

Marcin KOŁODZIEJ, Andrzej MAJKOWSKI, Remigiusz Jan RAK

POLITECHNIKA WARSZAWSKA, INSTYTUT ELEKTROTECHNIKI TEORETYCZNEJ I SYSTEMÓW INFORMACYJNO-POMIAROWYCH,
ul. Koszykowa 75, 00-661 Warszawa

Wykorzystanie maszyny wektorów wspierających (SVM) do klasyfikacji sygnału EEG na użytek interfejsu mózg-komputer

Mgr inż. Marcin KOŁODZIEJ

Asystent w Instytucie Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych na Wydziale Elektrycznym Politechniki Warszawskiej. Ukończony kierunek elektrotechnika o specjalności Automatyka i Inżynieria Komputerowa na Wydziale Elektrycznym Politechniki Warszawskiej. Przewód doktorski: Przetwarzanie analiza i klasyfikacja sygnału EEG na potrzeby interfejsu mózg-komputer. Zainteresowania naukowe: cyfrowe przetwarzanie sygnałów, data-mining, systemy ekspertowe.

e-mail: kolodzim@iem.pw.edu.pl



Prof. dr hab. inż. Remigiusz J. RAK

Absolwent Wydziału Elektroniki Politechniki Warszawskiej (specjalność Radiotechnika). Uzyskał stopień doktora nauk technicznych (1982), doktora habilitowanego (1998), tytuł naukowy profesora (2004), stanowisko profesora zwyczajnego (2009). Autor i współautor 125 publikacji. Zainteresowania naukowe: cyfrowe przetwarzanie sygnałów, wirtualne przyrządy pomiarowe, projektowanie systemów pomiarowych, rozproszone systemy pomiarowe, wirtualne laboratorium.

e-mail: rakrem@iem.pw.edu.pl



Dr inż. Andrzej MAJKOWSKI

Absolwent Wydziału Elektrycznego Politechniki Warszawskiej. Od 1995 roku pracownik Instytutu Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych Wydziału Elektrycznego. Stopień doktora nauk technicznych uzyskał w roku 2000. Zainteresowania naukowe: cyfrowe przetwarzanie sygnałów, projektowanie i oprogramowanie systemów pomiarowych.

e-mail: amajk@iem.pw.edu.pl



Streszczenie

W artykule przedstawiono wykorzystanie maszyny wektorów wspierających (SVM) na użytek interfejsów mózg-komputer (BCI). W opracowanych algorytmach jako cechy sygnału EEG wykorzystano jego wariancję. Przedstawiono wyniki badań związanych z wykorzystaniem sieci SVM jako klasyfikatora. Eksperymenty przeprowadzono przy użyciu różnego rodzaju funkcji jądra.

Słowa kluczowe: BCI, interfejs mózg-komputer, EEG, maszyna wektorów wspierających (SVM).

Implementation of support vector machine for classification of EEG signal for brain-computer interface

Abstract

Implementing communication between man and machine by use of EEG signals is one of the biggest challenges in the signal theory. Such communication could improve the standard of living of people with severe motor disabilities. Some disable persons cannot move, however they can think about moving their arms, legs and this way produce stable motor-related EEG signals. These signals can be used to construct BCI systems. However, the proper interpretation of the EEG signals is a very difficult task. There are three main stages in EEG signal analysis: feature extraction, feature selection and classification. The main aim of the paper is to implement a support vector machine as a classifier for the brain-computer interface. The proposed algorithm uses the EEG signal variance in the frequency range 8-30Hz. Experiments were conducted with use of different kernel functions for the SVM classifier. The best results were achieved for the quadratic polynomial kernel function. The classification error for testing data was 0.13.

Keywords: BCI, brain-computer interface, EEG, Support Vector Machine.

