



**POLITECHNIKA
GDAŃSKA**

WYDZIAŁ ELEKTROTECHNIKI
I AUTOMATYKI

Imię i nazwisko autora rozprawy: Aleksander Pałkowski
Dyscyplina naukowa: Automatyka i Robotyka

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim: Automatyzacja procesu rehabilitacji dzieci z *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta*

Tytuł rozprawy w języku angielskim: Automation of the rehabilitation process for children with cerebral palsy and osteogenesis imperfecta

Promotor <i>podpis</i>	Drugi promotor <i>podpis</i>
dr hab. inż. Grzegorz Redlarski	
Promotor pomocniczy <i>podpis</i>	Kopromotor <i>podpis</i>
dr inż. Ariel Dzwonkowski	

Gdańsk, rok 2018

Małym ludziom o wątych ciałach, ale wielkich sercach.

Podziękowania

Chciałbym gorąco podziękować wszystkim osobom, których działania umożliwiły realizację badań opisanych w niniejszej rozprawie: prof. Grzegorzowi Redlarskiemu, prof. Januszowi Siebertowi, Piotrowi Kuczyńskiemu oraz mojej kochanej mamie.

Szczególne podziękowania chciałbym skierować dodatkowo do prof. Grzegorza Redlarskiego — mojego promotora. Bez wsparcia, pomocy, a może przede wszystkim cierpliwości Pana Profesora z pewnością nie znajdowałbym się w tym miejscu mojego życia. Jestem bardzo wdzięczny za możliwość pracy z Nim.

Spis treści

Spis ważniejszych symboli, skrótów i akronimów	3
1. Wstęp	5
1.1. Wprowadzenie	5
1.2. Aktualny stan wiedzy	10
1.3. Cel i teza rozprawy	11
1.4. Struktura rozprawy	12
2. Aspekty fizjologiczne omawianych zagadnień	14
2.1. Układ mięśniowy	14
2.1.1. Budowa i funkcjonowanie	14
2.1.2. Pomiar i analiza sygnałów mioelektrycznych	22
2.2. <i>Paralysis cereбрalis infantium</i>	24
2.3. <i>Osteogenesis imperfecta</i>	27
3. Przegląd wybranych metod i systemów rehabilitacyjnych	31
3.1. Podstawowe ćwiczenia i akcesoria rehabilitacyjne	31
3.2. Urządzenia wspomagające rehabilitację	36
3.3. Zaawansowane systemy rehabilitacyjne	39
4. Metodologia badań własnych	43
4.1. Plan i zakres badań	43
4.2. Charakterystyka grupy badanej	49
4.3. Aparatura badawcza	50
4.3.1. Jednostka komputerowa i oprogramowanie	50
4.3.2. Kamera Kinect	51
4.3.3. Specjalistyczny elektromiograf	53
4.4. Metody obliczeniowe	56
4.4.1. Metody przetwarzania sygnałów EMG	56
4.4.2. Metody sztucznej inteligencji	59
4.4.3. Metody statystyczne i miary błędu	66
4.4.4. Algebra kwaternionów	68
5. Wyniki i dyskusja	71
5.1. Analiza ruchu kończyn i aktywności bioelektrycznej mięśni	71
5.1.1. Badania ruchomości stawów	71
5.1.2. Badania wpływu dodatkowych obciążeń	83
5.2. Identyfikacja stanu osoby ćwiczącej	91
5.3. Ocena wykonywanych ćwiczeń	99
5.4. Estymacja wykonywanych ruchów na podstawie sygnałów EMG	104



6. Podsumowanie i wnioski	108
Bibliografia	111
Spis rysunków	117
Spis tablic	123
A. Dane statystyczne wartości zmiennych wejściowych maszyn uczących	125

Spis ważniejszych symboli, skrótów i akronimów

Symbole

\mathbb{H}	Algebra kwaternionów; zob. rozdz. 4.4.4, s. 68
\hat{y}	Wartość teoretyczna zmiennej objaśnianej

Skróty i akronimy

ACC	Dokładność (Accuracy); zob. wzór (4.31), s. 66
AI	Sztuczna inteligencja (Artificial Intelligence)
CGAU8	Falka pochodna gaussowska zespolona 8 (Complex Gaussian 8 Wavelet)
CMOR	Falka Morleta zespolona (Complex Morlet Wavelet)
CWT	Ciągła transformata falkowa (Continuous Wavelet Transform); zob. rozdz. 4.4.1, s. 58
DT	Drzewa decyzyjne (Decision Trees); zob. rozdz. 4.4.2, s. 60
EMG	Elektromiografia; zob. rozdz. 2.1.2, s. 22
F1	Miara F_1 (F_1 Score); zob. wzór (4.34), s. 67
FBSP	Falka sklejkę częstotliwości (Frequency B-Spline Wavelet)
GAUS8	Falka pochodna gaussowska 8 (Gaussian 8 Wavelet)
HITL	Człowiek-w-pętli (Human-in-the-Loop); zob. rozdz. 1.1, s. 7
IEMG	Całka sygnału EMG (Integrated EMG); zob. wzór (4.4), s. 58
KNN	Algorytm k najbliższych sąsiadów (K -Nearest Neighbors); zob. rozdz. 4.4.2, s. 59
LSLQ	Najmniejsze kwadraty logarytmu współczynnika dokładności (Least Squares Log of Accuracy Ratio); zob. wzór (4.36), s. 68
MAE	Średni błąd bezwzględny (Mean Absolute Error); zob. wzór (4.35), s. 67
MAV	Średnia wartości bezwzględnych amplitudy sygnału (Mean Absolute Value); zob. wzór (4.2), s. 57
MAV1	Zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1 (Modified Mean Absolute Value Type 1); zob. wzór (4.5), s. 58



MAV2	Zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2 (Modified Mean Absolute Value Type 2); zob. wzór (4.6), s. 58
MEXH	Falka Rickera (Mexican Hat Wavelet)
MLP	Perceptron wielowarstwowy (Multilayer Perceptron); zob. rozdz. 4.4.2, s. 64
MORL	Falka Morleta
OI	Wrodzona łamliwość kości (łac. <i>osteogenesis imperfecta</i>); zob. rozdz. 2.3, s. 27
PCI	Mózgowe porażenie dziecięce (łac. <i>paralysis cerebralis infantium</i>); zob. rozdz. 2.2, s. 24
SHAN	Falka Shannona
SSI	Prosta całka kwadratowa sygnału (Simple Square Integral); zob. wzór (4.7), s. 58
SVC	Klasyfikacja wektorów nośnych (Support Vector Classification); zob. rozdz. 4.4.2, s. 61
SVM	Maszyna wektorów nośnych (Support Vector Machines); zob. rozdz. 4.4.2, s. 61
SVR	Regresja wektorów nośnych (Support Vector Regression); zob. rozdz. 4.4.2, s. 61
VAR	Wariancja sygnału EMG (Variance of EMG); zob. wzór (4.8), s. 58
WL	Długość przebiegu (Waveform Length); zob. wzór (4.3), s. 57

Rozdział 1

Wstęp

„My hand trembles, but my heart does not.”

— STEPHEN HOPKINS,
podczas podpisywania Deklaracji
niepodległości Stanów Zjednoczonych

1.1. Wprowadzenie

Automatyka (Control Engineering) jest dziedziną nauki zajmującą się badaniami nad metodami sterowania różnorodnymi procesami. We współczesnej definicji automatyki ujmuje się grupy metod i zagadnień związanych zarówno z klasycznymi metodami sterowania PID, nowoczesną teorią sterowania (m.in. sterowanie predykcyjne, sterowanie adaptacyjne), jak i z metodami sztucznej inteligencji.

Badania nad teorią sterowania i jej praktycznymi zastosowaniami przyczyniły się w dużej mierze do przyspieszonego rozwoju gospodarczego współczesnego społeczeństwa. Choć początkowo krytykowane ze względu na zmniejszanie miejsc pracy dla robotników, procesy automatyzacji (Automation), tj. ograniczanie lub zastępowanie ludzkiej pracy przez samoczynną pracę maszyn, pozwoliły na wykonywanie szeregu prac szybciej i dokładniej niż przed ich wprowadzeniem. Koronnym przykładem automatyzacji i jej wpływu mogą być pierwsze na świecie roboty przemysłowe Unimate 1000 zainstalowane w 1961 roku w fabryce General Motors w Trenton, w stanie New Jersey – wydarzenie to zmieniło oblicze motoryzacji. Ostatnie lata badań odznaczają się wzmożonym rozwojem sztucznej inteligencji (Artificial Intelligence, AI), która w sposobie rozumowania coraz bardziej przypomina ludzi.

Postęp AI jest rzeczą, która może budzić pewne wątpliwości. Max Tegmark, profesor fizyki i kosmologii na Massachusetts Institute of Technology, w swojej książce pt. „Life 3.0: Being Human in the Age of Artificial Intelligence” roztacza wizję społeczeństwa wspieranego przez zaawansowaną AI, ale przede wszystkim podejmuje dyskusję o możliwych konsekwencjach takiego stanu rzeczy [1]. Zadawane są pytania o to, które zawody powinny zostać w pełni zautomatyzowane,



w jaki sposób systemy autonomiczne powinny być traktowane przez systemy prawne, czy – o to, co dla wielu jest elementem kluczowym – rozwój superinteligencji stanowi zagrożenie dla ludzkości. Autor nie podaje ostatecznych odpowiedzi na te pytania, jednak szczególnie podkreśla fakt, że każda osoba zajmująca się badaniami nad wykorzystaniem AI powinna mieć powyższe na uwadze.

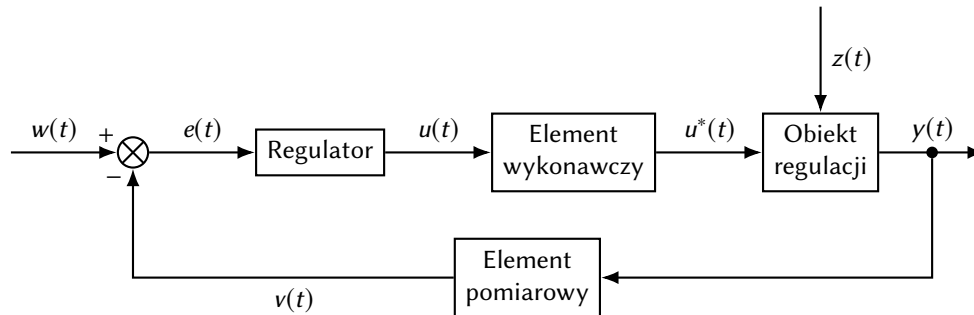
W obliczu coraz powszechniejszych badań nad synergią AI z innymi dziedzinami nauki, a w szczególności z medycyną, wielu naukowców zaczyna podnosić niektóre z wymienionych kwestii. Wzywa się w tym przypadku do zbadania problemów etycznych, takich jak stronniczość algorytmów i danych, kwestia prywatności pacjentów oraz podatność rozwiązań na komercyjne pobudki prywatnych korporacji [2]. Trudno jednak zignorować wyniki eksperymentów, w których AI potrafi dokonywać diagnozy choroby z co najmniej taką samą dokładnością, jak wykwalifikowani lekarze-specjaliści [3].

Choroby takie, jak *osteogenesis imperfecta* czy *paralysis cereбрalis infantium* odbierają częściowo lub nawet całkowicie możliwość własnej lokomocji. Aktualnie zauważa się brak odpowiednich przyrządów rehabilitacyjnych, przystosowanych do prowadzenia wyspecjalizowanych ćwiczeń ruchowych, których dostępność nie byłaby przeszkodą dla potrzebujących rodzin. Oprócz utrudnień w dostępie do urządzeń należy także mieć na uwadze ograniczone możliwości i liczbę osób odpowiedzialnych za rehabilitację w zakresie diagnozowania stanu zdrowia, planowania ćwiczeń oraz kontrolowania ich przebiegu. Ponadto, jako problem wskazuje się niechęć dzieci do wykonywania ćwiczeń, których przebieg jest często żmudny i długotrwały [4]. W dobie coraz większego nacisku na medycynę spersonalizowaną, jedynym efektywnym sposobem przezwyciężenia odnośnych problemów może być zautomatyzowanie procesów ćwiczeniowych i ich doposażenie w atrakcyjne wytwory informatyki, np. gry komputerowe.

Poprzez automatyzację procesu rozumie się ograniczenie roli kontrolującego czynnika ludzkiego – osoby rehabilitanta – podczas całego przebiegu rehabilitacji, począwszy od doboru zestawu ćwiczeń, aż po szczegółowy nadzór sposobu ich wykonywania. Uzyskanie takiego efektu wymaga zastosowania efektywnych metod identyfikacji ruchów kończyn oraz utworzenia odpowiedniej bazy wiedzy rehabilitacyjnej. Wówczas na podstawie wykrytych ruchów możliwe będzie dokonywanie weryfikacji prawidłowości wykonywanych ćwiczeń, a w przypadku jej braku – formułowanie wymuszeń korekcyjnych.

W celu przybliżenia idei automatyzacji w rehabilitacji, należy cofnąć się do jej definicji, a w szczególności do opisu jednego z jej aspektów – układu regulacji. Sterowanie w takim układzie polega na wykorzystaniu sygnału sterującego (zazwyczaj z automatycznego regulatora bądź od człowieka) do wywierania działania na dany obiekt regulacji tak, aby uzyskać określony efekt sterowania. Jedno z klasycznych podejść do tego tematu zakłada utworzenie pętli od wyjścia obiektu regulacji ze sprzężeniem zwrotnym, do elementu porównującego, czyli komparatora (rys. 1.1). Element porównujący służy oszacowaniu różnicy pomiędzy wartością zadaną układu $w(t)$ a wartością zmierzoną $v(t)$, która jest wynikiem działania elementu pomiarowego monitorującego wyjście obiektu regulacji $y(t)$. Otrzymałą różnicę sygnałów nazywa się uchybem $e(t)$ i podaje się na wejście regulatora, który wedle zaimplementowanej metody generuje sygnał sterowania $u(t)$ dla elementu wykonawczego. Ostatecznie, element wykonawczy oddziałuje na obiekt regulacji wymu-

szaniem $u^*(t)$. Dodatkowo rozróżnia się zakłócenia $z(t)$ działające bezpośrednio na regulowany obiekt. Charakter odnośnych sygnałów jest zależny od obiektu regulacji i oczekiwanego efektu jego działania.




Rysunek 1.1. Schemat klasycznego układu regulacji (w pętli zamkniętej) [5]

Wprowadzając do powyższego modelu czynnik ludzki, taki typ systemu określić można mianem człowiek-w-pętli (Human-in-the-Loop, HITL). Najbardziej ogólna definicja HITL podaje, że jest to model wymagający do funkcjonowania interakcji z człowiekiem. Termin ten jest najczęściej łączony z wykonywaniem symulacji pewnych procesów, w których centralnym ośrodkiem decyzyjnym, bądź wykonawczym jest człowiek. Można zatem do tej kategorii zaliczyć wszelkie symulacje prowadzenia samochodu, sterowania samolotem, czy nawet symulacje działań wojennych z udziałem żywych żołnierzy.

Ideę tą można zastosować w przeprowadzaniu procesów medycznych, zastępując nieożywiony obiekt regulacji człowiekiem. Należy podkreślić, iż w przypadku rehabilitacji dzieci znaczna większość zajęć prowadzona jest bez udziału zaawansowanych systemów decyzyjnych czy wspomagających. Poprzez analogię do zamkniętego układu regulacji można stwierdzić, że rolę elementu porównującego, elementu pomiarowego, regulatora oraz elementu wykonawczego w całości spełnia osoba rehabilitanta. Mnogość i efektywność metod wykorzystujących uczenie maszynowe do wnioskowania automatycznego, systemów eksperckich oraz metod wspomagania ruchu człowieka każe jednak przypuszczać, że możliwe jest – ale także zasadne – znaczne zmniejszenie udziału rehabilitanta na rzecz wspomnianych efektów rozwoju nauki i techniki.

Poprzez pewną modyfikację procesu rehabilitacji można uzyskać wskazywany efekt. Mianowicie, gdyby urządzenie do rehabilitacji zostało wyposażone w elementy wspomagające ruch (np. egzoszkielec), kontrolę funkcji pozostałych części mechanicznych, na które oddziałuje pacjent (np. pedały roweru treningowego z regulowanym oporem) oraz wizualizację ćwiczeń sprzężoną z ruchami pacjenta (np. grę komputerową), to odnośne składowe stanowiłyby element wykonawczy obiektu regulacji – człowieka. Czynności fizjologiczne pacjenta, będące kluczowymi dla procesu rehabilitacji, mogą być wtedy mierzone za pomocą nowoczesnych matryc czujników (mierzących aktywność elektromiograficzną czy elektroencefalograficzną) umieszczonych w poszczególnych częściach urządzenia. Informacje te można wykorzystać w systemie eksperckim, którego zadaniem jest ocenić jakość wykonywanego ćwiczenia i zdecydować o jego postępie. Automatycznie podejmowana decyzja, będąca połączeniem bazy wiedzy z wybranymi metodami uczenia maszynowego, jest w takiej konfiguracji wartością zadaną układu. Nie należy jednak

całkowicie eliminować osoby rehabilitanta, która to powinna mieć wgląd do danych opisujących realizację ćwiczeń oraz mieć możliwość wpływu na działanie systemu decyzyjnego. Ideę opisanego układu regulacji przedstawiono na rysunku 1.2.

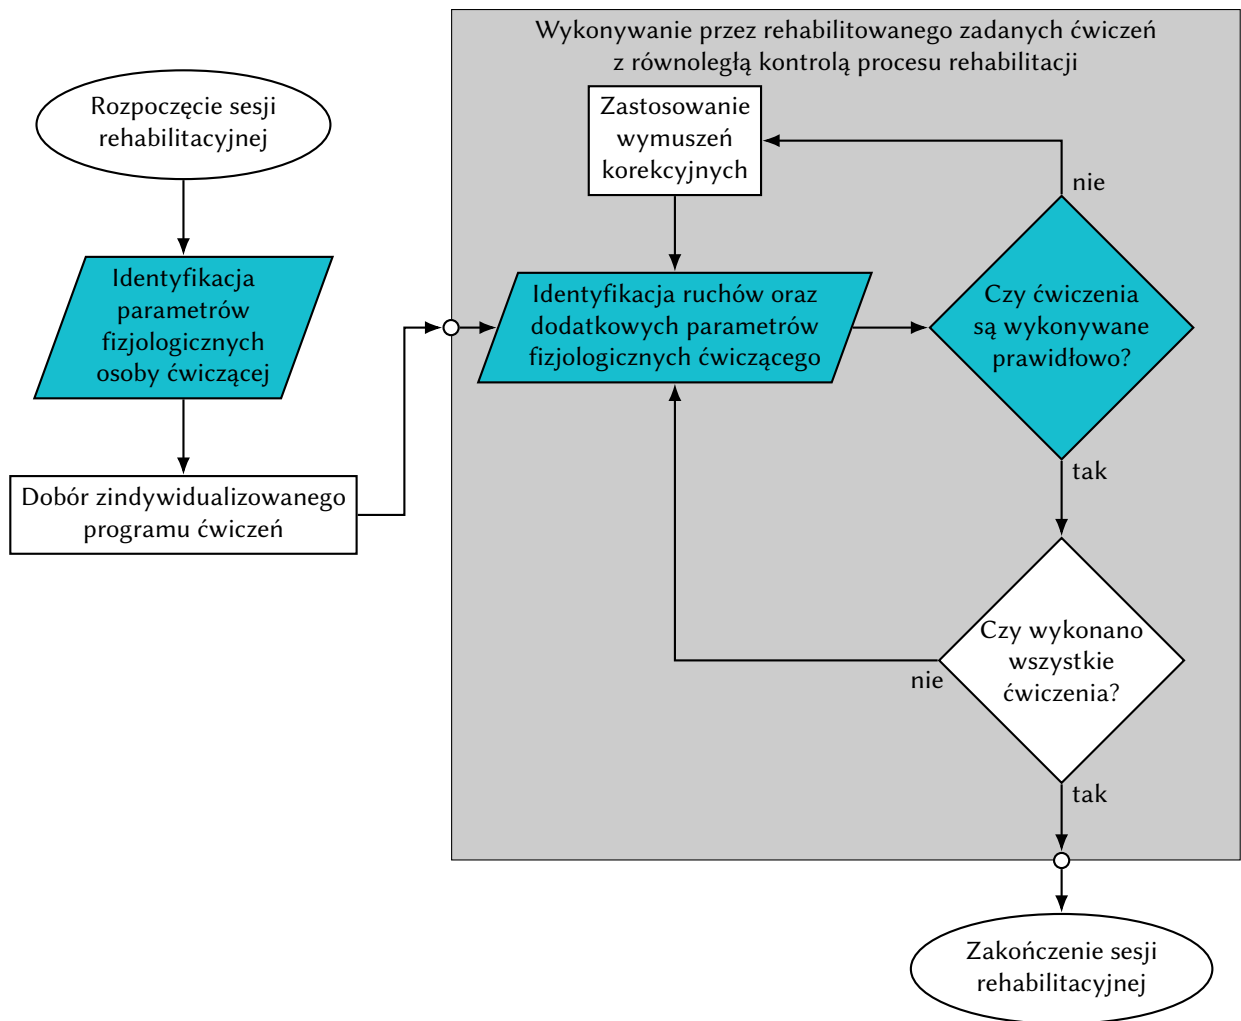


Rysunek 1.2. Schemat propozycji układu regulacji typu HITL do zastosowania w rehabilitacji

Funkcjonowanie zautomatyzowanego systemu rehabilitacji można streścić w postaci algorytmu opisującego kolejne kroki podejmowane w trakcie jednej sesji ćwiczeniowej (rys. 1.3). Proces ten można podzielić na dwa główne etapy: obejmujące dobór programu ćwiczenia na podstawie charakterystyk fizjologicznych pacjenta i ocenę rehabilitanta oraz pętlę regulacji procesu rehabilitacji. Na obu etapach następuje ocena czynności układu ruchu na podstawie m.in. elektromiografii, encefalografii, czy ogólnego pomiaru charakterystyki ruchu ciała. W pętli regulacji następuje ciągła ocena sposobu wykonywania danego ćwiczenia, a w przypadku niezgodności z wcześniej ustalonym planem (kiedy pacjent wykonuje ćwiczenie zbyt szybko, gwałtownie itp.), jest uruchamiana procedura korekcyjna sugerująca osobie ćwiczącej własnowolną zmianę. Podejście to nie tylko umożliwia szybką reakcję na błędne wykonywanie ćwiczeń (co może prowadzić do pogorszenia stanu zdrowia pacjenta), ale również może być przyczynkiem do bardziej efektywnego, od podejścia manualnego, „zaprogramowania” prawidłowego sposobu wykonywania ćwiczeń i poprawnych odruchów.

Uogólniony opis zautomatyzowanego systemu rehabilitacji, przedstawiony powyżej, można uściślić, proponując przykładowe urządzenie wykorzystujące omówioną ideę (rys. 1.4). Urządzenie to można porównać do konsoli do gier. Aczkolwiek w odróżnieniu od rozwiązań profesjonalnych, chociażby firm takich jak Microsoft czy Sony, kontrolerem jest tutaj całe urządzenie rehabilitacyjne, a użytkownik steruje grą, oddziałując swoim ciałem na elementy ruchome, takie jak: pedały, ortezy itp. Ze względu na dużą skuteczność we wspomaganie procesów rehabilitacyjnych (uwaga pacjentów jest odwrócona od samych ćwiczeń) podobne rozwiązania można spotkać w niektórych nowoczesnych systemach rehabilitacyjnych (zob. rozdz. 3.3). Odróżnia je jednak brak funkcjonalności wyżej opisanego systemu automatyzacji, który – w opisywanym przykładzie – samoczynnie dostosowuje delikatne wymuszenia mechaniczne (przez egzoszkielet i pedały) oraz zmiany w środowisku gry do zindywidualizowanego programu ćwiczeń.


Usługi medyczne są po dziś dzień jednymi z najmniej zautomatyzowanych. Z oczywistych względów wprowadzenie samodzielnego wniosku przez system czy urządzenie wśród wielu



Rysunek 1.3. Schemat blokowy przedstawiający uproszczony algorytm proponowanego zautomatyzowanego procesu rehabilitacji

osób budziłyby zastrzeżenia natury etycznej (podejmowanie ryzykownych decyzji przez maszynę), prawnej (odpowiedzialność za pacjenta), a także metodologicznej (poprawność podejmowanych decyzji). Zdrowie człowieka – jako najwyższe dobro – jest traktowane w sposób jak najsilniej wykluczający możliwość popełnienia pomyłki, co przekłada się na staranność w procesach rozwojowych medycyny. Stąd też fizjoterapia dzieci z *paralysis cerebialis infantium* oraz *osteogenesis imperfecta*, w porównaniu z pozostałymi dziedzinami nauk o zdrowiu, wydaje się być szczególnie marginalizowana pod względem stosowania najnowszych zdobyczy nauki i techniki. Jest to sytuacja niestosowna, ponieważ uniemożliwia znaczną poprawę warunków życia ludzi obarczonych tymi chorobami, a wśród takich można wskazać jednostki wybitne i potrzebne społeczeństwu, jak Michel Petrucciani (rys. 1.5), genialny pianista jazzowy, który cierpiał na *osteogenesis imperfecta* typu III, czy autor cytatu wprowadzającego – Stephen Hopkins, sygnatariusz Deklaracji niepodległości Stanów Zjednoczonych, wedle zapisków historii mający objawy *paralysis cerebialis infantium*.

Automatyczna regulacja procesów rehabilitacyjnych (a także większości medycznych) w pętli ze sprzężeniami jest tematem wciąż niedostatecznie zbadanym. Choć droga do praktycznego stosowania



Rysunek 1.4. Koncept systemu rehabilitacji wykorzystującego techniki multimedialne, ortezy wspomagane oraz kontrolę działania elementów mechanicznych przyrządu do zautomatyzowanej regulacji ćwiczeń

wania w medycynie rozwiązań opartych na idei samoczynnej analizy i wnioskowania jest daleka, to nawet na tym etapie nie należy zaprzestawać wzmożonych badań prowadzących w przyszłości do ich wdrożenia. Niniejsza rozprawa stanowi jeden z kroków stawianych w tym kierunku.



Rysunek 1.5. Michel Petrucciani [6]

1.2. Aktualny stan wiedzy

Z powodu szerokiego zakresu rozprawy doktorskiej, powiązanego jednocześnie z metodami analizy biosygnatów, AI oraz fizjoterapią, analizę aktualnego stanu tych zagadnień postanowiono rozdzielić na dwie części. Poniżej przedstawiono krótkie podsumowanie stanu wiedzy dotyczącego analizy sygnału elektromiograficznego. Natomiast w rozdziale 3 skupiono się na ukazaniu aktualnej sytuacji w temacie metod rehabilitacji i przyrządów w niej stosowanych.

Wybór odpowiedniej reprezentacji sygnału dla modelu maszyny uczącej istotnie wpływa na jego efektywność. Do analizy sygnałów elektromiografii wyróżnia się trzy grupy danych opisują-

cych przebiegi aktywności mięśni. Są to reprezentacje w dziedzinie czasu, dziedzinie częstotliwości oraz reprezentacje czasowo-częstotliwościowe lub w domenie skali czasu [7]. Ostatnia grupa ze względu na duże obciążenie obliczeniowe oraz potrzebę dodatkowego zmniejszania wielkości przestrzeni cech nie jest zalecana do analizy niestacjonarnych sygnałów elektromiografii [8]. Ponadto wykorzystanie przekształceń w dziedzinie częstotliwości wiąże się z niepotrzebnym obciążeniem obliczeniowym, a także nie dostarcza znacząco lepszych rezultatów w procesie klasyfikacji [8, 9]. W sprzeczności z tymi twierdzeniami stoją jednak niektóre prace naukowe, które udowadniają znakomitą efektywność przekształceń falkowych jako metody opisu sygnału mioelektrycznego, osiągając ponad 96% poprawności w rozróżnianiu danych stanów przez testowane metody uczenia maszynowego (m.in. sztuczne sieci neuronowe i losowy las) [10, 11].

Znaczna część prac dotyczących wykorzystania AI w analizie elektromiografii skupia się na problemach klasyfikacji wybranych stanów ciała ludzkiego, takich jak: identyfikacji stanów patologicznych tkanki mięśniowej, rozróżnieniu pozycji ciała, bądź klasyfikacji gestów wykonywanych ręką [8, 12–14]. Innym stanem, który mniej powszechnie stanowi podstawę badań nad modelami klasyfikacji, jest stan zdrowotny układu ruchu, do identyfikacji którego można już znaleźć efektywne rozwiązania [15]. Istnieją również publikacje przedstawiające modelowanie ruchu kończyn, w tym głównie estymację momentów w stawach [16, 17], a także nieliczne próby wykorzystania metod regresji do szczegółowego dekodowania ruchu i pozycji łańcuchów kinematycznych kończyn [18, 19]. Analiza literatury wskazuje na dwie, najczęściej wykorzystywane w odnośnych problemach, metody uczenia maszynowego: sztuczne sieci neuronowe oraz maszynę wektorów nośnych.

1.3. Cel i teza rozprawy

Celem nadrzędnym prac badawczych będących tematem przedmiotowej rozprawy jest opracowanie podstaw metodologicznych dla automatycznej platformy eksperckiej asystującej w procesie rehabilitacji dzieci chorych na *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta*. Propozycja opisywanego systemu składa się z trzech części: podsystemu identyfikującego stan układu ruchu pacjenta, podsystemu odpowiedzialnego za weryfikację wykonywanych ćwiczeń oraz podsystemu identyfikacji ruchów kończyn na podstawie sygnałów elektromiografii powierzchniowej.

Przedstawiona metodyka nie jest ostatecznym rozwiązaniem problemu braku automatyzacji procesów rehabilitacyjnych, a jedynie stanowi fundament dla dalszego rozwoju układów regulacji automatycznej w odnośnym kierunku.

Biorąc powyższe pod uwagę, formułuje się tezę:

Zastosowanie metod uczenia maszynowego do analizy napięcia mięśniowego w procesach rehabilitacji dzieci z *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta* pozwala na zautomatyzowanie szeregu zestawów ćwiczeń i procedur im towarzyszących.

Wykazanie powyższej tezy wymaga realizacji następujących etapów:

- gromadzenia wyników aktywności mioelektrycznej i opisu ruchu kończyn podczas wykonywania ćwiczeń przez dzieci zdrowe, dzieci z *paralysis cereбрalis infantium* oraz dzieci z *osteogenesis imperfecta*,
- selekcji metod do przetwarzania sygnału elektromiograficznego,
- wyboru sposobu reprezentacji wiedzy dla modeli uczenia maszynowego,
- zastosowania metod klasyfikacji do analizy aktywności bioelektrycznej mięśni w celu identyfikacji cech sygnałów, które umożliwiają ocenę kondycji układu ruchu pacjenta,
- opracowania modelu klasyfikacyjnego do analizy sygnału elektromiograficznego, mierzonego podczas wykonywania wybranych ruchów, który pozwoli na ocenę poprawności wykonywania ruchów podczas planowanych ćwiczeń,
- zastosowania metod regresji do analizy aktywności mioelektrycznej, mierzonej podczas wykonywania ruchów kończyn, umożliwiającą dokładną estymację ruchów wyłącznie na podstawie aktywności mięśniowej.

1.4. Struktura rozprawy

Zagadnienia techniczne, dla których rozwiązania przedstawiono w rozprawie, odnoszą się bezpośrednio do tematyki związanej z fizjologią człowieka, a w szczególności do istoty aktywności bioelektrycznej mięśni. Stąd też, pomimo faktu, że dziedzina pracy znajduje się w zakresie nauk inżynierskich, autor uważa za konieczne przedstawienie czytelnikowi podstaw teoretycznych wybranych elementów biologii i medycyny odnoszących się do opisywanych zagadnień. Jest to niezbędne do zrozumienia sposobu analizy sygnałów elektromiografii oraz poznania motywacji do opracowania opisanego metodologii. Z tego względu interdyscyplinarny charakter pracy wymusił rozdzielenie treści na części odnoszące się do nauk inżynierskich oraz nauk o życiu.

Rozdziały dysertacji można zatem podzielić na dwie kategorie. Rozdziały 2 i 3 służą przedstawieniu fizjologicznego tła teoretycznego dla przeprowadzonych badań. Rozdział 2 opisuje źródło i istotę zjawiska aktywności elektrycznej mięśni, a także przybliży od strony medycznej dwie poruszane w sposób szczególny choroby. Rozdział 3 przedstawia z kolei stan wiedzy technicznej odnoszącej się do tematyki rehabilitacji ruchowej u dzieci.

Rozdziały 4 i 5 stanowią już własny wkład autora w przedstawione eksperymenty oraz teorię z tym związaną. W rozdziale 4 ukazano szczegóły metodologiczne wykonanych badań. Opis i plan badań zawarty jest w rozdziale 4.1. Natomiast rozdział 4.2 opisuje szczegółowo badaną grupę wolontariuszy wraz z kryteriami, według których grupa ta była dobierana. W rozdziale 4.3 zawarty został opis i sposób wykorzystania aparatury badawczej. Metody obliczeniowe, tj. metody filtracji i przetwarzania sygnałów, metody uczenia maszynowego oraz metody statystyczne i inne miary zestawiono w rozdziale 4.4. Wyniki wykonanych badań opisano w rozdziale 5, gdzie w pierwszej kolejności analizowano zebrane pomiary aktywności mioelektrycznej oraz dane rotacji kończyn

(rozdz. 5.1), by następnie przedstawić wyniki identyfikacji stanu zdrowia pacjentów (rozdz. 5.2), oceny wykonywanych ćwiczeń (rozdz. 5.3) oraz estymacji ruchów kończyn (rozdz. 5.4).

Pracę zamyka podsumowanie i wnioski zawarte w rozdziale 6 oraz zestawienie 93 pozycji cytowanej literatury.

Ponadto, treść rozprawy uzupełnia dodatek A zawierający dane statystyczne wartości zmiennych wejściowych maszyn uczących, które nie zostały zamieszczone w głównej części pracy.

Rozdział 2

Aspekty fizjologiczne omawianych zagadnień

2.1. Układ mięśniowy

2.1.1. Budowa i funkcjonowanie

Układ ruchu człowieka (łac. *motorium*) jest częścią jego organizmu odpowiadającą za utrzymanie postawy i wykonywanie ruchów. Ze względu na zakres wykonywanych czynności, układ ruchu można podzielić na trzy główne składniki: układ szkieletowy (łac. *systema skeletale*), więzadła (łac. *ligamenta*) oraz układ mięśniowy (łac. *systema musculare*).

Układ mięśniowy, a dokładniej zawarte w nim mięśnie szkieletowe, stanowią składnik czynny układu ruchu, a więc odpowiadają za ruch kości względem siebie i innych struktur oraz stanowią wsparcie dla całego ciała. Zbudowane są z wielojądrzastych, długich, ułożonych równolegle do siebie włókien z poprzecznymi prążkami. Mięśnie szkieletowe unerwione są przez motoneurony zapewniające ich spójną funkcjonalność. W ciele ludzkim występuje ponad 440 mięśni tego rodzaju.


Należy nadmienić, iż, oprócz mięśni szkieletowych, w skład układu mięśniowego wchodzi również dwa inne typy tkanki mięśniowej: mięśnie gładkie oraz mięsień sercowy. Mięśnie gładkie występują m.in. w ścianach naczyń krwionośnych, gałce ocznej, czy strukturach powiązanych z układem oddechowym, pokarmowym oraz moczowo-płciowym. Ich unerwienie zapewniają włókna trzewne ruchowe. Mięsień sercowy występuje z kolei wyłącznie w ścianach serca lub w ścianach niektórych dużych naczyń blisko ich połączenia z sercem. Jest on unerwiony przez nerwy trzewne ruchowe. Ze względu na funkcję jaką spełniają odnośne mięśnie, opis ich budowy, działania, czy metod badania ich funkcji czynnościowych zostanie pominięty w dalszej części rozprawy.

W strukturze mięśnia szkieletowego można wyróżnić dwa typy elementów – bierne i czynne. Elementem czynnym są białka posiadające zdolność kurczenia się pod wpływem impulsów nerwowych. Strukturą bierną mięśnia – jego tkanka łączna – nadaje mu kształt, sprężystość i konsystencję, określane jako tonus mięśniowy. Prawidłowy tonus mięśniowy jest cechą zależną głównie od



parametrów mechanicznych samej tkanki.

Budowę mięśnia można opisać jako zespół struktur tworzących zintegrowane zespoły (rys. 2.1). Główną jego strukturę stanowi włókno mięśniowe pogrupowane w pęczki otoczone tkanką wiotką. Często pęczki te są zebrane w grupy, tworząc brzusiec mięśniowy otoczony omięsną zewnętrzną. Podstawowym elementem budowy mięśnia jest sarkomer (o długości około $2,5 \mu\text{m}$), który *de facto* odpowiada za mechanizm aktywnego skurczu komórek mięśniowych.



Rysunek 2.1. Struktura mięśnia szkieletowego z uwzględnieniem błon łącznotkankowych [20]

W czasie pobudzenia komórki mięśniowej można zaobserwować zmianę odległości prążków mięśnia widocznych na miofibrylach. Wówczas następuje skrócenie każdego sarkomeru, dając w efekcie skurcz całej struktury mięśnia. Przeciętna zmiana długości pojedynczego sarkomeru mieści się w zakresie $1 \mu\text{m}$, zatem im większa jest liczba sarkomerów tworzących włókno mięśniowe (a tym samym większa długość samego włókna), tym większy jest zakres zmian jego długości. Od liczby sarkomerów, również wprost proporcjonalnie, zależy maksymalna szybkość skurczu włókna mięśniowego. W przypadku maksymalnej wartości siły skurczu izometrycznego najważniejszy jest inny parametr, opisujący tym razem architekturę danego mięśnia – powierzchnia jego przekroju. Mięśnie szkieletowe, w zależności od typu włókien i rozkładu, mogą rozwijać siłę skurczu $20\text{--}35 \text{ N}$ na każdy centymetr kwadratowy przekroju poprzecznego [20].

Ruch ciała pojawia się w wyniku skurczu mięśnia lub grupy mięśni. Charakterystyka ruchu zależy zarówno od grupy mięśni współdziałających, jak i mięśni przeciwstawnych. Jednakże oddziałują na nią również opory ruchu spowodowane przez przemieszczanie się kości w stawach, czy opory wywołane obecnością innych tkanek znajdujących się wokół stawu.

W większości przypadków (jak choćby w ruchu zginającym) można rozpatrywać dwa typy aktywności mięśni szkieletowych: aktywne skracanie się mięśni agonistycznych oraz bierne rozciąganie się antagonistów. Parametry ruchu zginającego wynikają więc z różnicy momentów sił mięśni agonistycznych i antagonistycznych działających w danym stawie. Pomimo funkcjonowania


jako element bierny, mięśnie antagonistyczne często poddawane są współpobudzeniu. Zjawisko to, wraz z pracą ekscentryczną danego antagonisty, zapewnia układowi nerwowemu dodatkową kontrolę nad momentami sił w stawach, przyczyniając się także do zmniejszenia wrażliwości na przypadkowe zmiany obciążenia w stawie, bądź w całym łańcuchu kinematycznym. Kontrola nad charakterystyką ruchu, a zwłaszcza jego precyzją, jest ponadto uwidoczniła w pozornej nadmiarowości mięśni. Oprócz głównych mięśni agonistycznych i antagonistycznych, w procesie wykonywania pojedynczego ruchu mogą współuczestniczyć również wielorakie mięśnie synergistyczne. W ten sposób, oprócz głównej funkcji napędowej agonistów, zaobserwować można – dla pozostałych typów mięśni – funkcję tłumiącą, która odnosi się do płynnej regulacji wypadkowej siły napędowej układu poprzez kontrolowane wyhamowanie skurczu napędowego. Dodatkowo, w zależności od rodzaju skurczu pracę mięśni można podzielić na następujące jej rodzaje:

- koncentryczna – kiedy moment siły mięśnia jest większy niż działające nań siły zewnętrzne. Mięsień wówczas skraca się, a jego przyczepy zbliżają się do siebie,
- ekscentryczna – kiedy na mięsień działają siły zewnętrzne przewyższające siły generowane przez ten mięsień. Mięsień w tym trybie wydłuża się, a przyczepy oddalają się od siebie,
- izometryczna – gdy siły zewnętrzne są równe sile wyprodukowanej przez mięsień. Mięsień nie zmienia swej długości, ale jego napięcie wzrasta.

