Pomiary i przetwarzanie sygnałów medycznych

Piotr Augustyniak, Anna Broniec, Marek Iwaniec, Andrzej Izworski, Eliasz Kańtoch, Tomasz Nabagło, Magdalena Smoleń, Magdalena Szymczyk, Piotr Szymczyk

AGH Akademia Górniczo-Hutnicza, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej, Kraków

Streszczenie: Diagnostyka medyczna oparta na pozyskiwaniu i przetwarzaniu sygnałów jest przedmiotem zainteresowań badawczych i projektów wdrożeniowych prowadzonych w Katedrze Biocybernetyki i Inżynierii Biomedycznej. Została ona utworzona w 2018 roku i kontynuuje tradycje Międzywydziałowej Szkoły Inżynierii Biomedycznej (MSIB), która powstała w 2005 roku. Katedra prowadzi interdyscyplinarne badania naukowe we współpracy z otoczeniem medycznym i przemysłowym. Niniejszy artykuł opisuje dziewięć tematów badawczych wybranych spośród prowadzonych prac jako najbardziej istotne przykłady technicznego wsparcia medycyny przyszłości. Czytelnik znajdzie tu propozycje arbitralnego próbkowania elektrokardiogramu, zastosowania metody *flicker noise spectroscopy* (FNS) do analizy sygnału elektroencefalograficznego, opracowanie stanowiska treningowo-rehabilitacyjnego wykorzystującego efekt Magnusa, metody interpretacji słuchowych potencjałów wywołanych, propozycje pomiarów i przetwarzania sygnałów pochodzących z profilaktycznych i telemedycznych urządzeń ubieralnych, projekt systemów pomiarowych do zastosowania w nawigacji zespołu kaniula–prowadnica, pomiary i analizę sygnałów w różnych stanach aktywności fizycznej i psychicznej człowieka, metody przetwarzania sygnałów na potrzeby równoległych i rozproszonych systemów wbudowanych oraz omówienie prac nad nowymi rodzajami sieci neuronowych.

Słowa kluczowe: sygnały elektrofizjologiczne, przetwarzanie sygnałów, inżynieria biomedyczna

MEDICAL SIGNALS ACQUISITION AND PROCESSING

Abstract: Medical diagnostics based on the acquisition and processing of signals is the subject of research interests and implementation projects carried out at the Department of Biocybernetics and Biomedical Engineering. The Department was founded in year 2018 and originates from the Multidisciplinary School of Engineering in Biomedicine (MSIB – Międzywydziałowej Szkoły Inżynierii Biomedycznej), founded in 2005. The Department of Biocybernetics and Biomedical Engineering hosts interdisciplinary scientific research and closely cooperates with the medical and industrial environment. This article describes nine research topics selected from the portfolio of work as the most important examples of technical support for the medicine of the future. The reader will find here proposals for arbitrary sampling of the electrocardiogram, application of the flicker noise spectroscopy to the analysis of electro-encephalographic signal, development of a rehabilitation and training station using the Magnus effect, interpretation methods for auditory evoked potentials, proposals for measurements and processing of signals from preventive and telemedical wearable devices, design of measurement systems for use in the navigation of the cannula-guide assembly, measurement and analysis of signals in various states of human physical and mental activity, methods of signal processing oriented to parallel and distributed systems and investigations on new types of neural networks.

Keywords: electrophysiological signals, signal processing, biomedical engineering

https://doi.org/10.7494/978-83-66727-89-2_6

1. Wstęp

Artykuł ten przedstawia najważniejsze zainteresowania naukowe pracowników Katedry Biocybernetyki i Inżynierii Biomedycznej w zakresie pomiarów i przetwarzania sygnałów generowanych przez funkcje życiowe i aktywność człowieka. Warto zwrócić uwagę na dwa specyficzne rodzaje tych sygnałów: sygnały elektrofizjologiczne, reprezentujące pracę organów człowieka i będące podstawą ich diagnozowania, oraz sygnały wynikające z ciągłego pomiaru aktywności człowieka w jego naturalnym środowisku. Ponieważ pomiary te wymagają wykorzystania rozmaitych zasad fizycznych, niemal regułą jest przetwarzanie sygnału multimodalnego, czyli takiego, którego składniki opisują fizyczną rzeczywistość w różny sposób i wymagają jednoczesnego użycia kilku metod przetwarzania. Innym kryterium podziału jest umiejscowienie sensora: albo na ciele osoby diagnozowanej, albo jako elementu infrastruktury związanej np. z pomieszczeniem. Sensory te są komplementarne i dopiero fuzja informacji daje pełny obraz aktywności nadzorowanej osoby.

2. Elektrokardiografia z użyciem niejednorodnej reprezentacji sygnału

2.1. Arbitralne próbkowanie elektrokardiogramu

Wiedza o tym, że rozkład informacji diagnostycznych w elektrokardiogramie (EKG) jest niejednorodny, jest powszechna i akceptowana oraz stanowi podstawę kilku metod kompresji i redukcji szumu, jednak przewidywanie tych niejednorodności wciąż pozostaje wyzwaniem naukowym. Śledzenie ruchu oka jest uznaną metodą identyfikacji preferencji obserwatora wynikających z jego wiedzy i doświadczenia, zatem parametry okoruchowe eksperta wykonującego zadanie interpretacji elektrokardiogramu mogą być źródłem wiedzy o istotności poszczególnych fragmentów zapisu. Stwierdzono, że statystyki ścieżek wzrokowych ekspertów są wygodną ilościową miarą gęstości informacji medycznej dla każdego konkretnego składnika (tj. fali) zapisu EKG (Augustyniak i Tadeusiewicz 2006).

Zbudowanie ogólnego modelu perceptualistycznego zapisu EKG umożliwia wykorzystanie wiedzy z poprzednich eksperymentów okoruchowych do sterowania interwałem arbitralnego (tj. niejednorodnego) próbkowania sygnału EKG (Augustyniak 2020). Zaproponowana metoda składa się z trzech kroków:

1. Na podstawie modelu czasowego rozkładu gęstości informacji wyznaczana jest lokalna szerokość pasma EKG i rzutowana na rzeczywisty sygnał z uwzględnieniem aktualnych pozycji załamków.
2. Wartość interwału próbkowania jest zmienna i wyznaczana lokalnie dla kolejnych próbek. Równocześnie sygnał EKG jest adaptacyjnie filtrowany dolnoprzepustowo.

3. Wartości próbek zapisu EKG są interpolowane w nowych pozycjach czasowych, tworząc niejednorodne szeregi czasowe. W większości przypadków liczba próbek jest znacznie zredukowana.

Do oceny próbkowania percepcyjnego użyto transformacji odwrotnej, w której docelowy interwał próbkowania był jednorodny. Zastosowana miara procentowej różnicy średniokwadratowej (PRD) sygnału oryginalnego i zrekonstruowanego wskazywała 3–5% (odpowiednio dla współczynników kompresji 3,0–4,7). Dodatkowo wykonano testy zalecane przez normę BS EN 60601-2-25:2015 używaną do oceny medycznej przydatności interpretacji wykonywanej automatycznie. Testy te, na podstawie zapisów z bazy danych CSE (Willems i in. 1987), wykazały powtarzalność parametrów diagnostycznych (tj. długości załamków EKG) w zakresie tolerancji wymaganej dla wyrobu medycznego. Stało się tak dzięki skupieniu zniekształceń w mniej istotnych częściach cyklu serca, gdzie interwał próbkowania sygnału jest dłuższy.

