

AUTOREFERAT ROZPRAWY DOKTORSKIEJ

**Sztuczne sieci neuronowe w analizie  
sygnałów biomedycznych**

AUTOR : MGR INŻ. GRZEGORZ RUTKOWSKI

Promotor:

DR HAB. INŻ. KRZYSZTOF PATAN, PROF. UZ

Promotor pomocniczy:

DR HAB. INŻ. ARTUR GRAMACKI, PROF. UZ

*Wydział Informatyki, Elektrotechniki i Automatyki*

*Uniwersytet Zielonogórski*

# 1 Wprowadzenie

Szacuje się, że liczba chorych na epilepsję sięga 50 milionów osób na całym świecie. Około 1-2% populacji ma napady padaczkowe. W Polsce określa się liczbę chorych na padaczkę na 300-400 tysięcy [3]. Zachorowalność na padaczkę jest nieco wyższa u mężczyzn, wyraźnie wyższa u dzieci oraz osób powyżej 65 roku życia. Współczynnik zachorowalności w tym okresie życia, wzrasta w miarę wieku pacjenta i po 75 roku życia jest większy niż u dzieci po 10 roku życia i wynosi do 150 przypadków na 100000 rocznie; ma to związek z chorobami naczyniowymi mózgu, chorobami zwyrodnieniowymi np. chorobą Alzheimera oraz nowotworami mózgu.

W pracy doktorskiej rozważano problem wykrywania krótkotrwałych napadów padaczkowych trwających około 1 sekundę. Przedstawiono i dokonano analizy szerokiej gamy metod przetwarzania, analizy i klasyfikacji sygnału EEG, które mogą być wykorzystane na potrzeby komputerowych systemów wspomaganie decyzji lekarzy neurologów w zakresie wykrywania zaburzeń neurologicznych. W rozprawie dokonano przeglądu dostępnych metod oraz rozwiązań wykorzystujących powszechnie stosowane algorytmy poczynając od metod klasycznych, takich jak odchylenie standardowe sygnału, suma skumulowana, metody wykorzystujące entropię przybliżoną oraz metody sprawdzające regularność przebiegu, aż do metod opartych o sztuczną inteligencję, w tym metod klasyfikacji opartych na uczeniu głębokim.

Użyte w rozprawie dane rzeczywiste zostały zgromadzone oraz gruntownie przeanalizowane we współpracy ze specjalistami w dziedzinie neurologii Szpitala Wojewódzkiego w Zielonej Górze, Oddziału Neurologii i Udarów (obecnie Uniwersyteckiego Szpitala im. Karola Marcinkiewicza w Zielonej Górze, Klinicznego Oddziału Neurologii). Poddano je rzetelnemu sprawdzeniu w celu eliminacji artefaktów, które mogłyby przy nieodpowiedniej analizie wstępnej znacznie wpłynąć na prezentowane wyniki.

Każdy dostępny zapis składał się z 16 kanałów pomiarowych. Cały proces pomiaru został wykonany z zachowaniem standardów dla tego rodzaju pomiarów EEG. Uzyskane dane zostały zgromadzone zarówno dla pacjentów z napadami epileptycznymi (104 zapisy) jak i dla przypadków zdrowych (71 zapisy). Utworzona została baza zapisów zawierająca łącznie 1176 sekwencji sygnałów EEG, gdzie 588 podciągnięć sygnałowych zostało oznaczonych według orzeczeń lekarzy neurologii jako napad epileptyczny oraz 588 podciągnięć określających normę dla przypadków zdrowych.

## 1.1 Sformułowanie problemu – zapis międzynapadowy

W trakcie rutynowego badania EEG trwającego od 20 do 30 minut jest wielce prawdopodobne, że typowe wyładowania padaczkowe nie wystąpią. Szacuje się że tylko u 25%-

30% badanych rejestruje się napady padaczkowe [6]. Dlatego dużą popularnością cieszy się badanie EEG międzynapadowe (*ang.*interictal). Nieprawidłowości międzynapadowe są ściśle skorelowane z padaczką, aczkolwiek powody ich powstawania nie są do końca znane [9]. Nieprawidłowości, które są swoiste dla padaczki, ale obserwowane w międzynapadowym badaniu EEG noszą nazwę padaczkopodobnych. Zmiany międzynapadowe występują w formie fale ostrych lub iglic lub zespołów iglica-fala wolna. Iglice trwają od 30-70ms, podczas gdy fale wolne od 70-100ms. W połączeniu w fala wolną wyładowanie padaczkopodobne trwa ok. 250ms [9]. Brak wyładowań w okresie międzynapadowym nie wyklucza jednak rozpoznania padaczki. Jedynie część pacjentów z padaczką ma zmiany w EEG w trakcie rutynowego badania.