Za wytwarzanie przez mięśnie szkieletowe odpowiednich sił i momentów obrotowych odpowiedzialny jest układ nerwowy (łac. *systema nervosum*). Stąd też, aby w sposób precyzyjny sterować działaniem mięśni w obliczu dużej złożoności ruchów wykonywanych przez układ motoryczny oraz fizycznych ograniczeń w szybkości przekazywania informacji przez układ nerwowy, ciała kręgowców wyposażone są w dwa rodzaje reakcji ruchowych: odruchy i ruchy dowolne. Odruchy pełnią rolę prostych automatyzmów umożliwiających szybką realizację nawet złożonych reakcji ruchowych. Wykonywane są one bez udziału świadomości, w sposób schematyczny, reagując tym samym głównie na bodźce istotne ze względu na bezpieczeństwo ciała. Z kolei ruchy dowolne stanowią przemyślaną część motoryki ciała, wykonywaną z pełną premedytacją w celu realizacji założonych czynności. Są to również ruchy wykonywane w fazie uczenia układu ruchu, zwanej warunkowaniem, prowadzącej do powstania nowych odruchów.


Ze względu na powyższe, sterowanie aktywnością mięśni odbywa się na dwóch poziomach: ośrodkowym (łac. *systema nervosum centrale*) i obwodowym (łac. *systema nervosum periphericum*). Integracja obu rodzajów sterowania następuje w motoneuronach alfa rozmieszczonych w rogach przednich istoty szarej rdzenia kręgowego (rys. 2.2). Ośrodkowy układ nerwowy składa się z mózgowia (łac. *encephalon*) i rdzenia kręgowego (łac. *medulla spinalis*). Obwodowy układ nerwowy jest złożony ze wszystkich pozostałych struktur nerwowych i łączy ośrodkowy układ nerwowy z resztą ciała.

Motoneurony są rozmieszczone na różnych poziomach rdzenia kręgowego, a ich położenie w samym rdzeniu jest zależne od przyporządkowania do sterowania konkretną grupą funkcjonalną mięśni (rys. 2.3). Wypustki aksonalne motoneuronów wraz z korzeniem tylnym rdzenia (przewodzącym sygnały czuciowe) tworzą wspólnie nerw rdzeniowy (łac. *nervus spinalis*), który



Rysunek 2.2. Organizacja sterowania aktywnością mięśni na poziomie rdzenia kręgowego [20]


wydostaje się poza kręgosłup przez obustronne otwory międzykręgowe, by dalej, przez sieć nerwów obwodowych, dotrzeć do poszczególnych włókien mięśniowych. W ciele człowieka występuje 31 par nerwów rdzeniowych – jedna dla każdego segmentu rdzenia. Zespół motoneuronu alfa i unerwianych przez niego włókien mięśniowych określa się mianem jednostki motorycznej (ruchowej).



Rysunek 2.3. Przekrój rdzenia kręgowego z zaznaczonym położeniem motoneuronów alfa kontrolujących aktywność różnych grup funkcjonalnych mięśni [20]


Nerwy obwodowe, dostarczając nerwowy potencjał czynnościowy do złącza nerwowo-mięśniowego, powodują wydzielanie z kolbki synaptycznej aksonu neuroprzekaźnika zwanego acetylocholiną (ACh). ACh wiąże się ze znajdującymi się na błonie postsynaptycznej receptorami nikotynowymi. Skutkiem tej transmisji synaptycznej jest depolaryzacja komórki mięśniowej – przejściowy spadek różnicy potencjałów po obu stronach błony mięśniowej spowodowany wzrostem napięcia wewnątrz komórki. Odpowiedzialna za ten stan jest zmiana koncentracji jonów w płynie komórkowym i pozakomórkowym we włóknach mięśniowych, nazwana mechanizmem pompy sodowo-potasowej. Podczas stanu spoczynkowego wyróżnia się przede wszystkim większą koncentrację jonów sodu i chloru oraz mniejszą koncentrację jonów potasu na zewnątrz włókna.

Wyrzut ACh doprowadza do lokalnej depolaryzacji błony komórki mięśniowej, co w rezultacie otwiera w niej kanały sodowe zależne od napięcia elektrycznego. Następuje gwałtowne wpływanie jonów sodu do wnętrza komórki, powodując dalsze podwyższenie jej potencjału wewnątrzkomórkowego. Po przekroczeniu wartości 20 mV napływ jonów sodu zostaje zahamowany, a rozpoczyna się stopniowy wypływ jonów potasu na zewnątrz. Proces ten przenosi się na obszary sąsiadujące ze złączem nerwowo-mięśniowym. Potencjał czynnościowy włókna mięśniowego powoduje przepływ prądów jonowych pomiędzy zmieniającym się obszarem aktywnym, a sąsiadującymi z nim nieobudzonymi jeszcze obszarami błony komórkowej. Odnośny potencjał czynnościowy przenosi się wzdłuż włókna w obydwu kierunkach. W końcowej fazie jest odzyskiwany pierwotny potencjał spoczynkowy komórki [20]. Opisany proces został zilustrowany na rysunku 2.4.




Rysunek 2.4. Powstanie potencjału czynnościowego w komórce mięśniowej [21]

Mechanizm skurczu mięśnia wyjaśnia w szczególności teoria ślizgowa H. E. Huxley'a [22]. Wskutek pobudzenia zespołu połączonych szeregowo sarkomerów mięsień ulega skróceniu, co jest wynikiem współdziałania białek kurczliwych – wciągania nitki aktyny między włókna miozyny w pojedynczej jednostce (rys. 2.5). W wyniku tego zmniejsza się odległość pomiędzy błonami granicznymi Z, szerokość prążka I oraz szerokość strefy H.



Rysunek 2.5. Zmiana długości sarkomeru podczas skurczu [23]


Wyrzut ACh zainicjowany pojedynczym potencjałem czynnościowym motoneuronu uruchamia wytwarzanie wystarczającej ilości pobudzającego potencjału postsynaptycznego we włóknie mięśniowym, aby wygenerować w nim własny potencjał czynnościowy prowadzący do krótkotrwałego skurczu jednostkowego (w sekwencji skrócenia i relaksacji włókna). Potencjał czynnościowy we włóknie mięśnia szkieletowego trwa od 1 do 2 ms. Skurcz jednostkowy tkanki poprzedza okres utajenia trwający 3–10 ms, po którym następuje właściwa aktywność mechaniczna mięśnia trwająca ok. 100 ms i więcej (rys. 2.6) [23]. Choć skurcz jednostkowy charakteryzuje niewielka siła, to dzięki sumowaniu czasowo-przestrzennemu poszczególnych skurczów w całej jednostce ruchowej, wytwarzana jest odpowiednia siła (często o znacznej wartości).



Rysunek 2.6. Korelacja potencjału czynnościowego i skurczu we włóknie mięśniowym [23]

Z perspektywy funkcjonowania układu nerwowego siła generowana podczas skurczu jest zależna od trzech czynników: liczby włókien mięśniowych przypadających na jednostkę motoryczną, częstotliwości impulsów nerwowych generowanych przez motoneurony alfa oraz liczby aktywnych jednostek ruchowych. Kontrola częstotliwości pobudzenia jednostki motorycznej służy integracji pojedynczych skurczów w ramach działania jednostki. Wraz ze wzrostem częstotliwości pobudzenia motoneuronu alfa skraca się czas pomiędzy kolejnymi skurczami jednostkowymi. Jeżeli okres występowania pobudzeń będzie na tyle krótki, że nie nastąpi w tym czasie pełna

relaksacja jednostki motorycznej, to wystąpi efekt sumowania skurczów. Opisana zależność nie ma charakterystyki liniowej (rys. 2.7), ponieważ powyżej częstotliwości pobudzenia 30 Hz (w przypadku wolnych jednostek ruchowych) siła skurczu osiąga swą maksymalną wartość, co nazywane jest skurczem tężcowym. Stąd też układ nerwowy nie posiada już możliwości kontrolowania w tym zakresie siły skurczu poprzez zmianę częstotliwości wyładowań motoneuronów. Dalsze zwiększenie siły mięśniowej może nastąpić wyłącznie poprzez rekrutację kolejnych jednostek motorycznych. Jest to też ostatni wyznacznik siły skurczu mięśnia. Według zasady sformułowanej przez Hennemana [24, 25] kolejność rekrutacji jednostek zależy od rozmiarów ciała komórkowego motoneuronu alfa. Ponadto występuje pewna gradacja w kolejności pobudzania poszczególnych jednostek motorycznych – małe jednostki unerwiane przez niewielkie neurony są rekrutowane jako pierwsze, a następnie włączane są jednostki coraz większe. W ten sposób następuje stopniowanie siły skurczu zgodnie ze stopniem wielkości pobudzających motoneuronów.




Rysunek 2.7. Siła skurczu mięśnia w zależności od częstotliwości pobudzenia jednostek ruchowych [20]

Istotną częścią kontroli obwodowej narządu ruchu są układy sensoryczne tworzące pętle sprzężenia zwrotnego z odpowiednich receptorów. Ich praca odgrywa szczególnie rolę w trakcie procesów uczenia się reakcji, gdzie informacja czuciowa jest niezbędna dla układu nerwowego w trakcie tworzenia nowych programów ruchowych [20]. Nowy ruch dowolny często jest pozbawiony prawidłowej koordynacji zespołów kinematycznych, uniemożliwiając tym samym wykonywanie go w sposób precyzyjny. Ograniczenie to wynika ze świadomej kontroli wykonywanego ruchu, a więc dotyczy również bariery w szybkości przewodzenia informacji w układzie nerwowym. Po wytworzeniu prawidłowego wzorca aktywności rola układu obwodowego zostaje zredukowana do bieżącej kontroli i ewentualnej korekcji błędów, bez angażowania tzw. najwyższych pięter układu nerwowego.

Układ ruchu człowieka korzysta głównie (pomijając telereceptory, jak wzrok, słuch itp.) z informacji przekazywanych przez cztery rodzaje mechanoreceptorów. Mięśniowy receptor wrzecionowy reaguje na zmianę długości danego mięśnia. Dostarcza on informacji do motoneuronu alfa o pracy pobudzanego mięśnia, jednocześnie mając wpływ na pracę mięśni antagonistycznych i synergistycznych zaangażowanych w wykonywany ruch. Receptory ścięgnowe z kolei wychwytyują bodźce związane z naprężeniem wywołanym skurczem pęczka włókien mięśniowych. Przekazują

te informacje do motoneuronu alfa i do mózdzku. W efekcie ich pracy zostaje wyhamowana aktywność własnego motoneuronu alfa, co nazywane jest odruchem ścięgnistym. Jest to zatem przykład ujemnego sprzężenia zwrotnego – wykorzystywanego powszechnie w technice. Pozostałe dwa mechanoreceptory – stawowe oraz skórne – reagują na, odpowiednio, deformacje struktur stawowych oraz kontakt ciała z obiektami w jego otoczeniu.

Podstawa kontroli aktywności ruchowej znajduje się w układzie ośrodkowym. To w ośrodkach korowych mózgu są realizowane główne procesy decyzyjne związane z podjęciem konkretnej czynności ruchowej, a także wynikającym z tej decyzji wzbudzeniem włókien mięśniowych (rys. 2.8). Jednym z najważniejszych obszarów jest pierwszorzędowa kora ruchowa (M1, pole 4 według podziału Brodmanna), która odpowiada za generowanie skurczy określonych mięśni, a także za różnego rodzaju synergie podczas sterowania ruchem. Sąsiadująca z nią drugorzędowa kora ruchowa (pole 6), a dokładnie obszary kory przedruchowej (PM) i dodatkowej kory ruchowej (SMA), jest zaangażowana w planowanie i koordynację obustronnych ruchów dowolnych, w szczególności ruchów złożonych i skoordynowanych. SMA steruje ponadto aktywnością dalszych mięśni kończyn, zaś PM – mięśni bliższych i osiowych. W ogólnym planowaniu ruchów i działań oraz w rozważaniu ich konsekwencji uczestniczy także kora przedczołowa. Z kolei odbieraniem informacji somatosensorycznych ze wzgórza (a docelowo z jąder nerwów czaszkowych i rdzenia kręgowego) zajmuje się pierwszorzędowa kora czuciowa (S1, pole 3, 1 i 2). Za analizę bodźców odpowiada również kora asocjacyjna ciemieniowa (SAC, pole 5 i 7). Ponadto mózdzek odpowiada za kontrolę sekwencji zdarzeń i wprowadzanie korekty do programu na podstawie informacji zwrotnych z mięśni o skuteczności jego realizacji.



Rysunek 2.8. Umiejscowienie ważniejszych ośrodków korowych biorących udział w kontroli ruchowej (powierzchnia boczna mózgu) [26]

Ruchowe ośrodki mózgowo łączą się z rdzeniem kręgowym poprzez wyspecjalizowane drogi. Wyróżnia się trzy takie drogi: korowo-rdzeniowe, przedsionkowo-rdzeniowe oraz siatkowo-rdzeniowe. Istotnym szczegółem anatomicznym jest sposób zstępowania włókien w przypadku drogi korowo-rdzeniowej. Włókna te, zstępując z obu półkul mózgowych, przechodzą na przeciwną stronę w skrzyżowaniu piramid na poziomie rdzenia przedłużonego, co wyjaśnia krzyżową kontrolę mięśni obu stron ciała przez przeciwległe półkule [27].

2.1.2. Pomiar i analiza sygnałów mioelektrycznych

Elektromiografia (EMG), czyli badanie aktywności bioelektrycznej mięśni, dostarcza informacji o aktywności nerwowej i generowanych dzięki niej wzorcach koordynacji mięśni. Badania nad tym zagadnieniem rozpoczęto pod koniec XVIII wieku, jednak dopiero w 1890 roku Etienne Marey jako pierwszy dokonał zapisu EMG. Badania prowadzone w XX wieku dostarczyły dogłębnej wiedzy na temat jej źródła pochodzenia oraz metod analizy.

Pobudzenie włókien mięśniowych przez potencjały docierające z układu nerwowego bada się za pomocą odpowiednich urządzeń wyposażonych w dedykowane do tego celu sondy. Najbardziej dokładnych wyników dostarczają badania wykorzystujące sondy inwazyjne – mikroelektrody wkłuwane do wnętrza komórki mięśniowej, bądź zewnątrzkomórkowe elektrody igłowe. W przypadku badań biomechanicznych w dużej mierze stosuje się jednak elektrody powierzchniowe będące nieinwazyjnym odpowiednikiem powyższych.

Podczas generowania potencjałów czynnościowych we włóknach mięśniowych można zaobserwować również przepływ prądów w otaczającej mięsień tkance. Fakt ten jest wykorzystywany przez EMG powierzchniową, w której za pomocą elektrod przytwierdzanych bezpośrednio do skóry rejestruje się prądy przez nią przepływające. W zależności od odległości źródła sygnału od elektrody, wartość szczytowa aktywności bioelektrycznej mięśnia wynosi 0,01–5 mV.


EMG powierzchniowa wykorzystuje dwie konfiguracje elektrod do wykonywania rejestracji. W rejestracji jednobiegunowej aktywna elektroda zostaje przytwierdzona nad powierzchnią mięśnia, zaś druga – referencyjna – jest umieszczana w miejscu elektrycznie nieaktywnym, tj. z dala od mięśni i nerwów (np. nad kością lub ścięgnem). Konfiguracja ta jest bardzo czuła, ale jednocześnie bardziej podatna na zakłócenia. W konfiguracji dwubiegunowej (różnicowej) dwie aktywne elektrody umieszcza się obok siebie na skórze w pobliżu badanego mięśnia (rys. 2.9). Każda z elektrod jest podłączona do innego wejścia wzmacniacza – jedna do wejścia nieodwracającego, zaś druga do wejścia odwracającego. Na wyjściu wzmacniacza pojawia się więc napięcie różnicowe równe

$$U_{wy} = k(U_+ - U_-), \quad (2.1)$$

gdzie: k – wzmocnienie napięciowe wzmacniacza, U_+ i U_- – sygnały na wejściach nieodwracającym i odwracającym.

Rejestrowane przez elektrody dwubiegunowe sygnały mioelektryczne stanowią przekształcony sygnał aktywności jednostek motorycznych. Ten sam sygnał pojawiający się kolejno pod elektrodą dodatnią i ujemną wywołuje na wyjściu wzmacniacza aparatu EMG najpierw sygnał o polaryzacji dodatniej, a następnie ujemnej, docierając do każdej z elektrod w różnym czasie.


Ponadto, w celu zmniejszenia zakłóceń podczas rejestracji powierzchniowej stosuje się dodatkową elektrodę, zwaną elektrodą uziemiającą. W związku z możliwością indukowania w ciele ludzkim pasożytniczych sygnałów zakłócających (np. o częstotliwości sieci elektrycznej), elektrodę uziemiającą łączy się z masą rejestratora, co powoduje znaczną redukcję tych sygnałów. Elektrodę umieszcza się zwykle w miejscu elektrycznie nieaktywnym.



Rysunek 2.9. Rejestracja potencjałów czynnościowych mięśni przez elektrody dwubiegunowe [20]


Pomimo oczywistych zalet **EMG** powierzchniowej związanych z łatwością przeprowadzania jej rejestracji, badanie to posiada pewne ograniczenia. Pozwala ono rejestrować jedynie aktywność bioelektryczną mięśni położonych blisko pod powierzchnią skóry. Ponadto sygnał elektryczny docierający do powierzchni skóry różni się od potencjałów generowanych w mięśniu. Silny wpływ na ten efekt mają zarówno właściwości bioelektryczne tkanki pomiędzy mięśniem a elektrodą, jak i rozmiar oraz konfiguracja elektrod rejestrujących. Zbierane powierzchniowo sygnały **EMG** nie odzwierciedlają zatem pełnej aktywności elektrycznej mięśnia, a całkowite świadome rozluźnienie (wyłączenie aktywności mięśnia) jest z reguły niemożliwe.

Zazwyczaj sygnał **EMG** rejestrowany za pomocą elektrod powierzchniowych posiada widmo częstotliwości w zakresie 10–400 Hz (rys. 2.10). Należy jednak podkreślić, że widmo mocy sygnału silnie zależy od rozmiarów i konfiguracji elektrod rejestrujących.



Rysunek 2.10. Widmo sygnału **EMG** rejestrowanego elektrodą powierzchniową [20]

Istotnym czynnikiem wpływającym na postać widma sygnału EMG jest efekt zmęczenia mięśni. Objawia się on zmniejszeniem siły mięśnia przy jednoczesnym wzroście jego aktywności bioelektrycznej. Efektem tego jest przesunięcie w dół częstotliwości środkowej widma mocy sygnałów EMG (rys. 2.11).



Rysunek 2.11. Zmiana częstotliwości medialnej widma sygnału EMG w wyniku zmęczenia mięśnia [20]

Zmęczenie mięśnia wpływa bezpośrednio na wzrost mocy sygnałów niskich częstotliwości z 17% do 60% oraz na zmniejszenie częstotliwości medialnej EMG z około 40 Hz do około 30 Hz [20]. Oprócz zmęczenia samej tkanki, na zmiany rozkładu widma mocy wpływają także takie czynniki, jak:

- zmiana ciśnienia wewnętrznego w mięśniu,
- dysfunkcja wrzecion mięśniowych,
- kształt potencjału jednostki ruchowej,
- zmiana szybkości przewodzenia potencjałów czynnościowych we włóknach mięśniowych,
- synchronizacja pobudzenia jednostek ruchowych,
- liczba rekrutowanych jednostek ruchowych,
- konfiguracja elektrod pomiarowych.

2.2. Paralysis cerebialis infantium

Mózgowe porażenie dziecięce (łac. *paralysis cerebialis infantium*, PCI) jest zaburzeniem ruchu i postawy spowodowanym uszkodzeniem mózgu w okresie prenatalnym, w trakcie porodu lub w czasie pierwszych kilku lat życia dziecka. Uszkodzenie te upośledza zdolność nerwowego systemu ośrodkowego do prawidłowej kontroli mięśni szkieletowych. W związku z tym niemowlęta cierpiące na PCI mają trudności w opanowaniu podstawowych umiejętności ruchowych, takich jak czworakowanie, siadanie czy chodzenie, a skutki porażenia utrzymują się z reguły przez całe życie. Zaburzenie to jest więc klasyfikowane jako niepełnosprawność rozwojowa. Występując w przypadku około 2,1 na 1 000 urodzeń [28], PCI jest najbardziej powszechnym zaburzeniem ruchowym wśród dzieci [29].

Wyróżnia się dwa podziały systematyczne dla PCI [30, 31]. Jego klasyfikacja w zależności od porażonych mięśni jest następująca:


- kwadriplegia – porażenie dotyka wszystkich mięśni dziecka. Mięśnie tułowia, kończyn górnych i dolnych, a często nawet mięśnie twarzy, nie funkcjonują prawidłowo. Oprócz problemów w motoryce dużej i małej, występować mogą problemy z jedzeniem i mówieniem. W przypadku kwadriplegii poważnego stopnia dziecko ma trudności ze wszystkimi czynnościami życia codziennego,
- diplegia – porażone są przede wszystkim nogi, zatem upośledzenie w dużym stopniu dotyka umiejętności stania i chodzenia. Z powodu napięcia spastycznego w kończynach dolnych, osoby dotknięte tym rodzajem PCI mają tendencję do stania na palcach, rotowania nóg do wewnątrz i łączenia kolan. Część osób osiąga w pewnym stopniu samodzielność w poruszaniu się, jednakże poważna diplegia skazuje chorego na poruszanie się z pomocą balkonika lub nawet wózka,
- hemiplegia – porażenie dotyczy tylko jednej strony ciała, przy czym ręka najczęściej dotknięta jest silniej niż noga. Z powodu osłabienia mięśni, złej koordynacji i spastyczności dotkniętej nogi, największy problem sprawia nauka chodzenia. Często dzieci z hemiplegią są w stanie nauczyć się kompensować jednostronne upośledzenie drugą, nieporażoną stroną.

Z kolei klasyfikacja w zależności od lokalizacji uszkodzenia mózgu przedstawia się następująco:

- postać piramidowa (spastyczna) – charakteryzuje się występowaniem nadmiernego napięcia mięśniowego, co ogranicza zakres ruchów. Pojawiają się ruchy mimowolne wywołane przez nieprawidłowe odruchy. Dotyka około 80% dzieci z PCI (rys. 2.12),
- postać pozapiramidowa – charakteryzuje się obniżeniem napięcia mięśniowego, co powoduje znaczne osłabienie mięśni i trudność z ich kontrolowaniem. Mogą występować następujące rodzaje ruchów mimowolnych: atetoz (powolne, wijące ruchy), ataksja (niepewne, charakteryzujące się drżeniem i brakiem koordynacji ruchy), dystonia (powolne, rytmiczne, skręcające ruchy) oraz choreoatetoz (nagłe, urywane, szybkie ruchy). Występuje u około 10% dzieci z PCI (rys. 2.13),
- postać mieszana – cechuje się występowaniem zarówno napięcia spastycznego, jak i ruchów mimowolnych charakterystycznych dla postaci pozapiramidowej. Postać tą identyfikuje się u około 10% dzieci z PCI.

Spastyczność jest statycznym wzmożeniem napięcia mięśniowego. Długotrwanie nieleczone powoduje szereg zmian biomechanicznych, spośród których zahamowanie wzrostu mięśni należy do najpoważniejszych. Wyróżnić można określoną grupę najczęstszych wzorców ruchowych spastyczności wraz z udziałem mięśni aktywnych [32]:

- przywiedzenie i rotację wewnętrzną w stawie ramiennym (m. piersiowy większy, najszerszy grzbietu, obły większy, podłopatkowy),
- zgięcie w stawie łokciowym (m. ramiennie-promieniowy, dwugłowy ramienia, ramienny),



Rysunek 2.12. Dziecko z czterokończynowym porażeniem spastycznym [30]



Rysunek 2.13. Dziecko z atetotycznym porażeniem czterokończynowym [30]

- pronację przedramienia (m. nawrotny czworoboczny, nawrotny obły),
- zgięcie nadgarstka (m. zginacz nadgarstka promieniowy, zginacz nadgarstka łokciowy, zginacze palców),
- zgięcie palców z wyjątkiem stawów międzypaliczkowych dalszych (m. zginacz palców powierzchniowy, zginacz palców głęboki),
- zgięcie i przywiedzenie kciuka (m. przywodziciel kciuka, zginacz długi kciuka, mięśnie kłębku),
- zgięcie w stawie biodrowym (m. biodrowo-łędźwiowy, łędźwiowy, prosty uda),
- zgięcie kolana (m. półbłoniasty, półścięgnisty, dwubrzuścowy łydki),
- przywiedzenie uda (m. przywodziciele uda, smukły),
- wyprost kolana (m. czworogłowy uda),
- stopę końsko-szpotawa (m. brzuchaty łydki, płaszczkowaty, piszczelowy tylny i przedni, zginacze palców),
- wyprostowany paluch (m. prostownik długi palucha).

U części dzieci z **PCI** niepełnosprawność wykracza poza ramy odnośnego zaburzenia. Wy różnia się takie objawy współistniejące, jak: upośledzenie umysłowe, padaczka, utrata wzroku lub słuchu. W takich przypadkach dziecko, prócz rehabilitanta, potrzebuje wsparcia specjalistów z różnych dziedzin medycyny.

Aby usystematyzować objawy występujące u dzieci chorych na **PCI** oraz wspomóc w prognozie ich postępów, opracowano testy mierzące umiejętności w zakresie motoryki dużej [33]. Skala



motoryki dużej (Gross Motor Function Measure) mierzy aktualne umiejętności ruchowe dziecka i pozwala na okresową ocenę jego postępów. Na podstawie sporządzonej skali trudności możliwy jest dobór zadań i ćwiczeń, których może podjąć się rehabilitowane dziecko. System klasyfikacji funkcji motoryki dużej dla dzieci z mózgowym porażeniem dziecięcym (Gross Motor Function Classification System for Cerebral Palsy) z kolei przyporządkowuje dzieci do jednego z pięciu poziomów i opisuje jakie ogólne postępy w zakresie motoryki dużej osiągają.

Według powyższego systemu klasyfikacji, dzieci z **PCI** osiągają największy postęp w funkcjach motorycznych w okresie od urodzenia do 3–4 roku życia. Maksimum tych możliwości jest zwykle osiągnięte w wieku około 7 lat. Dzieci klasyfikowane na poziomie IV i V mają tendencję do osiągnięcia swojego potencjału wcześniej niż dzieci na niższych poziomach. Nadzwyczaj ważne jest zatem rozpoczęcie intensywnych czynności rehabilitacyjnych jak najwcześniej, licząc od okresu noworodkowego, po okres niemowlęcy, poniemowlęcy, aż do okresu wczesnodziecięcego. Stanowi to warunek konieczny wypracowania prawidłowych odruchów oraz wystarczającej siły mięśni, aby umożliwić poprawne funkcjonowanie w dalszych okresach życia.

Niemożliwe jest wyleczenie dziecka z **PCI**. Istnieją jednak leki i procedury chirurgiczne, które mogą zredukować spastyczność, zwiększyć długość mięśni i wyeliminować przykurcze w obrębie stawów. Środki te znacznie ułatwiają dziecku osiągnięcie umiejętności z zakresu motoryki dużej, aczkolwiek nie mogą zastąpić rehabilitacji ortopedycznej i neurofizjologicznej. Spośród interwencji medycznych najczęściej stosuje się następujące: leki doustne zmniejszające napięcie mięśniowe (np. baklofen, dantrolen, valium), dooponowa pompa baklofenowa, zastrzyki z toksyny botulinowej, selektywna tylna rizotomia, elektrostymulacja nerwowo-mięśniowa.


Biorąc pod uwagę powyższe, prawidłowa rehabilitacja dzieci chorych na **PCI** powinna spełniać szereg założeń [30]. Przede wszystkim należy stosować odpowiednie techniki dotyczące pobudzania umiejętności uspionych, intensyfikacji korygowania nieprawidłowości i zwiększania aktywności ruchowej. Podstawą terapii motorycznej jest więc nauczanie dziecka prawidłowych wzorców ruchowych. Nie można jednak zapominać o technikach integrujących czynności motoryczne z komunikowaniem się, percepcją, a także z rozumieniem kontekstu czynności codziennych.

Istotnym procesem związanym z leczeniem **PCI** – zarówno przed rozpoczęciem, jak i w trakcie – jest rozpoznanie oraz monitorowanie ich stanu psychofizycznego. **PCI** skutkuje bardzo szerokim zakresem stopni niedorozwoju motorycznego, a opisane w literaturze postępowanie terapeutyczne dotyczy ściśle określonych deficytów ruchowych. Na osobie rehabilitanta spoczywa więc odpowiedzialność dokonania prawidłowej oceny stopnia rozwoju psychofizycznego i doboru technik rehabilitacyjnych w zależności od wieku, rodzaju i nasilenia odruchów patologicznych oraz występowania objawów współistniejących.

2.3. *Osteogenesis imperfecta*

Wrodzona łamliwość kości (łac. *osteogenesis imperfecta*, OI) jest grupą zaburzeń dziedzicznych związanych przeważnie z anomalią kolagenu [34]. Kolagen jest jednym z głównych składników macierzy zewnątrzkomórkowej kości, skóry, ścięgien i ścian naczyń krwionośnych. Kolagen

typu I stanowi około 97% składu kolagenu tworzącego kości, z pozostałymi 3% składającymi się głównie z kolagenu typu V [35]. W wyniku odnośnych nieprawidłowości u osób dotkniętych **OI** wytrzymałość tkanki łącznej ulega drastycznemu osłabieniu (rys. 2.14). Częstość występowania **OI** ocenia się na 6–7 na 100 000 mieszkańców Ziemi [36], co czyni to zaburzenie jedną z dwóch najczęściej diagnozowanych dysplazji szkieletowych, będąc w ogólnej klasyfikacji jednak chorobą rzadką.




Rysunek 2.14. Różnice w budowie kości zdrowej i kruchej [36]

Uporczywość fenotypu **OI** jest niezwykle różnorodna – zawiera się w nim szerokie spektrum upośledzenia struktury i występowania zniekształceń układu kostnego. Od łagodnych nieprawidłowości w budowie kośćca w przypadku **OI** typu I, przez rozległe deformacje ciała występujące dla **OI** typu III (rys. 2.15), aż po przypadki śmiertelne będące następstwem poważnych złamań w okresie okołoporodowym (typ II). Na rysunku 2.15 można również dostrzec dodatkowe objawy spowodowane wadliwym rozwojem tkanki kostnej, jak skolioza (na większości przykładów) lub rozdrobnienie płytek nasadowych (oznaczone strzałkami). Strzałki w kształcie trójkątów wskazują ponadto na zastosowanie jednej z metod leczenia operacyjnego skutków złamań i wzmocnienia kości – prętów ortopedycznych.

W chwili obecnej wyróżnia się 19 typów zaburzenia zależnych od występujących cech klinicznych, histologii kości, wzorców dziedziczenia i przyczyn genetycznych [38]. Początkowo brano pod uwagę tylko cztery spośród nich (I–IV), związane z mutacjami punktowymi w łańcuchach DNA sekwencji genów *COL1A1* i *COL1A2*, kodujących łańcuchy polipeptydowe $\alpha 1(I)$ i $\alpha 2(I)$ kolagenu typu I [39]. Dopiero badania przeprowadzone w ciągu ostatnich kilkunastu lat ujawniły więcej typów **OI**, niekoniecznie związanych ze strukturalnymi bądź ilościowymi mutacjami kolagenu typu I.

Wyżej wspomniane pierwsze cztery typy **OI**, związane z mutacjami genów *COL1A1* i *COL1A2*, dziedziczone są w sposób autosomalny dominujący. Efektem tych typów zaburzenia są defekty w syntezie i strukturze kolagenu, diagnozowane aktualnie u 80%–90% przypadków ludzi chorych na **OI** [34, 38, 40]. Typ I, będący najczęściej występującym, wiąże się głównie ze zwiększonym ryzykiem złamań kości i zazwyczaj nie oznacza deformacji ciała. **OI** typu II odznacza się wysoką śmiertelnością w okresie okołoporodowym z powodu występowania poważnych złamań i deformacji. Pacjenci z typem III niekiedy przeżywają złamania podczas okresu niemowlęctwa



Rysunek 2.15. Zdjęcia rentgenowskie osób dorosłych chorych na wybrane typy **OI** [37]

i dzieciństwa, jednak charakteryzują się postępującymi, poważnymi deformacjami ciała, które z czasem coraz bardziej utrudniają funkcjonowanie. Typ **IV OI** jest postacią umiarkowaną tego schorzenia, będąc formą pośrednią pomiędzy typem **I** a **III**. Ponadto, u części osób z tej grupy typów można zaobserwować niebieskie bądź szare zabarwienie twardówek oczu, a nawet utratę słuchu oraz *dentinogenesis imperfecta*, czyli uwarunkowane genetycznie zaburzenie rozwoju zębów przejawiające się przebarwieniami i miękkością tej tkanki.

Pozostałe, znacznie rzadsze, typy **OI** są powiązane z mutacjami innych genów, skutkującymi odmiennymi defektami tkanki łącznej [34, 38]: wadami w procesie mineralizacji kości (typ **V** i **VI**), wadami modyfikacji kolagenu (typy **VII–IX**), defektami w przetwarzaniu i krzyżowym sieciowaniu (Cross-Linking) kolagenu (typy **X–XII** oraz jeden niesklasyfikowany typ związany z mutacją genu *PLOD2*) oraz wadami w różnicowaniu i funkcjonowaniu osteoblastów (typy **XIII–XVIII**). Większość odnośnych typów **OI** jest dziedziczona w sposób autosomalny recesywny, poza typami **V**, **XV** i **XVIII**, które odznaczają się dziedziczeniem, odpowiednio, autosomalnym dominującym, częściowo autosomalnym recesywnym i recesywnym sprzężonym z płcią. Skutki tych defektów są także zróżnicowane i obejmują od zmian łagodnych, aż po silne (dla większości) zniekształcenia kości oraz rizoamię, tj. skrócenie proksymalnych części kończyn. Niektóre przypadki (typ **VII**, **IX**, **X**, **XI** i **XIV**) skutkują niebieskim lub szarym zabarwieniem twardówek oczu.

Należy ponadto nadmienić, iż w poważnych formach **OI** występować mogą nawet nieprawidłowości w funkcjonowaniu płuc i serca, a życie niektórych osób z tym schorzeniem jest związane dodatkowo z ciągłym i silnym bólem.

OI jest nieuleczalna. Stąd też jedynie poprzez prowadzenie zdrowego trybu życia, a zwłaszcza częste ćwiczenia fizyczne, można utrzymać ciało w możliwie poprawnej kondycji. Leczenie sprowadza się głównie do leczenia objawowego i obejmuje doraźną pomoc w przypadkach złamań kości czy terapię przeciwbólową. Osoby z **OI** muszą nierzadko korzystać z pomocy urządzeń ortopedycznych, jak np. wózków, ortez, kul lub aparatów na zęby. Stosuje się również chirurg-

giczne wszczepianie w kości długich, metalowych prętów ortopedycznych w celu wzmocnienia tkanki i zapobiegania jej dalszym zniekształceniom. Jediną formą leczenia farmakologicznego jest podawanie bifosfonianów – preparatów używanych w leczeniu osteoporozy [34, 41].

W odróżnieniu od PCI, OI nie skutkuje bezpośrednio zaburzeniem pracy składnika czynnego układu ruchu człowieka. Jednakże brak regularnej rehabilitacji ortopedycznej pociąga za sobą konsekwencje w równym stopniu poważne, jak w przypadku PCI, z zahamowaniem wzrostu mięśni włącznie. Dlatego osoby chore na OI są szczególnie zachęcane do regularnych ćwiczeń fizycznych wspierających budowę siły mięśni i kości. Znakomitą aktywnością w tym przypadku jest pływanie i terapie wodne, ponieważ ruch w wodzie jest obarczony bardzo niewielkim ryzykiem złamań.

Kwestia bezpieczeństwa w trakcie rehabilitacji jest kluczowa. Oprócz różnego stopnia deformacji ciała, co wymaga używania odpowiednio dostosowanych elementów przyrządów rehabilitacyjnych, kruchość kości powoduje, że przyłożenie nawet niewielkiej siły może wywołać groźny uraz u osoby ćwiczącej. Kontrola sił oddziałujących na ciało ma zatem istotne znaczenie i powinna być zawsze brana pod uwagę podczas planowania procesu rehabilitacji, a przede wszystkim podczas projektowania urządzeń lub systemów ją wspomagających.

Rozdział 3

Przegląd wybranych metod i systemów rehabilitacyjnych

3.1. Podstawowe ćwiczenia i akcesoria rehabilitacyjne

Nadrzędnym celem rehabilitacji dzieci z zaburzeniami działania układu ruchu jest usprawnienie tzw. motoryki dużej. Motoryka jest pojęciem określającym stopień rozwoju ruchowego dziecka, a dzieli się na dwa typy: motorykę dużą i małą. Motoryka duża obejmuje obszerne ruchy, w które zaangażowane jest całe ciało lub jego znaczna część, np. nogi bądź ręce. Jest to codzienna aktywność ruchowa dziecka, która w efekcie rozwija koordynację ruchową i koncentrację uwagi. Przykładami czynności zawierającymi się w tym zakresie są np.: chodzenie, skakanie, jazda na rowerze, czy rzucanie piłką. Motoryka mała odnosi się natomiast do ruchów palców i dłoni, tj. ruchów o mniejszym zakresie, ale większych wymaganiach w sferze skupienia i koncentracji uwagi. Odpowiada ona czynnościom manualnym takim, jak: pisanie, rysowanie, czy rzeźbienie.

Koncentrowanie się na poprawie motoryki dużej nie jest bez znaczenia, ponieważ aktywność ta jest nadrzędna względem motoryki małej. Rozwój aktywności ruchowej bezpośrednio wpływa na rozwój koordynacji ruchowej oraz koncentracji uwagi, co umożliwi wykonywanie coraz bardziej złożonych czynności manualnych. W efekcie, im większa sprawność w zakresie motoryki dużej, tym większe stają się możliwości motoryki małej u dziecka.

Podstawą wszelkiej rehabilitacji ortopedycznej są ćwiczenia rozciągające. Regularny ruch mięśni zapobiega ich skracaniu się i utrzymuje stawy w należytej kondycji. Podczas prawidłowego rozwoju dziecka, wskutek wzrostu kości na długość oraz aktywności ruchowej, mięśnie są rozciągane, co stymuluje je do wzrostu. Dzieci z **PCI** mogą nie być w stanie samodzielnie kontrolować np. wyprostów lub zgięć w stawie z powodu spastyczności mięśni antagonistycznych, braku wystarczającej siły, czy występowania nieprawidłowych odruchów. W przypadku **OI** również można mówić o utrudnieniach w realizacji wymaganej aktywności ruchowej – wiele prostych aktywności, w które angażują się dzieci, jak np. jazda na rowerze, jest obciążonych wysokim ryzykiem uszkodzenia kości, co definitywnie zmniejsza spektrum możliwości rozwoju ruchowego.



Następstwem braku wymaganego ruchu jest więc skrócenie mięśni, a także patologiczny rozwój więzadeł. Te zaś prowadzą do powstawania przykurczów stawowych (braku ruchu w stawie w pełnym zakresie) oraz podwichnięć lub zwichnięć stawów, czyli częściowego lub całkowitego wysunięcia kości z panewki stawu. Utrzymywanie przez dłuższy czas tych stanów powoduje nieodwracalne zmiany w strukturze kości [31]. Należy zatem raz jeszcze podkreślić słowa zawarte w rozdziałach 2.2 i 2.3, iż rozpoczęcie jak najwcześniejszej regularnej i intensywnej rehabilitacji dzieci z zaburzeniami układu ruchu jest warunkiem koniecznym do zapewnienia im dogodnego życia w ich przyszłości. Ćwiczenia rozciągające stanowią jeden z najważniejszych czynników w tym procesie.


Ponadto, zwiększone napięcie mięśniowe, obserwowane u osób z PCI, jest zaburzeniem, które nie sposób wyleczyć za pomocą ćwiczeń fizycznych. Dlatego należy przeciwdziałać jego skutkom poprzez regularne rozciąganie mięśni spastycznych oraz ćwiczenia wzmacniające siłę mięśni antagonistycznych do tych obciążonych spastycznością.

Nawet w przypadku ćwiczeń rozciągających konieczna jest konsultacja z terapeutą, ponieważ niezwykle ważne jest stosowanie się do specjalnych zaleceń i przestrzeganie środków ostrożności we wspomaganie rehabilitacji dzieci chorych na PCI bądź OI. Ćwiczeniom rozciągającym towarzyszy szereg wymagań dotyczących techniki ich wykonywania. Stawy muszą być ustabilizowane oraz należy wykonywać tylko jeden rodzaj ruchu dla stawu, tj. w przypadku prostowania lub zginania nie można dopuścić do skrętu lub rotacji w danym stawie. Ponadto, ćwiczenia muszą być wykonywane powoli, a dziecko powinno być w odpowiedniej pozycji, aby zminimalizować występowanie nieprawidłowych odruchów podczas ćwiczenia. Ważne jest również wycucie granic wykonywania ruchu, ponieważ zwiększanie elastyczności mięśni ponad ich możliwości jest niekorzystne [31].