2.2. Interpretacja elektrokardiogramu próbkowanego arbitralnie

Zapis EKG próbkowany arbitralnie charakteryzuje się podobną efektywnością przechowywania jak zapis poddany kompresji. Rosnąca liczba zapisów EKG rejestrowanych codziennie na całym świecie (szacunkowo jest to 600 TB danych) i regulacje wymuszające długie ich archiwizowanie (rzędu 40 lat) stanowiły motywację do podjęcia badań nad możliwością przeprowadzania podstawowych procedur diagnostycznych EKG o jakości akceptowalnej w medycynie bezpośrednio opartych na arbitralnej, niejednorodnej (tj. oszczędnej) reprezentacji EKG. W pracy Augustyniaka (2021) zaproponowano i przedstawiono zestaw trzech metod stanowiących podstawę interpretacji diagnostycznej elektrokardiogramu (EKG) dostosowanych do przetwarzania sygnału próbkowanego niejednorodnie:

1. Metodę wykrywania uderzeń serca opartą na technice dopasowania ruchomych wzorców. Wykorzystano wielomianowy estymator nieparametryczny opracowany przez Nadarayę (1964) i Watsona (1964), który umożliwiał przybliżenie kształtu zespołu QRS pękiem półprostych w dowolnych chwilach niezależnie od czasowej pozycji próbek.
2. Opartą na grafach reprezentację fragmentów sygnału arbitralnego do określenia miary podobieństwa, a w konsekwencji – klasyfikacji uderzeń serca.
3. Opartą na korelacji bezpośrednią transformację sygnału próbkowanego arbitralnie do dziedziny czasowo-skalowej. Pozwoliło to uzyskać wielorozdzielczą regularną reprezentację EKG i zastosować algorytm Martineza (Martinez i in. 2004) do dokładnego wyznaczenia załamków P, QRS i T.

Zaproponowana sekwencja procedur interpretacji EKG została zaimplementowana i przetestowana przy użyciu plików referencyjnych z baz danych MIT-BIH (Moody i Mark 1990)

oraz z CSE Multilead Database (Willems i in. 1987). Sygnały z baz były próbkowane arbitralnie zgodnie z modelem perceptualistycznym z ustawioną zmienną częstotliwością próbkowania w zakresie 100–500 Hz, co odpowiadało stopniowi kompresji 3,1. Wykrywanie zespołu QRS wykazało dokładność 99,93% przy odsetku fałszywych detekcji wynoszącym zaledwie 0,18%. Dokładność klasyfikacji uderzeń serca wyniosła 99,27% dla 14 najczęstszych typów rytmu wg etykiet MIT-BIH (99,37% wg etykiet AAMI). Dokładność wyznaczonego czasu trwania odcinków EKG, skumulowana dla perceptualistycznego modelu próbkowania i interpretacji sygnału niejednorodnego, wyniosła średnio 9,7 ms dla czasu trwania załamka P, 3,4 ms dla QRS, 6,7 ms dla odcinka P-Q i 17,7 ms dla odcinka Q-T. Zgodnie z normą IEC 60601-2-25:2015 wszystkie otrzymane wartości są akceptowalne dla oprogramowania interpretacyjnego wykorzystywanego w wyrobach medycznych.

2.3. Steganografia w strukturze cyfrowego elektrokardiogramu

Metoda cyfrowego znaku wodnego jest obecnie badana jako wydajny i bezpieczny sposób osadzania dodatkowych danych dotyczących pacjenta lub otaczającego go środowiska w strukturze cyfrowego elektrokardiogramu. W artykule Świerkosz i Augustyniaka (2018) przedstawiono koncepcję metody oraz prace eksperymentalne dotyczące oceny utraty jakości diagnostycznej sygnału elektrokardiogramu w świetle wymagań normy przemysłowej BS EN 60601-2-25:2015. Zaproponowano i wdrożono oryginalną technikę osadzania znaku wodnego w dziedzinie transformaty czasowo-skalowej oraz adaptacyjnego projektowania kontenera znaku wodnego indywidualnie dla każdego odprowadzenia EKG i każdej ewolucji serca. W części eksperymentalnej przetestowano sześć różnych falek, sześć wartości głębi bitowej kodowania (w tym dobór automatyczny zależny od szumu) i dwa rodzaje treści znaku wodnego (tekstową i numeryczną) w poszukiwaniu warunków, jakie musi spełniać elektrokardiogram jako nośnik znaku wodnego zachowujący informację diagnostyczną z dokładnością wymaganą przez normę IEC. W przeciwieństwie do prac innych autorów miarą zgodności nie była różnica wartości sygnału, ale odchyłki w wynikach wyznaczania granic załamków EKG. Wyniki porównań rezultatów diagnostycznych wyznaczonych na podstawie 7300 oryginalnych 10-sekundowych zapisów EKG i rezultatów diagnostycznych z odpowiadających im zapisów ze znakiem wodnym zostały przetworzone statystycznie w celu ujawnienia możliwego pogorszenia jakości (wiarygodności) interpretacji z powodu osadzenia znaku wodnego. W rezultacie eksperymentu: wskazano falkę Symlet 11. rzędu jako najlepszą z testowanych falek, wykazano ważną rolę procedur wyznaczania granic załamków EKG i procedury śledzenia szumu, udowodniono duży wpływ podobieństwa amplitudy i rozkładu wartości znaku wodnego do analogicznych parametrów szumu oraz zbadano stabilność procedury osadzania cyfrowego znaku wodnego dla różnych częstości akcji serca w rytmach pochodzenia przedsionkowego.

3. Analiza sygnału elektroencefalograficznego (EEG) metodą *flicker noise spectroscopy* (FNS)

3.1. Metoda FNS

Podstawową ideą spektroskopii szumu migotania (FNS – *flicker noise spectroscopy*) jest założenie, że cała informacja o badanym układzie zawarta jest w korelacjach występujących w sekwencjach nieregularności sygnału, takich jak piki, skoki czy nieciągłości pochodnych różnego stopnia. Narzędziami służącymi do ekstrakcji oraz analizy informacji zawartej w sygnale są widmo mocy sygnału oraz momenty różnicowe pierwszego i kolejnych rzędów (Timashev 2001, Timashev i Polyakov 2007). W metodzie FNS separuje się analizowany sygnał na składową niskoczęstotliwościową odpowiadającą swoistym dla układu „rezonansom" oraz dwie składowe „chaotyczne", których źródłem są nieregularności (odpowiednio piki oraz skoki).

3.2. Elektroencefalografia

Elektroencefalografia (EEG) jest metodą służącą do badania elektrycznej aktywności synchronicznie pracujących neuronów kory mózgowej. Najbardziej charakterystyczną cechą sygnału elektroencefalograficznego jest występowanie w nim rytmów (fal), czyli możliwych do zaobserwowania struktur o charakterystycznym zakresie częstotliwości i powtarzalnym kształcie. Należy podkreślić, że widmo sygnału EEG jest funkcją malejącą w sposób odwrotnie proporcjonalny do częstotliwości, co tłumaczy się działaniem czaszki jako filtru dolnoprzepustowego oraz tym, że częstotliwość generowanych rytmów jest odwrotnie proporcjonalna do liczby neuronów, które są odpowiedzialne za powstanie danego rytmu (Buzsáki i Draguhn 2004).

3.3. Analiza sygnału związanego z wyobrażeniem ruchu

W reakcji na zewnętrzny lub wewnętrzny bodziec w elektroencefalogramie zachodzą między innymi zmiany aktywności populacji neuronów, są one charakteryzowane przez krótkotrwałą zmianę mocy w określonych pasmach częstotliwości. Bodźcem wywołującym takie zmiany może być wyobrażenie ruchu ręką, które generuje zmiany w obrębie obszarów kory motorycznej, odpowiedzialnej za ruchy mięśni dłoni (leżą one w obszarach badanych przez elektrody C3 i C4). Nasze badania (Broniec 2016, 2021) pokazały, że metoda FNS może być alternatywnym sposobem analizy danych związanych z wyobrażeniem ruchu i daje możliwość znalezienia cech rozróżniających wyobrażenie ruchu lewą i prawą ręką. Zarówno parametryzacja sygnału metodą FNS, jak i funkcja prekursora nagłych zmian w sygnale bezbłędnie wskazują moment i półkulę, która była aktywna podczas wyobrażenia ruchu. Dla przykładu na rysunku 1 pokazano przebieg funkcji prekursora C dla elektrod C3 (a) oraz C4 (b) podczas wyobrażenia ruchu prawej ręki.

