

# KOMPUTEROWO WSPOMAGANA KLASYFIKACJA WYBRANYCH SYGNAŁÓW ELEKTROMIOGRAFII POWIERZCHNIOWEJ

Gustaw Rzyman<sup>1a</sup>, Grzegorz Redlarski<sup>1b</sup>, Marek Krawczuk

<sup>1</sup>Katedra Mechatroniki i Inżynierii Wysokich Napięć

<sup>a</sup>gustaw.rzyman@pg.gda.pl, <sup>b</sup>grzegorz.redlarski@pg.gda.pl

## Streszczenie

Wykorzystywanie sygnałów elektromiografii powierzchniowej (ang. Surface Electromyography, *SEMG*) w procesach sterowania systemami rehabilitacyjnymi stanowi obecnie standardową procedurę. Popularność SEMG wynika z nieinwazyjności metody oraz możliwości szybkiej i precyzyjnej identyfikacji funkcji mięśniowej. W przypadku osób małoletnich proces klasyfikacji sygnałów jest utrudniony ze względu na mniejsze rozmiary i wyższą dynamikę aktywności włókien mięśniowych niż u osób dorosłych. W związku z powyższymi uwagami, w artykule przedstawiono wyniki badań zwiększających wskaźnik poprawnej klasyfikacji wybranych ruchów dłoni dzieci. Omówiono zastosowane do tego celu modele matematyczne: k-najbliższych sąsiadów, drzewo decyzyjne oraz metodę wektorów nośnych; a także zastosowane miary i metodykę „strojenia” parametrów modeli.

**Słowa kluczowe:** sterowanie, klasyfikacja sygnałów, elektromiografia powierzchniowa

## COMPUTER-ASSISTED CLASSIFICATION OF SELECTED SURFACE ELECTROMYOGRAPHY SIGNALS

### Summary

Overarching objective of this paper is classification of basic hand gestures by surface electromyography for healthy children. Main difference between biosignals corresponding to adults and children muscle activity is disparate growth of muscles. For this reason youngsters need separate method of signals classification. In this paper we decide to create a mathematical model and compare three classification method: a support vector machine, k nearest neighbors and decision tree methods. Furthermore we used the best set of time domain (MAV, WAMP, WL and SSC) and selected several parameters to make each model as good as possible.

**Keywords:** control, signals classification, surface electromyography

### 1. WSTĘP

Badania związane ze poprawą klasyfikacji gestów dłoni, na podstawie analiz sygnałów elektromiograficznych (ang. Surface Electromyography, *SEMG*), są opisywane w rozległej literaturze przedmiotu [4, 9]. Badania SMEG polegają na rejestracji wzmocnionych sygnałów o bioelektrycznej aktywności danego mięśnia, w odpowiedniej pętli sprzężenia zwrotnego. Zarejestrowane we wskazany sposób informacje można wykorzystywać w procesach sterowania inteligentnymi robotami lub protezami rehabilitacyjnymi [2]. W nowoczesnych systemach rehabilitacyjnych wykorzystywane są zarówno sygnały

biochemiczne jak i bioelektryczne, pochodzące od osoby badanej. Dostarczają one użytecznych informacji w takim zakresie, że w wysoce zaawansowanych rozwiązaniach technicznych możliwe jest przejęcie i sprawowane kontroli nad obsługiwanym procesem, przy zachowaniu w pełni warunków bezpieczeństwa.

Obecnie w przypadku klasyfikacji gestów, w grupie osób dorosłych, satysfakcjonujące wyniki – na poziomie 98,12% – uzyskuje się po przyjęciu miary w postaci średniej wartości bezwzględnej sygnału (ang. mean

absolut value, MAV), a następnie zastosowaniu klasyfikatora maszyny wektorów nośnych (ang. support vector machines, SVM) [9].


U dzieci w przeciwieństwie do osób dorosłych wyniki są znacząco gorsze, co związane jest z wysokim współczynnikiem błędnej klasyfikacji wahającym się w przedziale 30-50% [19], co wynika z rozbieżności aktywności bioelektrycznej podyktowanej niepełnym stadium rozwoju włókien mięśniowych, mniejszą geometrią oraz szybszą i charakteryzującą się większą dynamiką aktywności ruchowej. Czynniki te – m.in. jak wykazano w pracach Granata i wsp. oraz Wu i wsp. [5, 18] – nastręczają trudności zarówno na etapie pomiarów jak i klasyfikacji sygnałów SMEG osób małych.

