

**POLITECHNIKA ŁÓDZKA**  
Wydział Elektrotechniki, Elektroniki,  
Informatyki i Automatyki

Rozprawa doktorska – streszczenie

**Analiza i implementacja metod sztucznej inteligencji  
przy niepełnej informacji medycznej na przykładzie  
oceny ryzyka chorób kardiologicznych**

mgr inż. Paweł Marciniak

Nr albumu: 161504

Promotor:

**Prof. dr hab. inż. Zygmunt Ciota**

Łódź, 2014

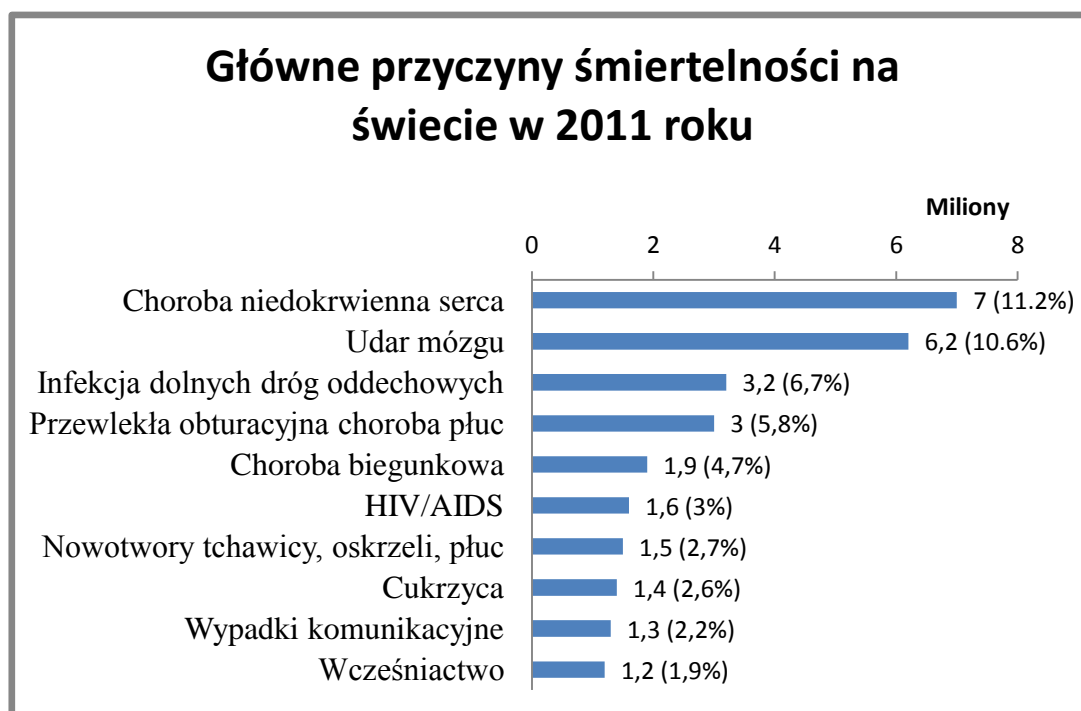
# Spis treści

<b>SPIS TREŚCI .....</b>	<b>1</b>
<b>1. WSTĘP.....</b>	<b>2</b>
<b>2. OBECNIE STOSOWANE SYSTEMY DO OCENY STANU OGÓLNEGO PACJENTA ....</b>	<b>7</b>
2.1. MODIFIED EARLY WARNING SCORE (MEWS) .....	7
2.2. APACHE III .....	7
2.3. THERAPEUTIC INTERVENTION SCORING SYSTEM .....	7
<b>3. METODY SZTUCZNEJ INTELIGENCJI.....</b>	<b>9</b>
3.1. SZTUCZNE SIECI NEURONOWE .....	9
3.2. SIECI BAYESOWSKIE .....	10
3.3. DRZEWA DECYZYJNE .....	11
<b>4. METODYKA BADAŃ.....</b>	<b>12</b>
4.1. MOTYWACJA .....	12
4.2. APLIKACJA TESTOWANIA ALGORYTMÓW.....	14
4.3. REDUKCJA WYMIAROWOŚCI DANYCH.....	17
4.4. ADAPTACJA DANYCH MEDYCZNYCH .....	18
4.5. REDUKCJA PARAMETRÓW MEDYCZNYCH .....	20
4.6. SIEĆ NEURONOWA PO REDUKCJI .....	21
<b>5. UWAGI I WNIOSKI KOŃCOWE.....</b>	<b>25</b>
<b>6. BIBLIOGRAFIA.....</b>	<b>27</b>

## 1. Wstęp

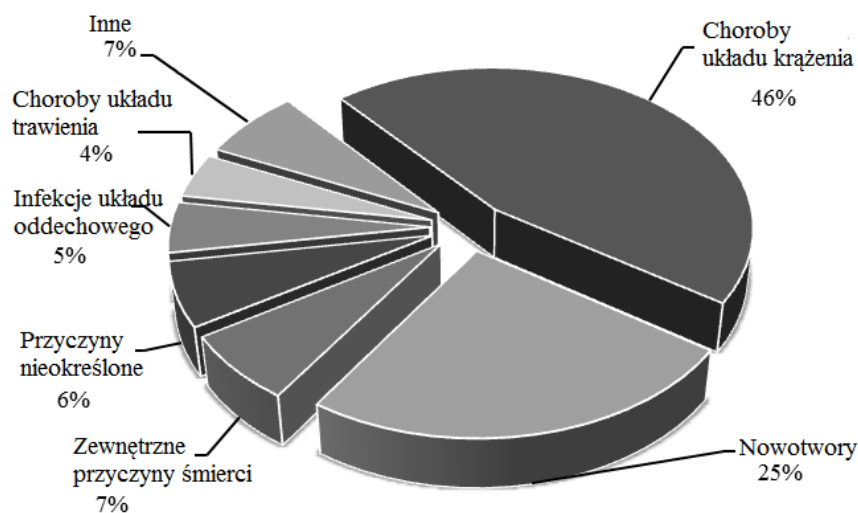
Choroby układu krążenia są najczęstszą przyczyną hospitalizacji (16% w grupie 6 400 000 pacjentów hospitalizowanych w 2006 roku) i stanowią największy odsetek zgonów (46% ogółu zgonów w 2006 roku) w Polsce [18][19]. Bezpośrednią przyczyną śmiertelności szpitalnej jest w głównej mierze nagłe zatrzymanie krążenia (NZK). Choroby układu krążenia są znacznie częstszą przyczyną przedwczesnych zgonów wśród mieszkańców Polski niż przeciętnie w Unii Europejskiej i w ostatnich latach w Polsce spadek przedwczesnej umieralności z ich powodu uległ niestety spowolnieniu. Pomimo że odsetek zgonów w Unii Europejskiej jest niższy niż w Polsce (około 40% wszystkich zgonów), szacuje się, że związane z tą grupą chorób obciążenie finansowe dla systemów opieki zdrowotnej UE wynosiło w 2006 roku nieco poniżej 110 mld euro. Oznacza to roczny koszt 223 euro na jednego mieszkańca, czyli około 10 procent całkowitych wydatków na opiekę zdrowotną w UE. Choroby układu krążenia, jako jedne z najczęstszych chorób przewlekłych, mają negatywne skutki dla rynku pracy i są silnie powiązane z warunkami społecznymi.

Dane dotyczące śmiertelności na świecie wyglądają podobnie. Badania przeprowadzone w 2011 roku przez Światową Organizację Zdrowia (ang. World Health Organization) również ukazują choroby serca jako główną przyczynę zgonów na świecie.



Rysunek 1.1 Przyczyny śmiertelności na świecie w 2011 roku według Światowej Organizacji Zdrowia

Wprowadzenie standardów resuscytacji i postęp w technikach monitorowania funkcji życiowych nie rozwiązały wszystkich problemów związanych z ryzykiem nagłego zatrzymaniem krążenia u chorych leczonych w szpitalach. Według danych ze szpitali brytyjskich w wyniku resuscytacji udaje się przywrócić funkcje życiowe u 43% pacjentów z NZK, ale jedynie 30% przeżywa następne 24 godziny. Do czasu wypisania ze szpitala przeżywa jedynie 22% chorych [1].



Rysunek 1.2 Przyczyny śmierci w Polsce w 2006 roku

Poziom zdrowia ludności analizuje się przede wszystkim na podstawie wyników badań medycznych. Ma on silny wpływ na wszystkie dziedziny naszego życia. Za jeden z najważniejszych aspektów mających na celu poprawienie poziomu zdrowia uważa się poprawną interpretację danych medycznych i zaproponowanie prawidłowej diagnozy. Sytuacje, w których lekarze muszą brać pod uwagę duże ilości danych znacznie utrudniają podejmowanie poprawnych decyzji medycznych. Potrzebne jest w związku z tym narzędzie, które będzie w stanie pomóc im w postawieniu właściwej diagnozy. Do tego celu mogą zostać zastosowane sztuczne sieci neuronowe, które są częścią systemów sztucznej inteligencji.

