

Karta z dziekanatu

POLITECHNIKA POZNAŃSKA WYDZIAŁ
ELEKTRYCZNY INSTYTUT AUTOMATYKI I
INŻYNIERII INFORMATYCZNEJ

Bartosz Śniegowski

Praca dyplomowa magisterska

**Śledzenie aktywności jednostek motorycznych w trakcie skurczu
mięśnia.**

Promotor: Dr inż. Przemysław Mazurkiewicz

Poznań 2012

Streszczenie

W pracy przedstawiono, algorytm rozpoznawania aktywności jednostek motorycznych w sygnale EMG. Przedstawiona metoda obejmuje etap segmentacji sygnału EMG, porównanie segmentów danych ze wzorcem i na tej podstawie wnioskowanie o przynależności do danej jednostki motorycznej.

W pracy, poruszone są zagadnienia dotyczące anatomii układu nerwowo-mięśniowego, metod akwizycji sygnału ze szczególnym uwzględnieniem tej zastosowanej w pracy. Przedstawiono koncepcję algorytmu, oraz analizę poprawności klasyfikacji.

Abstract

This thesis treats about algorithm of motor units activity detection during small muscle force. Presented method includes stage segmentation EMG signal, comparison segments data with model, and in effect classification to particular motor unit.

Additionally treat about muscle-nervous anatomy, method registration EMG signal. Finally concept of algorithm and analysis of classification correctness, have been presented.

Spis treści:

1. Wprowadzenie	5
1.1 Budowa układu nerwowo-mięśniowego	6
1.1.1 Budowa neuronu	6
1.1.2 Typy komórek mięśniowych	6
1.1.3 Połączenie nerwowo-mięśniowe	7
1.2 Powstawanie sygnału EMG	8
1.3 Pomiar sygnału EMG	9
1.3.1 Rejestracja elektrodą wkłuwaną	9
1.3.2 Rejestracja elektrodą powierzchniową	10
1.3.3 Rejestrator zastosowany w projekcie	12
2. Przegląd literatury	14
3. Dekompozycja sygnału EMG	15
3.1 Przetwarzanie wstępne sygnału EMG	15
3.2 Segmentacja	17
3.2.1 Ręczna	18
3.2.2 Automatyczna pierwsza	19
3.2.3 Automatyczna druga	20
3.3 Klasyfikacja	21
3.3.1 Metoda pierwsza	22
3.3.2 Metoda druga	23
3.3.3 Metoda trzecia	38
3.3.4 Metoda czwarta	38
3.4 Metody weryfikacji uzyskanych wyników	29
3.4.1 Funkcja Drawsignal2	29
3.4.2 Funkcja Drawsignal3	29
3.4.3 Funkcja Prezentacja wyników	30
3.4.4 Funkcja Wynikisubplot	30
3.5 Ciekawsze funkcje	31
4. Implementacja metody	34
5. Inne programy	34
5.1 Usuwacz szumu gaussowskiego	34
5.2 Test losowości	36
6. Wyniki	37
7. Podsumowanie	54
8. Bibliografia	55
9. Załączniki na płycie CD	56


1. Wprowadzenie

W Pracy przedstawiono oprogramowanie, przeznaczone do estymacji aktywności różnych jednostek motorycznych z rzeczywistego sygnału. Do jego rejestracji wykorzystywana jest wielokanałowa elektroda powierzchniowa. Taka konstrukcja pozwala obserwować kształt sygnałów występujących w kilku punktach pomiarowych, dzięki czemu możliwe jest zwiększenie dokładności analizy, a co za tym idzie rozpoznanie większej liczby charakterystycznych potencjałów niż w przypadku elektrody jednokanałowej. Korzyści płynące z zastosowania układu powierzchniowego, to nieinwazyjność i brak konieczności posiadania uprawnień do przeprowadzania eksperymentów. Wadą jest niższa dokładność, ponieważ rejestrowany sygnał jest osłabiany przez rezystancje tkanek przez które się przedostaje. Drugim czynnikiem wpływającym na obniżenie dokładności jest zasięg elektrody. Ponieważ zbiera ona sygnały ze znacznie większej powierzchni niż elektroda igłowa, wzajemnie się one na siebie nakładają i zakłócają. W efekcie przyjęto, że celem nie jest rozpoznanie wszystkich aktywności, a jedynie tych których źródłem są jednostki motoryczne wyładowujące w najbliższym otoczeniu elektrod. Z pomiarowego punktu widzenia są to sygnały o dużej amplitudzie widoczne na wykresie jako wyraźne impulsy aktywności elektrycznej. Jako czas rejestracji przyjęto 10 sekund. Wspomniane oprogramowanie może się przydać do badań mających na celu lepsze poznanie układu nerwowego, bądź rzucić świeższe spojrzenie na metody analizy. Temat jest ważny ponieważ układ nerwowy odgrywa kluczową rolę w kontroli nad ciałem. W przeciwieństwie do fal mózgowych których świadome generowanie jest skomplikowane i absorbuje niemal całkowicie umysł, sygnały EMG są przez wszystkich z łatwością tworzone, przy każdym ruchu.

Istnieje zatem możliwość, że po rozdzieleniu takiego sygnału sterującego pojedynczym mięśniem, człowiek będzie w stanie nauczyć się łatwego kontrolowania kilku pojedynczych jednostek motorycznych z osobna w efekcie mógł by sterować kilkoma dodatkowymi mechanicznymi przegubami, co pozwoliło by na dodanie mu dodatkowych rąk, bądź urządzeń jak chociażby włącznik niewidocznego alarmu, czy w odleglejszej przyszłości bramy garażowej.

1.1 Budowa układu nerwowo-mięśniowego

1.1.1 Budowa neuronu



Rys. 1. Neuron[6].

Neuron, czyli komórka nerwowa, komunikuje[1] się odbierając sygnały elektryczne poprzez dendryty, a wysyłając je aksonem do synaps. Maksymalna długość aksonu to około 1m.

Uszkodzenie, bądź całkowite przerwanie aksonu nie zabija komórki, jednakże zrywa komunikację. Nowy akson może wrosnąć w szczelinę powstałą wewnątrz starego, co daje szansę na odnowienie połączenia, jednakże zwarzywszy na powolność wzrostu, i ryzyko obrania innej ścieżki, przy większych odległościach proces często nie zostaje zakończony w rozsądnym czasie. Kolejnym problemem jest fakt iż w miejscu docelowym połączenia zostają odnawiane w sposób losowy.


1.1.2 Typy komórek mięśniowych

-Szybko męczliwe – przystosowane[1] do oddychania beztlenowego, trawią cukier do kwasu mlekowego(który następnie przetwarzany jest w cukier przez wątrobę), są rozmieszczone głównie na obrzeżach mięśnia

-Wolno męczliwe – przystosowane do oddychania tlenowego, trawią cukier do wody i dwutlenku węgla, znajdują się głównie w wewnętrznej części mięśnia.

-Średnio męczliwe – posiadają cechy obu wymienionych grup komórek.


1.1.3 Połączenie nerwowo-mięśniowe



Rys. 2. Połączenie nerwowo-mięśniowe[8].

Pojedyncza komórka nerwowa[1] steruje grupą kilku do kilkuset komórek mięśniowych zazwyczaj jednego typu męczliwości. Połączenie jest zrealizowane zazwyczaj w okolicy środka mięśnia, tj. w mniej więcej równej odległości od obu najbliższych ścięgien.

Mięsień posiada jedynie zdolność do kurczenia się. Ponowne rozciągnięcie jest realizowane, przy użyciu przeciwstawnego mięśnia.




Rys.3. Organizacja przestrzenna połączeń nerwowo-mięśniowych[7].

Przestrzennie jednostka[1] motoryczna(czyli pojedyncza komórka nerwowa) steruje włóknami mięśniowymi, rozmieszczonymi dość równomiernie, na całym przekroju poprzecznym mięśnia, zatem połączenie nie ma charakteru zwartej grupy.

Różne jednostki motoryczne, sterują różnymi liczbami włókien mięśniowych, generalnie różnica ta w obrębie jednego mięśnia nie przekracza 10x, a w obrębie różnych 100x.

1.2 Powstawanie sygnału EMG



Rys. 4. Pojedynczy potencjał czynnościowy[4].

Wywołanie skurczu mięśnia[4] polega na wysłaniu przez komórkę nerwową sygnału do włókien mięśniowych. W stanie spoczynku pomiędzy błoną wewnętrzną, a zewnętrzną komórki mięśniowej utrzymywany jest przez pompę jonową ujemny potencjał. Wysłanie sygnału przez komórkę nerwową powoduje wyrzucenie substancji transmitterowej do szczeliny synaptycznej, co skutkuje wymuszeniem pochłaniania jonów sodu przez komórkę mięśniową, rezultatem pochłaniania jest zmniejszenie wartości bezwzględnej potencjału. Jeśli jego wartość zmieni się wystarczająco znacznie, to dzięki napięciowo zależnym kanałom sodowym, komórka mięśniowa zacznie jeszcze szybciej pochłaniać sód, co poskutkuje jeszcze szybszą zmianą potencjału, a w efekcie pojawienie się potencjału czynnościowego. Substancje transmitterowe są rozkładane przez enzymy, pochłaniane przez komórkę nerwową oraz dyfundują ze szczeliny synaptycznej, dodatkowo komórka mięśniowa próbuje utrzymać potencjał spoczynkowy używając pompy jonowej, w efekcie po depolaryzacji następuje szybka repolaryzacja. Kolejnym efektem wywołania potencjału czynnościowego jest uwalnianie jonów wapnia w przestrzeni wewnątrzkomórkowej, a co za tym idzie skurczenie kurczliwych elementów komórki mięśniowej.

Celowym efektem tego działania, jest przekazanie sygnału, a co za tym idzie skurcz mięśnia, efektem ubocznym chwilowy wzrost napięcia propagujący zgodnie z prawami fizyki

od wyższego do niższego potencjału, z uwzględnieniem rezystancji struktur na które napotyka.


Jako że każda jednostka motoryczna, ma swoją organizację przestrzenną i specyficzną dla siebie liczbę podległych komórek mięśniowych, kształt sygnału powstającego przy jej aktywności w punkcie pomiarowym jest dla niej charakterystyczny.

Zatem logiczne wydają się spostrzeżenia, że sygnały z głębi mięśnia, względem tych generowanych bliżej elektrody powierzchniowej, będą miały niższą amplitudę, dłuższy czas trwania i mniej stromy wykres.


Podczas słabego wysiłku fizycznego, wyładowania będą następowały rzadziej niż podczas wysiłku silnego, tym samym, rzadziej będą się trafiały nałożone na siebie aktywności dwóch lub większej liczby jednostek motorycznych.

1.3 Pomiar sygnału EMG

1.3.1 Rejestracja elektrodą wkłuwaną



Rys. 5. Przykładowe typy elektrod wkłuwanych z zaznaczonym na szaro obszarem pomiarowym[3].