Powyższe niedogodności skłoniły autorów do przeprowadzenia serii pomiarów, a następnie badań mających na celu zoptymalizowanie metod klasyfikacji biosygnałów pochodzących od dzieci. W badaniach tych ograniczono się do klasyfikacji gestów wynikających z bioelektrycznej aktywności mięśni przedramienia, gdyż w przyszłości to właśnie one mogą stanowić podstawę do sterowania pracą bionicznej ortozy rehabilitacyjnej kończyny górnej.

## 2. POMIARY ORAZ PRZETWARZANIE SYGNAŁÓW POMIAROWYCH

### 2.1. ZAKRES POMIARÓW

Wszystkie pomiary zostały wykonane na grupie w pełni zdrowych osób małych, w wieku od 7 do 15 lat, obu płci. Badania spełniały normę eksperymentu kontrolowanego. Urządzenie pomiarowe stanowił dwukanałowy elektromiograf NeuroTrac MyoPlus2 (wraz z oprogramowaniem *NeuroTrac PC Software*), którego częstotliwość próbkowania wynosiła 16 Hz. Odczyty i zapisy potencjału czynnościowego jednostki ruchowej dotyczyły zginacza promieniowego nadgarstka oraz prostownika promieniowego długiego nadgarstka. Mięśnie te działają antagonistycznie i odpowiadają za zdefiniowane w eksperymencie ruchy dłoni (rys. 1): zamknięcie pięści (HC), otwarcie dłoni (HO), zgięcie dłoni w nadgarstku „do przodu” (WF), zgięcie dłoni w nadgarstku „do tyłu” (WE), wyprostowanie palca wskazującego (IF), wyprostowanie kciuka (T). Elektrody zostały umieszczone na skórze bezpośrednio nad głową badanego mięśnia oraz w miejscu niewystępowania aktywności bioelektrycznej- elektroda referencyjna (np. na kości lub stawie).




Rys. 1. Wykaz gestów zastosowanych podczas badania

### 2.2. CEL PRZETWARZANIA SYGNAŁÓW POMIAROWYCH

Sygnały z elektromiografu należą do grupy sygnałów niestacjonarnych, dlatego ich cyklicznym pomiarom towarzyszą pewne niedogodności, wynikające z losowego charakteru zmian i tym samym trudności w określaniu częstotliwości próbkowania, długości sygnału czy chwili, w której należy rozpocząć pomiar. Ponadto każdemu ze zdefiniowanych podczas badań gestów (rys. 1) towarzyszą różnice cech rejestrowanych przebiegów, które stanowią podstawę zautomatyzowania procesu klasyfikacji.

Na rys. 2 przedstawiono przykładowe przebiegi reprezentujące (dla gestu WE) podczas wykonywania czynności antagonistycznych: zginania i prostowania.



Rys. 2. Przykład zmienności sygnałów z SEMG podczas wykonywania czynności antagonistycznych (dla gestu WE)

Biorąc pod uwagę powyższe uzasadnienie, a także przedstawione na rys. 2 rozbieżności, można stwierdzić, że podstawowym celem przetworzenia jest wyodrębnienie z całej populacji jedynie tych przebiegów pomiarowych, które niosą informacje istotne i miarodajne. Pierwszym etapem przetwarzania jest więc odseparowanie sygnałów odpowiadających aktywnościom mięśniowym podczas wykonywania określonych gestów, a następnie poddanie ich procesowi filtracji pasmowo-procesowej w

celu usunięcia wartości próbek znacznie odbiegających od oczekiwanych wartości średnich.

W celu osiągnięcia wyżej wymienionego założenia autorzy dokonali czynności opisanych w kolejnych podrozdziałach. Podjęte działania obejmowały: zdefiniowanie miar zmienności sygnałów pomiarowych oraz ich klasyfikację leżącą u podstaw wielowymiarowej analizy danych.

### 2.3. MIARY ZMIENNOŚCI PRZEBIEGÓW POMIAROWYCH

W literaturze poświęconej miarom zmienności przebiegów lub funkcji opisywany jest szereg parametrów wywodzących się z różnych działów matematyki, statystyki, analizy matematycznej, analizy funkcjonalnej, itp. [1].