Wykrywanie wyładowań padaczkowych jest procesem trudnym ze względu na liczne artefakty, które pojawiają się w zapisie EEG. Artefakty mogą być spowodowane przyczynami technicznymi takimi jak, wahania napięcia jak również mogą mieć podłoże biologiczne. Typowe artefakty biologiczne powodowane są napinaniem mięśni, ruchem gałek ocznych lub ruchem ciała. Na rys. 1 przedstawiono przykładowe reprezentacje krótkotrwałych, nagłych zmian sygnału EEG. Wykresy a) i b) pokazują przykłady napadów padaczkopodobnych wskazanych przez neurologa. Początek napadu został zaznaczony czerwoną, przerywaną linią. Widać wyraźnie zmianę amplitudy sygnału oraz parametry statystyczne sygnału. Z kolei na wykresach c) i d) przedstawiono prawidłowe międzynapadowe zapisy EEG. W tych dwóch przypadkach również można zaobserwować zmiany amplitudy sygnału oraz zmianę jego właściwości statystycznych, ale tym razem sygnały zarejestrowano u zdrowych osób i te gwałtowne zmiany nie są związane z padaczką. Pokazane przykłady jasno ilustrują, że problem wykrywania padaczki na podstawie krótkotrwałych zmian sygnału jest problemem trudnym do rozwiązania.

**Na tym tle można zdefiniować główny cel stawiany proponowanemu w rozprawie doktorskiej systemowi wykrywania napadów padaczkowych. Zadaniem systemu diagnostycznego jest wskazanie czy międzynapadowy zapis EEG reprezentuje epilepsję czy nie. Poza tym, ważnym zagadnieniem jest podanie czasu wystąpienia napadu oraz czas jego trwania.**


## **1.2 Przegląd proponowanego rozwiązania - cel i teza pracy**

W pracy przedstawiono nowe podejście do procesu wykrywania napadów padaczkowych z użyciem najnowszych rozwiązań algorytmicznych, jakim jest uczenie głębokie [1, 4, 5, 7, 8]. Na podstawie otrzymanych rezultatów z zaimplementowanych metod wykazano, iż redukcja danych ma ogromny wpływ na otrzymywane wyniki, a zastosowanie i dobór odpowiednich metod w kluczowy sposób wpływa na jakość generowanych cech charakterystycznych sygnału EEG na potrzeby późniejszej klasyfikacji. Należy zaznaczyć, iż


a)




b)



c)



d)



**Rysunek 1:** Przykłady zapisów EEG: napady padaczkopodobne a), b) i przypadki zdrowe c), d).

przeprowadzone eksperymenty przebiegały dwuetapowo: (i) projektowanie systemu z wykorzystaniem próbek uprzednio zgromadzonych w postaci bazy danych w trybie off-line, (ii) weryfikacja zaprojektowanego systemu na zasadzie analizy całego zapisu EEG w try-

bie on-line. Uzyskane wyniki potwierdzają tezę, że zaproponowany system wykorzystujący uczenie głębokie charakteryzuje się dużo lepszą jakością rozpoznawania niż inne metody. Na przykład metoda wykorzystująca odchylenie standardowe dała wyniki specyficzności z przedziału od 58,71% do 92,18%, ale tylko w przypadku jednej osoby uzyskano wynik większy od 90%. Stwierdzono również, iż analiza sygnału EEG wykonywana w trybie on-line daje gorsze rezultaty od metod działających w trybie off-line biorąc pod uwagę wskaźnik specyficzności. Z tego względu należało szukać lepszych rozwiązań zarówno na etapie budowy klasyfikatorów jak i samej klasyfikacji.

Na tej podstawie oraz dzięki osiągniętych wstępnym wynikom sformułowano tezę:

**Wykorzystanie technik sztucznej inteligencji umożliwi zbudowanie wydajnego systemu wykrywania krótkotrwałych napadów padaczkowych, który znacząco polepszy jakość stawianych diagnoz w stosunku do istniejących metod**

W celu wykazania tak postawionej tezy w pracy rozważano i rozwiązano następujące zadania i problemy:

- zbudowanie bazy danych zawierającej rzeczywiste zapisy EEG opisujące stany normalne jak i padaczkowe przeanalizowane przez lekarzy specjalistów z zakresu neurologii,
- przeprowadzenie analizy statystycznej w zakresie wykrywania krótkotrwałych napadów padaczkowych,
- wyznaczanie cech charakterystycznych EEG na potrzeby klasyfikacji,
- klasyfikacja napadów padaczkowych,
- opracowanie systemu wykrywania napadów padaczkowych z zastosowaniem głębokich sieci neuronowych,
- wykrywanie napadów padaczkowych w trybie on-line.

## **2 Badane metody**

### **2.1 Metody statystyczne**

W rozprawie przetestowano metody oparte o analizę odchylenia standardowego sygnału, sumę skumulowaną, metody wykorzystujące entropię przybliżoną oraz metodę sprawdzającą regularność przebiegu.

Jedną z testowanych metod była analiza zmian odchylenia standardowego w każdym badanym kanale sygnału EEG. Przeprowadzone eksperymenty nie przyniosły zadowalających rezultatów. W przypadku niektórych pacjentów metoda nie zlokalizowała żadnego napadu padaczkowego.

System oparty na metodzie CUSUM (*ang.* cumulative sum) wykazał się lepszą czułością i wskazał aż 33 pacjentów ze 100%-tą trafnością wskazań, a dla 40 pacjentów system wykrył co najmniej połowę miejsc napadów epileptycznych. Pomimo dość dobrych rezultatów system nadal wskazywał duży procent fałszywych alarmów, co świadczy o jego niedoskonałości.