Analiza porównawcza funkcji prekursora dla elektrody C3 i C4 pokazuje, że potrafi on bezbłędnie wskazać zmianę stanu mózgu oraz półkulę, która została aktywowana podczas zadania. W przypadku większości badanych zmiany funkcji prekursora następują z większą amplitudą na elektrodzie C3 (leżącej na lewej półkuli mózgowej) podczas wyobrażenia ruchu prawą ręką, natomiast dla ruchu lewej ręki na elektrodzie C4 (leżącej na półkuli prawej), co jest zgodne z kontralateralnym sterowaniem mięśniami ciała. Pik w prekursorze pojawia się w postaci struktury „pik-dip", z czego maksimum występuje przed badanym zjawiskiem, stąd jego nazwa – prekursor.

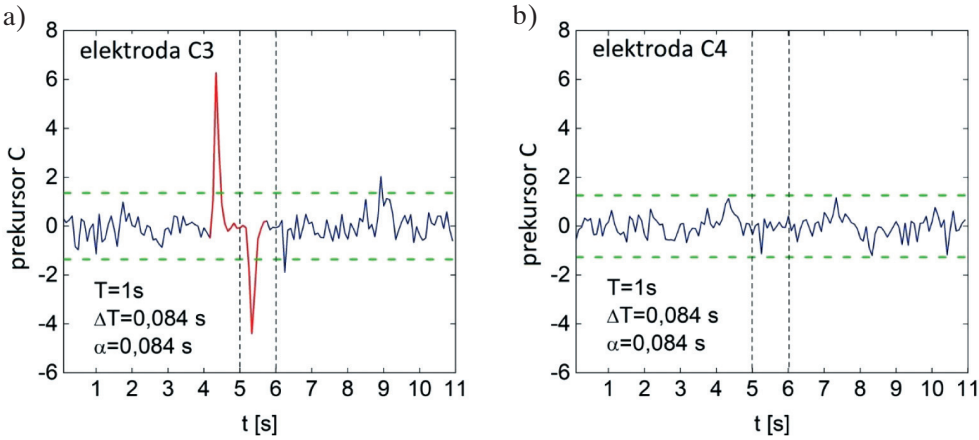

Rys. 1. Prekursor C w funkcji czasu dla elektrod C3 (a) oraz C4 (b) podczas wyobrażenia ruchu prawej ręki. Pionowe kropkowane linie oznaczają bodziec dźwiękowy, po którym następuje zadanie ruchowe. Poziome zielone linie oznaczają granicę 3σ, powyżej której piki są statystycznie istotne

Pochodzenie szumu migotania 1/f w mózgu wzbudza zainteresowanie od lat, ponieważ nie jest do końca wyjaśnione. Przypuszcza się, że te wysoce skorelowane fluktuacje są generowane przez oscylacyjną synchronizację neuronów lub spontaniczny proces przejścia fazowego wielu neuronów, które oddziałują ze sobą (Allegrini 2009). Metoda FNS dostarcza nowych narzędzi analizy sygnału i ekstrakcji cech, ponieważ wprowadza informacje o zadaniu motorycznym zawarte w składowej chaotycznej sygnału.

4. Wykorzystanie efektu Magnusa w sporcie i technice

4.1. Siła Magnusa

Obecnie dużym zainteresowaniem cieszą się metody i urządzenia wspomagające rehabilitację i trening sportowy. Ponieważ dobre wyniki aktywności ruchowej opierają się na właściwej kontroli i koordynacji ruchu, znajomość fizyki sportu jest powszechnie wykorzy-

stywana w rehabilitacji narządu ruchu oraz do poprawy wyników uzyskiwanych w różnych dyscyplinach sportowych. Przykładem zjawiska znacząco wpływającego na ruch obiektów jest siła Magnusa:

$$F_M = Bm\omega \times V \tag{1}$$

której wartość zależy od prędkości kątowej ω i liniowej V względem ośrodka.

Kierunek siły Magnusa prostopadłej do kierunku przepływu, działającej na obracającą się i poruszającą się względem płynu bryłę obrotową, sprawia, że efekty jej działania są niejednokrotnie pozornie zaskakujące, a równocześnie wywierają często istotny wpływ na poruszający się obiekt. Z tego powodu trwają intensywne prace zmierzające do wykorzystania tego efektu w technice, np. energetyce, wojsku, ale również w sporcie i rehabilitacji.

4.2. Przeprowadzone badania

Badania obejmowały detekcję współrzędnych znacznika umieszczonego na piłce do siatkówki poruszającej się w przestrzeni trójwymiarowej, na podstawie sekwencji zarejestrowanych nieostrych obrazów. Przeanalizowano wpływ różnych rodzajów szumów (rozmywającego szumu „atmosferycznego", zakłóceń spowodowanych ruchem obiektu lub kamery, braku ostrości obrazu oraz szumu współogniskowego) na dokładność detekcji położenia znacznika umieszczonego na poruszającej się piłce. Zagadnienie rekonstrukcji obrazu na podstawie zarejestrowanego obrazu zaszumionego zostało opisane równaniem całkowym Fredholma pierwszego rodzaju:

$$\int_0^1\int_0^1 \{k_1(x,s)\}\cdot\{k_2(y,t)\}\cdot\{f(x,y)\}dxdy = \{g(s,t)\} \tag{2}$$

gdzie:

$\{k_1(x, s)\}$, $\{k_2(y, s)\}$ – funkcje podcałkowe zdefiniowane dla kierunku poziomego i pionowego,

$\{g(s, t)\}$ – obraz zaszumiony,

$\{f(x, y)\}$ – poszukiwane rozwiązanie.

W wyniku dyskretyzacji równania (2) równanie opisujące problem redukcji zakłóceń rejestrowanego obrazu przyjmuje postać:

$$\left(\left[K_1(x,s)\right]\otimes\left[K_2(y,t)\right]\right)\cdot\{F(x,y)\} = \{G(s,t)\} \tag{3}$$

gdzie:

$\otimes$ – iloczyn Kroneckera,

$[K_1]$, $[K_2]$ – macierze modelujące zakłócenia w kierunku poziomym ($[K_1]$) oraz pionowym ($[K_2]$).

4.3. Podsumowanie

Estymacja parametrów kinematycznych szybko poruszającego się obiektu w trudnych warunkach (np. z dużej odległości, w słabym oświetleniu) stanowi istotne wyzwanie. Dotyczy to składowych prędkości liniowej, ale przede wszystkim prędkości kątowej. Przeprowadzone badania wykazały, że w przypadku obrazów niezaszumionych opracowana metoda umożliwia wykrycie położenia znacznika (na podstawie oszacowanego położenia środka ciężkości) z dokładnością do 3 pikseli. W przypadku obrazów obciążonych szumem współogniskowym dokładność detekcji położenia znacznika na poruszającej się piłce zależy od poprawności doboru progu binaryzacji. W toku przeprowadzonych badań odpowiedni dobór progu binaryzacji umożliwił określenie położenia znacznika z dokładnością do 5 pikseli, a wiec tylko nieznacznie mniejszą niż w przypadku obrazów niezaszumionych.

5. Interpretacja sygnałów biomedycznych na przykładzie słuchowych potencjałów wywołanych (SPW)

Systemy wspomagania diagnostyki medycznej bazujące na akwizycji, analizie i rozpoznawaniu sygnałów biomedycznych mają szerokie zastosowanie w praktyce klinicznej. Stale doskonalone są metody akwizycji tych sygnałów, a dostępność profesjonalnych urządzeń jest duża. Niestety sam prawidłowy pomiar sygnałów nie zapewnia jeszcze uzyskania poprawnych wyników analizy i rozpoznawania. Wynika to głównie ze specyfiki samych sygnałów biomedycznych, na ogół zaszumionych i losowo zakłócanych artefaktami pochodzenia głównie biologicznego.