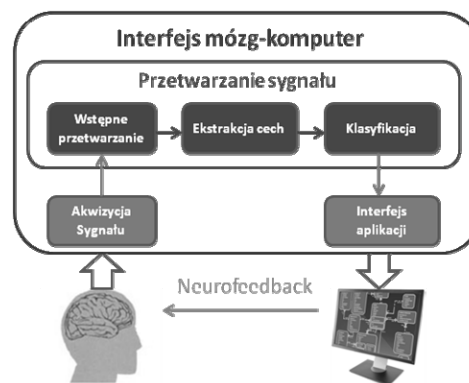
1. Interfejs mózg-komputer

Już w latach siedemdziesiątych (J. Vidal, 1973) sugerowano możliwość komunikacji z maszyną tylko za pomocą aktywności mózgu. Jednak dopiero w ostatniej dekadzie ubiegłego wieku

w kilku ośrodkach naukowych na świecie podjęto próby wykorzystania elektroencefalografii (EEG) do komunikacji bezpośredniej między mózgiem a komputerem. Tak więc, interfejsy mózg-komputer (BCI) charakteryzuje wykorzystanie sygnałów, pochodzących z mózgu. Natomiast elektryczną aktywność samych mięśni traktuje się w tym przypadku jako niepożądaną. Są to tak zwane artefakty fizjologiczne. Duży problem stanowi fakt, że amplituda tych artefaktów jest o wiele większa (miliwołty) niż samego sygnału EEG (mikrowołty).

Wyróżnić możemy interfejsy mózg-komputer działające w sposób synchroniczny i asynchroniczny. Interfejsy synchroniczne to takie, w których jest znane położenie fragmentu sygnału EEG niosącego użyteczne informacje. Na przykład, użytkownik zaczyna zadanie myślowe, po wystąpieniu pewnego bodźca. Fragment sygnału związany z tym zdarzeniem jest przetwarzany. Interfejsy asynchroniczne to takie, w których nie jest znane położenie fragmentu sygnału EEG niosącego użyteczne informacje. Dlatego musimy poddawać analizie całość zapisu sygnału. Dlatego interfejsy asynchroniczne są trudniejsze w realizacji.

Jak wspomniano w interfejsach mózg-komputer wykorzystuje się najczęściej sygnał EEG. Na początku sygnał przechodzi etap przetwarzania wstępnego. Kolejnym etapem jest ekstrakcja cech, która prowadzi do ilościowego opisu pewnych właściwości sygnału EEG. Ostatnim etapem jest klasyfikacja cech. Ważnym elementem systemów BCI jest neurofeedback, który umożliwia douczenie systemu i jego dopasowanie do konkretnego użytkownika (rys. 1).



Rys. 1. Schemat interfejsu mózg-komputer

Fig. 1. Diagram of brain-computer interface system

2. Opis eksperymentu

Podczas eksperymentu wykorzystano sygnał EEG zarejestrowany za pomocą 32 elektrod [3]. Zadaniem użytkownika było

wyobrażanie sobie trzech różnych zdarzeń (trzy klasy zdarzeń: ruch prawą ręką, lewą ręką oraz wypowiedzanie słowa na podaną literę). Celem eksperymentu była próba jak najdokładniejszej klasyfikacji sygnału EEG dla okna trwającego jedną sekundę [4]. Z każdego okna generowany był zestaw cech sygnału EEG. Jako cechy wykorzystano, estymowaną za pomocą wariancji, energię sygnału w paśmie 8-30 Hz. Dla każdego okna otrzymano w ten sposób 32 cechy. Ostatnim etapem była klasyfikacja sygnału EEG i zbadanie poziomu błędów otrzymanego podczas klasyfikacji. Schemat przebiegu eksperymentu zaprezentowano na rys. 2.



Rys. 2. Schemat przebiegu eksperymentu klasyfikacji sygnału EEG
Fig. 2. Block diagram of classification process

Celem eksperymentu było zbadanie czy metoda maszyny wektorów wspierających da dobre wyniki klasyfikacji w zastosowaniu do sygnału EEG na użytek interfejsu mózg-komputer. W poprzednich pracach [3,4,5] autorzy wykorzystywali do klasyfikacji liniową analizę dyskryminacyjną (LDA) oraz klasyfikator najbliższego sąsiedztwa (KNN). Dane testowano za pomocą 10-krotnego testu krzyżowego [5]. Podczas opisywanego eksperymentu, z użyciem sieci SVM jako klasyfikatora, autorzy uczyli i testowali klasyfikator na dwu różnych zbiorach. Takie podejście bardziej odzwierciedla rzeczywisty sposób pracy interfejsów BCI, które najpierw pracują w trybie kalibracji, a następnie w trybie właściwego działania.

