

Paweł STASIAKIEWICZ¹, Andrzej P. DOBROWOLSKI², Kazimierz TOMCZYKIEWICZ³

3. Wojskowy Ośrodek Metrologii (1), Wojskowa Akademia Techniczna, Wydział Elektroniki (2),
Wojskowy Instytut Medyczny, Klinika Neurologiczna (3)

doi:10.15199/48.2017.10.01

System wspierający ocenę wzrokowych potencjałów wywołanych w oparciu o analizę wielorozdzielczą

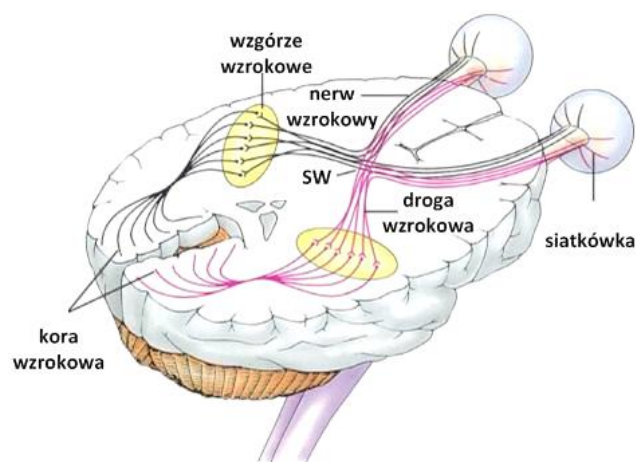
Streszczenie. Hipotezy dotyczące schorzeń drogi wzrokowej formułowane są na podstawie oceny wzrokowych potencjałów wywołanych powstałych na wskutek stymulacji oka zewnętrznym źródłem światła. Proces diagnostyczny jest złożony i skomplikowany, dlatego wymaga od lekarza doświadczenia i dobrej percepcji. W niniejszym artykule opracowano system wspierający proces decyzyjny, który charakteryzuje się w zbiorze testującym 100,00% czułością w grupie 49 przypadków przy 14,38% prawdopodobieństwie fałszywego alarmu w grupie 153 przypadków diagnostycznych.

Abstract. Hypotheses regarding visual pathway disorders are formulated on the basis of visual evoked potentials arising as a result of stimulation of the eye by external light source. Diagnostic process is complex and complicated and therefore requires a doctor's experience and a good perception. This article provides a system supporting decision-making process, which is characterized in the testing set by a 100.00% sensitivity in 49 cases with 14.38% probability of false alarm in the group of 153 diagnostic cases.
(System supporting visual evoked potentials assessment based on multiresolution analysis).

Słowa kluczowe: wzrokowe potencjały wywołane, falkowa analiza wielorozdzielcza, sieć wektorów podtrzymujących, selekcja cech.
Keywords: visual evoked potentials, wavelet multiresolution analysis, support vector machine, feature selection.

Wprowadzenie

Proces widzenia jest skomplikowanym zjawiskiem elektrochemicznym, który zapoczątkowany jest pobudzeniem komórek fotoczułych, pręcików i/lub czopków, przez światło. Wówczas chemiczna kompozycja pigmentu zmienia się chwilowo powodując przepolaryzowanie komórek nerwu wzrokowego [1]. W rezultacie tego zjawiska powstaje złożony potencjał czynnościowy, będący sumarycznym pobudzeniem neuronów, który jest przesyłany wzdłuż drogi wzrokowej, tj. przez nerw wzrokowy, skrzyżowanie wzrokowe (SW) i wzgórze wzrokowe, aż do kory wzrokowej [2] (rys. 1).



Rys.1. Ilustracja drogi wzrokowej [3].

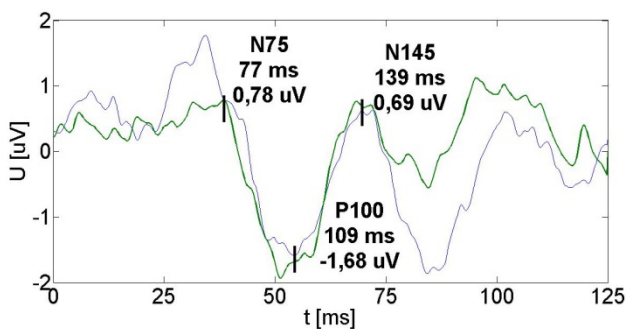
Ze względu na to, że przez neurony przepływa zmienny w czasie prąd generowane jest pole elektromagnetyczne. Wobec tego, istnieje możliwość rejestracji aktywności