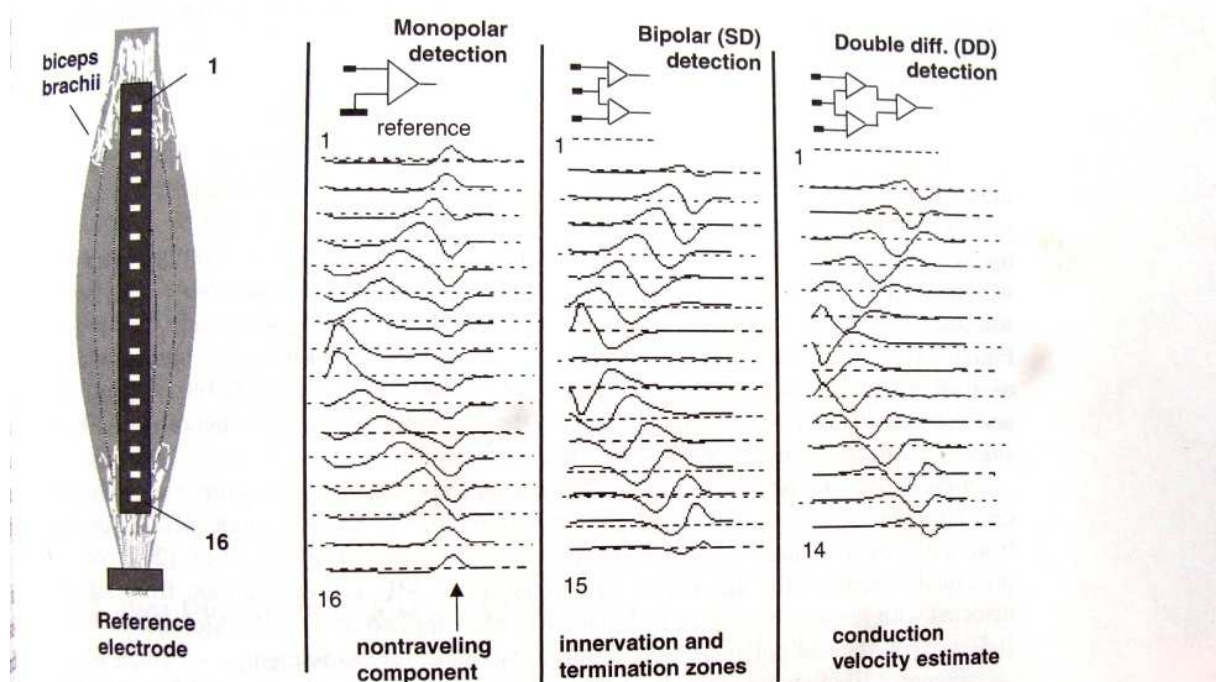


Rys. 6. Przykład użycia elektrody wkłuwanej[3].

Elektroda wkłuwana pozwala uzyskać najwyższej jakości sygnał poprzez uniknięcie rezystancji skóry[3] i tkanki tłuszczowej, oraz zmniejszenie odległości od połączeń nerwowo-mięśniowych. Zastosowanie precyzyjnych elektrod o małym zasięgu pozwala badać aktywność konkretnego rejonu mięśnia. Dodatkowo ponieważ wychwytyują mniejszą liczbę aktywności rzadziej następuje ich nakładanie się.

Główną wadą metody jest inwazyjność, wiążąca się z głównie z przejściowym bólem. Metoda jest powszechnie stosowana w diagnostyce chorób mięśni i nerwów.

1.3.2 Rejestracja elektrodą powierzchniową




Rys. 7. Rysunek poglądowy 16 kanałowej elektrody liniowej, oraz kształty rejestrowanych sygnałów w zależności od metody połączeń[3].

Metoda całkowicie nieinwazyjna, ponieważ w trakcie badania nie przebija się skóry nie ma potrzeby stosowania jednorazowych elementów. Z racji na odległość od badanego mięśnia i opory skóry oraz tkanki tłuszczowej sygnał jest gorszej jakości. Tym samym sygnał nią rejestrowany pozwala wykrywać nieco mniejszą liczbę jednostek motorycznych niż w przypadku zastosowania elektrody wkłuwanej.


Główny wpływ na kształt[3] sygnału ma sposób połączenia elektrod pomiarowych z układem rejestrującym. Połączenie monopolarne jest najprostsze, sygnał z punktu pomiarowego jest porównywany z odległym neutralnym odniesieniem o dużej powierzchni jak przykładowo przewodząca opaska.

W rezultacie im bliżej połączeń nerwowo-mięśniowych znajduje się elektroda tym sygnał jest silniejszy i krótszy, na rys.11 widać iż najbliższe są kanały 8 i 9. Na sąsiednie kanały sygnał dociera z opóźnieniem. Rezystancje tkanek wpływają na zmianę amplitudy, czas aktywności(długość wyładowania) wzrasta ponieważ połączenia są rozmieszczone na całej powierzchni mięśnia, zatem przy wzrastającej odległości docierają stopniowo.

Detekcja bipolarna opiera się na różnicy sygnału między elektrodami, zatem sygnał dociera najpierw do pierwszej i jest widoczny jako wzrost potencjału, a potem wędrując do drugiej jako spadek poniżej 0, ze względu na fakt iż sygnał propagując słabnie, drugi załamek ma mniejszą amplitudę od pierwszego. Na wykresie kanału 8 widać ciągłą linię, zdaje się to wynikać z faktu iż obie elektrody umieszczone są w podobnej odległości od źródła sygnału, zatem dociera on do nich niemal jednocześnie, ponieważ mierzona jest różnica między nimi, na wykresie nie widać nic. Na kolejnych kanałach widać już normalne 2 załamki, dla kanałów o numerze niższym od 8 pierwszy jest dodatni a drugi ujemny, dla większych odwrotnie, co właśnie zależy od tego która elektroda zostaje zasilona jako pierwsza. Sygnały rejestrowane tą metodą mają podobny czas trwania na kolejnych kanałach co ułatwia analizę.



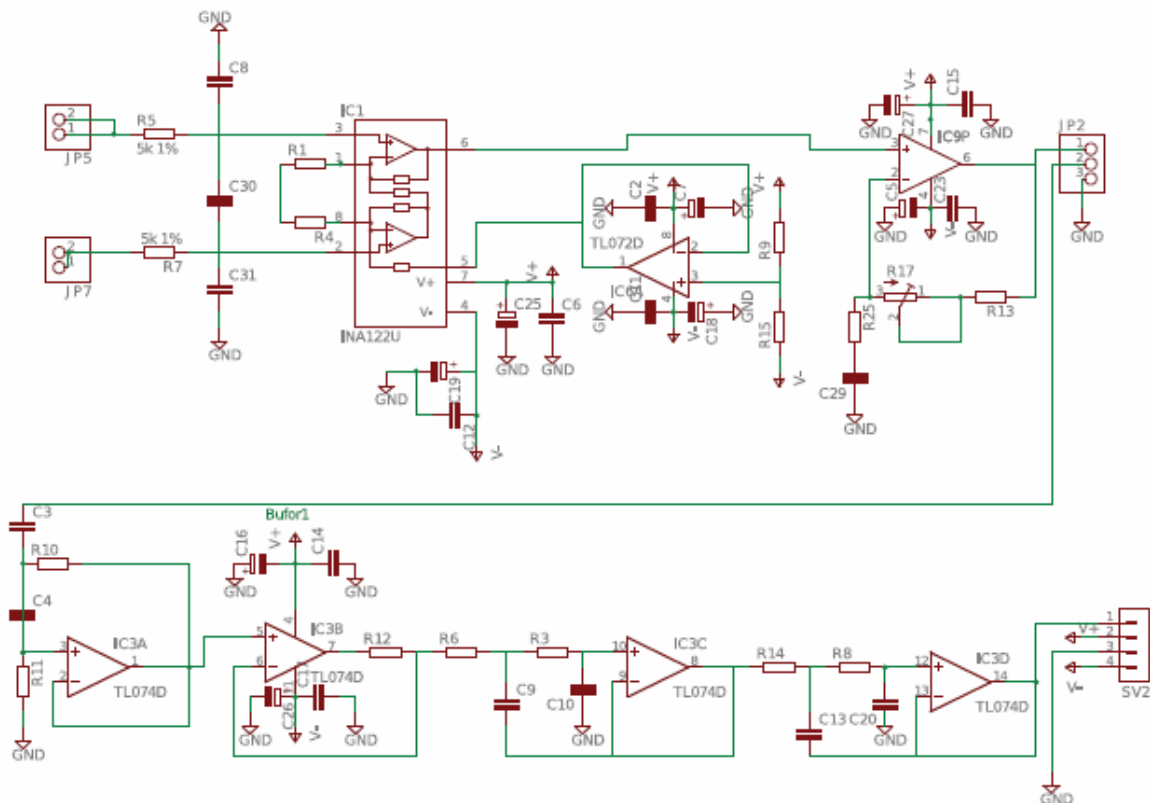
Rys. 8. Zdjęcie 126 kanałowej elektrody powierzchniowej[3].



Rys. 9. Metody detekcji filtrami przestrzennymi[3].

W zależności od posiadanego[3] układu pomiarowego, można łączyć elektrody w filtry przestrzenne, przykładowo NDD, to środkowa elektroda z wagą -4 i 4 kolejne ułożone na w równej odległości od niej na planie + o wadze 1 każda.

1.3.3 Rejestrator zastosowany w projekcie



Rys. 10. Szczegółowy schemat ideowy pojedynczego kanału pomiarowego.

Do pomiarów wykorzystywana jest 8 kanałowa elektroda powierzchniowa, posiadająca małe kontakty pomiarowe ułożone w linii. Celem ograniczenia zakłóceń sieciowych sygnał jest rejestrowany na laptopie zasilanym z baterii.

Pierwszym elementem układu jest 9 wtórników napięcia mających za zadanie zminimalizować zakłócenia pomiarowe i zapewnić układowi pomiarowemu stabilne napięcie wejściowe tożsamy z rzeczywistym.

Kolejnym elementem jest 8 torów pomiarowych, o implementacji widocznej na rys. 1. Układ posiada następujące filtry: górno i dolnoprzepustowy zachowujący pasmo 20-1000Hz, radiowej częstotliwości interferencyjnej, sieciowy 50Hz załączany na zwozce.

Sygnał jest konwertowany na postać cyfrową przy użyciu karty pomiarowej o 16bitowym próbkowaniu i częstotliwości do 200kHz.

Napięcie odniesienia mierzone jest na opasce zakładanej na nogę badanego.



Rys. 11. Orteza stawu skokowego (3), sonda pomiarowa (2) oraz ukł. Pomiarowy (1).

Widoczna na powyższym zdjęciu orteza ma na celu zablokowanie innych niż badane grup mięśni, celem wyeliminowanie docierających z nich sygnałów widzianych jako zakłócenia, dodatkowo posiada wbudowany mostek tensometryczny pozwalający mierzyć siłę rozwijaną w stawie skokowym.

2. Przegląd literatury

Sygnal EMG składa się z nałożonych na siebie aktywności różnych jednostek motorycznych. Kształt każdej z nich jest charakterystyczny, a w przypadku stałego obciążenia i poziomu zmęczenia mięśni również częstotliwość[9] jego pojawiania się. Zagadnienie dekompozycji dotyczy procesu rozpoznania tych kształtów i wyodrębnienia ich z głównego sygnału.