3. Klasyfikacja za pomocą SVM


Istotą metody SVM jest separacja zbioru próbek różnych klas za pomocą pewnej specjalnie dobranej hiperpłaszczyzny. Metoda SVM umożliwia separację danych o dowolnym rozkładzie. Problem separacji nieliniowego zbioru danych rozwiązywany jest poprzez linearyzację, która jednak powoduje zwiększenie wymiarowości przestrzeni cech. Istnieje wiele możliwości wyznaczenia hiperpłaszczyzny separującej dane, ale jakość tej separacji nie jest zawsze jednakowa. Założeniem metody SVM jest poszukiwanie takiej hiperpłaszczyzny, która zapewni najlepszą separowalność cech. Najlepszy podział danych w metodzie SVM to taki, który zapewni największy margines separacji (czyli najszerszy pas) wewnątrz którego nie znajdują się żadne próbki (rys. 3). O szerokości tego pasa decydują próbki skrajne, na których podtrzymywany jest margines separacji. Próbkę te nazywane są próbkami podtrzymującymi (wektorami wspierającymi), stąd pochodzi nazwa metody SVM.

Niech (x_i, d_i) dla $i=1,2,\dots,p$ oznacza podzbiór par uczących z pewnego zbioru, który podlega klasyfikacji - x_i oznacza dane wejściowe, a d_i przynależność do określonej klasy (wartość -1 lub 1). Przy założeniu liniowej separowalności obu klas równanie hiperpłaszczyzny separującej może być opisane jako:

$$g(x) = w^T x + b = 0 \quad (1)$$

gdzie $w = [w_1, w_2, \dots, w_N]^T$ oraz $x = [x_1, x_2, \dots, x_N]^T$. Wektor w opisujący hiperpłaszczyznę jest N -wymiarowy. Równania decyzyjne określające przynależność do określonej klasy przyjmują postać:

$$\begin{aligned} w^T x_i + b > 0 &\rightarrow d_i = 1 \\ w^T x_i + b < 0 &\rightarrow d_i = -1 \end{aligned} \quad (2)$$



Rys. 3. Prosta separująca wraz z marginesami separacji
Fig. 3. Discriminant line with separating margins

Jak już wspomniano za optymalną uważa się taką hiperpłaszczyznę, która maksymalizuje margines separacji pomiędzy dwoma klasami. Wektory podtrzymujące decydują o położeniu marginesów oraz o doborze hiperpłaszczyzny separującej. Warto zauważyć, że to właśnie te punkty są najtrudniejsze do właściwego zaklasyfikowania.

Po to, aby w pełni wykorzystać potencjał metody SVM często stosuje się powiększenie wymiarowości przestrzeni cech za pomocą nieliniowego przekształcenia ϕ na wektorach u i v . Takie powiększenie wymiarowości zwiększa szansę na uzyskanie rozkładów próbek, które umożliwiają łatwiejszą separację liniową. Funkcje $K(u, v) = \phi^T(u)\phi(v)$ nazywa się funkcjami jądra (ang. *kernel function*). To właśnie wprowadzeniu funkcji jądra metoda SVM zawdzięcza swoją skuteczność. Powszechnie zastosowanie znalazły funkcje jądra będące funkcjami liniowymi, funkcjami wielomianowymi, funkcjami radialnymi lub sigmoidalnymi (tab. 1). Zastosowanie funkcji jądra zwiększa szansę na separowalność danych oraz zwiększa skuteczność klasyfikacji.