Rysunki 3.1 i 3.2 przedstawiają przykłady podstawowych ćwiczeń rozciągających dla kończyn górnych i dolnych. W obu przypadkach można zaobserwować stosowanie się do wyżej wymienionych zaleceń. Podczas rozciągania mięśni ramienia ważne jest usztywnienie barku i górnej części ramienia, podczas gdy drugą ręką, trzymając nią dłoń i nadgarstek, należy delikatnie oraz precyzyjnie prowadzić całe ramię. Przy rozciąganiu mięśni łydki szczególną uwagę należy poświęcić pozycji stopy oraz uda.



Rysunek 3.1. Rozciąganie mięśni ramienia w siadzie [31]



Rysunek 3.2. Rozciąganie mięśni łydki [31]

U dzieci mających formę spastyczną kwadriplegii bądź hemiplegii występuje silne zgięcie w stawie łokciowym będące wynikiem aktywności mięśnia ramiennie-promieniowego, dwugłowego ramienia i ramiennego. Szczególnie istotne jest zatem wzmacnianie prostownika stawu łokciowego – mięśnia trójgłowego ramienia – aby mógł być przeciwwagą dla powyższych. Przykładem takiej stymulacji prostowania łokcia jest ćwiczenie bark-łokieć-dłoń (rys. 3.3). Jest to jedno z ćwiczeń, które powinno być wykonywane przy okazji wszelkich czynności z dzieckiem już we wczesnym okresie niemowlęctwa.




Rysunek 3.3. Ćwiczenie bark-łokieć-dłoń wykonywane w wysokim podporze [31]


Dzieci, u których w naturalnym toku rozwoju nie wykształciła się prawidłowa motoryka mogą mieć problemy z samodzielnym siadem, co w następstwie może doprowadzić do zaburzenia procesu nauki chodu. Zdrowe niemowlęta opanowują samodzielny siad pomiędzy 6 a 8 miesiącem życia; dzieci z PCI, w wyniku odpowiedniej rehabilitacji, mogą potrzebować do dwóch lat, aby przyswoić tą czynność [31]. W tym przypadku niezbędne jest wdrożenie ćwiczeń wzmacniających siłę i koordynację mięśni pleców, miednicy i brzucha.

Przykładem dla odnośnych ćwiczeń jest przejście z podłogi do siadu na ławce (rys. 3.4). Analogicznym zadaniem jest przejście z podłogi do siadu na wózku (jeśli dziecko na co dzień go używa), a także ćwiczenia odwrotne do nich. Wykorzystanie przedmiotów używanych regularnie we wspomaganym ćwiczeniu czynności codziennych, z którymi dana osoba ma trudności, jest nieodłączną częścią procesu powrotu do sprawności i nazywane jest rehabilitacją zadaniową. Ten rodzaj ćwiczeń przynosi duże korzyści zarówno dla osób z PCI [42], jak i osób po udarze [43].

Powyższą ideę można zastosować w późniejszych etapach rehabilitacji dla dzieci, które potrafią już stać z pomocą opiekuna lub balkonika. Stołek oraz poręcz dostosowana do wzrostu dziecka mogą posłużyć jako sprzęt do codziennego wzmacniania mięśni odpowiedzialnych za stanie (rys. 3.5).




Rysunek 3.4. Przejście z podłogi do siadu na ławce [31]



Rysunek 3.5. Stanie trzymając się dwiema rękami [31]


Dalsza stymulacja ruchów nóg jest niezbędna do usamodzielnienia się dzieci. U dzieci z PCI często osłabione są zginacze biodra, dlatego ważne są dla nich ćwiczenia, w których mogą naturalnie dźwigać nogi przeciw sile grawitacji. Ćwiczenia takie można urozmaicić używając dodatkowych akcesoriów (rys. 3.6). Zaletą takiego rozwiązania jest zdecydowanie mniejsze zaangażowanie rehabilitanta, co pozwala na prowadzenie procesu rehabilitacji grupy dzieci. Gwarantuje więc oszczędność zarówno czasu, jak i pieniędzy.



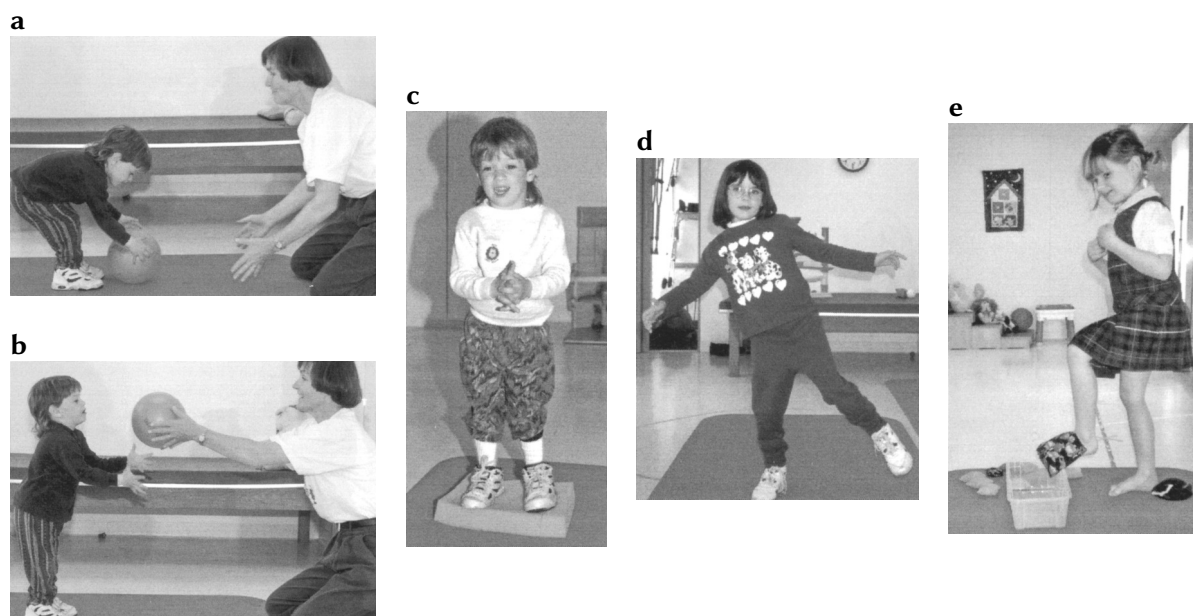
Rysunek 3.6. Przykłady ćwiczeń kończyn dolnych z wykorzystaniem prostych akcesoriów: **a)** kopanie balonu jedną nogą; **b)** podnoszenie piłki; **c)** przekładanie stopy przez kółko; **d)** jazda na deskorolce [31]

Zaburzona zdolność do dostosowywania pracy mięśni do zmieniających się warunków, występowanie nieprawidłowych odruchów, czy brak zdolności mózgu do przetwarzania informacji o położeniu ciała są powodami zakłócenia zmysłu równowagi. W przypadku dzieci zdrowych, trening reakcji równoważnych następuje naturalnie w toku rozwoju ruchowego, choć dopiero trening specjalistyczny (jak np. gimnastyka) zapewnia wysoki poziom tego zmysłu.

Trening reakcji równoważnych jest zatem naturalnym krokiem we wspomaganie nauki chodzenia, zwłaszcza dla dzieci z PCI, w przypadku których skutkuje on znaczną poprawą równowagi podczas stania [44]. Równowagę można ćwiczyć zarówno w siadzie (rys. 3.7), jak i stojąc (rys. 3.8), używając do tego przeróżnych akcesoriów.



Rysunek 3.7. Ćwiczenie równowagi w siadzie: a) zabawa z piłką; b) podrzucanie woreczkiem z fasolą [31]



Rysunek 3.8. Ćwiczenie koordynacji stojąc: a–b) gra w piłkę; c) stanie na gąbce; d) stanie na jednej nodze; e) gra woreczkiem z grochem jedną nogą [31]


Dodatkowym aspektem podkreślanym w literaturze, o którym należy wspomnieć, jest ciągła komunikacja z dzieckiem. Odciągnięcie umysłu dziecka od żmudności ćwiczeń, poczucie celu oraz gratyfikacja (choćby słowna) są kluczowymi częściami procesu rehabilitacji [31]. Integracja z grą komputerową wydaje się być zatem naturalnym rozwinięciem dla systemów rehabilitacyjnych.

W takim przypadku rolą rehabilitanta jest wybór zestawu ćwiczeń i monitorowanie ich przebiegu podczas korzystania osoby ćwiczącej z systemu.

3.2. Urządzenia wspomagające rehabilitację

Oprócz prostych akcesoriów, które używa się podczas różnorodnych ćwiczeń, rehabilitacja obejmuje również wykorzystanie pewnej liczby urządzeń i innych przedmiotów zbudowanych dla konkretnych celów. Rotor, stepper, czy zwykły rower treningowy są powszechnie stosowane podczas ćwiczeń, jednakże – ze względu na konieczność wykonywania złożonych ruchów kończyn i potrzebę odpowiedniej siły mięśniowej – tylko w przypadku dzieci, które wykształciły już zaawansowane funkcje motoryczne.


Jednym z najczęściej używanych urządzeń jest pionizator przedni (rys. 3.9a). Jego funkcją nie jest jedynie usztywnienie ciała dziecka w dogodnej pozycji, a głównie wymuszenie ćwiczeń mięśni szyi i górnej części pleców poprzez stymulowanie umiejętności utrzymywania głowy. Przechylenie pionizatora lekko do przodu przy jednoczesnym podaniu dziecku książki bądź wyświetleniu filmu umożliwia wykonywanie odnośnych ćwiczeń, odciągając uwagę dziecka od tej czynności. Innym rodzajem pionizatora jest stół pionizacyjny (rys. 3.9b), którego zadaniem jest pomoc w ponownym zaadaptowaniu się układu krążeniowo-oddechowego do pozycji pionowej, co w rezultacie ma przyczynić się do reedukacji chodu.



Rysunek 3.9. Pionizatory: a) pionizator przedni [31]; b) stół pionizacyjny [45]


Starsze dziecko, które opanowuje umiejętność wstawania powinno zostać jak najszybciej poddane dalszej terapii przygotowującej je do samodzielnego poruszania się. Na tym etapie powszechnie wykorzystuje się sprzęt ułatwiający chodzenie, czyli różnego rodzaju balkoniki. Balkoniki przednie (rys. 3.10a) są ich najmniej złożonym rodzajem. Poprzez zwykłe pionowe lub poziome rączki zapewniają użytkownikowi prostą podporę podczas chodzenia. Nie nadają się jednak dla dzieci, które potrzebują dodatkowego podparcia dla ramion, ponieważ w takiej konfiguracji dzieci wykazują tendencje do nieprawidłowego zginania bioder i wychylania tułowia. Dlatego powinny być używane tylko przez dzieci, które potrzebują wsparcia wyłącznie dla utrzymania równowagi.

Balkoniki tylne (rys. 3.10b) z kolei przeciwdziałają części z wymienionych wad. Ich kształt oraz sposób sterowania (dziecko ciągnie balkonik za sobą) stymulują do utrzymywania prawidłowej postawy, zapobiegają chodzeniu na palcach, a także chronią przed upadkiem do tyłu. Dzieci z silnym porażeniem dolnych i górnych kończyn muszą mieć jeszcze większe podparcie. Dodatkowe podpory klatki piersiowej oraz siedzisko zapewniają pionizatory dynamiczne (rys. 3.10c).



Rysunek 3.10. Sprzęt ułatwiający chodzenie: a) balkonik przedni; b) balkonik tylny; c) pionizator dynamiczny [31]

Dzieci nauczone nowych umiejętności motorycznych powinny kontynuować swój rozwój fizyczny, szczególnie pod kątem wzmacniania siły mięśniowej. Wykonywanie codziennych ćwiczeń rozciągających oraz innych form treningu siłowego są najlepszym sposobem, aby w późniejszych okresach życia wykształcić niezależność. Treningi te nie muszą mieć monotonnego charakteru ćwiczeń przedstawionych w tym i poprzednim rozdziale. W istocie, wykorzystanie do tego celu przedmiotów służących do zabawy jest wręcz wskazane. Trójkołowe rowery lub inne akcesoria dla dzieci (rys. 3.11) doskonale nadają się do poszerzania spektrum wykonywanych ćwiczeń. Należy jednak pamiętać, że niektóre z tych przedmiotów wymagają niewielkich przeróbek, aby dzieci z osłabionymi mięśniami bioder lub pleców mogły bezpiecznie z nich korzystać. Przykładem tego jest zamiana standardowego siodła rowerowego na siedzisko z oparciem i podporami dla klatki piersiowej.




Rysunek 3.11. Wykorzystanie w rehabilitacji rowerów i zabawek dziecięcych [31]

Odruchy patologiczne kończyn, spowodowane choćby zwiększonym napięciem mięśniowym, utrudniają poprawne wykonywanie rehabilitacji, pogłębiając inne nieprawidłowe odruchy i asy-

metrię pracy układu mięśniowego. W przypadku kończyny dolnej, odruchy patologiczne mogą, przykładowo, powiększać wady postawy, a u kończyny dolnej skutkować przykurczami przerywanymi efekty terapii, dlatego niezwykle ważne jest hamowanie odnośnych nieprawidłowości za pomocą specyficznych akcesoriów.

Patologicznym ustawieniom w stawie skokowym można zapobiegać poprzez stosowanie stabilizatorów. Dwustronny stabilizator stawu skokowego (rys. 3.12a) ogranicza ruchy stopy w kierunkach bocznych, co skutecznie eliminuje niechciane ruchy, np. zgięcie podszwowe z supinacją, występujące podczas zwiększonego napięcia spastycznego. W przypadku tzw. stopy opadającej, przeciwdziałać można, używając odpowiednich łusek zakładanych na stopę (rys. 3.12b). Nowoczesna rehabilitacja odchodzi jednak od używania sztywnych łusek na rzecz elastycznych łusek dynamicznych. Innym odruchem patologicznym stopy, który można blokować, używając odpowiednich akcesoriów, jest podwijanie się palców w kierunku podszwowym. W tym przypadku pomocne są wkładki do butów z podwyższoną częścią przednią, a także wycięcia w przednich częściach butów, za pomocą których można kontrolować pozycję palców (rys. 3.12e).

Jednym z efektów tzw. ręki spastycznej jest zgięcie i pronacja w stawie łokciowym, które można zabezpieczyć aparatem stabilizującym z regulacją kąta (rys. 3.12c). Pomimo oczywistej zalety w postaci możliwości indywidualnej konfiguracji kąta, orteza ta może zwiększać patologiczne napięcie mięśniowe w ręce. W obrębie dłoni obserwuje się zaś ustawienie jej w zgięciu dłoniowym oraz zgięcie dłoniowe palców, co z kolei można regulować anatomicznie wyprofilowaną łuską plastyczną (rys. 3.12d).



Rysunek 3.12. Ortezy i inne aparaty stabilizujące kończyny: **a)** dwustronny stabilizator stawu skokowego; **b)** łuska na stopę; **c)** aparat stabilizujący z regulacją kąta w stawie łokciowym; **d)** łuska plastyczna na dłoń; **e)** zabezpieczenie palców stopy przed podwijaniem się w kierunku podszwowym [45]

Interesującym przykładem zindywidualizowanej, wspomaganiej rehabilitacji dzieci z PCI jest terapia z wykorzystaniem kostiumu TheraSuit (rys. 3.13). TheraSuit jest proprioceptywną, dynamiczną ortezą składającą się ze spodenek, kamizelki i butów ze specjalnymi przyłączeniami.

Każda z tych części jest wzajemnie ze sobą połączona poprzez system elastycznych przyłączy. Kostium wspomaga proces rehabilitacji poprzez usztywnienie wybranych części ciała pacjenta, co w przypadku dzieci z PCI daje efekty w postaci stabilizacji tułowia, wyrównania napięcia mięśniowego, wzmocnienia siły oraz wytrzymałości mięśniowej, czy nauki i poprawy prawidłowej postawy oraz techniki chodu. Dynamiczna korekcja nerwowo-mięśniowa może być dostosowana indywidualnie do pacjenta poprzez zmianę konfiguracji przyłączy na elementach kostiumu.



Rysunek 3.13. Pacjent w kostiumie TheraSuit

W procesie leczenia i rehabilitacji urazów bądź zaburzeń związanych z funkcjonowaniem układu ruchu często są wykorzystywane metody stymulujące pracę wybranych narządów lub tkanek. Przykładem takiej metody jest choćby elektrostymulacja nerwowo-mięśniowa stosowana w leczeniu zaburzeń o podłożu neurologicznym. W rehabilitacji osób chorych na OI wykorzystuje się urządzenia aplikujące ciału wibracje o odpowiedniej częstotliwości [46]. Zauważono, iż metoda ta wspomaga prawidłowy rozwój tkanki mięśniowej.

3.3. Zaawansowane systemy rehabilitacyjne

Pod pojęciem „zaawansowanych urządzeń rehabilitacyjnych”, przedstawionych w niniejszym rozdziale, rozumie się urządzenia, które aplikują zdobycze najnowszych technologii do procesów leczenia i rehabilitacji ortopedycznej. Działanie takich przyrządów wspomagane jest przez różnego rodzaju sieci czujników, techniki multimedialne, a nawet przez metody sztucznej inteligencji. Urządzenia te zapewniają więc rehabilitantowi ciągły wgląd w wybrane parametry fizjologiczne ciała osoby rehabilitowanej, a jej z kolei zapewnia dodatkowe wspomaganie podczas treningów.


Koronnym przykładem nowoczesnego systemu rehabilitacyjnego jest Lokomat [47] (rys. 3.14). Jest to urządzenie do treningu lokomotorycznego złożone z egzoszkieletem wspomagającego pracę kończyn dolnych oraz ramy zapewniającej warunki odciążenia dynamicznego. Lokomat na bieżąco rejestruje wszystkie dane dotyczące dynamiki chodu pacjenta, a każdy aspekt kontroli ruchu jest konfigurowalny. Jest to jedno z bardziej powszechnych urządzeń tego typu użytkowanych na

całym świecie, dzięki czemu jego skuteczność w porównaniu do tradycyjnej terapii jest potwierdzona w szeregu publikacji [48]. Dodatkowo, urządzenie to może zostać wyposażone w system wizualnego sprzężenia zwrotnego, co w sposób znaczący poprawia jakość terapii wspomaganej mechanicznie [49].



Rysunek 3.14. Lokomat [47]


Kolejnymi popularnymi urządzeniami używanymi w rehabilitacji ortopedycznej są produkty firmy Biodex Medical Systems [50]. Są to, m.in., systemy odciążenia dynamicznego (rys. 3.15a), interaktywne bieżnie do reedukacji chodu (rys. 3.15b), dynamometry, czy ergometry. Wszystkie systemy są wysoce konfigurowalne, udostępniają dane identyfikujące upośledzenie funkcji fizycznych pacjentów, a także pozwalają na pracę w trybie izometrycznym, co jest szczególnie pożądane w rehabilitacji PCI i OI. Udowodniono zostało, że zastosowanie urządzenia Biodex prowadzi do poprawy funkcji chodu u dzieci z PCI [51].



Rysunek 3.15. Urządzenia wspomagające rehabilitację ruchową Biodex: a) system odciążenia dynamicznego NxStep; b) system asystujący podczas treningu chodu Gait Trainer 3 [50]

Jednymi z najbardziej zaawansowanych technologicznie systemów do rehabilitacji są egzoskielety HAL (Hybrid Assistive Limb) produkcji japońskiej firmy CYBERDYNE [52] (rys. 3.16).

Analogicznie, jak w przypadku aktywnej ortezy systemu Lokomat, HAL zapewnia wspomaganie ruchu osobom nawet ze znacznym niedowładem kończyn. Egzoszkielet można wykorzystać w połączeniu z praktycznie dowolnym innym sprzętem rehabilitacyjnym; w odróżnieniu od pozostałych podanych przykładów, jest to system mobilny. HAL znajduje szereg zastosowań, m.in. w rehabilitacji po ostrym udarze krwotocznym [53], czy w przypadku urazów rdzenia kręgowego [54].



Rysunek 3.16. Egzoszkielety HAL: **a)** wspomaganie rehabilitacji kończyn dolnych; **b)** wsparcie ruchu w stawie łokciowym; **c)** wsparcie ruchu w stawie kolanowym [52]

Wartym odnotowania systemem rehabilitacyjnym jest także odnoszący coraz większe sukcesy na rynku światowym sprzęt polskiej firmy EGZOTech – Luna EMG [55] (rys. 3.17). Luna EMG oferuje zarówno diagnostykę funkcji mięśniowych pacjentów, jak i w pełni zautomatyzowaną kinezyterapię. Dzięki wielu wymiennym rozszerzeniom, przeprowadzać można trening wszystkich rodzajów ruchów w stawach człowieka.



Rysunek 3.17. System do neurorehabilitacji Luna EMG [55]

Coraz większa liczba zrobotyzowanych urządzeń rehabilitacyjnych znajduje uzasadnienie w literaturze naukowej, według której terapia ludzi z PCI za pomocą sprzętu tego rodzaju przynosi bardzo dobre rezultaty [56–59]. Ponadto, umotywowane jest wykorzystanie interaktywnych

pomocy wizualnych (gier komputerowych) oraz urządzeń dla nich opracowanych (np. Microsoft Kinect, Nintendo Wii) jako dodatku do standardowej terapii fizycznej [60–66].

Należy jednak podkreślić, że wyżej wymienione systemy są szczególnie kosztowne, a dodatkowo nie posiadają rozwiązań podnoszących atrakcyjność wykonywanych ćwiczeń i tym samym motywujących dzieci do ich wykonywania. Podjęte przez autora badania mają stanowić w przyszłości alternatywę, z uwagi na:

- zastosowanie wspomagających rehabilitację gier komputerowych, które dostosowują swoje działanie do osoby ćwiczącej i wytycznych programu,
- implementację systemu wnioskowania i bazy wiedzy eksperckiej, pozwalających na automatyczny dobór i ocenę zindywidualizowanych ćwiczeń,
- duże ograniczenie udziału rehabilitanta podczas pojedynczej sesji, a tym samym umożliwienie symultanicznej rehabilitacji wielu dzieci,
- zmniejszenie nakładów finansowych i oszczędność czasu dla wszystkich osób zaangażowanych w proces rehabilitacji.

Powyższe charakterystyki wymagają jednak przede wszystkim podjęcia następujących działań, stanowiących przedmiot niniejszej rozprawy, tj.:

- opracowania metody szczegółowej identyfikacji stanu fizycznego rehabilitowanego dziecka (istnienie chorób lub niepożądanych objawów),
- wynalezienia efektywnej metodologii identyfikacji ruchów ciała (zmniejszenie liczby i stopnia skomplikowania systemu przyrządów pomiarowych),
- opracowania sposobu oceny realizowanego ćwiczenia (czy warunki ćwiczenia i sposób jego wykonywania są odpowiednie dla danego dziecka).

Rozdział 4

Metodologia badań własnych

4.1. Plan i zakres badań

Przedstawiony w poprzednich rozdziałach stan wiedzy związany z aktualnie prowadzonymi badaniami naukowymi (rozd. 1.2) oraz praktyką rehabilitacyjną (rozd. 3) wskazuje na brak powszechnego stosowania zdobytych najnowszych technologii, a szczególnie nowoczesnych metod komputerowych. Gros ćwiczeń ruchowych wykonywane jest wciąż manualnie, absorbując całą uwagę rehabilitanta tylko na jednym ze swoich pacjentów na raz. Nieliczne innowacyjne systemy rehabilitacyjne, jak np. Lokomat, pełnią głównie funkcje wspomaganie ruchu (poprzez stosowanie egzoszkieleatów) i odciążania uwagi ćwiczącego od całego procesu (poprzez zastosowanie prostych wizualizacji). Brak jest zatem warstw nadrzędnych (szczególnie warstwy optymalizacji) realizujących w sposób zautomatyzowany zadanie sterowania wielopoziomowego.

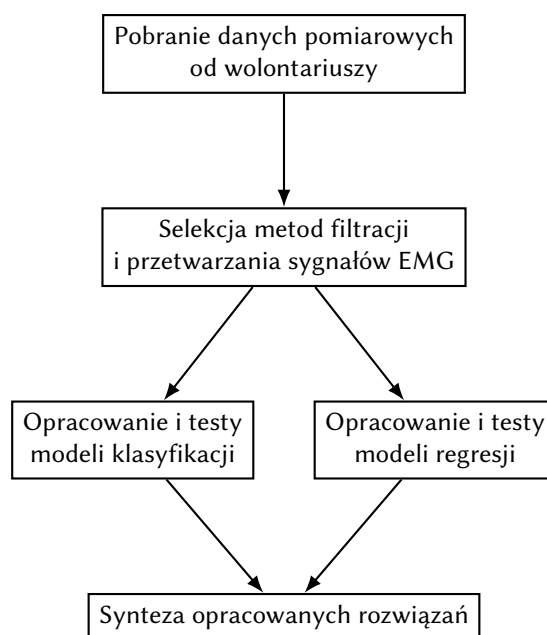
We wstępie do rozprawy zamieszczono dyskusję nad koncepcją rehabilitacji w pętli zamkniętej, tzw. HITL. Przedstawiony na rysunku 1.3 zarys algorytmu zautomatyzowanego procesu rehabilitacji jest z oczywistych względów niewykonalny w całości jako część prac prowadzonych na potrzebę dysertacji doktorskiej – opracowanie tak wielopoziomowego, sprawnego systemu sterowania wymagać będzie dużych pokładów pracy całych zespołów naukowych i znacznych środków finansowych. Dlatego niniejsza rozprawa skupia się wyłącznie na najważniejszych aspektach tej koncepcji (zaznaczonych kolorem turkusowym na rys. 1.3), będących fundamentami pod przyszłe rozwiązania.

Realizacja odnośnych celów została podzielona na pięć faz (rys. 4.1). Najpierw zebrano dane pomiarowe, czyli sygnały EMG generowane podczas ruchu kończyn osób badanych oraz dane opisujące ich ruch w przestrzeni. Następnie dobrano szereg metod przetwarzających owe dane (m.in. filtrację, transformację czasową) w celu przygotowania ich do dalszej analizy. Przetworzone dane użyto jako zbiory uczące i testujące w procesie konstruowania modeli uczenia maszynowego.

Przedstawiony zarys badania można więc uszczegółowić za pomocą następujących punktów opisujących eksperyment:

1. Osoba badana wykonuje ruchy kończynami oraz proste zdefiniowane ćwiczenia rehabilitacyjne z użyciem dedykowanego oprzyrządowania bądź bez ich udziału.






Rysunek 4.1. Zarys wykonanych faz badania

2. Kamera Kinect dokonuje rejestracji ruchów ciała w przestrzeni 3D w trakcie wykonywania powyższych ćwiczeń.
3. Elektromiograf rejestruje aktywność bioelektryczną mięśni odpowiadających za ruch ciała podczas zdefiniowanych ćwiczeń.
4. Selekcjonowane są metody przetwarzania pobranych sygnałów w celu wyeksponowania informacji, które najdokładniej opiszą dany przypadek w dalszych częściach badania.
5. Konstruowane są modele klasyfikacyjne zdolne rozróżnić stan fizyczny pacjenta, tj. czy dana osoba jest zdrowa, czy choruje na **PCI** lub **OI**.
6. Konstruowane są modele klasyfikacyjne zdolne stwierdzić (z określonym prawdopodobieństwem), czy dane ćwiczenie jest wykonywane poprawnie, czy nie.
7. Konstruowane są modele regresyjne, które na podstawie wprowadzonych danych **EMG** osoby badanej dokonają estymacji pozycji jej kończyn.
8. Finalnie, opracowane systemy zostają poddane syntezie i analizie jako baza pod wielozadaniowy system automatycznej rehabilitacji.


Punkty 1–3 reprezentują pierwszą fazę eksperymentu (rys. 4.2), która zakłada utworzenie odpowiedniej bazy danych pomiarowych wymaganej w kolejnych etapach badań. Dane gromadzone są podczas około 40-minutowych sesji z każdym z wolontariuszy. Dzieci są przygotowywane do badania przez objaśnienie szczegółów procedury. Nad brzuscami ich mięśni umieszczane są elektrody. W tym samym czasie naprzeciwko uruchamiana jest kamera Kinect.

Pomiar danych odbywa się w dwóch turach. W pierwszej kolejności wszyscy wolontariusze, siedząc na krześle, wykonują swobodne ruchy w stawach kończyn (zginanie/prostowanie, przywodzenie/odwodzenie itd.), sprawdzając ich ruchomość. Ruchy są wykonywane z różną szybkością, a niektóre z nich dodatkowo są badane pod wpływem zewnętrznego obciążenia (rys. 4.3). W trakcie drugiej tury wybrani wolontariusze są poproszeni o wykonanie serii podstawowych ćwiczeń reha-



Rysunek 4.2. Schemat badań przeprowadzonych z udziałem wolontariuszy


bilitacyjnych o niewielkiej intensywności (oraz małym obciążeniu) z użyciem prostych przyrządów treningowych, jak np. rotora. Podczas badań notuje się, czy dana osoba odczuwa dyskomfort. Pomimo faktu, że wszystkie osoby instruowane były do wykonywania takich samych serii ćwiczeń, to mogą występować modyfikacje dla indywidualnych przypadków. Stąd też wszelkie odstępstwa od przyjętej normy zostały opatrzone odpowiednim komentarzem w dalszych częściach rozprawy.



Rysunek 4.3. Obciążniki treningowe stosowane podczas badań: **a)** obciążnik naręczny o masie 1 kg; **b)** obciążnik o masie 0,5 kg; **c)** obciążnik o masie 1 kg; **d)** obciążnik o masie 2 kg

Przed rozpoczęciem symulacji modeli uczenia maszynowego, uzyskane sygnały zostały odpowiednio skondycjonowane (pkt 4). Należy jednak pamiętać, że aktywność mioelektryczna zmierzona przez aparat EMG bez wewnętrznej filtracji pasmowej może być obciążona częstotliwościami pasożytniczymi pochodzącymi od aktywności innych organów (np. serca) czy od sieci elektrycznej. Dlatego każdy pobrany sygnał został poddany filtracji środkowoprzepustowej. Przefiltrowane sygnały zostały poddane odpowiedniej obróbce w celu przygotowania danych wejściowych do sieci wnioskujących. W efekcie posłużono się przesuwными oknami czasowymi o szerokości w_l i kroku w_s (rys. 4.4). Najefektywniejsze wartości wskazanych parametrów zostały wyłonione na drodze dalszych eksperymentów.

Każdą próbkę uzyskaną w powyższy sposób poddano licznym transformacjom w dziedzinie czasu (m.in. średnia wartości bezwzględnych amplitudy sygnału,) i w dziedzinie czasowo-często-



Rysunek 4.4. Istota formowania próbek sygnału EMG w oknie czasowym


tliwościowej (ciągła transformata falkowa) w celu uzyskania właściwych danych wejściowych. Przed wykorzystaniem współczynników tych jako danych wejściowych sieci uczących, poddano je analizie wariacyjnej (używając testu statystyki χ^2 dla klasyfikacji i jednoczynnikowego testu regresji liniowej) w celu redukcji wymiarowości wektora cech opisującego dany przypadek, a uzyskane wektory danych wejściowych przeskalowano do normy jednostkowej ℓ^2 .

Wedle punktów 5–7, systemy automatycznego wnioskowania, będące istotą rozprawy, bazują na dwóch metodach nadzorowanego uczenia maszynowego – klasyfikacji i regresji. Problem klasyfikacji można opisać następująco. Mając zbiór n próbek $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, gdzie \mathbf{x}_i jest wektorem m cech i -tej próbki, a y_i jest jej etykietą (klasą), zadaniem algorytmu uczącego jest znalezienie funkcji $f : \mathcal{X} \rightarrow \mathcal{Y}$, dla której $\mathcal{X} \subseteq \mathbb{R}^m$ reprezentuje przestrzeń wejść, a $\mathcal{Y} = \{y_1, \dots, y_p\}$ przestrzeń wyjść. Funkcja f jest elementem pewnej przestrzeni funkcji \mathcal{F} nazywanej przestrzenią hipotezy. Celem klasyfikatora jest więc przydzielenie obiektowi $\mathbf{x}_i \in \mathcal{X}$ klasy $y_i \in \mathcal{Y}$. Odwołując się do tematu rozprawy, klasyfikacją jest przykładowo stwierdzenie, czy badana osoba wykonuje ćwiczenie prawidłowo, czy też nie (dwie klasy) na podstawie średniej wartości szczytowej i całki sygnału EMG z mięśni: dwugłowego oraz trójgłowego ramienia.

W odróżnieniu od klasyfikacji, regresja jest funkcyjną zależnością zmiennej ciągłej wyjściowej y (określanej jako zmienna objaśniana) od zmiennej x bądź wektora zmiennych \mathbf{x} wejściowych (objaśniających). Zatem, analogicznie do klasyfikacji, mając zbiór n próbek $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, gdzie $\mathbf{x}_i \in \mathbb{R}^m$ jest wektorem m zmiennych objaśniających i -tej próbki, a $y_i \in \mathbb{R}$ jest jej zmienną objaśnianą, zadaniem algorytmu uczącego jest znalezienie funkcji relacji $f(\mathbf{x}_i, \boldsymbol{\beta}) \approx y_i$, gdzie $\boldsymbol{\beta}$ jest pewnym wektorem (bądź skalarą) współczynników regresji. Przykładem zastosowania regresji jest estymacja wartości rotacji przedramienia względem ramienia na podstawie średniej wartości szczytowej i długości przebiegu sygnału EMG z mięśni: dwugłowego oraz trójgłowego ramienia.


Zastosowany proces uczenia nadzorowanego (Supervised Learning) zakłada uczestniczenie czynnika ludzkiego w postaci wspomaganie procesu tworzenia funkcji odwzorowującej wejście sieci na jej wyjście. „Nauczyciel” podaje na wejście maszyny uczącej wektory cech bądź zmiennych objaśniających wraz z odpowiadającymi im klasami, bądź zmiennymi objaśnianymi, dzięki czemu zaimplementowany algorytm nauczania modelu klasyfikacji/regresji może dostosować jego parametry tak, by jak najdokładniej odwzorować te zależności.

Podczas prac z odnośnymi metodami uczenia maszynowego typowo używa się podejścia trójetażowego. Najpierw, spośród zbioru n par danych wejściowych i wyjściowych, dokonuje się podziału na zbiór uczący oraz uogólniający (testujący). Zbioru uczącego używa się do przeprowadzenia pełnego procesu nadzorowanego nauczania sieci wnioskującej. Pozostałe dane wejściowe wprowadzone zostają do nauczonej sieci, a wynik procesu wnioskowania jest porównywany z danymi wyjściowymi będącymi częścią zbioru testującego. W ten sposób, stosując odpowiednią miarę, określa się jakość wytworzonego modelu. Opisany proces został zilustrowany na rysunku 4.5.



Rysunek 4.5. Schemat procesu przetwarzania danych pomiarowych (faza 1) oraz nauczania z nadzorem i testowania modelu uczenia maszynowego (fazy 2 i 3)

Oceny jakości wnioskowania modelu dokonuje się na drodze odpowiedniej strategii testującej. Najczęściej stosuje się strategię zwaną walidacją krzyżową (Cross-Validation), w której próbę statystyczną dzieli się na podzbiory o możliwie równej liczebności. Następnie przeprowadza się analizę każdego pojedynczego podzbioru w odniesieniu do reszty próbek. W k -krotnej walidacji zbiór par danych wejściowych i wyjściowych $\{c_1, \dots, c_n\}$ dzieli się na k podzbiorów, po czym przeprowadza się k iteracji, w trakcie których jeden podzbiór stanowi dane testujące, a pozostałe $k - 1$ – dane uczące. Jeśli $k = n$, to walidację taką nazywa się Leave-One-Out, czyli do oceny modelu używa się jedynie jednej pary danych wejściowych x_i i wyjściowych y_i (rys. 4.6).




Rysunek 4.6. Schemat walidacji krzyżowej typu Leave-One-Out

Algorytmy uczenia maszynowego strojone są przez różną liczbę parametrów, silnie wpływających na efektywność procesu nauczania. Dobór ich wartości jest często nieoczywisty, sprawiając w początkowych fazach eksperymentów trudności z zebraniem satysfakcjonujących wyników. Istnieją jednak metody wyboru zestawów parametrów, które zapewnią możliwie najefektywniejsze działanie estymatorów. Jedną z nich, wykorzystaną w opisanych badaniach, jest tzw. wyszukiwanie wyczerpujące (Grid Search), w trakcie którego algorytmowi podawane są po kolei parametry z wcześniej zdefiniowanych zbiorów, a na końcu otrzymuje się kombinację parametrów, które zapewniły optymalny wynik. Jest to ostatnia procedura w zastosowanej metodyce testowania modeli (rys. 4.7), której wynikiem jest wyselekcjonowany, najlepszy z testowanych klasyfikator bądź regresor.

Do wytworzenia modeli klasyfikacji i regresji wybrano cztery metody uczenia maszynowego:

- algorytm k najbliższych sąsiadów,
- drzewa decyzyjne,
- maszyna wektorów nośnych,
- perceptron wielowarstwowy.

Wybór odnośnych metod jest związany z poziomem ich implementacji w bibliotekach uczenia maszynowego wykorzystanych w eksperymencie. Do zadań klasyfikacji wykorzystano trzy



Rysunek 4.7. Procedura oceny maszyny uczącej

zbiory klas: zbiór określający stan fizyczny pacjenta {zdrowy, PCI, OI} (pkt 5) oraz zbiory określające ocenę wykonywania danego ćwiczenia {prawidłowo, niepoprawnie} i wagę zewnętrznego obciążenia nałożonego na kończynę {0,5 kg, 1 kg, 2 kg} (pkt 6). Jako zmiennymi objaśnianymi w regresji (pkt 7) posłużono się współrzędnymi kwaternionowymi rotacji stawu względem stawu nadrzędnego uzyskanymi z kamery Kinect.

Ostatecznie, wynikiem badań prowadzonych na potrzeby niniejszej rozprawy jest wybór najlepszego modelu oraz metodyki kondycjonowania sygnałów EMG dla każdego z opisanych zadań (pkt. 5–7).

4.2. Charakterystyka grupy badanej

Badaniami objęto szóstkę dzieci w wieku 8–17 lat. Grupa zawiera dzieci zdrowe, bez dysfunkcji układu motorycznego, oraz dzieci z wyraźnymi objawami zaburzenia prawidłowego funkcjonowania elementów układu ruchu, w tym z PCI i OI. Spośród dzieci chorych brane były pod uwagę jedynie te obciążone lekkim bądź średnim stopniem zaburzeń układu ruchu, posiadające możliwość swobodnego wykonywania lekkich ćwiczeń bez potrzeby wspomaganie pracy kończyn. Kryteria wyłączenia z badania obejmowały:

- całkowity paraliż kończyn,
- niezdolność do samodzielnego wykonywania czynności ruchowych,
- znaczne upośledzenie umysłowe uniemożliwiające poprawne wykonywanie zadanych przez opiekuna ćwiczeń,
- występowanie objawów współistniejących w postaci m.in. ciężkich i częstych napadów padaczkowych oraz drgawek.

Poniżej przedstawiono podział na grupy według kryterium zdrowotnego osób poddanych badaniom. Tabela 4.1 przedstawia przekrój wieku i płci zakwalifikowanych ochotników zgodnie z tym podziałem.

- A. Osoby zdrowe, tj. nie posiadające dysfunkcji układu motorycznego. Osoby zakwalifikowane stanowią tzw. grupę kontrolną eksperymentu.

B. Osoby chore na [PCI](#).

C. Osoby chore na [OI](#).

Tabela 4.1. Charakterystyka grup zbadanych ochotników

	Wszyscy ochotnicy	Grupa A	Grupa B	Grupa C
Liczebność	6	2	2	2
Płeć męska	3 (50%)	0	1 (50%)	2 (100%)
Wiek	10,8 ± 3,2	8,5 ± 0,5	15 ± 2	9 ± 1
Wzrost [cm]	139,7 ± 12,8	130 ± 4	155 ± 9	134 ± 6
Waga [kg]	32 ± 6,8	28,5 ± 2,5	41 ± 1	26,5 ± 2,5

Uwaga: Podane wartości wieku, wzrostu i wagi stanowią średnie ± odchylenia standardowe.

Przedstawione informacje uzyskano na podstawie retrospektywnej analizy danych uzyskanych podczas wywiadu przeprowadzanego przed każdym badaniem wszystkich ochotników pierwotnie włączonych do badania.

Na przeprowadzenie badań uzyskano zgodę Niezależnej Komisji Bioetycznej ds. Badań Naukowych przy Gdańskim Uniwersytecie Medycznym (nr pozwolenia NKBBN/570/2015-2016). Opiekunowie prawni dzieci kwalifikowanych do badania byli informowani o dobrowolnym udziale w badaniu i uzyskano od nich pisemną zgodę na powyższe. Wszystkie eksperymenty przedstawione w niniejszej rozprawie zostały przeprowadzone zgodnie z zatwierdzonymi wytycznymi, pod nadzorem specjalisty pediatrii ze stopniem naukowym w zakresie medycyny.