Jednym z projektów badających to zagadnienie jest DEMUSE, zakłada[9] on badanie sygnału rejestrowanego dwuwymiarową macierzą elektrod o dużej gęstości, takie podejście wynika z faktu, iż metoda opiera się na poszukiwaniu źródeł aktywności, a nie jak klasyczne dopasowywaniu do siebie podobnych kształtów. Zdaniem twórcy metoda jest bardzo szybka i pozwala prowadzić analizę w czasie rzeczywistym. Radzi sobie szczególnie dobrze z silnie zaszumianym sygnałem, oraz nie wymaga segmentacji. Jej główną wadą jest potrzeba utrzymywania stałego wysiłku i poziomu zmęczenia w trakcie sesji pomiarowej.

Inne podejście zaprezentowano w pracy[10]. W przedstawionej metodzie przedstawiono klasyczne podejście do tematu dekompozycji sygnału. Opiera się one na segmentacji sygnału i porównywaniu uzyskanych elementów ze sobą, w efekcie uzyskuje się grupy elementów podobnych do siebie i takie które nie są podobne do niczego. Następnym krokiem jest próba znalezienia źródeł sygnałów, co ma na celu rozdzielenie od siebie podobnych kształtów generowanych przez różne jednostki motoryczne. Ostatnim krokiem jest sprawdzenie wyników, metodą opierającą się o kontrolę regularności wyładowań każdej jednostki motorycznej. Metoda weryfikacji poprawności jest również opisywana w artykule A. Holobara[5].

Podobne lecz bardziej intuicyjne rozwiązanie problemu przedstawiono w opracowaniu Elektromyography Physiology, Endeneering and Noninvasive Applications[3]. Polega ono na posegmentowaniu sygnału, oraz zapisaniu go w macierzy w taki sposób, że istnieje w niej informacja na temat wartości różnicy dopasowania każdej pary aktywności. Następnie aktywności najbardziej do siebie podobne (czyli o najniższej wartości na ich skrzyżowaniu w macierzy) są łączone w grupy. Po każdej takiej operacji z macierzy usuwana jest jedna z kolumn a druga przyjmuje dla każdej komórki wartość błędu większego z dwóch możliwych. W efekcie uzyskuje się zbiory podobnych do siebie aktywności. Opisana metoda analizy została zaimplementowana celem weryfikacji autorskiego algorytmu. Opracowanie traktuje również o stosowanych obecnie układach pomiarowych, uwzględniając różnice kształtów uzyskiwanych na różnych ich typach.

3. Dekompozycja sygnału EMG

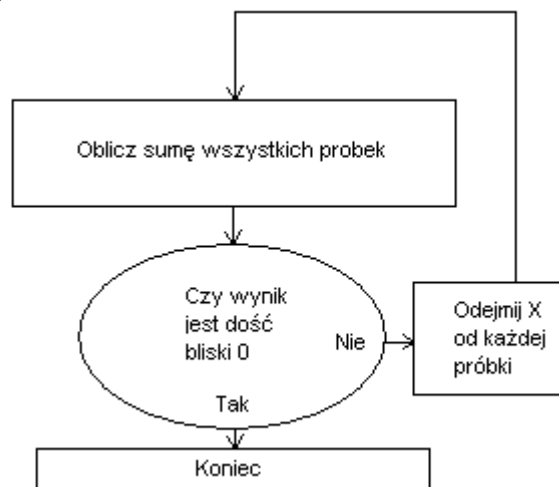
3.1 Przetwarzanie wstępne sygnału EMG



Rys. 12. Przykładowy nieobrobiony sygnał, uzyskany z układu pomiarowego.

Wszystkie rzeczywiste sygnały zastosowane w pracy zostały dostarczone przez promotora, pochodzą z eksperymentów przeprowadzonych na ochotnikach przy użyciu układu pomiarowego opisanego w rozdziale 1.3.3.

Jak widać na powyższym rysunku wartości średnie oscylują w okolicy 100, ze stanem równowagi utożsamiane jest raczej 0, zatem zdecydowano przesunąć je w tą okolicę celem ułatwienia dalszej analizy.

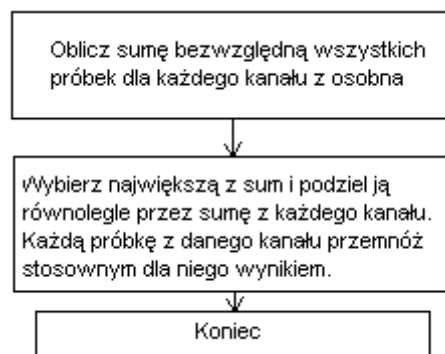


Rys. 13. Schemat blokowy metody wyśrodkowania sygnałów.

Algorytm opiera się na cyklicznym obliczaniu sumy wszystkich próbek z jednego kanału, a następnie odejmowaniu stałej wartości od każdej z nich aż do osiągnięcia sumy niższej niż założony próg. Następnie cała procedura wykonywana jest na każdym kolejnym kanale.

Drugi problem stanowi znaczna różnica między amplitudami występującymi na kolejnych kanałach, problem wydaje się wynikać z organizacji przestrzennej połączeń nerwowo-mięśniowych, największa ich liczba znajduje się w okolicy środka mięśnia tj. punkcie z którego różnica odległości do obu ścięgien jest najmniejsza tym samym w tej okolicy sygnał jest najsilniejszy, gdyż nie słabnie przebijając się przez dużą liczbę tkanek mających swoje rezystancje, drugą możliwą przyczyną jest konstrukcji przetwornika, gdzie kanały są niezależne, a ich wagi odbiegają od siebie.


Pierwszym sposobem rozwiązania problemu, było zapisanie wartości maksymalnej na każdym kanale z osobna, następnie z listy wartości maksymalnych wybrana została globalna wartość maksymalna. Kolejnym krokiem było pomnożenie wszystkich próbek z każdego kanału przez wartość globalnie maksymalną, oraz podzielenie przez wykrytą wcześniej wartość lokalnie maksymalną dla tego kanału. W efekcie uzyskano bardzo podobne amplitudy na wszystkich tożsamyh sygnaturach.



Rys. 14. Schemat blokowy metody zrównania amplitud sygnałów.

Drugą koncepcją było zastosowanie sumy bezwzględnej sygnału z każdego kanału, zamiast pojedynczej wartości maksymalnej. Główną korzyścią tej metody jest usunięcie wpływu pojedynczego szumu o amplitudzie na tyle dużej by zostać uznany za wartość maksymalną na kanale. Dodatkowo, kanały bardziej zaszumiane posiadają większy rozrzut wartości od pozostałych, tym samym większą sumę bezwzględną, zatem po wymnożeniu uzyskują niższe wartości maksymalne niż kanały mniej zaszumiane.

Aktualnie do standaryzacji używana jest metoda z sumą bezwzględną, ponieważ pozwala łatwo wykryć najgorsze kanały i je odrzucić, a różnice w amplitudach są na tyle małe, że nie trzeba się obawiać o problem z rozpoznanem tego samego sygnału.




Rys. 15. Sygnał po ustandaryzowaniu.

Jak widać wartość średnia oscyluje w okolicy 0, a amplitudy na kolejnych kanałach są do siebie zbliżone, zatem cel został osiągnięty. Ostatni kanał znacząco odbiega od pozostałych ponieważ został niepoprawnie zarejestrowany.

3.2 Segmentacja

Ma na celu oznakowanie fragmentów które będą podlegały dalszej analizie, dzięki czemu uzyskuje się ich konkretną skończoną liczbę. Jest wykonywana na wstępie wielu spotykanych w literaturze metod[3,10].


3.2.1 Ręczna



Rys. 16. Sygnał EMG z zaznaczonymi wyciętymi ręcznie sygnaturami jednostek motorycznych, oraz ich powiększeniami po prawej stronie.

We wczesnym etapie prac zaszła potrzeba szybkiego uzyskania sygnatur (za sygnaturę jest rozumiany charakterystyczny kształt aktywności występujący podczas wyładowania z jednostki motorycznej) o wysokiej jakości, za najprostsze rozwiązanie uznano ręczne wybranie fragmentów sygnału. Napisano procedurę, przyjmującą za parametry numery pierwszej i ostatniej próbki. Funkcja zapisuje elementy z zadanego przedziału, a następnie wyświetla na wykresie sygnał i sygnaturę kontrastującym do niego kolorem.

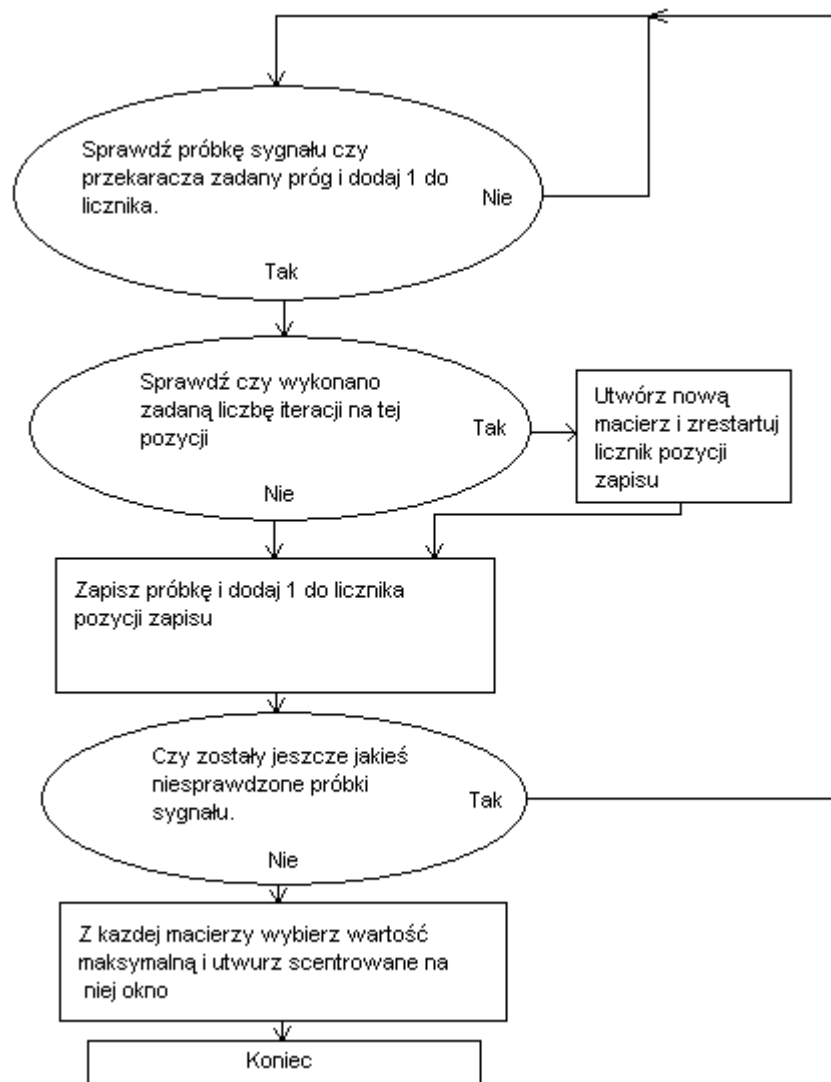
3.2.2 Automatyczna pierwsza



Rys. 17. Oznakowane automatycznie aktywności (na niebiesko zaznaczono oryginalny sygnał, na czerwono klasyfikację, wartość 0 oznacza jej brak, każda inna zaklasyfikowanie.), z powiększonym fragmentem po lewej.

