch współczynników SNR lub która z dwóch wartości energii była wyższa, tak klasyfikowano dany bodziec [2, 9].

Na rys. 1 przedstawiono schemat przetwarzania sygnału na przykładzie algorytmu AMUSE, przy czym struktura schematu jest taka sama również dla pozostałych trzech algorytmów.

Dla każdego z analizowanych algorytmów klasyfikowano 10 różnych przypadków, w zależności od tego, które składowe sygnału usunięto. W tabeli 1 zestawiono te przypadki i usuwane składowe.

Do przeprowadzenia obliczeń wykorzystano pakiet MNE-Python wzbogacony o algorytm AMUSE. W okresie wykonywania analiz w styczniu 2017 roku, pakiet ten oferował Ślepą Separację Sygnału wyłącznie w oparciu o FastICA, Infomax oraz Extended Infomax [6].



Rys. 1. Przykładowy schemat przetwarzania sygnału dla kolejnych algorytmów ślepej separacji sygnałów


Tabela 1. Analizowane przypadki usunięcia składowych sygnału

Lp.	Nr usuniętej składowej
1	0
2	0, 1, 2, 5, 6
3	0, 1, 2, 6
4	0, 1, 5, 6
5	0, 1, 6
6	0, 2, 3, 4, 6
7	0, 2, 4, 6
8	0, 4, 6
9	0, 5, 6
10	0, 6

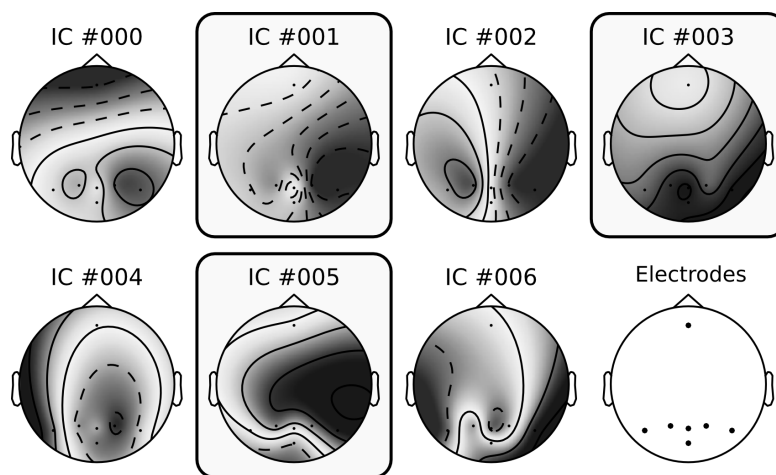
#### 4. WYNIKI POMIARÓW

Na rys. 2 przedstawiono sygnał zarejestrowany za pomocą elektrody O1, z którego usunięto pierwszą i ostatnią składową, poddany przetworzeniu przez cztery analizowane algorytmy. Na rys. 3 są widoczne przykładowe składowe statystycznie niezależne IC (*Independent Components*) uzyskane za pomocą algorytmu AMUSE (jest ich siedem – liczba ta odpowiada liczbie elektrod, z których pochodził analizowany sygnał). Jak wykazały analizy, głównie

składowe 1, 3 oraz 5 (w zaokrąglonych ramkach) niosą informacje istotne z punktu widzenia klasyfikacji sygnałów SSVEP. Pozostałe składowe to szum, który należy usunąć przed podjęciem dalszych analiz.



Rys. 2. Sygnał zarejestrowany z elektrody O1: A) nie poddany działaniu algorytmu ślepej separacji sygnału (widocznie zarysowane artefakty wynikające z mrukania); B) otrzymany przy użyciu algorytmu AMUSE; C) otrzymany za pomocą algorytmu FastICA; D) otrzymany przy użyciu algorytmu Infomax; E) otrzymany przy użyciu algorytmu Extended Infomax



Rys. 3. Przykładowe składowe niezależne uzyskane z sześciu elektrod na korze wzrokowej: O1, O2, Oz, PO7, PO8, POz oraz jednej czołowej – FPz.

W ramach przeprowadzonych badań oceniano również skuteczność klasyfikacji sygnału w zależności od typu użytego algorytmu oraz czasu ekspozycji bodźca (od 1 do 15 s).