Jako przykład można rozważyć analizę słuchowych potencjałów wywołanych, której zadaniem jest wczesne wykrycie i diagnostyka zaburzeń słuchu u małych dzieci. Zgodnie z zaleceniami proces diagnostyczny powinien być zakończony u małego dziecka przed upływem 6 miesiąca życia, co można osiągnąć jedynie dzięki zastosowaniu metod obiektywnych badania słuchu. Jedną z takich metod jest kontekstowe przetwarzanie SPW przy użyciu sieci neuronowych.

Pojedynczy przebieg potencjału składa się z od 5 do 7 fal, oznaczanych cyframi rzymskimi (I–VII). Przebieg ten wydobywany jest z sygnału EEG metodą synchronicznego uśredniania i jest rejestrowany w ciągu 10 ms lub 12 ms od chwili zadziałania bodźca akustycznego. Diagnostyka uszkodzeń słuchu na podstawie zapisów SPW opiera się na identyfikacji od 3 do 5 charakterystycznych fal występujących w tym zapisie. Latencje i amplitudy wykrytych fal stanowią parametry diagnostyczne. Jednym z podstawowych problemów w automatycznej diagnostyce SPW jest wykrycie i prawidłowe oznaczenie poszczególnych fal. Ze względu na dużą zmienność osobniczą, wysoki poziom szumów niskoczęstotliwościowych oraz występowanie artefaktów mięśniowych zadanie oznaczenia danej fali staje się skomplikowane. Największe trudności występują przy małej amplitudzie sygnału pobudzającego (<50 dB). Identyfikacja fal staje się łatwiejsza, jeżeli przeprowadzana

jest kontekstowa analiza wielu zapisów wykonanych przy stopniowo zmniejszanym natężeniu bodźca.

Badania wykorzystujące próbę automatyzacji procesu wyznaczania latencji poszczególnych fal oraz rozpoznawanie przy użyciu sieci neuronowych pozwoliły na uzyskanie wysokiej skuteczności klasyfikacji wynoszącej 93%. Przy wnioskowaniu na podstawie pojedynczych odpowiedzi skuteczność była mniejsza i wyniosła około 70%.

Przedstawione działania były częścią prac prowadzonych w celu stworzenia systemu akwizycji, standaryzacji, analizy, przetwarzania, wizualizacji i automatycznego rozpoznawania słuchowych potencjałów wywołanych.

6. Pomiary i przetwarzanie sygnałów pochodzących z urządzeń ubieralnych na potrzeby profilaktyki zdrowotnej i telemedycyny

Urządzenia ubieralne umożliwiają pomiar wybranych parametrów zdrowia człowieka na potrzeby profilaktyki zdrowotnej i mogą być zastosowane w różnych scenariuszach usług telemedycznych.

6.1. Monitorowanie aktywności człowieka z wykorzystaniem multimodalnych biomarkerów pobranych z urządzeń ubieralnych

Badania retrospektywne prowadzone w Katedrze Biocybernetyki i Inżynierii Biomedycznej AGH wspólnie z lekarzami ze Szpitala Uniwersyteckiego Collegium Medicum Uniwersytetu Jagiellońskiego umożliwiły opracowanie i zwalidowanie metodologii oceny ryzyka sercowo-naczyniowego oraz zespołu kruchości (*frailty syndrome*) podczas pomiarów wzorców aktywności człowieka na podstawie multimodalnych biomarkerów zebranych z czujników smartwatcha. Utworzona baza danych obejmowała 464 dni pomiarowe. Wyniki analiz sugerują, że w przyszłości smartwatche lub nowa-torskie urządzenia medyczne, które można nosić na ciele, mogą wspierać użytkowników w profilaktyce wybranych schorzeń, a tym samym otwierają nowe możliwości świadczenia usług zdrowotnych i obiecują przyspieszenie rozwoju nowatorskich usług telemedycznych (Kańtoch E. i Kańtoch A. 2021).

6.2. Pożądane cechy i zastosowania usług telemedycznych dla osób starszych wykorzystujących ubieralne urządzenia medyczne

W celu identyfikacji pożądanych cech i zastosowań usług telemedycznych dla osób starszych świadczonych z wykorzystaniem urządzeń medycznych do noszenia na ciele przeprowadzono badanie wśród 146 dorosłych ochotników. Analizę oparto na badaniach jakościowych oraz statystykach opisowych. Porównania dokonano z wykorzystaniem

testu chi-kwadrat Pearsona. Kwestionariusz, który został podzielony na 3 części (1 – dane socjodemograficzne, potrzeby i zachowania; 2 – stan zdrowia; 3 – badanie świadomości usług telemedycznych i koncepcji urządzenia), składał się z 37 pytań otwartych, półotwartych lub zamkniętych. Wyniki sugerują, że najbardziej pożądaną cechą urządzeń było wykrywanie sytuacji zagrożenia życia i zdrowia (Kańtoch E. i Kańtoch A. 2020).

6.3. Podsumowanie

Śledzenie wybranych parametrów zdrowotnych, takich jak częstość akcji serca, poziom aktywności ruchowej czy jakość snu z użyciem ubieralnych urządzeń medycznych może mieć istotne znaczenie w profilaktyce zdrowotnej. Najbardziej pożądaną cechą medycznych urządzeń ubieralnych jest mechanizm automatycznego wykrywania sytuacji zagrożenia życia i zdrowia użytkownika.

7. Systemy pomiarowe do zastosowania w nawigacji zespołu kaniula–prowadnica w obrębie głębokich rejonów drzewa oskrzelowego

7.1. Wprowadzenie

Bronchoskopia ma na celu zdiagnozowanie zmian w obrębie drzewa oskrzelowego. Sam bronchoskop jest narzędziem wyposażonym w źródło światła, kanał roboczy oraz przewód optyczny pozwalający na obserwację wnętrza drzewa oskrzelowego. Niestety jeśli chodzi o nawigację bronchoskopem, to jest ona możliwa do około tzw. trzeciej cariny (poziomu rozgałęzienia) drzewa oskrzelowego. Dzieje się tak, ponieważ średnica bronchoskopu wynosi około 6 mm, a zwężające się gałęzie drzewa oskrzelowego osiągają tę średnicę właśnie w okolicach trzeciej cariny. Pozostały odcinek do końca gałęzi drzewa oskrzelowego wynosi około 100 mm. Drogę tę może przebyć zespół kaniula–prowadnica (KP) wprowadzany do drzewa oskrzelowego przez kanał roboczy bronchoskopu. Zespół ten nie ma możliwości przekazywania obrazu, niemniej znając trójwymiarowy obraz drzewa oskrzelowego pochodzący z badania tomograficznego oraz analizując manewry wykonane prowadnicą oraz drogę przebytą przez zespół KP, można precyzyjnie przewidzieć położenie końcówki prowadnicy, a nawet zwizualizować jej przemieszczenie w czasie rzeczywistym (Michalski i in. 2017).

7.2. Metoda i wyniki jej weryfikacji

Aby zweryfikować tezę, że przesunięcie, rotację i zgięcie dystalnej końcówki prowadnicy można przewidzieć na podstawie pomiarów ręcznych manewrów uchwytem prowadnicy, użyto trzech prototypowych urządzeń (rys. 2): urządzenia D1 (kontrolującego liniowe

przesunięcie kaniuli), urządzenia D2 (kontrolującego kąt obrotu uchwytu) i urządzenia D3 (kontrolującego przesunięcie pierścienia uchwytu, które determinuje wygięcie końcówki prowadnicy).