W celu zoptymalizowania stopnia efektywności identyfikacji wybranych cech sygnałów SMEG należy zbadać, która ze znanych miar (lub które połączenie kombinacji znanych miar) pozwoli na uzyskanie najwyższego stopnia poprawnej klasyfikacji. Jednocześnie zastosowanie zbyt dużej liczby znanych metod negatywnie wpływa na wynik poprawnej klasyfikacji. Dlatego też podstawowym kryterium wyboru w opisywanym procesie postępowania są aktualne doniesienia literaturowe oraz doświadczenie zespołu w danej dziedzinie.

W wyniku analizy najnowszych pozycji literatury [10, 17, 19, 20], a także po uwzględnieniu wyników eksperymentów przeprowadzonych przez autorów i częściowo opisanych w pracy Palkowskiego i wsp. [9], wytypowano następujące miary: MAV, długość przebiegu w czasie (ang. wave length, WL), amplitudę Willsona (ang. Willson amplitude, WAMP) oraz współczynnik zmiany zbrocza (ang. slope sign change, SSC), które są opisane wzorami (1) ÷ (4), dla kolejnych, chwilowych wartości sygnałów  $x$ :

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (1)$$

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (2)$$

$$WAMP = \sum_{i=1}^{N-1} [f(|x_i - x_{i+1}|)] \quad (3)$$


$$f(x) = \begin{cases} 1 & \text{jeżeli } x \geq \text{wartości progowej} \\ 0 & \text{pozostłe} \end{cases}$$

$$SSC = \sum_{i=2}^{N-1} [f(|x_i - x_{i-1}|) \times [x_i - x_{i+1}]] \quad (4)$$

$$f(x) = \begin{cases} 1 & \text{jeżeli } x \geq \text{wartości progowej} \\ 0 & \text{pozostłe} \end{cases}$$

W odniesieniu do rozpatrywanego zagadnienia MAV pozwala w prosty i szybki sposób określić poziom skurczu badanego mięśnia. WL jest powiązana z amplitudą, częstotliwością i czasem analizowanego przypadku. WAMP służy do redukcji zakłóceń, natomiast współczynnik SSC jest związany z informacją o częstotliwości sygnałów pochodzących z SEMG. W przypadku wskaźników WAMP oraz SSC konieczny jest dobór paramet

trów progowych, dzięki którym eliminowane są nagłe skoki napięcia oraz nie dochodzi do interferencji sygnałów pochodzących z SEMG. Kolejnym krokiem opisywanej w niniejszym podrozdziale metodyki jest normalizacja poszczególnych metod analizy czasowej. Normalizacja sygnału z SEMG sprowadza się do przeskalowania amplitudy przez przyrównanie wielkości badanej z wartością wzorcową [13]. Na rys. 3, na bazie przebiegów z rys. 2, przedstawiony został wykres prezentujący wyżej opisywane czynności (gest po analizie SSC oraz po normalizacji). Należy podkreślić, że w celu dokonania analizy czasowej (osobnej dla każdej z opisanych metod), wartości progowe dla każdego klasyfikatora zostały dobrane w sposób indywidualny.



Rys. 3. Wykres sygnałów dla wybranego gestu po analizie SSC oraz normalizacji

### 2.4. METODYKA ANALIZY DANYCH

W celu rozstrzygnięcia, do której z grup testowych (rys. 1) należy zaliczyć dany przebieg pomiarowy, konieczne jest zastosowanie metod wielowymiarowej analizy danych, których szczególny przypadek stanowi analiza dyskryminacyjna. Podstawę tej metody – dającej miarodajne wyniki w przypadku homogenicznych zbiorów danych – stanowią dwa kolejne etapy: etap 1 – związany z budową modelu dla potrzeb zdefiniowania reguł klasyfikacyjnych na bazie zbioru uczącego oraz etap 2 – związany z klasyfikacją analizowanych obiektów na podstawie opracowanego modelu [15].

W wyżej wymienionej grupie metod, dla potrzeb klasyfikacji sygnałów SEMG, szczególne miejsce zajmuje liniowa analiza dyskryminacyjna (ang. linear discriminant analysis, LDA) oraz kwadratowa analiza dyskryminacyjna (ang. quadratic discriminant analysis, QDA). Zastosowanie wyżej wymienionych metod prowadzi do poprawnej interpretacji sygnałów SEMG, odpowiednio na poziomie 64,7% oraz 72,5% analizowanych przypadków [8]. Warto jednak zwrócić uwagę na fakt, że w opisywanym przypadku proces dyskryminacji nie był optymalizowany, a uzyskane wyniki zawierają bezpośredni odczyt wartości z SEMG.