W rozprawie podjęto również próbę zastosowania bardziej skomplikowanych metod. Jedną z nich była metoda oparta na entropii przybliżonej, która w sekwencji czasowej wykrywa wzorzec określający napad epileptyczny. Niestety pomimo analizy trendu zmian entropii eksperymenty nie przyniosły oczekiwanych rezultatów.

Metoda PRMS (*ang.* pattern match regularity statistics) umożliwia porównywanie wzorców względem wartości jak również trendu zmian. Niestety zaobserwowano podobne problemy jak w przypadku metody entropii przybliżonej. Metoda PRMS również nie przynosi zadowalających rezultatów dla sekwencji krótszych niż 1s.

## 2.2 Metody częstotliwościowe

W rozprawie sprawdzono również metody umożliwiające przedstawienie zapisów EEG w dziedzinie czas-częstotliwość i na tej podstawie wydobycie cech charakterystycznych. Testowano takie metody jak: Dyskretna Transformata Falkowa (*ang.* Discrete Wavelet Transform, DWT), Poszukiwanie dopasowujące (*ang.* Matching Pursuit, MP), czy transformata Stockwella (*ang.* Stockwell Transform, ST). Analizując wyniki można stwierdzić, że transformata Stockwella najlepiej różnicuje stany padaczkowe i stany niepadaczkowe niż inne dotychczas badane metody. Jednakże, analizowane zapisy EEG składały się z 16 kanałów i każdy z nich był poddawany transformacji czas-częstotliwość, co w rezultacie doprowadziło do uzyskania 16-tu dwuwymiarowych obrazów. Takie rozwiązanie nie jest dobre ze względu na wymuszenie podania na wejście klasyfikatora obrazów o bardzo dużym rozmiarze. Dlatego na podstawie uzyskanej reprezentacji wyznaczono zestawy atrybutów w postaci:

- podstawowych parametrów statystycznych - (wartość średnią, odchylenie standardowe, mediana, dominanta),
- energii składowych częstotliwościowych,
- entropii składowych częstotliwościowych.

Uzyskany zestaw atrybutów był następnie poddawany klasyfikacji. Należy jednak podkreślić, że metody częstotliwościowe są dość złożone obliczeniowo i możliwości realizacji systemu przetwarzającego takie dane w czasie rzeczywistym są raczej ograniczone.

## 2.3 Klasyfikatory

W rozprawie przetestowano również popularne klasyfikatory, takie jak naiwny klasyfikator Bayesa, liniowy dyskryminator Fishera, klasyfikator  $k$  najbliższych sąsiadów, maszynę wektorów nośnych oraz perceptron wielowarstwowy. Klasyfikacja odbywała się na podstawie atrybutów wyznaczanych przy zastosowaniu metod opisanych w poprzednim podrozdziale. Najlepsze rezultaty otrzymano dla sieci wielowarstwowej jednokierunkowej przy zastosowaniu atrybutów w postaci entropii składowych częstotliwościowych wyznaczonych za pomocą transformaty Stockwella. Całkowita jakość klasyfikacji kształtowała się na poziomie  $acc=99,1\%$ . Również pozostałe wskaźniki osiągnęły wysoki poziom: czułość klasyfikacji  $tpr=99,7\%$  i specyficzność klasyfikacji  $tnr=98,6\%$ . Badano również proces klasyfikacji dokonywanej w trybie on-line analizując cały zapis EEG wykonany dla danego pacjenta. Proponowany klasyfikator neuronowy, w trybie on-line uzyskał poziom pełnej wykrywalności napadów padaczkowych dla wszystkich 104 przypadków ( $tpr = 100\%$ ). Pomimo tak dobrych rezultatów w procesie wykrywalności napadów epileptycznych stwierdzono, iż równocześnie wskaźnik specyficzności dla wielu przypadków osiągał bardzo niskie wartości poniżej 13%. Świadczy to o niskiej rozpoznawalności fragmentów zapisu EEG dla pacjentów, u których zdiagnozowano padaczkę, odpowiadającym jednakże stanowi normalnemu.

## 3 Zastosowanie uczenia głębokiego

Podsumowując dotychczasowe analizowane metody stwierdzono, iż analiza sygnału EEG wykonywana w trybie on-line daje gorsze rezultaty od metod działających w trybie off-line w zakresie wskaźnika specyficzności. Z tego względu należało poszukiwać lepszych rozwiązań. Dlatego zdecydowano się sięgnąć po bardziej zaawansowane techniki sztucznej inteligencji, a mianowicie po uczenie głębokie i sieci neuronowe typu LSTM (ang. Long Short-Term Memory). Sieć LSTM to model neuronowy posiadający pamięć krótkoterminową, która utrzymuje się przez długi czas, co stanowić może najlepsze dotychczasowo znalezione rozwiązanie dla analizowanych zapisów EEG.