mózgu za pomocą elektrod umieszczonych na głowie pacjenta. W rezultacie badań Haliday'a z 1982 roku oraz spostrzeżenia asymetrycznej aktywacji nerwu wzrokowego w przypadkach patologicznych zaleca się pomiar 5-cio kanałowy [4]. Szczególnie istotne jest położenie dwóch elektrod, które przyjęło się rozmieszczać w następujący sposób: elektroda Oz umieszczana jest 5 cm nad guzowatością potyliczną, a elektroda referencyjna Cz przykładana jest 12 cm nad grzbietem nosa w linii środkowej. Jako zewnętrzne źródło stymulujące wykorzystywany jest błysk (ang. *flash*) lub naprzemienny wzorec szachownicy (ang. *pattern reversal*). Metoda błysku służy głównie do oceny drogi wzrokowej, od siatkówki aż do kory potylicznej, oraz wykorzystywana jest w stosunku do pacjentów niedowidzących lub niesłownych do obserwowania monitora przez dłuższy czas. Druga metoda jest wykorzystywana do rozpoznawania schorzeń występujących na drodze do skrzyżowania wzrokowego, takich jak stwardnienie rozsiane czy uszkodzenie przewodnictwa [4]. Ze względu na szersze zastosowanie drugiej metody stała się ona obiektem dalszych badań.

Zarejestrowany sygnał ma bardzo mały poziom – rzędu mikrowoltów. Dlatego dokonywane jest synchroniczne uśrednianie przebiegów o czasie trwania 250 ms w ciągu 3 minut. W rezultacie zwiększany jest stosunek sygnału do szumu. Częstotliwość próbkowania wynosi 4 kHz, a zatem sygnał ma długość 1000 próbek, a częstotliwość przesuwu (odwracania) wzorca jest z zakresu 1-2 Hz. Pomierzony sygnał zgodnie z powyższą procedurą nosi nazwę wzrokowego potencjału wywołanego – WPW (ang. *Visual Evoked Potentials*). Badanie jest realizowane osobno dla oka prawego oraz lewego, kilkakrotnie tak, aby można było wybrać jeden przebieg najlepiej zarejestrowany oraz sprawdzić powtarzalność przebiegów.

Do klasycznego opisu sygnału WPW wykorzystywany jest zestaw parametrów wyekstrahowanych w dziedzinie czasu, związanych z trzema następującymi po sobie ekstremami lokalnymi zwanymi *załamkami*. Maksima lokalne w medycynie przyjęto nazywać załamkami negatywnymi, natomiast minima lokalne załamkami pozytywnymi [5]. Ekstremum opisuje się przez określenie momentu jego wystąpienia tzw. *latencji* oraz jego wartości. Przyjęło się oznaczać załamki poprzez dużą literę oznaczającą rodzaj załamka (P – pozytywny, N – negatywny) oraz średnią wartość latencji w grupie przypadków zdrowych.

Na rysunku 2 przedstawiono sygnały WPW oraz załamki N75, P100 i N145, a także przykładowe wartości parametrów. Kolorem zielonym wyszczególniono najlepiej zarejestrowany sygnał. W celach diagnostycznych wykorzystywane są latencje poszczególnych załamków oraz wartości międzyszczytowe załamków N75-P100 oraz N145-P100. Wyznaczane są również tzw. latencje międzyoczne, tj. różnice latencji załamków N75 i P100 dla oka lewego i prawego. W rezultacie lekarz diagnozując pacjenta przeprowadza skomplikowaną analizę danych siedmiowymiarowych.



Rys. 2. Wzrokowe potencjały wywołane z zaznaczonymi charakterystycznymi załamkami.

Ponieważ parametry czasowe charakteryzują się słabymi możliwościami dyskryminacyjnymi [5] należy rozpatrywać je wspólnie. Powyższy problem stanowi motywację do opracowania systemu, który umożliwi wiarygodną klasyfikację wzrokowych potencjałów wywołanych za pomocą odpowiednio wygenerowanego zestawu cech dystyngtywnych.