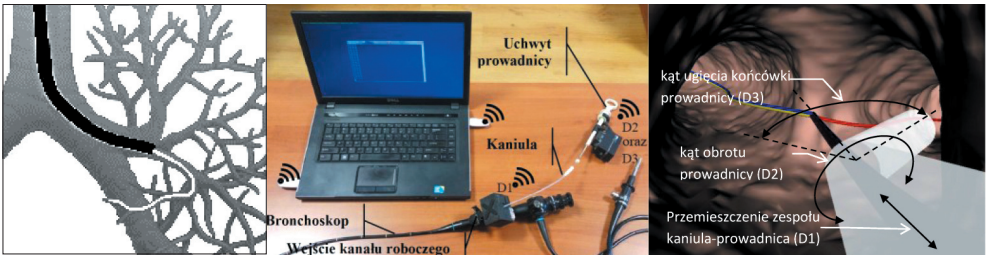

Rys. 2. Problem nawigacji wewnątrz drzewa oskrzelowego oraz jego rozwiązanie

W urządzeniu D1 (rys. 3) do pomiaru przemieszczenia liniowego zespołu KP zastosowano laserowy czujnik optyczny ADNS-9800. Pozwala on na pomiar przemieszczenia powierzchni kaniuli przez obserwację przesunięcia obrazu na matrycy czujnika. Obraz ten jest efektem odbicia światła laserowego, które pozwala na wyodrębnienie większej liczby detali obserwowanej powierzchni. Ze względu na to, że w trakcie badania kaniula nie obraca się, wykorzystywany jest jedynie pomiar jej przesunięcia osiowego. Względne przemieszczenia badanej powierzchni są w urządzeniu D1 przekazywane do mikrokontrolera ATmega32U4, który gromadzi i przetwarza je w celu obliczenia aktualnej pozycji kaniuli. Urządzenie D1 składa się z obudowy złożonej z części dolnej i pokrywy. W dolnej części znajduje się dolne łoże kaniuli, a w pokrywie jej łoże górne, które razem składają się na cylindryczny kanał roboczy o promieniu równym promieniowi zewnętrznemu kaniuli. W dolnym łożu znajduje się magnes neodymowy, którego zadaniem jest spozycjonowanie prowadnicy w dolnej części kanału, a tym samym wyizolowanie na matrycy ADNS-9800 jedynie obrazu powierzchni kaniuli.

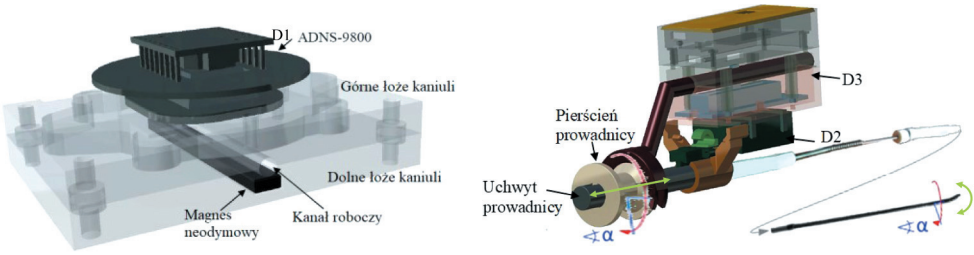

Rys. 3. Elementy funkcjonalne oraz sposób działania urządzeń D1, D2 i D3

Urządzenie D2 mierzy kąt obrotu uchwytu prowadnicy, a przez to obrót jej końcówki. Jest ono oparte na układzie BNO055 zamontowanym wewnątrz specjalnie zaprojektowanej obudowy zamocowanej do uchwytu prowadnicy. Zostało zbudowane tak, aby oś

związana z kątem *roll* urządzenia była równoległa do osi prowadnicy (rys. 2 i 3). BNO055 IMU jest wyposażony w procesor sygnałowy oraz urządzenia trójosiowe: magnetometr, żyroskop oraz akcelerometr.

Urządzenie D3 kontroluje ugięcie giętkiej końcówki prowadnicy w stosunku do kierunku zadanego przez jej oś. Wykorzystuje czujnik przemieszczenia umieszczony nad uchwytem prowadnicy (rys. 3). Uchwyt ma specjalny pierścień, który może poruszać się proksymalnie i dystalnie od położenia neutralnego. W zależności od kierunku przesuwu pierścienia końcówka prowadnicy wygina się w dwóch przeciwnych kierunkach. Wykorzystując pomiarowy przetwornik rezystancyjny, urządzenie D3 pozwala mierzyć ugięcie końcówki za pomocą pomiaru przemieszczenia pierścienia.

Urządzenia D2 i D3 przesyłają dane do mikrokontrolera AT-mega32U4, który podobnie jak D1 przekazuje je bezprzewodowo do komputera PC korzystając z technologii Bluetooth 4.0 (rys. 2). Aby zweryfikować poprawność działania systemu, dla każdego z urządzeń przeprowadzono serię 4 pomiarów. Błąd pomiaru urządzenia D1 względem układu odniesienia nie przekraczał 2 mm, co świadczy o jego przewadze nad stosowaną od lat w medycynie tzw. nawigacją elektromagnetyczną, gdzie błąd pomiaru przemieszczenia sięga 9 mm (Eberhardt i in. 2007). W przypadku urządzenia D2 maksymalny błąd wyniósł 10°, a w przypadku urządzenia D3 – 20°, jednak ze względu na odchylenia pomiędzy sąsiadującymi gałęziami drzewa oskrzelowego powyżej 30° błędy te są akceptowalne i nie zaburzają poprawnego procesu nawigacji.

8. Rejestracja i analiza sygnałów multimodalnych generowanych przez człowieka w różnych stanach jego aktywności fizycznej i psychicznej

Jednym z obszarów naszych naukowych i dydaktycznych zainteresowań jest rejestracja, przetwarzanie i automatyczna analiza sygnałów multimodalnych generowanych przez człowieka. Przebiegi czasowe takich sygnałów ściśle zależą od rodzaju i stopnia aktywności (fizycznej i psychicznej) człowieka, wobec czego po odpowiedniej ich klasyfikacji można je następnie wykorzystywać do określonych celów badawczych, medycznych, terapeutycznych, rehabilitacyjnych, treningowych.

Analizę aktywności motorycznej przeprowadzano na podstawie sygnałów (rys. 4) zarejestrowanych przy użyciu różnego typu urządzeń pomiarowych, takich jak systemy optoelektroniczne *motion capture*, platformy balansowe i podoskopowe, sensory wizyjne, akcelerometryczne, goniometryczne, elektromiograficzne, jak również sensory siły i ciśnienia. Akwizycja dokonywana była podczas zadanych rozmaitych ćwiczeń treningowych i re-

habilitacyjnych, prostych czynności życia codziennego (Mikrut i Smoleń 2011, Smoleń 2019, Smoleń i Augustyniak 2020) czy symulowanych sytuacji niebezpiecznych (Mikrut i in. 2012).

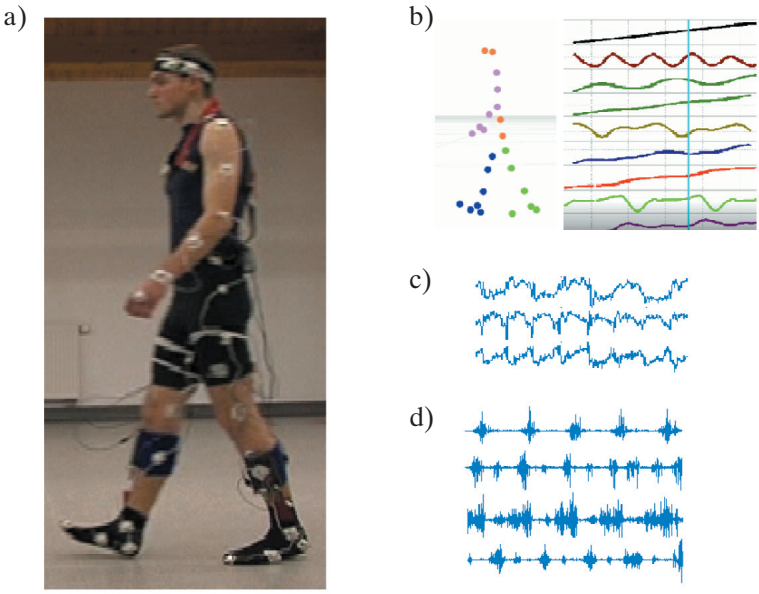

Rys. 4. Przykłady sygnałów motorycznych człowieka: a) wideo – pojedyncza klatka; b) *motion capture* – położenia markerów (umieszczonych na ciele) w czasie; c) sygnały akcelerometryczne w czasie; d) sygnały elektromiograficzne w czasie