W metodzie automatycznej przyjęto, że jednostki motoryczne których aktywności będą możliwe do wykrycia mają znacznie większą amplitudę od szumu, tym samym, możliwe będzie ich wykrycie poprzez oznaczenie wszystkich sygnałów o wartości bezwzględnej przekraczającej określony stosowny próg i ewentualną dalszą obróbkę powstałego sygnału. Metoda ta oznakowała większość jednostek motorycznych i dobrze wyglądała na wizualizacji. Ponieważ usuwała zbyt duże fragmenty aktywności, a także tworzyła segmenty o zmiennej długości trudno było dokonywać analizy przy jej użyciu. W efekcie nie została zastosowana w finalnym algorytmie, jednak wnioski z niej płynące pozwoliły zaprojektować kolejną znacznie ulepszoną.

3.2.3 Automatyczna druga




Rys. 18. Schemat blokowy segmentacji.

Sygnal wejściowy jest skanowany w poszukiwaniu wartości przekraczających zadany próg, jeśli taka zostanie znaleziona jest zapisywana do tabeli. Na kolejnych pozycjach zapisywane są następne wartości jeśli przekraczają próg, w innym razie nie, po zadanej liczbie iteracji przy najbliższej próbce przekraczającej zadany próg dodawana jest 2 do zmiennej g przez co kolejna sekwencja będzie zapisana na osobnej pozycji.

Z grup próbek wybierane są wartości maksymalne.

Następnie z wartości maksymalnych odtwarzane okna o zadanej długości, gdzie ich środkami są wspomniane wartości maksymalne. Ta metoda jest stosowana w dalszej analizie.



Rys. 19. Wyznaczone segmenty sygnału EMG.

Na powyższym rysunku widać efekt działania algorytmu na pojedynczym kanale.


3.3 Klasyfikacja

Jest to kolejny etap mający na celu dokonanie estymacji kształtów wyładowań generowanych przez jednostki motoryczne, występujące w posiadanym sygnale. Podjęto decyzję o opracowaniu autorskiej metody, a następnie implementacji jednej ze znanych, celem oceny skuteczności.

3.3.1 Metoda pierwsza

Metoda polega na wielokrotnym obliczeniu sumy kwadratów błędów, powstałych przez porównanie ze sobą kolejnych próbek wzorca aktywności z kolejnymi próbkami sygnału i zapisaniu jej do macierzy.

Przy każdym kolejnym obliczeniu sumy, jako pierwsza traktowana jest próbka sygnału z numerem o 1 większym niż poprzednio, a uzyskana wartość zapisywana jest w kolejnej komórce.




Rys. 20. Rozpoznawanie aktywności jednostek motorycznych, przybliżenie (niebieskim kolorem oznakowano sygnał oryginalny, pozostałymi sumy kwadratów błędów dopasowania).

Na wykresach widać badany sygnał i wartości uzyskane poprzez porównanie go z dwoma różnymi wzorcami. Tym wynik niższy, tym większe podobieństwo, w przypadku natrafienia na miejsce z którego wzorec został wycięty błąd wyniesie 0.

Metoda ta powstała na wczesnym etapie prac nie wymaga segmentacji, potrafi skutecznie rozpoznawać aktywności jednostek motorycznych których wzorce posiada. Główną jej wadą jest analizowanie dużych ilości danych, co absorbuje moc obliczeniową, a przede wszystkim zachowuje problem złożonym. Uznano że opracowanie w oparciu o nią metody estymacji kształtów należących do różnych jednostek motorycznych będzie zbyt skomplikowane i zdecydowano się na metody oparte o segmentację, ponieważ rozbijają duży problem na mniejsze.

Pomimo wad algorytm może się okazać przydatny w przypadku projektu analizującego sygnał EMG w czasie rzeczywistym, jeśli wcześniej zastosuje się skuteczny algorytm ekstrahujący kształty.

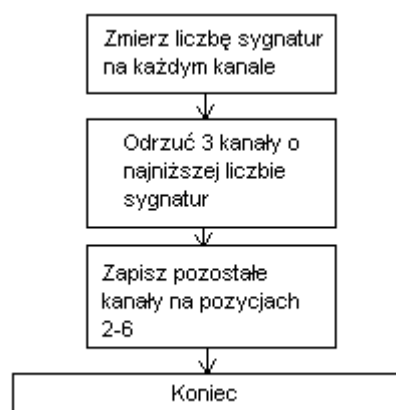


Rys. 21. Rozpoznawanie aktywności jednostek motorycznych.

Ostatni rysunek przedstawia wynik analizy dla całego sygnału. Jak widać błąd jest przeciętnie wielokrotnie większy niż w przypadku znalezienia tożsamej aktywności

3.3.2 Metoda druga

Jako wejście wykorzystywany jest ustandaryzowany i posegmentowany sygnał. Celem metody jest rozpoznanie możliwie dużej liczby kształtów, generowanych przez różne jednostki motoryczne w sygnale EMG. Najogólniej metoda polega na wstępnym znalezieniu aktywności, a następnie precyzyjnej klasyfikacji przy ich użyciu, szczegółowy opis znajduje się poniżej.



Rys. 22. Schemat blokowy algorytmu odrzucającego 3 najgorsze kanały.

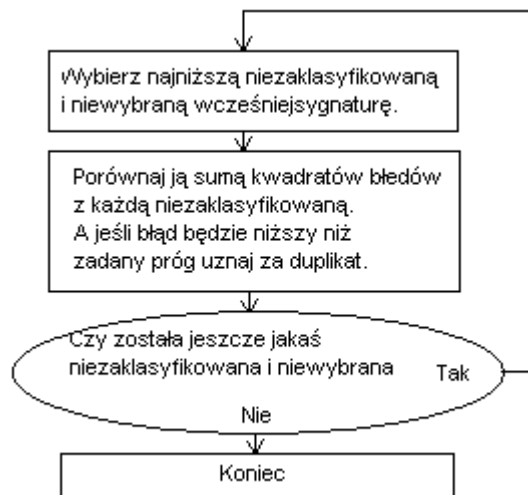
Usunięcie części kanałów uznano za korzystne ze względu na trudność idealnego przymocowania elektrody oraz istnienie rejonów o fizjologicznie niższej jakości sygnału. Wstępnie odrzucane są 3 kanały o najniższej jakości z ośmiu dostępnych. Uznano, że nieparzysta liczba pozwoli uniknąć spornej sytuacji, w której pierwsza połowa kanałów dokonała sprzecznej klasyfikacji z drugą. Usunięcie jednego uznano za działanie zbyt drobne, a 5-ciu wiązało by się z usunięciem ponad połowy, stąd decyzja o 3. Niska jakość sygnału na kanale, rozpoznawana jest poprzez małą liczbę znalezionych segmentów, która wynika z niższej niż na innych kanałach wartości maksymalnej sygnału, a ta ze specyfiki programu standaryzującego, który nieco dyskryminuje, kanały bardziej zaszumiane.



Rys. 23. Schemat blokowy usunięcia aktywności nie pojawiających się równoległe na wszystkich kanałach.

Następnie odrzucane są sygnaty, które nie pojawiają się na wszystkich kanałach. Takie podejście zmniejsza liczbę analizowanych aktywności, ale znacząco podnosi dokładność, usuwając, aktywności o dużym zaszumieniu.

Algorytm przegląda kolejno wszystkie sygnaty z drugiego kanału, zapisuje dla każdej globalny numer próbki, elementu o największej wartości sygnału (czyli element znajdujący się na środku okna). W kolejnym kroku, sprawdza czy próbka o danym numerze występuje na wszystkich kanałach jeśli tak wszystkie sygnaty ją zawierające oznacza 1. Procedura jest powtarzana dla wszystkich numerów. Następnie wszystkie nieoznaczone sygnaty ze wszystkich kanałów są usuwane.



Rys. 24. Schemat blokowy wstępnego wyszukiwania aktywności.

W kolejnym etapie następuje wstępna klasyfikacja. Brana jest pierwsza sygnatura i porównywana metodą sumy kwadratów błędów kolejno z wszystkimi następnymi, jeśli błąd będzie niższy niż zadany próg dana jednostka zostaje zaklasyfikowana jako duplikat wzorca. Następnie brana jest kolejna nie uznana za duplikat jednostka i porównywana ze wszystkimi nie uznanymi za duplikaty jednostkami, klasyfikując je jako swoje duplikaty jeśli błąd jest wystarczająco niski. Procedura powtarzana jest aż do ostatniej nie zaklasyfikowanej jednostki.

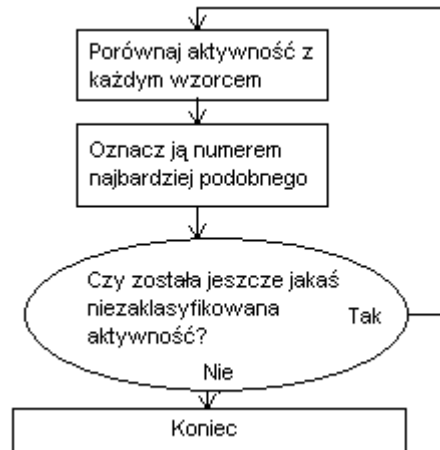


Rys. 25. Tworzenie list wzorców i wybór jednej do dalszej analizy.

Następnie tworzona jest lista jednostek które posiadają swoje duplikaty, jest to realizowane poprzez zapytanie (find), o numer każdej z sygnatur na pozycji 101 gdzie znajdują się numery wzorców przypisane do podobnych sobie sygnatur (niepodobne do

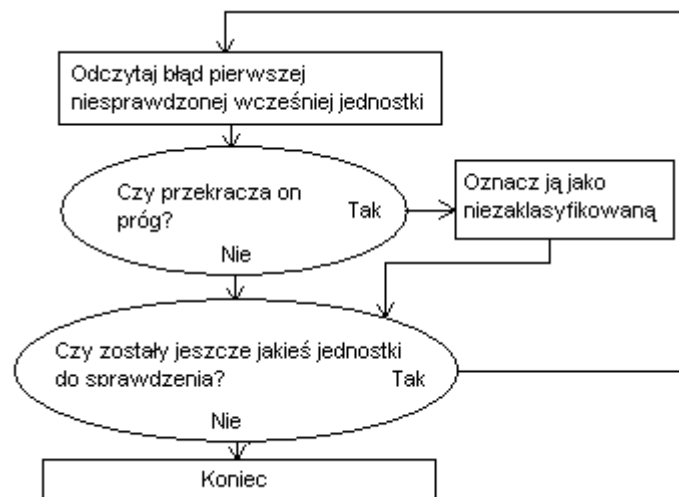
niczego i wzorce są oznaczone 0). Pozycja 101 została wybrana, aby zapewnić 100 komórek na zapis próbek każdej aktywności w praktyce wykorzystywane jest 20.

Następnie do każdego kanału przypisywana jest lista wzorców z kanału najlepszego (w ten sposób można poprzez zakomentowanie małego fragmentu kodu, odzyskać własne listy każdego z kanałów i testować inne podejścia).