Systemy wspomaganie diagnostyki medycznej rozwijane są od kilkadziesiąt lat. Różne metody sztucznej inteligencji stosowane są w wielu aplikacjach służących zarówno do rozpoznawania, jak i poprawnej klasyfikacji sygnałów wejściowych. Mając na uwadze dynamiczny ich rozwój, a także dotychczasowe aplikacje tych metod do zagadnień medycznych, celowe wydaje się zastosowanie algorytmów sztucznej inteligencji do analizy ryzyka chorób kardiologicznych.

Biorąc pod uwagę wykazaną na wstępie potrzebę obiektywizacji i automatyzacji oceny stanu pacjenta, co wiąże się z potencjalną możliwością zmniejszenia śmiertelności

wewnątrzszpitalnej, uzasadnione wydają się badania nad algorytmami pozwalającymi na taką ocenę. Dają one bowiem szansę na zbliżenie standardu opieki nad pacjentem do postępowania optymalnego. Do najczęściej wykorzystywanych i najskuteczniejszych metod sztucznej inteligencji należą: sztuczne sieci neuronowe, sieć Bayesa, algorytmy genetyczne [5][6], drzewa decyzyjne, logika rozmyta.

Potwierdzeniem istotności tej tematyki jest przyznanie przez Narodowe Centrum Nauki finansowania projektu pt. „Zautomatyzowany system wieloparametrowej oceny stanu ogólnego pacjenta z pogłębioną analizą funkcji układu oddechowego i układu krążenia”. Wniosek ten uplasował się na czternastym miejscu wśród wszystkich wniosków z panelu dyscypliny „Informatyka i technologie informacyjne” i otrzymał finansowanie. Autor rozprawy brał udział w przygotowaniu i pisaniu wniosku. Prace prowadzone w ramach tego projektu są istotną częścią badań prowadzonych w ramach doktoratu.

Głównym celem tego projektu jest badanie metodyki oceny ogólnego stanu chorego, ryzyka nagłego zatrzymania krążenia (NZK) oraz wspomaganie decyzji dotyczącej dalszego leczenia wykorzystując sztuczne sieci neuronowe. Ich zastosowanie może zmniejszyć ryzyko NZK i śmiertelności szpitalnej. Wyżej wymienione algorytmy działają na podstawie danych zbieranych w czasie rzeczywistym oraz informacji wprowadzonych przez personel medyczny. Omawiany projekt ma na celu przede wszystkim badanie zastosowania sztucznych sieci neuronowych oraz sieci Bayesa w medycynie ze szczególnym uwzględnieniem:

- zaawansowanej analizy zgromadzonych danych oceniających stan pacjenta,
- oceny ryzyka nagłego zatrzymania krążenia,
- sugerowanej metody dalszego leczenia,
- wskazania najbardziej prawdopodobnej przyczyny pogorszenia stanu zdrowia pacjenta.

Najistotniejszym punktem projektu jest rozszerzenie aktualnego stanu wiedzy na temat adaptacji sztucznych sieci neuronowych oraz sieci Bayesa do oceny ogólnego stanu pacjenta i oceny ryzyka NZK. Dane wejściowe pobierane są w trybie rzeczywistym z monitora funkcji życiowych.

Zadaniem sieci neuronowych oraz sieci Bayesa jest bardziej precyzyjna ocena stanu pacjenta na podstawie sygnałów z monitora funkcji, wykrycie sytuacji świadczących o ryzyku NZK, a w szczególności wykrycie cech niestabilności elektrycznej serca, ostrej

niewydolności serca, niewydolności oddechowej, odwodnienia lub przewodnienia, ciężkiej infekcji oraz określenie sugestii co do dalszego postępowania.

Najprostszym podejściem jest tu porównywanie parametrów rejestrowanych przebiegów z pewnymi wartościami progowymi. Podejście takie, z uwagi na odgórnie założone wartości progów, nie uwzględnia jednak specyfiki przebiegu parametrów u poszczególnych pacjentów, nie umożliwia także zaawansowanego wnioskowania na podstawie grupy przesłanek – poszczególne parametry są zwykle rozpatrywane całkowicie oddzielnie, a co najwyżej łączone w sposób nieuwzględniający wagi poszczególnych parametrów, ich korelacji itp.

Ocena stanu ogólnego pacjenta wymaga czasu, wiedzy i doświadczenia, toteż wprowadzenie systemu wspomagania decyzji wydaje się być znaczną pomocą pozwalającą na zaoszczędzenie czasu i obniżenie ryzyka błędu.

Niezbędne badania spirometryczne i echokardiograficzne prowadzone są przez członków zespołu na atestowanym sprzęcie dostępnym w Klinice Pneumonologii i Alergologii z Pododdziałem Kardiologicznym Szpitala Klinicznego Nr 1 Uniwersytetu Medycznego w Łodzi. Do akwizycji danych i testów wykorzystany jest zakupiony przez Katedrę Mikroelektroniki i Technik Informatycznych kardiomonitor. Zakupiony monitor wyprodukowany został przez polską firmę Emtel, która zgodziła się na współpracę w ramach prowadzonych prac poprzez udostępnienie niezbędnych protokołów, jak i wsparcie techniczne przy obsłudze sprzętu. KMiTI uzyskała zgodę komisji bioetycznej przy Uniwersytecie Medycznym w Łodzi na wykonanie badań klinicznych opisanych we wniosku.

Praktyczne zastosowanie urządzenia jako uzupełnienie monitorów funkcji życiowych w jednostkach medycznych daje nadzieję na lepszą kwalifikację do hospitalizacji i zmniejszenie ryzyka popełnienia błędu w ocenie ogólnego stanu pacjenta. Ponadto pozwoli na wczesne wykrycie zagrożenia wystąpienia NZK i w efekcie zmniejszenie śmiertelności szpitalnej. Ważnym efektem będzie też wyznaczenie parametrów krzywej oddechowej mogących mieć znaczenie diagnostyczne i prognostyczne, określenie przedziałów ich wartości normalnych, a także przedstawienie możliwości zastosowania parametrów uzyskanych z krzywej oddechowej i sygnału EKG zamiast kardiografii impedancyjnej.

W czasie trwania studiów doktoranckich autor rozprawy prowadził badania dotyczące cybernetyki [A1], [A2], przetwarzania sygnałów [A4], [A7] oraz metod sztucznej inteligencji

[A6]. Główne prace skupione są nad metodami rejestracji, przetwarzania i analizy sygnałów medycznych, a w szczególności nad dwoma zagadnieniami dotyczącymi sztucznej inteligencji – sieciami neuronowymi [A3] i sieciami bayesowskimi [A5].

## **CEL I TEZY PRACY**

Głównym celem pracy jest opracowanie efektywnych algorytmów metod sztucznej inteligencji dla nowatorskiego systemu monitorującego, wspomagającego w czasie rzeczywistym podejmowanie decyzji medycznych, związanych z oceną stanu ogólnego pacjenta ze szczególnym uwzględnieniem parametrów kardiologicznych. Danymi wejściowymi do systemu (wykonanego w postaci zminiaturyzowanego urządzenia) są wielorakie parametry zbierane przez typowy monitor funkcji życiowych.

Podstawowym zadaniem postawionym przed opisanymi badaniami jest analiza parametrów fizjologicznych pacjenta pozwalająca na zminimalizowanie zbioru danych wejściowych dla algorytmów sztucznej inteligencji przy zachowaniu pierwotnej jakości klasyfikacji oraz zwiększenie jakości klasyfikacji przy zastosowaniu pierwotnej liczby parametrów. Obydwa zagadnienia są istotne z punktu widzenia monitorowania stanu pacjenta w trybie rzeczywistym i możliwe są do zaimplementowania na systemie mikroprocesorowym niewielkiej mocy dołączonym do monitora funkcji życiowych.

Tezy rozprawy zostały sformułowane następująco:

**1. Dekompozycja parametrów jakościowych stanu kardiologicznego pacjenta wraz z usunięciem liniowych zależności wszystkich parametrów umożliwi poprawę skuteczności rozpoznania stanu kardiologicznego przy jednoczesnym zachowaniu tak samo licznego zbioru wejściowego.**

**2. Konstrukcja nowych niezależnych liniowo cech w modelu stratyfikacji ryzyka zgonu umożliwi znaczną redukcję liczby danych wejściowych pacjenta bez utraty użytecznej informacji predykcyjnej i przy zachowaniu jakości klasyfikacji uzyskiwanej z zastosowaniem pierwotnego zbioru parametrów fizjologicznych pacjenta.**

Do realizacji zadania postawionego w tezach pracy autor podjął prace badawcze, które obejmowały opracowanie i zaimplementowanie metod redukcji zbioru różnego rodzaju parametrów fizjologicznych pacjenta, a także weryfikację opracowanych algorytmów przy użyciu rzeczywistych zbiorów danych.