### 3. KLASYFIKACJA SYGNAŁÓW

#### 3.1. ISTOTA KLASYFIKACJI

Obecnie znanych jest szereg metod klasyfikacji sygnałów pochodzących z różnorodnych urządzeń pomiarowych, w tym z elektromiografu - począwszy od metod klasyfikacji wykorzystujących sztuczną inteligencję i uczenie maszynowe, poprzez analizy dyskryminacyjne, a skończywszy na inteligentnych systemach wsparcia decyzyjnego. Efektywność klasyfikatorów można zwiększyć dodatkowo, stosując algorytmy optymalizacyjne. Jeden ze standardowych przykładów w tej dziedzinie demonstruje zastosowanie sztucznych sieci neuronowych do rozpoznawania gestów dłoni na bazie sygnałów zarejestrowanych za pomocą elektromiografu. Skuteczność rozpoznawania wynosi w tym przypadku od 72% do 92%, w zależności od rodzaju zastosowanej sieci neuronowej [17]. Należy podkreślić, że omówiony przykład nie uwzględnia klasyfikatora SVM, który obecnie uchodzi za jedno z najefektywniejszych narzędzi w przypadku złożonych i nieliniowych modeli, które nie są separowalne liniowo [6]. Niemniej jednak przykład optymalizacji klasyfikatora SVM za pomocą algorytmu optymalizacji rojem cząstek (ang. particle swarm optimization, PSO) można znaleźć w pracy Subasi [14], a propozycję wspomaganie klasyfikatora SVM przez algorytm optymalizacyjny kukulek (ang. cuckoo search, CS), w pracy Palkowskiego i wsp. [9]. Warto podkreślić, że w tym ostatnim przypadku uzyskuje się wysoką poprawność klasyfikacji, sięgającą 98,12%.

Porównywalnie wysoką skutecznością działania charakteryzuje się sieć adaptacyjna bazująca na systemie wnioskowania rozmytego (ang. adaptive neuro-fuzzy inference system, ANFIS). W przypadku tego podejścia opisywana skuteczność poprawnych klasyfikacji sięga 95% [13].

Kolejny sposób klasyfikacji sygnałów SEMG jest związany z zastosowaniem metody K najbliższych sąsiadów (ang. K nearest neighbors, KNN). Poprawność rozpoznawania gestów dłoni u osób dorosłych sięga tu 82% [7].

Ostatnią ze wskazywanych w literaturze metod, ważną i często stosowaną metodą klasyfikacji, jest drzewo decyzyjne [2]. Osiągana poprawność klasyfikacji sygnałów sięga 96,67%.

Powyższa analiza porównawcza wskazuje jednoznacznie, że wybór odpowiedniego klasyfikatora jest najistotniejszym, a zarazem najtrudniejszym działaniem na etapie szybkiej i efektywnej klasyfikacji sygnałów bioelektrycznych. Skuteczność właściwej interpretacji sygnału zależy od wielu czynników, w tym m.in. od: jego źródła (rodzaju mięśnia i jego lokalizacji), maksymalnej liczby moni-

torowanych mięśni (wynikającej z liczby kanałów elektromiografu), wieku pacjenta, stanu zdrowia, itp.

Uwzględniając powyższe oraz przyjmując jako kryterium wyboru metody wskaźnik poprawnej klasyfikacji sygnałów bioelektrycznych, wytypowano następujące metody klasyfikacji sygnałów SMEG u osób małoletnich:

- maszynę wektorów nośnych,
- metodę K najbliższych sąsiadów,
- drzewo decyzyjne.

Dodatkowo, w celu usprawnienia procesu nauczania maszynowego, w przypadku każdego z klasyfikatorów sięgnięto po metodę krzyżowej walidacji (ang. cross validation). Istotą krzyżowej walidacji stanowi podział całego zbioru danych na mniejsze podzbiory o równej liczbie danych, a następnie sekwencyjny wybór określonego podzbioru na potrzeby walidacji, a wszystkich pozostałych jako podzbioru do uczenia sieci. Maksymalna liczba krzyżowych walidacji jest więc określona liczbą podzbiorów, dzięki czemu możliwe jest zastosowanie wielokrotnej walidacji wykorzystującej ten sam zbiór danych do uczenia maszynowego oraz do walidacji modelu matematycznego. Dodatkową zaletą zastosowania takiego podejścia jest przeciwdziałanie efektowi przeuczenia modelu.