4.3. Aparatura badawcza

4.3.1. Jednostka komputerowa i oprogramowanie

Wszystkie pomiary i symulacje zostały wykonane z użyciem komputera klasy PC charakteryzującego się procesorem Intel Core i7-3770 z czterema rdzeniami o taktowaniu 3,40 GHz, zainstalowaną pamięcią fizyczną o pojemności 32 GB oraz kartą graficzną NVIDIA GeForce GTX 660. Dodatkowo, w celu akwizycji analogowych danych pomiarowych z aparatu [EMG](#), komputer został wyposażony w 16-kanalową kartę wejść/wyjść NI PCI-6025E firmy National Instruments o rozdzielczości 12 bitów i maksymalnej częstotliwości próbkowania 200 kS/s.

Komputer użyty do przeprowadzania symulacji pracował na systemie Microsoft Windows 7 x64. Czynności związane z przetwarzaniem i analizą danych, wykonywaniem symulacji, a także z przygotowywaniem materiałów do rozprawy wykonano z użyciem języka programowania Python 3.6. Wykorzystano biblioteki numeryczne NumPy v1.14.3 [67] oraz pandas v0.22.0 [68] jako podstawę obsługi danych liczbowych, bibliotekę SciPy v1.0.1 [67, 69] jako narzędzie do podstawowego przetwarzania sygnałów, bibliotekę PyWavelets v0.5.2 [70] do analizy falkowej sygnałów, bibliotekę scikit-learn v0.19.1 [71, 72] udostępniającą metody uczenia maszynowego, a także bibliotekę



Matplotlib v2.2.2 [73] jako narzędzie do wykonania graficznej analizy danych. Ponadto, część oprogramowania użytego w procesie badawczym do rejestrowania pozycji ciała opracowano w języku programowania C# w środowisku Visual Studio 2015, a obsługa karty wejść/wyjść odczytującej pomiary EMG została powierzona oprogramowaniu National Instruments SignalExpress 2015.

4.3.2. Kamera Kinect


Kamera Kinect (rys. 4.8) jest przetwornikiem ruchu opracowanym na potrzeby konsoli Xbox 360, wyprodukowanym przez firmę Microsoft. Urządzenie pozwala użytkownikowi na interakcję z konsolą bez konieczności używania kontrolera, poprzez interfejs wykorzystujący gesty wykonywane przy pomocy kończyn i całego ciała, jak i przez komendy głosowe. Dzięki udostępnionemu przez producenta zestawu SDK (Software Development Kit) [74] kamera może być wykorzystana poza konsolą jako: kontroler interakcji człowiek-maszyna, urządzenie do budowy map środowiska, bądź jako narzędzie do zapisu i oceny ruchu [75].




Rysunek 4.8. Kamera Kinect wykorzystana do wykrywania pozycji ciała osób badanych

Urządzenie jest wyposażone w dwie kamery, promiennik podczerwieni, macierz czterech mikrofonów kierunkowych, akcelerometr i napęd pozwalający na uchylenie głowicy. Pierwsza z kamer to standardowa kamera RGB o rozdzielczości 640×480 wykorzystywana do przetwarzania obrazu wizyjnego (m.in. rozpoznawanie twarzy) oraz nanoszenia kolorów i tekstur na obiekty wirtualne. Druga kamera jest częścią podsystemu sensora, zwracającą informację o głębi. Podsystem ten działa na zasadzie pomiaru odległości za pomocą światła strukturalnego. Promiennik podczerwieni wyświetla przed kamerą chmurę punktów, których położenia są rejestrowane przez kamerę z filtrem podczerwonym. Uzyskana rozdzielczość informacji o głębi z kamery to 300×200 . Obraz ten jest programowo interpolowany do rozdzielczości kamery wizyjnej. Zakres działania czujnika odległości to 0,4–6,5 m, a częstotliwość zapisu informacji wynosi 30 Hz. Informacja o odległości we wszystkich punktach daje możliwość programowego odczytania np. sylwetki człowieka i wykrycia jego gestykulacji. Zastosowanie metody światła strukturalnego pozwala na bezbłędne działanie sensora tylko w pomieszczeniach – odczyt jest wrażliwy na znaczne nasłonecznienie.

Działanie kamery Kinect bazuje na mapowaniu 20 punktów charakterystycznych na ludzkim ciele, na podstawie obrysu jego kształtu. Kinect śledzi odnośne punkty (zwane „stawami”), umieszczając jednocześnie pomiędzy nimi obiekty łączące – „kości” (rys. 4.9a). Współrzędne przestrzenne każdego obiektu są zależne od umiejscowienia kamery oraz pozycji punktu środka bioder (rys. 4.9b). Pozostałe „stawy” i „kości” określone są w globalnym układzie odniesienia (wedle kamery) lub w lokalnym układzie ciała ze środkiem w punkcie środka bioder (rys. 4.9c). Rysunek 4.10 przedstawia działanie kamery Kinect w praktyce – „szkielet” nałożony na ludzkie ciało.




Rysunek 4.9. Informacje o pozycji ludzkiego ciała pobierane przez sensor Kinect: **a)** umiejscowienie „stawów” (czerwone kropki) i „kości” (zielone kreski); groty strzałek wskazują na „stawy” podrzędne w hierarchii; **b)** globalne układy współrzędnych sensora Kinect i podrzędnego mu układu środka bioder; **c)** składanie układu współrzędnych prawego nadgarstka do głównego układu środka bioder



Rysunek 4.10. Prawidłowo nałożony „szkielet” współrzędnych ciała

Działanie algorytmu śledzenia punktów na ciele można dodatkowo modyfikować poprzez zmianę wartości parametrów filtrów wykorzystywanych w tym procesie. Stroić można takie parametry, jak: wygładzanie, stopień korekcji do naturalnych danych, liczbę przewidywanych klatek, promień drgania i maksymalny promień odchylenia. Wartości odnośnych parametrów podczas trwania eksperymentu były stałe i wynosiły odpowiednio: 0,7, 0,2, 0,5, 0,1 i 0,1.

W celu komunikacji z kamerą, wizualizacji jej działania oraz zapisywania danych pomiarowych opracowano w języku programowania C# program KinectMotionCapture [76]. Interfejs tego programu (rys. 4.11) umożliwia uruchomienie i podgląd strumienia szkieletu kamery Kinect, zmianę parametrów wygładzania strumienia, jak również zapis do pliku współrzędnych znaczników ciała oraz orientacji „kości” w postaci hierarchicznych oraz bezwzględnych macierzy obrotu i współrzędnych kwaternionowych.




Rysunek 4.11. Interfejs programu komputerowego służącego do pobierania pozycji ciała z kamery Kinect i zapisywania ich do plików (obraz z kamery przedstawia odbicie lustrzane)

Przy porównaniu obu powyższych zapisów (rys. 4.10 i 4.11) można zwrócić uwagę na dużo mniejszą dokładność pozycjonowania znaczników w przypadku rejestracji w warunkach eksperymentu (rys. 4.11). Kinect potrzebuje całej frontalnej sylwetki stojącego człowieka, aby móc efektywnie pozycjonować wszystkie punkty „szkieletu”. Każde odstępstwo powoduje błędy, a pozycja siedząca, wykorzystana podczas większości pomiarów, szczególnie uniemożliwia jednoczesne uchwycenie wszystkich kończyn. Stąd też każdy pomiar skupiał się wyłącznie na jednej kończynie, dla której możliwe było ustawienie warunków eksperymentu (pozycja i obrót ciała względem kamery) tak, aby zminimalizować wszelkie błędy. Pomimo podjętych wysiłków, estymacja pozycji ciała przez kamerę Kinect okazała się najmniej efektywną z wdrożonych procedur rejestracji opisywanego badania.

4.3.3. Specjalistyczny elektromiograf


Do odczytu aktywności bioelektrycznej mięśni osób zakwalifikowanych posłużono się 12-kanalowym aparatem do mierzenia biosygnalów napięciowych (rys. 4.12). Należy podkreślić, że aparat został wytworzony na zamówienie w celu jego dostosowania do konkretnych wymagań postawionych realizacji badań opisanych w niniejszej pracy. Wymagania te dotyczyły przede wszystkim możliwości pomiaru niezmodyfikowanego sygnału EMG z regulowanym wzmocnieniem jego amplitudy (urządzenie pomiarowe jest zatem wyposażone jedynie w układy do wstępnej filtracji).




Rysunek 4.12. Urządzenie wykorzystane do powierzchniowego pomiaru aktywności bioelektrycznej mięśni podczas badań: **a)** widok z podłączonymi czterema sondami pomiarowymi; **b)** wnętrze urządzenia

Schemat obwodu kanału pomiarowego rzeczonoego aparatu EMG przedstawia rysunek 4.14. Układ bazuje na wzmacniaczu wejściowym AD8221, dla którego napięcia na końcówkach rezystora ustalającego wzmocnienie są w praktyce identyczne, jak na jego wejściach. Wyjścia wzmacniacza skierowane są na wtórnik LM358, z których napięcia są podawane, przez rezystory 1 k Ω , na przewody ekranujące. Jest to działanie konieczne, by zapewnić jednakowe przekazywanie potencjałów z miejsc pod elektrodami, pomimo różnic w impedancjach samych elektrod. Działanie takiego układu jest równoważne znacznemu zmniejszeniu pojemności wejściowej wzmacniacza widzianej przy elektrodach. Ponadto, sygnały z wtórników trafiają na sumator uśredniający je na rezystorach 10 k Ω , co reprezentuje średni potencjał osoby badanej. Po odwróceniu fazy i wzmocnieniu, sygnał podawany jest na elektrodę referencyjną. Dzięki temu uzyskuje się wyrównanie chwilowych potencjałów ciała badanego i masy wzmacniacza wejściowego. Jest to wymagane ze względu na główny mechanizm eliminacji zakłóceń, czyli pomiar napięcia jako różnicy potencjałów eliminujący sygnał wspólny. Ostatecznie, wzmocnienie amplitudy sygnału EMG zmierzonego przez odnośny aparat ustawiono na 250. Pomiar sygnałów odbywał się z częstotliwością 100 Hz.

Elektromiograf wyposażono w chlorosrebrowe, jednorazowe elektrody listkowe Tele 1334 (rys. 4.13). Ich wymiary 13 \times 34 mm pozwoliły na ich umiejscowienie nawet nad niewielkimi partiami mięśni na kończynach dzieci. W większości przypadków, podczas pomiarów, elektrody były dodatkowo przytwierdzane taśmą, aby zminimalizować ryzyko odpięcia się elektrody od ciała podczas ruchu dziecka.



Rysunek 4.13. Elektroda bipolarna elektromiografu badawczego



Rysunek 4.14. Schemat obwodu jednego z kanałów pomiarowych elektromiografu

4.4. Metody obliczeniowe

4.4.1. Metody przetwarzania sygnałów EMG

Filtracja

Wykorzystane urządzenie pomiarowe celowo nie zostało wyposażone w filtry usuwające artefakty, czy nieznane wcześniej częstotliwości pasożytnicze, by ocenić możliwość ich ewentualnego wykorzystania w procesach analizy sterowania.

W celu zmniejszenia efektów zakłóceń o wysokiej częstotliwości i artefaktów będących wynikiem ruchu ciała, w analizie sygnałów EMG zastosowano filtrację środkowoprzepustową. Artefakty ruchu charakteryzują się komponentami o niskiej częstotliwości i dużej mocy, które częściowo pokrywają się z pasmem informacji mioelektrycznej (niewielki wpływ artefaktów jest więc nieunikniony). Stąd też w celu zminimalizowania oddziaływania niepożądanych składowych sygnału, zachowując jednocześnie pierwotną postać wymaganych informacji, postanowiono zastosować, na wstępnym etapie kondycjonowania, filtr Butterwortha.


Filtr Butterwortha charakteryzuje się maksymalnie płaską charakterystyką amplitudową w paśmie przenoszenia i jej płynnym spadkiem do zera w paśmie zaporowym [77]. Charakterystyka w paśmie zaporowym jest pomniejszana o 6 dB na oktawę, na każdy rząd filtru, a częstotliwość odcięcia wyznaczana jest w punkcie spadku sygnału o 3 dB. Wzmocnienie $G(\omega)$ dolnoprzepustowego filtru Butterwortha n -tego rzędu można podać w postaci transmitancji $H(s)$ jako

$$G^2(\omega) = |H(j\omega)|^2 = \frac{G_0^2}{1 + \left(\frac{j\omega}{j\omega_c}\right)^{2n}}, \quad (4.1)$$


gdzie: ω_c – częstotliwość odcięcia, G_0 – wzmocnienie przy zerowej częstotliwości.

Biorąc pod uwagę szerokość pasma informacji mioelektrycznej (10–400 Hz) oraz częstotliwość pomiarów (100 Hz), dla wszystkich sygnałów EMG dobrano filtr środkowoprzepustowy 5. rzędu o paśmie przenoszenia 10–49,8 Hz. Zapewniał on zarówno negację niskoczęstotliwościowych artefaktów, jak i zmniejszenie wpływu częstotliwości sieci elektrycznej. Odpowiedź odnośnego filtru przedstawiono na rysunku 4.15.

Ponadto, ze względu na potencjalne zaszumienie informacji o pozycji ciała spowodowane błędami w działaniu kamery Kinect, wdrożono dodatkowo wygładzanie danych rotacji kończyn. Zmianę pozycji poszczególnych części ciała podczas testów można było potraktować jako operację powolną, o stosunkowo dużym okresie wykonywania, zatem jedynie składowe widma o bardzo niskich wartościach stanowiły pożądaną informację. Wstępne testy w zakresie kondycjonowania sygnałów wykazały, że wykorzystanie dolnoprzepustowego filtru Butterwortha 1. rzędu o częstotliwości granicznej 0,2 Hz (rys. 4.16) jest odpowiednim kompromisem pomiędzy efektywnym usunięciem wpływu szumów, a zachowaniem prawidłowego odwzorowania charakterystyki ruchów.



Rysunek 4.15. Odpowiedź częstotliwościowa środkowoprzepustowego filtra Butterwortha zastosowanego w filtracji sygnałów EMG. Przerywane linie koloru czarnego wskazują na częstotliwości odcięcia



Rysunek 4.16. Odpowiedź częstotliwościowa dolnoprzepustowego filtra Butterwortha zastosowanego w filtracji parametrów rotacji „kości” uzyskanych z kamery Kinect. Przerywana linia koloru czarnego wskazuje na częstotliwość graniczną

Transformacja w dziedzinie czasu

Wśród przekształceń w dziedzinie czasu szczególnie wyróżnić można dwie następujące: średnia wartości bezwzględnych amplitudy sygnału (Mean Absolute Value, MAV) i długość przebiegu (Waveform Length, WL). Literatura podaje ich dużą efektywność we wspomaganianiu procesu klasyfikacji sygnałów EMG, zwłaszcza w przypadku wykorzystania pojedynczych współczynników oraz ich zestawów [8, 9]. Wzory (4.2) i (4.3) pozwalają obliczyć wyżej wymienione miary dla n kolejnych wartości wektora \mathbf{x} próbek sygnału:

$$\text{MAV} = \frac{1}{n} \sum_{i=1}^n |x_i|, \quad (4.2)$$

$$\text{WL} = \sum_{i=1}^{n-1} |x_{i+1} - x_i|, \quad (4.3)$$

Założono ponadto zbadanie wpływu kilku pozostałych, prostych przekształceń, które podaje literatura: całka sygnału EMG (Integrated EMG, IEMG), zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1 (Modified Mean Absolute Value Type 1, MAV1), zmo-

dyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2 (Modified Mean Absolute Value Type 2, MAV2), prosta całka kwadratowa sygnału (Simple Square Integral, SSI) oraz wariancja sygnału EMG (Variance of EMG, VAR). Wzory (4.4)–(4.8) poniżej przedstawiają przytoczone transformacje:

$$\text{IEMG} = \sum_{i=1}^n |x_i|, \quad (4.4)$$

$$\text{MAV1} = \frac{1}{n} \sum_{i=1}^n w_i |x_i|, \quad (4.5)$$

$$w_i = \begin{cases} 1 & \text{jeżeli } 0,25n \leq i \leq 0,75n \\ 0,5 & \text{jeżeli } 0,25n > i > 0,75n, \end{cases}$$

$$\text{MAV2} = \frac{1}{n} \sum_{i=1}^n w_i |x_i|, \quad (4.6)$$

$$w_i = \begin{cases} 1 & \text{jeżeli } 0,25n \leq i \leq 0,75n \\ 4i/n & \text{jeżeli } i < 0,25n \\ 4(i-n)/n & \text{jeżeli } i > 0,75n, \end{cases}$$

$$\text{SSI} = \sum_{i=1}^n x_i^2, \quad (4.7)$$

$$\text{VAR} = \frac{1}{n-1} \sum_{i=1}^n x_i^2. \quad (4.8)$$

Ciągła transformata falkowa

Sygnał EMG, jak praktycznie wszystkie biosygnale, jest przykładem niestacjonarnego szeregu czasowego. Podstawę jego analizy stanowią więc metody czasowe, które jednakże nie zawierają wszystkich informacji mogących opisać wszelkie różnice pomiędzy przebiegami. Z powodu charakteru EMG analiza czysto częstotliwościowa jest podejściem nieodpowiednim, dlatego należy poszukiwać alternatyw do niej. Obecnie taką alternatywą jest ciągła transformata falkowa (Continuous Wavelet Transform, CWT) [78].

Transformacja falkowa pozwala na przejście z układu czas-wartość do układu czas-skala (lub czas-częstotliwość), umożliwiając tym samym pełną analizę zmiany częstotliwości w dziedzinie czasu. W przeciwieństwie do popularnej transformacji Fouriera, jest to zatem analiza czasowo-częstotliwościowa, użyteczna w analizie zarówno globalnych, jak i lokalnych cech sygnału.

Transformata falkowa jest wynikiem operacji iloczynu skalarnego badanego sygnału i funkcji ciągłej, zawartej w dziedzinach czasu oraz częstotliwości, zwanej falką. Falki stanowią jądro przekształcenia wykonywanych operacji, które opierają się na zbiorze składającym się z przebiegu podstawowego (nazywanego falką matką) oraz jego kopiami przesuniętymi w czasie oraz



rozciągniętymi bądź ściśniętymi na osi czasu (falki córki).

CWT sygnału $s(t)$ z wykorzystaniem falki głównej $\Psi(t)$ jest otrzymywana poprzez zastosowanie następującego przekształcenia całkowego:

$$\tilde{s}_{\Psi}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} s(t) \Psi\left(\frac{t-b}{a}\right) dt, \quad (4.9)$$

gdzie: a – parametr skali, b – parametr przesunięcia, $\Psi\left(\frac{t-b}{a}\right)$ – jądro transformacji falkowej.

Ze względu na swój charakter, istnieje teoretycznie nieskończenie wiele falek możliwych do wykorzystania w CWT. Standardowo jednak używa się jednej z wielu rodzin falek opisanych w literaturze [79]. W przedstawionej analizie sygnałów EMG, z uwagi na dostępność implementacji danych funkcji w wykorzystanej bibliotece programistycznej, zdecydowano się ograniczyć do następujących: pochodna gaussowska zespolona 8 (Complex Gaussian 8 Wavelet, CGAU8), Morleta zespolona (Complex Morlet Wavelet, CMOR), sklejki częstotliwości (Frequency B-Spline Wavelet, FBSP), pochodna gaussowska 8 (Gaussian 8 Wavelet, GAUS8), Rickera (często nazywana w nomenklaturze angielskiej Mexican Hat, MEXH), Morleta (MORL) i Shannona (SHAN). Ponadto, liczba poziomów skali we wszystkich transformatach była stała i wynosiła 128.

4.4.2. Metody sztucznej inteligencji

Algorytm k najbliższych sąsiadów

Algorytm k najbliższych sąsiadów (K -Nearest Neighbors, KNN) jest nieparametrycznym algorytmem wykorzystywanym w zadaniach klasyfikacji i regresji [80]. Należy on do grupy metod uczenia bazującego na przykładach, co zwykle łączone jest równocześnie z algorytmami tzw. uczenia leniwego (Lazy Learning), w których funkcja aproksymowana jest jedynie lokalnie, a wszystkie obliczenia są odroczone do chwili wnioskowania. Algorytm ten charakteryzuje się zatem brakiem modelu i generowaniem wyniku bezpośrednio z danych, co zalicza go jako jedną z najmniej złożonych metod uczenia maszynowego.

Głównym założeniem KNN jest to, że równoważne sobie wektory n cech, bądź zmiennych objaśniających, mają bardzo zbliżone wartości, a więc punkty w n -wymiarowej przestrzeni o współrzędnych odpowiadających tym wektorom są położone stosunkowo blisko siebie.

Etap nauczania ogranicza się jedynie do umieszczenia punktów odpowiadającym wektorom ze zbioru uczącego w przestrzeni rozwiązań i zapisaniu informacji o ich klasie lub wartości zmiennej objaśnianej. W etapie wnioskowania daną obserwację (np. element zbioru testującego) pozycjonuje się w tej samej przestrzeni, a następnie pobieranych jest k najbliższych jej sąsiadujących punktów zbioru uczącego, gdzie $k \in \mathbb{N}_+$ jest ustalonym z góry parametrem. Dalsze kroki zależą od rodzaju wybranej metody wnioskowania, a przedstawiają się następująco:

- dla klasyfikacji – odczytywane są klasy wybranych sąsiadów i określana jest klasa dominująca wśród nich, tj. klasa, do której przynależy największa liczba wytypowanych sąsiadów, a testowanej obserwacji przyporządkowuje się klasę dominującą,

- dla regresji – odczytywane są wartości zmiennych objaśnianych wybranych sąsiadów, a testowanej obserwacji przyporządkowuje się ich średnią arytmetyczną lub medianę.

Wybór k najbliższych sąsiadów odbywa się na podstawie odpowiedniej metryki, której zadaniem jest ocena odległości pomiędzy punktami reprezentującymi dwie obserwacje. Zazwyczaj jest to metryka euklidesowa, ale stosuje się również odległość Mahalanobisa lub odległość Hamminga.

Drzewa decyzyjne

Drugim przykładem nieparametrycznej maszyny uczącej wykorzystanej w opisywanych badaniach jest metoda o nazwie drzewa decyzyjne (Decision Trees, DT) [81]. Reprezentacja wiedzy takiego systemu bazuje na idei drzewa decyzyjnego – acyklicznego spójnego grafu skierowanego – będącego metodą graficznego wspomaganie podejmowania decyzji. Drzewo takie podzielone jest na trzy elementy: korzeń, zbiór gałęzi oraz zbiór liści. Korzeń stanowi punkt początkowy wykonywania algorytmu, od którego gałęzie prowadzą do kolejnych węzłów, w których sprawdzany jest pewien zdefiniowany wcześniej warunek dotyczący danej obserwacji. Na podstawie wyniku w węźle wybierana jest następna gałąź aż cały proces dotrze do jednego z węzłów końcowych – liści, czyli zakończeń każdego rozgałęzienia. Liście w tym procesie reprezentują ostateczną decyzję podjętą na podstawie serii testów zmiennych danej obserwacji.

Łatwo zauważyć, że opisany powyżej algorytm składa się tylko z warunkowych instrukcji sterujących i znajduje swoją analogię w instrukcjach `if-else` znanych z komputerowych języków programowania. Ten sposób modelowania wykorzystywany jest w przeprowadzaniu operacji klasyfikacji i regresji (noszących miano drzew klasyfikacyjnych i drzew regresyjnych), co jest odmianą hierarchicznej analizy skupień oraz przykładem tzw. algorytmu zachłannego (Greedy Algorithm).

DT mogą być przygotowane „ręcznie” poprzez narysowanie odpowiedniego grafu bądź opracowanie tabeli obserwacji i zmiennych. Istnieją jednak specjalistyczne algorytmy statystyczne, które w sposób zautomatyzowany dzielą dane, tworząc kolejne węzły drzewa, a następnie przeprowadzają proces wnioskowania. Jednym z takich algorytmów, użytym na potrzeby niniejszej rozprawy w wersji zoptymalizowanej, jest CART (Classification and Regression Trees). Odnosny algorytm można opisać za pomocą równań matematycznych [72]. Mając zatem wektory treningowe $\mathbf{x}_i \in \mathbb{R}^n$, $i = 1, 2, \dots, l$ oraz wektor etykiet $\mathbf{y} \in \mathbb{R}^l$, drzewo decyzyjne rekurencyjnie dzieli przestrzeń tak, że próbki z tymi samymi etykietami są zgrupowane razem. Dane zawarte w węźle m oznaczane są przez Q . Dla każdego z kandydatów $\theta = (j, t_m)$ zawierającego cechę j i próg t_m należy przeprowadzić dodatkowo podział danych na podzbiory $Q_{lewy}(\theta)$ oraz $Q_{prawy}(\theta)$ tak, że:

$$\begin{aligned} Q_{lewy}(\theta) &= (x, y) \mid x_j \leq t_m, \\ Q_{prawy}(\theta) &= Q \setminus Q_{lewy}(\theta). \end{aligned} \quad (4.10)$$

Zanieczyszczenie w m , przedstawione we wzorze (4.11), obliczane jest dla N_m obserwacji przez użycie funkcji zanieczyszczenia H , której postać jest zależna od zadania, które dana maszyna ucząca wykonuje (klasyfikacja lub regresja). Następnie wybierane są parametry minimalizujące owe

zanieczyszczenie (4.12). Całość operacji wykonywana jest rekurencyjnie, poszukując podzbiorów $Q_{lewy}(\theta^*)$ i $Q_{prawy}(\theta^*)$, aż do chwili osiągnięcia maksymalnej dopuszczalnej głębokości drzewa, kiedy $N_m < \min_{\text{próbki}}$ lub gdy $N_m = 1$.

$$G(Q, \theta) = \frac{n_{lewy}}{N_m} H(Q_{lewy}(\theta)) + \frac{n_{prawy}}{N_m} H(Q_{prawy}(\theta)) \quad (4.11)$$

$$\theta^* = \arg \min_{\theta} G(Q, \theta) \quad (4.12)$$

Jeżeli od systemu oczekuje się wyniku klasyfikacji przyjmującego wartości z przedziału $\{0, 1, \dots, K-1\}$, to dla węzła m , reprezentującego region R_m , wzór (4.13) oznacza proporcję obserwacji klasy k w tym węźle.

$$p_{mk} = 1/N_m \sum_{x_i \in R_m} I(y_i = k) \quad (4.13)$$

Mając powyższy współczynnik p_{mk} , zanieczyszczenie w węźle przy danych uczących X_m można oszacować następującymi miarami: funkcją Giniego (4.14), entropią krzyżową (4.15) lub miarą błędu klasyfikacji (4.16).

$$H(X_m) = \sum_k p_{mk} (1 - p_{mk}) \quad (4.14)$$

$$H(X_m) = - \sum_k p_{mk} \log(p_{mk}) \quad (4.15)$$

$$H(X_m) = 1 - \max(p_{mk}) \quad (4.16)$$

W przypadku problemu regresji popularnymi miarami, których wartości są minimalizowane, do określania lokalizacji przyszłych kandydatów są: błąd średniokwadratowy (4.17), który minimalizuje błąd ℓ^2 , używając wartości średnich w węzłach końcowych oraz średni błąd bezwzględny (4.18), którym minimalizuje się błąd ℓ^1 , używając median w węzłach końcowych.

$$c_m = \frac{1}{N_m} \sum_{i \in N_m} y_i, \quad (4.17)$$

$$H(X_m) = \frac{1}{N_m} \sum_{i \in N_m} (y_i - c_m)^2$$

$$\bar{y}_m = \frac{1}{N_m} \sum_{i \in N_m} y_i, \quad (4.18)$$

$$H(X_m) = \frac{1}{N_m} \sum_{i \in N_m} |y_i - \bar{y}_m|$$

Maszyna wektorów nośnych

Maszyna wektorów nośnych (Support Vector Machines, SVM) jest liniowym klasyfikatorem binarnym, którego nauka zakłada wyznaczenie hiperpłaszczyzny dzielącej z maksymalnym marginesem obserwacje przynależące do dwóch klas [82, 83]. SVM należy do rodziny uogólnionych

liniowych klasyfikatorów i może być interpretowana jako rozszerzenie perceptronu. Szczególną właściwością jest to, że metoda ta jednocześnie minimalizuje błąd klasyfikacji empirycznej i maksymalizuje margines geometryczny, co jest powodem nazywania jej klasyfikatorem maksymalnego marginesu.

Model SVM jest, podobnie jak KNN, reprezentacją punktów oznaczających na podstawie wartości wektorów cech współrzędne w przestrzeni wielowymiarowej. W odróżnieniu jednak od KNN, proces uczenia SVM składa się również z etapu mapowania tychże punktów w taki sposób, aby obserwacje należące do oddzielnych kategorii były przedzielone jak najszerzą przerwą w przestrzeni. Przerwa ta określana jest na podstawie hiperpłaszczyzny, której parametry są wyznaczane przez odpowiedni algorytm w trakcie uczenia. Nowe obserwacje są więc mapowane do tej samej przestrzeni, a ich klasa określana jest na podstawie lokalizacji względem przerwy.

Każda hiperpłaszczyzna może być zapisana jako zbiór punktów \mathbf{x} spełniających warunek

$$\mathbf{w} \cdot \mathbf{x} - b = 0, \quad (4.19)$$

gdzie: \mathbf{w} – wektor normalny do hiperpłaszczyzny, b – pewien współczynnik.

Można zatem zdefiniować dwie równoległe hiperpłaszczyzny, które oddzielają dane należące do dwóch klas tak, aby odległość między płaszczyznami była jak największa. Przestrzeń pomiędzy tymi hiperpłaszczyznami nazywana jest marginesem, a hiperpłaszczyznę znajdującą się pośrodku (4.19) określa się wówczas jako posiadającą maksymalny margines. Hiperpłaszczyzny oznaczające margines równają się wartości 1 oraz -1 , a punkty przynależące do poszczególnych klas znajdują się powyżej pierwszej lub poniżej drugiej.

Operacja klasyfikacji wykonywana przez SVM bywa nazywana klasyfikacją wektorów nośnych (Support Vector Classification, SVC), a jej najnowsze implementacje korzystają ze zmodyfikowanych modeli i algorytmów, które usprawniają efektywność uczenia oraz umożliwiają rozwiązywanie bardziej złożonych problemów. Jedną z takich modyfikacji jest zastąpienie powyższej definicji marginesu przez tzw. miękki margines (Soft Margin) [83, 84]. W związku z tym opracowano szereg typów SVC, spośród których można wymienić: C-SVC, ν -SVC i liniową SVC [72].

Proces nauczania i wnioskowania SVC można zdefiniować w następujący sposób. Niech $\mathbf{x}_i \in \mathbb{R}^p$, $i = 1, 2, \dots, n$ będzie nauczającym wektorem cech przynależących do dwóch klas, a $\mathbf{y} \in \{1, -1\}^n$ będzie wektorem oznaczającym te klasy, wtedy C-SVC rozwiązuje następujący problem pierwotny

$$\begin{aligned} \min_{\mathbf{w}, b, \zeta} \quad & \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \zeta_i \\ \text{z warunkami: } & y_i \left(\mathbf{w}^T \phi(\mathbf{x}_i) + b \right) \geq 1 - \zeta_i, \\ & \zeta_i \geq 0, \quad i = 1, \dots, n. \end{aligned} \quad (4.20)$$

Jego forma dualna to

$$\begin{aligned} \min_{\alpha} \frac{1}{2} \alpha^T Q \alpha - \mathbf{e}^T \alpha \\ \text{z warunkami: } \mathbf{y}^T \alpha = 0, \\ 0 \leq \alpha_i \leq C, \quad i = 1, \dots, n, \end{aligned} \quad (4.21)$$

gdzie: \mathbf{e} – wektor jedynek, $C > 0$ – górna granica, Q – dodatnia macierz pół-określona o wielkości $n \times n$, $Q_{ij} \equiv y_i y_j K(\mathbf{x}_i, \mathbf{x}_j)$, $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ – jądro.

W powyższym przekształceniu wektory uczące są niejawnie mapowane do przestrzeni o wyższej wymiarowości przez funkcję ϕ . Ostatecznie, funkcję decyzyjną można zapisać jako

$$\text{sgn} \left(\sum_{i=1}^n y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + \rho \right), \quad (4.22)$$

gdzie: α_i – współczynniki wektora nośnego, ρ – pewne stałe.

Pomimo, że SVM została początkowo opracowana jako metoda liniowa analizująca przypadki binarne, to pewne modyfikacje w algorytmach pozwalają poszerzyć jej zakres działania. Klasyfikacja nieliniowa może być efektywnie wykonywana przy pomocy procesu o nazwie sztuczka jądra (Kernel Trick) wykorzystującego nieliniową funkcję jądra (ϕ) do niejawnego mapowania danych wejściowych na przestrzeń o większej liczbie wymiarów niż oryginalnie.

Ponadto, klasyfikację wieloklasową można umożliwić przez stosowanie odpowiedniej strategii testującej, która zredukuje problem wieloklasowy do wielu problemów binarnych [85]. Takimi strategiami są: jeden kontra jeden (One-Versus-One) oraz jeden kontra reszta (One-Versus-Rest). W pierwszym przypadku konstruowanych jest $c(c-1)/2$ klasyfikatorów (gdzie c jest liczbą klas), a każda nowa obserwacja analizowana jest po kolei przez nie wszystkie. Zastosowana większościowa strategia głosowania nadaje obserwacji klasę, która została wskazana największą liczbą razy. W jeden kontra reszta konstruowanych jest c klasyfikatorów, a w etapie uogólniania, po uprzedniej analizie, stosowana jest strategia zwycięzca bierze wszystko, co oznacza, że przypisuje się klasę wybraną przez klasyfikator z największą wartością funkcji wyjściowej. W badaniach opisanych w niniejszej rozprawie zastosowano C-SVC ze strategią jeden kontra jeden.

SVM może być rozszerzona i dostosowana do rozwiązywania problemów regresji. Modyfikacja tej metody nosi nazwę regresji wektorów nośnych (Support Vector Regression, SVR) [84, 86], a wśród dostępnych implementacji wyróżnia się: ε -SVR, ν -SVR oraz liniową SVR [72].

Do przeprowadzenia eksperymentów wybrano ε -SVR, której działanie można opisać, używając poniższych równań. Mając wektory zmiennych objaśniających $\mathbf{x}_i \in \mathbb{R}^p$, $i = 1, 2, \dots, n$ oraz wektor zmiennych objaśnianych $\mathbf{y} \in \mathbb{R}^n$, ε -SVR rozwiązuje następujący problem pierwotny

$$\min_{\mathbf{w}, b, \zeta, \zeta^*} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n (\zeta_i + \zeta_i^*)$$

z warunkami: $y_i - \mathbf{w}^T \phi(\mathbf{x}_i) - b \leq \varepsilon + \zeta_i,$ (4.23)

$$\mathbf{w}^T \phi(\mathbf{x}_i) + b - y_i \leq \varepsilon + \zeta_i^*,$$

$$\zeta_i, \zeta_i^* \geq 0, \quad i = 1, \dots, n.$$

Jego forma dualna to

$$\min_{\alpha, \alpha^*} \frac{1}{2} (\alpha - \alpha^*)^T Q (\alpha - \alpha^*) + \varepsilon e^T (\alpha + \alpha^*) - \mathbf{y}^T (\alpha - \alpha^*)$$

z warunkami: $e^T (\alpha - \alpha^*) = 0,$ (4.24)

$$0 \leq \alpha_i, \alpha_i^* \leq C, \quad i = 1, \dots, n,$$

gdzie: e – wektor o wartościach równych jedności, $C > 0$ – górna granica, Q – dodatnia pół-określona macierz o wielkości $n \times n$, $Q_{ij} \equiv K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ – jądro. Wektory zmiennych uczących są niejawnie mapowane przez funkcję ϕ do przestrzeni o wyższym wymiarze. Funkcja decyzyjna dla odnośnego problemu jest następująca

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + \rho, \quad (4.25)$$

gdzie: α_i – współczynniki wektora nośnego, ρ – pewne stałe.

Jako funkcji jądra w **SVC** i **SVR** najczęściej używa się jednej z poniższych:

- funkcja liniowa: $\langle x; x' \rangle$,
- funkcja wielomianowa: $(\gamma \langle x; x' \rangle + r)^d$,
- radialna funkcja bazowa: $\exp(-\gamma \|x - x'\|^2)$,
- funkcja sigmoidalna: $\tanh(\gamma \langle x; x' \rangle + r)$.

Ze względu na charakter sygnału **EMG**, funkcja liniowa w jego przypadku stanowi nieodpowiednią podstawę do budowania poprawnego modelu wnioskowania. Spośród pozostałych funkcji wybór *a priori* odpowiedniej dla danego problemu nie jest oczywisty. Automatyczny wybór funkcji jądra i jego parametrów może zaburzyć ocenę wyników modelu i ostatecznie doprowadzić do efektu przeuczenia [87]. Choć powszechnie, ze względu na krzepkość i nieliniowość, jako domyślną funkcję jądra zaleca się radialną funkcję bazową, to w trakcie badań opracowano zestawienie jakości modeli bazujących na wszystkich odnośnych funkcjach w celu dokonania wyboru odpowiedniej dla przedstawionego problemu.

Perceptron wielowarstwowy

Perceptron wielowarstwowy (Multilayer Perceptron, MLP) jest rozszerzeniem perceptronu – sztucznej sieci neuronowej składającej się z pewnej liczby niezależnych neuronów McCullocha-Pittsa [88]. Sieć ta zbudowana jest z jednej warstwy wejściowej, jednej warstwy wyjściowej oraz

jednej lub wielu warstw ukrytych, znajdujących się pomiędzy wejściem a wyjściem systemu. Warstwa wejściowa złożona jest z liczby neuronów odpowiadającej liczbie danych wejściowych (cech bądź zmiennych objaśniających). Budowa warstwy wyjściowej uzależniona jest od wyboru sposobu modelowania procesu, choć standardowo zakłada jeden neuron wyjściowy wskazujący pojedynczą wartość liczbową jako wynik wnioskowania sieci. Dobór warstw ukrytych jest z kolei nietrywialny i niekiedy wiąże się z przeprowadzaniem wielokrotnych testów strojenia.

Każdy neuron może posiadać wiele wejść i jedną wartość wyjściową, a parametrami przypisywanymi do niego są: wagi jego wejść oraz funkcja aktywacji. Neuron McCullocha-Pittsa przeprowadza dwie operacje. Początkowo, wykonywane jest działanie sumy ważonej wejść neuronu, do wyniku dodając również wartość proggu. Następnie rezultat ten jest przekształcany przez funkcję aktywacji, co stanowi wynik działania neuronu. Pojedynczy neuron przekazuje swoją odpowiedź na wejście wszystkich neuronów warstwy dalszej.

Wartości wag początkowo są ustalane losowo. MLP minimalizuje funkcję strat (Loss Function) przez wielokrotne aktualizowanie wag poszczególnych neuronów. Po obliczeniu straty, jej wartość jest propagowana z warstwy wyjściowej do poprzednich warstw, uaktualniając każdy parametr wagi celem zmniejszenia wartości straty, co nazywane jest procesem wstecznej propagacji błędów (Backpropagation). Algorytm zatrzymuje się, gdy osiągnie ustaloną, maksymalną liczbę iteracji, lub gdy nie nastąpi poprawa strat większa niż pewna, z reguły mała wartość.

Podstawową definicję matematyczną MLP można podać w sposób opisany w pracy [72]. Mając zatem zbiór próbek uczących $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, gdzie $\mathbf{x}_i \in \mathbb{R}^n$ oraz $y_i \in \{0, 1\}$, MLP z jedną warstwą ukrytą zawierającą jeden neuron naucza się funkcji

$$f(\mathbf{x}) = W_2 g(W_1^T \mathbf{x} + b_1) + b_2, \quad (4.26)$$

gdzie: $W_1 \in \mathbb{R}^m$ – wagi warstwy wejściowej, $W_2 \in \mathbb{R}$ – waga warstwy ukrytej, $b_1 \in \mathbb{R}$ – próg aktywacji warstwy wejściowej, $b_2 \in \mathbb{R}$ – próg aktywacji warstwy ukrytej, $g(\cdot) : \mathbb{R} \rightarrow \mathbb{R}$ – funkcja aktywacji neuronu.