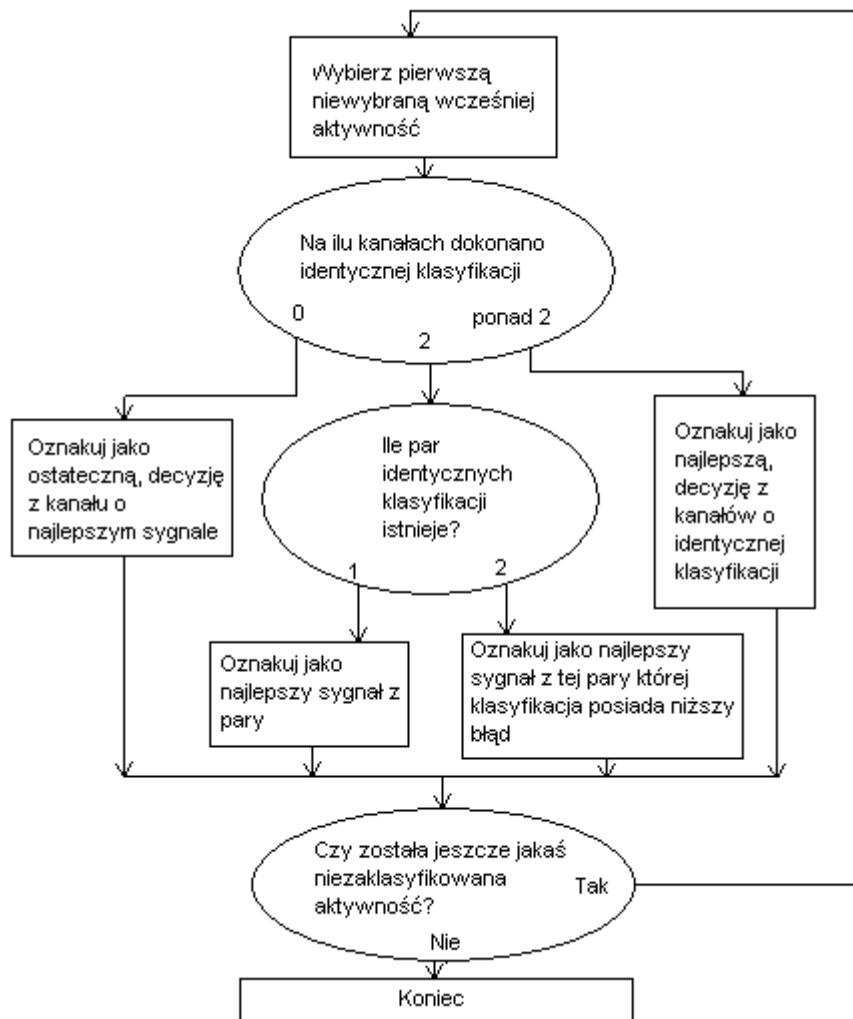
Rys. 26. Algorytm klasyfikacji

Znalezione elementy są uznawane za wzorce i przy ich użyciu sprawdzane są wszystkie pozostałe sygnatury (również te które poprzednio zostały uznane za niepodobne do żadnego z wzorców). Następuje porównanie badanej sygnatury z każdym wzorcem i oznaczenie numerem najbardziej podobnego, oraz zapisanie wartości błędu dopasowania.




Rys. 27. Wyszukiwanie aktywności o błędzie przekraczającym próg celem uznania za nieklasyfikowane.

Następnie jednostki o błędzie przekraczającym zadany próg są oznaczane jako nieklasyfikowane. Dodatkowo następuje wyświetlenie ich ilości.



Rys. 28. Ostateczna klasyfikacja na podstawie cząstkowych.

Ostatnim krokiem jest wybór ostatecznych wyników, na podstawie rozwiązań z kolejnych kanałów. Ponieważ w analizie uwzględniane jest ich 5, 3-krotny wybór danej jednostki kwalifikuje ją jako ostatecznie wybraną. W przypadku dwukrotnego istnieją dwie możliwości jeżeli jest to jedyna wielokrotna klasyfikacja uznawana jest za poprawną, w innym razie sprawdzana jest wielkość błędów generowana przez każdą z 2 możliwości i wybierana ta mniejsza. Jeśli na każdym kanale dokonano innej klasyfikacji za poprawny uważa się wynik z kanału Uznanej za najlepszy przy segmentacji.



Rys. 29. Przykład klasyfikacji.

3.3.3 Metoda trzecia

Podobna do drugiej przedstawionej w poprzednim rozdziale z tą modyfikacją, że w drugiej fazie kiedy zostały wybrane wzorce, w poprzedniej metodzie następowało porównanie każdego wzorca z daną aktywnością i dopasowanie najlepszego dla każdego kanału z osobna, zatem dopasowania dla tej samej aktywności bywały różne na różnych kanałach. Tutaj dany wzorec jest dopasowywany jednocześnie, zatem liczona jest suma błędów ze wszystkich kanałów, co upraszcza obliczenia a jednocześnie według założeń miało zaowocować większą dokładnością dopasowania, niestety wyniki okazały się być gorsze niż w poprzedniej metodzie, zatem funkcja analizator2, zostaje zamieszczona ale szerzej nie opisywana.

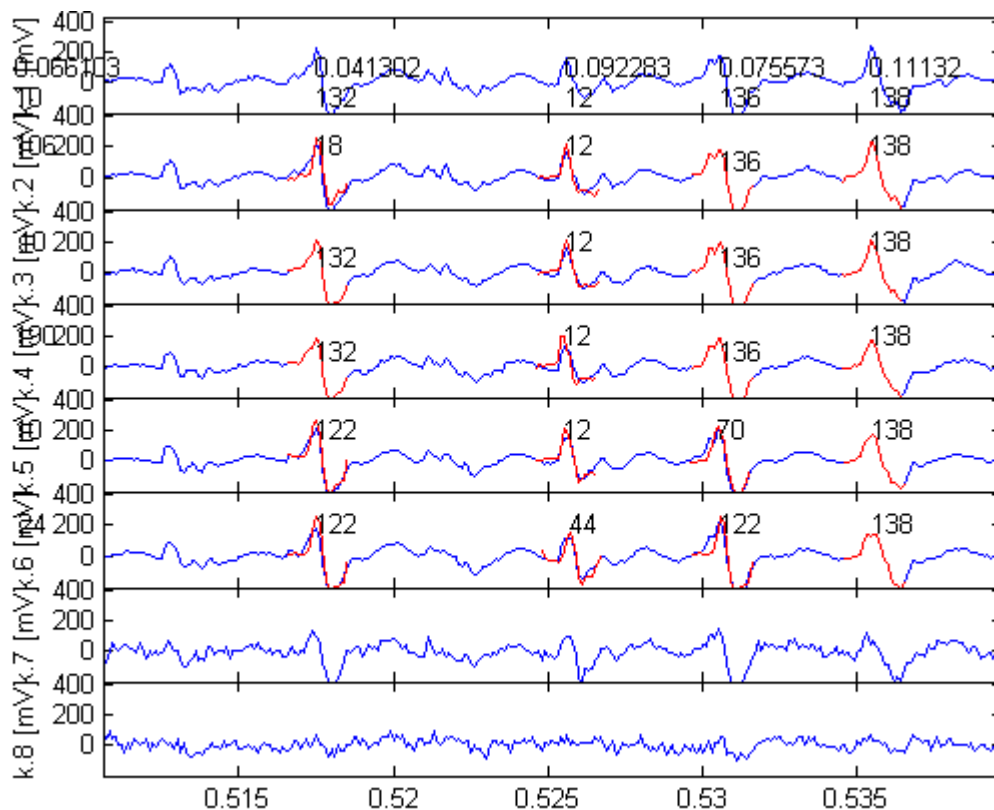
3.3.4 Czwarta

Metoda ta powstała celem zweryfikowania poprawności pracy, głównej autorskiej metody opisanej w projekcie. Jej parametrem jest liczba iteracji scalania które mają zostać wykonane. Opiera się na klastryzacji[3] opisanej ogólnie w rozdziale 2. Rzeczywista implementacja nieco różni się od teoretycznej, wejściem jest posegmentowany sygnał. Miarą różnicy między każdą parą sygnatur jest suma kwadratów błędów pomiędzy kolejnymi parami ich próbek. Usuwanie wiersza nie polega na jego usunięciu, a jedynie przypisaniu jego komórkom błędu znacznie większego niż możliwy, konkretnie równego 9. Każde takie przypisywanie jest notowane, a następnie w kolejnym etapie następuje tworzenie grup scalonych aktywności. Po zakończeniu pracy procedura wyświetla wyniki w postaci okna subplot wewnątrz którego na każdym podwykresie znajdują się uznane za tożsame aktywności, oraz ich średnia trajektoria.

3.4 Metody weryfikacji uzyskanych wyników

3.4.1 Funkcja Drawsignal2

Weryfikowanie poprawności pracy algorytmów dekomponujących, było niezbędne od momentu wygenerowania przez nie pierwszych wyników. Pozwalała wprowadzać modyfikacje w sposób sprawny dzięki szybkiemu wykrywaniu błędów. Ponieważ od promotora uzyskano procedurę Drawsignal pobierającą na wejście macierz 8 sygnałów i wyświetlającą je równoległe do siebie, a analiza odbywała się w sposób wielokanałowy, zdecydowano ją wykorzystać. Naniesiono modyfikacje w efekcie których funkcja Drawsignal2 po wyświetleniu sygnału, nakłada kontrastującym kolorem na miejsca wskazane jako aktywności kształty uznane za tożsame. Klasyfikacje tej samej aktywności na różnych kanałach mogą być odmienne, wtedy wyświetlenie jest zgodne z decyzją na kanale. W efekcie pozwala wzrokowo ocenić poprawność klasyfikacji. Sama zmiana koloru oznaczała by najprawdopodobniej, że dana aktywność sama jest wzorcem, niewiele odbiegające od siebie linie czerwona i niebieska sugerują bardzo dobrą klasyfikację, natomiast niepowiązane ze sobą kształty poważny błąd. Obok nałożonych kształtów wzorców wyświetlone są ich numery. Dodatkowo na pierwszym kanale wyświetlana jest ostateczna klasyfikacja podjęta na podstawie decyzji cząstkowych z kolejnych kanałów, oraz nad nią wartość błędu dopasowania, obliczona jako jego średnia wartość ze wszystkich kanałów.