## **2. Obecnie stosowane systemy do oceny stanu ogólnego pacjenta**

### **2.1.Modified Early Warning Score (MEWS)**

Zmodyfikowany Wskaźnik Wczesnego Ostrzegania (MEWS) to prosty współczynnik używany do szybkości określenia stanu pacjenta. Jest on oparty na danych pochodzących z czterech odczytów parametrów fizjologicznych (skurczowe ciśnienie krwi, tętno, częstość oddechów, temperatura ciała) i jedną obserwacją na podstawie wpisu pielęgniarki – poziom świadomości (możliwe wartości to AVPU [Alert (świadomy), Voice (reaguje na głos), Pain (reaguje na ból), Unresponsive (brak reakcji)]) [12][9].

### **2.2.APACHE III**

Acute Physiology, Age and Chronic Health Evaluation (APACHE III) jest wskaźnikiem opierającym się na metodzie wprowadzonej w 1991 roku przez Knausa, składającym się z punktów [40]:

- za nieprawidłowości fizjologiczne (zakres od 0 do 252) – 17 zmiennych fizjologicznych odzwierciedlających wartości życiowe, badania laboratoryjne i stan neurologiczny;
- za wiek (od 0 do 24);
- za współistniejące choroby przewlekłe (od 0 do 23) [8].

Sumując wyniki z trzech wymienionych kategorii otrzymujemy ostateczną wartość współczynnika APACHE III (zakres od 0 do 299). Współczynnik ten może być używany do pomiaru stopnia zaawansowania choroby i porównywania stanu pacjentów w ramach jednej kategorii diagnostycznej lub niezależnie od posiadanego schorzenia.

### **2.3.Therapeutic Intervention Scoring System**

Terapeutyczna Skala Interwencji Medycznych (TISS – The Therapeutic Intervention Scoring System) została wprowadzona w 1974 roku i stała się powszechnie stosowaną metodą klasyfikacji pacjentów znajdujących się w stanie krytycznym. Ze względu na ciągły



rozwój dziedzin nauki stosowanych w oddziałach intensywnej opieki medycznej (medycyny, elektroniki, informatyki) wskaźnik ten był wielokrotnie aktualizowany. W przeciwieństwie do innych systemów punktacji, TISS nie jest wskaźnikiem służącym do określenia stanu ogólnego pacjenta lub stopnia zaawansowania choroby. Skala TISS służy do określenia kosztów opieki nad pacjentem hospitalizowanym na Oddziale Intensywnej Opieki Medycznej oraz do kalkulacji czasu pracy personelu medycznego niezbędnego do pełnej opieki nad chorym. Jedną z odmian systemu TISS – TISS-28 – stosowaną jest w Polsce. Formularz TISS-28 składa się z 28 pytań (odpowiedź tak/nie) podzielonych na 7 grup: czynności podstawowe, oddychanie, krążenie krwi, nerki, metabolizm, ośrodkowy układ nerwowy, inne interwencje [10].

### 3. Metody sztucznej inteligencji

#### 3.1. Sztuczne sieci neuronowe

Wymienienie wszystkich dziedzin nauki i życia, w jakich stosowane są sztuczne sieci neuronowe jest zadaniem trudnym. Ciągły rozwój metod sztucznej inteligencji jest motorem do prób zastosowania sieci neuronowych w miejscach, w których do tej pory nie były stosowane. Sztuczne sieci neuronowe wykorzystywane są w różnych dziedzinach, takich jak:

- ekonomia;
- statystyka;
- medycyna;
- przewidywanie wyniku zawodów sportowych;
- prognozowanie postępów w nauce;
- diagnostyka układów elektronicznych;
- selekcja celów śledztwa w kryminalistyce;
- analiza spektralna;
- planowanie remontów maszyn;
- poszukiwanie ropy naftowej;
- sterowanie procesów przemysłowych;
- klasyfikacja i identyfikacja obrazów, dokumentów, danych.

Zaletą sztucznych sieci neuronowych jest ich uniwersalność – mogą być zaimplementowane zarówno programowo, jak i w warstwie sprzętowej (np. w postaci układów VLSI [14][15]).

Algorytmy sztucznych sieci neuronowych mogą wypracowywać wnioski dzięki zakodowanej w nich wiedzy lekarskiej dotyczącej związków między elementami różnorodnych sytuacji fizjologicznych i patologicznych oraz umożliwić uczenie się systemu przez porównanie zestawu danych wejściowych oraz informacji pochodzących od lekarza (rozpoznanie).

Zastosowanie sztucznych sieci neuronowych w medycynie jest bardzo szerokie. SSN są stosowane m.in. przy:

- analizie przebiegów sygnałów EKG, EEG i innych – w szczególności przy wykrywaniu niebezpiecznych symptomów;
- analizie obrazów – rozpoznawaniu i interpretacji różnego typu obrazów z aparatury medycznej;
- klasyfikacji i ocenie stanu pacjenta – rozpoznawaniu symptomów oznaczających pogorszenie stanu pacjenta;
- wspomaganie dalszego leczenia – optymalizacji sposobu leczenia, sugerowaniu odpowiedniej terapii.

### 3.2. Sieci bayesowskie

W XVIII wieku brytyjski matematyk i duchowny Thomas Bayes sformułował twierdzenie teorii prawdopodobieństwa, które pośmiertnie zostało nazwane twierdzeniem Bayesa. Omawiana reguła łączy ze sobą prawdopodobieństwo warunkowe zdarzeń  $P(X|Y)$  oraz  $P(Y|X)$ . Zasada ta mówi nam, jak bezwarunkowe i warunkowe prawdopodobieństwa są ze sobą powiązane, czy mamy do czynienia z prawdopodobieństwem obiektywnym czy subiektywnym. Na przykład jeśli  $X$  jest zdarzeniem „u pacjenta występuje wysoka gorączka”, a  $Y$  jest zdarzeniem „pacjent ma grypę”, twierdzenie Bayesa pozwala przeliczyć znany odsetek gorączkujących wśród chorych na grypę i znane odsetki gorączkujących i chorych na grypę w całej populacji, na prawdopodobieństwo, że ktoś jest chory na grypę, gdy wiemy, że ma wysoką gorączkę

Sieci bayesowskie, będące zaawansowaną formą probabilistycznego podejścia opartego o rozumowanie bayesowskie, znalazły wiele zastosowań w aplikacjach medycznych [2][16][17]. Sieć bayesowska składa się z grafu skierowanego opisującego zależności jakościowe pomiędzy zdarzeniami oraz specyfikacji liczbowej opisującej zależności ilościowe. Opis graficzny stosowany w sieciach bayesowskich jest przejrzysty, ekspresywny, łatwy do analizy i modyfikacji, pozwala w wygodny sposób zakodować proces decyzyjny naśladujący ludzkie rozumowanie. Graf pozwala określić związki przyczynowo-skutkowe między zdarzeniami, a tym samym pokazać, które zdarzenia są od siebie warunkowo niezależne. Dzięki koncepcji warunkowej niezależności sieć ma możliwość prowadzenia lokalnych obliczeń, obejmujących niewielki wycinek przestrzeni zmiennych, co zapewnia efektywność obliczeniową. Specyfikacja liczbową jest podawana dla węzłów grafu i obejmuje prawdopodobieństwa bezwarunkowe i warunkowe, uzależnione od stanu węzłów-rodziców

danego węzła. W przeciwieństwie do np. sieci neuronowych, pełna specyfikacja (struktura, wartości liczbowe) jest zrozumiała i łatwa do analizy przez człowieka, może być też przez człowieka opracowana. Daje to możliwość zakodowania fragmentu wiedzy i doświadczenia lekarza w postaci algorytmu numerycznego. Sieci tego typu mają możliwość uczenia maszynowego, zarówno struktury, jak i specyfikacji liczbowej, na podstawie danych historycznych, co umożliwia ich opracowanie na podstawie badań klinicznych przeprowadzonych w projekcie. Dodatkowo, możliwe jest, w przypadku długotrwałego monitorowania pacjenta, dostosowanie algorytmu do jego specyfiki na podstawie danych pomiarowych i decyzji (rozpoznania) lekarza.