#### 3.2. KLASYFIKATOR SVM

Klasyfikator określany mianem maszyny wektorów nośnych (SVM) jest techniką nadzorowanego uczenia maszynowego. Polega ona na rozwiązywaniu zagadnień klasyfikacji binarnej na podstawie wyznaczonej hiperpłaszczyzny lub ich zbioru oddzielającego dwie klasy  $y_i \in (-1; +1)$  od siebie. W celu zwiększenia skuteczności klasyfikatora dąży się do wyznaczenia jak największego marginesu rozdziału klas. Pierwotnie SVM został stworzony z myślą o rozwiązywaniu zagadnień liniowych, jednak w późniejszym okresie został przekształcony w nieliniowy klasyfikator poprzez zastosowanie funkcji *Kernela*.

Zastosowanie powyższego klasyfikatora sprowadza się do kilku następujących po sobie kroków [11]:

- zgromadzenie danych niezbędnych w procesie uczenia maszynowego,
- podjęcie próby wyznaczenie rozwiązania,
- wyznaczenia parametrów hiperpłaszczyzny o najlepszych właściwościach względem rozdziału klas,
- trenowanie docelowego modelu przy użyciu wyznaczonych wcześniej i optymalnych parametrów klasyfikatora,
- walidacja wyników przy użyciu testowego zestawu danych.

Podstawowymi zaletami powyższej metody są: wysoka skuteczność rozdziału klas w przestrzeni wielowymiarowej oraz wszechstronność zastosowania [11].

Stosując metodę maszyny wektorów nośnych, konieczny jest więc dobór parametrów modelu. W procesie klasyfikacji gestów u osób małoletnich na podstawie sygnałów SEMG takimi parametrami są: współczynnik błędu określający błąd klasyfikatora lub szerokość marginesu rozdziału, współczynnik jądrowego estymatora gęstości oraz parametr odwzorowujący jądrowy estymator gęstości (związany z funkcją *Kernela*).

### 3.3. METODA K NAJBLIŻSZYCH SĄSIADÓW

Algorytm KNN jest nieparametryczną metodą rozpoznawania rozwiązań (na etapie uczenia maszynowego) stosowaną w zagadnieniach klasyfikacji i regresji. Metoda ta jest rozszerzeniem teorii określanej mianem algorytmu najbliższych sąsiadów (ang. nearest neighbors, NN), która opiera się na modelu pamięciowym określonym przez pewien zestaw danych. Przynależność parametru do odpowiedniej klasy określana jest na podstawie większości znanych  $k$  najbliższych sąsiadów. Zastosowanie algorytmu KNN w procesie rozpoznawania gestów składa się z następujących etapów:

- wybór  $n$  wektorów uczących określających  $k$  najbliższych sąsiadów (niezależnie od przynależności do klasy),
- rozpoznanie spośród  $k$  parametrów (gdzie  $k$  jest liczbą sąsiadów) tych, które odpowiadają sygnałom związanym z wykonywaniem danego gestu,
- przypisanie nowego parametru wejściowego do klasy danego gestu przy wykorzystaniu jak największej liczby  $k_i$  (parametr dla  $i$ -tej klasy).

Należy podkreślić, że w metodzie K najbliższych sąsiadów wartość poprawnej klasyfikacji zależy przede wszystkim od parametrów takich jak: liczba najbliższych sąsiadów ( $k$ ) oraz zakres parametrów doboru sąsiadów.

### 3.4. ISTOTA DRZEWA DECYZYJNEGO

Drzewo decyzyjne (ang. decision tree, DT) bazuje na modelu matematycznym, który przewiduje odpowiedź układu za pomocą statystyki (na podobieństwo sieci neuronowych, które posiadają sprzężenie zwrotne i poszukują optymalnego rozwiązania). Struktura DT opiera się na schemacie blokowym, gdzie każdy węzeł wewnętrzny odpowiada za sprawdzenie cech danego sygnału, rozgałęzienie reprezentuje odpowiedź modelu, a węzły końcowe determinują przynależność do poszczególnych klas. Jest to więc rodzaj klasyfikacji bazującej na zasadzie przyrównania do znanych parametrów, nazywany często „systemem eksperckim”. Ponadto, jak podaje literatura [12], w przypadku nadmiernej mnogości

klas algorytm drzewa decyzyjnego może okazać się niepraktyczny w odniesieniu do innych klasyfikatorów.