Warunki badań

Wyniki z przeprowadzonych badań medycznych pochodzą z Kliniki Neurologicznej Wojskowego Instytutu Medycznego w Warszawie. Wzrokowe potencjały wywołane zostały zarejestrowane za pomocą systemu *Nicolet VikingSelect* firmy *CareFusion*.

Pozyskane rezultaty badań są oryginalnie pogrupowane w foldery związane z sesjami, tj. dotyczą pojedynczego badania. Dane zapisano w postaci wielu plików w tym plików binarnych, które były trudne do zinterpretowania. W wyniku wcześniejszych badań słuchowych potencjałów wywołanych [6] opracowano funkcję do odczytywania plików binarnych. Przygotowanie danych o przypadkach diagnostycznych stanowiło poważny problem, dlatego opracowano bazę danych z odpowiednim interfejsem graficznym [7].

Przyjęto rozpatrywać każdy sygnał WPW osobno niezależnie od tego czy rejestracja odbywała się dla prawego czy lewego oka. Zastosowano takie podejście w rezultacie analizy raportów z badań pacjentów, które zawierają diagnozę osobno dla lewego oraz prawego oka. Wyjątek stanowi latencja międzyoczna, której nie

uwzględniono w niniejszych badaniach. Dlatego opracowany system wspiera ocenę 5-ciu parametrów z wyłączeniem latencji międzyocznych.

Stan pacjenta określany jest przez lekarza jako zdrowy lub chory. Dlatego zdecydowano wyróżnić dwie klasy przypadków diagnostycznych. W niektórych sytuacjach lekarz opisuje wyniki pacjenta jako pograniczne patologii i normy lub brak odpowiedzi na bodziec. Postanowiono nie wykorzystywać tych przypadków do badań nad klasyfikatorem, ale po jego opracowaniu sprawdzić rezultaty klasyfikacji nietypowych sygnałów WPW. O ile stan pacjenta z pogranicza nie ma odpowiednika w przyjętych klasach to przypadek braku odpowiedzi na bodziec powinien być przyporządkowywany do klasy chory. Sygnał WPW jest klasyfikowany jako brak odpowiedzi na bodziec wtedy, gdy nie sposób zaobserwować w jego przebiegu charakterystycznych załamków.

Własności klasyfikatora przyjęto oceniać za pomocą trzech parametrów określonych zależnościami (1)-(3).

- Czulość (ang. *Sensitivity*) to stosunek poprawnie zidentyfikowanych chorych do wszystkich przypadków patologicznych.

$$(1) \quad SE = \frac{TP}{TP + FN} \cdot 100\%$$

gdzie, *TP* (ang. *True Positive*) oznacza liczbę prawidłowo zdiagnozowanych chorych pacjentów, *FN* (ang. *False Negative*) to liczba pacjentów chorych zaklasyfikowanych jako zdrowi.

- Fałszywy alarm (ang. *False Alarm*) to stosunek niepoprawnie zidentyfikowanych zdrowych do wszystkich przypadków prawidłowych.

$$(2) \quad FA = \frac{FP}{TN + FP} \cdot 100\%$$

gdzie, *FP* (ang. *False Positive*) to liczba pacjentów zdrowych zaklasyfikowanych jako chorzy, *TN* (ang. *True Negative*) oznacza liczbę prawidłowo zdiagnozowanych pacjentów zdrowych.

- Dokładność (ang. *Accuracy*) to stosunek wszystkich poprawnie zidentyfikowanych stanów pacjentów do liczebności próby

$$(3) \quad AC = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\%$$

Niniejsze badania są kontynuacją analiz przedstawionych w [5, 8, 9]. W ramach [9] rozwiązano problem generacji cech za pomocą falkowej analizy wielorozdzielczej realizowanej algorytmem Mallata w oparciu o falki o zwartym nośniku. Wybrano wówczas 12 falek, zakres poziomów dekompozycji od 7 do 9 oraz zakres przesunięć kołowych sygnału WPW. Zaproponowano również eksperymentalny algorytm do selekcji cech wraz z interfejsem graficznym, który maksymalizował sumę miar Fishera trzech składników głównych *PCA* (ang. *Principal Component Analysis*), zwaną sumaryczną miarą Fishera w skrócie *SMF*. Za jego pomocą przeprowadzono wstępną selekcję cech wyników otrzymywanych dla różnych przesunięć kołowych sygnału WPW. Wytypowano dla każdej falki po dwa najlepsze rezultaty. Opracowano pilotażowy klasyfikator K_{db8} za pomocą zestawu 5-ciu parametrów otrzymanych w oparciu o falkę $db8$. Do wyznaczenia wektora wag użyto transformacji *LDA* (ang. *Linear Discriminant Analysis*) oraz do wyznaczenia stałej polaryzacji charakterystyki *ROC* (ang. *Receiver Operating Characteristic*). W tabeli 1 przedstawiono własności klasyfikatora K_{db8} .