### **3.3. Drzewa decyzyjne**

Jedną z bardzo popularnych technik wykorzystywanych do analizy danych są drzewa decyzyjne [7]. Drzewem decyzyjnym nazywamy drzewo-graf, które można przedstawić jako graficzną metodę wspomagania procesu podejmowania decyzji (klasyfikacji). Obraz drzewa decyzyjnego składa się z:

- korzenia (wierzchołka w którym podejmowana jest pierwsza decyzja);
- gałęzi (łączyjących ze sobą wierzchołki, określających liczbę możliwych wariantów – wartości atrybutów);
- węzłów (wierzchołków, z których wychodzi co najmniej jedna gałąź);
- liści (wierzchołków końcowych – bez gałęzi wychodzących).

Drzewo decyzyjne jest grafem składającym się z wierzchołków (atrybutów) i gałęzi reprezentujących wartości tego atrybutu. Metoda drzewa decyzyjnego opiera się na analizie różnych przypadków opisanych przez pewne zestawy atrybutów. Każdy z atrybutów przyjmuje pewne wartości dyskretne (w przypadku zmiennych ciągłych wskazana jest dyskretyzacja poprzez wprowadzenie przedziałów).

Odpowiednia klasyfikacja polega na przejściu od korzenia do liścia i przypisaniu do danego przypadku klasy (decyzji) zapisanej w liściu. Możliwe jest to dzięki podziale złożonego problemu na zadania, kolejno na mniejsze zadania i podzadania, aż do momentu, w którym będzie możliwe podjęcie jednoznacznej decyzji. W każdym wierzchołku sprawdzany jest pewien warunek (atrybut) dotyczący danego przypadku, i na jego podstawie wybierana jest jedna z gałęzi prowadząca do kolejnego węzła (liścia).

## 4. Metodyka badań

### 4.1. Motywacja

Badania prowadzone w ramach niniejszej pracy stanowią jedną z części interdyscyplinarnego projektu finansowanego przez Narodowe Centrum Nauki pod tytułem „Zautomatyzowany system wieloparametrowej oceny stanu ogólnego pacjenta z pogłębioną analizą funkcji układu oddechowego i układu krążenia”, realizowanego wspólnie przez Katedrę Mikroelektroniki i Technik Informatycznych Politechniki Łódzkiej oraz Uniwersytecki Szpital Kliniczny nr 1 im. N. Barlickiego Uniwersytetu Medycznego w Łodzi.

Główną ideą projektu jest opracowanie nowatorskiego systemu monitorującego, wspomagającego w czasie rzeczywistym podejmowanie decyzji medycznych, związanych z oceną stanu ogólnego pacjenta, na podstawie wielorakich danych zbieranych przez typowy monitor funkcji życiowych; system zostanie wykonany w postaci zminiaturyzowanego urządzenia dołączonego do wybranego modelu monitora. Istotnym z punktu widzenia medycyny jest również przeprowadzenie dogłębnej analizy krzywej oddechowej, wyznaczonej przez monitor funkcji życiowych, w celu określenia jej przydatności jako istotnego składnika oceny stanu pacjenta. W omawianym projekcie biorą udział pracownicy i doktoranci Katedry Mikroelektroniki i Technik Informatycznych Politechniki Łódzkiej oraz Uniwersytecki Szpital Kliniczny nr 1 im. N. Barlickiego Uniwersytetu Medycznego w Łodzi, co przedstawia tabela.

Tabela 4.1 Wykonawcy projektu

<b>Politechniki Łódzka</b>	<b>Uniwersytet Medyczny w Łodzi</b>
Prof. dr hab. inż. Andrzej Napieralski	Prof. dr hab. n. med. Paweł Górski
Prof. dr hab. inż. Zygmunt Ciota	Dr n. med. Tomasz Waszyrowski
Dr hab. inż. Mariusz Zubert	Lek. med. Sebastian Majewski
Dr inż. Wojciech Tylman	
Mgr inż. Zbigniew Kulesza	
Mgr inż. Maciej Wenerski	
Mgr inż. Paweł Marciniak	
Mgr inż. Radosław Tomala	
Mgr inż. Rafał Kotas	


W ramach prac prowadzonych w projekcie autor brał czynny udział przy projektowaniu i realizacji aplikacji napisanej w języku C++, służącej do zbierania danych klinicznych z monitora funkcji życiowych. Transmisja parametrów odbywa się w trybie rzeczywistym. Za jej pomocą zapisywane są dane pacjentów z komercyjnego monitora funkcji życiowych. Jest to podstawą do implementacji i weryfikacji algorytmów sztucznej inteligencji.



Rysunek 4.1 Monitor funkcji życiowych Emtel FX2000-MD

Ze względu na fakt, że system sztucznej inteligencji ma działać w trybie rzeczywistym i powinien umożliwiać interakcję z personelem medycznym, został dokonany wybór sprzętu elektronicznego, na którym mają zostać zaimplementowane algorytmy decyzyjne.

Najprostszym wyborem spełniającym takie wymagania jest komputer przenośny wyposażony w ekran dotykowy. Ten wybór ma swoje wady – najważniejszą z nich jest obudowa takiej jednostki: dwa elementy połączone zawiasowo i zewnętrzne źródło energii nie gwarantują wymaganej solidności, zwłaszcza, jeśli urządzenie ma być stosowane w ambulansach. Innym możliwym rozwiązaniem byłby tablet lub smartfon z dużym ekranem. Problem w tym wypadku jest podobny, jak w przypadku standardowego komputera przenośnego i dodatkowo może wymagać zewnętrznych urządzeń peryferyjnych, takich jak zasilacz, głośnik, ewentualnie klucz-konwerter interfejsu Ethernet. Problemy te spowodowały, że do implementacji algorytmów wybrana została platforma Embest DevKit8500 z procesorem Cortex- A8, procesorem graficznym TMS320C64x oraz akceleratorem grafiki POWERVR SGX.



Rysunek 4.2 Platforma implementacji algorytmów Embest DevKit8500D

Na wymienionej platformie sprzętowej mogą zostać zainstalowane i wspierane systemy operacyjne: Android, Ångström, Windows i Linux.

## 4.2. Aplikacja testowania algorytmów

W celu przetestowania omawianego modelu sztucznych sieci neuronowych autorzy zaprojektowali dedykowaną aplikację. Program ten został napisany w języku C# i posiada właściwości pozwalające na [A3]:

- modelowanie wielowarstwowych sieci neuronowych bez sprzężenia zwrotnego;
- wybór liczby warstw ukrytych;
- określenie metody nauczania (dwie nadzorowane metody nauczania zostały wdrożone – algorytm wstecznej propagacji błędów oraz jego modyfikacja w postaci metody gradientów sprzężonych);
- zdefiniowanie liczby neuronów w każdej warstwie ukrytej;
- ustawienie współczynnika uczenia;
- wybór metody wstecznej propagacji z współczynnikiem momentum. Wprowadzanie tego współczynnika pomaga uniknąć problemów oscylacji (które mogą wystąpić w podstawowej wersji algorytmu wstecznej propagacji błędów) i utknięcia w lokalnym minimum;
- zdefiniowanie współczynnika nachylenia funkcji aktywacji;
- dodanie wejścia Bias do warstwy wejściowej i do każdej z warstw ukrytych;

- zdefiniowanie warunku końca nauki. Oprogramowanie pozwala na zakończenie uczenia przez ustawienie maksymalnego błędu (który jest liczony po prezentacji wszystkich wzorców ze zbioru uczącego) lub określenie maksymalnej liczby iteracji;
- określenie początkowych wag. Użytkownik ma dwie możliwości: losowanie wag (w zakresie od -0,2 do 0,2) lub załadowanie wag z pliku;
- zapisanie wag (początkowych i końcowych) do pliku;
- normalizowanie zestawu danych (wejścia i wyjścia). Normalizacja nie dotyczy wejść dwustanowych (binarnych). Użytkownik może wybrać jeden z trzech sposobów normalizacji:
  - „binarny” – tryb ten klasyfikuje wejścia numeryczne (np. stężenia cholesterolu, ciśnienie spoczynkowe krwi) do pewnych grup, jak pokazano w tabeli 3. Przynależność do grupy jest zakodowana wartościami binarnymi (nowymi wejściami sieci). Korzystając z tej metody liczba wejść zwiększa się (3-4 grupy – 2 wejścia, 5-8 grupy – 3 wejścia, itp.).