Warto podkreślić, że model matematyczny opierający się na klasyfikatorze DT posiada tylko jeden parametr istotnie wpływający na jakość poprawnej klasyfikacji – jest to funkcja określająca jakość rozdziału danych.

### 3.5. WYNIKI I DYSKUSJA

Badanie poprawności klasyfikacji gestów wykonywanych przez osoby małoletnie pozwoliło na przetestowanie klasyfikatora SVM, metody KNN oraz algorytmu DT. Najwyższą skuteczność klasyfikacji (określoną jako odsetek poprawnych klasyfikacji – tab. 1) uzyskano, stosując metodę wektorów nośnych. W omawianym przypadku, odsetek ten wyniósł 70%, co stanowi wynik porównywalny z wartościami podawanymi w literaturze [19].

Pozostałe metody (KNN i DT) prowadzą do osiągnięcia porównywalnych rezultatów klasyfikacji, które są nieco niższe, aniżeli w przypadku klasyfikatora SVM.

Powodów uzyskiwania najwyższego stopnia klasyfikacji w przypadku klasyfikatora SVM należy upatrywać w mnogości wykorzystywanych metod optymalizacji, gdyż – jak wykazano w pracy Palkowskiego i wsp. [9] – dodatkowe usprawnienie modelu za pomocą algorytmu rojowego pozwala z reguły na kiluprocentowe zwiększanie stopnia poprawnych klasyfikacji.

Tab. 1. Wyniki klasyfikacji sygnałów za pomocą SVM, KNN oraz DT u osób dorosłych i małoletnich

Klasyfikator	Osoby dorosłe	Osoby małoletnie
SVM	96,81%	70%
KNN	82%	67,7%
DT	77,22%	68,7%

### 4. PODSUMOWANIE I WNIOSKI

Uzyskane wartości poprawnej klasyfikacji sygnałów są niższe u osób małoletnich, co pozwala przypuszczać, iż jest to związane z niepełnym rozwojem włókien mięśniowych (w porównaniu z osobami dorosłymi). Fakt ten znacznie utrudnia pomiary, z uwagi na mniejsze rozmiary mięśni i tym samym słabsze sygnały pomiarowe, o wyższej dynamice – wynikającej ze zwiększonej ruchliwości dzieci. Ponadto w pomiarach z udziałem dzieci zauważalna jest mniejsza powtarzalność rejestrowanych sygnałów. Wskazane czynniki w sposób negatywny wpływają na skuteczność klasyfikatora, co wymaga zastosowania większej liczby miar zmienności funkcji oraz konieczność dokonania optymalizacji modelu matematycznego. Dodatkowo pożądana może być także

większa liczba kanałów pomiarowych elektromiografu. Young i wsp. [20] wskazują, iż zastąpienia elektromiografu 2-kanałowego urządzeniem 6-kanałowym pozwala na zmniejszenie błędów klasyfikacji nawet o 224%. Na tej podstawie można sądzić, że zastosowanie wyżej wymienionych urządzeń u dzieci pozwoliłoby na zwiększenie stopnia poprawnej klasyfikacji do wartości uzyskiwanych w grupie osób dorosłych (90% i więcej).

Warto podkreślić, iż zastosowanie sygnałów SEMG pochodzących od osób małoletnich w celu sterowania ortezą bioniczną wymaga monitoringu dodatkowych bodźców, aby zapewnić motywację do utrzymania zaangażowania w wykonywane serie ćwiczeń na jednolitym poziomie. Dobrym przykładem takiego działania może być połączenie egzoszkieletu rehabilitacyjnego z interaktywną grą komputerową, która pomoga w utrzymaniu skupienia dziecka, a jednocześnie nie powoduje zbyt wysokiej aktywności mięśni.