Głęboka sieć LSTM składa się z wielu warstw zawierających elementy LSTM. Poza tym zawiera dodatkowe warstwy znane z innych struktur sieci głębokich takie jak warstwa softmax, czy warstwa klasyfikacyjna. Ogólną strukturę głębokiej sieci LSTM

zaprezentowano na rys. 2. **Warstwy LSTM** przetwarzają sekwencje wejściowe wydobywając i zapamiętując długookresowe zależności między próbkami w wejściowej sekwencji czasowej. Tak wydobyte dane przekazywane są do **warstwy softmax**, która przypisuje prawdopodobieństwo z przedziału (0;1) określające przyporządkowanie danej sekwencji czasowej do każdej z rozważanych klas. Co oczywiste, suma prawdopodobieństw przyporządkowanych każdej klasie musi być równa 1. Warstwa ta posiada tyle samo jednostek przetwarzających co warstwa wyjściowa. Operację wykonywaną przez tę warstwę można przedstawić w następujący sposób:


$$P(y = j|x) = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}}, \quad j = 1, \dots, K \quad (1)$$

gdzie  $j$  jest indeksem klasy,  $K$  jest liczbą klas,  $x$  jest wejściem warstwy softmax [2]. Warstwa softmax jest połączona z  $n$ -tą warstwą LSTM w sposób zupełny przy użyciu klasycznej **warstwy połączeń pełnych** (*ang.* fully-connected). Wreszcie, **warstwa klasyfikacyjna** pobiera odpowiedzi generowane przez warstwę softmax i przypisuje każde wejście do jednej z  $K$  wzajemnie wykluczających się klas przy użyciu funkcji entropii krzyżowej definiowanej jako:

$$loss = - \sum_{i=1}^N \sum_{j=1}^K t_{ij} \ln(y_{ij}), \quad (2)$$

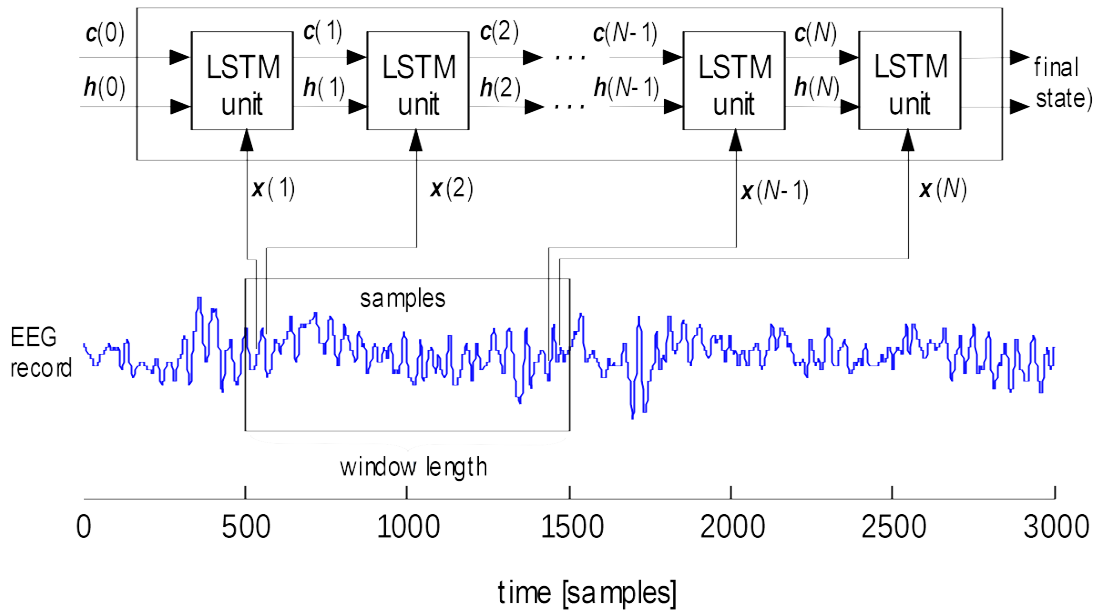
gdzie  $N$  oznacza liczbę próbek,  $t_{ij}$  jest wskaźnikiem, że próbka  $i$ -ta należy do klasy  $j$ -tej, a  $y_{ij}$  jest wyjściem jednostki softmax.

Idea przetwarzania wejściowej sekwencji czasowej przez warstwę LSTM została zaprezentowana na rys. 3. Z zapisu EEG, za pomocą przesuwającego okna o ustalonej długości pobiera się sekwencję czasową do dalszego przetwarzania. Pierwsza warstwa sieci LSTM zawiera tyle komórek LSTM z ilu próbek składa się obrabiana sekwencja czasowa. Zaś każda komórka LSTM zawiera  $D$  jednostek przetwarzających. Każda komórka LSTM pobudza następną przy użyciu sygnałów stanu komórki  $\mathbf{c}(k)$  i sygnału wyjściowego komórki  $\mathbf{h}(k)$ . Dzięki temu cała warstwa LSTM jest w stanie wydobyć zależności czasowe pomiędzy kolejnymi próbkami przetwarzanej sekwencji czasowej. Wyjścia poszczególnych



**Rysunek 2:** Głęboka sieć neuronowa typu LSTM





**Rysunek 3:** Idea klasyfikacji sekwencji czasowych przy użyciu sieci LSTM

komórek LSTM są umieszczane w macierzy stanowiącej pobudzenie kolejnej warstwy LSTM. Macierz ta ma rozmiar  $D \times N$ , gdzie  $N$  oznacza długość przetwarzanej sekwencji, zaś  $D$  oznacza liczbę jednostek ukrytych. Kolejna warstwa LSTM z reguły zawiera mniejszą liczbę jednostek ukrytych. Wydobyte zależności czasowych pomiędzy kolejnymi próbkami sekwencji czasowej przetwarzane są przez kolejne warstwy zgodnie ze schematem zaprezentowanym na rys. 2.