Tabela 1. Własności klasyfikatora k_{db8} (u – oznacza zbiór uczący, t – zbiór testujący).

Parametr	Wartość parametru	Liczba przypadków diagnostycznych
SE (u)	100,00%	35
SE (t)	90,48%	21
FA (u)	8,57%	35
FA (t)	10,85%	129
AC	91,36%	220

Zgodnie z zaleceniami zawartymi w podsumowaniu obserwacji w ramach [9], w niniejszych badaniach postanowiono przeprowadzić analizę porównawczą 24 zestawów parametrów, wyznaczyć ostateczną funkcję klasyfikującą za pomocą sieci SVM (ang. *Support Vector Machine*) oraz zebrać większą liczbę przypadków diagnostycznych.

Do opracowania systemu przygotowano znacznie większą liczbę badań, które wraz z podziałem na klasy przedstawiono w tabeli 2.

Tabela 2. Zestawienie przygotowanych do badań przypadków diagnostycznych.

Klasa	Liczba przypadków diagnostycznych
Zdrowy	253
Chory	149
Pogranicze patologii i normy	60
Brak odpowiedzi na bodziec	32

Selekcja cech

Do procesu selekcji cech wytypowano 24 zestawy parametrów otrzymanych za pomocą 12 falek. Proces wyboru odpowiedniego zestawu parametrów postanowiono wykonać za pomocą algorytmu zaproponowanego i szczegółowo omówionego w [9]. Funkcja ocenia możliwości cech do dyskryminacji klas w układzie współrzędnych otrzymanym przez transformację PCA. Wobec tego rozpatrywana jest kombinacja cech, co oznacza uwzględnianie ich współzależności, i to w takim układzie współrzędnych, w którym są one nieskorelowane. Predyspozycje cech określane są za pomocą miar Fishera trzech składników głównych PCA. Macierz kowariancji danych po transformacji PCA jest diagonalna, a elementy na przekątnej są uporządkowane malejąco. Można wnioskować, że zmienne charakteryzujące się bardzo małą wariancją stanowią szum pomiarowy [10]. Wybór trzech pierwszych składników głównych PCA jest uzasadniony przeprowadzonymi wcześniej badaniami lecz można go także wytłumaczyć w następujący sposób: jeżeli składniki o największych wariancjach charakteryzują się korzystnymi wskaźnikami dyskryminacyjnymi, to można wnioskować, że zestaw cech, za pomocą których te składniki otrzymano, odznacza się nie gorszymi własnościami różnicującymi.


Dla każdego zestawu przeprowadzono selekcję cech poprzez definiowanie oczekiwanej liczby parametrów. Procedura iteracyjnie eliminuje cechy, które minimalnie zmniejszają lub maksymalnie zwiększają wartość SMF. W każdym przypadku istniała taka liczba parametrów, po której przekroczeniu możliwości dyskryminacyjne zwiększały się diametralnie. Dzięki archiwizacji wartości SMF w każdej iteracji, istniała możliwość zaobserwowania momentu zwiększenia się predyspozycji różnicujących. Skupiano wówczas uwagę na tak wybranej liczbie parametrów. Następnie weryfikowano czy, któryś z wybranych parametrów nie narzucał niekorzystnego układu współrzędnych, tj. takiego, w którym możliwości dyskryminacyjne cech są zanizone. Takie zjawisko może nastąpić w sytuacji, gdy parametr jest skorelowany z innymi cechami i charakteryzuje się słabymi możliwościami dyskryminacyjnymi. Proces realizowano za pomocą interfejsu graficznego, który umożliwia definiowanie

wektora cech stale odrzucanych lub zachowywanych. Algorytm selekcji cech wraz z interfejsem graficznym znacznie przyspieszył wybór odpowiedniego zestawu parametrów, dzięki czemu pozwolił na przebadanie dużej liczby kombinacji. Pomimo tego, że wybierane przez algorytm cechy charakteryzowały się zadowalającymi własnościami dyskryminacyjnymi w procesie weryfikacji udawało się odnajdywać korzystniejsze rezultaty. Predyspozycje do różnicowania każdego zestawu parametrów przyjęto oceniać za pomocą miary Fishera danych jednowymiarowych po transformacji LDA. Wybrano 10 najlepszych wyników, które zestawiono w tabeli 3.