Aby określić, który z algorytmów uzyskał najlepsze rezultaty, dla każdego z nich oraz dla każdej z 10 kombinacji usuniętych składowych wykreślono krzywe przedstawione na rys. 4 i 5. Następnie, wyznaczono pola pod otrzymanymi krzywymi. Im większe pole, tym wyższa jest skuteczność oraz krótszy czas potrzebny na zadowalającą (z założenia większą niż 80%) poprawność klasyfikacji. Otrzymane wyniki zestawiono w tabeli 2. Ostatni wiersz tabeli zawiera odniesienie, tj. pole uzyskane pod krzywą, która została wyznaczona na podstawie klasyfikowania sygnału niepoddanego działaniu żadnego algorytmu ślepej separacji sygnału.

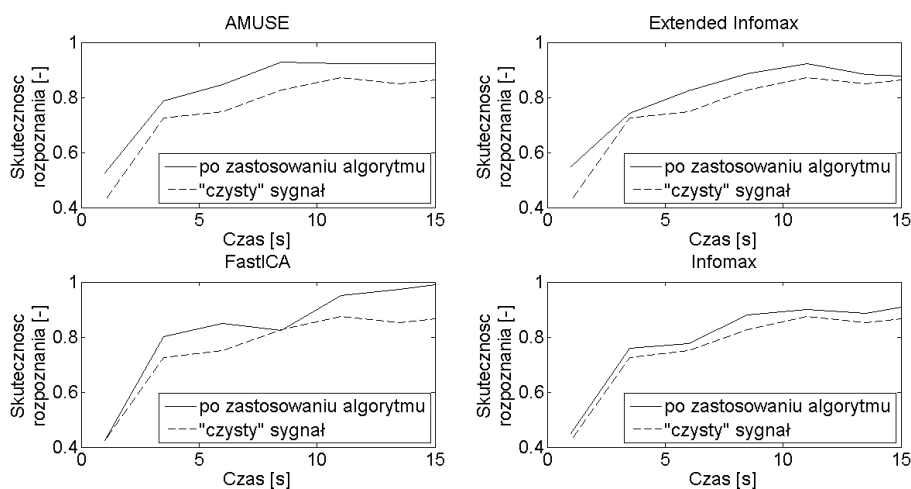
Tabela 2. Zestawienie wartości pola pod krzywą klasyfikacji dla każdego z algorytmów oraz sposobów klasyfikacji sygnału

Numer usuniętej składowej	SNR				ENERGIA			
	AMUSE	Extended Infomax	Fast ICA	Infomax	AMUSE	Extended Infomax	Fast ICA	Infomax
0	12,40	11,75	11,62	11,85	11,38	11,00	10,93	11,00
0, 1, 2, 5, 6	11,40	11,40	12,43	10,10	10,90	10,90	11,55	10,13
0, 1, 2, 6	11,48	<b>12,30</b>	<b>12,48</b>	10,28	10,13	11,68	12,30	10,30
0, 1, 5, 6	12,00	12,00	12,25	11,68	11,53	11,53	11,75	11,05
0, 1, 6	12,30	12,30	12,20	11,88	11,38	11,38	11,95	10,95
0, 2, 3, 4, 6	12,15	11,78	11,58	11,55	11,83	11,83	11,20	11,43
0, 2, 4, 6	<b>12,58</b>	11,68	11,80	10,93	12,48	<b>11,98</b>	<b>12,30</b>	<b>11,58</b>
0, 4, 6	12,38	11,88	12,00	11,93	<b>12,63</b>	11,33	11,18	11,55
0, 5, 6	12,10	11,88	12,125	11,65	11,75	10,93	11,67	11,20
0,6	12,08	11,83	12,10	<b>12,03</b>	11,53	11,18	11,45	11,25
Bez BSS	11,4				10,65			