W rozprawie zaprezentowano eksperymentalnie dwa rozwiązania klasyfikacyjne typu sekwencja-sekwencja oraz sekwencja-etykieta.

W przypadku modeli klasyfikacyjnych typu sekwencja-sekwencja dokonano eksperymentalnego doboru optymalnej konfiguracji sieci LSTM (tabela 1), która została zastosowana do realizacji klasyfikacji w postaci mapowania sekwencji wejściowej do wzorcowej sekwencji wyjściowej. W celu oceny jakości klasyfikacji zaproponowano trzy kryteria opierające swoje działanie na odpowiednim ustawieniu progu decyzyjnego na współczynnikach czułości ( $tpr$ ), specyficzności ( $tnr$ ) oraz wskaźniku całkowitej klasyfikacji ( $acc$ ):

**kryterium 1:** sekwencję uznaje się za zaklasyfikowaną jako napad “padaczkowy prawidłowo” jeżeli oba wskaźniki  $tpr$  i  $tnr$  uzyskają jednocześnie wartości większe niż 50%,

**kryterium 2:** sekwencję uznaje się za zaklasyfikowaną jako “stan normalny” jeżeli wskaźnik  $tnr$  uzyska wartość większą niż 50%,

**kryterium 3:** sekwencję uznaje się za zaklasyfikowaną prawidłowo jeżeli wartość wskaźnika  $acc$  jest nie mniejsza niż 85%.

**Tabela 1:** Wybrane struktury LSTM

sieć	liczba węzłów LSTM					funkcja aktywacji		
	1 warstwa	2 warstwa	3 warstwa	4 warstwa	5 warstwa	$\sigma_c$	$\sigma_s$	$\sigma_h$
net2	60	–	–	–	–	tangens hiperboliczny	sigmoida	liniowa
net3	100	–	–	–	–	tangens hiperboliczny	sigmoida	liniowa
net5	60	50	–	–	–	tangens hiperboliczny	sigmoida	liniowa
net9	100	70	30	–	–	tangens hiperboliczny	sigmoida	liniowa
net11	60	50	40	20	–	tangens hiperboliczny	sigmoida	liniowa
net12	70	70	70	70	–	tangens hiperboliczny	sigmoida	liniowa

**Tabela 2:** Wyniki wykrywania napadów dla LSTM sekwencja–sekwencja

sieć	kryterium 1		kryterium 2		kryterium 3	
	najlepszy [%]	średnio [%]	najlepszy [%]	średnio [%]	najlepszy [%]	średnio [%]
net 2	69,4	67,8	<b>81,9</b>	81,4	77,6	76,7
net 3	66,0	64,9	<b>81,9</b>	<b>81,7</b>	77,3	76,5
net 5	88,1	81,8	80,6	79,7	86,4	82,9
net 9	96,6	92,3	79,1	77,9	94,6	89,3
net 11	98,8	96,4	79,2	77,1	<b>96,0</b>	<b>94,8</b>
net 12	98,6	96,0	78,4	76,2	<b>96,0</b>	93,4

Po przeprowadzeniu szeregu eksperymentów stwierdzono, iż za pomocą głębokiej sieci LSTM jest możliwe osiągnięcie skuteczności detekcji napadów epileptycznych nawet na poziomie 99% (tabela 2). Najlepsze rezultaty detekcji osiągnięto dla sieci złożonej z 5 warstw ukrytych. Dla porównania przy czterech warstwach ukrytych uzyskano wynik 73,6%, co świadczy o tym, iż ilość warstw ma znaczący wpływ na uzyskanie wysoko jakościowych rezultatów. Zaobserwowano, że zwiększanie liczby neuronów w sieciach z małą liczbą warstw ukrytych nie polepsza znacząco jakości klasyfikacji (pomiędzy 64,8% a 73,6%). Podczas analizy przypadków zdrowych za pomocą kryterium 2 najlepszy rezultat rzędu 81,9% osiągnięto dla najprostszego modelu sieci **net 3**. Wzrost liczby neuronów oraz liczb warstw sieci spowodował jedynie stopniowe zmniejszanie się jakości klasyfikacji. Natomiast w przypadku kryterium 3 wskaźniki całkowitej klasyfikacji podobnie jak w przypadku kryterium 1, osiągały bardzo dobre rezultaty.

W przypadku modelu klasyfikacyjnego typu sekwencja–etykieta również badano różne topologie sieci neuronowej (tabela 3). Najlepsze uśrednione wskaźniki czułości i całkowitej dokładności uzyskał model **net 5** (tabela 4). Co do wskaźnika uśrednionej specyficzności, najlepsze wyniki zaobserwowano dla modelu **net 10**, jednak różnice między modelami nie są znaczące. Z kolei analizując wyniki uzyskane dla najlepiej działających sieci, największe wartości wskaźników *tpr* i *acc* są widoczne dla modelu **net 7**. Ponownie najlepszą wartość indeksu *tnr* uzyskano dla modelu struktury **net 10**. Ponieważ głównym celem jest wykrycie napadów padaczkowych, model **net 7** został wybrany do dalszych eksperymentów.

