

Marcin JUKIEWICZ\*

## WYKORZYSTANIE MASZINY WEKTORÓW NOŚNYCH ORAZ LINIOWEJ ANALIZY DYSKRYMINACYJNEJ JAKO KLASYFIKATORÓW CECH W INTERFEJSACH MÓZG-KOMPUTER

Głównym celem artykułu jest porównanie skuteczności klasyfikacji cech dwóch algorytmów klasyfikujących wykorzystywanych w interfejsach mózg-komputer: SVM (ang. *Support Vector Machine*, Maszyna Wektorów Nośnych) oraz LDA (ang. *Linear Discriminant Analysis*, Liniowa Analiza Dyskryminacyjna). W artykule przedstawiono interfejs, w którym użytkownikowi prezentowane są dwa bodźce migające z różną częstotliwością (10 i 15 Hz), a następnie za pomocą elektrod elektroencefalografu mierzona jest odpowiedź elektryczna mózgu. W takich interfejsach sygnał zbierany jest zwykle w okolicach potylicznych (nad korą wzrokową). W prezentowanym rozwiązaniu sygnał mierzony jest z okolic czołowych. W przetwarzaniu i analizie sygnału zastosowano algorytmy statystycznego uczenia maszynowego. Do ekstrakcji cech sygnału wykorzystano Szybka Transformata Fouriera, do selekcji cech: test t-Welcha, a do klasyfikacji cech: SVM oraz DLA. Na podstawie odpowiedzi uzyskanej z klasyfikatora możliwe jest np. wysterowanie kierunku skrętu robota mobilnego lub włączenie czy wyłączenie oświetlenia.

SŁOWA KLUCZOWE: interfejs mózg-komputer, brain-computer interface, Support Vector Machine, Maszyna Wektorów Nośnych, Linear Discriminant Analysis, Liniowa Analiza Dyskryminacyjna

### 1. WSTĘP

#### 1.1. Interfejsy mózg-komputer

Interfejs mózg-komputer (BCI) to urządzenie, które pozwala osobom sparaliżowanym sterować np. robotem, protezą bądź wózkiem inwalidzkim wykorzystując jedynie reakcje własnego mózgu. Pozwala ono na bezpośrednie przełożenie intencji człowieka na sygnały sterujące, tworząc bezpośrednią ścieżkę komunikacji pomiędzy ludzkim mózgiem a urządzeniami zewnętrznymi, bez udziału mięśni i obwodowego układu nerwowego. Urządzenia te mogą być jedynym możliwym sposobem komunikacji osób niepełnosprawnych, np. z porażeniem dziecięcym, po udarze lub z urazami mózgu czy rdzenia kręgowego [1, 2].

---


\* PolitechnikaPoznańska.

W interfejsach nieinwazyjnych powszechnie stosowany jest elektroencefalograf (EEG) z uwagi na szybką odpowiedź elektryczną mózgu na zmieniające się bodźce, względną łatwość akwizycji sygnału oraz niższe koszty systemu w porównaniu z innymi metodami monitorowania aktywności mózgu (magnetoencefalografia, spektroskopia bliskiej podczerwieni, pozytonowa emisyjna tomografia komputerowa lub funkcjonalny rezonans magnetyczny) [2, 3].

Interfejsy wymagają bodźców zewnętrznych. Bodźce mogą być słuchowe, somatosensoryczne lub wzrokowe [2]. Oznacza to, że takimi bodźcami mogą być różne dźwięki, stymulacja dotykowa lub migające światła o różnych częstotliwościach. Spontaniczna, elektryczna reakcja mózgu pojawiająca się na powierzchni mózgu w wyniku zarejestrowania przez człowieka zewnętrznego bodźca nazywana jest potencjałem wywołanym. W typowym interfejsie mózg-komputer każdy bodziec jest związany z poleceniem, które steruje aplikacją bądź urządzeniem zewnętrznym. Aby wybrać polecenie, użytkownik musi skupić swoją uwagę na odpowiednim bodźcu.