W przypadku klasyfikacji binarnej jako funkcję aktywacji neuronów warstwy wyjściowej stosuje się logistyczną funkcję sigmoidalną $g(z) = 1/(1 + e^{-z})$ by uzyskać wartości wyjściowe z przedziału (0; 1). Próg równy 0,5 będzie wtedy przydzielał obserwacjom o wartości wyjściowej 0,5 bądź większej klasę 1, a pozostałym – klasę 0. Dla liczby klas k większej niż dwie $f(\mathbf{x})$ staje się wektorem o wielkości k , a zamiast funkcji logistycznej wykorzystywana jest funkcja softmax

$$\text{softmax}(z)_i = \frac{\exp(z_i)}{\sum_{l=1}^k \exp(z_l)}, \quad (4.27)$$

gdzie: z_i – i -ty element wejścia funkcji softmax (odpowiadający i -tej klasie).

Wynikiem operacji jest wektor zawierający wartości prawdopodobieństwa przynależności próbki x do poszczególnych klas. Ostatecznie, wybierana jest klasa o najwyższej wartości tego współczynnika.

MLP używa różnych funkcji strat w zależności od podejmowanego problemu. W opisywanym modelu wykorzystano funkcję entropii krzyżowej (cross entropy), która dla przypadku klasyfikacji binarnej przybiera następującą formę

$$L(\hat{y}, y, W) = -y \ln \hat{y} - (1 - y) \ln(1 - \hat{y}) + \alpha \|W\|_2^2, \quad (4.28)$$

gdzie: $\alpha \|W\|_2^2$ – zwrot regulujący ℓ^2 (kara), który karze złożone modele, $\alpha > 0$ – hiperparametr kontrolujący wielkość kary.

MLP rozwiązujący problem regresji używa funkcji tożsamościowej jako funkcji aktywacji warstwy wyjściowej, zatem jego odpowiedź równa się $f(x)$. Zmiany obejmują również funkcję strat, którą jest błąd kwadratowy zdefiniowany jako

$$L(\hat{y}, y, W) = \frac{1}{2} \|\hat{y} - y\|_2^2 + \frac{\alpha}{2} \|W\|_2^2. \quad (4.29)$$

Optymalizacja sieci, tj. minimalizacja funkcji strat L poprzez dobór odpowiednich wartości wag W , odbywa się za pomocą metody gradientu prostego (Gradient Descent). W każdej iteracji algorytmu, obliczony w odniesieniu do aktualnych wag sieci, gradient strat ∇L_W jest odejmowany od W , a nowe wartości wag przypisywane są wedle poniższego wzoru

$$W^{i+1} = W^i - \epsilon \nabla L_W^i, \quad (4.30)$$

gdzie: i – krok iteracji, $\epsilon > 0$ – wskaźnik uczenia się.

Do określania funkcji aktywacji neuronów warstw ukrytych **MLP** stosuje się z reguły jedną z poniższych funkcji:

- tożsamościową: x ,
- logistyczną sigmoidalną: $1/(1 + e^{-x})$,
- tangensa hiperbolicznego: $\tanh x$,
- rektyfikowaną liniową: $\max(0; x)$.

4.4.3. Metody statystyczne i miary błędu

Metryki klasyfikacji

Dokładność Dokładność (Accuracy, ACC) jest podstawową miarą klasyfikacji. Pokazuje ona średnią liczbę prawidłowo sklasyfikowanych próbek. Wartości **ACC** mieszczą się w przedziale $\langle 0; 1 \rangle$, gdzie 1 oznacza, że wszystkie próbki zostały prawidłowo oznaczone, a 0 – iż maszyna ucząca nie sklasyfikowała prawidłowo ani jednej próbki. Jeżeli \mathbf{y} jest wektorem n rzeczywistych klas zbioru, a $\hat{\mathbf{y}}$ jest wektorem n tożsamości teoretycznych klas (odpowiedzi klasyfikatora), to **ACC** można zdefiniować następująco

$$\text{ACC}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{n} \sum_{i=1}^n 1(\hat{y}_i = y_i), \quad (4.31)$$

gdzie: $1(x)$ – funkcja charakterystyczna zbioru.

Miara F_1 Jednymi z kilku miar jakości predykcyjnej testu, które ukazują stopień, w jakim dana metoda klasyfikuje próbki pozytywne i negatywne, są precyzja (Precision) oraz czułość (Recall). Precyzja (4.32) jest zdolnością klasyfikatora do nieprzyznania próbce ujemnej etykiety dodatniej. Ukazuje ona stosunek obserwacji prawidłowo rozpoznanych jako klasa poszukiwana do wszystkich próbek sklasyfikowanych jako ta klasa, czyli zależność pomiędzy liczbą wyników prawdziwie dodatnich t_p a ogólną liczbą wyników dodatnich (sumą prawdziwie dodatnich i fałszywie dodatnich f_p). Czułość (4.33) z kolei jest umiejętnością klasyfikatora do znalezienia wszystkich dodatnich próbek. Oznacza więc ułamek obserwacji dobrze sklasyfikowanych jako szukana klasa wśród wszystkich obserwacji klasy poszukiwanej, a więc zależność pomiędzy wynikami prawdziwie dodatnimi a sumą wyników prawdziwie dodatnich i fałszywie ujemnych f_n .

$$P = \frac{t_p}{t_p + f_p} \quad (4.32)$$

$$R = \frac{t_p}{t_p + f_n} \quad (4.33)$$

Precyzja i czułość modelu klasyfikacji mogą zostać rozważone podczas pojedynczego testu, zwanego miarą F_1 (F_1 Score, F1). F_1 jest średnią harmoniczną precyzji i czułości, która dostarcza wartości z przedziału $\langle 0; 1 \rangle$, dla którego 1 jest wartością najlepszą. Metrykę tą oblicza się na podstawie następującego wzoru

$$F1 = 2 \cdot \frac{P \cdot R}{P + R}. \quad (4.34)$$

Metryki regresji

Średni błąd bezwzględny Średni błąd bezwzględny (Mean Absolute Error, MAE) jest miarą różnicy pomiędzy dwiema zmiennymi rzeczywistymi, używaną powszechnie w ocenie działania regresji. Jest to w istocie metryka ryzyka odpowiadająca oczekiwanej wartości straty błędu bezwzględnego, czyli straty normy ℓ^1 . Idealną wartością MAE jest 0. Jeżeli $\mathbf{y} \in \mathbb{R}^n$ jest wektorem n rzeczywistych wartości zmiennych objaśnianych, zaś $\hat{\mathbf{y}} \in \mathbb{R}^n$ jest odpowiadającym mu wektorem wartości teoretycznych zmiennych objaśnianych, to metryka MAE posiada następującą formę

$$MAE(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (4.35)$$

Najmniejsze kwadraty logarytmu współczynnika dokładności Najmniejsze kwadraty logarytmu współczynnika dokładności (Least Squares Log of Accuracy Ratio, LSLQ) są względną miarą dokładności działania modeli regresyjnych, będącą alternatywą do jednej z bardziej powszechnych miar – średniego bezwzględnego błędu procentowego (Mean Absolute Percentage Error, MAPE) [89, 90]. MAPE jest metryką stronniczą, która spośród ocenianych metod predykcji systematycznie faworyzuje te, których prognozy są zbyt niskie. Prowadzi to do powstawania

modeli, które niedoszacowują wartości zmiennych objaśnianych, a ich prognozy nie są powiązane z prostą statystyką lub miarą położenia. Błędu tego pozbawiony jest logarytm współczynnika dokładności, a dodatkowe poddanie go metodzie najmniejszych kwadratów powoduje, że modele wybrane na jego podstawie będą przewidywać wartości poniżej średniej arytmetycznej, jednocześnie będąc bardziej odpornymi na obserwacje odstające. **LSLQ** są miarą błędu, dlatego w najlepszym przypadku wynikiem oceny będzie liczba 0.

Mając wektor n rzeczywistych wartości zmiennych objaśnianych $\mathbf{y} \in \mathbb{R}^n$ oraz wektor n wartości teoretycznych zmiennych objaśnianych $\hat{\mathbf{y}} \in \mathbb{R}^n$, wzór na błąd **LSLQ** jest następujący

$$\text{LSLQ}(\mathbf{y}, \hat{\mathbf{y}}) = \sum_{i=1}^n [\ln(\hat{y}_i/y_i)]^2. \quad (4.36)$$

4.4.4. Algebra kwaternionów

Kwaterniony to struktura algebraiczna będąca rozszerzeniem ciała liczb zespolonych [91, 92]. Algebrę kwaternionów (\mathbb{H}) wprowadził w roku 1843 William Rowan Hamilton – irlandzki matematyk, fizyk i astronom, znany ze swoich przełomowych prac dotyczących mechaniki klasycznej, optyki, czy algebry. Kwaterniony są aktualnie traktowane jako czterowymiarowa, unormowana algebra z dzieleniem nad liczbami rzeczywistymi, a więc \mathbb{H} może być uznana za dziedzinę.

Każdy kwaternion q może być zdefiniowany jako macierz z przestrzeni $M_2(\mathbb{C})$ postaci

$$\mathbf{q} = \begin{bmatrix} r & s \\ -\bar{s} & \bar{r} \end{bmatrix}, \quad (4.37)$$

gdzie: r, s – dowolne liczby zespolone.

Można zatem powyższą macierz przedstawić w postaci

$$\mathbf{q} = \begin{bmatrix} w + jx & y + jz \\ -y + jz & w - jx \end{bmatrix}, \quad (4.38)$$

gdzie: $w, x, y, z \in \mathbb{R}$.

Jeżeli wprowadzone zostaną dodatkowe oznaczenia:

$$\mathbf{i} = \begin{bmatrix} j & 0 \\ 0 & -j \end{bmatrix}, \quad \mathbf{j} = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}, \quad \mathbf{k} = \begin{bmatrix} 0 & j \\ j & 0 \end{bmatrix}, \quad \mathbf{p} = \begin{bmatrix} p & 0 \\ 0 & p \end{bmatrix}, \quad p \in \mathbb{R}, \quad (4.39)$$

to dowolny kwaternion można również zapisać w sposób

$$q = w + x\mathbf{i} + y\mathbf{j} + z\mathbf{k}. \quad (4.40)$$

Współczynniki x, y i z związane z podstawowymi jednostkami kwaternionu \mathbf{i}, \mathbf{j} i \mathbf{k} można zapisać w postaci trójwymiarowego wektora $\mathbf{v} = (x, y, z)$, co prowadzi do możliwości wyznaczenia kwaternionu jako pary rzeczywistej wielkości skalarnej oraz trójwymiarowego wektora wielkości rzeczywistych związanych z tzw. częścią urojoną kwaternionu

$$q = (w, \mathbf{v}) \equiv (w + \mathbf{v}), \quad q \in \mathbb{H}, w \in \mathbb{R}, \mathbf{v} \in \mathbb{R}^3. \quad (4.41)$$

Najważniejszym działaniem, które przeprowadza się na kwaternionach jest mnożenie. Działanie to jest łączne, ale w przeciwieństwie do mnożenia skalarów, nie jest przemienne. Zachodzą również rozdzielności mnożenia względem dodawania. Niżej podane wzory (4.42) i (4.43) rozwijają działanie mnożenia według notacji ukazanych we wzorach, odpowiednio, (4.40) i (4.41). Ponadto, odwrotność kwaternionu definiuje się wedle wzoru (4.44).

$$\begin{aligned} (w_1 + x_1\mathbf{i} + y_1\mathbf{j} + z_1\mathbf{k})(w_2 + x_2\mathbf{i} + y_2\mathbf{j} + z_2\mathbf{k}) &= w_1w_2 - x_1x_2 - y_1y_2 - z_1z_2 \\ &+ (w_1x_2 + x_1w_2 + y_1z_2 - z_1y_2)\mathbf{i} \\ &+ (w_1y_2 - x_1z_2 + y_1w_2 + z_1x_2)\mathbf{j} \\ &+ (w_1z_2 + x_1y_2 - y_1x_2 + z_1w_2)\mathbf{k} \end{aligned} \quad (4.42)$$

$$(w_1, \mathbf{v}_1)(w_2, \mathbf{v}_2) = (w_1w_2 - \mathbf{v}_1 \cdot \mathbf{v}_2, w_1\mathbf{v}_2 + w_2\mathbf{v}_1 + \mathbf{v}_1 \times \mathbf{v}_2) \quad (4.43)$$

$$q^{-1} = \frac{q^*}{\|q\|^2} = \frac{w - x\mathbf{i} - y\mathbf{j} - z\mathbf{k}}{w^2 + x^2 + y^2 + z^2} = \frac{(w, -\mathbf{v})}{(w^2, \|\mathbf{v}\|^2)} \quad (4.44)$$

Kwaterniony pierwotnie służyły opisowi mechaniki w przestrzeni trójwymiarowej, a w dzisiejszych czasach są nadal podstawą przekształceń rotacji, m.in. w grafice komputerowej. W pojęciu geometrycznym kwaternion może być rozumiany jako kąt i oś obrotu, gdzie, odwołując się do notacji skalarno-wektorowej (4.41), w oznacza kąt obrotu, a \mathbf{v} definiuje oś, wokół której obrót ten jest wykonywany.

Notacja osiowo-kątowa kwaternionu nie jest jednak bezpośrednio wyprowadzana z powyższych zależności. Jeżeli przyjąć, iż α reprezentuje kąt obrotu, a $\mathbf{u} = (u_x, u_y, u_z) = u_x\mathbf{i} + u_y\mathbf{j} + u_z\mathbf{k}$ jest wektorem jednostkowym definiującym oś, to postać kwaternionu opisującego obrót osiowo-kątowy jest następująca

$$q = \left(\cos \frac{\alpha}{2}, \mathbf{u} \sin \frac{\alpha}{2} \right) = \left[\cos \frac{\alpha}{2}, \left(u_x \sin \frac{\alpha}{2}, u_y \sin \frac{\alpha}{2}, u_z \sin \frac{\alpha}{2} \right) \right]. \quad (4.45)$$

Ponieważ część wektorowa kwaternionu jest wektorem w przestrzeni \mathbb{R}^3 , geometria ta jest odzwierciedlona w strukturze algebraicznej kwaternionów. Wiele operacji na wektorach można więc przedstawić w postaci kwaternionów, co umożliwi stosowanie tej metodyki wszędzie tam, gdzie wykorzystywane są wektory przestrzenne. Dowolny punkt (o_x, o_y, o_z) w przestrzeni trójwymiarowej odpowiadać będzie kwaternionowi $o = [0, (o_x, o_y, o_z)]$. Niech q będzie kwaternionem w notacji osiowo-kątowej (4.45). Obrót wokół osi \mathbf{u} o kąt α punktu reprezentowanego przez kwaternion o można wykonać poprzez następujące działanie

$$o' = qoq^{-1} = \left(\cos \frac{\alpha}{2} + \mathbf{u} \sin \frac{\alpha}{2} \right) o \left(\cos \frac{\alpha}{2} - \mathbf{u} \sin \frac{\alpha}{2} \right) = o_{\perp} \cos \alpha + (\mathbf{u} \times o) \sin \alpha + o_{\parallel}, \quad (4.46)$$

gdzie: o_{\perp} – składniki o prostopadłe do \mathbf{u} , o_{\parallel} – składniki o równoległe do \mathbf{u} .

Wykonanie dwóch następujących po sobie obrotów, najpierw o kwaternion q , a następnie o p , można sprowadzić do pojedynczej operacji obrotu o kwaternion będący iloczynem pq (4.47). Jest to przykład na jedną z korzystnych właściwości operowania w przestrzeni \mathbb{H} , tj. prostego łączenia obrotów poprzez mnożenie kolejnych kwaternionów.

$$o' = p(qoq^{-1})p^{-1} = pqoq^{-1}p^{-1} = pqo(pq)^{-1} \quad (4.47)$$

Do pozostałych zalet stosowania kwaternionów w przekształceniach obrotów należy zaliczyć:

- szybką inwersję obrotów,
- bardziej efektywną normalizację (normowane są jedynie 4 składowe),
- szybką konwersję do/z macierzy obrotu,
- płynną interpolację obrotów,
- zużywanie mniejszej ilości pamięci procesowej w porównaniu do macierzy obrotu.

Rozdział 5

Wyniki i dyskusja

5.1. Analiza ruchu kończyn i aktywności bioelektrycznej mięśni

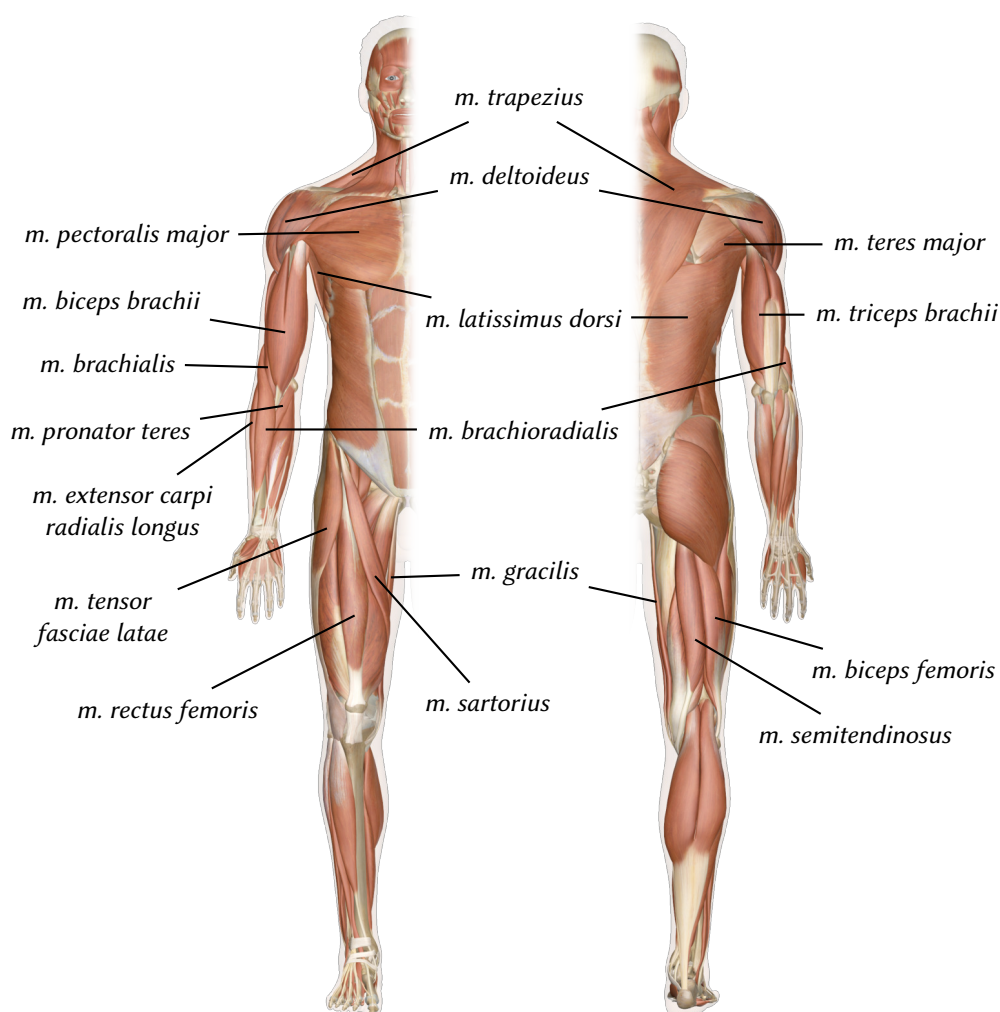
5.1.1. Badania ruchomości stawów

Mięśnie, których aktywność została zarejestrowana i zbadana (rys. 5.1) wyselekcjonowano na podstawie opisów anatomicznych definiujących poszczególne ruchy kończyny górnej i dolnej [23]. Z powodu ograniczeń fizjologicznych (określających udział mięśni w poszczególnych warstwach: powierzchniowej, pośredniej i głębokiej, w wytwarzaniu wypadkowych momentów) liczba badanych mięśni została ograniczona do niezbędnego minimum. Szczególną uwagę przywiązano więc do tych mięśni, których aktywność opisuje możliwie szeroki zakres ruchów. Dodatkowym czynnikiem wyboru była wielkość brzuśców mięśniowych, ponieważ fizjonomia dzieci (zwłaszcza o słabo wykształconych mięśniach) jest utrudnieniem w umieszczaniu elektrod (z uwagi na ich wielkość).

Przedstawione w rozdziale 4.4.1 charakterystyki filtrów (rys. 4.15 i 4.16) są efektem serii testów wykonanych w celu wyłonienia ich rodzajów odpowiednich dla wstępnego przetworzenia analizowanych sygnałów. Rysunek 5.2 ukazuje efekt działania środkowoprzepustowego filtra danych EMG. Dla niefiltrowanego przebiegu widać wyraźną dominację składowych o niskich częstotliwościach (rys. 5.2b), które nie zawierają informacji użytecznej o sygnale EMG. Można także zauważyć zwiększoną moc składowej 50 Hz, odpowiadającej częstotliwości sieci elektrycznej. Zastosowanie filtra Butterwortha zmienia całkowicie charakterystykę sygnału, pozostawiając jedynie informacje zawarte w paśmie 10–49 Hz, ze znacznie zmniejszonym wpływem częstotliwości sieci (rys. 5.2d).

Rysunek 5.3 dokumentuje, że filtracja danych rotacji jest również wymagana. Zastosowana do rejestracji ruchu kamera Kinect charakteryzuje się minimalną wymaganą dokładnością i odpornością na błędy, dlatego na oryginalnym przebiegu rotacji (rys. 5.3a) można zauważyć wiele krótkich skoków wartości szczytowych spowodowanych chwilowymi błędami w estymacji pozycji znaczników kamery. Widmo sygnału (rys. 5.3b) wykazuje niewielkie, ale liczne składowe






Rysunek 5.1. Położenie mięśni zbadanych podczas eksperymentu [93]

częstotliwości, które są niemożliwe do uzyskania przez ruch kończyny ludzkiej. Ponadto, biorąc pod uwagę fakt, iż wszystkie ruchy wykonywane w trakcie eksperymentów przez osoby badane były relatywnie wolne, podkreśla się potrzebę ich wygładzenia. Efektem tej procedury było zastosowanie filtracji dolnoprzepustowej (rys. 5.3c), w wyniku której uzyskano dane wygładzone i prawie całkowicie pozbawione zakłóceń. Przebieg w takiej formie w sposób satysfakcjonujący reprezentuje rzeczywisty ruch znacznika wokół rozpatrywanego stawu.

Kończyna górna została zbadana pod kątem analizy wyselekcjonowanych typów ruchomości w stawach: ramiennym (łac. *articulatio humeri*) oraz łokciowym (łac. *articulatio cubiti*). W trakcie testów wykonywanych przez wolontariuszy cierpiących na PCI uwzględniono dodatkowo efektywność poruszania jedną ręką przy zmiennym obciążeniu: lekkim oraz ciężkim. Poniżej wyszczególniono wszystkie typy ruchów kończyny górnej, których analizę umieszczono w rozprawie:


- odwodzenie i przywodzenie w stawie ramiennym,
- zgięcie do przodu i wyprost do tyłu w stawie ramiennym,
- zginanie i prostowanie w stawie łokciowym,
- rzucanie przedmiotem.



Rysunek 5.2. Porównanie naturalnego przebiegu EMG oraz przebiegu wstępnie przefiltrowanego: **a)** sygnał otrzymany z elektromiografu; **b)** widmo rzeczywistego sygnału; **c)** przebieg po filtracji; **d)** widmo przefiltrowanego sygnału

Podczas ruchu w stawie ramiennym gromadzono przebiegi aktywności mioelektrycznej następujących mięśni:

- trójgłowego ramienia (łac. *m. triceps brachii*),
- obłego większego (łac. *m. teres major*),
- najszerszego grzbietu (łac. *m. latissimus dorsi*),
- naramiennego (łac. *m. deltoideus*),
- dwugłowego ramienia (łac. *m. biceps brachii*),
- piersiowego większego (łac. *m. pectoralis major*),
- czworobocznego (łac. *m. trapezius*).



Rysunek 5.3. Porównanie szeregów czasowych współrzędnych kwaternionowych pozyskanych z kamery Kinect oraz efektu ich filtracji: **a)** oryginalny przebieg rotacji; **b)** widmo oryginalnego przebiegu; **c)** przebieg po filtracji; **d)** widmo przefiltrowanego przebiegu

Ruch w stawie łokciowym odwzorowano z kolei na podstawie aktywności następujących mięśni:

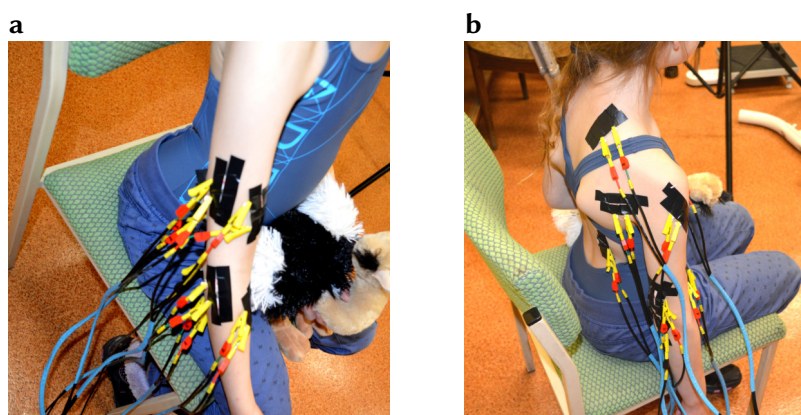
- dwugłowego ramienia (łac. *m. biceps brachii*),
- prostownika promieniowego długiego nadgarstka (łac. *m. extensor carpi radialis longus*),
- trójgłowego ramienia (łac. *m. triceps brachii*),
- ramiennego (łac. *m. brachialis*),
- ramiennie-promieniowego (łac. *m. brachioradialis*),
- nawrotnego obłego (łac. *m. pronator teres*).

Z powodu złożoności ruchu kończyny górnej (dwa stawy i pięć stopni swobody, pomijając dłoń), jednoczesne zgromadzenie pomiarów aktywności wszystkich wyżej wymienionych mięśni z punktu widzenia procesu analizy było niewykonalne. Dlatego ograniczono liczbę badanych mięśni do najważniejszych, które biorą udział w ruchu zarówno stawu ramiennego, jak i łokciowego, tj. mięśni:


- dwugłowego ramienia (łac. *m. biceps brachii*),

- trójgłowego ramienia (łac. *m. triceps brachii*).

Do badania ruchu w stawie łokciowym, stawie ramiennym i ruchu całej kończyny (ręki) użyto, odpowiednio, 13 (rys. 5.4a), 15 (rys. 5.4b) i 5 elektrod. We wszystkich przypadkach eksperyment przeprowadzono w pozycji siedzącej przy asyście kamery Kinect umieszczonej prostopadle do płaszczyzny czołowej ciała (rys. 5.5–5.7). Rysunki 5.8–5.17 zamieszczone poniżej przedstawiają zgromadzone pomiary ruchu w odnośnych przypadkach.




Rysunek 5.4. Rozmieszczenie elektrod podczas badania ruchu kończyny górnej: **a)** badanie ruchu w stawie łokciowym; **b)** badanie ruchu w stawie ramiennym



Rysunek 5.5. „Szkielec” współrzędnych ciała nałożony podczas wykonywania przez pacjenta ruchów w stawie ramiennym: **a)** rozluźnienie; **b)** odwiedzenie; **c)** zgięcie do przodu

Ruch ramienia i przedramienia względem ich nadrzędnych stawów zbadano u wszystkich wolontariuszy. Wybór ruchów odwodzenia i przywodzenia oraz zgięcia do przodu i wyprost do tyłu w stawie ramiennym został podyktowany ograniczeniami czasowymi badania. Pominięto w ten sposób pozostałe ruchy możliwe do wykonania przez człowieka w stawie ramiennym, tj.: zgięcie poziome i wyprost poziomy oraz rotację do wewnątrz i rotację na zewnątrz.

We wszystkich przypadkach ruchu odwodzenia i przywodzenia w stawie ramiennym można wskazać na wzmożoną aktywność *m. deltoideus* i *m. trapezius* (zwłaszcza przy rozpoczęciu przywodzenia). Zauważalna, ale znacznie słabsza, jest także aktywność *m. teres major*, *m. triceps brachii* oraz *m. biceps brachii*. Również na wszystkich przebiegach wartość szczytowa najbardziej aktywnych mięśni utrzymuje się na podobnym poziomie, z wyjątkiem aktywności mioelektrycznej



Rysunek 5.6. „Szkielet” współrzędnych ciała nałożony podczas wykonywania przez pacjenta zgięcia w stawie łokciowym




Rysunek 5.7. „Szkielet” współrzędnych ciała nałożony podczas wykonywania przez pacjenta rzutu przedmiotem

m. biceps brachii dziecka z PCI (rys. 5.10). W tym przypadku jest widoczne niekontrolowane, nadmierne napięcie mięśniowe – typowe dla osób ze spastyczną postacią PCI. Fakt ten może przyczynić się do bardziej dokładnego rozróżniania osób z PCI od pozostałych, równocześnie będąc przeszkodą dla innych typów wnioskowania.


W przypadku zgięcia do przodu i wyprostowania do tyłu (rys. 5.11–5.13) obserwuje się podobne zależności, z różnicą zwiększenia udziału *m. teres major* i *m. pectoralis major* w procesie wykonywania tych ruchów.

Staw łokciowy przystosowany jest do realizowania dwóch sekwencji ruchów: zginania i prostowania oraz pronacji i supinacji. Drugi przypadek nie został zbadany, ponieważ czułość rozróżnienia poszczególnych etapów tych ruchów przez kamerę Kinect jest zbyt niska.


Podczas zginania i prostowania w stawie łokciowym (rys. 5.14–5.16), aktywność wszystkich zmierzonych mięśni, oprócz *m. brachioradialis* i *m. triceps brachii*, jest wyraźnie widoczna w poszczególnych etapach tych ruchów. Zginanie charakteryzuje się silną aktywnością *m. biceps brachii*, a prostowanie – *m. extensor carpi radialis longus*, *m. brachialis* oraz *m. pronator teres*. Wartości szczytowe *m. brachioradialis* i *m. triceps brachii* (prostownika stawu ramiennego) zwiększają się nieznacznie podczas etapu prostowania, ale wedle ukazanych przebiegów, ich siła jest wielokrotnie mniejsza od pozostałych mięśni, co może wskazywać na ich słabe wykształcenie (zwłaszcza *m. triceps brachii*) u zbadanych dzieci, a także na wspomaganie ruchu siłą grawitacji.




Rysunek 5.8. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę zdrową, odwodzenia i przywodzenia w stawie ramiennym (9-letnie dziecko płci żeńskiej)




Rysunek 5.9. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na OI , odwodzenia i przywodzenia w stawie ramiennym (10-letnie dziecko płci męskiej)



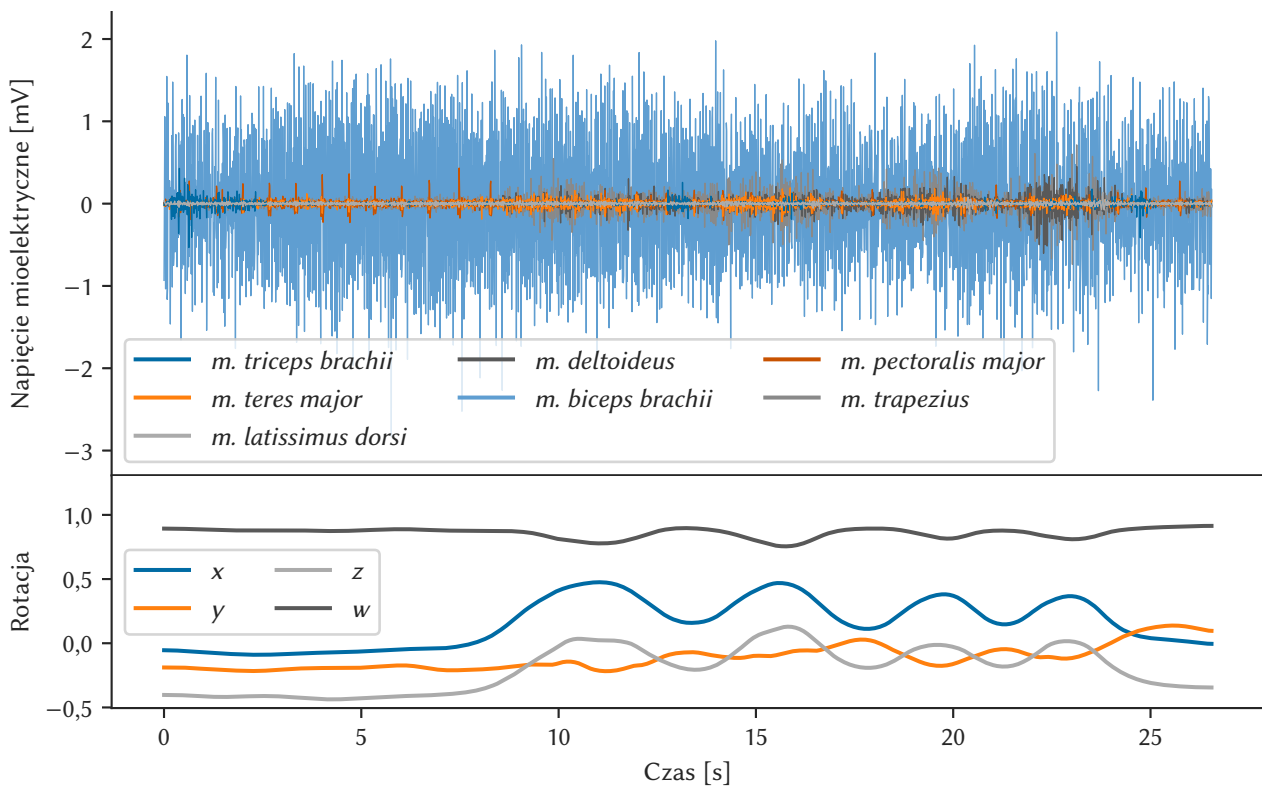
Rysunek 5.10. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na PCI, odwodzenia i przywodzenia w stawie ramiennym (17-letnie dziecko płci męskiej)




Rysunek 5.11. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę zdrową, zgięcia do przodu i wyprostowania do tyłu w stawie ramiennym (9-letnie dziecko płci żeńskiej)




Rysunek 5.12. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na **OI**, zgięcia do przodu i wyprostów do tyłu w stawie ramiennym (10-letnie dziecko płci męskiej)




Rysunek 5.13. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na **PCI**, zgięcia do przodu i wyprostów do tyłu w stawie ramiennym (17-letnie dziecko płci męskiej)



Rysunek 5.14. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja przedramienia (w przestrzeni H) zmierzone podczas wykonywania, przez osobę zdrową, zginania i prostowania w stawie łokciowym (8-letnie dziecko płci żeńskiej)



Rysunek 5.15. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja przedramienia (w przestrzeni H) zmierzone podczas wykonywania, przez osobę chorą na OI, zginania i prostowania w stawie łokciowym (10-letnie dziecko płci męskiej)




Rysunek 5.16. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja przedramienia (w przestrzeni H) zmierzone podczas wykonywania, przez osobę chorą na PCI, zginania i prostowania w stawie łokciowym (17-letnie dziecko płci męskiej)

Wartości szczytowe napięcia odnośnych mięśni, a szczególnie *m. biceps brachii*, u dzieci z OI (rys. 5.15) są większe od pozostałych o około 0,2 mV. Przyczyną tego może być fakt, iż osoby te regularnie wykonują ćwiczenia zwiększające siłę mięśni kończyn, aby przeciwdziałać słabości tkanki kostnej. U wolontariuszy z PCI (rys. 5.16) ponownie zaobserwowano nienaturalnie nadmierne napięcie *m. biceps brachii*, a także analogiczny stan dla *m. extensor carpi radialis longus*.

Test rzutu przedmiotami o masach 0,2 kg i 2 kg przeprowadzono z udziałem jednej osoby chorej na PCI, aby móc wykorzystać zebrane dane do opracowania jednego z modeli identyfikacji poprawności wykonywanego ćwiczenia. Wybór wymienionych mas jest nieprzypadkowy, ponieważ ciężar 2 kg okazał się dla ćwiczącego bardzo trudny w swobodnym operowaniu – osoba ta odznaczała się wysokim stopniem spastyczności oraz znacznie obniżonym poziomem tkanki mięśniowej. W przypadku tego badania rejestrowano jednocześnie ruch stawu ramiennego oraz łokciowego.

Aktywności elektryczne *m. biceps brachii* i *m. triceps brachii* zarejestrowane w trakcie testu rzutu przedmiotem znajdują się na podobnym poziomie. Wyraźnie zaznaczona jest chwila rzutu, kiedy wartości szczytowe napięcia obu mięśni osiągają wartość około 2 mV. Z powodu przeskalowania wykresu przez ten fakt, wysoka aktywność *m. biceps brachii*, wyraźnie widoczna na poprzednich wykresach, jest tutaj praktycznie niezauważalna.

Ruch kończyny dolnej został zbadany w trakcie wykonywania przez ochotników ćwiczenia na rotorze z regulowanym obciążeniem (rys. 5.18). Każdorazowo wykonano cztery powtórzenia, począwszy od najmniejszego stopnia obciążenia, aż do największego (przrząd nie posiadał skali



Rysunek 5.17. Aktywność bioelektryczna mięśni oraz korespondujące z nią rotacje ramienia i przedramienia (w przestrzeni H) zmierzone podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem o masie 0,2 kg (17-letnie dziecko płci męskiej)

liczbowej). Z powodu braku odpowiedniego sprzętu w większości miejsc, w których odbyły się pomiary, eksperyment ten został przeprowadzony jedynie z udziałem dzieci chorych na OI, dla których najwyższy poziom okazał się zbyt ciężki, dając dane do opracowania następnego modelu identyfikacji poprawności wykonywanego ćwiczenia.

Analogicznie, jak podczas testów rzucania przedmiotem, zarejestrowano ruch dwóch elementów anatomicznych kończyny: uda i goleni. Na ciałach osób badanych umieszczano 13 elektrod (rys. 5.19) mierzących aktywność bioelektryczną (rys. 5.20) następujących sześciu mięśni:

- półścięgnistego (łac. *m. semitendinosus*),
- smukłego (łac. *m. gracilis*),
- krawieckiego (łac. *m. sartorius*),
- dwugłowego uda (łac. *m. biceps femoris*),
- prostego uda (łac. *m. rectus femoris*),
- napinacza powięzi szerokiej (łac. *m. tensor fasciae latae*).

Ćwiczenie na rotorze było wykonywane wolnym, jednostajnym tempem, zatem na rysunku 5.20 widać wyraźnie zarysowane etapy pracy mięśni podczas operacji pedałowania – z aktywnością *m. sartorius* w początkowej fazie, *m. semitendinosus* i *m. biceps femoris* w środkowej oraz *m. gracilis* i *m. tensor fasciae latae* przy końcu cyklu. Z powodu występowania podparcia zarówno dla tułowia,



Rysunek 5.18. Badanie aktywności mięśni nóg podczas ćwiczeń na rotorze rehabilitacyjnym




Rysunek 5.19. Rozmieszczenie elektrod podczas badania ruchu kończyny dolnej

jak i dla nóg, a także bardzo małego oporu pedałów, wartości szczytowe napięć w przedstawionym przypadku są nawet o połowę mniejsze od pozostałych zaprezentowanych ćwiczeń.

Należy dodatkowo zwrócić uwagę na przedstawione przebiegi rotacji stawów. Pomimo zastosowanej filtracji eliminującej większość szumów, dane uzyskane z kamery Kinect nadal posiadają wiele wad, które w oczywisty sposób sprawiają, że przebiegów tych nie można uznać za jednoznaczny reprezentację ruchu. Można więc z dużą pewnością stwierdzić, że taka forma wiedzy może stanowić przeszkodę dla efektywnego nauczania modeli regresyjnych.

5.1.2. Badania wpływu dodatkowych obciążeń

Opisane w poprzednim rozdziale ruchy w stawie łokciowym zostały przebadane przy użyciu różnego rodzaju obciążników (rys. 5.21). Stąd też podczas każdego porównania przebiegów dokonano analizy widmowej i analizy falkowej (z użyciem falki CMOR) w celu wyróżnienia potencjalnych różnic przebiegów w domenie częstotliwości oraz czasu i częstotliwości. Poniżej zawarto zestawy wyników opisujące zmiany w aktywności EMG wywołane dodatkowym obciążeniem dłoni u dzieci zdrowych (rys. 5.22–5.24), chorych na OI (rys. 5.25–5.27), oraz z PCI (rys. 5.28–5.30). W wyniku ograniczeń czasowych podczas badań pacjentów, analiza wpływu obciążeń u osób zdrowych i chorych na PCI została ograniczona wyłącznie do jednego istotnego przypadku.