Opracowane klasyfikatory zastosowano również w trybie on-line do analizy całego

**Tabela 3:** Wybrane sieci LSTM dla modelu sekwencja-etykieta

sieć	liczba węzłów			
	1 warstwa	2 warstwa	3 warstwa	4 warstwa
sieć 3	50	100	–	–
sieć 5	10	30	50	–
sieć 6	50	30	10	–
sieć 7	50	50	50	–
sieć 10	50	50	50	50
sieć 11	70	60	50	50

**Tabela 4:** Wyniki wykrywania napadów dla LSTC sekwencja-etykieta

sieć	$t\bar{p}r$ [%]	$t\bar{n}r$ [%]	$a\bar{c}c$ [%]	$tpr_{best}$ [%]	$tnr_{best}$ [%]	$acc_{best}$ [%]
sieć 3	71.6	92.3	86.7	76.2	93.6	88.2
sieć 5	<b>76.0</b>	92.8	<b>88.3</b>	79.6	94.1	89.3
sieć 6	74.5	92.7	87.8	76.2	94.3	89.2
sieć 7	74.1	93.0	87.9	<b>79.8</b>	94.0	<b>89.8</b>
sieć 10	74.2	<b>93.3</b>	88.2	78.4	<b>95.1</b>	89.4
sieć 11	75.0	92.5	87.8	79.4	93.3	88.9

rekordu EEG dla każdego pacjenta z osobna. Dla modelu klasyfikacyjnego sekwencja-etykieta w każdym analizowanym przypadku zdiagnozowano padaczkę, osiągając indeks  $tpr$  o wartościach z przedziału od 20% do 100%. W przypadku 33 pacjentów system wykrył wszystkie napady wskazane przez neurologa. Z kolei indeks specyficzności przyjął wartości od 27,7% do 100%. Oznacza to, że w niektórych przypadkach system wygenerował dużą liczbę fałszywych alarmów o napadach, których faktycznie nie było. Ogólna dokładność oscylowała w przedziale od 28,2% do 99,9%. Porównując te rezultaty z wynikami osiągniętymi dla modelu klasyfikacyjnego sekwencja-sekwencja można wyraźnie stwierdzić, że ten drugi model działa znacznie lepiej niż model sekwencja-etykieta. Wyniki uzyskane na grupie osób zdrowych były bardzo dobre. Całkowita dokładność osiągnęła wartości z przedziału [68%, 100%]. W przypadku 66 badanych uzyskano wynik ponad 90%. Porównując uzyskane rezultaty z wynikami uzyskanymi dla modelu sekwencja-sekwencja można wyciągnąć wniosek, że model sekwencja-etykieta działa znacznie lepiej niż model sekwencja-sekwencja.

Po przeprowadzonej analizie wszystkich osiągniętych rezultatów zarówno dla przypadków epileptycznych jak i zdrowych, można stwierdzić, że zaprezentowane oba podejścia działają całkiem dobrze. Jednak proponowany model sekwencja-sekwencja przewyższa model sekwencja-etykieta w przypadku zadań związanych z wykrywaniem napadów epileptycznych dla przypadków chorych. Z kolei model sekwencja-etykieta działa znacznie lepiej do klasyfikowania zdrowych przypadków.

Osiągnięte rezultaty świadczą o zasadności zastosowania uczenia głębokiego z użyciem sieci LSTM do analizy i klasyfikacji danych biomedycznych. Poprawność wykrywalności

proponowanego systemu osiągnęła bardzo wysokie rezultaty zarówno w rozpoznawaniu przypadków chorych jak i zdrowych. Udowodniono tym samym, iż zastosowanie tego typu rozwiązań może mieć wpływ na poprawność stawianych diagnoz przez specjalistów neurologii oraz może stanowić w przyszłości alternatywę jako narzędzie wspomagające diagnostykę kliniczną.

## 4 Oryginalne osiągnięcia

Do oryginalnych rozwiązań osiągniętych podczas realizacji pracy doktorskiej można zaliczyć:

- zbudowanie elektronicznej bazy danych zapisów EEG zgromadzonej dzięki współpracy z pracownikami Oddziału Neurologii i Udarów Szpitala Wojewódzkiego w Zielonej Górze (obecnie Klinicznego Oddziału Neurologii Uniwersyteckiego Szpitala w Zielonej Górze). Zarejestrowane zapisy pacjentów poddane zostały konwersji ze standardu EDF do plików MAT. Oryginalne zapisy EEG zostały zarejestrowane z częstotliwością próbkowania 500 Hz. Zapisów dokonano w latach 2010–2012 podczas rutynowego badania EEG. Dla każdego pacjenta do bazy danych wprowadzono orzeczenie specjalisty neurologa. Oryginalne orzeczenia były dostępne w wersji papierowej;
- wykonanie analizy statystycznej zapisów EEG pod kątem jakości wykrywania napadów padaczkowych. Przeanalizowano metody wykorzystujące: odchylenie standardowe sygnału, sumę skumulowaną, entropię przybliżoną oraz metodę sprawdzającą regularność sygnału;
- zastosowanie metody PCA do redukcji ilości kanałów pomiarowych sygnału EEG w celu ograniczenia rozmiaru przetwarzanych danych;
- zastosowanie metod analizy czasowo-częstotliwościowej do przetworzenia danych surowych i wskazania cech charakterystycznych obrazów EEG. Przebadano krótko-czasową transformatę Fouriera, dyskretną transformatę falkową, metodę Matching-Pursuit oraz transformatę Stockwella. W szczególności transformata Stockwella była nowym podejściem do analizy sygnałów EEG w dziedzinie częstotliwości;
- zastosowanie klasyfikatorów klasycznych (naiwny klasyfikator Bayesa, klasyfikator kNN oraz liniowa dyskryminacja Fishera) oraz klasyfikatorów wykorzystujących sieci neuronowe (SVM oraz perceptron wielowarstwowy) do klasyfikacji krótkotrwałych napadów padaczkowych;