Tabela 4.2 Normalizacja „binarna”

<b>Ciśnienie spoczynkowe krwi (CSK)</b>		
Wejście [x <sub>1</sub> ]	Warunek	Wejścia [x <sub>1</sub> , x <sub>2</sub> ] po normalizacji
80	CSK<100	0,0
120	100≤CSK<135	0,1
160	135≤CSK<170	1,0
220	170≤CSK<205	1,1

- „binarny rozszerzony” – tryb ten klasyfikuje wejścia numeryczne (takie jak poziom cholesterolu, ciśnienie spoczynkowe krwi) do pewnych grup, jak pokazano w tabeli 4.3. W tym przypadku liczba wejść (po normalizacji) jest zawsze równa liczbie grup.

Tabela 4.3 Normalizacja „binarna rozszerzona”

<b>Ciśnienie spoczynkowe krwi (CSK)</b>		
Wejście [x <sub>1</sub> ]	Warunek	Wejścia [x <sub>1</sub> , x <sub>2</sub> ] po normalizacji
80	CSK<100	0,0,0,1
120	100≤CSK<135	0,0,1,0
160	135≤CSK<170	0,1,0,0
220	170≤CSK<205	1,0,0,0

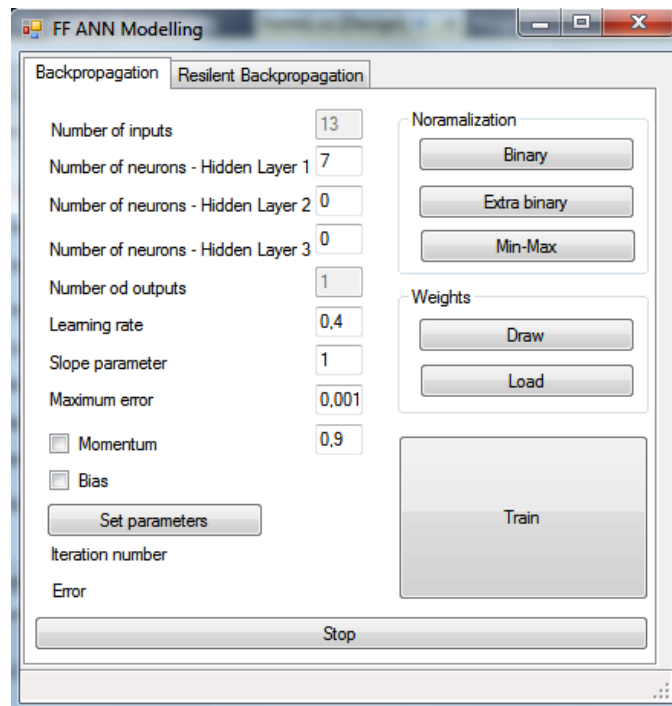


- o „min – max” – normalizacja ta może być opisana za pomocą następującego równania:

$$f(x) = \frac{x - \min(x)}{\max(x) - \min(x)}, \quad (4.1)$$

gdzie  $\min(x)$  i  $\max(x)$  są to odpowiednio minimalne i maksymalne wartości ze zbioru wartości danego wejścia. W tym przypadku liczba wejść (przed i po normalizacji) jest stała.

W wyniku użycia normalizacji "binarnej" i "binarnej rozszerzonej" można uzyskać na wejściu tylko dwie wartości –  $\{0,1\}$ . Użycie normalizacji "min-max" powoduje, że na wejściu sieci może się pojawić dowolna liczba z przedziału  $[0,1]$ .



Rysunek 4.3 Program do modelowania sztucznych sieci neuronowych [A3]

Badania skuteczności metod proponowanych w niniejszej pracy zostały przeprowadzone na podstawie danych z dwóch baz danych.

Baza danych **Cleveland** została opracowana przez dr. Robert Detrano z V.A. Medical Center, Long Beach and Cleveland Clinic Foundation. Baza ta składa się z danych zapisanych podczas badania 303 pacjentów. Sześciu pacjentów z powodu błędów z zapisie niektórych parametrów zostało odrzuconych. Każdy pacjent opisany został przez 13 parametrów medycznych (pola wejściowe). Czternasty parametr (wyjściowy) oznacza ogólny stan

pacjenta ze szczególnym uwzględnieniem chorób serca. Parametr ten przyjmuje wartości od 0 do 4, gdzie wartość 0 oznacza zdrowego pacjenta, natomiast wartość 4 dotyczy pacjenta w najgorszym stanie.

Druga baza danych **Łódź** zebrana została przez lekarzy jednego z łódzkich szpitali klinicznych. Zawiera dane od 73 pacjentów opisanych przez 67 wielorakich parametrów pochodzących z różnego typu badań fizjologicznych. Dotyczą one między innymi sygnału EKG, parametrów chemicznych krwi, ogólnego stanu i wydolności serca. W bazie tej znajdują się również informacje na temat pacjenta spisywane podczas przyjęcia do szpitala – są to np. wiek, płeć. Parametr wyjściowy wpisany do bazy odwołuje się do wywiadu zrobionego z pacjentem po okresie dwóch lat od hospitalizacji.

### **4.3. Redukcja wymiarowości danych**

W rozdziale tym zaprezentowane zostały matematyczne narzędzia służące redukcji wymiaru danych w klasyfikacji. Przedstawione metody stosowane są w eksploracyjnej analizie danych z wielowymiarowej przestrzeni. Zadaniem tych rozwiązań jest wyrażenie wielowymiarowych obserwacji przy użyciu małej liczby współrzędnych, przy zachowaniu oryginalnych relacji między nimi. Odbywa się to poprzez identyfikację i eliminację nieistotnych nadmiarowych informacji w zbiorze danych. Redukcja wymiarowości jest etapem przygotowującym dane, który może być wdrożony przed właściwym algorytmem klasyfikacji, regresji lub innych metod sztucznej inteligencji. Cechy otrzymane w wyniku tego etapu mogą być następnie wykorzystane przez inne procedury analiz wielowymiarowych. Poprzez zastosowanie tego typu analiz możliwe jest zwizualizowanie danych wielowymiarowych na płaszczyźnie lub wykresie trójwymiarowym. Niekiedy do wyznaczenia istotnych cech można wykorzystać wykres współrzędnych równoległych (parallel coordinates plot). Prezentuje on zmienne wielowymiarowe w postaci wykresu dwuwymiarowego, pozwala również określić, jak zmieniają się wartości poszczególnych cech dla tych samych obserwacji [4].

Redukcja danych pozwala odnieść następujące korzyści:

- zwiększyć efektywność uczenia – redukcja wymiaru umożliwia wybór istotnych cech z punktu widzenia zadania klasyfikacji. Pozwala to zredukować

efekt przeuczenia, polegający na zbyt mocnym dopasowaniu klasyfikatora do danych uczących;

- zmniejszyć czas uczenia – w niektórych metodach wzrost liczby wymiarów powoduje więcej niż proporcjonalny wzrost czasu działania algorytmu;
- zmniejszyć wymagania dotyczące maszyny obliczeniowej;
- zmniejszyć złożoność struktury danych wejściowych – umożliwia to lepszą interpretację zidentyfikowanych sygnałów;
- wyeliminować błędy i szumy ze zbioru uczącego – pozwala to na eliminację cech nieistotnych dla zadania klasyfikacji;
- uzyskać kompromis pomiędzy poziomem kompresji danych wejściowych a skutecznością działania klasyfikatora.

Matematyczne metody mające na celu redukcję danych mogą być oparte o **konstrukcję cech**. W takim modelu  $n$  cech wejściowych zostaje poddanych pewnej transformacji, w wyniku której nowe zmienne wyjaśniają całość (lub zdecydowaną większość) zakodowanej informacji przy zmniejszonej liczbie danych wejściowych. Przykładami takiego typu analizy mogą być:

- analiza czynnikowa;
- analiza składowych głównych;
- skalowanie wielowymiarowe.

#### **4.4. Adaptacja danych medycznych**

Wykorzystując dwie dostępne bazy danych autor zdecydował się na badania nad odpowiednim przygotowaniem danych wejściowych. Jest to istotne z punktu widzenia projektu, w którym przeprowadzana będzie analiza wielu danych w trybie rzeczywistym. W dostępnej autorowi literaturze analiza składowych głównych w aplikacjach medycznych stosowana jest wyłącznie do analizy sygnału EKG.

Autor w niniejszej pracy proponuje zastosowanie analizy korespondencji i analizy składowych głównych w przypadku wielorakiego rodzaju parametrów fizjologicznych. Są to dane wyrażone zarówno na skali proporcjonalnej, jak i nominalnej.

W przypadku danych jakościowych autor przeprowadził ich dekompozycję. Pomimo że sieci neuronowe są w stanie rozwiązywać złożone problemy nieliniowe to zastosowanie binaryzacji sygnałów jakościowych poprawiło skuteczność działania sieci. Może to być związane z błędnym (przypadkowym) kodowaniem zmiennych jakościowych przez lekarzy. W takim przypadku mogą pojawiać się znaczne nieliniowości, które mogą utrudniać poprawne rozpoznanie przez sieć neuronową.