## 1.2. Wzrokowe potencjały wywołane

Aby wybrać polecenie, użytkownik musi skupić swoją uwagę na odpowiednim bodźcu. Wzrokowe potencjały wywołane stanu ustalonego SSVEP (ang. *Steady State Visual Evoked Potentials*) to reakcja mózgu obserwowalna głównie w korze wzrokowej, podczas gdy osoba badana skupia uwagę na obrazie (wyświetlanym na ekranie monitora) migoczącym z częstotliwością powyżej 4 Hz. Częstotliwością dominującą w sygnale elektrycznym zmierzonym w okolicach potylicznych jest więc częstotliwość, z jaką migocze bodziec obserwowany przez badanego oraz jego harmoniczne.



Rys. 1. Umieszczenie elektrod przedczołowych i potylicznych wg standardu 10-20

W sytuacji, kiedy bodźców jest więcej i każdy pulsuje z inną częstotliwością, można stwierdzić, na który z obiektów patrzy badany [2, 7].

Do pomiaru sygnału znad kory wzrokowej (obszar potyliczny), wykorzystywane są głównie elektrody encefalografu oznaczone jako O1, O2 i Oz, zgodnie z międzynarodowym standardem 10-20 (rys. 1) [2].

### 1.3. Przedstawienie problemu

Montaż i korygowanie umiejscowienia elektrod na potylicy może być uciążliwe z uwagi na owłosienie w tym rejonie głowy oraz szczególnie kłopotliwe u osób o ograniczonej sprawności ruchowej (np. pacjenci leżący). Dlatego warto rozważyć możliwość pomiaru reakcji SSVEP w rejonach innych niż płat potyliczny. W tym artykule zaproponowano wykorzystanie sygnału mierzonego z kory przedczołowej [5, 6]. Jest to miejsce istotne z uwagi na brak owłosienia czoła, ma jednak pewne wady. Sygnał z tej okolicy zawiera głównie tak zwane fale alfa o częstotliwości (8-13) Hz i beta (13-30) Hz, związane z poziomem skupienia i zrelaksowania osoby badanej oraz składowe pochodzące od aktywności mięśni czoła [4]. Częstotliwość, z jaką miga bodziec, nie jest więc częstotliwością dominującą w sygnale pozyskiwanym z tych okolic.

## 2. BADANIA WŁASNE

Badanemu prezentowane były bodźce w postaci dwóch żółto-zielonych szachownic, z których każda była kwadratem o wymiarach (7x7) cm. Szachownicę lewą wyświetlano z częstotliwością 15 Hz, natomiast szachownicę prawą z częstotliwością 10 Hz. Prezentowano je na 14-calowym monitorze LED, umieszczonym w odległości 50 cm od osoby badanej.

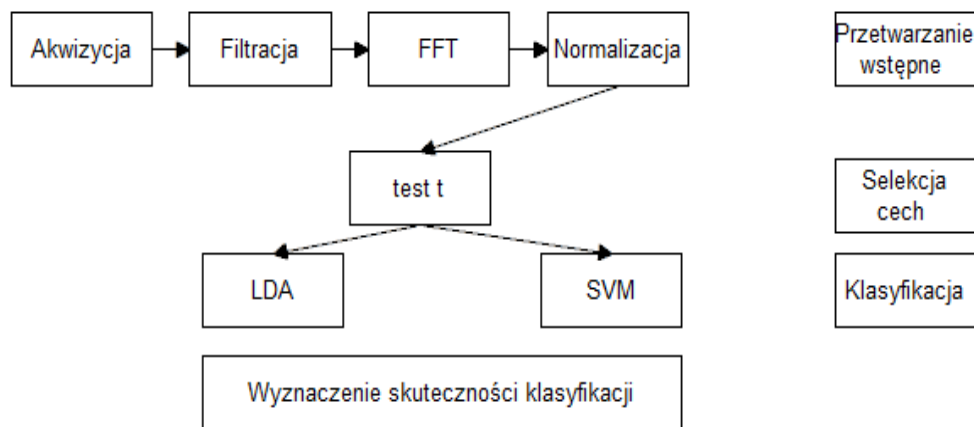
Do pomiaru sygnału z głowy użyto jednej, suchej elektrody czołowej Fp1 (rys. 1) oraz jednej elektrody referencyjnej zamontowanej na uchu. Sygnał rejestrowano z częstotliwością próbkowania równą 512 Hz.