- zrealizowanie systemu detekcji napadów padaczkowych za pomocą głębokich sieci LSTM. Sieci uczone były w trybie off-line za pomocą wzorów pobieranych w zbudowanej na potrzeby dysertacji bazy danych, natomiast jakość klasyfikacji dokonywana była w trybie on-line za pomocą okna przesuwającego. Opracowano dwa typy systemu klasyfikacyjnego: typu sekwencja–sekwencja i sekwencja–etykieta.

## 4.1 Publikacje autorskie i współautorskie

- artykuły w czasopismach
  1. Wyznaczanie atrybutów sygnału EEG w oparciu o transformację Stockwella / Grzegorz Rutkowski, Krzysztof Patan, 2013. *Pomiary, Automatyka, Kontrola* Vol. 59, nr 3, 208-211, (pkt: 7),
  2. Porównanie i ocena metod klasyfikacji sygnałów EEG / Grzegorz Rutkowski, Krzysztof Patan, 2012. *Pomiary, Automatyka, Kontrola* Vol. 58, nr 4, 97-100 (pkt: 7),
  3. Sztuczne sieci neuronowe w interpretacji i analizie sygnałów biomedycznych EEG. Przegląd metod / Grzegorz Rutkowski, Krzysztof Patan, 2011. *Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska*, nr 2, 28-33 (pkt: 2),
- rozdziały w monografiach zwartych
  1. Application of Deep Learning to Seizure Classification, Krzysztof Patan, Grzegorz Rutkowski // W: *Advances in Diagnostics of Processes and Systems: Selected Papers from the 14th International Conference on Diagnostics of Processes and Systems (DPS), September 21-23, 2020, Zielona Góra (Poland), 2021.* / ed. J. Korbicz, K. Patan, M. Luzar, Cham : Springer International Publishing, s. 157-172, (pkt: 20),
  2. Detection of Epileptic Seizures via Deep Long Short-Term Memory, Krzysztof Patan, Grzegorz Rutkowski // W: *Current Trends in Biomedical Engineering and Bioimages Analysis: proceedings of the 21st Polish Conference on Biocybernetics and Biomedical Engineering - PCBEE 2019, 2020.* / eds. J. Korbicz, R. Maniewski, K. Patan, M. Kowal, Cham: Springer Nature Switzerland, s. 166-178 (pkt: 20),
  3. Analysis of EEG signals for the purpose of clinical diagnosis based on epileptic seizures, Grzegorz Rutkowski // W: *Technical notes on engineering applications and challenges*, 2017. / ed. Paweł Majdzik, Zielona Góra: Oficyna Wydawnicza Uniwersytetu Zielonogórskiego, s. 83–92, (pkt: 20)

4. Analiza sygnałów EEG za pomocą sztucznych sieci neuronowych, Krzysztof Patan, Grzegorz Rutkowski // W: Sieci neuronowe w inżynierii biomedycznej, 2013. / red. R. Tadeusiewicz, J. Korbicz, L. Rutkowski, W. Duch . T. 9, Warszawa: Akademicka Oficyna Wydaw. EXIT (Inżynieria Biomedyczna. Podstawy i Zastosowania), s. 281–303, (pkt: 5),
- artykuły w materiałach konferencji międzynarodowych i krajowych:
    1. Application of deep learning to seizure classification, 2020. Krzysztof Patan, Grzegorz Rutkowski // W: 14th International Conference on Diagnostics of Processes and Systems - DPS : abstract book. Zielona Góra, Polska Zielona Góra, 2020, s. 39,
    2. Computer aided on-line seizure detection using stockwell transform, 2013. Grzegorz Rutkowski, Krzysztof Patan, Paweł Leśniak // W: 11th International Conference on Diagnostics of Processes and Systems - DPS 2013. Łągów Lubuski, Polska Berlin Heidelberg (pkt: 15),
    3. Computer-aided off-line diagnosis of epileptic seizures, 2014. Grzegorz Rutkowski, Krzysztof Patan // W: 13th International Conference on Artificial Intelligence and Soft Computing - ICAISC 2014. Zakopane, Polska Cham : Springer International Publishing Switzerland, 2014, Vol. 2, s. 187-194 (pkt: 15),
    4. Comparison of Time-Frequency Feature Extraction Methods for EEG Signals Classification, 2013. Grzegorz Rutkowski, Krzysztof Patan, Paweł Leśniak // W: Artificial intelligence and soft computing : part 2 : 12th international conference : ICAISC 2013. Zakopane, Polska Berlin : Springer - Verlag, 2013, Lecture Notes in Computer Science, Vol. 7895, s. 320-329 (pkt: 15),
    5. Selected methods of biomedical signal analysis based on EEG records for cases of epileptic seizures, 2013. Grzegorz Rutkowski // W: XV International PHD Workshop - OWD 2013. Wisła, Polska [Gliwice] : Organising Committee of the Symposium PPEE Seminar BSE, 2013, Conference Archives PTETIS; Vol. 33, 2013, s. 452-455,
    6. Wyznaczanie atrybutów sygnału EEG w oparciu o transformację Stockwella, 2013. Grzegorz Rutkowski, Krzysztof Patan // W: Modelowanie i pomiary w medycynie - MPM 2013 : XII sympozjum : streszczenia referatów. Krynica-Zdrój, Polska Kraków, 2013, s. 45-46,
    7. Analysis and classification of EEG data : an evaluation of methods, 2012. Krzysztof Patan, Grzegorz Rutkowski // W: 11th International Conference on