Binaryzacja danych jest często wykonywanym procesem, jeżeli w zbiorze danych uczących sieci neuronowej występują zmienne na skali nominalnej. Jak można zauważyć z badań przeprowadzonych przez autora, dekompozycja danych podnosi skuteczność predykcyjną sieci.

W przypadku danych z bazy w Cleveland, w której występowało stosunkowo dużo danych jakościowych przeprowadzono porównanie wyników skuteczności działania sieci w przypadku danych oryginalnych oraz danych po dekompozycji. Operacja ta spowodowała zwiększenie się liczby danych wejściowych z 13 do 25. Dla lepszej generalizacji wniosków każdy rodzaj sieci przebadany został 100 razy (wykorzystując różne wagi początkowe). Przebadane zostały sieci o następujących metodach uczenia:

- największego spadku;
- gradientów sprzężonych;
- algorytmu zmiennej metryki (BFGS).

Każda z metod uczenia sieci przebadana została z dwiema różnymi funkcjami aktywacji – logistycznej oraz tangensa hiperbolicznego.

Wszystkie przedstawione badania zostały przeprowadzone dla losowo podzielonego zbioru danych. Przebadane zostały przypadki, w których zbiór uczący wynosił 50%, 60%, 70% oraz 80%. Wszystkie porównywane ze sobą skuteczności działania sieci odnoszą się do dokładnie takiego samego zbioru uczącego. W uczeniu sieci brał udział również zbiór testowy. Służył on weryfikacji algorytmu uczenia i pozwalał na zatrzymanie procesu uczenia w przypadku zwiększania się liczby błędnie rozpoznanych wzorców w zbiorze testowym. Był on zabezpieczeniem procesu uczenia przed nadmiernym dopasowaniem się zbioru uczącego (przeuczeniem).

## 4.5. Redukcja parametrów medycznych

W celu ograniczenia liczby parametrów wejściowych sieci neuronowej została zastosowana metoda konstrukcji nowych cech w oparciu o ideę składowych głównych. W dostępnej autorowi literaturze istnieje kilka pozycji opisujących zastosowanie tej metody do redukcji danych charakteryzujących przebieg EKG [11][13][3]. Autor proponuje wykorzystanie tej metody do redukcji różnego rodzaju parametrów pochodzących z typowego monitora funkcji życiowych. Oprócz parametrów z przebiegu EKG występują tam również informacje na temat składu chemicznego krwi oraz innych parametrów charakteryzujących pracę serca i ogólny stan pacjenta.

W celu redukcji danych wejściowych modułu decyzyjnego (sieci neuronowej) został skonstruowany zredukowany zbiór zawierający liniowo niezależne parametry wejściowe. Na poniższym rysunku przedstawiony został wykres osypiska prezentujący odsetek całkowitej wariancji wyjaśnianej przez odpowiednią liczbę nowych parametrów.

Tabela 4.4 Skuteczność odwzorowania zmiennych pierwotnych dla bazy danych Cleveland

Numer	Wartość własna nowej cechy	Wariancja poszczególnych nowych cech (%)	Skumulowana jakość odwzorowania (%)
1	5,93	23,73	23,73
2	3,44	13,76	37,49
3	2,67	10,66	48,15
4	2,19	8,75	56,91
5	2,11	8,45	65,37
6	1,39	5,57	70,94
7	1,27	5,09	76,04
8	1,09	4,37	80,42
9	0,97	3,87	84,29
10	0,76	3,05	87,34
11	0,67	2,69	90,04
12	0,64	2,54	92,58
13	0,53	2,12	94,71
14	0,49	1,97	96,68
15	0,24	0,95	97,64
16	0,16	0,63	98,27
17	0,14	0,56	98,83
18	0,11	0,45	99,29
19	0,10	0,4	99,69
20	0,08	0,31	100,0

Tabela 4.4 prezentuje wartości własne i skumulowaną wartość wariancji dla odpowiedniej liczby parametrów.

Jak widać zarówno z tabeli, jak i wykresu osypiska, zastosowanie 20 z 25 nowych liniowo niezależnych składowych gwarantuje zachowanie jakości odwzorowania na poziomie 100%. Należy również zauważyć, że w przypadku ograniczenia liczby nowych parametrów do wartości sprzed dekompozycji zachowana skumulowana wariancja przekracza 90%. Istnieje zatem duże prawdopodobieństwo poprawnego odwzorowania struktury procesu przy pomocy jedynie połowy zmiennych. Badania sprawdzające skuteczność działania sieci neuronowej dla różnej liczby nowych niezależnych liniowo parametrów zostały przeprowadzone i umieszczone w tabelach 5.12-5.14.

#### **4.6. Sieć neuronowa po redukcji**

Po przeprowadzeniu redukcji danych i wybraniu 13 parametrów z uzyskanych po dekompozycji 25 przeprowadzone zostały badania skuteczności działania sieci neuronowej. Należy zauważyć, że dla 20 z 25 parametrów jakość odwzorowania struktury danych wynosi 100%. W pracy porównane zostały wyniki działania sieci neuronowej po wykonaniu redukcji danych wejściowych ze skutecznością sieci dla zmiennych wejściowych zbinaryzowanych. Wszystkie badania zostały przeprowadzone dla 4, 6, 8, 10, 12, 14, 16, 18, 20, 22 oraz 24 neuronów w warstwie ukrytej.

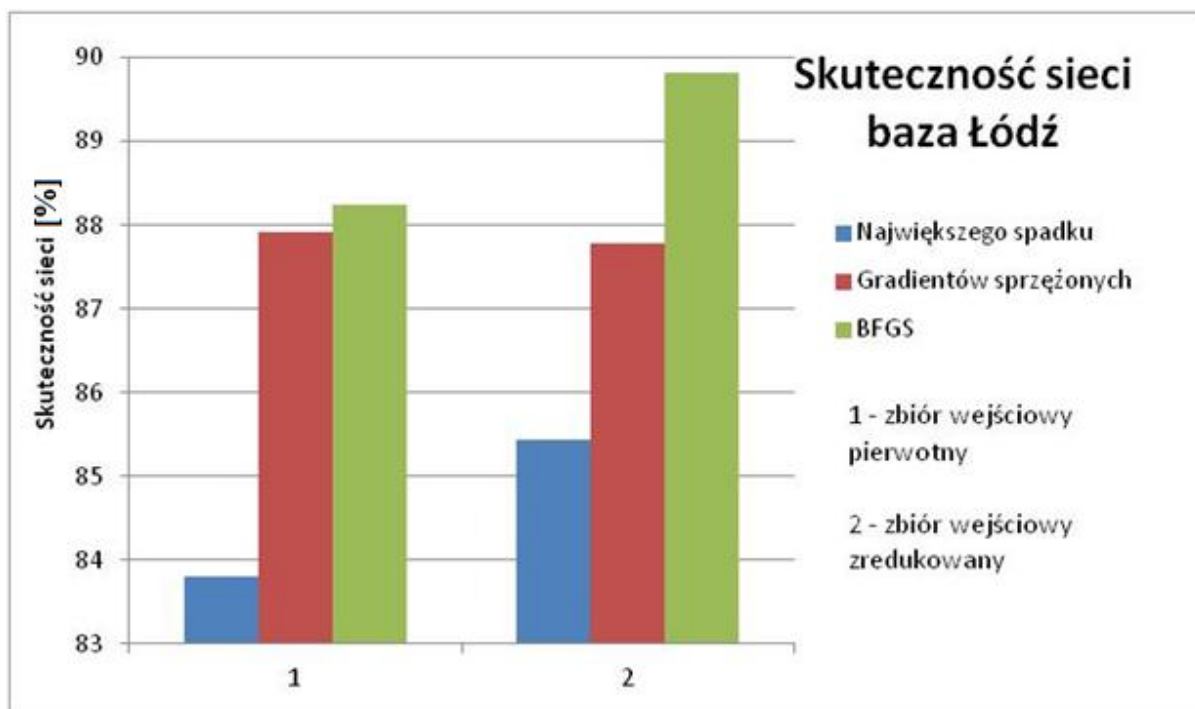
**Poniżej przedstawiono porównanie skuteczności uczenia sieci przed dekompozycją i po dekompozycji:**

- Pierwszą testowaną metodą uczenia była metoda największego spadku. Dla trzech przypadków redukcja liniowych zależności przyniosła poprawę skuteczności działania sieci. Jedynie w przypadku zbioru uczącego 50% sieć po redukcji osiągnęła nieznacznie gorszą skuteczność działania. Należy jednak zauważyć, że dla zbioru uczącego 50% proces uczenia sieci metodą największego spadku utykał w lokalnym minimum (dla wszystkich 100 przypadków uczenia). Miało to miejsce dla sieci zarówno przed redukcją, jak i po redukcji, niezależnie od liczby neuronów w warstwie ukrytej. Największy wzrost skuteczności sieci zaobserwowano dla zbioru uczącego 80%. W tym

przypadku proces nauki również zatrzymywał się w lokalnym minimum (przed redukcją oraz po redukcji).