W każdym z piętnastu powtórzeń badany proszony był, aby najpierw skupiał wzrok na lewej szachownicy przez 1 s, a następnie, także przez 1 s, na prawej szachownicy. W ten sposób uzyskano 30 jednosekundowych próbek. Do analizy sygnału wykorzystano środowisko MATLAB.

Na rys. 2 przedstawiono kolejne etapy analizy sygnału, omówione poniżej.

Sygnał został poddawany filtracji cyfrowej za pomocą filtru pasmowo-przepustowego tak, aby do dalszej analizy pozostało jedynie pasmo częstotliwości (5,0-49,5) Hz. Następnie wykorzystano 1024-punktową FFT do ekstrakcji cech sygnału. Uzyskane w ten sposób cechy zostały znormalizowane w przedziale od 0 do 1.

Selekcja wykorzystywana jest do minimalizacji liczby cech poddawanych dalszej analizie, poprzez uszeregowanie ich od cech „najistotniejszych” do „najmniej istotnych”. Odrzucenie cech nieistotnych pozwala na znaczne przyspieszenie działania interfejsu w czasie rzeczywistym. Do selekcji użyto testu t-Welcha.



Rys. 2. Schemat blokowy prezentujący kolejne etapy przetwarzania sygnału

W ostatnim etapie uczenia interfejsu próbki poddawane są pięciokrotnemu sprawdzianowi walidacji krzyżowej. Z pełnego zbioru wydzielanych jest 6 próbek, które stają się zbiorem testowym, reszta próbek to zbiór treningowy. Do klasyfikacji używane są dwa algorytmy: Maszyna Wektorów Nośnych SVM (ang. *Support Vector Machine*) oraz Liniowa Analiza Dyskryminacyjna LDA (ang. *Linear Discriminant Analysis*). Klasyfikacja odbywa się przy użyciu  $k$  cech (gdzie  $k = 1, 2, \dots, 90$ ). W zebranych wynikach klasyfikacji obu algorytmów ustala się, które odpowiedzi są prawidłowe, a które nie i na tej podstawie wyznaczana jest skuteczność danego klasyfikatora.

W ostatniej fazie ustalana jest optymalna (o największej skuteczności rozpoznania bodźca) liczba wyselekcjonowanych wcześniej cech. Tylko te cechy wykorzystywane są w etapie testowania interfejsu. W tym etapie badany poddawany jest kolejnym 30 próbom. W każdej z prób informuje się go, na której z szachownic ma skupić wzrok.

### 3. ANALIZA WYNIKÓW

W tabeli 1 zamieszczono wyniki pozyskane w badaniach 10 osób. Tabela przedstawia skuteczność klasyfikacji w fazie testowej dwóch algorytmów: Maszyny Wektorów Nośnych oraz Liniowej Analizy Dyskryminacyjnej. Maszyna Wektorów Nośnych umożliwiła uzyskanie skuteczności w przedziale od 63% do 87%. Średnia wartość skuteczności tego algorytmu wyznaczona na podstawie wyników uzyskanych od wszystkich osób wynosi 77%. Liniowa Analiza Dyskryminacyjna umożliwiła uzyskanie skuteczności w przedziale od 67% do 90%. Średnia wartość skuteczności tego algorytmu wyznaczona na podstawie wyników uzyskanych od wszystkich osób wynosi 80%.