- Artificial Intelligence and Soft Computing - ICAISC. Zakopane, Polska, 2012, Lecture Notes in Artificial Intelligence, Vol. 7268, s. 310-317 (pkt: 15),
8. Porównanie i ocena metod klasyfikacji sygnałów EEG, 2012. Grzegorz Rutkowski, Krzysztof Patan // W: Modelowanie i pomiary w medycynie - MPM 2012 : XI sympozjum : streszczenia referatów. Krynica-Zdrój, Polska Kraków, 2012, s. 69-70,
  9. Artificial neural networks in the classification of EEG signals, 2011. Grzegorz Rutkowski // W: XIII International PHD Workshop - OWD 2011. Wisła, Polska, Gliwice, 2011, Conference Archives PTETIS; Vol. 29, 2011, s. 291-294,
  10. Sztuczne sieci neuronowe w interpretacji i analizie sygnałów biomedycznych EEG. Przegląd metod, 2011. Grzegorz Rutkowski, Krzysztof Patan // W: Modelowanie i Pomiary w Medycynie - MPM 2011 : materiały X jubileuszowego sympozjum. Krynica, Polska Kraków: Wydaw. Katedry Metrologii AGH, 2011, s. 121-127.

## 4.2 Granty badawcze

Doktorant brał udział w 3 projektach w ramach dotacji dla młodych naukowców oraz uczestników studiów doktoranckich na Wydziale Informatyki, Elektrotechniki i Automatyki Uniwersytetu Zielonogórskiego: Tematy realizowanych projektów to:

- Analiza i klasyfikacja sygnałów EEG (diagnostyka, rozpoznawanie wzorców), metody SSN – zastosowania, 2011 r.
- Zautomatyzowany system rozpoznawania jednostek chorobowych na podstawie sekwencji EEG, 2012 r.
- Realizacja systemu wspomaganie decyzji rozpoznawania zaburzeń neurologicznych w trybie on-line na podstawie sekwencji EEG, 2013 r.

## Literatura

- [1] H. Anila Glory. Ahw-bgoa-dnn: a novel deep learning model for epileptic seizure detection. *Neural Computing and Applications*, 10, 2020.
- [2] Ch. M. Bishop. *Pattern recognition and machine learning*. Springer, Cambridge, 2006.
- [3] Raport Komisji Polskiego Towarzystwa Epileptologii. Standardy diagnostyki i leczenia chorych z padaczką w polsce. *Epileptologia 2002*, 10:109–130, 2002.
- [4] A. Gramacki, K. Dzięziola, and J. Gramacki. Detection of epileptic seizures in EEG signals using deep learning techniques. In *21st Polish Conference on Biocybernetics and Biomedical Engineering : abstract book; ISBN: 9788388317163*, page 88, Polska, 2019. Zielona Góra, Lubuskie Towarzystwo Naukowe.
- [5] K. Patan and G. Rutkowski. Detection of epileptic seizures via deep Long Short-Term Memory. In K. Patan M. Kowal J. Korbicz, R. Maniewski, editor, *Current Trends in Biomedical Engineering and Bioimages Analysis : proceedings of the 21st Polish Conference on Biocybernetics and Biomedical Engineering - PCBEE 2019, Advances in Intelligent Systems and Computing : Vol. 1033*, pages 166–178, Cham, 2019. Springer Nature Switzerland.
- [6] K. Rejdak, R. Rola, M. Mazurkiewicz-Bełdzińska, I. Halczuk, B. Błaszczuk, A. Rysz, and D. Ryglewicz. Diagnostyka i leczenie padaczki u osób dorosłych - rekomendacje Polskiego Towarzystwa Neurologicznego. *Polski Przegląd Neurologiczny*, 12(1):15-27, 2016.
- [7] A. Sharmila. Epilepsy detection from EEG signals, a review. *Journal of Medical Engineering Technology*, 42(5):368–380, 2018.
- [8] A. Shoeibi. Epileptic seizure detection using deep learning techniques: A review 2014-2020. *arXiv:01276*.
- [9] Dudek F. E. Staley, K. J. Interictal spikes and epileptogenesis. *Epilepsy Curr.*, 6(6):199-202, 2006.