Tab. 1. Typy funkcji jądra stosowane w SVM
Tab. 1. SVM kernel functions

F. jądra	Równanie	Uwagi
Liniowa	$K(u, v) = u^T v + \gamma$	γ - dowolna wartość
Wielomian	$K(u, v) = (u^T v + \gamma)^p$	p - stopień wielomianu
Radialna	$K(u, v) = \exp(-\gamma \ u - v\ ^2)$	γ - wspólne dla wszystkich funkcji jądra

Przedstawione do tej pory rozważania dotyczyły problemu separowalności dwóch klas. Przy klasyfikacji sygnału EEG, najczęściej mamy do czynienia z wieloma klasami zdarzeń. Dlatego wprowadza się modyfikacje do algorytmu SVM, które umożliwiają klasyfikację większej liczby klas. Najpopularniejsze z nich to strategię klasyfikacji: jedna klasa przeciw wszystkim, jedna klasa przeciw jednej oraz jedna przeciw pozostałym [8]. Autorzy zastosowali strategię jedna przeciw pozostałym. W rozpatrywanym w artykule zadaniu trzyklasowym w pierwszej kolejności testowana jest pierwsza klasa (1) przeciwko pozostałym (2+3). Jeśli wygra klasa (1) to próbka przydzielana jest do tej klasy. Jeśli nie wygrywa klasa (1), a klasa (2+3) to następnie testowane są kolejne klasy z podzbioru (2+3) czyli klasa (2) przeciwko (3). W ten sposób możliwy jest wybór właściwej klasy.

4. Wyniki badań

Jak wspomniano, w badaniach wykorzystano energię sygnału EEG w paśmie 8-30 Hz w charakterze cech. Dane zostały podzielone na: uczące (80%) i testujące (20%). Dodatkowo autorzy przebadali wpływ różnych funkcji jądra na jakość klasyfikacji dla danych uczących i testujących. W tabelach od 2 do 9 zaprezentowano wyniki nauki i testowania klasyfikatorów dla różnego rodzaju funkcji jądra. Z macierzy pomyłek można odczytać, w ilu przypadkach model poprawnie sklasyfikował dane testowe a w ilu się pomylił, tzn. np. wybrał klasę K2 w miejsce K3 lub odwrotnie.

Tabela 2 zawiera macierz pomyłek (*confusion-matrix*) dla liniowej funkcji jądra w trybie nauki klasyfikatora. Tabela 3 zawiera macierz pomyłek dla liniowej funkcji jądra w trybie testowania klasyfikatora. Tabele od 4 do 9 zawierają błędy nauki i testowania klasyfikatora dla różnego rodzaju funkcji jądra.

Tab. 2. Macierze pomyłek dla danych uczących SVM – liniowa funkcja jądra.

Całkowity błąd dla danych uczących 0.2549

Tab. 2. Confusion matrix - training data, linear kernel function. Total error 0.2549

Linowe jądro SVM	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	132	22	22
K3	53	210	67
K7	17	14	228

Tab. 3. Macierze pomyłek dla danych testujących SVM, – liniowa funkcja jądra.

Całkowity błąd dla danych testujących 0.2732

Tab. 3. Confusion matrix - testing data, linear kernel function. Total error 0.2732

Linowe jądro SVM	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	31	6	9
K3	11	54	15
K7	9	3	56

Tab. 4. Macierze pomyłek dla danych uczących SVM - wielomian stopnia

drugiego jako funkcja jądra. Całkowity błąd dla danych uczących 0.0013

Tab. 4. Confusion matrix - training data, quadratic polynomial kernel function. Total error 0.0013

Wielomian 2 stopnia	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	201	0	0
K3	1	246	0
K7	0	0	317

Tab. 5. Macierze pomyłek dla danych testujących SVM - wielomian stopnia

drugiego jako funkcja jądra. Całkowity błąd dla danych testujących 0.1340

Tab. 5. Confusion matrix - testing data, quadratic polynomial kernel function. Total error 0.1340

Wielomian 2 stopnia	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	44	3	8
K3	5	56	4
K7	2	4	68

Tab. 6. Macierze pomyłek dla danych uczących SVM, - wielomian stopnia

trzeciego jako funkcja jądra. Całkowity błąd dla danych uczących 0

Tab. 6. Confusion matrix - training data, third degree polynomial kernel function. Total error 0.