Rysunek 5.20. Aktywność bioelektryczna mięśni oraz korespondujące z nią rotacje uda i golenia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na **OI**, ćwiczenia na rotorze (10-letnie dziecko płci męskiej)




Rysunek 5.21. Badanie aktywności mięśni rąk z obciążnikami


Użycie obciążników w zginaniu i prostowaniu w stawie łokciowym (rys. 5.22) wywołało około dwukrotne zwiększenie wartości szczytowej aktywności bioelektrycznej wszystkich badanych mięśni u osoby zdrowej (rys. 5.14). Zależność ta jest odzwierciedlona w analizie widmowej (rys. 5.23) i falkowej (rys. 5.24) odnośnego przebiegu – kształt widma i spektrogramu sygnałów **EMG** pobranych bez obciążenia (rys. 5.23a i 5.24a) nie różni się znacząco w stosunku do ich odpowiedników pochodzących od przebiegów z obciążonego przedramienia (rys. 5.23b i 5.24b). W przypadku analizy widma jest zauważalny jedynie niewielki wzrost udziału wyższych częstotli-



Rysunek 5.22. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę zdrową, ruchów zginania i prostowania w stawie łokciowym z obciążnikami o masie 2 kg




Rysunek 5.23. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę zdrową, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 2 kg




Rysunek 5.24. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę zdrową, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 2 kg

wości. Największa różnica jest jednak widoczna w zmianie wartości szczytowych przedstawionych na odnośnych wykresach, gdzie obserwuje się około dwukrotny ich wzrost w przypadku widma oraz towarzyszący jemu około trzykrotny wzrost wartości współczynników na spektrogramie.



Rysunek 5.25. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na **OI**, ruchów zginania i prostowania w stawie łokciowym z obciążnikami: **a)** obciążenie o masie 0,5 kg; **b)** obciążenie o masie 1 kg; **c)** obciążenie o masie 2 kg


Analogiczne wnioski można przytoczyć na podstawie analizy wykresów odnoszących się do ruchów zginania i prostowania w stawie łokciowym wykonywanych przez osobę chorą na **OI** (rys. 5.25–5.27). Wprowadzenie niewielkiego obciążenia o masie 0,5 kg powoduje praktycznie niezauważalny wzrost średniej wartości szczytowej **EMG** (rys. 5.25a) w odniesieniu do przebiegu bez obciążenia (rys. 5.15). Porównanie widm obu przebiegów (odpowiednio rys. 5.26b i 5.26a) ukazuje niewielki wzrost mocy *m. extensor carpi radialis longus* oraz *m. pronator teres* w paśmie wyższych częstotliwości, a także spadek mocy *m. pronator teres* dla niskich częstotliwości, w stosunku do pozostałych mięśni; ogólnie notuje się około 1,5-krotny wzrost wartości widma i wartości współczynników falkowych (rys. 5.27b i 5.27a). Dalsze zwiększenie ciężaru zewnętrznego spowodowało kolejny, analogiczny wzrost wartości szczytowych **EMG** (rys. 5.25b i 5.25c), jak i widma (rys. 5.26c i 5.26d) oraz wartości na spektrogramie (rys. 5.27c i 5.27d). Istotna w tym przypadku jest obserwacja, iż występują tutaj bardzo niewielkie różnice pomiędzy sygnałem zmierzonym z obciążeniem o masie 1 kg a obciążeniem o masie 2 kg, co może wskazywać na wykładniczy charakter zmian analizowanych cech aktywności mięśniowej.




Rysunek 5.26. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na **OI**, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 0,5 kg; **c)** z obciążeniem o masie 1 kg; **d)** z obciążeniem o masie 2 kg

Obciążenie osoby z **PCI** podczas wykonywania ruchów zginania i prostowania w stawie łokciowym w danym przypadku (rys. 5.28) prowadzi do zbliżonych konsekwencji, jak w wyżej wymienionych – następuje prawie dwukrotny wzrost wartości szczytowych sygnału **EMG** oraz wartości mocy widma (rys. 5.29) i współczynników falkowych (rys. 5.30). W przedstawionym przykładzie na uwagę zasługują rozkłady widma porównywanych sygnałów, na których widać bardzo wyraźne cechy wspólne pod postacią wyróżniających się wysokich wartości mocy wokół tych samych, wybranych częstotliwości.

Biorąc pod uwagę zilustrowane powyżej przebiegi **EMG** i ich analizę, można stwierdzić, że możliwym jest rozróżnienie na ich podstawie poszczególnych stanów zdrowia badanych wolontariuszy. Jest to widoczne szczególnie na wykresach widma oraz współczynników falkowych, które różnią się w sposób znaczący pomiędzy sobą. Wskazuje to, że wykorzystanie informacji w dziedzinie czasu i częstotliwości jako zmiennych wejściowych modeli wnioskujących może zapewnić efektywność procesu uczenia oraz dalszego uogólniania.



Rysunek 5.27. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę chorą na **OI**, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 0,5 kg; **c)** z obciążeniem o masie 1 kg; **d)** z obciążeniem o masie 2 kg




Rysunek 5.28. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na **PCI**, ruchów zginania i prostowania w stawie łokciowym z obciążnikami o masie 1 kg


Zgodną co do zakresu analizę przygotowano również dla ćwiczenia na rotorze (rys. 5.34–5.36) oraz operacji rzucania przedmiotem (rys. 5.31–5.33). Jak podkreślono w rozdziale 5.1.1, testy te wykonano dla ograniczonej grupy uczestników badania.

Osoba z **PCI** poddana testowi rzutu przedmiotem, w drugim podejściu otrzymała taki, którego masa (2 kg) uniemożliwiała swobodne operowanie przedmiotem – podniesienie przedmiotu, a następnie rzut sprawiał wolontariuszowi duży wysiłek. Przedstawione na rysunku 5.31 napięcie mioelektryczne zmierzone podczas rzutu cięższym przedmiotem nie wykazuje praktycznie żadnych różnic w aktywności, bądź wartości szczytowej badanych mięśni, wobec pierwszego etapu testu (rys. 5.17). Niewielkie, zauważalne różnice występują również w widmie sygnałów (rys. 5.32) oraz na spektrogramach (rys. 5.33). Można zatem postawić hipotezę, że klasyfikacja dwóch odnośnych stanów na podstawie zebranych sygnałów **EMG** będzie mało efektywna.


Zwiększenie obciążenia rotora o jeden stopień nie wywołuje znaczącej zmiany w przebiegu aktywności mioelektrycznej (rys. 5.34a), w stosunku do aktywności podczas ćwiczenia na rotorze nieobciążonym (rys. 5.20). Poza niewielkimi zmianami w proporcjach zakresów niskich i wysokich



Rysunek 5.29. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na PCI, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 1 kg




Rysunek 5.30. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę chorą na PCI, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 1 kg




Rysunek 5.31. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem o masie 2 kg

częstotliwości, również analiza widmowa (rys. 5.35a i 5.35b) nie dostarcza widocznych różnic. Stąd też możliwość pewnego odróżnienia obu stanów daje dopiero analiza falkowa, według której rozkład współczynników falkowych jest podobny, ale ich wartości są – w skali globalnej – większe



Rysunek 5.32. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem: **a)** przedmiot o masie 0,2 kg; **b)** przedmiot o masie 2 kg




Rysunek 5.33. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem: **a)** przedmiot o masie 0,2 kg; **b)** przedmiot o masie 2 kg

(rys. 5.36a i 5.36b). Dalsze podwyższenie obciążenia, do poziomu średniego, nieznacznie zwiększa wartość szczytową przebiegu EMG (rys. 5.34b). W trakcie badań można zaobserwować także zintensyfikowanie aktywności *m. semitendinosus* w środkowej fazie cyklu pedałowania. Przypadek ten jest jednak prawie niemożliwy do rozróżnienia od poprzedniego na podstawie widma sygnału (rys. 5.35c). Wyniki analizy falkowej nie odznaczają się i w tym przypadku znacznymi różnicami w wartościach współczynników (rys. 5.36c); potencjalnie, jedynie rozkład poszczególnych wartości na spektrogramie może świadczyć o wystąpieniu zmiany w warunkach ćwiczenia.

W przypadku najcięższego obciążenia można stwierdzić o wyraźnych rozbieżnościach w stosunku do każdego poprzedniego poziomu. W tym przypadku, pomimo iż średnia wartość szczytowa sygnału EMG (rys. 5.34c) nie wyróżnia się na tle pozostałych przebiegów, to wyniki jego analizy spektralnej (rys. 5.35d) i falkowej (rys. 5.36d) ukazują znaczące różnice.

Podsumowując, należy stwierdzić, że w obu przypadkach następuje kilkukrotnie większy wzrost wartości współczynników falkowych względem niższego stopnia obciążenia rotora. Istotne jest to, że poziom obciążenia, który przyjęto, został uznany przez osobę ćwiczącą jako za ciężki




Rysunek 5.34. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na **OI**, ćwiczenia na rotorze: **a)** lekki poziom obciążenia; **b)** średni poziom obciążenia; **c)** wysoki poziom obciążenia

i niekomfortowy. Na tej podstawie, zgodnie z metodyką badania, istnieją silne przesłanki, iż model klasyfikacyjny będzie funkcjonował efektywnie (stany są dobrze rozgraniczone).

5.2. Identyfikacja stanu osoby ćwiczącej

Zgodnie z założeniami (rozd. 4.1), najistotniejszą funkcją postulowanego zautomatyzowanego systemu rehabilitacyjnego, którego metodykę funkcjonowania stanowi przedmiot niniejszej rozprawy, jest identyfikacja i klasyfikacja stanu zdrowia. Z powodu charakterystyki grupy zbadanych wolontariuszy, prace koncentrowały się na zbudowaniu modelu klasyfikacji trzech stanów reprezentujących: dziecko o prawidłowo funkcjonującym układzie ruchu (zdrowe), dziecko z **PCI** oraz dziecko z **OI**.

Oprócz przekształceń w dziedzinie czasu (rozd. 4.4.1), które jednoznacznie opisują każdy przebieg **EMG**, przypisując mu charakterystyczną liczbę, zdecydowano się na wykorzystanie również analizy falkowej. Wynikiem **CWT** jest seria współczynników zawartych jednocześnie



Rysunek 5.35. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na **OI**, ćwiczenia na rotorze: **a)** bez obciążenia; **b)** lekki poziom obciążenia; **c)** średni poziom obciążenia; **d)** wysoki poziom obciążenia


w dziedzinie czasu, jak i skali (częstotliwości), co w takiej postaci nie stanowi efektywnej cechy uczącej.

Dane otrzymane z **CWT** można poddać redukcji wymiarowości poprzez zsumowanie wartości bezwzględnych współczynników falkowych dla każdego poziomu skali, otrzymując w rezultacie wykresy liniowe zmiany wartości współczynników w dziedzinie skali (rys. 5.37).


Przykładowe zestawienie sum współczynników falkowych, przedstawione na rysunku 5.37, wskazuje na znaczne różnice w ich wartościach pomiędzy analizowanymi stanami zdrowia. Różnice te są uwidocznione zarówno w zależnościach pomiędzy liniami reprezentującymi poszczególne mięśnie, jak i w skalach osi rzędnych.

Następnym krokiem jest przekształcenie wyżej wymienionych danych do formy pojedynczych cech opisujących dany przypadek. W tym celu posłużono się metodą trapezów, aby oszacować pole pod wykresami opisującymi aktywność mięśni, otrzymując w ten sposób wartości mogące stanowić opis sygnału uzyskany w wyniku transformacji falkowej.

Mając na względzie wszystkie przekształcenia czasowe oraz falki, które stanowią bazę transformaty falkowej, a także liczbę m analizowanych mięśni, otrzymuje się $14m$ zmiennych wejściowych modeli wnioskujących wykorzystanych w opisywanych badaniach.



Rysunek 5.36. Analiza falkowa aktywności bioelektrycznej *m. semitendinosus* zmierzonej podczas wykonywania, przez osobę chorą na **OI**, ćwiczenia na rotorze: **a)** bez obciążenia; **b)** lekki poziom obciążenia; **c)** średni poziom obciążenia; **d)** wysoki poziom obciążenia



Rysunek 5.37. Sumy współczynników falkowych (**CMOR**) oszacowanych dla aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania ruchów zginania i prostowania w stawie łokciowym: **a)** osoba zdrowa; **b)** osoba chora na **PCI**; **c)** osoba chora na **OI**

Wyżej wymienionym transformacjom poddano wycinki przebiegów **EMG**, które otrzymano w wyniku operacji okienkowania o szerokości 250 ms i kroku 66 ms. Szerokość okna wybrano na drodze wstępnych testów tak, aby móc jak najczęściej aktualizować zmiany w wybranych stanach osoby ćwiczącej, nie tracąc przy tym zbyt wielu próbek sygnału z powodu niskiej częstotliwości pomiaru. Wartość kroku okna stanowi wielokrotność okresu pomiaru danych rotacji stawów.

Wartości cech wykorzystanych w klasyfikacji stanów zdrowia dzieci przedstawiono w tabelach 5.1–5.3. Wstępna analiza danych z tabeli wykazuje, że największe różnice w wartościach średnich zmiennych wejściowych występują w transformacjach falkowych. Wysokie wartości odchyłeń standardowych są najprawdopodobniej skutkiem stosowania okna statycznego w dzieleniu

przebiegu, ponieważ oprócz informacji istotnych o rzeczywistej aktywności mięśni w trakcie wykonywania ruchu, przekształceniu są poddawane również momenty rozluźnienia mięśni pomiędzy ruchami.

Tabela 5.1. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym przez osoby zdrowe

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio- radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	2,756 ± 2,339	0,648 ± 0,397	0,670 ± 0,280	1,239 ± 1,740	1,295 ± 1,049	0,391 ± 0,303
MAV	0,110 ± 0,094	0,026 ± 0,016	0,027 ± 0,011	0,050 ± 0,070	0,052 ± 0,042	0,016 ± 0,012
MAV1	0,081 ± 0,070	0,019 ± 0,012	0,020 ± 0,008	0,037 ± 0,054	0,038 ± 0,031	0,012 ± 0,009
MAV2	0,053 ± 0,050	0,013 ± 0,009	0,013 ± 0,006	0,024 ± 0,042	0,025 ± 0,022	0,008 ± 0,007
SSI	0,864 ± 1,536	0,040 ± 0,053	0,033 ± 0,027	0,388 ± 2,190	0,173 ± 0,313	0,016 ± 0,035
VAR	0,036 ± 0,064	0,002 ± 0,002	0,001 ± 0,001	0,016 ± 0,091	0,007 ± 0,013	0,001 ± 0,001
WL	2,099 ± 1,762	0,485 ± 0,320	0,521 ± 0,219	0,920 ± 1,252	0,966 ± 0,762	0,301 ± 0,242
CGAU8	506,580 ± 427,760	118,950 ± 74,240	121,880 ± 51,150	232,950 ± 354,390	237,170 ± 191,640	71,640 ± 56,240
CMOR	446,760 ± 378,470	104,960 ± 64,900	108,310 ± 45,460	202,610 ± 294,470	209,840 ± 170,180	63,330 ± 49,390
FBSP	790,310 ± 669,190	185,650 ± 114,900	191,500 ± 80,390	358,850 ± 523,430	371,160 ± 300,970	112,030 ± 87,430
GAUS8	731,260 ± 617,820	171,740 ± 106,960	176,180 ± 73,930	335,340 ± 505,270	342,550 ± 276,890	103,450 ± 81,090
MEXH	871,450 ± 738,300	204,860 ± 126,330	211,430 ± 88,720	394,210 ± 565,710	409,350 ± 331,550	123,580 ± 96,140
MORL	620,630 ± 523,730	145,720 ± 91,100	149,110 ± 62,580	286,130 ± 439,020	290,390 ± 234,510	87,720 ± 68,970
SHAN	374,400 ± 315,050	87,860 ± 55,320	89,540 ± 37,590	174,230 ± 275,490	174,830 ± 141,000	52,840 ± 41,780

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.

Tabela 5.2. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym przez osoby chore na PCI

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio- radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	3,720 ± 3,872	0,364 ± 0,152	0,557 ± 0,296	2,670 ± 2,970	0,514 ± 0,121	0,256 ± 0,085
MAV	0,149 ± 0,155	0,015 ± 0,006	0,022 ± 0,012	0,107 ± 0,119	0,021 ± 0,005	0,010 ± 0,003
MAV1	0,110 ± 0,115	0,011 ± 0,005	0,017 ± 0,009	0,079 ± 0,088	0,015 ± 0,004	0,008 ± 0,003
MAV2	0,072 ± 0,079	0,007 ± 0,004	0,011 ± 0,007	0,052 ± 0,060	0,010 ± 0,003	0,005 ± 0,002
SSI	1,877 ± 2,491	0,010 ± 0,010	0,026 ± 0,039	1,048 ± 1,422	0,018 ± 0,008	0,005 ± 0,006
VAR	0,078 ± 0,104	<0,001 ± <0,001	0,001 ± 0,002	0,044 ± 0,059	0,001 ± <0,001	<0,001 ± <0,001
WL	3,143 ± 3,358	0,272 ± 0,119	0,429 ± 0,234	2,292 ± 2,646	0,415 ± 0,110	0,189 ± 0,084
CGAU8	675,310 ± 703,120	66,300 ± 28,160	101,760 ± 55,650	484,640 ± 539,180	93,390 ± 22,360	46,700 ± 16,540
CMOR	601,080 ± 625,890	58,820 ± 24,640	90,210 ± 48,330	431,430 ± 479,860	83,050 ± 19,660	41,440 ± 14,060
FBSP	1 062,470 ± 1 106,260	104,010 ± 43,620	159,520 ± 85,580	762,590 ± 848,170	146,830 ± 34,780	73,270 ± 24,960
GAUS8	976,400 ± 1 016,540	95,820 ± 40,570	147,030 ± 80,080	700,710 ± 779,470	135,010 ± 32,250	67,490 ± 23,700
MEXH	1 173,300 ± 1 221,340	114,820 ± 47,990	176,060 ± 94,040	842,150 ± 936,470	162,130 ± 38,310	80,870 ± 27,270
MORL	826,050 ± 860,100	81,140 ± 34,560	124,550 ± 68,370	592,770 ± 659,560	114,220 ± 27,400	57,150 ± 20,410
SHAN	495,820 ± 516,290	48,760 ± 20,970	74,900 ± 41,650	355,760 ± 396,010	68,550 ± 16,530	34,350 ± 12,620

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.




Tabela 5.3. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym przez osoby chore na **OI**

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio- radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	26,227 ± 25,124	13,378 ± 9,764	4,819 ± 5,103	9,364 ± 11,283	8,480 ± 7,477	3,316 ± 2,001
MAV	0,105 ± 0,101	0,054 ± 0,039	0,019 ± 0,020	0,038 ± 0,045	0,034 ± 0,030	0,013 ± 0,008
MAV1	0,079 ± 0,076	0,040 ± 0,030	0,015 ± 0,016	0,028 ± 0,034	0,025 ± 0,023	0,010 ± 0,006
MAV2	0,052 ± 0,055	0,027 ± 0,022	0,010 ± 0,012	0,019 ± 0,024	0,017 ± 0,017	0,007 ± 0,005
SSI	8,776 ± 17,334	1,717 ± 2,213	0,369 ± 1,077	1,441 ± 3,603	0,871 ± 1,340	0,092 ± 0,108
VAR	0,035 ± 0,070	0,007 ± 0,009	0,002 ± 0,004	0,006 ± 0,015	0,004 ± 0,005	<0,001 ± <0,001
WL	5,741 ± 5,893	2,842 ± 2,183	0,993 ± 1,192	1,952 ± 2,497	1,517 ± 1,331	0,689 ± 0,439
CGAU8	4 435,730 ± 4 602,510	2 066,670 ± 1 472,550	842,450 ± 1 029,420	1 637,860 ± 1 917,370	1 478,670 ± 1 319,830	496,900 ± 303,770
CMOR	4 178,090 ± 4 169,230	2 042,470 ± 1 439,140	784,870 ± 935,330	1 514,730 ± 1 797,030	1 372,220 ± 1 218,130	495,170 ± 292,740
FBSP	7 043,290 ± 7 126,920	3 406,190 ± 2 395,160	1 330,660 ± 1 635,180	2 565,270 ± 3 041,370	2 325,540 ± 2 085,530	819,370 ± 485,700
GAUS8	6 604,800 ± 6 939,280	3 078,300 ± 2 214,940	1 255,320 ± 1 580,230	2 432,260 ± 2 874,030	2 192,380 ± 1 983,920	738,110 ± 460,370
MEXH	15 041,740 ± 14 774,310	7 520,110 ± 5 435,910	2 811,840 ± 3 355,470	5 423,280 ± 6 516,890	4 961,920 ± 4 511,980	1 824,360 ± 1 109,850
MORL	5 437,620 ± 5 590,830	2 536,500 ± 1 797,140	1 035,740 ± 1 243,310	2 016,100 ± 2 341,190	1 827,340 ± 1 621,280	609,910 ± 367,590
SHAN	3 352,590 ± 3 374,030	1 600,650 ± 1 133,910	651,300 ± 753,740	1 262,710 ± 1 437,960	1 163,930 ± 1 046,410	384,040 ± 227,140

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* **IEMG** – całka sygnału EMG, **MAV** – średnia wartości bezwzględnych amplitudy sygnału, **MAV1** – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, **MAV2** – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, **SSI** – prosta całka kwadratowa sygnału, **VAR** – wariancja sygnału EMG, **WL** – długość przebiegu, **CGAU8** – falka pochodna gaussowska zespolona 8, **CMOR** – falka Morleta zespolona, **FBSP** – falka sklejkowej częstotliwości, **GAUS8** – falka pochodna gaussowska 8, **MEXH** – falka Rickera, **MORL** – falka Morleta, **SHAN** – falka Shannona.

Dodatkowa analiza rozkładów gęstości prawdopodobieństwa wybranych zmiennych (rys. 5.38) wykazuje istotne różnice pomiędzy rozkładami wartości danych zmiennych dla poszczególnych klas. Wartości p naniesione na wykresy są rezultatem dwustronnego testu Kołmogorowa-Smirnowa, który weryfikuje hipotezę zerową twierzącą, że dwie niezależne próbki pochodzą od tego samego rozkładu ciągłego. Według wybranego poziomu istotności 1% wszystkie ukazane cechy, podzielone według stanu zdrowia, charakteryzują się rozbieżnością i z dużą pewnością można na ich podstawie odróżnić klasy. Należy również dodać, że odchylenia wartości wszystkich podanych cech związanych z dziećmi z **OI** są znacznie większe niż u pozostałych badanych.



Rysunek 5.38. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji stanu zdrowia osoby ćwiczącej na podstawie ruchów zginania i prostowania w stawie łokciowym: **a)** **FBSP** *m. biceps brachii*; **b)** **GAUS8** *m. biceps brachii*; **c)** **MEXH** *m. biceps brachii*; **d)** **MEXH** *m. extensor carpi radialis longus*

Zgodnie z opisem procedury testowej, zawartym w rozdziale 4.1, na wejście modeli wnioskujących nie podawano wszystkich możliwych zmiennych, a za pomocą testu wariancji wybierano k najlepszych z nich. Liczbę tą starano się jak najbardziej zminimalizować bez znacznej straty efektywności klasyfikacji/regresji. Początkowe testy wykazały, że 5 uprzednio wyselekcjonowanych cech charakterystycznych sygnału wystarcza, żeby zapewnić dobrą dokładność większości modelom. Otrzymany zbiór danych, który poddawano testom, zdecydowano podzielić na 200 podzbiorów dla walidacji krzyżowej.

Uzyskane wyniki przedstawiono w tabeli 5.4, która opisuje wyniki klasyfikacji wyłącznie na podstawie ruchów zginania i prostowania w stawie łokciowym. Bez wątpliwości najlepszą metodą okazała się **KNN**, w przypadku zastosowania której osiągnięto rezultaty wyższe o 4,2% według metryki **ACC** i o 5,2% według metryki **F1** od drugiego najlepszego algorytmu – **DT**. Należy podkreślić, że wszystkie przetestowane metody uzyskały co najmniej satysfakcjonujące wyniki klasyfikacji.

Tabela 5.4. Wyniki klasyfikacji stanu zdrowia osoby ćwiczącej na podstawie ruchów zginania i prostowania w stawie łokciowym

Miary*	SVM	KNN	DT	MLP
ACC	0,831 ± 0,149	0,943 ± 0,114	0,901 ± 0,159	0,876 ± 0,180
F1	0,778 ± 0,189	0,932 ± 0,133	0,880 ± 0,191	0,852 ± 0,208

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* ACC – dokładność, F1 – miara F₁.


Pięć cech, które zostały wytypowane jako najlepsze, to:

- FBSP, GAUS8 i MEXH *m. biceps brachii*,
- MEXH *m. brachialis*,
- MEXH *m. extensor carpi radialis longus*

Ponadto, wyszukiwanie wyczerpujące wykazało, że powyższe wyniki KNN zostały osiągnięte dla następujących parametrów modelu:

- liczba sąsiadów: 3,
- funkcja wagowa używana w prognozowaniu: odległość,
- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 1.

Rozkłady gęstości prawdopodobieństwa wyników klasyfikacji oraz ich test zbieżności dowodzą, że największym błędem i odchyleniem klasyfikacji obarczona była klasa reprezentująca ludzi zdrowych, a najmniejszym – ludzi z OI. Ponadto, wartości dla par klas ludzi zdrowych i z PCI, ale również ludzi z PCI i z OI mogą być zbieżne.

**Rysunek 5.39.** Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji stanu zdrowia osoby ćwiczącej na podstawie ruchów zginania i prostowania w stawie łokciowym

Można zatem stwierdzić, że ocena stanu zdrowia (w zdefiniowanym zakresie) na podstawie przebiegów EMG przez model komputerowy jest możliwa, a jej efektywność już na tym etapie jest bardzo dobra.

5.3. Ocena wykonywanych ćwiczeń

Do oceny ćwiczeń wykorzystano ponownie modele klasyfikacyjne, których zadaniem było zaklasyfikowanie danego przebiegu **EMG** (a konkretnie jego reprezentacji) do jednej z ustalonych klas. Jako eksperyment wstępnie badający efektywność stosowania opisywanej metodyki, ocenę ograniczono do kilku, prostych zależności definiujących odczucia fizyczne osoby ćwiczącej. Procedura przygotowywania danych i przeprowadzania testów modeli we wszystkich dyskutowanych wynikach jest identyczna z przedstawioną w rozdziale 5.2.

Rozwinięciem przytoczonej analizy wpływu zewnętrznych obciążeń na aktywność mięśniową (rozdz. 5.1.2) jest test możliwości automatycznego ustalania masy obciążenia, wyłącznie na podstawie analizy przebiegu **EMG** mięśni odpowiadających za ruch kończyny. Stąd też zbiór klas odpowiada zastosowanym w trakcie eksperymentów obciążnikom, tym samym składa się z obciążeń o masach: 0,5 kg, 1 kg, 2 kg.

Tabele A.3–A.6 zawarte w dodatku A rozprawy ukazują przekrój danych statystycznych wartości zmiennych wejściowych zastosowanego klasyfikatora. Analogicznie z danymi cech w klasyfikacji stanu zdrowotnego (tab. 5.1–5.3), współczynniki związane z transformatą falkową są najbardziej charakterystyczne. Klasyfikacja masy obciążeń bazuje na sygnale **EMG** pochodzącym od tych samych mięśni, co klasyfikacja stanu zdrowia, stąd też wybór pięciu najlepszych typów zmiennych w przedmiotowym przypadku jest identyczny (zob. rozdz. 5.2).

Analiza rozkładów gęstości prawdopodobieństwa wybranych zmiennych (rys. 5.40) dokumentuje, że w rozpatrywanym przypadku również występuje rozróżnienie każdej ze zdefiniowanych klas, aczkolwiek, nie jest ono już tak wyraźne, jak podczas klasyfikacji stanu zdrowia. Ponadto, odchylenie wartości zmiennych odpowiadających ćwiczeniom bez obciążenia jest wyraźnie mniejsze od pozostałych opcji.


Kolejna tabela (tab. 5.5) przedstawia wyniki klasyfikacji zastosowanego obciążenia. Ponownie metoda **KNN** okazała się najbardziej efektywną, jednak tym razem poziom wyników znacząco odbiega od poprzednich. Metoda **KNN** prowadzi do wyników lepszych aż o 22,4% według metryki **ACC** i o 28,6% według metryki **F1** w porównaniu do algorytmu **DT**. Stąd też jego wynik można ocenić co najwyżej jako akceptowalny. Pozostałe z badanych metod klasyfikacji (**DT**, **SVM** i **MLP**) okazały się nieskuteczne.

Tabela 5.5. Wyniki klasyfikacji masy zastosowanego obciążenia zewnętrznego, umieszczonego na dłoni osoby ćwiczącej, na podstawie ruchów zginania i prostowania w stawie łokciowym

Miary*	SVM	KNN	DT	MLP
ACC	0,488 ± 0,131	0,746 ± 0,190	0,522 ± 0,205	0,470 ± 0,173
F1	0,349 ± 0,147	0,707 ± 0,210	0,421 ± 0,226	0,348 ± 0,174

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* **ACC** – dokładność, **F1** – miara F_1 .



Rysunek 5.40. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji wagi zastosowanego obciążenia zewnętrznego na podstawie ruchów zginania i prostowania w stawie łokciowym: **a)** FBSP *m. biceps brachii*; **b)** GAUS8 *m. biceps brachii*; **c)** MEXH *m. biceps brachii*; **d)** MEXH *m. extensor carpi radialis longus*


Należy podkreślić, że wyszukiwanie wyczerpujące wykazało, że powyższe wyniki KNN zostały osiągnięte dla następujących parametrów modelu:

- liczba sąsiadów: 1,
- funkcja wagowa używana w prognozowaniu: równomierna,
- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 4.

Interpretując gęstości prawdopodobieństwa wyników klasyfikacji oraz ich test zbieżności (rys. 5.41), należy dodać, że najlepsze statystycznie wyniki były osiągnięte przy klasyfikacji przebiegów powiązanych z ruchem nieobciążonym dodatkowo. Pozostałe klasy przebiegów EMG osiągnęły efektywność niewiele niższą, ale wysoce zbieżną, czego dowodem są podane wartości p .

Drugim rodzajem oceny ćwiczeń, który zaimplementowano i przebadano, jest klasyfikacja poziomu dopasowania stopnia trudności ćwiczenia. Należy przez to rozumieć stwierdzenie, czy obciążenie, któremu poddawane jest ćwiczące dziecko, jest dla niego odpowiednie, czy też nie (tzn. wykonywanie ruchów staje się uciążliwe, powoduje znaczny dyskomfort itp.). Dla tak sformułowanych warunków wybrano dwa scenariusze: ćwiczenie na rotorze (z 4-poziomową zmianą obciążenia) oraz rzucanie przedmiotami (lekkim i bardzo ciężkim).

Klasyfikacja poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzutu przedmiotem w bok odbywa się przez wybór dwóch stanów: rzucany przedmiot ma

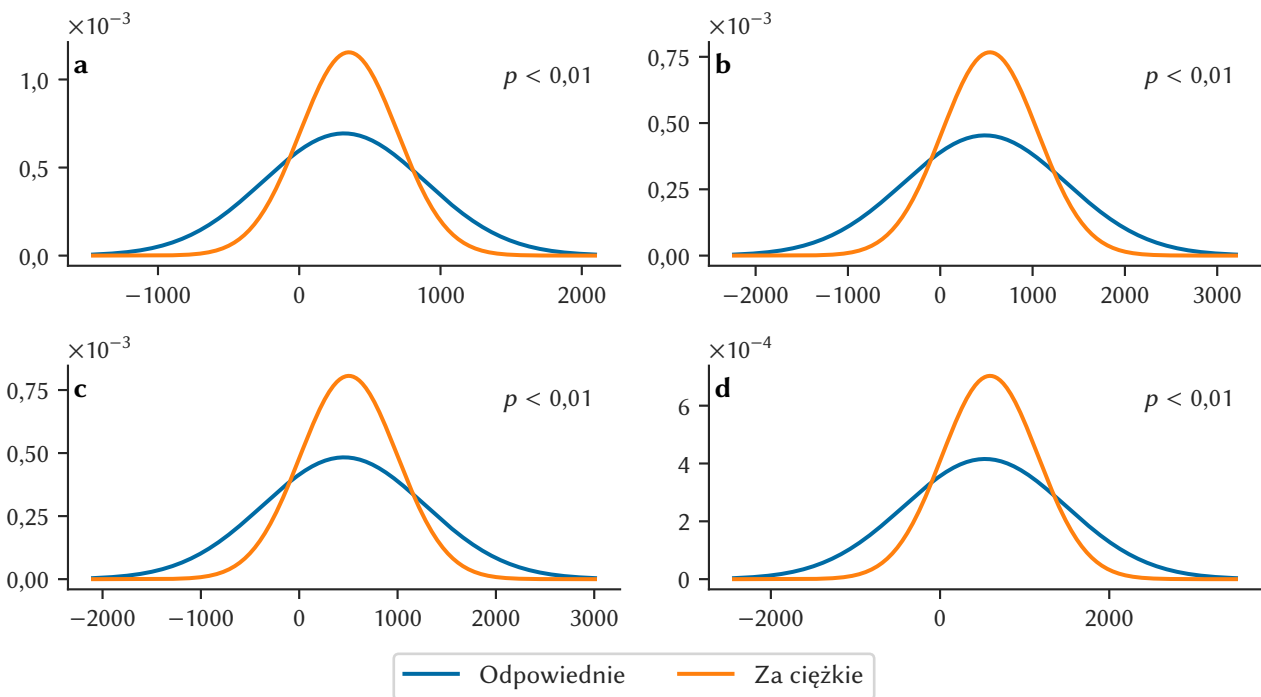


Rysunek 5.41. Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji masy zastosowanego obciążenia zewnętrznego na podstawie ruchów zginania i prostowania w stawie łokciowym

odpowiednią wagę (0,2 kg w tym przypadku) lub rzucający przedmiot jest zbyt ciężki (2 kg), a sam rzut sprawia duże trudności.

Według tabel A.1 i A.2 transformacje falkowe są powtórnie grupą o największym zróżnicowaniu wartości pomiędzy zdefiniowanymi klasami. Pięć cech, które zostały wybrane przez algorytm jako najlepsze, to: CGAU8, FBSP, GAUS8, MEXH i MORL *m. biceps brachii*.

Rysunek 5.42 ilustruje analizę gęstości prawdopodobieństwa odnośnych cech. Pomimo testu zbieżności, który wskazuje na niezależność cech przynależących do poszczególnych klas, ich wartości średnie i odchylenia standardowe są bardzo podobne. Z tego powodu można stwierdzić, że istnieje szansa, że odróżnienie obu klas będzie utrudnione.



Rysunek 5.42. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji poziomu dopasowania stopnia trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzutu przedmiotem w bok: **a)** CGAU8 *m. biceps brachii*; **b)** FBSP *m. biceps brachii*; **c)** GAUS8 *m. biceps brachii*; **d)** MEXH *m. biceps brachii*

Według wyników klasyfikacji (tab. 5.6) wszystkie metody gwarantują zbliżoną efektywność na poziomie zadowalającym. Model klasyfikujący oparty na KNN osiągnął najwyższą efektywność,

o 0,8% wyższą według metryki ACC i o 1,2% wyższą według metryki F1 w porównaniu do DT. Wyniki te dodatkowo odznaczają się najwyższym odchyleniem standardowym w porównaniu z pozostałymi testami, co stanowi dla klasyfikatora dodatkową trudność.

Tabela 5.6. Wyniki klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzucania przedmiotem w bok

Miary*	SVM	KNN	DT	MLP
ACC	0,660 ± 0,318	0,690 ± 0,317	0,682 ± 0,317	0,503 ± 0,189
F1	0,580 ± 0,366	0,619 ± 0,368	0,607 ± 0,367	0,362 ± 0,201


Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* ACC – dokładność, F1 – miara F₁.

W rozpatrywanym przypadku wyszukiwanie wyczerpujące wykazało, że najlepsze rezultaty zostały osiągnięte dla następujących parametrów modelu:

- liczba sąsiadów: 7,
- funkcja wagowa używana w prognozowaniu: równomierna,
- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 1.

Poziom wyników potwierdza rozkład gęstości prawdopodobieństwa (rys. 5.43), według którego efektywność identyfikacji obu klas charakteryzuje duże odchylenie standardowe. Wynik ten wskazuje na potwierdzenie analizy przebiegów przedstawionej w rozdziale 5.1.2, według której – mając dodatkowo na względzie wyższą efektywność klasyfikacji w pozostałych przypadkach – konsekwencją tego stanu jest mały procent wypełnienia przebiegu napięciem mięśniowym wynikającym z rzeczywistych ruchów kończyny.



Rysunek 5.43. Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzucania przedmiotem w bok


Klasyfikacja poziomu dopasowania trudności ćwiczenia do możliwości pacjenta na podstawie ruchów kończyny dolnej, podczas ćwiczenia na rotorze, bazuje na 4 seriach ze zmianą obciążenia w czasie pedałowania: seria bez obciążenia (tj. z bardzo małym obciążeniem), z lekkim poziomem obciążenia, ze średnim poziomem i z wysokim poziomem. Pierwsze trzy kategorie zostały

zakwalifikowane jako odpowiednie dla ćwiczącego. Podczas ćwiczenia przy wysokim poziomie wolontariusz zaczynał uskarżać się na duże trudności w wykonywaniu ćwiczenia, dlatego przebiegi EMG zebrane podczas tej serii zakwalifikowano jako „zbyt ciężkie”.

Cechy wykorzystane w odnośnym procesie klasyfikacji zostały zawarte w tabelach A.7 i A.8. Pięć cech, które zostały wytypowane jako najistotniejsze, to:

- MEXH *m. sartorius*,
- FBSP, GAUS8, MEXH i MORL *m. semitendinosus*

Powyższy wybór uzasadnia rozkład gęstości prawdopodobieństwa kilku z powyższych zmiennych (rys. 5.44). Ich rozkłady, podzielone na zdefiniowane klasy, znacząco różnią się od siebie, a według wartości p są zdecydowanie rozbieżne. Wartości cechujące klasę oznaczającą zbyt ciężkie ćwiczenie są bardziej skupione, zwłaszcza w przypadku zmiennej MEXH *m. sartorius*.



Rysunek 5.44. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze: **a)** MEXH *m. sartorius*; **b)** FBSP *m. semitendinosus*; **c)** GAUS8 *m. semitendinosus*; **d)** MEXH *m. semitendinosus*

Wyniki klasyfikacji znajdujące się w tabeli 5.7 wskazują, że najbardziej efektywnym klasyfikatorem poziomu dopasowania ciężkości ćwiczenia na rotorze jest KNN. Wszystkie przetestowane metody osiągają wynik bardzo dobry, zatem KNN jest korzystniejszy zaledwie o 0,5% według metryki ACC i o 0,8% według metryki F1 w porównaniu do MLP, czyli drugiego w kolejności najbardziej efektywnego klasyfikatora. Tak, jak w każdym z poprzednich testów, najefektywniejsza metoda gwarantuje również najmniejsze odchylenie standardowe wyników, co jest korzystniejsze z punktu widzenia ich interpretacji.

Tabela 5.7. Wyniki klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze

Miary*	SVM	KNN	DT	MLP
ACC	0,932 ± 0,186	0,953 ± 0,141	0,928 ± 0,171	0,948 ± 0,159
F1	0,921 ± 0,207	0,945 ± 0,162	0,908 ± 0,207	0,937 ± 0,180


Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* ACC – dokładność, F1 – miara F_1 .

Należy podkreślić, że wyszukiwanie wyczerpujące wykazało, że najkorzystniejsze wyniki zostały osiągnięte dla następujących parametrów modelu:

- liczba sąsiadów: 3,
- funkcja wagowa używana w prognozowaniu: odległość,
- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 1.

Warto zauważyć, że wyniki klasyfikacji obu zdefiniowanych stanów można uznać za zbieżne (rys. 5.45). Jednakże te, należące do klasy oznaczającej odpowiedni poziom ciężaru, cechuje wyraźnie lepsza wartość średnia i skupienie wartości.

**Rysunek 5.45.** Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze

Podsumowując efektywność oceny wykonywanych ćwiczeń należy stwierdzić, że we wszystkich testach uzyskano średnią wartość dokładności klasyfikacji nie mniejszą niż 79,63%. Najlepszą efektywność osiągnięto podczas klasyfikacji poziomu dopasowania ciężkości ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze (95,3%). W pozostałych testach niższa dokładność wynika z możliwości doboru analizowanych danych EMG.

5.4. Estymacja wykonywanych ruchów na podstawie sygnałów EMG

Do estymacji ruchów na podstawie sygnałów EMG posłużono się metodyką bazującą na modelach regresyjnych, których zadaniem jest estymacja dokładnej wartości parametrów kwaternionu

(opisujących rotację elementu anatomicznego wokół stawu) w danej chwili, na podstawie zmien-nych objaśniających będących charakterystyką aktywności mięśniowej zmierzonej, w pewnym przedziale czasowym, przed wystąpieniem tej chwili. Do estymacji wybrano trzy rodzaje ruchów: zginanie i prostowanie w stawie łokciowym, odwodzenie i przywodzenie w stawie ramiennym oraz zgięcie do przodu i wyprost do tyłu w stawie ramiennym.