Na rysunku 3 przedstawiono dane otrzymane za pomocą falki db4 po transformacji LDA oraz pogrubionymi liniami średnie w klasach. Dane oddzielono składową stałą w celach poglądowych. Na ilustracji zobrazowano 100 przypadków diagnostycznych po 50 dla klasy *zdrowy* oraz *chory*. Można zaobserwować, że istnieje sposobność dobrania progu decyzyjnego tak, aby nastąpiły dwa błędy dla klasy *zdrowy*, co jest wynikiem obiecującym.

Tabela 3. Zestawienie możliwości dyskryminacyjnych cech po transformacji LDA.

Nazwa falki	Miara Fishera po LDA	Przesunięcie kołowe sygnału WPW	Liczba cech
db4	1,45	76	5
sym14	1,42	47	6
db8	1,41	70	5
db2	1,41	-251	6
db2	1,40	-261	3
sym5	1,39	-234	6
db4	1,39	68	7
db8	1,38	76	4
sym5	1,38	-258	7
db7	1,38	-14	8



Rys.3. Dane otrzymane za pomocą falki db4 zrzutowane na kierunek optymalny.

W wyniku selekcji cech oraz analizy porównawczej do opracowania systemu wybrano 5 cech otrzymanych w rezultacie dekompozycji falkowej sygnału WPW, przesuniętego kołowo o 76 próbek, przeprowadzonej za pomocą falki db4.

Klasyfikacja

Postanowiono do opracowania klasyfikatora wykorzystać sieć SVM, która obecnie w większości problemów klasyfikacji jest bezkonkurencyjna [10]. Wyznaczenie funkcji klasyfikującej polega na znalezieniu w procesie uczenia takich mnożników Lagrange'a, przyporządkowanych do wektorów nośnych, które gwarantują optymalnie szeroki margines separacji. Proces optymalizacji szerokości marginesu dla danych nieseparowalnych liniowo jest realizowany poprzez definiowanie tzw. miękkiego marginesu (ang. *soft margin*) oraz nieliniowej funkcji jądra. Miękki margines uzyskiwany jest przez określenie tzw. stałej regularyzacji C , która umożliwia ograniczenie wartości mnożników Lagrange'a (wzór 4).

$$(4) \quad 0 \leq \alpha_{oj} \leq C$$

gdzie α_{oj} to mnożniki Lagrange'a.

W efekcie można regulować wpływ wektorów nośnych na położenie hiperpłaszczyzny rozdzielającej dane z różnych klas. Z kolei funkcja jądra umożliwia przekształcenie nieliniowe wektorów cech z przestrzeni pierwotnej do innej przestrzeni o takim samym lub większym wymiarze, w której stają się one separowalne liniowo [11].

Jak pokazano w poprzednim rozdziale dane są nieseparowalne liniowo (rys 3). Dlatego zdecydowano drogą badań odnaleźć odpowiednią funkcję jądra wraz z jej parametrami oraz stałą regularyzacji. Zazwyczaj poszukiwanie odpowiednich wartości parametru funkcji jądra oraz stałej regularyzacji odbywa się metodą prób [10]. Takie podejście z kolei jest bardzo czasochłonne. W rezultacie postanowiono przygotować bazę danych wraz z interfejsem graficznym, który umożliwi efektywne przebadanie wielu kombinacji podczas badań oraz dokona ich archiwizacji i zestawienia zgodnie z zdefiniowanym przez użytkownika widokiem.