- Drugą porównaną metodą była metoda gradientów sprzężonych. Dla wszystkich zbiorów uczących redukcja liniowych zależności przyniosła poprawę skuteczności uczenia. Największy przyrost skuteczności wystąpił dla zbioru uczącego 80%. W przypadku sieci po redukcji i binaryzacji, gdy zbiorem uczącym była połowa całego zbioru danych, uzyskano największą skuteczność uczenia. W porównaniu do procesu uczenia metodą największego spadku, dla wszystkich przypadków, oprócz jednego, zaobserwowano poprawę skuteczności działania sieci. Jedynym wyjątkiem jest przypadek zbioru uczącego 80% oraz 24 neuronów w warstwie ukrytej, gdzie skuteczność sieci była jednakowa (92,31%).
- Ostatnią sprawdzoną metodą był algorytm zmiennej metryki (BFGS). Dla wszystkich przypadków (uwzględniając liczbę neuronów w warstwie ukrytej oraz rozmiar zbioru uczącego) zaobserwowano poprawę skuteczności działania sieci, podobnie jak w przypadku uczenia metodą gradientów sprzężonych. Największa poprawa oraz największa bezwzględna wartość skuteczności uczenia uzyskana została dla zbioru uczącego 80%.

Podobne obliczenia przeprowadzone zostały również dla bazy danych z Łodzi. Na rysunku 4.4 przedstawione zostały porównania skuteczności działania sieci dla trzech stosowanych algorytmów uczenia. Do zbioru zredukowanego użyto 32 nowych zmiennych – odpowiada to 95.29% użytecznej informacji. Wartość ta została wybrana po rozmowach z lekarzami ze Szpitala im. Barlickiego w Łodzi, którzy na podstawie doświadczenia i literatury uznali, że minimalna wartość użytecznej informacji branej pod uwagę przy uczeniu powinna wynosić 95%. Badania zostały przeprowadzone dla przypadku, gdy liczba neuronów w warstwie ukrytej wynosiła 12. Dla tak skonstruowanej sieci otrzymywane były najwyższe skuteczności działania sieci. Można zatem uznać, że prezentowana struktura sieci neuronowej została dobrana optymalnie pod względem skuteczności uczenia. Dla innej (większej lub mniejszej) liczby neuronów w warstwie ukrytej otrzymano niższą jakość nauczania. Na rysunku 4.4 przedstawione zostały wyniki uśrednione dla 100 przypadków uczenia.



Rysunek 4.4 Porównanie skuteczności uczenia sieci przed redukcją i po redukcji dla bazy danych z Łodzi

Z przedstawionych badań wynika, że po zastosowaniu redukcji danych liniowo zależnych ograniczono liczbę parametrów z 25 do 20 przy zachowaniu 100% użytecznej informacji. Porównania przeprowadzone dla metody gradientów sprzężonych, metody największego spadku oraz algorytmu BFGS pokazują, że redukcja danych do 13 parametrów pozwala na uzyskanie co najmniej takiej samej jakości predykcyjnej jak przed redukcją. Podobny wniosek można wyciągnąć dla bazy danych z Łodzi. 67 parametrów pierwotnych zostało zredukowanych do 57 nowych zmiennych przy zachowaniu 100% informacji. Do nauki sieci neuronowej wykorzystano 32 nowe zmienne (co odpowiada 95,29% informacji) i, tak jak pokazuje rysunek 4.4, dla wszystkich algorytmów uczenia uzyskano skuteczność sieci przynajmniej na podobnym poziomie. **Dowodzi to tezy drugiej niniejszej rozprawy doktorskiej.**

**Poniżej przedstawiono porównanie skuteczności uczenia sieci przed dekompozycją i po dekompozycji i redukcji:**

- Metoda największego spadku - dla wszystkich rozmiarów zbioru uczącego nastąpiła poprawa skuteczności działania sieci. Z tabeli można odczytać, że zysk z przeprowadzenia dekompozycji i redukcji rośnie wraz ze zwiększaniem zbioru uczącego. Dla sieci pierwotnej największa skuteczność uczenia osiągnięta została



dla zbioru uczącego 60%. W przypadku binaryzacji i redukcji największą skuteczność zaobserwowano dla zbioru uczącego 80%.

- Metoda gradientów sprzężonych - wszystkie przebadane sieci wykazywały wzrost skuteczności działania w wyniku dekompozycji i redukcji liniowych zależności. Największa poprawa skuteczności została zaobserwowana dla zbioru uczącego 80%. Najwyższa bezwzględna wartość skuteczności sieci po redukcji danych liniowo zależnych została osiągnięta dla zbioru uczącego 50%. W przypadku sieci pierwotnej sytuacja ta miała miejsce dla zbioru uczącego 60%.
- Algorytm zmiennej metryki (BFGS) - wykonanie dekompozycji danych, zastosowanie metody redukcji danych liniowo zależnych i odrzucenie czynników niosących najmniej informacji (tak, aby uzyskać taką samą liczbę zmiennych wejściowych) dla wszystkich przebadanych przypadków poprawiło skuteczność uczenia. Algorytm BFGS największą skuteczność (ponad 92%) uzyskał dla zbioru uczącego 80%. Dla innych rozmiarów zbioru uczącego skuteczność wynosiła ok. 90%.

Na podstawie powyższych badań można wnioskować, że dekompozycja parametrów jakościowych stanu kardiologicznego pacjenta wraz z usunięciem liniowych zależności wszystkich parametrów umożliwia wzrost skuteczności rozpoznania stanu kardiologicznego przy jednoczesnym zachowaniu takiej samej liczby parametrów wejściowych. **Dowodzi to tezy pierwszej niniejszej rozprawy doktorskiej.**

## 5. Uwagi i wnioski końcowe

W rozprawie zostały przedstawione metody sztucznej inteligencji wykorzystywane przy zadaniu klasyfikacji. Algorytmy sieci neuronowych wykorzystywane w badaniach przeprowadzonych w ramach niniejszej pracy mogą zostać zaimplementowane w docelowym systemie mikroprocesorowym, będącym przystawką do monitora funkcji życiowych. Zaproponowany sposób redukcji pozwala na wykonanie analizy klasyfikacji i podjęcia decyzji w oparciu o mniejszą liczbę cech. Jest to kwestią istotną w przypadku takiego rozwiązania, jak omawiana przystawka do monitora funkcji życiowych, która musi analizować wiele zmiennych w trybie rzeczywistym i na ich podstawie podjąć decyzję co do sugerowanego rozpoznania lekarskiego. Układ rozpoznający, którego składowym zadaniem jest klasyfikacja, może dopuszczać zwiększenie liczby błędnych decyzji – ważniejszy w takich systemach jest limit czasu nałożony na wykonanie całości zadania. Można do zilustrowania takiego zagadnienia posłużyć się przykładem rozpoznawania twarzy w miejscach publicznych. Nie jest najważniejszym warunkiem fakt, że algorytm decyzyjny na 100% ustalił, że dana osoba jest poszukiwana, jeżeli czas potrzebny do uzyskania tego wyniku był na tyle długi, że osoba ta zdążyła dawno opuścić dane miejsce. W przypadku danych medycznych bardzo istotne jest zachowanie odpowiedniej skuteczności decyzyjnej – błąd w takim przypadku może wiązać się z poważnymi konsekwencjami zdrowotnymi. Oczywiście nad każdym systemem stoi jeszcze pracownik medyczny, który podejmuje ostateczną decyzję co do dalszego postępowania. Nie zmienia to jednak faktu, że od systemów decyzyjnych dotyczących diagnozy i wykrywania sytuacji krytycznych wymaga się szczególnie wysokiej jakości predykcji.

Powyższe rozważania wskazują, że wspomniana minimalizacja danych wejściowych (szybkość działania modułu decyzyjnego) ma w przypadkach medycznych duże znaczenie, ale nie mniejsze niż dokładności przewidywania algorytmów sztucznej inteligencji.

W celu weryfikacji zaproponowanej metody przeprowadzony został szereg czasochłonnych eksperymentów, które zostały przedstawione w rozprawie. Uzyskane wyniki sugerują przydatność zaproponowanej metody. Rezultaty zostały otrzymane dla wielu różnych metod uczenia sieci neuronowej i różnych struktur sieci. Każdy z przypadków podanych w tabelach wyników został uśredniony ze 100 prób uczenia. Daje to możliwość

generalizacji wyników, a nie porównania jedynie najlepszych przypadków uczenia sieci (w przypadku, gdy wagi początkowe zostały optymalnie dobrane).