Oprócz wspomnianych powyżej zagadnień biomechanicznych przedmiotem naszych badań jest również elektroencefalografia (EEG), elektrokardiografia (EKG), elektrookulografia (EOG), okulografia w podczerwieni, wideookulografia, rejestracja pulsu (BVP – *blood volume pulse*), reakcji skórno-galwanicznej (GSR – *galvanic skin response*) i oddechu (z użyciem termistora umieszczanego pod nosem i pasa tensometrycznego umieszczanego na brzuchu lub klatce piersiowej). Takie multimodalne rejestracje mogą posłużyć do oceny stanu zdrowia podczas czuwania (Augustyniak i in. 2010, Kańtoch E. i in. 2011, Smoleń i in. 2011) i snu (Smoleń 2009, Smoleń i in. 2010a, 2010b) w domowym monitoringu. Kolejnym ciekawym i istotnym zastosowaniem jest ich analiza w różnych innych stanach aktywności psychicznej: podczas wykonywania ćwiczeń relaksacyjnych, oddechowych, gruntujących, medytacyjnych, hipnotycznych, treningowych (np. *biofeedback*) i terapeutycznych. Dzięki korelacji umysłu i ciała możliwe jest bowiem określenie wpływu i efektywności wybranych metod wspierających rozwój i zdrowie psychofizyczne człowieka.

Otrzymane przez nas wyniki potwierdziły skuteczność różnorodnych metod rejestracji, przetwarzania i analizy sygnałów człowieka w wielu praktycznych interdyscyplinarnych zastosowaniach na pograniczu medycyny, techniki, sportu, treningu, psychologii i terapii.

9. Przetwarzanie równoległe i rozproszone sygnałów

Przedstawiony obszar badawczy dotyczy szeroko pojętego przetwarzania sygnałów na potrzeby aplikacji w równoległych i rozproszonych systemach wbudowanych.

9.1. Systemy równoległe

Programowanie równoległe i systemy równoległe dają nam możliwość lepszego wykorzystania zasobów obliczeniowych, aby rozwiązywać bardziej wymagające problemy techniczne w krótszym czasie, niż jest to możliwe na pojedynczym sekwencyjnym komputerze. Rozwój systemów wielordzeniowych i wieloprocesorowych sprawia, że programowanie równoległe jest aktualnie niezbędną praktyką programistyczną. Konieczne staje się pisanie programów równoległych, w których wiele wątków wykonawczych współpracuje ze sobą, aby szybciej osiągnąć założoną funkcjonalność systemu (Szymczyk M. 1993, Szymczyk P. i Szymczyk M. 2011b, Szymczyk M. i Szymczyk P. 2020).

9.2. Systemy rozproszone

Cena pojedynczego mikrokontrolera często jest bardzo niska, zatem możliwe jest budowanie urządzeń mających formę systemu rozproszonego, którego elementami są czujniki podłączone bezpośrednio (lokalnie) do indywidualnie dedykowanych i zaprogramowanych mikrokontrolerów. Uzyskane za pomocą czujników dane można częściowo przetworzyć w węźle, a następnie przesłać do węzła centralnego w celu dalszej analizy lub do chmury w celu późniejszego wykorzystania (lub dokładniejszej analizy) (Szymczyk M. i Szymczyk P. 2004).

9.3. Systemy mikroprocesorowe

Mikroprocesory oparte na pojedynczej jednostce centralnej (CPU) zapewniały przez ponad 6 dekad szybki wzrost wydajności i obniżenie kosztów aplikacji komputerowych. Obecnie wszyscy producenci mikroprocesorów skupili się na rozwiązaniach wielordzeniowych (z powodu kłopotów z udoskonaleniem technologii produkcji i działania tranzystorów), co ponownie skutkuje zwiększaniem mocy obliczeniowej i pojawieniem się nowych, niedostępnych dotychczas obszarów zastosowań. Takie mikroprocesory są elementem architektury nie tylko superkomputerów i komputerów codziennego użytku, ale

także różnych specjalizowanych systemów wbudowanych (*embedded systems*) (Szymczyk P. i Szymczyk M. 2011a).

9.4. Systemy wbudowane

Z systemami wbudowanymi mamy obecnie powszechnie do czynienia w codziennym życiu – są stosowane m.in. w przemyśle samochodowym, lotniczym, medycznym i kosmicznym. Ich złożoność jest różna i zależy od potrzeb – od niskiej z pojedynczym mikrokontrolerem, po bardzo wysoką z wbudowanymi wieloma jednostkami, urządzeniami peryferyjnymi i zaimplementowanymi protokołami komunikacyjnymi do współpracy z różnorodnymi sieciami (Szymczyk M. 2002, Szymczyk P. i Szymczyk M. 2011a).

9.5. Systemy bezprzewodowe

Urządzenia bezprzewodowe (WD – *wireless devices*) są niezwykle atrakcyjną technologią informatyczną i stały się częścią naszego życia w zakresie wymiany informacji, w tym również tych o naszym zdrowiu. Zupełnie nowym obszarem badawczym w systemach rozproszonych i wbudowanych są sieci bezprzewodowe typu WBAN (*wireless body area networks*) zintegrowane z ludzkim ciałem w celu osobistego monitorowania stanu zdrowia. Składają się one z małych urządzeń umieszczonych na ciele człowieka lub wewnątrz niego i wykorzystują możliwość komunikacji bezprzewodowej. Problem energooszczędności tego typu sieci jest bardzo istotny ze względu na specyfikę współpracy z ludzkim ciałem. Długi czas życia węzła o różnych wymaganiach operacyjnych wymaga zaprojektowania systemu bezpiecznego pod względem zasilania na wszystkich poziomach hierarchii systemu, a wiadomo, że problem optymalizacji parametrów wydajności bezprzewodowej sieci sensorowej jest zagadnieniem trudnym i złożonym (Szymczyk M. i Augustyniak 2022).

9.6. Przetwarzanie sygnałów

Systemy oparte na mikrokontrolerach i mikroprocesory zdominowały dziedzinę przetwarzania sygnałów i obrazów, kosztem przetwarzania analogowego. W najprostszej formie przetwarzanie sygnałów sprowadza się do manipulowania danymi zebranymi przez próbkowanie sygnałów analogowych. Przetwarzanie sygnałów można zatem uznać za umiejętność pracy z ciągami liczb (Szymczyk P. i in. 2015a, 2015b, Szymczyk P. i Szymczyk M. 2018).

9.7. Podsumowanie

Obszar badawczy dotyczy szybko rozwijającej się dziedziny przetwarzania sygnałów dla potrzeb sieci typu WBAN.

10. Sieci neuronowe z wielomianami aproksymującymi oraz przekształceniami Laplace'a i Z

10.1. Wstęp

Sieci neuronowe jako jeden z istotnych obszarów biocybernetyki cały czas są przedmiotem badań i intensywnie się rozwijają, ponieważ są bardzo efektywnym narzędziem uczącym się. Przedstawione poniżej wyniki badań pokazują nowe rodzaje sieci neuronowych, które mogą być stosowane do analizy, przetwarzania i interpretacji różnego rodzaju sygnałów. Sygnałami tymi mogą być na przykład obrazy medyczne uzyskiwane za pomocą takich metod obrazowania jak rentgenografia, tomografia komputerowa, rezonans magnetyczny czy tomografia pozytonowa.