Zaplanowano opracować szereg klasyfikatorów dla różnych wartości stałej regularyzacji oraz parametrów funkcji jądra. Przyjęto dwa sposoby oceny klasyfikatorów. W pierwszym podejściu, które nazwano metodą standardową, wyznaczono losowo zbiór uczący oraz testujący. Wybrano 200 przypadków diagnostycznych do procesu uczenia po 100 z klasy *zdrowy* oraz *chory*, a pozostałe do procesu testowania. Drugie rozwiązanie dotyczyło tzw. metody krosvalidacji krzyżowej. W tej metodzie proces uczenia odbywa się iteracyjnie, tak aby do procesu uczenia wykorzystać wszystkie możliwe wektory cech. Przygotowano 10 bloków danych. Każdy z bloków zawiera, z wyjątkiem ostatniego, 15 przypadków chorych oraz 25 zdrowych. W każdej iteracji 9 bloków wykorzystywanych jest do procesu uczenia a 1 blok do procesu testowania. Otrzymane własności klasyfikatora są wartością średnią otrzymanych wyników z 10 iteracji. Ze względu na fakt, że metoda krosvalidacji krzyżowej jest skomplikowana obliczeniowo, na początku za pomocą metody standardowej wybierany jest zakres stałej regularyzacji bądź parametru funkcji jądra zasadny do bardziej szczegółowej analizy.

W pierwszej kolejności poszukiwano odpowiedniej funkcji jądra oraz ewentualnie jej parametru. Wybrano następujące funkcje jądra: liniową, kwadratową, wielomianową oraz Gaussa.

Spośród wybranych funkcji jądra dwie są parametryczne tj. funkcja wielomianowa oraz Gaussa. Dla pierwszej funkcji można definiować stopień wielomianu p , z którego wzrostem rośnie złożoność obliczeniowa. Z tego względu ograniczono się do stopnia 3, 4 oraz 5. Z kolei dla funkcji jądra Gaussa istnieje sposobność do definiowania parametru z zakresu liczb rzeczywistych dodatnich. Zastosowano uproszczenie polegające na tym, że

eksperymentalnie dobrano wartość parametru przy stałej regularyzacji wynoszącej 1. Najlepsze rezultaty otrzymano dla parametru σ równego 0,62; 0,64; 0,94.

Tabela 4. Wybrane funkcje jądra [10] \mathbf{x}_i to wektor cech, p oraz σ to parametry funkcji jądra.

Funkcja jądra	Równanie
Liniowa	$\mathbf{K}(\mathbf{x}_j, \mathbf{x}_i) = \mathbf{x}_j^T \mathbf{x}_i$
Kwadratowa	$\mathbf{K}(\mathbf{x}_j, \mathbf{x}_i) = (1 + \mathbf{x}_j^T \mathbf{x}_i)^2$
Wielomianowa	$\mathbf{K}(\mathbf{x}_j, \mathbf{x}_i) = (1 + \mathbf{x}_j^T \mathbf{x}_i)^p$
Gaussa	$\mathbf{K}(\mathbf{x}_j, \mathbf{x}_i) = \exp\left(-\frac{\ \mathbf{x}_j - \mathbf{x}_i\ ^2}{2\sigma^2}\right)$

Po wybraniu parametrów funkcji jądra przeprowadzono liczne eksperymenty ukierunkowane na dobór suboptymalnej wartości stałej regularyzacji. Im większa wartość tego parametru, tym wektory nośne będące w najbliższym sąsiedztwie klasy przeciwnej będą miały większy wpływ na położenie hiperpłaszczyzny rozdzielającej. Takie zjawisko może mieć bardzo negatywny wpływ na jakość klasyfikatora szczególnie, gdy te przypadki są znacznie odbiegające. Z drugiej strony bardzo mała wartość stałej regularyzacji skutkuje tym, że wektorów nośnych jest bardzo dużo, co również powoduje znaczne pogorszenie własności funkcji klasyfikującej.

W pierwszej kolejności oceniano klasyfikator dla różnych wartości stałej regularyzacji za pomocą metody standardowej. Wybrano zakresy charakteryzujące się najlepszymi własnościami dyskryminacyjnymi, aby dokonać oceny porównawczej funkcji klasyfikujących za pomocą metody krosvalidacji. Przeprowadzono analizę porównawczą otrzymanych rezultatów w oparciu o szereg parametrów zdefiniowanych w rozdziale *Warunki badań*. Postanowiono wykorzystać dodatkowy wskaźnik charakterystyczny dla sieci SVM, tj. górne oszacowanie błędu wyrażone przez wzór 5 [10].

$$(5) \quad E_{SVM} = \frac{N_{SV}}{u-1} \cdot 100\%$$

gdzie: E_{SVM} to górne oszacowanie błędu, u stanowi liczebność zbioru uczącego, N_{SV} oznacza liczbę wektorów nośnych.