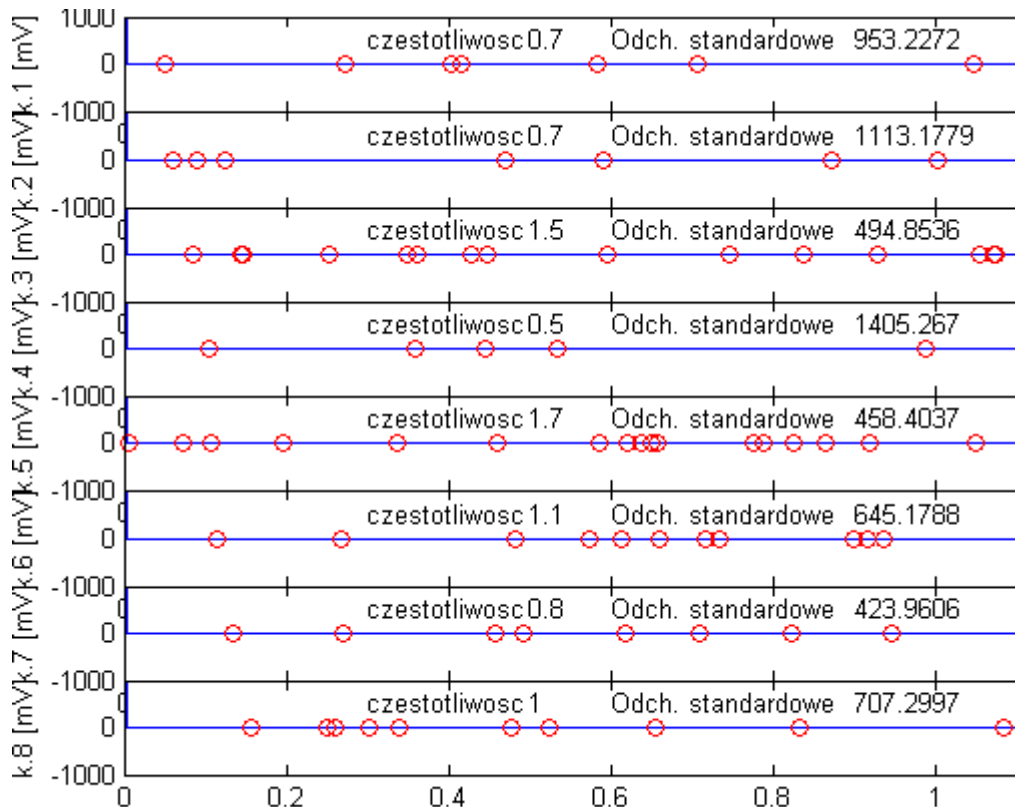
Rys. 30. Drawsignal2.

3.4.2 Funkcja Drawsignal3

Program podobny do poprzedniego z tą główną różnicą, że na kolejnych kanałach nie wyświetla sygnatur cząstkowych klasyfikacji tylko te z finalnej.

3.4.3 Funkcja PrezentacjaWykresow


Procedura również powstała poprzez modyfikację kodu funkcji DrawSignal. Wyświetla na każdym kanale pojawienia się jednej jednostki motorycznej. Każde pojedyncze jej pojawienie się oznaczane jest okręgiem. Dodatkowo oblicza oraz wyświetla częstotliwość jej występowania i odchylenie standardowe między odległościami sąsiednich próbek. Parametrem procedury jest numer pierwszej jednostki motorycznej, której wystąpienia zostają wyświetlone na kanale u samej góry okna, poniżej wyświetlane są jednostki o kolejnych numerach.



Rys. 31. Wyświetlenie aktywności pojedynczych jednostek motorycznych.

3.4.4 Funkcja WynikiSubplot

Procedura bazuje na funkcji subplot, wyświetla wszystkie zaklasyfikowane aktywności, przy czym tożsame znajdują się na wspólnym wykresie, a czerwonym kolorem oznaczona jest ich uśredniona trajektoria. Uśrednienie jest liczone poprzez zsumowanie próbek o tych samych numerach, a następnie podzielenie ich przez liczbę aktywności. Kolejność wyświetlania wykresów z aktywnościami jest następująca, w lewym górnym rogu znajduje się wykres pierwszej aktywności, bezpośrednio po nim po prawej stronie 2, następnie 3, aż do końca wiersza, po jego zakończeniu kolejnym elementem jest wykres po lewej stronie wiersza następnego.



Rys. 32. Efekt działania funkcji wynikisubplot.

3.5 Ciekawsze funkcje

```

if(mm(i,j)>0.1)
    flag=1;
    if(b>hsghs*0.8)
        g=g+2;
        a=1;
        b=0;
    end
    u(a,g+1)=i;
    u(a,g+2)=mm(i,j);
    a=a+1;
else
    if(flag==1)
        b=b+1;
    end
end
end
end

```

Procedura zapisująca grupy próbek na miejscu których powstaną okna.

Jeśli wartość przekracza zadany próg zapisywana jest do tabeli wraz ze swoim numerem, zmienna a odpowiadająca za pozycję zapisu jest inkrementowana, zmienna b licznikowa również, dodatkowo wywieszana jest flaga. Jeśli kolejna zmienna przekracza próg procedura się powtarza w innym razie inkrementowana jest tylko zmienna licznikowa b. Jeśli b przekroczy zadany próg inkrementowana jest zmienna g, w wyniku czego następny zapisy nastąpi na innej pozycji, zatem poprzedni zlepek zmiennych zostanie oddzielony, dodatkowo resetowane są zmienne a i b.

```

for i=1:length(sygnatury2(1,:))/2

    c=sygnatury2(dlokna/2,i*2-1);
    if(~(isempty(find(sygnatury3==c)) | isempty(find(sygnatury4==c)) |
    isempty(find(sygnatury5==c)) | isempty(find(sygnatury6==c)) ))
        sygnatury2(102,i*2-1)=1;
        [a,b]=find(sygnatury3==c);
        sygnatury3(102,b)=1;
        [a,b]=find(sygnatury4==c);
    end
end

```

```

sygnatury4(102,b)=1;
[a,b]=find(sygnatury5==c);
sygnatury5(102,b)=1;
[a,b]=find(sygnatury6==c);
sygnatury6(102,b)=1;
end
end

```

Procedura znakująca aktywności występujące na wszystkich kanałach. Wybierana jest aktywność, znajdujący numer środkowej próbki i wyszukiwany na wszystkich kanałach, jeśli zostanie znaleziony na każdym następuje oznakowanie. Następnie wybierana jest kolejna próbka i aktywność i procedura się powtarza, aż zostaną sprawdzone wszystkie.

```

c=0;
cqw(20,20)=0;
rtr=0;
for j=1:length(p2)
    subplot(5,5,j)
    for i=1:length(s)
        if(s(i)==p2(j))
            cqw(1:20,j)=sygnatury2(1:20,2*i)+cqw(1:20,j);
            rtr=rtr+1;
        end
    end
    plot(1:20,sygnatury2(1:20,2*i))
    hold on
end
if (i==length(s))
    cqw(1:20,j)=cqw(1:20,j)/rtr;
    rtr=0;
end
plot(cqw(1:20,j),'r');
hold on
end
end
end

```

Procedura `wyniksubplot`, wyświetlająca wyniki na podwykresach. Pod zmienną `j` podstawiane są kolejne numery wzorców, po każdej takiej operacji tworzone jest nowe okno `subplot`, oraz następuje przeszukiwanie zmiennej `s` w poszukiwaniu podstawionego wzorca o numerze identycznym z tym znajdującym się w zmiennej `j`. Jeśli taki zostanie znaleziony, następuje wyświetlenie kształtu aktywności do której jest przypisany, oraz dodanie jej próbek do tablicy `cqw` i inkrementacja zmiennej `rtr`.

Po zakończeniu przeszukiwania zmiennej `s`, następuje obliczenie kształtu przeciętnej trajektorii, poprzez podzielenie zmiennej `cqw` przechowującej nałożone na siebie próbki uznawanych za tożsame aktywności przez zmienną `rtr`, przechowującą ich liczbę, następnie wyświetlenie tegoż kształtu i wyzerowanie zmiennej `rtr`, cała procedura powtarza się dla kolejnych wartości zmiennej `j`, aż sprawdzone zostaną wszystkie wzorce.

```

for k=1:length(sygnatury2(1,:))/2
for i=k:length(sygnatury2(1,:))/2
for j=1:20
    c=(sygnatury2(j,2*k) -sygnatury2(j,2*i))^2 +c ;
end
d(k,i)=c;
c=0;
end
end

```


Funkcja wypełniająca macierz dla metody klasteryzacji, zaczynając od wewnętrznej funkcji zmienna j jest inkrementowana od 1 do 20 zatem odpowiada wszystkim kolejnym próbkom porównywanych zmiennych, zmienna i odpowiada za numer drugiej z porównywanych aktywności, jest wybierana z przedziału od wartości k , celem uniknięcia powtórzeń, do długości zmiennej przechowującej informację o trajektoriach sygnatur podzielonej przez 2 ponieważ wspomniane trajektorie są zapisywane w niej na co 2 pozycji. Ostatnia zmienna k jest generowana w ten sam sposób co zmienna i z tą różnicą, że pierwszą wartością jest 1. Co 20 iteracji wyniki trafiają do macierzy d , a zmienna c która je dotychczas przechowywała zostaje wyzerowana.

```
for i=1:length(d(:,1))
    for j=1:length(d(1,:))
        if(d(i,j)==0)
            d(i,j)=9;
        end
    end
end
```

Z macierzy będą wybierane wartości najmniejsze, zatem 0 będące komórkami nieczynnymi należy przed dalszą obróbką zastąpić wartościami dużymi. W tym przypadku są to 9 będące ponad 10 razy większe od maksymalnych występujące tam wartości. Macierz przeszukiwana jest w obu wymiarach (odpowiadają za nie zmienne i oraz j) od 1 do ostatniej komórki, przy czym pierwszą w obu wymiarach jest 1, a ostatnia zostaje wyszukana przy użyciu funkcji `length`. Jeśli zostanie znaleziona komórka o wartości 0, następuje przypisanie jej wartości 9.

4. Implementacja metody

Oprogramowanie zostało napisane w środowisku programistycznym Matlab i stanowi grupę kolejno uruchamianych m-plików:

Standaryzator – w drugiej linii podawana jest ścieżka do pliku z sygnałem, który ma zostać ustandaryzowany, a w przedostatniej komendzie ścieżka do pliku który ma zostać utworzony.

Sam m-plik posiada 3 niezależne oddzielone od siebie moduły które można uruchomić lub zakomentować, są to kolejno: wyrównanie wartości średniej, zrównanie amplitud metodą sumy, zrównanie amplitud metodą wartości maksymalnej.

Segm23 – służy do posegmentowania sygnału, oraz odrzucenia 3 najgorszych kanałów, pierwszą aktywną linijkę stanowi załadowanie sygnału, zmieniając ścieżkę można wczytać inny, następnie podawana jest długość okna wpisana na sztywno jako 20, oraz zakomentowany moduł odsumiający, który można uruchomić.

Wybieracz – ma za zadanie usunąć wszystkie sygnatury które nie pojawiają się na wszystkich kanałach. Nie posiada parametrów.

Przy pojedynczej sekwencji uruchomień należy wybrać jeden z programów do analizy (opisane w punkcie rozdziale 3.3):

Analizator – dokonuje analizy główną metodą, jego parametry to tolerancja, czyli wielkość akceptowalnego błędu dla pierwszej fazy analizy i tol2 czyli próg błędu powyżej którego dana

aktywność zostanie uznana za niezaklasyfikowaną. Po wykonaniu się, wyświetla w głównym oknie mathlaba: liczbę sygnatur, nieprzypisanych aktywności i średni błąd na jednostkę.

Klasteryzacja – dokonuje analizy poprzez klasteryzację, parametrem jest liczba iteracji scalania, z których zostaną wyświetlone wyniki. Można ją zmienić w 2 linijce kodu, oznakowanej opisem. Po wykonaniu automatycznie wyświetla wyniki w postaci podwykresów, z których każdy stanowi nałożone na siebie aktywności jednej jednostki motorycznej. Nie współpracuje z funkcjami wyświetlającymi wyniki.