10.2. Sieci neuronowe z wielomianami aproksymującymi

Zaproponowano oryginalny sposób reprezentacji sygnału na wejściu sieci neuronowej przez aproksymację przebiegu tego sygnału wielomianem, a następnie próbowano wykorzystać współczynniki tego wielomianu jako sygnały podawane na wejście sieci neuronowej (Szymczyk P. i in. 2015a). Można zaproponować następujący sposób postępowania. Oznaczmy jako $G_x(d)$ przebieg sygnału o numerze x w punkcie o współrzędnej d. Zakładamy, że sygnał $G_x(d)$ może być aproksymowany wielomianem stopnia N o współczynnikach $a_{0x}, a_{1x}, a_{2x}, \ldots, a_{Nx}$. Można to symbolicznie zapisać w formie zależności:

$$G_x \cong \sum_{i=0}^{N} a_{ix} d^i \tag{4}$$

Po wykonaniu takiej aproksymacji można przyjąć, że sygnał $G_x(d)$ na wejściu sieci neuronowej reprezentowany będzie przez wektor $N + 1$ współczynników $a_{0x}, a_{1x}, a_{2x}, \ldots, a_{Nx}$.

Takie podejście prowadzi do stworzenia klasycznej sieci z wagami w postaci współczynników wielomianów aproksymujących sygnał. Struktury sieci oraz sposoby uczenia tak uzyskanej sieci są powszechnie znane – analogiczne do zwykłych, klasycznych sieci neuronowych.

10.3. Sieci neuronowe z przekształceniem Laplace'a

Jedną z odmian sieci neuronowych jest sieć neuronowa z przekształceniem Laplace'a (Szymczyk P. i Szymczyk M. 2015a, 2015b) przedstawiona na rysunku 5. Zbudowana jest ona z neuronów mających funkcję przejścia w postaci transformaty Laplace'a.

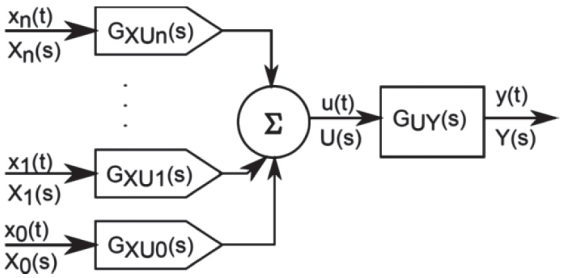

Rys. 5. Neuron z przekształceniem Laplace'a

10.4. Sieci neuronowe z przekształceniem Z

Drugą z zaproponowanych odmian sieci neuronowych są sieci neuronowe z przekształceniem Z. Na rysunku 6 przedstawiono neuron z przekształceniem Z. Powstają one w sposób analogiczny do opisanych poprzednio sieci neuronowych z przekształceniem Laplace'a. Zasadnicza różnica polega na tym, że przekształcenie Laplace'a zostało zastąpione przekształceniem Z, co umożliwia zastosowanie tych sieci do analizy sygnałów dyskretnych (Szymczyk P. 2015, Szymczyk P. i Szymczyk M. 2018, Szymczyk M. i Szymczyk P. 2020).

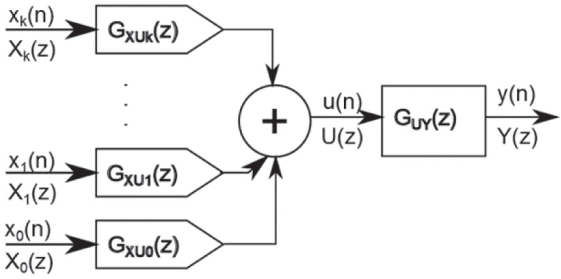

Rys. 6. Neuron z przekształceniem Z

10.5. Podsumowanie

W artykule zasygnalizowano prace autorów i wskazano pozycje literatury gdzie można poszerzyć informacje na temat szczegółów przedstawionych nowych rodzajów sieci neuronowych oraz ich zastosowań w przetwarzaniu sygnałów.

Literatura

Allegrini P., Menicucci D., Bedini R., Gemignani A., Grigolini P., West P., Paradisi P., 2009, *Spontaneous brain activity as a source of ideal 1/f noise*, Physical Review E, vol. 80(6), 061914. https://doi.org/10.1103/physreve.80.061914.

Augustyniak P., 2020, *Adaptive sampling of the electrocardiogram based on generalized perceptual features*, Sensors, vol. 20(2), 373. https://doi.org/10.3390/s20020373.

Augustyniak P., 2021, *Diagnostic interpretation of non-uniformly sampled electrocardiogram*, Sensors, vol. 21(9), 2969. https://doi.org/10.3390/s21092969.

Augustyniak P., Tadeusiewicz R., 2006, *Assessment of electrocardiogram visual interpretation strategy based on scanpath analysis*, Physiological Measurement, vol. 27, no. 7, s. 597–608. https://doi.org/10.1088/0967-3334/27/7/004.

Augustyniak P., Smoleń M., Broniec A., Chodak J., 2010, *Data integration in multimodal home care surveillance and communication system*, [w:] Piętka E., Kawa J. (eds.), *Information Technologies in Biomedicine*, Advances in Intelligent and Soft Computing, vol. 69, Springer Berlin, Heidelberg, s. 391–402. https://doi.org/10.1007/978-3-642-13105-9_39.

Broniec A., 2016, *Analysis of EEG signal by flicker-noise spectroscopy: identification of right-/left-hand movement imagination*, Medical & Biological Engineering & Computing, vol. 54(12), s. 1935–1947. https://doi.org/10.1007/s11517-016-1491-z.

Broniec A., 2021, *The FNS-based analysis of precursors and cross-correlations in EEG signal related to an imaginary motor task*, Biomedical Signal Processing and Control, vol. 64, s. 1–9, 102315. https://doi.org/10.1016/j.bspc.2020.102315.

BS EN 60601-2-25:2015, *Medical electrical equipment – Part 2-25: Particular requirements for the basic safety and essential performance of electrocardiographs*.

Buzsáki G., Draguhn A., 2004, *Neuronal oscillations in cortical networks*, Science, vol. 304(5679), s. 1926–1929. https://doi.org/10.1126/science.1099745.

Devine A., 2012, *Basketball training device*, United States Patent, Patent no. US 8277340 B1.

Eberhardt R., Anantham D., Herth F., Feller-Kopman D., Ernst A., 2007, *Electromagnetic navigation diagnostic bronchoscopy in peripheral lung lesions*, Chest, vol. 131(6), s. 1800–1805. https://doi.org/10.1378/chest.06-3016.

Kańtoch E., Kańtoch A., 2020, *What features and functions are desired in telemedical services targeted at Polish older adults delivered by wearable medical devices? – Pre-COVID-19 flashback*, Sensors, vol. 20(18), 5181. https://doi.org/10.3390/s20185181.

Kańtoch E., Kańtoch A., 2021, *Cardiovascular and pre-frailty risk assessment during shelter-in--place measures based on multimodal biomarkers collected from smart telemedical wearables*, Journal of Clinical Medicine, vol. 10(9), 1997. https://doi.org/10.3390/jcm10091997.

Kańtoch E., Smoleń M., Augustyniak P., Kowalski P., 2011, *Wireless body area network system based on ECG and accelerometer pattern*, Computing in Cardiology, vol. 38, s. 245–248.

Martinez J.P., Almeida R., Olmos S., Rocha A.P., Laguna P., 2004, *A wavelet-based ECG delineator: Evaluation on standard databases*, IEEE Transactions on Biomedical Engineering, vol. 51(4), s. 570–581. https://doi.org/10.1109/TBME.2003.821031.

Michalski D., Nabagło T., Tutaj J., Mysiński W., Petryniak R., Pietrzyk D., Wojciechowski W., Tabor Z., 2017, *Mechatronics supported virtual bronchoscopy for navigation in bronchoscopy of peripheral respiratory tree*, [w:] Tavares J.M.R.S., Jorge R.M.N. (eds.), *VipIMAGE 2017. Proceedings of the VI ECCOMAS Thematic Conference on Computational Vision and Medical Image Processing. Porto, Portugal, October 18–20, 2017*, Lecture Notes in Computational Vision and Biomechanics, vol. 27, Springer, Cham, s. 320–328. https://doi.org/10.1007/978-3-319-68195-5_35.

Mikrut Z., Smoleń M., 2011, *A neural network approach to recognition of the selected human motion patterns*, Automatyka, t. 15, z. 3, s. 535–543.