Konsekwencją wzoru 5 jest fakt, że należy minimalizować liczbę wektorów nośnych. Nawet w przypadku, gdy zwiększy się liczba błędnych klasyfikacji w zbiorze uczącym, mniejsza liczba wektorów nośnych spowoduje zmniejszenie błędu klasyfikacji w zbiorze testującym [11].

Wybrano najlepsze rezultaty otrzymane dla konkretnych funkcji jądra. Otrzymane wyniki zestawiono w tabeli 5.

Tabela 5. Otrzymane własności funkcji klasyfikujących (u – oznacza zbiór uczący, t – zbiór testujący, SV – liczba wektorów nośnych).

Funkcja jądra	Parametr	C	uSE [%]	uFP [%]	tSE [%]	tFP [%]	ACC [%]	N_{SV}
Gaussa	$\sigma=0,94$	48,0	95,35	9,53	95,29	9,43	92,29	79,2
Kwadratowa	–	4,6	94,34	8,30	94,67	9,79	92,60	84,7
Wielomianowa	$p=5,00$	0,2	94,61	7,90	95,33	8,99	92,99	79,2
Liniowa	–	202,0	94,69	9,44	95,33	10,59	92,04	72,6

Zaprezentowane wyniki są porównywalne w odniesieniu do czułości, prawdopodobieństwa fałszywego alarmu oraz dokładności. Jednak ze względu na fakt, że klasyfikator zbudowany na liniowej funkcji jądra posiada najmniejszą

liczbę wektorów nośnych oraz jest najmniej skomplikowany obliczeniowo został wybrany do zbudowania systemu.

Przed opracowaniem systemu postanowiono odnieść się do rezultatów otrzymanych w ramach [9]. Jednak, aby

tego dokonać należało opracować klasyfikator dla danych otrzymanych w oparciu o falkę db8 za pomocą sieci SVM. Wykonano analizę dla liniowej funkcji jądra ukierunkowaną na dobór odpowiedniej stałej regularyzacji. Otrzymane rezultaty przedstawiono w tabeli 6.

Tabela 6. Otrzymane własności funkcji klasyfikującej zbudowanej na podstawie falki db8.

C	uSE [%]	uFP [%]	tSE [%]	tFP [%]	ACC [%]	N _{sv}
77	91,90	11,77	91,86	12,63	89,53	90,2

Na podstawie własności klasyfikatora zbudowanego za pomocą falki db8 w porównaniu z klasyfikatorem otrzymanym w oparciu o falkę db4, można stwierdzić, że sformułowane dotychczas wnioski oraz podjęte decyzje są zasadne, gdyż pozwoliły na otrzymanie znacznie lepszych rezultatów.

Do opracowania systemu wykorzystano metodę standardową używaną poprzednio do oceny klasyfikatora. Wykorzystano także wcześniej przygotowane dane z klasy *pogranicze patologii i normy oraz brak odpowiedzi na bodziec* do procesu testowania systemu. Otrzymane własności wyznaczonego klasyfikatora zestawiono w tabelach 7 i 8.

Tabela 7. Otrzymane własności systemu klasyfikującego.

uSE [%]	uFP [%]	tSE [%]	tFP [%]	ACC [%]
95,00	6,00	100,00	14,38	91,79

Tabela 8. Otrzymane własności systemu klasyfikującego cd (tP – oznacza zbiór z pogranicza, tB – zbiór przypadków nie reagujących na bodziec).

N _{sv}	E _{SVM} [%]	tP [%]	tB [%]
28	14,08	66,67	90,63

Otrzymano korzystne własności klasyfikacyjne systemu. Czulość klasyfikatora w zbiorze testującym wyniosła 100%, co jest szczególnie dobrym rezultatem w zastosowaniach medycznych. Konsekwencje złego przyporządkowania stanu pacjentowi choremu są zdecydowanie bardziej poważne niż w sytuacji odwrotnej. Dlatego prawdopodobieństwo fałszywego alarmu na poziomie 14,38% nie stanowi problemu, ponieważ spowoduje jedynie większą liczbę pacjentów zdiagnozowanych jako chorych. Ciekawym zjawiskiem jest sposób reagowania klasyfikatora na przypadki z klas, które nie były wykorzystywane w procesie uczenia. Zgodnie z wcześniej sformułowanymi przypuszczeniami funkcja klasyfikująca nieznacznie lepiej niż losowo przyporządkowuje pacjentom z pogranicza patologii i normy stan zdrowy. Co więcej w kwestii pacjentów nie reagujących na bodziec 90,63% pacjentów zostało przyporządkowanych do klasy *chory*. Jak wykazano powyżej, opracowany system skutecznie wesprze lekarzy w procesie podejmowania decyzji o stanie zdrowia pacjenta.