Sformułowane na początku rozprawy tezy zostały potwierdzone badaniami eksperymentalnymi. Należy jednak zauważyć, że teza 3 jest niemalże tożsama z tezą 1. Jeżeli przyjmiemy, że sygnały wejściowe wyrażone na skali nominalnej w celu lepszej zdolności uczenia sieci neuronowej zostały poddane binaryzacji i taką sieć (z powiększoną liczbą parametrów wejściowych) przyjmiemy jako zbiór wejściowy sieci, to potwierdzona zostanie teza pierwsza. Przyjmując za zbiór danych wejściowych pierwotnie przyjęte parametry (również te wyrażone na skali nominalnej) zastosowanie znajduje tutaj teza trzecia.

Kontynuacją prac związanych z projektem oceny ryzyka nagłego zatrzymania krążenia będzie weryfikacja zaprezentowanej metody w odniesieniu do danych rzeczywistych otrzymywanych z monitora funkcji życiowych. W obecnej chwili aplikacja, której autor jest współtwórcą została oddana do szpitala i za jej pomocą odbywa się zbieranie danych. W przypadku, gdy metoda zostanie pomyślnie zweryfikowana na danych zebranych przez zaprojektowaną aplikację autor podejmie próbę implementacji i walidacji jej w ostatecznej wersji systemu decyzyjnego.

Ponadto autor w dalszych pracach chciałby podjąć próby zastosowania różnego rodzaju metod znajdowania zależności nieliniowych na jej podstawie dokonywania redukcji danych. Ciekawa również wydaje się kwestia zaimplementowania algorytmów pozwalających na jednoczesną analizę danych ciągłych oraz skategoryzowanych.

## 6. Bibliografia

- A1. **Kotas R., Kulesza Z., Tylman W., Napieralski A., Marciniak P.**, *Model of Human Palm Controlled by Glove with Micromachined Accelerometers*, Elektronika – Konstrukcje, Technologie, Zastosowania, Listopad 2010, nr 11/2010, s. 67-70, ISBN 0033-2089
- A2. **Kotas R., Kulesza Z., Tylman W., Napieralski A., Marciniak P.**, *SModel of Human Palm Controlled by Glove with Micromachined Accelerometers*, 17th International Conference Mixed Design of Integrated Circuits and Systems MIXDES 2010, 24-26 June 2010, Wrocław, Poland, wyd. Tech. Univ. Łódź, DMCS, Poland, pp.613-618, ISBN 978-83-928756-3-5
- A3. **Marciniak P., Ciota Z., Kotas R.**, *Classification Support Algorithms for Patient's General Condition Based on Artificial Neural Network*, 20th International Conference Mixed Design of Integrated Circuits and Systems MIXDES 2013, 20-22 June 2013, Gdynia
- A4. **Tomala R., Wenerski M., Marciniak P., Kotas R., Napieralski A.**, *Power Supply and Signal Filtering for 24-Hour ECG*, International Journal of Microelectronic and Computer Science, 2011, Volume 2, Number 1, ISSN 2080-8755
- A5. **Tylman W., Waszyrowski T., Napieralski A., Kamiński M., Kulesza Z., Kotas R., Marciniak P., Tomala R., Wenerski M.**, *System for estimation of patient's state – discussion of the approach*, New Results in Dependability and Computer Systems Volume 224, 2013, pp 501-511
- A6. **Wenerski M., Tomala R., Marciniak P., Kotas R.**, *Fuzzy Logic System For Rectification of Erroneous Measurements Caused by Human Intervention in HPFF Instalation*, International Journal of Microelectronic and Computer Science 2011, Volume 2, Number 1, ISSN 2080-8755
- A7. **Wojnarowski T., Kotas R., Marciniak P., Tomala R., Kulesza Z., Napieralski A.**, *ECG signal filtering for high definition Holter monitoring system*, MEMSTECH 2011 VII-th International Conference: Perspective technologies and methods in mems design, Lviv - Polyana, UKRAINE 11-14 May, 2011, pp.137-141, ISBN 978-966-2191-19-6

1. **Cooper S., Cade J.** Predicting survival, in-hospital cardiac arrest: Resuscitation survival variables and training effectiveness. *Resuscitation*. Vol. 35 (1), ss. 17-22.
2. **F.J. Díez, J. Mira, E. Iturralde, S. Zubillaga.** DIAVAL, a Bayesian expert system for echocardiography. *Artificial Intelligence in Medicine*. 1997, 10, strony 59-73.
3. **Hao Zhang, Li-Qing Zhang.** ECG analysis based on PCA and Support Vector Machines. *International Conference on Neural Networks and Brain*. 2005, 2.
4. **Jambu, M.** *Exploratory and multivariate data analysis*. Orlando : Academic Press, 1991.
5. **Katarzyński, P., Handkiewicz, A., Szczęsny, S., Melosik, M., Naumowicz, M.,** Design of elliptic filters with phase correction by using genetic algorithm, *Przegląd Elektrotechniczny*, Volume 86, Issue 11 A, 2010, strony 69-73.
6. **Katarzyński, P., Handkiewicz, A., Szczęsny, S., Melosik, M., Naumowicz, M.,** *Genetic algorithms in gyrator-capacitor filters*, Proceedings of the 18th International Conference - Mixed Design of Integrated Circuits and Systems, MIXDES 2011 , Article number 6015996, strony 602-607.
7. **Khemphila Anchana, Boonjing Veera.** Comparing performances of logistic regression, decision trees , and neural networks. *Computer Information Systems and Industrial Management Applications*. 2010, 10.
8. **Knaus WA, Wagner DP, Draper EA, Zimmerman JE, Bergner M, Bastos PG, Sirio CA, Murphy DJ, Lotring T, Damiano A.** he APACHE III prognostic system. Risk prediction of hospital mortality for critically ill hospitalized adults. *Chest*. 100, 1991, strony 1619–1636.
9. **McNelis J., Marini C., Kalimi R., Jurkiewicz M., Ritter G., Nathan I.** A comparison of predictive outcomes of APACHE II and SAPS II in surgical intensive care unit. *American Journal of Medical Quality* 2001. 16, strony 161-165.
10. **Miranda DR, de Rijka A, Schaufeli W.** Simplified Therapeutic Intervention Scoring System: The TISS-28 items. Results from a multicenter study. *Crit. Care Med*. 1996, 24, str. 643.
11. **Monasterio V., Laguna P., Martinez, J.P.** Multilead Analysis of T-Wave Alternans in the ECG Using Principal Component Analysis. *IEEE Transactions on Biomedical Engineering*. 2008, 56, strony 1880-1890.

12. **Subbe C.P., Kruger M., Gemmel L.** Validation of a modified Early Warning Score in medical admissions. *Quarterly Journal of Medicine*. 2001, 94, strony 521-526.
13. **Vargas F., Lettnin D., Felippetto de Castro M.C.,** Electrocardiogram pattern recognition by means of MLP network and PCA: a case study on equal amount of input signal types. *Proceedings 7th Brazilian Symposium on Neural Networks, Macarthy M.* 2002, strony 202-205.
14. **Wawryn, K., Strzeszewski, B.,** Current mode circuits for programmable WTA neural network, *Analog Integrated Circuits and Signal Processing*, Volume 27, Issue 1-2, April 2001, strony 49-69.
15. **Wawryn, K.,** AB class current mode multipliers for programmable neural networks, *Electronics Letters*, Volume 32, Issue 20, 1996, strony 1902-1904.
16. **Wemmenhove, B., Mooij J.M., Wiegerinck W., Leisink M., Kappen H.J., Neijt J.P.** Inference in the Promedas Medical Expert System. *Lecture Notes in Computer Science*. 2007, 4594, strony 456-460.
17. **Wiggins M., Saad A., Litt B., Vachtsevanos G.** Evolving a Bayesian classifier for ECG-based age classification in medical applications. *Applied Soft Computing*. 2008, 8, strony 599-608.
18. **Wojtyniak B., Goryński P. , Rabczanko D. i wsp.** *Umieralność przedwczesna i ogólna z powodu chorób układu krążenia w Polsce na tle sytuacji w Unii Europejskiej, Europie i USA.* Warszawa : Państwowy Zakład Higieny, 2007.
19. **Wojtysiak B., Goryński P. i wsp.** *Sytuacja zdrowotna ludności Polski.* Warszawa : Narodowy Instytut Zdrowia Publicznego – Państwowy Zakład Higieny, 2008.