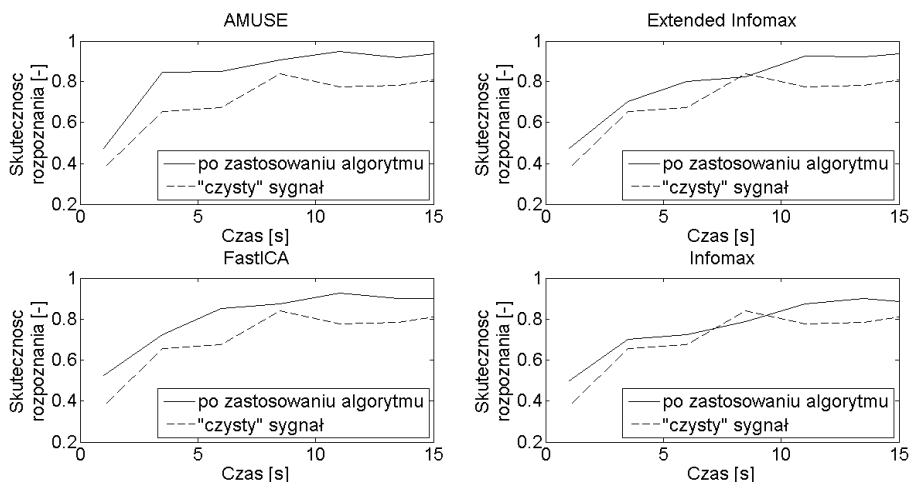
W 90% przypadków uzyskano wyniki lepsze niż wynik odniesienia. Przeprowadzono test t istotności różnic. W każdym przypadku różnice w wynikach klasyfikacji pomiędzy sygnałami nie poddanymi działaniu ślepej separacji sygnału a tymi, dla których użyto algorytmów BSS okazały się istotne statystycznie ( $p < 0,05$ ). Oznacza to, że pomiędzy uzyskanymi wynikami są znaczące różnice, a lepsze rezultaty klasyfikacji zostały otrzymane, gdy sygnały były poddawane działaniu algorytmów ślepej separacji sygnału. W teście statystycznym ANOVA porównano wyniki uzyskane przy wykorzystaniu wszystkich algorytmów, aby sprawdzić, który z nich osiągnął statystycznie istotne najlepsze rezultaty. Na podstawie wyników testu można stwierdzić, że

nie ma różnic statystycznych pomiędzy wynikami otrzymanymi przez kolejne algorytmy.

W tabeli 2 pogrubioną czcionką zaznaczono największą wartość pola pod krzywą dla każdego z algorytmów. Na rysunkach 4 i 5 przedstawiono krzywe najlepszych uzyskanych wyników (linią ciągłą) oraz krzywe odniesienia (linią przerywaną) dla klasyfikatora wykorzystującego SNR oraz klasyfikatora wykorzystującego energię sygnału.



Rys. 4. Krzywe klasyfikacji dla 4 algorytmów ślepej separacji sygnałów oraz klasyfikatora SNR



Rys. 5. Krzywe klasyfikacji dla 4 algorytmów ślepej separacji sygnałów oraz klasyfikatora energii

W tabeli 3 zestawiono wartości skuteczności klasyfikacji, która jest podsumowaniem rys. 4 oraz rys. 5, dla wszystkich algorytmów ślepej separacji sygnałów i sposobów klasyfikacji sygnału dla najkrótszego (1 s) i najdłuższego (15 s) czasu akwizycji danych.

Tabela 3. Zestawienie wartości skuteczności klasyfikacji dla wszystkich algorytmów ślepej separacji sygnałów i sposobów klasyfikacji oraz dwóch czasów akwizycji sygnału

Czas [s]	SNR				ENERGIA			
	AMUSE	Extended Infomax	FastICA	Infomax	AMUSE	Extended Infomax	FastICA	Infomax
1	52,5%	55,0%	42,5%	45,0%	47,5%	47,5%	52,5%	50,0%
15	92,5%	87,5%	100%	92,5%	95,0%	95,0%	90,0%	87,5%

## 5. PODSUMOWANIE

W artykule przedstawiono wyniki uzyskane w ramach badań dotyczących usuwania artefaktów z sygnału EEG pozyskanego z powierzchni głowy osoby badanej. Sygnały tego typu, np. SSVEP, mogą być wykorzystywane do sterowania interfejsem mózg-komputer. W niniejszym artykule zakłócenia nie pochodzące z mózgu (czyli artefakty) były niwelowane za pomocą algorytmów ślepej separacji sygnału. Porównano cztery algorytmy: AMUSE, Infomax, Extended Infomax oraz FastICA. Do walidacji uzyskanych rezultatów wykorzystano dwa klasyfikatory. Pierwszy z nich do klasyfikacji wykorzystywał współczynnik SNR, drugi wyznaczoną wartość energii sygnału. Otrzymane rezultaty przeanalizowano także ze względu na występowanie różnic istotnych statystycznie. Na podstawie analizy statystycznej udało się stwierdzić, że lepsze rezultaty klasyfikacji uzyskuje się w tych przypadkach, w których zastosowano algorytmy ślepej separacji sygnałów.

We wcześniejszych pracach wspomniano o możliwości wykorzystania ślepej separacji sygnałów w interfejsach mózg-komputer wykorzystujących zjawisko SSVEP. Brakuje jednak porównań między algorytmami i odpowiedzi na pytanie czy zawsze należy korzystać z tych algorytmów (czy zawsze poprawiają skuteczność rozpoznania bodźca) oraz który z algorytmów wybrać.