## Literatura

1. Ahsan Md R., Muhammad I., Othman K.: EMG signal classification for human computer interaction: a review. "European Journal of Scientific Research" 2009, Vol. 33, No.3, p. 480-501.
2. Ercan G., Subasi A.: Comparison of decision tree algorithms for EMG signal classification using DWT. "Biomedical Signal Processing and Control" 2015, Vol. 18, p. 138-144.
3. Fougner A., Stavdahl O., Kyberd P., Losier Y., Parker P. : Control of upper limb prostheses: terminology and proportional myoelectric control—a review. "IEEE Transactions on neural systems and rehabilitation engineering" 2012, Vol. 20, No. 5, p. 663-677.
4. Gijsberts A., Atzori M., Castellini C., Muller H., Caputo B. : Movement error rate for evaluation of machine learning methods for sEMG-based hand movement classification. "IEEE Transactions on Neural Systems and Rehabilitation Engineering" 2014, Vol. 22, No. 4, p. 735-744.
5. Granata K., Darin P., Mark A.: Repeatability of surface EMG during gait in children. "Gait & Posture" 2005, Vol. 22, No. 4, p. 346-350.
6. Güler N., Sabri K.: Classification of EMG signals using PCA and FFT. "Journal of Medical Systems" 2005, Vol. 29, No. 3, p. 241-250.
7. Mohammad T., Hasan M. : Comparison between kNN and SVM for EMG Signal Classification. „International Journal on Recent and Innovation Trends in Computing and Communication (IJRITCC)" 2015, Vol. 3, No. 12, p. 6799-6801.
8. Muhammad F., Rashid N., Akhtar H., Muhammad Z., Gilani S., Ansari U.: Evaluation of LDA, QDA and decision trees for multifunctional controlled below elbow prosthetic limb using EMG signals. "Robotics and Emerging Allied Technologies in Engineering (iCREATE)" 2014, International Conference on. IEEE, 2014.
9. Palkowski, A., Redlarski, G.: Basic Hand Gestures Classification Based on Surface Electromyography. "Computational and mathematical methods in medicine" 2016, DOI 10.1155/2016/6481282.
10. Phinyomark A., Quaine F., Charbonnier S., Serviere C., Tarpin-Bernard F., Laurillau Y. : EMG feature evaluation for improving myoelectric pattern recognition robustness. "Expert Systems with Applications" 2013, Vol. 40, No. 12, p. 4832-4840.
11. Redlarski G., Gradolewski D., Palkowski A.: A system for heart sounds classification. "PloS one" 2014, Vol. 9 No.11, DOI 10.1371/journal.pone.0112673.
12. Safavian R., and Landgrebe D.: A survey of decision tree classifier methodology. "IEEE transactions on systems, man, and cybernetics" 1991, Vol. 21, No. 3, p. 660-674.
13. Sobota G.: Elektromiografia i jej zastosowanie w zaburzeniach aparatu żucia. „Twój Przegląd Stomatologiczny" 2012, Vol. 6, p. 57-61.
14. Subasi A.: Classification of EMG signals using combined features and soft computing techniques. "Applied soft computing" 2012, Vol. 12, No. 8, p. 2188-2198.
15. Subasi A.: Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders. "Computers in biology and medicine" 2013, Vol. 43, No. 5, p. 576-586.

16. Tojza P. : Komputerowo wspomagana analiza przebiegów pH-metrii i pH-metrii z impedancją. Rozprawa doktorska, Gdańsk 2016, p. 65-73.
17. Tsenov G., Zeghib A., Palis F., Shoylev N., Mladenov V. : Neural networks for online classification of hand and finger movements using surface EMG signals. "Neural Network Applications in Electrical Engineering" 2006, NEUREL 2006. 8th Seminar on. IEEE, 2006.
18. Wu M., Liao L., Luo X., Ye X., Yao Y., Chen P., Shi L., Huang H., Wu Y. : Analysis and classification of stride patterns associated with children development using gait signal dynamics parameters and ensemble learning algorithms. "BioMed research international" 2016, DOI 10.1155/2016/9246280.
19. Young A., Smith L., Rouse E., Hargrove L. : Classification of simultaneous movements using surface EMG pattern recognition. "IEEE Transactions on Biomedical Engineering" 2013, Vol. 60, No. 5, p. 1250-1258.



Artykuł dostępny na podstawie licencji Creative Commons Uznanie autorstwa 3.0 Polska.  
<http://creativecommons.org/licenses/by/3.0/pl>