Mikrut Z., Pleciak P., Smoleń M., 2012, *Combining pattern matching and optical flow methods in home care vision system*, [w:] Piętka E., Kawa J. (eds.), *Information Technologies in Biomedicine: Third International Conference, ITIB 2012, Gliwice, Poland, June 11–13, 2012: Proceedings*, Lecture Notes in Computer Science, vol. 7339, Springer, Berlin, Heidelberg, s. 537–548. https://doi.org/10.1007/978-3-642-31196-3_54.

Moody G.B., Mark R.G., 1990, *The MIT-BIH arrhythmia database on CD-ROM and software for use with it*, [w:] *Proceedings. Computers in Cardiology*, IEEE, Piscataway, s. 185–188. https://doi.org/10.1109/CIC.1990.144205.

Nadaraya E.A., 1964, *On estimating regression*, Theory of Probability & Its Applications, vol. 9, s. 141–142. https://doi.org/10.1137/1109020.

Smolen M., 2009, *Analysis of EEG activity during sleep – brain hemisphere symmetry of two classes of sleep spindles*, Polish Journal of Medical Physics and Engineering, vol. 15(2), s. 65–75. https://doi.org/10.2478/v10013-009-0007-7.

Smoleń M., 2019, *Consistency of outputs of the selected motion acquisition methods for human activity recognition*, Journal of Healthcare Engineering, vol. 2019, 9873430. https://doi.org/10.1155/2019/9873430.

Smoleń M., Augustyniak P., 2020, *Assisted living system with adaptive sensor's contribution*, Sensors, vol. 20(18), 5278. https://doi.org/10.3390/s20185278.

Smoleń M., Czopek K., Augustyniak P., 2010a, *Non-invasive sensors based human state in nightlong sleep analysis for home-care*, Computing in Cardiology, vol. 37, s. 45–48.

Smoleń M., Czopek K., Augustyniak P., 2010b, *Sleep evaluation device for home-care*, [w:] Piętka E., Kawa J. (eds.), *Information Technologies in Biomedicine*, Advances in Intelligent and Soft Computing, vol. 69, Springer, Berlin, Heidelberg, s. 367–378. https://doi.org/10.1007/978-3-642-13105-9_37.

Smoleń M., Kańtoch E., Augustyniak P., Kowalski P., 2011, *Wearable patient home monitoring based on ECG and ACC sensors*, [w:] Jobbágy Á. (ed.), *5th European Conference of the International Federation for Medical and Biological Engineering. 14–18 September 2011, Budapest, Hungary*, IFMBE Proceedings, vol. 37, Springer, Berlin, Heidelberg, s. 941–944. https://doi.org/10.1007/978-3-642-23508-5_244.

Szczerbik E., Kalinowska M., 2011, *The influence of knee marker placement error on evaluation of gait kinematic parameters*, Acta of Bioengineering and Biomechanics, vol. 13(3), s. 43–46.

Szymczyk M., 1993, *Parallel algorithms and architectures for control and optimization. Report. Community Action for Corporation in Sciences and Technology with Central and Eastern European Countries*, Valencia.

Szymczyk M., 2002, *Communication problems in real-time and embedded systems*, [w:] Farana R., Smutný L. (eds.), *Proceedings of 3rd International Carpathian Control Conference ICCC'2002: XXVIIth Seminary ASR'2002 "Instruments & Control" (ASR'2002): 16th International Conference Automated Systems of Control of Technological Processes (ASRTP'2002): 4th Automatyzacja Maszyn, Urządzeń i Procesów (APRO): Malenovice, Czech Republic, May 27–30, 2002*, VŠB-TU, Ostrava, s. 407–412.

Szymczyk M., Augustyniak P., 2022, *Selected energy consumption aspects of sensor data transmission in distributed multi-microcontroller embedded systems*, Electronics, vol. 11(6), 848. https://doi.org/10.3390/electronics11060848.

Szymczyk M., Szymczyk P., 2004, *Reliability of cluster system with a lot of software instances*, [w:] Bubak M., Albada G.D., van, Sloot P.M.A., Dongarra J.J. (eds.), *Computational Science – ICCS 2004: 4th International Conference. Kraków, Poland, June 6–9, 2004: Proceedings, Part I*, Lecture Notes in Computer Science, vol. 3036, Springer, Berlin, Heidelberg, s. 417–420. https://doi.org/10.1007/978-3-540-24685-5_55.

Szymczyk M., Szymczyk P., 2020, *Automatic processing of Z-transform artificial neural networks using parallel programming*, Neurocomputing, vol. 379, s. 74–88. https://doi.org/10.1016/j.neucom.2019.10.078.

Szymczyk P., 2015, *Z-transform artificial neural networks*, Neurocomputing, vol. 168, s. 1207–1210. https://doi.org/10.1016/j.neucom.2015.05.001.

Szymczyk P., Szymczyk M., 2011a, *Bezpieczeństwo i niezawodność systemów wbudowanych opartych na nowoczesnych mikrokontrolerach*, Automatyka, t. 15, z. 2, s. 443–450.

Szymczyk P., Szymczyk M., 2011b, *Matlab and parallel computing*, Image Processing & Communications, vol. 17, no. 4, s. 207–216.

Szymczyk P., Szymczyk M., 2015a, *Supervised learning Laplace transform artificial neural networks and using it for automatic classification of geological structure*, Neurocomputing, vol. 154, s. 70–76. https://doi.org/10.1016/j.neucom.2014.12.018.

Szymczyk P., Szymczyk M., 2015b, *Classification of geological structure using ground penetrating radar and Laplace transform artificial neural networks*, Neurocomputing, vol. 148, s. 354–362. https://doi.org/10.1016/j.neucom.2014.06.025.

Szymczyk P., Szymczyk M., 2018, *Identification of dynamic object using Z-Transform artificial neural network*, Neurocomputing, vol. 312, s. 382–389. https://doi.org/10.1016/j.neucom.2018.05.097.

Szymczyk P., Tomecka-Suchoń S., Szymczyk M., 2015a, *Neural networks as a tool for georadar data processing*, International Journal of Applied Mathematics and Computer Science, vol. 25, no. 4, s. 955–960. https://doi.org/10.1515/amcs-2015-0068.

Szymczyk P., Marcak H., Tomecka-Suchoń S., Szymczyk M., Gajer M., Gołębiowski T., 2015b, *Komputerowe przetwarzanie i analiza danych georadarowych*, Wydawnictwo Naukowe IAE, Kraków.

Świerkosz A., Augustyniak P., 2018, *Optimizing wavelet ECG watermarking to maintain measurement performance according to industrial standard*, Sensors, vol. 18(10), 3401. https://doi.org/10.3390/s18103401.

Tadeusiewicz R., Korohoda P., 1997, *Komputerowa analiza i przetwarzanie obrazów*, Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków.

Timashev S.F., 2001, *Flicker-noise spectroscopy in analysis of chaotic fluxes in distributed dynamical dissipative systems*, Russian Journal of Physical Chemistry A, vol. 75(10), s. 1742–1749.

Timashev S.F., Polyakov Y.S., 2007, *Review of flicker noise spectroscopy in electrochemistry*, Fluctuation and Noise Letters, vol. 7, no. 2, s. R15–R47. https://doi.org/10.1142/S0219477507003829.

Wardle J.L., Jensen J.M., 2005, *Methods and devices for sport ball training*, United States Patent, Patent no. US 20050113193 A1.

Watson G.S., 1964, *Smooth regression analysis*, Sankhyâ: The Indian Journal of Statistics, Series A, vol. 26, no. 4, s. 359–372.

Willems J.L., Arnaud P., Bemmel J.H., van, Bourdillon P.J., Degani R., Denis B., Graham I., Harms F.M., Macfarlane P.W., Mazzocca G., Meyer J., Zywietz Ch., Common Standards for Quantitative Electrocardiography (CSE) Working Party, 1987, *A reference data base for multilead electrocardiographic computer measurement programs*, Journal of the American College of Cardiology, vol. 10(6), s. 1313–1321. https://doi.org/10.1016/s0735-1097(87)80136-5.