Regresja jest metodą, która z reguły estymuje jedną zmienną objaśnianą, dlatego zdecydowano, na tym etapie, na modelowanie regresorów wyłącznie na bazie parametru w kwaternionu. Parametr ten można uznać za kluczowy w opisie rotacji, ponieważ opisuje on kąt, o jaki następuje obrót (zob. rozdz. 4.4.4). Procedura przygotowywania danych i przeprowadzania testów modeli we wszystkich niżej przedstawionych wynikach jest identyczna z przedstawioną w rozdziale 5.2 klasyfikacją zdrowia.

Tabela 5.8 prezentuje wyniki estymacji ruchów zginania i prostowania w stawie łokciowym. Najmniejszym błędem w teście odznaczyła się metoda KNN, której błędy są mniejsze o 0,004 według metryki MAE i o 0,007 według metryki LSLQ w porównaniu z MLP – drugim najlepszym regresorem. Jednakże, biorąc pod uwagę zakres zmian wartości parametrów kwaternionu, średni błąd o wartości 0,106 można uznać za zbyt duży, aby móc wykorzystać tą metodę w procesie rehabilitacji, do analizy napięcia mioelektrycznego.

Tabela 5.8. Wyniki estymacji ruchów zginania i prostowania w stawie łokciowym

Miary*	SVM	KNN	DT	MLP
LSLQ	0,246 ± 0,817	0,210 ± 0,613	0,238 ± 0,774	0,217 ± 0,699
MAE	0,103 ± 0,103	0,106 ± 0,077	0,103 ± 0,100	0,110 ± 0,083

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* LSLQ – najmniejsze kwadraty logarytmu współczynnika dokładności, MAE – średni błąd bezwzględny.

Pięć cech, które zostały sklasyfikowane jako najistotniejsze w tym przypadku, to: WL, CGAU8, FBSP, MORL i SHAN *m. brachialis*. Z kolei wynikiem wyszukiwania wyczerpującego są następujące parametry KNN:

- liczba sąsiadów: 9,
- funkcja wagowa używana w prognozowaniu: równomierna,
- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 2.

Według wyników estymacji ruchów odwodzenia i przywodzenia w stawie ramiennym (tab. 5.9), najkorzystniejszym regresorem w tym zadaniu jest KNN. Metoda ta gwarantuje niemal dwukrotnie korzystniejszy wynik według metryki MAE oraz prawie trzykrotnie korzystniejszy według metryki LSLQ od poprzednio opisanego zadania regresji. Wszystkie regresory mają zatem zbliżoną efektywność, a wybór KNN podyktowany jest analizą zarówno średniego błędu z obu miar, jak i jego odchylenia standardowego.

Tabela 5.9. Wyniki estymacji ruchów odwodzenia i przywodzenia w stawie ramiennym

Miary*	SVM	KNN	DT	MLP
LSLQ	0,050 ± 0,189	0,046 ± 0,162	0,052 ± 0,192	0,046 ± 0,160
MAE	0,051 ± 0,064	0,056 ± 0,056	0,054 ± 0,064	0,059 ± 0,055

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* LSLQ – najmniejsze kwadraty logarytmu współczynnika dokładności, MAE – średni błąd bezwzględny.

Pięć cech, które zostały wytypowane przez algorytm jako najistotniejsze, to:

- MORL *m. trapezius*,
- MAV, MAV1, MAV2 i VAR *m. triceps brachii*.

Z kolei wyszukiwanie wyczerpujące wykazało, że najlepsze wyniki zostały osiągnięte dla następujących parametrów modelu:

- liczba sąsiadów: 9,
- funkcja wagowa używana w prognozowaniu: równomierna,
- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 3.

Wyniki estymacji ruchów zgięcia do przodu i wyprost do tyłu w stawie ramiennym, przedstawione na rysunku 5.10, wskazują na KNN jako najefektywniejszą metodę regresji. Ponownie wyniki regresji są bardzo zbliżone, a wybór konkretnej metody jest kompromisem pomiędzy wartością średnią a odchyleniem standardowym wyników. Poziom otrzymanych błędów kwalifikuje jednak te modele jako akceptowalne dla przedstawionego systemu rehabilitacji.

Tabela 5.10. Wyniki estymacji ruchów zgięcia do przodu i wyprost do tyłu w stawie ramiennym

Miary*	SVM	KNN	DT	MLP
LSLQ	0,084 ± 0,314	0,079 ± 0,271	0,083 ± 0,324	0,080 ± 0,313
MAE	0,067 ± 0,075	0,072 ± 0,062	0,065 ± 0,074	0,068 ± 0,070

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

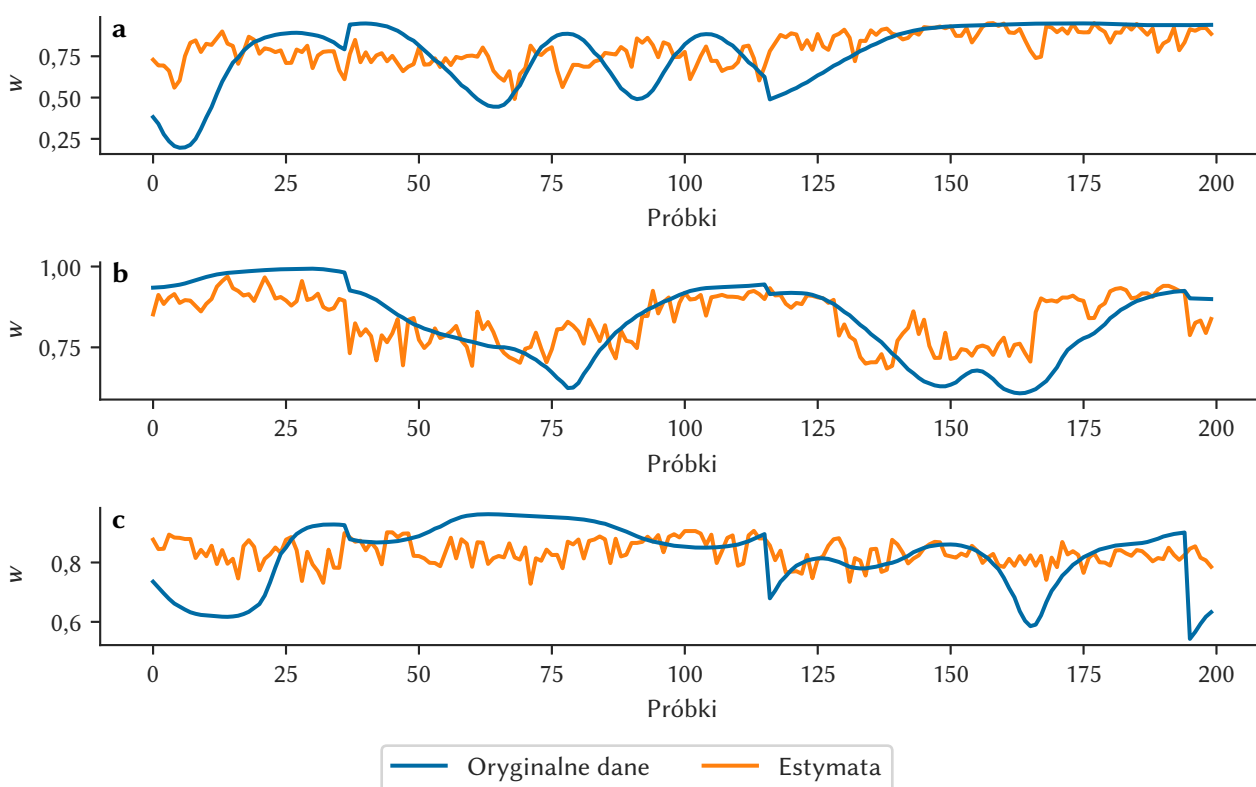
* LSLQ – najmniejsze kwadraty logarytmu współczynnika dokładności, MAE – średni błąd bezwzględny.

Wybór pięciu najistotniejszych cech kształtuje się identycznie, jak dla estymacji ruchów odwodzenia i przywodzenia w stawie ramiennym – modele te korzystają z tego samego zestawu zmiennych wejściowych (tzn. tych samych mięśni). Ponadto, wyszukiwanie wyczerpujące wykazuje, że najlepsze wyniki KNN są możliwe do osiągnięcia dla następujących parametrów modelu:

- liczba sąsiadów: 9,
- funkcja wagowa używana w prognozowaniu: równomierna,

- algorytm szacujący najbliższych sąsiadów: BallTree,
- rozmiar liścia: 5,
- parametr mocy: 3.

W celu demonstracji osiągniętych rezultatów przygotowano dodatkowo wizualizację wybranych wycinków estymat parametru w kwaternionu w porównaniu do ich rzeczywistych wartości (rys. 5.46). Na przedstawionym przykładzie wyłącznie estymacja odwodzenia i przywodzenia w stawie ramiennym (rys. 5.46b) podąża prawidłowo – ale nadal z pewnym błędem – za torem zmian rzeczywistych wartości. Jest to jednak związane przede wszystkim z bardzo gładkim przebiegiem krzywej. Jak wynika z analizy rysunków 5.46a i 5.46c, testowane regresory są nieodporne na krótkie (trwające poniżej 1 s) i stosunkowo duże skoki wartości zmiennych objaśnianych. Należy zauważyć, że nawet najlepszy przypadek wciąż wymaga dodatkowych operacji w zakresie kondycjonowania sygnału (np. filtracji).



Rysunek 5.46. Porównanie wycinków oryginalnych próbek danych rotacji z ich estymatami: **a)** zginanie i prostowanie w stawie łokciowym; **b)** odwodzenie i przywodzenie w stawie ramiennym; **c)** zgięcie do przodu i wyprost do tyłu w stawie ramiennym

Przedstawiona metodyka estymacji ruchów stanowi gwarancję uzyskania satysfakcjonujących wyników – średnia z wartości błędów wynosi 0,078. Gorsze wyniki estymacji ruchów zginania i prostowania w stawie łokciowym są spowodowane użytymi zmiennymi objaśnianymi regresorów. Zapis ruchu tworzony przez kamerę Kinect zawiera niemożliwe do wyeliminowania zakłócenia, które skutecznie pozbawiają modele regresyjne możliwości ich efektywnego nauczania.

Rozdział 6

Podsumowanie i wnioski

Problemem badawczym, którego dotyczyła niniejsza rozprawa jest metodologia automatycznego wspomaganie procesu rehabilitacji dzieci chorych na *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta*. Choroby te odbierają częściowo lub nawet całkowicie możliwość własnej lokomocji. Aktualnie zauważa się brak odpowiednich przyrządów rehabilitacyjnych, przystosowanych do prowadzenia wyspecjalizowanych ćwiczeń ruchowych, których dostępność, szczególnie ze względu na koszt, nie byłaby przeszkodą dla potrzebujących rodzin. Oprócz utrudnień w dostępie do urządzeń należy także mieć na uwadze ograniczone możliwości i liczbę osób odpowiedzialnych za rehabilitację w zakresie diagnozowania, układania planu ćwiczeń oraz kontrolowania jej przebiegu. Ponadto, jako istotny problem należy wskazać niechęć dzieci do wykonywania ćwiczeń, których przebieg jest często żmudny i długotrwały. W dobie coraz większego nacisku na medycynę spersonalizowaną, jednym z efektywnych sposobów przezwyciężenia odnośnych problemów może być zautomatyzowanie procesów ćwiczeniowych.

Usługi medyczne są po dziś dzień jednymi z najmniej zautomatyzowanych. Stąd też, z oczywistych względów, wprowadzenie samodzielnego wnioskowania wśród wielu osób budziłoby zastrzeżenia natury etycznej (podejmowanie ryzykownych decyzji przez maszynę), prawnej (odpowiedzialność za pacjenta), a także metodologicznej (poprawność podejmowanych decyzji). Zdrowie człowieka – jako najwyższe dobro – było od zawsze traktowane w sposób jak najsilniej wykluczający możliwość popełnienia pomyłki, co przekłada się na staranność w procesach rozwojowych medycyny. Nieliczne innowacyjne systemy rehabilitacyjne, jak np. Lokomat, pełnią głównie funkcje wspomaganie ruchu (poprzez stosowanie egzoszkieleatów) i odciążania uwagi ćwiczącego od całego procesu (poprzez zastosowanie prostych wizualizacji). Brak jest zatem warstw nadrzędnych (szczególnie warstwy optymalizacji) realizujących w sposób zautomatyzowany zadanie sterowania wielopoziomowego. Pomimo tych przypadków zaawansowanych urządzeń terapeutycznych (rozd. 3.3), fizjoterapia dzieci z *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta*, w porównaniu z pozostałymi dziedzinami nauk o zdrowiu, wydaje się być szczególnie marginalizowana pod względem stosowania najnowszych zdobyczy nauki i techniki.

Celem nadrzędnym prac badawczych będących tematem dysertacji było opracowanie podstaw metodologicznych dla automatycznej platformy eksperckiej asystującej podczas procesu rehabi-



litacji dzieci chorych na *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta*, co wiąże się z postawioną na początku pracy tezą o treści „zastosowanie metod uczenia maszynowego do analizy napięcia mięśniowego w procesach rehabilitacji dzieci z *paralysis cereбрalis infantium* oraz *osteogenesis imperfecta* pozwoli na zautomatyzowanie szeregu zestawów ćwiczeń i procedur im towarzyszących”. Propozycja opisywanego systemu składała się z trzech części: podsystemu identyfikującego stan układu ruchu pacjenta, podsystemu odpowiedzialnego za weryfikację wykonywanych ćwiczeń oraz podsystemu identyfikacji ruchów kończyn na podstawie sygnałów elektromiografii powierzchniowej. Cele te do realizacji wymagały podejścia wieloetapowego, w którym wykonano szereg prac związanych m.in. z: gromadzeniem odpowiednich danych, selekcją efektywnych metod przetwarzania sygnałów, wyborem reprezentacji danych dla maszyn uczących, a także opracowaniem modeli klasyfikacyjnych i regresyjnych. Przedstawioną w rozprawie metodykę nie należy jednak traktować jako ostateczne rozwiązanie problemu braku automatyzacji procesów rehabilitacyjnych, a jedynie jako fundament dla dalszego rozwoju układów regulacji automatycznej w odnośnym kierunku.

Prace wykonane w ramach badań nad tematyką rozprawy podzielono na cztery fazy obejmujące: gromadzenie danych pomiarowych od wolontariuszy, selekcję metod filtracji i przetwarzania sygnałów elektromiografii, opracowanie i testy modeli klasyfikacji oraz opracowanie i testy modeli regresji.

Dane zgromadzono podczas około 40-minutowych sesji z każdym z wolontariuszy. Nad brzościami ich mięśni umieszczano elektrody, a następnie proszono wolontariuszy o wykonywanie serii prostych ruchów i ćwiczeń. W czasie wykonywania ćwiczeń mierzona była aktywność mioelektryczna wybranych mięśni, a kamera Kinect rejestrowała ruch poszczególnych części ciała.

Każdy z zarejestrowanych przebiegów elektromiografii dzielono na fragmenty, stosując metodę okien statycznych. Uzyskane w ten sposób zbiory wartości napięcia poddawano licznym transformacjom w dziedzinie czasu (m.in. średnia wartości bezwzględnych amplitudy sygnału,) i w dziedzinie czasowo-częstotliwościowej (ciągła transformata falkowa), w celu uzyskania właściwych danych wejściowych. Przed wykorzystaniem wszystkich współczynników jako danych wejściowych sieci uczących, poddawano je analizie wariacyjnej w celu redukcji wymiarowości wektora cech opisującego dany przypadek, a uzyskane wektory danych wejściowych przeskalowywano do normy jednostkowej.

Do utworzenia modeli klasyfikacji i regresji wykorzystano cztery metody uczenia maszynowego: algorytm k najbliższych sąsiadów, drzewa decyzyjne, maszyna wektorów nośnych i perceptron wielowarstwowy. Zbadano ich skuteczność podczas trzech głównych zadań: identyfikacji stanu zdrowia (dziecko zdrowe, z PCI lub z OI), oceny wykonywania ćwiczeń (ruchu łokciem z obciążeniem, rzutu przedmiotem i ćwiczenia na rotorze) oraz estymacji wykonywanych ruchów (w stawie łokciowym i ramiennym) na podstawie sygnałów elektromiografii. W pierwszym zadaniu uzyskano w pełni satysfakcjonującą dokładność klasyfikacji na poziomie 94,3%. Oceny wykonywania ćwiczeń dokonano z dokładnością sięgającą 79,63%. Efekt ostatniego zadania obarczony był średnim błędem bezwzględnym wynoszącym 0,078.



Stwierdzono, że na podstawie stosowanej metodyki możliwe jest opracowanie zintegrowanego systemu wnioskującego i kontrolującego przebieg rehabilitacji (zautomatyzowanie). Osoba poddawana rehabilitacji może zostać poddana diagnozie przed rozpoczęciem ćwiczeń (określone mogą być np. obostrzenia dot. podnoszonych ciężarów). Następnie – w trakcie ćwiczeń – jej ruch może już zostać poddany weryfikacji w zakresie prawidłowości wykonywanego schematu ćwiczeń (na podstawie estymacji rotacji elementów kończyn wokół stawów), obciążenia kończyny górnej dodatkowymi przedmiotami, bądź ustalenia obciążenia dla układu pedałów w rotorze. Fakt ten w pełni uzasadnia postawioną w rozprawie tezę.

Oryginalnym wkładem autora jest więc przede wszystkim wykorzystanie maszyn uczących oraz przebiegów napięcia mięśniowego do celów komputerowego: rozróżnienia dzieci zdrowych od chorujących na *paralysis cerebialis infantium* lub *osteogenesis imperfecta*, ustalenia wagi ciężarka umieszczonego na ręce podczas ćwiczenia, oceny stopnia dopasowania ciężkości ćwiczenia do możliwości pacjenta oraz estymacji parametrów kwaternionu opisującego rotację elementów anatomicznych wokół stawów ciała. Rozprawa zawiera również oryginalną analizę porównawczą napięcia mięśniowego pozyskanego podczas wykonywania ćwiczeń dzieci zdrowych, z *paralysis cerebialis infantium* oraz z *osteogenesis imperfecta*.

Warto również podkreślić, że wykonanie opisanych badań wymagało utworzenia złożonej, dedykowanej aplikacji komputerowej, za pomocą której możliwa była kontrola działania kamery Kinect i zapis jej rejestracji w formie danych liczbowych opisujących ruch ciała.

Rozwinięciem dla opisanych badań byłoby powtórzenie procedury testowej na dużej próbie populacyjnej. Większa różnorodność i liczność przebiegów elektromiografii pozwoliłaby uzyskać bardziej dokładne i efektywne wyniki. Należałoby jednak sięgnąć po inne metody rejestracji ruchu niż kamera Kinect, której niedoskonałości (duży stopień zaszumienia przebiegów) są powodem przeprowadzania procesu uczenia modeli w sposób mniej efektywny.

Bibliografia

- [1] M. Tegmark. *Life 3.0: Being Human in the Age of Artificial Intelligence*. 1 wyd. New York: Alfred A. Knopf, 2017, s. 364.
- [2] D. S. Char, N. H. Shah i D. Magnus. „Implementing Machine Learning in Health Care — Addressing Ethical Challenges”. W: *New England Journal of Medicine* 378.11 (2018), s. 981–983. DOI: [10.1056/NEJMp1714229](https://doi.org/10.1056/NEJMp1714229).
- [3] L. Oakden-Rayner i in. „Precision Radiology: Predicting longevity using feature engineering and deep learning methods in a radiomics framework”. W: *Scientific Reports* 7 (2017), s. 1648. DOI: [10.1038/s41598-017-01931-w](https://doi.org/10.1038/s41598-017-01931-w).
- [4] D. Anaby i in. „Current Rehabilitation Practices for Children with Cerebral Palsy: Focus and Gaps”. W: *Physical & Occupational Therapy In Pediatrics* 37.1 (2017), s. 1–15. DOI: [10.3109/01942638.2015.1126880](https://doi.org/10.3109/01942638.2015.1126880).
- [5] Wikipedia. *Układ regulacji (automatyka)*. URL: [https://pl.wikipedia.org/wiki/Uk%7B%5C%7Dad%7B%5C_%7Dregulacji%7B%5C_%7D\(automatyka\)](https://pl.wikipedia.org/wiki/Uk%7B%5C%7Dad%7B%5C_%7Dregulacji%7B%5C_%7D(automatyka)) (term. wiz. 30. 11. 2017).
- [6] *Michel Petrucciani - Legendary Jazz Pianist*. URL: <http://www.michelpetrucciani.com> (term. wiz. 02. 08. 2017).
- [7] M. A. Oskoei i H. Hu. „Myoelectric control systems—A survey”. W: *Biomedical Signal Processing and Control* 2.4 (2007), s. 275–294. DOI: [10.1016/j.bspc.2007.07.009](https://doi.org/10.1016/j.bspc.2007.07.009).
- [8] A. Phinyomark, P. Phukpattaranont i C. Limsakul. „Feature reduction and selection for EMG signal classification”. W: *Expert Systems with Applications* 39.8 (2012), s. 7420–7431. DOI: [10.1016/j.eswa.2012.01.102](https://doi.org/10.1016/j.eswa.2012.01.102).
- [9] M. A. Oskoei i H. Hu. „Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb”. W: *IEEE Transactions on Biomedical Engineering* 55.8 (2008), s. 1956–1965. DOI: [10.1109/TBME.2008.919734](https://doi.org/10.1109/TBME.2008.919734).
- [10] M. Hariharan i in. „A comparative study of wavelet families for classification of wrist motions”. W: *Computers & Electrical Engineering* 38.6 (2012), s. 1798–1807. DOI: [10.1016/j.compeleceng.2012.08.009](https://doi.org/10.1016/j.compeleceng.2012.08.009).
- [11] E. Gokgoz i A. Subasi. „Comparison of decision tree algorithms for EMG signal classification using DWT”. W: *Biomedical Signal Processing and Control* 18 (2015), s. 138–144. DOI: [10.1016/j.bspc.2014.12.005](https://doi.org/10.1016/j.bspc.2014.12.005).
- [12] K. S. Kim i in. „Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions”. W: *Current Applied Physics* 11.3 (2011), s. 740–745. DOI: [10.1016/j.cap.2010.11.051](https://doi.org/10.1016/j.cap.2010.11.051).
- [13] A. Palkowski i G. Redlarski. „Basic Hand Gestures Classification Based on Surface Electromyography”. W: *Computational and Mathematical Methods in Medicine* 2016 (2016), s. 7. DOI: [10.1155/2016/6481282](https://doi.org/10.1155/2016/6481282).



- [14] K. Veer i T. Sharma. „A novel feature extraction for robust EMG pattern recognition”. W: *Journal of Medical Engineering & Technology* 40.4 (2016), s. 149–154. DOI: [10.3109/03091902.2016.1153739](https://doi.org/10.3109/03091902.2016.1153739).
- [15] A. Palkowski i in. „Basic evaluation of limb exercises based on electromyography and classification methods”. W: *8th International Interdisciplinary PhD Workshop*. Świnoujście, Poland, 2018, s. 32–32.
- [16] L. Peng, Z.-G. Hou i W. Wang. „A dynamic EMG-torque model of elbow based on neural networks”. W: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Milan, Italy: IEEE, 2015, s. 2852–2855. DOI: [10.1109/EMBC.2015.7318986](https://doi.org/10.1109/EMBC.2015.7318986).
- [17] Z. Li, J. Guo i D. Huang. „Bidirectional joint torque prediction with EMG of multiple channels: Both agonist and antagonist muscles are necessary”. W: *2016 Chinese Control and Decision Conference (CCDC)*. Yinchuan, China: IEEE, 2016, s. 4226–4231. DOI: [10.1109/CCDC.2016.7531723](https://doi.org/10.1109/CCDC.2016.7531723).
- [18] A. Krasoulis, S. Vijayakumar i K. Nazarpour. „Evaluation of regression methods for the continuous decoding of finger movement from surface EMG and accelerometry”. W: *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*. Montpellier, France: IEEE, 2015, s. 631–634. DOI: [10.1109/NER.2015.7146702](https://doi.org/10.1109/NER.2015.7146702).
- [19] J. Nieveen i in. „Polynomial Kalman filter for myoelectric prosthetics using efficient kernel ridge regression”. W: *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)*. Shanghai, China: IEEE, 2017, s. 432–435. DOI: [10.1109/NER.2017.8008382](https://doi.org/10.1109/NER.2017.8008382).
- [20] J. W. Błaszczuk. *Biomechanika kliniczna*. 1 wyd. Warszawa: Wydawnictwo Lekarskie PZWL, 2004, s. 283.
- [21] R. Skoczylas, red. *Biologia: podręcznik do liceum ogólnokształcącego, liceum profilowanego i technikum: kształcenie w zakresie rozszerzonym część 2, tom 2*. 1 wyd. Warszawa: Wydawnictwa Szkolne i Pedagogiczne, 2003, s. 328.
- [22] D. J. Magee, J. E. Zachazewski i W. S. Quillen. *Scientific Foundations and Principles of Practice in Musculoskeletal Rehabilitation*. 1 wyd. Saunders, 2007, s. 720.
- [23] D. Tejszerska, E. Świtoński i M. Gzik, red. *Biomechanika narządu ruchu człowieka*. 1 wyd. Radom: Wydawnictwo Naukowe Instytutu Technologii Eksploatacji - PIB, 2011, s. 492.
- [24] E. Henneman. „Relation between Size of Neurons and Their Susceptibility to Discharge”. W: *Science* 126.3287 (1957), s. 1345–1347.
- [25] E. Henneman i L. M. Mendell. „Functional Organization of Motoneuron Pool and its Inputs”. W: *Comprehensive Physiology*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2011, s. 423–507. DOI: [10.1002/cphy.cp010211](https://doi.org/10.1002/cphy.cp010211).
- [26] B. Kolb i I. Q. Whishaw. „Neuropsychology”. W: *Handbook of Psychophysiology*. Red. J. T. Cacioppo, L. G. Tassinary i G. G. Berntson. 4 wyd. Cambridge Handbooks in Psychology. Cambridge: Cambridge University Press, 2016, s. 26–38. DOI: [10.1017/9781107415782.003](https://doi.org/10.1017/9781107415782.003).
- [27] R. L. Drake, A. W. Vogl i A. W. M. Mitchell. *Gray's Anatomy for Students*. Red. M. Bruska i in. 3 wyd. Wrocław: Edra Urban & Partner, 2016, s. 366.
- [28] M. Oskoui i in. „An update on the prevalence of cerebral palsy: a systematic review and meta-analysis”. W: *Developmental Medicine & Child Neurology* 55.6 (2013), s. 509–519. DOI: [10.1111/dmcn.12080](https://doi.org/10.1111/dmcn.12080).

- [29] P. J. Accardo, red. *Capute & Accardo's Neurodevelopmental Disabilities in Infancy and Childhood: Neurodevelopmental Diagnosis and Treatment*. 3 wyd. Baltimore, MD: Brookes Publishing, 2007, s. 704.
- [30] S. Levitt. *Rehabilitacja w porażeniu mózgowym i zaburzeniach ruchu*. 2 wyd. Warszawa: Wydawnictwo Lekarskie PZWL, 2007, s. 466.
- [31] S. Martin. *Nauczanie umiejętności ruchowych dzieci z mózgowym porażeniem dziecięcym i podobnymi zaburzeniami ruchowymi*. 1 wyd. Warszawa: ReHouse – Gilewski, Boryczka, Makarevskaya spółka jawna, 2012, s. 254.
- [32] N. H. Mayer, A. Esquenazi i M. K. Childers. „Common patterns of clinical motor dysfunction”. W: *Muscle & Nerve* 20.S6 (1997), s. 21–35. DOI: [10.1002/\(SICI\)1097-4598\(1997\)6+<21::AID-MUS4>3.0.CO;2-L](https://doi.org/10.1002/(SICI)1097-4598(1997)6+<21::AID-MUS4>3.0.CO;2-L).
- [33] P. L. Rosenbaum i in. „Prognosis for Gross Motor Function in Cerebral Palsy”. W: *JAMA* 288.11 (2002), s. 1357–1363. DOI: [10.1001/jama.288.11.1357](https://doi.org/10.1001/jama.288.11.1357).
- [34] A. Forlino i J. C. Marini. „Osteogenesis imperfecta”. W: *The Lancet* 387.10028 (2016), s. 1657–1671. DOI: [10.1016/S0140-6736\(15\)00728-X](https://doi.org/10.1016/S0140-6736(15)00728-X).
- [35] J. P. Bilezikian, L. G. Raisz i T. J. Martin, red. *Principles of Bone Biology*. 3 wyd. Academic Press, 2008, s. 1900.
- [36] Genetics Home Reference. *Osteogenesis imperfecta*. URL: <https://ghr.nlm.nih.gov/condition/osteogenesis-imperfecta> (term. wiz. 02.08.2017).
- [37] J. Reeder i E. Orwoll. „Adults with Osteogenesis Imperfecta”. W: *New England Journal of Medicine* 355.26 (2006), e28. DOI: [10.1056/NEJMicm062996](https://doi.org/10.1056/NEJMicm062996).
- [38] H. Kang, S. Aryal A. C. i J. C. Marini. „Osteogenesis imperfecta: new genes reveal novel mechanisms in bone dysplasia”. W: *Translational Research* 181 (2017), s. 27–48. DOI: [10.1016/j.trsl.2016.11.005](https://doi.org/10.1016/j.trsl.2016.11.005).
- [39] D. O. Silience, A. Senn i D. M. Danks. „Genetic heterogeneity in osteogenesis imperfecta”. W: *Journal of Medical Genetics* 16.2 (1979), s. 101–116. DOI: [10.1136/jmg.16.2.101](https://doi.org/10.1136/jmg.16.2.101).
- [40] P. Arundel. „Osteogenesis imperfecta”. W: *Paediatrics and Child Health* 25.12 (2015), s. 574–579. DOI: [10.1016/j.paed.2015.07.007](https://doi.org/10.1016/j.paed.2015.07.007).
- [41] F. Rauch i F. H. Glorieux. „Osteogenesis imperfecta”. W: *The Lancet* 363.9418 (2004), s. 1377–1385. DOI: [10.1016/S0140-6736\(04\)16051-0](https://doi.org/10.1016/S0140-6736(04)16051-0).
- [42] C.-S. Song. „Effects of Task-oriented Approach on Affected Arm Function in Children with Spastic Hemiplegia Due to Cerebral Palsy”. W: *Journal of Physical Therapy Science* 26.6 (2014), s. 797–800. DOI: [10.1589/jpts.26.797](https://doi.org/10.1589/jpts.26.797).
- [43] V. Rowe. „Task-Oriented Training at Home for Stroke Rehabilitation”. W: *American Journal of Occupational Therapy* 70 (2016), 7011520302p1. DOI: [10.5014/ajot.2016.70S1-P05080](https://doi.org/10.5014/ajot.2016.70S1-P05080).
- [44] A. Shumway-Cook i M. H. Woollacott. *Motor Control: Theory and Practical Applications*. 2 wyd. Baltimore: Lippincott Williams & Wilkins, 2001, s. 614.
- [45] E. Mikołajewska. *Neurorehabilitacja Zaopatrzenie ortopedyczne*. 1 wyd. Warszawa: Wydawnictwo Lekarskie PZWL, 2009, s. 136.
- [46] W. Högler i in. „The Effect of Whole Body Vibration Training on Bone and Muscle Function in Children With Osteogenesis Imperfecta”. W: *The Journal of Clinical Endocrinology & Metabolism* 102.8 (2017), s. 2734–2743. DOI: [10.1210/jc.2017-00275](https://doi.org/10.1210/jc.2017-00275).
- [47] Hocoma. *Lokomat*. URL: <https://www.hocoma.com/us/solutions/lokomat> (term. wiz. 02.08.2017).

- [48] U. Dunder i in. „A Comparative Study of Conventional Physiotherapy Versus Robotic Training Combined with Physiotherapy in Patients with Stroke”. W: *Topics in Stroke Rehabilitation* 21.6 (2014), s. 453–461. DOI: [10.1310/tsr2106-453](https://doi.org/10.1310/tsr2106-453).
- [49] L. Zimmerli i in. „Increasing Patient Engagement During Virtual Reality-Based Motor Rehabilitation”. W: *Archives of Physical Medicine and Rehabilitation* 94.9 (2013), s. 1737–1746. DOI: [10.1016/j.apmr.2013.01.029](https://doi.org/10.1016/j.apmr.2013.01.029).
- [50] Biodex Medical Systems. *Biodex*. URL: <http://www.biodex.com> (term. wiz. 02.08.2017).
- [51] J. R. Engsborg, S. A. Ross i D. R. Collins. „Increasing Ankle Strength to Improve Gait and Function in Children with Cerebral Palsy: A Pilot Study”. W: *Pediatric Physical Therapy* 18.4 (2006), s. 266–275. DOI: [10.1097/01.pep.0000233023.33383.2b](https://doi.org/10.1097/01.pep.0000233023.33383.2b).
- [52] CYBERDYNE. *HAL (Hybrid Assistive Limb)*. URL: <https://www.cyberdyne.jp/english/products/HAL/> (term. wiz. 02.08.2017).
- [53] T. Ogata i in. „Hybrid Assistive Limb (HAL) Rehabilitation in Patients with Acute Hemorrhagic Stroke”. W: *Neurologia medico-chirurgica* 55.12 (2015), s. 901–906. DOI: [10.2176/nmc.oa.2015-0209](https://doi.org/10.2176/nmc.oa.2015-0209).
- [54] D. Grasmücke i in. „Experiences in Four Years of HAL Exoskeleton SCI Rehabilitation”. W: *Converging Clinical and Engineering Research on Neurorehabilitation II. Biosystems & Biorobotics, vol 15*. Red. J. Ibáñez i in. Cham: Springer, 2017, s. 1235–1238. DOI: [10.1007/978-3-319-46669-9_201](https://doi.org/10.1007/978-3-319-46669-9_201).
- [55] EGZOTech. *Luna EMG*. URL: <https://egzotech.com> (term. wiz. 02.08.2017).
- [56] A. C. Schmartz i in. „Measurement of muscle stiffness using robotic assisted gait orthosis in children with cerebral palsy: a proof of concept”. W: *Disability and Rehabilitation: Assistive Technology* 6.1 (2011), s. 29–37. DOI: [10.3109/17483107.2010.509884](https://doi.org/10.3109/17483107.2010.509884).
- [57] S. K. Phelan, B. E. Gibson i F. V. Wright. „What is it like to walk with the help of a robot? Children’s perspectives on robotic gait training technology”. W: *Disability and Rehabilitation* 37.24 (2015), s. 2272–2281. DOI: [10.3109/09638288.2015.1019648](https://doi.org/10.3109/09638288.2015.1019648).
- [58] B. Beveridge i in. „“You gotta try it all”: Parents’ Experiences with Robotic Gait Training for their Children with Cerebral Palsy”. W: *Physical & Occupational Therapy In Pediatrics* 35.4 (2015), s. 327–341. DOI: [10.3109/01942638.2014.990547](https://doi.org/10.3109/01942638.2014.990547).
- [59] H. J. A. van Hedel, A. Meyer-Heim i C. Rüsç-Bohtz. „Robot-assisted gait training might be beneficial for more severely affected children with cerebral palsy”. W: *Developmental Neurorehabilitation* 19.6 (2016), s. 410–415. DOI: [10.3109/17518423.2015.1017661](https://doi.org/10.3109/17518423.2015.1017661).
- [60] Y.-J. Chang, S.-F. Chen i J.-D. Huang. „A Kinect-based system for physical rehabilitation: A pilot study for young adults with motor disabilities”. W: *Research in Developmental Disabilities* 32.6 (2011), s. 2566–2570. DOI: [10.1016/j.ridd.2011.07.002](https://doi.org/10.1016/j.ridd.2011.07.002).
- [61] C. Gordon, S. Roopchand-Martin i A. Gregg. „Potential of the Nintendo Wii as a rehabilitation tool for children with cerebral palsy in a developing country: a pilot study”. W: *Physiotherapy* 98.3 (2012), s. 238–242. DOI: [10.1016/j.physio.2012.05.011](https://doi.org/10.1016/j.physio.2012.05.011).
- [62] Y.-J. Chang, W.-Y. Han i Y.-C. Tsai. „A Kinect-based upper limb rehabilitation system to assist people with cerebral palsy”. W: *Research in Developmental Disabilities* 34.11 (2013), s. 3654–3659. DOI: [10.1016/j.ridd.2013.08.021](https://doi.org/10.1016/j.ridd.2013.08.021).
- [63] D. Fehlings i in. „Interactive Computer Play as “Motor Therapy” for Individuals With Cerebral Palsy”. W: *Seminars in Pediatric Neurology* 20.2 (2013), s. 127–138. DOI: [10.1016/j.spen.2013.06.003](https://doi.org/10.1016/j.spen.2013.06.003).

- [64] B. Bonnechère i in. „Can serious games be incorporated with conventional treatment of children with cerebral palsy? A review”. W: *Research in Developmental Disabilities* 35.8 (2014), s. 1899–1913. DOI: [10.1016/j.ridd.2014.04.016](https://doi.org/10.1016/j.ridd.2014.04.016).
- [65] F. R. C. Machado i in. „Motor Improvement Using Motion Sensing Game Devices for Cerebral Palsy Rehabilitation”. W: *Journal of Motor Behavior* 49.3 (2017), s. 273–280. DOI: [10.1080/00222895.2016.1191422](https://doi.org/10.1080/00222895.2016.1191422).
- [66] D. Levac i in. „Active Video Gaming for Children with Cerebral Palsy: Does a Clinic-Based Virtual Reality Component Offer an Additive Benefit? A Pilot Study”. W: *Physical & Occupational Therapy In Pediatrics* 38.1 (2018), s. 74–87. DOI: [10.1080/01942638.2017.1287810](https://doi.org/10.1080/01942638.2017.1287810).
- [67] S. van der Walt, S. C. Colbert i G. Varoquaux. „The NumPy Array: A Structure for Efficient Numerical Computation”. W: *Computing in Science & Engineering* 13.2 (2011), s. 22–30. DOI: [10.1109/MCSE.2011.37](https://doi.org/10.1109/MCSE.2011.37).
- [68] W. McKinney. „Data Structures for Statistical Computing in Python”. W: *Proceedings of the 9th Python in Science Conference*. Red. S. van der Walt i J. Millman. 2010, s. 51–56.
- [69] E. Jones, T. Oliphant, P. Peterson i in. *SciPy: Open source scientific tools for Python*. 2001. URL: <https://www.scipy.org>.
- [70] G. Lee i in. *PyWavelets - Wavelet Transforms in Python*. URL: <https://github.com/PyWavelets/pywt>.
- [71] F. Pedregosa i in. „Scikit-learn: Machine Learning in Python”. W: *Journal of Machine Learning Research* 12 (2011), s. 2825–2830.
- [72] O. Grisel i in. *scikit-learn/scikit-learn: 0.19.1*. DOI: [10.5281/zenodo.1034765](https://doi.org/10.5281/zenodo.1034765). URL: <https://zenodo.org/record/1034765>.
- [73] J. D. Hunter. „Matplotlib: A 2D Graphics Environment”. W: *Computing in Science & Engineering* 9.3 (2007), s. 90–95. DOI: [10.1109/MCSE.2007.55](https://doi.org/10.1109/MCSE.2007.55).
- [74] Microsoft. *Kinect for Windows SDK*. URL: <https://msdn.microsoft.com/en-us/library/hh855347.aspx> (term. wiz. 30. 11. 2017).
- [75] R. A. Clark i in. „Validity of the Microsoft Kinect for assessment of postural control”. W: *Gait & Posture* 36.3 (2012), s. 372–377. DOI: [10.1016/j.gaitpost.2012.03.033](https://doi.org/10.1016/j.gaitpost.2012.03.033).
- [76] A. Palkowski. *KinectMotionCapture: A simple software for capturing human body movements using the Kinect camera*. 2016. DOI: [10.5281/zenodo.58700](https://doi.org/10.5281/zenodo.58700). URL: <https://zenodo.org/record/58700>.
- [77] G. Bianchi i R. Sorrentino. *Electronic Filter Simulation & Design*. 1 wyd. New York: McGraw-Hill Professional, 2007, s. 606.
- [78] J. T. Białasiewicz. *Falki i aproksymacje*. 1 wyd. Warszawa: Wydawnictwa Naukowo-Techniczne, 2004, s. 288.
- [79] F. Wasilewski. *Wavelet Properties Browser*. URL: <http://wavelets.pybytes.com> (term. wiz. 30. 11. 2017).
- [80] N. S. Altman. „An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression”. W: *The American Statistician* 46.3 (1992), s. 175–185. DOI: [10.1080/00031305.1992.10475879](https://doi.org/10.1080/00031305.1992.10475879).
- [81] L. Breiman i in. *Classification and Regression Trees*. 1 wyd. Monterey: Brooks/Cole Publishing, 1984, s. 358.