Programów wyświetlających wyniki:

Wywołaniedrawsignala – m-plik wywołujący funkcję drawsignal2 napisany ze względu na mnogość jej parametrów. Wystarczy wywołać.

Prezentacjawynikow – funkcja wyświetlająca na jednym wykresie odstępy między wyładowaniami jednej jednostki motorycznej, na kolejnych wykresach znajdują się kolejne pojedyncze jednostki. Parametrem jest numer aktywności wyświetlonej jako pierwsza (na jednym wykresie mieści się ich 8). Opcjonalnie odkomentowując zaznaczony w m-pliku fragment tekstu można wyświetlić jako tło sygnał EMG, zamiast linii prostej.


Wynikisubplot – Funkcja nie posiada parametrów, jest tylko wywoływana.

5. Inne programy


5.1 Usuwacz szumu gaussowskiego

Jedną z koncepcji uproszczenia obróbki sygnału, było jego wstępne odszumienie. Efektem prac jest uzyskany algorytm. Jak widać jest on krótki i przejrzysty. Opiera się na uśrednianiu wartości sąsiednich próbek, oraz wykrywaniu wartości szczytowych, dla których uśrednianie nie jest wykonywane. W praktyce radzi sobie skutecznie z szumem gaussowskim, niestety sygnał EMG, nie ma takiego charakteru, zatem nadaje się on do jedynie do poprawy wyników sygnału syntetycznego, a ponieważ ten ma być wykorzystywany do oceny jakości algorytmu, program nie został wykorzystany, a zamieszczony jest jako ciekawostka.

```
for i=101:length(mm)-101
    if(cc(i,1)~=max(cc(i-100:i+100,1)) & cc(i,1)~=min(cc(i-100:i+100,1)) )
        cc(i,1)=(mm(i-2,1)+mm(i+2,1)+mm(i-1,1)+mm(i+1,1)+mm(i,1))/5;
        %cc(i,1)=(mm(i+3,1)+mm(i-3,1)+mm(i-2,1)+mm(i+2,1)+mm(i-
1,1)+mm(i+1,1)+mm(i,1))/7;
    end
end
```




Rys. 33. Sygnał syntetyczny zaszumiany(niebieski) i odszumiony(czerwony).



Rys. 34. Sygnał syntetyczny bardziej zaszumiany(niebieski) i odszumiony(czerwony)

Na powyższych rysunkach widać, że pomimo różnych poziomów zaszumienia uzyskany kształt jest niemal identyczny.



Rys. 35. Sygnał rzeczywisty przed odszumieniem(niebieski) i odszumiony(czerwony).

5.2 Test losowości

W trakcie testów poprawności zaszła potrzeba zweryfikowania jaką wartość odchylenia standardowego posiada aktywność pojawiająca się w losowo wybranych momentach sygnału o 11000 próbek. Celem rozwiązania problemu napisano aplikację generującą wybraną liczbę aktywności o pseudolosowych numerach, za generator posłużyła procedura rand generująca pseudolosowe wartości z przedziału od 0 do 1, jej wynik został pomnożony przez 11000, uzyskując w efekcie żądany przedział. Następnie zostało policzone odchylenie standardowe i całość powtórzona 1000 razy celem uśrednienia wyniku. Obliczona wartość to ~ 2300 . Parametrem jest zmienna lpr decydująca ile razy pojawi się szacowana aktywność się aktywności.

```
%liczba aktywnosci
lpr=15;
for j=1:1000
    wyn=0;
    for i=1:lpr
        x(i)=11000*rand;
    end
    x=sort(x);

    for i=1:lpr-1
        r(i)=x(i)-x(i+1);
    end
    r2=sum(r)/(lpr-1);
for i=1:lpr-1
```

```
wyn=wyn+(r(i)-r2)^2;  
end  
wyn2=sqrt(wyn);  
wyn3(j)=wyn2;  
end  
sum(wyn3)/1000
```

6. Wyniki

Procedura testowa polega na wzrokowej analizie sygnału z naniesionymi poprzez procedurę Drawsignal2 klasyfikacjami. Skonfrontowaniu trajektorii uzyskanych przez procedurę główną z tymi które zwraca algorytm oparty o klasteryzację (tego testu nie wykonuje się dla sygnału syntetycznego, gdyż liczba jednostek motorycznych jest znana), oraz sprawdzeniu regularności występowania wyładowań znalezionych jednostek motorycznych i porównaniu odchylenia standardowego z wartościami uzyskiwanymi dla aktywności występujących losowo, symulowanych programem.

Błędy i tolerancje są wyrażone jako suma kwadratów błędów z kolejnych próbek porównywanych aktywności. Sygnałami rzeczywistymi są pomiary wykonane na ochotnikach, przy użyciu układu z rozdziału 1.3.3.

Analiza działania programu dla sygnału nr.1.

Przyjęte parametry analizy:

Próg amplitudy dla segmentacji 0.1

Tolerancja wstępnej segmentacji 0.02

Tolerancja 2 segmentacji 0.07


Efekty:

Liczba znalezionych aktywności 142

Liczba wzorców 20

Liczba aktywności niezaklasyfikowanych 17


Przeciętny błąd na znalezionej jednostkę, na kanał 0.0403




Rys. 36. Przybliżony fragment sygnału.

Na niebiesko zaznaczony jest sygnał oryginalny, czerwonym kolorem oznaczono jednostki motoryczne zaklasyfikowane jako zgodne z występującymi aktywnościami. Na pierwszym kanale zapisana jest uśredniona wielkość błędu ze wszystkich kanałów oraz poniżej numer wzorca jednostki motorycznej.

Jak widać jedynie klasyfikacja jednostki 3 jest dyskusyjna. Pozostałe wydają się być poprawne.



Rys. 37. Przeciętna trajektoria każdej z 20 jednostek motorycznych.




Rys. 38. Przeciętna trajektoria każdej z 9 jednostek motorycznych znalezionych programem opartym o klasteryzację.

Porównanie średnich trajektorii dla klasyfikacji 2 różnymi metodami, pierwsza to główna stosowana w projekcie, a druga to klasteryzacja - spotykana w literaturze i ceniona, napisana celem porównania.

Zestawiając wyniki z obu programów można uznać że trajektorie z klasteryzacji mają swoje odpowiedniki (dopasowanie po współrzędnych wykresów):


(1,1) ~ (5,2), (2,1) ~ (3,4), (1,2) ~ (1,4), (2,2) ~ (5,3), (3,2) ~ (3,1), (4,2) ~ (4,1), (1,3) ~ (2,1)
 (2,3) ~ (1,2), (3,3) ~ (2,4), (4,3) ~ (2,3)

Zatem można dopasować wszystkie trajektorie do siebie, pomimo pewnych różnic należy mieć na uwadze, że obie metody zwróciły różną liczbę sygatur, zatem uśrednione kształty mają prawo od siebie nieco odbiegać. Podsumowując oba algorytmy zwracają podobne wyniki, a różnią się głównie liczbą wybranych jako niezależne sygatur, która w metodzie autorskiej jest zdecydowanie większa. Można uznać wynik testu za korzystny, z sugestią że metoda może mieć tendencje do traktowania jednej jednostki motorycznej jako kilku podobnych.




Rys. 39. Aktywność jednostek motorycznych w trakcie zmiennego wysiłku, kropkami oznaczono pojedyncze wyładowania, a szarą linią wysiłek mięśnia[5].


Jak widać na powyższym wykresie, zwiększające się obciążenie mięśni powinno skutkować rekrutacją kolejnych jednostek motorycznych, a zmniejszające ich zwalnianiem. W trakcie pracy pojedyncza jednostka motoryczna wykazuje względnie stałą częstotliwość wyładowań, która stopniowo zmienia się w trakcie obciążenia (wzrastające wymusza wzrost częstotliwości).



Rys. 40. Wystąpienia jednostek 1-8



Rys. 41. Wystąpienia jednostek 9-16



Rys. 42. Wystąpienia jednostek 17-20

W przypadku szumu równomiernego odchylenie standardowe powinno wynosić około 2300 (oszacowane programem opisanym rozdziale 5.2), wartości zanotowane w trakcie eksperymentu są zdecydowanie niższe, co sugeruje iż wynik nie jest losowy, a co za tym idzie przynajmniej częściową poprawność klasyfikacji.

Analiza działania programu dla sygnału nr.2.

Przyjęte parametry analizy:

Próg amplitudy dla segmentacji 0.1

Tolerancja wstępnej segmentacji 0.02

Tolerancja 2 segmentacji 0.07


Efekty:

Liczba znalezionych aktywności 175

Liczba wzorców 17


Liczba aktywności niezaklasyfikowanych 37

Przeciętny błąd na znalezionej jednostkę na kanał 0.0534




Rys. 43. Przybliżony fragment sygnału.

Na powyższym rysunku widać 5 zaklasyfikowanych aktywności. Wybór decyzji ostatecznej na podstawie decyzji cząstkowych wydaje się działać poprawnie ponieważ dla 1,3,4,5 aktywności dopasowana została aktywność wybrana na największej liczbie kanałów. Dla aktywności 2 jedna z dwóch które wystąpiły tą samą liczbą razy. Klasyfikacja aktywności 2 i 3 budzi pewne wątpliwości, co może wynikać ze sporego zaszumienia, które widać w postaci oscylacji między zaklasyfikowanymi fragmentami.



Rys. 44. Przeciętna trajektoria każdej z 17 jednostek motorycznych.



Rys. 45. Przeciętna trajektoria każdej z 10 jednostek motorycznych wykrytych metodą klasteryzacji.

Da się zaobserwować znaczne podobieństwo kształtów generowanych przez obie metody. Test wypada pomyślnie.

Analiza działania programu dla sygnału nr.3.

Przyjęte parametry analizy:

Próg amplitudy dla segmentacji 0.1

Tolerancja wstępnej segmentacji 0.02

Tolerancja 2 segmentacji 0.07


Efekty:

Liczba znalezionych aktywności 104

Liczba wzorców 12

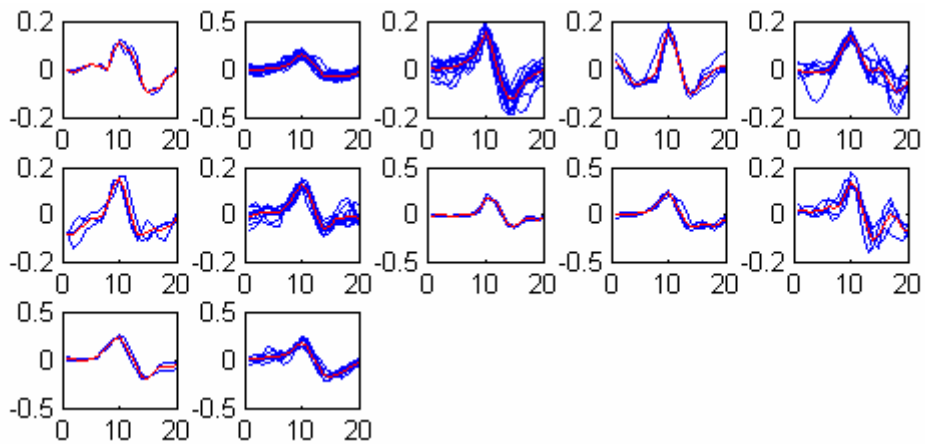
Liczba aktywności niezaklasyfikowanych 5

Przeciętny błąd na znalezionej jednostkę na kanał 0.0275




Rys. 46. Przybliżenie fragmentu zaklasyfikowanej aktywności.