Tabela 1. Skuteczność klasyfikacji w fazie testu

Podmiot	Faza testu	
	LDA	SVM
Osoba 1	90%	83%
Osoba 2	67%	63%
Osoba 3	90%	87%
Osoba 4	80%	63%
Osoba 5	57%	77%
Osoba 6	80%	80%
Osoba 7	87%	87%
Osoba 8	90%	67%
Osoba 9	77%	80%
Osoba 10	83%	80%
średnia	80%	77%

#### 4. PODSUMOWANIE

W przedstawionych badaniach dokonano analizy dwóch algorytmów uczenia maszynowego na potrzeby dwuklasowego interfejsu mózg-komputer, bazującego na analizie sygnału pobranego z kory przedczołowej. Lepszym rozwiązaniem od Maszyny Wektorów Nośnych okazała się Liniowa Analiza Dyskryminacyjna. Dla algorytmu LDA średnia (dla 10 osób) skuteczność klasyfikacji jest o 3% większa niż w przypadku algorytmu SVM, dając skuteczność rozpoznania bodźca w przedziale od 67 do 90%.

Należy sądzić, że polepszenie wyników rozpoznania bodźca oraz zwiększenie liczby klas powinny być możliwe przez zwiększenie liczby elektrod pomiarowych zamontowanych na czole badanej osoby. Otrzymane dotąd wyniki są na tyle obiecujące, że przedmiotem planowanych dalszych prac nad interfejsem mózg-komputer będzie modyfikacja układu pomiarowego.

## LITERATURA

- [1] Birbaumer N., Breaking the silence: Brain–computer interfaces (BCI) for communication and motor control. *Psychophysiology*, Volume 43, 517–532, ISSN 0048-5772, 2005.
- [2] Graimann B., Allison B., Pfurtscheller G., Brain–Computer Interfaces: A Gentle Introduction, *Brain-Computer Interfaces The Frontiers Collection*. 2010.
- [3] Schalk G., McFarland D. J., Hinterberger T., Birbaumer N., Wolpaw J R., BCI2000: A General-Purpose Brain-Computer Interface (BCI) System, *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1034-1043, 2004.
- [4] van Drongelen W., *Signal Processing for Neuroscientists*, Academic Press, 2006.
- [5] Vialatte F., Maurice M., Dauwels J., Cichocki A., Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives, *Progress in Neurobiology* 90, pp. 418–438, 2010.
- [6] Wang R., Zhang Y., Gao X., Gao S., “Lead selection for SSVEP-based binocular rivalry,” in 2005 First International Conference on Neural Interface.
- [7] Wolpaw J. R., Birbaumer N., McFarland D. J., Pfurtscheller G., T. M. Vaughan, Brain–computer interfaces for communication and control, *Clinical Neurophysiology* 113, pp. 767–791, 2002.

### **USING SUPPORT VECTOR MACHINE AND LINEAR DISCRIMINANT ANALYSIS FOR FEATURES CLASSIFICATION IN BRAIN-COMPUTER INTERFACES**

The main aim of this article is to compare the effectiveness of the classification of the two classifiers used in brain-computer interfaces: SVM (Support Vector Machine) and LDA (Linear Discriminant Analysis). The article presents an interface in which the subject is presented the two stimuli flashing at different frequencies (10 and 15 Hz) and then by using EEG electrodes electrical response of the brain is measured. In these interfaces, the signal is typically collected in the occipital area (on the visual cortex). In the presented solution the signal is measured from the prefrontal cortex. For signal processing and analysis statistical machine learning algorithms were used. For features' extraction Fast Fourier Transform was used. For features' selection Welch's t test was used. For features' classification was used SVM and DLA. Based on the responses obtained from the classifier it is possible to control the direction of a mobile robot's movement or turning the lights on and off.