- [82] B. E. Boser, I. M. Guyon i V. N. Vapnik. „A training algorithm for optimal margin classifiers”. W: *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*. New York: ACM Press, 1992, s. 144–152. DOI: [10.1145/130385.130401](https://doi.org/10.1145/130385.130401).
- [83] C. Cortes i V. Vapnik. „Support-vector networks”. W: *Machine Learning* 20.3 (1995), s. 273–297. DOI: [10.1007/BF00994018](https://doi.org/10.1007/BF00994018).
- [84] V. N. Vapnik. *The Nature of Statistical Learning Theory*. 2 wyd. New York: Springer New York, 2000, s. 314. DOI: [10.1007/978-1-4757-3264-1](https://doi.org/10.1007/978-1-4757-3264-1).
- [85] K.-B. Duan i S. S. Keerthi. „Which Is the Best Multiclass SVM Method? An Empirical Study”. W: *Multiple Classifier Systems. MCS 2005. Lecture Notes in Computer Science*. Red. N. C. Oza i in. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005, s. 278–285. DOI: [10.1007/11494683_28](https://doi.org/10.1007/11494683_28).
- [86] A. J. Smola i B. Schölkopf. „A tutorial on support vector regression”. W: *Statistics and Computing* 14.3 (2004), s. 199–222. DOI: [10.1023/B:STCO.0000035301.49549.88](https://doi.org/10.1023/B:STCO.0000035301.49549.88).
- [87] G. C. Cawley i N. L. C. Talbot. „On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation”. W: *Journal of Machine Learning Research* 11 (2010), s. 2079–2107.
- [88] S. Marsland. *Machine Learning: An Algorithmic Perspective*. 2 wyd. Boca Raton, FL: Chapman i Hall/CRC Press, 2015, s. 457.
- [89] C. Tofallis. „A better measure of relative prediction accuracy for model selection and model estimation”. W: *Journal of the Operational Research Society* 66.8 (2015), s. 1352–1362. DOI: [10.1057/jors.2014.103](https://doi.org/10.1057/jors.2014.103).
- [90] C. Tofallis. „Erratum: A better measure of relative prediction accuracy for model selection and model estimation”. W: *Journal of the Operational Research Society* 66.3 (2015), s. 524–524. DOI: [10.1057/jors.2014.124](https://doi.org/10.1057/jors.2014.124).
- [91] W. Sierpiński i J. Łoś. *Arytmetyka teoretyczna*. 5 wyd. Warszawa: Państwowe Wydawnictwo Naukowe, 1969, s. 273.
- [92] L. Dorst, D. Fontijne i S. Mann. *Geometric Algebra for Computer Science*. 1 wyd. Boston: Morgan Kaufmann, 2009, s. 664.
- [93] InnerBody. *Muscular System*. URL: <http://www.innerbody.com> (term. wiz. 30. 11. 2017).

Spis rysunków

1.1.	Schemat klasycznego układu regulacji (w pętli zamkniętej) [5]	7
1.2.	Schemat propozycji układu regulacji typu HITL do zastosowania w rehabilitacji	8
1.3.	Schemat blokowy przedstawiający uproszczony algorytm proponowanego zautomatyzowanego procesu rehabilitacji	9
1.4.	Koncepcja systemu rehabilitacji wykorzystującego techniki multimedialne, ortezy wspomagane oraz kontrolę działania elementów mechanicznych przyrządu do zautomatyzowanej regulacji ćwiczeń	10
1.5.	Michel Petrucciani [6]	10
2.1.	Struktura mięśnia szkieletowego z uwzględnieniem błon łącznotkankowych [20]	15
2.2.	Organizacja sterowania aktywnością mięśni na poziomie rdzenia kręgowego [20]	17
2.3.	Przekrój rdzenia kręgowego z zaznaczonym położeniem motoneuronów alfa kontrolujących aktywność różnych grup funkcjonalnych mięśni [20]	17
2.4.	Powstanie potencjału czynnościowego w komórce mięśniowej [21]	18
2.5.	Zmiana długości sarkomeru podczas skurczu [23]	19
2.6.	Korelacja potencjału czynnościowego i skurczu we włóknie mięśniowym [23]	19
2.7.	Siła skurczu mięśnia w zależności od częstotliwości pobudzenia jednostek ruchowych [20]	20
2.8.	Umieszczenie ważniejszych ośrodków korowych biorących udział w kontroli ruchowej (powierzchnia boczna mózgu) [26]	21
2.9.	Rejestracja potencjałów czynnościowych mięśni przez elektrody dwubiegunowe [20]	23
2.10.	Widmo sygnału EMG rejestrowanego elektrodą powierzchniową [20]	23
2.11.	Zmiana częstotliwości medialnej widma sygnału EMG w wyniku zmęczenia mięśnia [20]	24
2.12.	Dziecko z czterookończynowym porażeniem spastycznym [30]	26
2.13.	Dziecko z atetotycznym porażeniem czterookończynowym [30]	26
2.14.	Różnice w budowie kości zdrowej i kruchej [36]	28
2.15.	Zdjęcia rentgenowskie osób dorosłych chorych na wybrane typy OI [37]	29
3.1.	Rozciąganie mięśni ramienia w siadzie [31]	32
3.2.	Rozciąganie mięśni łydki [31]	33
3.3.	Ćwiczenie bark-łokieć-dłoń wykonywane w wysokim podporze [31]	33
3.4.	Przejście z podłogi do siadu na ławce [31]	34
3.5.	Stanie trzymając się dwiema rękami [31]	34



3.6. Przykłady ćwiczeń kończyn dolnych z wykorzystaniem prostych akcesoriów: a) kopanie balonu jedną nogą; b) podnoszenie piłki; c) przekładanie stopy przez kółko; d) jazda na deskorolce [31]	34
3.7. Ćwiczenie równowagi w siadzie: a) zabawa z piłką; b) podrzucanie woreczkiem z fasolą [31]	35
3.8. Ćwiczenie koordynacji stojąc: a-b) gra w piłkę; c) stanie na gąbce; d) stanie na jednej nodze; e) gra woreczkiem z grochem jedną nogą [31]	35
3.9. Pionizatory: a) pionizator przedni [31]; b) stół pionizacyjny [45]	36
3.10. Sprzęt ułatwiający chodzenie: a) balkonik przedni; b) balkonik tylny; c) pionizator dynamiczny [31]	37
3.11. Wykorzystanie w rehabilitacji rowerów i zabawek dziecięcych [31]	37
3.12. Ortezy i inne aparaty stabilizujące kończyny: a) dwustronny stabilizator stawu skokowego; b) łuska na stopę; c) aparat stabilizujący z regulacją kąta w stawie łokciowym; d) łuska plastyczna na dłoń; e) zabezpieczenie palców stopy przed podwijaniem się w kierunku podeszwowym [45]	38
3.13. Pacjent w kostiumie TheraSuit	39
3.14. Lokomat [47]	40
3.15. Urządzenia wspomagające rehabilitację ruchową Biodex: a) system odciążenia dynamicznego NxStep; b) system asystujący podczas treningu chodu Gait Trainer 3 [50]	40
3.16. Egzoszkielety HAL: a) wspomaganie rehabilitacji kończyn dolnych; b) wsparcie ruchu w stawie łokciowym; c) wsparcie ruchu w stawie kolanowym [52]	41
3.17. System do neurorehabilitacji Luna EMG [55]	41
4.1. Zarys wykonanych faz badania	44
4.2. Schemat badań przeprowadzonych z udziałem wolontariuszy	45
4.3. Obciążniki treningowe stosowane podczas badań: a) obciążnik naręczny o masie 1 kg; b) obciążnik o masie 0,5 kg; c) obciążnik o masie 1 kg; d) obciążnik o masie 2 kg	45
4.4. Istota formowania próbek sygnału EMG w oknie czasowym	46
4.5. Schemat procesu przetwarzania danych pomiarowych (faza 1) oraz nauczania z nadzorem i testowania modelu uczenia maszynowego (fazy 2 i 3)	47
4.6. Schemat walidacji krzyżowej typu Leave-One-Out	48
4.7. Procedura oceny maszyny uczącej	49
4.8. Kamera Kinect wykorzystana do wykrywania pozycji ciała osób badanych	51
4.9. Informacje o pozycji ludzkiego ciała pobierane przez sensor Kinect: a) umiejscowienie „stawów” (czerwone kropki) i „kości” (zielone kreski); groty strzałek wskazują na „stawy” podrzędne w hierarchii; b) globalne układy współrzędnych sensora Kinect i podrzędnego mu układu środka bioder; c) składanie układu współrzędnych prawego nadgarstka do głównego układu środka bioder	52
4.10. Prawidłowo nałożony „szkielet” współrzędnych ciała	52



4.11. Interfejs programu komputerowego służącego do pobierania pozycji ciała z kamery Kinect i zapisywania ich do plików (obraz z kamery przedstawia odbicie lustrzane) . . .	53
4.12. Urządzenie wykorzystane do powierzchniowego pomiaru aktywności bioelektrycznej mięśni podczas badań: a) widok z podłączonymi czterema sondami pomiarowymi; b) wnętrze urządzenia	54
4.13. Elektroda bipolarna elektromiografu badawczego	54
4.14. Schemat obwodu jednego z kanałów pomiarowych elektromiografu	55
4.15. Odpowiedź częstotliwościowa środkowoprzepustowego filtra Butterwortha zastosowanego w filtracji sygnałów EMG. Przerzywane linie koloru czarnego wskazują na częstotliwości odcięcia	57
4.16. Odpowiedź częstotliwościowa dolnoprzepustowego filtra Butterwortha zastosowanego w filtracji parametrów rotacji „kości” uzyskanych z kamery Kinect. Przerzywana linia koloru czarnego wskazuje na częstotliwość graniczną	57
5.1. Położenie mięśni zbadanych podczas eksperymentu [93]	72
5.2. Porównanie naturalnego przebiegu EMG oraz przebiegu wstępnie przefiltrowanego: a) sygnał otrzymany z elektromiografu; b) widmo rzeczywistego sygnału; c) przebieg po filtracji; d) widmo przefiltrowanego sygnału	73
5.3. Porównanie szeregów czasowych współrzędnych kwaternionowych pozyskanych z kamery Kinect oraz efektu ich filtracji: a) oryginalny przebieg rotacji; b) widmo oryginalnego przebiegu; c) przebieg po filtracji; d) widmo przefiltrowanego przebiegu	74
5.4. Rozmieszczenie elektrod podczas badania ruchu kończyny górnej: a) badanie ruchu w stawie łokciowym; b) badanie ruchu w stawie ramiennym	75
5.5. „Szkielet” współrzędnych ciała nałożony podczas wykonywania przez pacjenta ruchów w stawie ramiennym: a) rozluźnienie; b) odwiedzenie; c) zgięcie do przodu	75
5.6. „Szkielet” współrzędnych ciała nałożony podczas wykonywania przez pacjenta zgięcia w stawie łokciowym	76
5.7. „Szkielet” współrzędnych ciała nałożony podczas wykonywania przez pacjenta rzutu przedmiotem	76
5.8. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę zdrową, odwodzenia i przywodzenia w stawie ramiennym (9-letnie dziecko płci żeńskiej)	77
5.9. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na OI, odwodzenia i przywodzenia w stawie ramiennym (10-letnie dziecko płci męskiej)	77
5.10. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na PCI, odwodzenia i przywodzenia w stawie ramiennym (17-letnie dziecko płci męskiej)	78

5.11. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę zdrową, zgięcia do przodu i wyprost do tyłu w stawie ramiennym (9-letnie dziecko płci żeńskiej)	78
5.12. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na OI, zgięcia do przodu i wyprost do tyłu w stawie ramiennym (10-letnie dziecko płci męskiej)	79
5.13. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja ramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na PCI, zgięcia do przodu i wyprost do tyłu w stawie ramiennym (17-letnie dziecko płci męskiej)	79
5.14. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja przedramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę zdrową, zginania i prostowania w stawie łokciowym (8-letnie dziecko płci żeńskiej)	80
5.15. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja przedramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na OI, zginania i prostowania w stawie łokciowym (10-letnie dziecko płci męskiej)	80
5.16. Aktywność bioelektryczna mięśni oraz korespondująca z nią rotacja przedramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na PCI, zginania i prostowania w stawie łokciowym (17-letnie dziecko płci męskiej)	81
5.17. Aktywność bioelektryczna mięśni oraz korespondujące z nią rotacje ramienia i przedramienia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem o masie 0,2 kg (17-letnie dziecko płci męskiej)	82
5.18. Badanie aktywności mięśni nóg podczas ćwiczeń na rotorze rehabilitacyjnym	83
5.19. Rozmieszczenie elektrod podczas badania ruchu kończyny dolnej	83
5.20. Aktywność bioelektryczna mięśni oraz korespondujące z nią rotacje uda i golenia (w przestrzeni \mathbb{H}) zmierzone podczas wykonywania, przez osobę chorą na OI, ćwiczenia na rotorze (10-letnie dziecko płci męskiej)	84
5.21. Badanie aktywności mięśni rąk z obciążnikami	84
5.22. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę zdrową, ruchów zginania i prostowania w stawie łokciowym z obciążnikami o masie 2 kg	85
5.23. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę zdrową, ruchów zginania i prostowania w stawie łokciowym: a) bez obciążenia; b) z obciążeniem o masie 2 kg	85
5.24. Analiza falkowa aktywności bioelektrycznej <i>m. biceps brachii</i> zmierzonej podczas wykonywania, przez osobę zdrową, ruchów zginania i prostowania w stawie łokciowym: a) bez obciążenia; b) z obciążeniem o masie 2 kg	85
5.25. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na OI, ruchów zginania i prostowania w stawie łokciowym z obciążnikami: a) obciążenie o masie 0,5 kg; b) obciążenie o masie 1 kg; c) obciążenie o masie 2 kg	86

- 5.26. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na OI, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 0,5 kg; **c)** z obciążeniem o masie 1 kg; **d)** z obciążeniem o masie 2 kg 87
- 5.27. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę chorą na OI, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 0,5 kg; **c)** z obciążeniem o masie 1 kg; **d)** z obciążeniem o masie 2 kg 88
- 5.28. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na PCI, ruchów zginania i prostowania w stawie łokciowym z obciążnikami o masie 1 kg 88
- 5.29. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na PCI, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 1 kg 89
- 5.30. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę chorą na PCI, ruchów zginania i prostowania w stawie łokciowym: **a)** bez obciążenia; **b)** z obciążeniem o masie 1 kg 89
- 5.31. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem o masie 2 kg 89
- 5.32. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem: **a)** przedmiot o masie 0,2 kg; **b)** przedmiot o masie 2 kg 90
- 5.33. Analiza falkowa aktywności bioelektrycznej *m. biceps brachii* zmierzonej podczas wykonywania, przez osobę chorą na PCI, rzutu przedmiotem: **a)** przedmiot o masie 0,2 kg; **b)** przedmiot o masie 2 kg 90
- 5.34. Aktywność bioelektryczna mięśni zmierzona podczas wykonywania, przez osobę chorą na OI, ćwiczenia na rotorze: **a)** lekki poziom obciążenia; **b)** średni poziom obciążenia; **c)** wysoki poziom obciążenia 91
- 5.35. Analiza widmowa aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania, przez osobę chorą na OI, ćwiczenia na rotorze: **a)** bez obciążenia; **b)** lekki poziom obciążenia; **c)** średni poziom obciążenia; **d)** wysoki poziom obciążenia 92
- 5.36. Analiza falkowa aktywności bioelektrycznej *m. semitendinosus* zmierzonej podczas wykonywania, przez osobę chorą na OI, ćwiczenia na rotorze: **a)** bez obciążenia; **b)** lekki poziom obciążenia; **c)** średni poziom obciążenia; **d)** wysoki poziom obciążenia 93
- 5.37. Sumy współczynników falkowych (CMOR) oszacowanych dla aktywności bioelektrycznej mięśni zmierzonej podczas wykonywania ruchów zginania i prostowania w stawie łokciowym: **a)** osoba zdrowa; **b)** osoba chora na PCI; **c)** osoba chora na OI 93
- 5.38. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji stanu zdrowia osoby ćwiczącej na podstawie ruchów zginania i prostowania w stawie łokciowym: **a)** FBSP *m. biceps brachii*; **b)** GAUS8 *m. biceps brachii*; **c)** MEXH *m. biceps brachii*; **d)** MEXH *m. extensor carpi radialis longus* 97

5.39. Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji stanu zdrowia osoby ćwiczącej na podstawie ruchów zginania i prostowania w stawie łokciowym	98
5.40. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji wagi zastosowanego obciążenia zewnętrznego na podstawie ruchów zginania i prostowania w stawie łokciowym: a) FBSP <i>m. biceps brachii</i> ; b) GAUS8 <i>m. biceps brachii</i> ; c) MEXH <i>m. biceps brachii</i> ; d) MEXH <i>m. extensor carpi radialis longus</i>	100
5.41. Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji masy zastosowanego obciążenia zewnętrznego na podstawie ruchów zginania i prostowania w stawie łokciowym	101
5.42. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji poziomu dopasowania stopnia trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzutu przedmiotem w bok: a) CGAU8 <i>m. biceps brachii</i> ; b) FBSP <i>m. biceps brachii</i> ; c) GAUS8 <i>m. biceps brachii</i> ; d) MEXH <i>m. biceps brachii</i>	101
5.43. Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzucania przedmiotem w bok	102
5.44. Rozkłady gęstości prawdopodobieństwa wybranych danych wejściowych klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze: a) MEXH <i>m. sartorius</i> ; b) FBSP <i>m. semitendinosus</i> ; c) GAUS8 <i>m. semitendinosus</i> ; d) MEXH <i>m. semitendinosus</i>	103
5.45. Rozkłady gęstości prawdopodobieństwa wyników najbardziej efektywnej klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze	104
5.46. Porównanie wycinków oryginalnych próbek danych rotacji z ich estymatami: a) zginanie i prostowanie w stawie łokciowym; b) odwodzenie i przywodzenie w stawie ramiennym; c) zgięcie do przodu i wyprost do tyłu w stawie ramiennym	107

Spis tablic

4.1. Charakterystyka grup zbadanych ochotników	50
5.1. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym przez osoby zdrowe	94
5.2. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym przez osoby chore na PCI	95
5.3. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym przez osoby chore na OI	96
5.4. Wyniki klasyfikacji stanu zdrowia osoby ćwiczącej na podstawie ruchów zginania i prostowania w stawie łokciowym	98
5.5. Wyniki klasyfikacji masy zastosowanego obciążenia zewnętrznego, umieszczonego na dłoni osoby ćwiczącej, na podstawie ruchów zginania i prostowania w stawie łokciowym	99
5.6. Wyniki klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny górnej podczas rzucania przedmiotem w bok	102
5.7. Wyniki klasyfikacji poziomu dopasowania trudności ćwiczenia na podstawie ruchów kończyny dolnej podczas ćwiczenia na rotorze	104
5.8. Wyniki estymacji ruchów zginania i prostowania w stawie łokciowym	105
5.9. Wyniki estymacji ruchów odwodzenia i przywodzenia w stawie ramiennym	106
5.10. Wyniki estymacji ruchów zgięcia do przodu i wyprost do tyłu w stawie ramiennym	106
A.1. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny górnej podczas rzucania lekkim przedmiotem w bok	125
A.2. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny górnej podczas rzucania w bok przedmiotem o wadze zbyt dużej dla ćwiczącego	126
A.3. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym bez zewnętrznego obciążenia	127



A.4. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym z obciążeniem zewnętrznym 0,5 kg	128
A.5. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym z obciążeniem zewnętrznym 1 kg	129
A.6. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym z obciążeniem zewnętrznym 2 kg	130
A.7. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny dolnej podczas wykonywania ćwiczenia na rotorze o niewielkim obciążeniu	131
A.8. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny dolnej podczas wykonywania ćwiczenia na rotorze o obciążeniu za dużym dla ćwiczącego	132

Dodatek A

Dane statystyczne wartości zmiennych wejściowych maszyn uczących

Tabela A.1. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny górnej podczas rzucania lekkim przedmiotem w bok

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. triceps brachii</i>
IEMG	0,847 ± 1,004	0,670 ± 0,742
MAV	0,034 ± 0,040	0,027 ± 0,030
MAV1	0,025 ± 0,030	0,020 ± 0,022
MAV2	0,016 ± 0,023	0,013 ± 0,017
SSI	0,151 ± 0,310	0,086 ± 0,173
VAR	0,006 ± 0,013	0,004 ± 0,007
WL	0,702 ± 0,898	0,571 ± 0,686
CGAU8	159,300 ± 191,760	125,380 ± 141,880
CMOR	138,110 ± 164,320	109,030 ± 121,610
FBSP	244,670 ± 291,420	193,100 ± 215,660
GAUS8	229,230 ± 275,300	180,510 ± 203,680
MEXH	269,010 ± 319,540	212,420 ± 236,420
MORL	195,810 ± 236,200	154,030 ± 174,770
SHAN	119,460 ± 145,220	93,830 ± 107,520

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.



Tabela A.2. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny górnej podczas rzucania w bok przedmiotem o wadze zbyt dużej dla ćwiczącego

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. triceps brachii</i>
IEMG	2,179 ± 2,170	1,643 ± 1,593
MAV	0,087 ± 0,087	0,066 ± 0,064
MAV1	0,064 ± 0,065	0,048 ± 0,048
MAV2	0,041 ± 0,051	0,031 ± 0,038
SSI	0,987 ± 2,183	0,536 ± 1,154
VAR	0,041 ± 0,091	0,022 ± 0,048
WL	1,874 ± 1,869	1,471 ± 1,427
CGAU8	412,090 ± 426,100	309,720 ± 312,260
CMOR	355,310 ± 358,680	267,640 ± 263,130
FBSP	629,450 ± 636,280	474,080 ± 466,710
GAUS8	592,260 ± 609,420	445,310 ± 446,660
MEXH	691,740 ± 694,830	521,220 ± 509,840
MORL	507,490 ± 527,340	381,240 ± 386,330
SHAN	311,440 ± 328,440	233,720 ± 240,530

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkki częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.

Tabela A.3. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym bez zewnętrznego obciążenia

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio- radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	5,879 ± 7,850	2,055 ± 3,575	0,943 ± 0,804	2,104 ± 2,203	1,513 ± 1,528	0,790 ± 0,972
MAV	0,098 ± 0,116	0,018 ± 0,015	0,015 ± 0,007	0,056 ± 0,089	0,022 ± 0,017	0,010 ± 0,008
MAV1	0,073 ± 0,087	0,013 ± 0,011	0,011 ± 0,005	0,041 ± 0,066	0,017 ± 0,013	0,008 ± 0,006
MAV2	0,048 ± 0,060	0,009 ± 0,009	0,007 ± 0,004	0,027 ± 0,045	0,011 ± 0,010	0,005 ± 0,005
SSI	1,429 ± 2,744	0,119 ± 0,313	0,019 ± 0,018	0,453 ± 0,987	0,063 ± 0,146	0,016 ± 0,032
VAR	0,039 ± 0,075	0,001 ± 0,002	0,001 ± 0,001	0,018 ± 0,041	0,001 ± 0,002	<0,001 ± 0,001
WL	2,422 ± 2,586	0,573 ± 0,725	0,362 ± 0,109	1,222 ± 1,846	0,534 ± 0,302	0,273 ± 0,232
CGAU8	1 009,740 ± 1 308,390	337,910 ± 556,430	156,050 ± 126,900	373,620 ± 402,410	275,180 ± 372,450	126,130 ± 131,070
CMOR	941,820 ± 1 284,500	322,280 ± 548,850	145,540 ± 119,120	337,410 ± 357,530	249,040 ± 311,690	120,970 ± 140,040
FBSP	1 614,190 ± 2 194,550	543,070 ± 914,430	246,980 ± 195,600	585,800 ± 629,320	428,430 ± 553,360	203,780 ± 228,280
GAUS8	1 490,720 ± 2 007,860	500,650 ± 833,360	227,300 ± 187,580	544,250 ± 585,550	404,750 ± 567,080	185,350 ± 198,760
MEXH	2 858,880 ± 4 774,180	1 098,510 ± 2 061,160	443,920 ± 485,800	864,600 ± 861,820	775,270 ± 1 153,840	387,390 ± 554,800
MORL	1 236,500 ± 1 571,340	414,970 ± 682,320	192,900 ± 157,730	459,060 ± 492,370	339,570 ± 457,410	155,100 ± 158,950
SHAN	761,530 ± 944,260	259,480 ± 429,870	121,790 ± 103,140	282,690 ± 297,660	213,000 ± 281,170	97,110 ± 99,300

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.

Tabela A.4. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym z obciążeniem zewnętrznym 0,5 kg

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio-radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	14,175 ± 16,110	9,387 ± 8,862	2,140 ± 1,611	4,839 ± 5,556	7,565 ± 4,920	2,066 ± 1,540
MAV	0,060 ± 0,062	0,041 ± 0,032	0,013 ± 0,005	0,023 ± 0,020	0,030 ± 0,020	0,011 ± 0,004
MAV1	0,045 ± 0,047	0,031 ± 0,025	0,010 ± 0,004	0,017 ± 0,015	0,023 ± 0,015	0,008 ± 0,003
MAV2	0,030 ± 0,035	0,020 ± 0,018	0,007 ± 0,003	0,011 ± 0,012	0,015 ± 0,012	0,005 ± 0,002
SSI	3,107 ± 5,481	1,073 ± 1,389	0,051 ± 0,067	0,391 ± 0,749	0,578 ± 0,747	0,042 ± 0,042
VAR	0,013 ± 0,022	0,004 ± 0,006	<0,001 ± <0,001	0,002 ± 0,003	0,002 ± 0,003	<0,001 ± <0,001
WL	3,110 ± 3,639	2,063 ± 1,918	0,467 ± 0,232	1,017 ± 1,169	1,438 ± 1,006	0,466 ± 0,312
CGAU8	2 465,660 ± 2 860,880	1 515,920 ± 1 446,740	354,610 ± 286,460	907,280 ± 1 108,320	1 432,180 ± 980,080	312,780 ± 236,500
CMOR	2 308,370 ± 2 626,100	1 461,590 ± 1 364,010	335,970 ± 262,760	812,590 ± 959,540	1 266,670 ± 852,670	311,290 ± 230,540
FBSP	3 925,770 ± 4 492,610	2 457,480 ± 2 292,060	566,010 ± 448,340	1 386,680 ± 1 653,740	2 160,930 ± 1 475,400	516,980 ± 382,210
GAUS8	3 691,860 ± 4 297,890	2 246,300 ± 2 146,760	525,160 ± 437,130	1 339,780 ± 1 648,780	2 103,080 ± 1 458,510	463,810 ± 356,350
MEXH	8 268,980 ± 9 562,500	5 313,550 ± 5 056,180	1 179,160 ± 994,850	2 835,380 ± 3 373,970	4 487,120 ± 3 078,040	1 125,040 ± 875,460
MORL	3 014,540 ± 3 502,160	1 866,930 ± 1 783,170	436,800 ± 347,170	1 123,000 ± 1 368,190	1 781,900 ± 1 214,420	384,420 ± 287,980
SHAN	1 850,500 ± 2 167,190	1 178,750 ± 1 125,170	276,560 ± 216,300	708,500 ± 860,770	1 129,910 ± 769,960	243,970 ± 183,140

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* **IEMG** – całka sygnału EMG, **MAV** – średnia wartości bezwzględnych amplitudy sygnału, **MAV1** – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, **MAV2** – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, **SSI** – prosta całka kwadratowa sygnału, **VAR** – wariancja sygnału EMG, **WL** – długość przebiegu, **CGAU8** – falka pochodna gaussowska zespolona 8, **CMOR** – falka Morleta zespolona, **FBSP** – falka sklejkowej częstotliwości, **GAUS8** – falka pochodna gaussowska 8, **MEXH** – falka Rickera, **MORL** – falka Morleta, **SHAN** – falka Shannona.

Tabela A.5. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym z obciążeniem zewnętrznym 1 kg

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio- radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	13,640 ± 20,333	4,926 ± 9,251	2,648 ± 3,986	5,747 ± 8,297	4,244 ± 6,106	1,401 ± 2,186
MAV	0,180 ± 0,132	0,035 ± 0,032	0,031 ± 0,015	0,099 ± 0,111	0,038 ± 0,026	0,014 ± 0,006
MAV1	0,134 ± 0,098	0,026 ± 0,024	0,023 ± 0,012	0,074 ± 0,084	0,028 ± 0,020	0,010 ± 0,005
MAV2	0,087 ± 0,069	0,017 ± 0,017	0,015 ± 0,009	0,047 ± 0,061	0,019 ± 0,015	0,007 ± 0,004
SSI	5,669 ± 12,803	0,715 ± 2,124	0,196 ± 0,543	1,538 ± 2,971	0,423 ± 0,867	0,047 ± 0,104
VAR	0,086 ± 0,103	0,004 ± 0,008	0,002 ± 0,003	0,042 ± 0,102	0,004 ± 0,005	<0,001 ± <0,001
WL	5,199 ± 4,515	1,286 ± 1,940	0,893 ± 0,793	2,590 ± 2,711	1,102 ± 1,029	0,423 ± 0,420
CGAU8	2 423,160 ± 4 163,350	777,930 ± 1 426,550	462,880 ± 752,690	1 013,730 ± 1 416,720	724,590 ± 1 058,790	221,200 ± 339,900
CMOR	2 225,810 ± 3 673,150	757,060 ± 1 389,460	419,870 ± 658,870	926,950 ± 1 333,300	678,840 ± 987,900	214,930 ± 330,650
FBSP	3 805,730 ± 6 348,980	1 269,150 ± 2 315,770	716,340 ± 1 132,170	1 593,930 ± 2 260,860	1 157,830 ± 1 689,480	361,370 ± 550,400
GAUS8	3 569,540 ± 6 302,500	1 159,000 ± 2 150,290	679,900 ± 1 129,080	1 492,300 ± 2 147,690	1 079,310 ± 1 605,900	328,680 ± 512,390
MEXH	6 953,310 ± 12 599,910	2 683,680 ± 5 271,660	1 356,670 ± 2 429,060	2 773,890 ± 4 854,910	2 330,790 ± 3 762,650	730,370 ± 1 268,310
MORL	2 969,170 ± 5 026,500	954,150 ± 1 739,370	572,070 ± 929,530	1 242,120 ± 1 706,570	890,490 ± 1 294,390	270,500 ± 414,020
SHAN	1 795,260 ± 2 900,220	601,760 ± 1 092,960	362,730 ± 606,910	756,680 ± 1 003,150	565,800 ± 832,700	166,920 ± 254,120

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.

Tabela A.6. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni podczas wykonywania ruchów zginania i prostowania w stawie łokciowym z obciążeniem zewnętrznym 2 kg

Cechy sygnału*	<i>m. biceps brachii</i>	<i>m. brachialis</i>	<i>m. brachio- radialis</i>	<i>m. extensor carpi radialis longus</i>	<i>m. pronator teres</i>	<i>m. triceps brachii</i>
IEMG	27,376 ± 33,622	12,297 ± 12,395	5,865 ± 7,369	12,193 ± 15,248	10,827 ± 9,801	3,110 ± 2,808
MAV	0,162 ± 0,117	0,062 ± 0,039	0,040 ± 0,023	0,079 ± 0,061	0,082 ± 0,047	0,022 ± 0,011
MAV1	0,121 ± 0,089	0,047 ± 0,030	0,030 ± 0,018	0,059 ± 0,047	0,061 ± 0,036	0,016 ± 0,009
MAV2	0,080 ± 0,066	0,031 ± 0,022	0,019 ± 0,015	0,038 ± 0,034	0,040 ± 0,027	0,011 ± 0,007
SSI	12,471 ± 22,963	1,868 ± 2,254	0,713 ± 1,647	2,693 ± 5,348	1,605 ± 1,730	0,117 ± 0,120
VAR	0,066 ± 0,092	0,008 ± 0,009	0,004 ± 0,006	0,017 ± 0,028	0,015 ± 0,016	0,001 ± 0,001
WL	6,946 ± 7,473	2,802 ± 2,514	1,520 ± 1,568	3,047 ± 3,137	2,473 ± 1,375	0,780 ± 0,483
CGAU8	4 445,800 ± 5 490,800	1 769,270 ± 1 769,040	1 101,290 ± 1 473,280	2 084,470 ± 2 522,610	1 796,730 ± 1 653,870	462,440 ± 410,550
CMOR	4 201,510 ± 5 163,630	1 819,800 ± 1 806,730	1 018,000 ± 1 375,250	1 945,350 ± 2 391,670	1 711,860 ± 1 561,640	457,760 ± 403,600
FBSP	7 041,850 ± 8 637,410	3 010,880 ± 2 978,180	1 753,720 ± 2 399,880	3 298,630 ± 4 022,560	2 897,030 ± 2 645,050	758,570 ± 660,510
GAUS8	6 585,850 ± 8 191,780	2 641,990 ± 2 661,530	1 658,810 ± 2 275,510	3 096,180 ± 3 752,080	2 663,340 ± 2 482,300	683,310 ± 613,890
MEXH	14 958,980 ± 19 332,760	6 656,380 ± 6 887,560	3 490,970 ± 5 017,790	6 781,460 ± 8 862,890	5 945,100 ± 6 029,060	1 618,450 ± 1 560,350
MORL	5 463,260 ± 6 740,940	2 161,340 ± 2 157,950	1 340,750 ± 1 768,300	2 559,900 ± 3 105,600	2 210,460 ± 2 036,040	567,160 ± 502,000
SHAN	3 403,720 ± 4 269,560	1 356,530 ± 1 376,790	815,800 ± 1 043,170	1 604,010 ± 1 952,680	1 398,900 ± 1 340,590	353,830 ± 320,440

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* **IEMG** – całka sygnału EMG, **MAV** – średnia wartości bezwzględnych amplitudy sygnału, **MAV1** – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, **MAV2** – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, **SSI** – prosta całka kwadratowa sygnału, **VAR** – wariancja sygnału EMG, **WL** – długość przebiegu, **CGAU8** – falka pochodna gaussowska zespolona 8, **CMOR** – falka Morleta zespolona, **FBSP** – falka sklejkowej częstotliwości, **GAUS8** – falka pochodna gaussowska 8, **MEXH** – falka Rickera, **MORL** – falka Morleta, **SHAN** – falka Shannona.

Tabela A.7. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny dolnej podczas wykonywania ćwiczenia na rotorze o niewielkim obciążeniu

Cechy sygnału*	<i>m. biceps femoris</i>	<i>m. gracilis</i>	<i>m. rectus femoris</i>	<i>m. sartorius</i>	<i>m. semiten- dinosus</i>	<i>m. tensor fasciae latae</i>
IEMG	2,070 ± 1,118	2,432 ± 0,978	2,828 ± 2,258	2,179 ± 1,942	4,023 ± 2,803	2,692 ± 1,166
MAV	0,008 ± 0,005	0,010 ± 0,004	0,011 ± 0,009	0,009 ± 0,008	0,016 ± 0,011	0,011 ± 0,005
MAV1	0,006 ± 0,003	0,007 ± 0,003	0,009 ± 0,007	0,007 ± 0,006	0,012 ± 0,009	0,008 ± 0,004
MAV2	0,004 ± 0,003	0,005 ± 0,002	0,006 ± 0,005	0,004 ± 0,005	0,008 ± 0,006	0,005 ± 0,003
SSI	0,036 ± 0,037	0,044 ± 0,036	0,092 ± 0,171	0,061 ± 0,143	0,158 ± 0,205	0,055 ± 0,054
VAR	<0,001 ± <0,001	<0,001 ± <0,001	<0,001 ± 0,001	<0,001 ± 0,001	0,001 ± 0,001	<0,001 ± <0,001
WL	0,406 ± 0,238	0,438 ± 0,206	0,558 ± 0,480	0,409 ± 0,418	0,801 ± 0,594	0,543 ± 0,274
CGAU8	344,000 ± 199,360	388,300 ± 167,890	492,350 ± 426,170	373,190 ± 336,150	672,190 ± 481,650	421,730 ± 197,990
CMOR	323,090 ± 177,250	371,970 ± 150,120	456,260 ± 381,850	348,150 ± 318,360	635,320 ± 441,180	407,070 ± 185,340
FBSP	541,450 ± 300,370	618,970 ± 254,120	771,210 ± 660,140	588,790 ± 547,330	1 069,440 ± 745,560	675,520 ± 316,200
GAUS8	504,800 ± 293,400	570,690 ± 252,620	727,960 ± 644,220	552,940 ± 510,620	994,960 ± 722,220	621,420 ± 304,760
MEXH	1 170,340 ± 646,570	1 351,000 ± 565,410	1 647,380 ± 1 409,660	1 273,820 ± 1 228,370	2 310,310 ± 1 614,490	1 487,050 ± 695,680
MORL	427,590 ± 247,690	481,800 ± 206,070	609,340 ± 520,220	462,220 ± 411,740	829,950 ± 586,190	520,790 ± 237,330
SHAN	275,330 ± 160,080	312,780 ± 133,590	384,260 ± 312,320	295,390 ± 259,220	520,890 ± 351,800	331,260 ± 144,370

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.

Tabela A.8. Zestawienie wartości zmiennych wejściowych maszyn uczących opisujących aktywność bioelektryczną mięśni kończyny dolnej podczas wykonywania ćwiczenia na rotorze o obciążeniu za dużym dla ćwiczącego

Cechy sygnału*	<i>m. biceps femoris</i>	<i>m. gracilis</i>	<i>m. rectus femoris</i>	<i>m. sartorius</i>	<i>m. semiten- dinosus</i>	<i>m. tensor fasciae latae</i>
IEMG	1,112 ± 0,800	1,637 ± 1,089	1,813 ± 0,955	0,906 ± 0,405	1,602 ± 1,688	2,958 ± 1,789
MAV	0,004 ± 0,003	0,007 ± 0,004	0,007 ± 0,004	0,004 ± 0,002	0,006 ± 0,007	0,012 ± 0,007
MAV1	0,003 ± 0,003	0,005 ± 0,003	0,005 ± 0,003	0,003 ± 0,001	0,005 ± 0,005	0,009 ± 0,006
MAV2	0,002 ± 0,002	0,003 ± 0,002	0,004 ± 0,002	0,002 ± 0,001	0,003 ± 0,004	0,006 ± 0,004
SSI	0,012 ± 0,022	0,024 ± 0,031	0,025 ± 0,032	0,006 ± 0,007	0,036 ± 0,081	0,077 ± 0,093
VAR	0,000 ± <0,001	<0,001 ± <0,001	<0,001 ± <0,001	0,000 ± 0,000	<0,001 ± <0,001	<0,001 ± <0,001
WL	0,218 ± 0,185	0,337 ± 0,248	0,338 ± 0,180	0,179 ± 0,087	0,321 ± 0,370	0,628 ± 0,436
CGAU8	172,810 ± 139,960	252,400 ± 179,420	273,910 ± 161,540	144,290 ± 71,630	260,500 ± 260,120	493,630 ± 313,870
CMOR	167,950 ± 128,730	245,230 ± 166,970	267,160 ± 141,590	136,090 ± 62,900	254,330 ± 270,840	458,810 ± 278,940
FBSP	280,650 ± 223,280	406,400 ± 280,090	438,140 ± 234,020	226,160 ± 107,030	427,750 ± 458,130	771,350 ± 473,540
GAUS8	256,270 ± 212,710	370,110 ± 265,310	397,210 ± 229,920	211,310 ± 108,780	385,090 ± 398,590	728,450 ± 468,400
MEXH	623,590 ± 493,830	900,840 ± 607,770	975,310 ± 518,710	493,600 ± 220,820	930,320 ± 1 022,730	1 658,360 ± 1 030,980
MORL	213,020 ± 170,540	313,360 ± 221,690	341,900 ± 206,080	178,910 ± 87,520	322,000 ± 311,210	608,620 ± 385,860
SHAN	134,060 ± 105,510	202,520 ± 144,550	221,470 ± 137,670	114,350 ± 59,130	205,280 ± 181,890	378,320 ± 239,940

Uwaga: Podane wartości stanowią średnie ± odchylenia standardowe.

* IEMG – całka sygnału EMG, MAV – średnia wartości bezwzględnych amplitudy sygnału, MAV1 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 1, MAV2 – zmodyfikowana średnia wartości bezwzględnych amplitudy sygnału typ 2, SSI – prosta całka kwadratowa sygnału, VAR – wariancja sygnału EMG, WL – długość przebiegu, CGAU8 – falka pochodna gaussowska zespolona 8, CMOR – falka Morleta zespolona, FBSP – falka sklejkowej częstotliwości, GAUS8 – falka pochodna gaussowska 8, MEXH – falka Rickera, MORL – falka Morleta, SHAN – falka Shannona.