Aktywności nie różnią się znacząco od sygnatur które są im przypisywane, sugeruje to poprawne działanie metody, bądź niewielkie błędy.




Rys. 47. Jednostki motoryczne (na niebiesko oznaczone nałożone na siebie tożsame aktywności, a na czerwono przeciętna trajektoria).




Rys. 48. Jednostki motoryczne klasyfikacja klasteryzacją.

Zestawienie z dwóch powyższych rysunków pozwala zaobserwować, że podobne sygnatury charakteryzują się podobnym rozrzutem kształtów w obu metodach.




Rys. 49. Przeciętna trajektoria każdej z 13 jednostek motorycznych.




Rys. 50. Przeciętne trajektorie jednostek motorycznych znalezione metodą klasteryzacji. Same trajektorie również mają swoje odpowiedniki.

Da się zaobserwować podobieństwa trajektorii, wynik testu można uznać za pomyślny.



Rys. 51. Wystąpienia jednostek 1-8



Rys. 52. Wystąpienia jednostek 9-12

Odchylenie standardowe w większości przypadków jest znacznie niższe niż 2300, zatem i tu można uznać iż większość jednostek została zaklasyfikowana poprawnie. Wyjątki stanowią jednostki 1 i 6.

Analiza działania programu dla sygnału syntetycznego niezasmionego z 5 symulowanymi typami aktywności.

Przyjęte parametry analizy:

Próg amplitudy dla segmentacji 0.12

Tolerancja wstępnej segmentacji 0.02

Tolerancja 2 segmentacji 0.07

Efekty:


Liczba znalezionych aktywności 51

Liczba wzorców 10

Liczba aktywności niezaklasyfikowanych 5


Przeciętny błąd na znalezionej jednostkę na kanał 0.2646

Obliczony błąd jest o rząd większy niż przy sygnałach rzeczywistych, co sugeruje błąd jego obliczenia, lub klasyfikacji.




Rys. 53. Wyświetlenie fragmentu sygnału z zaznaczonymi klasyfikacjami.

Jak widać na powyższym rysunku, aplikacja pomija znaczną część aktywności, może to być spowodowane specyfiką programu segmentującego, który odrzuca jednostki nie występujące na wszystkich kanałach, metoda sprawdzenia zakłada, że czas propagacji między kanałami nie pozwoli pojedynczej aktywności przemieścić się o więcej niż połowę okna, gdyż większe przemieszczenie nie występowało na badanych sygnałach rzeczywistych, hipoteza zostanie sprawdzona przy kolejnym sygnale syntetycznym. Drugi problem stanowią przesunięcia wzorców względem tożsamych z nimi aktywności, klasyfikacja jest poprawna, jednak wyświetlenie nie, problem nie występował na sygnałach rzeczywistych.



Rys. 54. Jednostki motoryczne (na niebiesko oznaczone) nałożone na siebie tożsame aktywności, a na czerwono przeciętna trajektoria).

Jak widać rozróżnienie między kształtami tożsamych aktywności jest minimalny, co sugeruje poprawną pracę programu. Jednostki o współrzędnych (1,1), (1,2), (2,2) oraz (3,2) wyglądają podobnie co potwierdza skłonność metody do tworzenia duplikatów. Analizując sygnatury można zaobserwować 4 różne kształty zatem jedna aktywność nie została znaleziona.



Rys. 55. Wystąpienia jednostek 1-8

Przeciętne odchylenie standardowe jest około 2,5 razy niższe niż w przypadku sygnałów rzeczywistych, jednakże należy mieć na uwadze że dane uzyskane z generatora losowego miały nieco inną częstotliwość próbkowania i wymagały przeskalowania. W efekcie sygnały z rzeczywistego układu mogły się pojawić na pozycjach 1-11000, a z generatora losowego na pozycjach 1-6666.

W tym wypadku pomocne okazało się ponowne wykorzystanie funkcji testowości opisanej w rozdziale 5.2, pokazała ona, że przy takim zakresie danych wejściowych dla rozkładu pseudolosowego normalnego wariancja wynosi przeciętnie ~ 1400 . Zatem uzyskana w tym teście wartość jest przeciętnie ~ 3 krotnie niższa niż przy szumie losowym. Warto wspomnieć, że dla sygnałów rzeczywistych stosunek wynosił $\sim 2-2.5$, zatem uzyskane tu wyniki są lepsze

Analiza działania programu dla sygnału syntetycznego niezaszumionego, po zapisaniu na wszystkich kanałach sygnału z kanału pierwszego, celem całkowitego usunięcia przesunięć między aktywnościami. Parametry analizy pozostały bez zmian celem zwiększenia wiarygodności próby.

Przyjęte parametry analizy:

Próg amplitudy dla segmentacji 0.12

Tolerancja wstępnej segmentacji 0.02

Tolerancja 2 segmentacji 0.07

Efekty:


Liczba znalezionych aktywności 90

Liczba wzorców 15

Liczba aktywności niezaklasyfikowanych 24


Przeciętny błąd na znalezionej jednostkę na kanał 0.0126

Wartość błędu jest o połowę niższa niż przy sygnałach rzeczywistych stąd wniosek, że wprowadzona zmiana pozwoliła wyeliminować znaczący błąd.



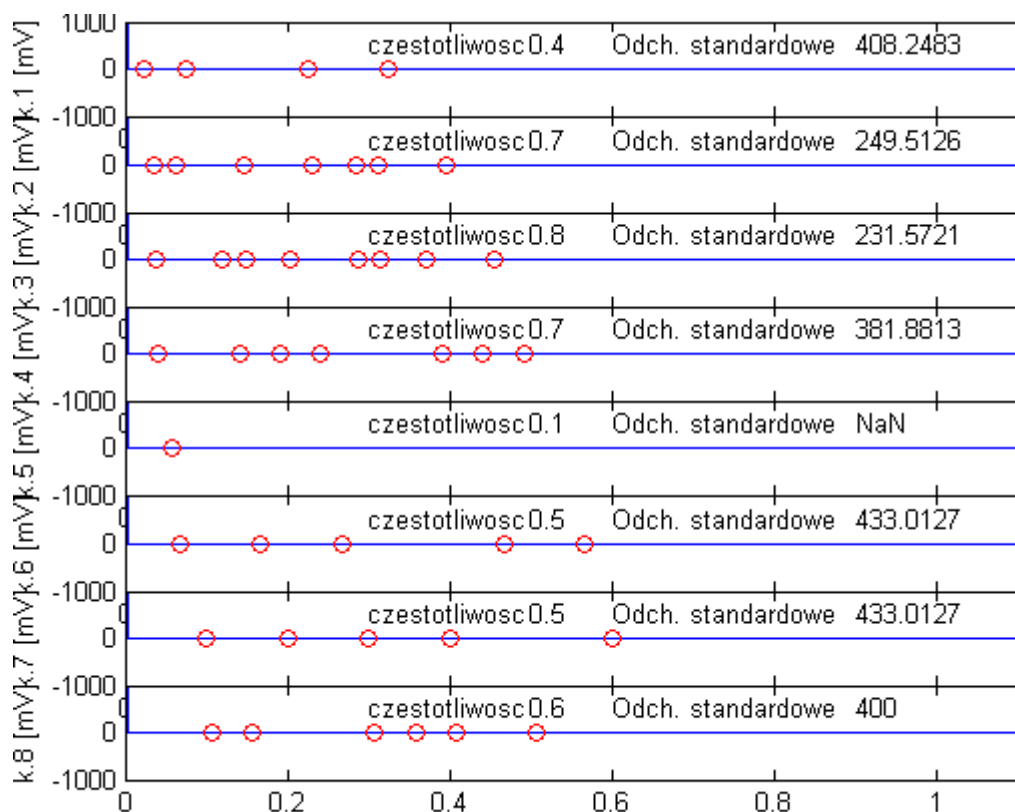
Rys. 56. Jednostki motoryczne (na niebiesko oznaczone nałożone na siebie tożsame aktywności, a na czerwono przeciętna trajektoria).

Duplikatów jest jeszcze więcej niż poprzednio, rozpoznano 5 aktywności.




Rys. 57. Wyświetlenie fragmentu sygnału z zaznaczonymi klasyfikacjami.

Jak widać przesunięcia zostały usunięte, klasyfikacje nakładają się na aktywności tak, że sygnał oryginalny jest całkowicie przykryty zatem klasyfikacja jest poprawna.



Rys. 58. Wystąpienia jednostek 1-8



Rys. 59. Wystąpienia jednostek 9-15

Wynik podobny do uzyskanego w teście poprzedniego sygnału syntetycznego. Nieco lepszy niż uzyskiwany przy sygnałach rzeczywistych.

7. Podsumowanie

Metoda potrafi rozróżniać aktywności jednostek motorycznych. Cel został osiągnięty. Jej główną wadą jest tworzenie zbyt dużej liczby wzorców w efekcie część z nich jest do siebie podobna. Celem eliminacji tego problemu można by zastosować kolejną fazę analizy usuwającą duplikaty.

Kolejnym możliwym ulepszeniem aplikacji wydaje się być dodanie kolejnej fazy analizy, w której wszystkie znalezione aktywności będą usuwane z badanego sygnału, obniżony zostanie próg segmentacji i wykonana próba znalezienia jednostek o małej amplitudzie.

Innym rozsądnym rozwiązaniem może być zarzucenie prac nad metodą, celem wykorzystania znanej z literatury i zastosowanej w pracy metody opartej o klasteryzację. Ponieważ jest ona logiczna, przejrzysta i prosta w implementacji. Porównując stosunek pracy do uzyskanych efektów, algorytm klasteryzacji wydaje się być znacznie korzystniejszy.

Ciekawym materiałem do badań jest możliwość świadomego sterowania konkretną jednostką motoryczną w trakcie skurczu mięśnia, do tego celu należało by zaadaptować aplikację do pracy w czasie rzeczywistym i skonstruować wizualizację pokazującą z osobna aktywności 2 znacznie różniących się dużych jednostek, oraz znaleźć ochotników chętnych poświęcić wiele czasu, na monotony eksperyment.

8. Bibliografia

1. Hausmanowa I., Elektromiografia kliniczna, PZWL, 1986
2. Pasko M., Walczak J., Teoria sygnałów, Wyd. Politechniki Śląskiej, 2003
3. Merletti R., Parker P., Electromyography Physiology, Engineering and Noninvasive Applications, Wiley-IEEE Press, 2004
4. Konrad P., Abc Emg, Technomex 2007
5. Holobar A., Clinical Neurophysiology, Elsevier, 2009
6. <http://en.wikipedia.org/wiki/Neuron>
7. <http://www.flashcardmachine.com/physiologyfinal-exam.html>
8. <http://www.nature.com/nrneurol/index.html>
9. http://www.lisn.polito.it/DEMUSE/Publish/DEMUSE_Decomposition_Techniques.html
10. <http://www.emglab.net/emglab/index.php>

9. Załączniki na płycie CD

Kody programów

Praca dyplomowa w formatach doc i pdf.