Podsumowanie

Opracowano wiarygodny system do zautomatyzowania procesu oceny wzrokowych potencjałów wywołanych za pomocą licznej grupy 402 przypadków diagnostycznych. Funkcja klasyfikacyjna jest planowana do wykorzystania w codziennej praktyce lekarskiej w aplikacji *Software supporting diagnostics of Brainstem Auditory Evoked Potentials* używanej dotychczas do analizy słuchowych potencjałów wywołanych [6].

W dalszej kolejności autorzy planują opracowanie metody do oceny schorzeń rozpoznawanych za pomocą latencji międzyocnych oraz klasyfikatora do oceny wzrokowych potencjałów wywołanych zarejestrowanych za pomocą metody *Flash*.

Autorzy: ppor. mgr inż. Paweł Stasiakiewicz, 3. Wojskowy Ośrodek Metrologii, ul. Wileńska 14, 56-400 Oleśnica, E-mail: pawel.stasiakiewicz@wat.edu.pl; dr hab. inż. Andrzej Piotr Dobrowolski, prof. WAT, Wojskowa Akademia Techniczna, Wydział Elektroniki, ul. Sylwestra Kaliskiego 2, 00-908 Warszawa, E-mail: andrzej.dobrowolski@wat.edu.pl; dr hab. n. med. Kazimierz Tomczykiewicz, Wojskowy Instytut Medyczny, Klinika Neurologiczna, ul. Szaserów 128, 04-141 Warszawa, E-mail: ktomczykiewicz@wim.mil.pl.

LITERATURA

- [1] https://sound.eti.pg.gda.pl/student/pp/oko-budowa_i_wlasnosci.pdf, (05 Luty 2015).
- [2] Zaher A., Visual and Brainstem Auditory Evoked Potentials in Neurology, *InTech*, (2012).
- [3] <http://www.edoctoronline.com/medical-atlas.asp?c=4&id=21878&m=1&p=33&cid=1060&s>, (05 Luty 2015).
- [4] Binnie C. D., Cooper R., Manguiere F., Osselton J., Prior P. F., Tedman B. M., Clinical Neurophysiology: EMG, Nerve Conduction and Evoked Potentials, *Elsevier B.V.*, 1 (2004), 2nd Edition.
- [5] Dobrowolski A. P., Okoń M., Spectral analysis of visual evoked potentials, *Signal Processing Symposium SPSympo-2015*, (2015).
- [6] Dobrowolski A. P., Suchocki M., Tomczykiewicz K., Majda-Zdanczewicz E., Classification of auditory brainstem response using wavelet decomposition and SVM network, *Biocybernetics and Biomedical Engineering*, 36 (2016), nr 2, 427-436.
- [7] Stasiakiewicz P., Suchocki M., Projekt i implementacja bazy wzrokowych potencjałów wywołanych, *wiWAT*, (2015).
- [8] Dobrowolski A. P., Klasyfikacja wzrokowych potencjałów wywołanych w oparciu o dekompozycję wielorozdzielczą i sieć SVM, *Elektronika: konstrukcje, technologie, zastosowania*, 57 (2016), nr 2, 42-46.
- [9] Stasiakiewicz P., Dobrowolski A. P., Tomczykiewicz K., Automatyczna klasyfikacja wzrokowych potencjałów wywołanych w oparciu o dekompozycję falkową, *KNTWRE*, (2016).
- [10] Osowski S., Metody i narzędzia eksploracji danych, *Wydawnictwo BTC*, (2013), Wyd. 1.
- [11] Dobrowolski A. P., Wierzbowski M., Tomczykiewicz K., Multiresolution MUAPS decomposition and SVM-based analysis in the classification of neuromuscular disorders, *Computer Methods and Programs in Biomedicine 2012*, 107 (2012), nr 3, 393-403.