Otrzymane przez autorów rezultaty są bardzo obiecujące. Na ich podstawie można stwierdzić, że użycie algorytmów ślepej separacji sygnałów można i powinno się implementować w interfejsach mózg-komputer wykorzystujących zjawisko SSVEP, ponieważ mają one istotny wpływ na zwiększenie skuteczności rozpoznania na co w danej chwili patrzy osoba badana. Otrzymane



wyniki pokazały również, iż żaden z zastosowanych algorytmów nie osiągnął statystycznie lepszych rezultatów niż pozostałe.

W dalszych badaniach warto wziąć pod uwagę większą liczbę algorytmów oraz rozszerzyć grupę osób badanych. Dzięki temu można będzie z większą dozą pewności stwierdzić, czy istnieje jeden, najlepszy sposób estymacji źródeł w ramach ślepej separacji sygnału (być może pewna klasa algorytmów jest lepsza dla konkretnego typu danych) oraz czy zawsze warto zastosować określony algorytm, by nie pogorszyć poziomu klasyfikacji sygnałów.

### LITERATURA

- [1] Amari, S., Cichocki, A., Hua Yang, H., A new learning algorithm for blind signal separation. *Advances in Neural Information Processing Systems*, 1996, s. 757–763.
- [2] Bakardjian H., Tanaka T., Cichocki A., Optimization of SSVEP brain responses with application to eight-command brain-computer interface. *Neuroscience Letters*, vol. 469, no. 1, 2010, s. 34–38.
- [3] Bell, A.J., Sejnowski, T.J., An information-maximization approach to blind separation and blind deconvolution. *Neural Computation*, 7(6), 1995, s. 1129–1159.
- [4] Cichocki, A., Amari S., Adaptive blind signal and image processing: learning algorithms and applications. Vol. 1. John Wiley & Sons, 2002.
- [5] Graimann, B., Allison, B., Pfurtscheller, G., Brain-computer interfaces: A gentle introduction. In *Brain-Computer Interfaces*. Springer Berlin Heidelberg, 2010.
- [6] Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., Hämäläinen, M., MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*, 7, 267, 2013.
- [7] Hyvarinen, A., Fast and robust fixed-point algorithms for independent component analysis. *IEEE Transactions on Neural Networks*, 10(3), 1999, s. 626–634.
- [8] Lee, T.W., Girolami, M., Sejnowski, T.J., Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural Computation*, 11(2), 1999, s. 417–441.
- [9] Martinez, P., Bakardjian, H., Cichocki, A., Multi-command real-time brain machine interface using SSVEP: feasibility study for occipital and forehead sensor locations. In *Advances in Cognitive Neurodynamics ICCN 2007* (s. 783–786). Springer Netherlands, 2008.
- [10] Vialatte, F.B., Maurice, M., Dauwels, J., Cichocki, A., Steady-state visually evoked potentials: focus on essential paradigms and future perspectives. *Progress in Neurobiology*, 90(4), 2010.
- [11] Wang, Y., Gao, X., Hong, B., Jia, C., Gao, S., Brain-computer interfaces based on visual evoked potentials. *IEEE Engineering in Medicine and Biology Magazine*, 27(5), 2008, s. 64–71.
- [12] Wang Y., Wang R., Gao X., Hong B., Gao S., A practical vep-based brain-computer interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 2, 2006, s. 234–240.

### **ARTIFACT REMOVAL FROM BRAIN–COMPUTER INTERFACE SIGNALS**

Electroencephalography allows recording the electrical activity of the brain. This method is used for diagnosis purposes as well as in brain–computer interfaces. Focusing on the brain–computer interface, it can be used to let the direct communication between the brain and a computing unit. This device is particularly useful for paralyzed patients or people suffering from a lock–in syndrome. Of the phenomena used in such systems, steady state visually evoked potentials (SSVEP) are probably the most common ones. If a subject is asked to focus on the flashing stimulus, a signal of the same frequency may be measured from the subject’s visual cortex. Proper preprocessing steps has to be taken in order to obtain maximally accurate stimuli recognition (as the specific frequency). One way to achieve this might be by applying the Blind Source Separation algorithms (BSS). BSS are designed to find and remove artifacts from the measured signal, e.g. noises associated with eye blinks or facial muscles contraction. In the present article an utilization of the BSS algorithms in the SSVEP–based EEG study was described. Additionally we report the accuracy of the stimuli categorization as depending on the number of removed components, kind of the blind source separation procedure and the type of the classification algorithm.

*(Received: 08. 02. 2017, revised: 22. 02. 2017)*