Wielomian 3 stopnia	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	202	0	0
K3	0	264	0
K7	0	0	317

Tab. 7. Macierze pomyłek dla danych uczących SVM, SVM, - wielomian stopnia

trzeciego jako funkcja jądra. Całkowity błąd dla danych testujących = 0.1753

Tab. 7. Confusion matrix - testing data, third degree polynomial kernel function. Total error 0.1753

Wielomian 3 stopnia	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	39	5	8
K3	7	55	6
K7	5	3	66

Tab. 8. Macierze pomyłek dla danych uczących SVM - radialna funkcja jądra.

Całkowity błąd dla danych uczących 0

Tab. 8. Confusion matrix - training data, radial kernel function. Total error 0

RBF	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	202	0	0
K3	0	264	0
K7	0	0	317

Tab. 9. Macierze pomyłek dla danych uczących SVM - radialna funkcja jądra.

Całkowity błąd dla danych testujących 0.2010

Tab. 9. Confusion matrix - testing data, radial kernel function. Total error 0.2010

RBF	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	29	4	3
K3	15	59	10
K7	7	0	67

5. Wnioski

Jak wskazują otrzymane wyniki, w przypadku zastosowania energii (wariancji) jako cech sygnału EEG, najlepiej sprawuje się klasyfikator SVM z funkcją jądra w postaci wielomianu drugiego stopnia. Klasyfikator SVM dla innych przebadanych funkcji jądra, radialnej czy wielomianu trzeciego stopnia, również dobrze separuje dane testujące, ale zbyt dopasowuje się do zbioru uczącego i nie ma dobrych właściwości generalizacyjnych. Dla wielomianu drugiego stopnia jako funkcji jądra błąd klasyfikacji dla danych testujących wynosi 0,134. Warto zauważyć, że wyniki odzwierciedlają proces nauki i testowania klasyfikatora, który przebiega w sposób analogiczny jak podczas działania rzeczywistych systemów BCI.

Z poprzednich badań autorów [3,4,5] wynika, że dla analogicznych danych błąd klasyfikacji dla klasyfikatora LDA wynosił 0,338, a dla klasyfikatora KNN - 0,237. Z porównania wyników można wysnuć wniosek, że metodę SVM można uznać za dobry klasyfikator. Należy jednak podkreślić, że dla klasyfikatorów LDA i KNN w procesie nauki i testowania zastosowano 10-cio krotny test krzyżowy, a więc inny podział na dane uczące i testujące, co mogło wpłynąć na wyniki klasyfikacji.

6. Literatura

- [1] Wolpaw J. R., Birbaumer N., D. J. McFarland, Pfurtscheller G., Vaughan T. M.: Braincomputer interfaces for communication and control, Clin. Neurophysiol., 113: 767–791, 2002.
- [2] Wolpaw J. R., McFarland D. J., Vaughan T. M.: Brain-Computer Interface Research at the Wadsworth Center, IEEE Trans. Rehab. Eng., 8(2): 222–226, 2000.
- [3] Kołodziej M., Majkowski A., Rak R.: Optymalizacja doboru okien czasowych do przetwarzania sygnału EEG w interfejsach mózg-komputer, IX Szkoła-Konferencja "Metrologia Wspomagana Komputerowo" MWK'2011, Waplewo, 2011.
- [4] Kołodziej M., Majkowski A., Rak R.: Wizualizacja rozkładu potencjału EEG na głowie pacjenta w zastosowaniu do asynchronicznego interfejsu mózg MPM, X Jubileuszowe Sympozjum "Modelowanie i Pomiary w Medycynie", Krynica, 2011.
- [5] Kołodziej M., Majkowski A., Rak R.: Wykorzystanie t-statystyk do szybkiej selekcji cech sygnału EEG na użytek interfejsu mózg-komputer IX Szkoła-Konferencja "Metrologia Wspomagana Komputerowo" MWK'2011, Waplewo, maj 2011.
- [6] Koronacki J., Ćwik J.: Statystyczne systemy uczące się, wydanie drugie, Exit, Warszawa, 2008.
- [7] Krzyśko M., Wołyński W., Górecki T., Skorzybut M.: Systemy uczące się Rozpoznawanie wzorców analiza skupień i redukcja wymiarowości 2008.
- [8] Osowski S.: Sieci neuronowe do przetwarzania informacji, 2000.